



การฟื้นฟูภาพถ่ายดิจิทัลด้วยการตรวจสอบตัวเองของการเรียนรู้เชิงลึก
Digital Image Restoration Using Self-Validation Deep Learning

อัสวรณ ลิมส์ืบเชื้อ

Asavaron Limsuebchuea

วิทยานิพนธ์นี้สำหรับการศึกษิตตามหลักสูตรปริญญาปรัชญาคุษฎีบัณฑิต
สาขาวิชาวิศวกรรมไฟฟ้า
มหาวิทยาลัยสงขลานครินทร์

**A Thesis Submitted in Fulfillment of the Requirements for the
Degree of Doctor of Philosophy in Electrical Engineering
Prince of Songkla University**

2566

ลิขสิทธิ์ของมหาวิทยาลัยสงขลานครินทร์

ชื่อวิทยานิพนธ์ การฟื้นฟูสภาพถ่ายติจิตอลด้วยการตรวจสอบตัวเองของการเรียนรู้เชิงลึก
 ผู้เขียน นายอัครณ ลิ่มสืบเชื้อ
 สาขา วิศวกรรมไฟฟ้า

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

คณะกรรมการสอบ

..... ประธานกรรมการ
 (รองศาสตราจารย์ ดร.พรชัย พุกฤษัฎทรานนต์) (รองศาสตราจารย์ ดร.ทิมพันธุ์ เจริญพงษ์)

อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม

..... กรรมการ
 (ผู้ช่วยศาสตราจารย์ ดร.รักกฤตว์ ดวงสร้อยทอง)

..... กรรมการ
 (ผู้ช่วยศาสตราจารย์
 ดร. รักกฤตว์ ดวงสร้อยทอง)

..... กรรมการ
 (ผู้ช่วยศาสตราจารย์
 ดร. คุณดาว บุรณะพานิชย์กิจ)

..... กรรมการ
 (ผู้ช่วยศาสตราจารย์ ดร.ชลากร ครุพงศ์ศิริ)

บัณฑิตวิทยาลัย มหาวิทยาลัยสงขลานครินทร์ อนุมัติให้บัณฑิตวิทยาลัย
 สำหรับการศึกษ ตามหลักสูตรปริญญาคุณวุฒิปบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า

.....
 (ผู้ช่วยศาสตราจารย์.ดร.เถกิง วงศ์ศิริ ชาติ)

รักษาการแทนคณบดีบัณฑิตวิทยาลัย

ขอรับรองว่า ผลงานวิจัยนี้มาจากการศึกษาวิจัยของนักศึกษาเอง และได้แสดงความขอบคุณบุคคลที่มีส่วนช่วยเหลือแล้ว

ลงชื่อ.....

(รองศาสตราจารย์ ดร.พรชัย พฤษย์ภัทรานนท์)

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

ลงชื่อ.....

(ผู้ช่วยศาสตราจารย์

ดร.รักกฤตวิวัฒน์สร้อยทอง)

อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม

ลงชื่อ.....

(นายอัศวรณ ลิ่มสืบเชื้อ)

นักศึกษา

ข้าพเจ้าขอรับรองว่า ผลงานวิจัยนี้ไม่เคยเป็นส่วนหนึ่งของการอนุมัติปริญญาในระดับใดมาก่อน
และไม่ได้ถูกใช้ในการยื่นขออนุมัติปริญญาในขณะนี้

ลงชื่อ.....

(นายอัศวรณ ถิมสืบเชื้อ)

นักศึกษา

ชื่อวิทยานิพนธ์	การฟื้นฟูภาพถ่ายดิจิทัลด้วยการตรวจสอบตัวเองของการเรียนรู้เชิงลึก
ผู้เขียน	นายอัศวณ ลิ่มสืบเชื้อ
สาขาวิชา	วิศวกรรมไฟฟ้า
ปีการศึกษา	2565

บทคัดย่อ

การเกิดสัญญาณรบกวนและการถูกลดทอนคุณภาพในภาพถ่ายดิจิทัลสามารถเกิดจากสภาพแวดล้อมภายนอกและความผิดปกติทางไฟฟ้าของอุปกรณ์ถ่ายภาพ โดยปัญหาดังกล่าวส่งผลให้ภาพขาดความคมชัดและทำให้การประมวลผลภาพเกิดความผิดพลาดได้ อีกทั้งในบางสถานการณ์อาจไม่สามารถบันทึกภาพที่มีองค์ประกอบของภาพเช่นเดิมได้อีก ดังนั้นการฟื้นฟูภาพถ่ายดิจิทัลจากภาพที่มีอยู่จึงมีความสำคัญอย่างยิ่งเพื่อให้ได้ภาพที่สามารถนำมาใช้ในการประมวลผลภาพได้ โดยปัจจุบันการประมวลผลภาพด้วยการเรียนรู้เชิงลึกซึ่งเป็นวิธีที่มีประสิทธิภาพที่ดี แต่มักจะใช้ข้อมูลจำนวนมากในการเรียนรู้ ทำให้อาจไม่สามารถนำมาใช้งานที่มีข้อจำกัดของการจัดหาข้อมูลจำนวนมากมาใช้เรียนรู้ได้ โดยงานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาการเรียนรู้เชิงลึกในการฟื้นฟูและกำจัดสัญญาณรบกวนที่มีข้อจำกัดในการจัดหาหรือไม่สามารถจัดหาชุดข้อมูลในการเรียนรู้ได้ เช่นปัญหา single image และ blind noise โดยงานวิจัยนี้ได้นำเสนอหัวข้อการทดลองออกเป็น 3 หัวข้อการทดลองเพื่อพัฒนาการเรียนรู้เชิงลึกในรูปแบบต่างๆ โดยการทดลองที่ 1 เป็นการเพิ่มประสิทธิภาพของการเรียนรู้เชิงลึกด้วย edge-perceptual loss สำหรับการกำจัดสัญญาณรบกวนในภาพถ่ายดิจิทัล ซึ่งเป็นการนำการคำนวณ multiple loss จากความแตกต่างระหว่างขอบของวัตถุและ pixel ของภาพ ซึ่งสามารถกำจัดสัญญาณรบกวนของการเรียนรู้เชิงลึกได้ แต่ยังไม่สามารถแก้ปัญหาปริมาณข้อมูลที่ใช้ได้ ในการทดลองที่ 2 นำเสนอ self-validation Noise2Noise (SV-N2N) framework ซึ่งสามารถเรียนรู้ด้วยตัวเองและไม่อาศัยข้อมูลภาพที่ปราศจากสัญญาณรบกวนมาเป็นตัวตรวจสอบในการเรียนรู้ การทดลองที่ 3 เป็นการทดลองนำเสนอแนวคิดของการกำจัดสัญญาณรบกวนพร้อมทั้งฟื้นฟูความคมชัดของภาพจากการลดและเพิ่มขนาดภาพด้วยเทคนิค self-validation ซึ่งสามารถกำจัดสัญญาณรบกวนและเพิ่มความคมชัดของภาพได้

Thesis Title	Digital Image Restoration Using Self-Validation Deep Learning
Author	Mr. Asavaron Limsuebchuea
Major Program	Electrical Engineering
Academic Year	2022

ABSTRACT

Noise occurrence and image quality loss are crucial issues in image processing. They can occur from the surrounding environment or the electric signal in the camera device. They result in the degradation of image quality and might lead the image processing to errors. In addition, rephotographing is not feasible for obtaining new usable images in some situations, such as single image problems and blind noise scenarios. Therefore, image denoising and restoration of damaged are essential for image processing tasks. Deep learning network is a successful learning-based method with excellent performance that has resulted in much research; nevertheless, it requires more training data. Therefore, it is unsuitable for applications without training data. This research aims to develop a deep learning framework that can be used in the field that lacks validation data for training. This research divides the experiments into 3 topics. The first experiment is an edge-perceptual loss for image denoising which exploits the edge loss and pixel-wise loss for training denoising networks. While this training strategy can increase the performance of the denoising network, it still requires more image data for training. The second experiment presents a self-validation Noise2Noise (SV-N2N) framework to solve the insufficient training dataset for deep learning. SV-N2N can self-train without validation of a noise-free image. The third experiment employs image downsampling and upsampling to eliminate noise and self-validation to restore image resolution. The outcomes demonstrate that the proposed approach can remove and recover image detail from noise and poor resolution.

กิตติกรรมประกาศ

ขอขอบพระคุณ รองศาสตราจารย์ ดร.พรชัย พฤกษ์ภัทรานันต์ อาจารย์ที่ปรึกษา วิทยานิพนธ์ และผู้ช่วยศาสตราจารย์ ดร. รักษกฤตว์ ดวงสร้อยทอง อาจารย์ที่ปรึกษาร่วม ที่ได้กรุณาอุทิศ เวลาให้คำปรึกษา ความรู้ที่เป็นประโยชน์ ชัดเจนกระบวนการคิดวิเคราะห์ รวมทั้งให้กำลังใจในการแก้ปัญหาและอุปสรรคต่างๆ ตลอดจนตรวจสอบและแก้ไขรายงานวิทยานิพนธ์ให้เป็นไปใน แนวทางที่ถูกต้องสมบูรณ์

ขอขอบพระคุณ รองศาสตราจารย์ ดร.ทิมพันธุ์ เจริญพงษ์ ที่ได้กรุณาอุทิศเวลาเป็น ประธานกรรมการสอบป้องกันวิทยานิพนธ์ ให้คำแนะนำที่เป็นประโยชน์ต่อการทำงานวิจัย และ ตรวจทานวิทยานิพนธ์ให้ดำเนินไปอย่างสมบูรณ์

ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.คุณดาว บุรณะพานิชย์กิจ และผู้ช่วย ศาสตราจารย์ ดร.ชลากร ครูพงศ์ศิริ ที่ได้อุทิศเวลาเป็นกรรมการสอบป้องกันวิทยานิพนธ์ ให้ คำแนะนำที่เป็นประโยชน์ต่อการพัฒนางานวิจัย และตรวจทานวิทยานิพนธ์ให้ดำเนินไปอย่าง สมบูรณ์

ขอขอบพระคุณ คณะวิศวกรรมศาสตร์ และมหาวิทยาลัยสงขลานครินทร์ ที่ให้การ สนับสนุนทุนวิจัย อุปกรณ์ และสถานที่ในการทำวิทยานิพนธ์ คณาจารย์และบุคลากรในภาควิชา วิศวกรรมไฟฟ้าทุกๆ ท่าน พี่ ๆ เพื่อน ๆ รวมทั้งน้อง ๆ นักศึกษามหาวิทยาลัยสงขลานครินทร์ทุก ท่านที่ให้คำแนะนำ คำปรึกษา และกำลังใจที่ดีตลอดมา

ขอขอบพระคุณ ทุนโครงการศูนย์การศึกษาสำหรับภูมิภาคอาเซียนตอนล่าง สำหรับนักศึกษาระดับปริญญาเอก และทุนอุดหนุนการวิจัยเพื่อวิทยานิพนธ์ บัณฑิตวิทยาลัย มหาวิทยาลัยสงขลานครินทร์ เป็นแหล่งเงินทุนให้ข้าพเจ้าทำงานวิจัยในระดับปริญญาเอกจนสำเร็จ

สุดท้ายนี้ ข้าพเจ้าขออน้อมรำลึกถึงพระคุณของบิดามารดาและครอบครัว ที่ สนับสนุน ให้กำลังใจที่ดีเยี่ยม และทุนทรัพย์แก่ข้าพเจ้าตลอดมา จนกระทั่งทำให้ข้าพเจ้าประสบความสำเร็จ

อัครณ ลิ่มสืบเชื้อ

สารบัญ

	หน้า
สารบัญ	(8)
รายการตาราง	(11)
รายการภาพประกอบ	(12)
สัญลักษณ์คำย่อและตัวย่อ	(16)
บทที่ 1 บทนำ	17
1.1 ที่มาและความสำคัญ	17
1.2 วัตถุประสงค์	22
1.3 ขอบเขตการวิจัย	22
1.4 การเกิดสัญญาณรบกวนในภาพถ่าย	22
1.5 ประเภทของสัญญาณรบกวนในภาพถ่าย	23
1.5.1 สัญญาณรบกวนแบบ Gaussian	24
1.5.2 Impulse noise	25
1.5.3 Poisson noise	26
1.5.4 Speckle noise	28
1.6 ประเภทอัลกอริทึมในการกำจัดสัญญาณรบกวนในภาพถ่ายดิจิทัล	29
1.6.1 การกำจัดสัญญาณรบกวนในภาพถ่ายด้วยอัลกอริทึมประเภท filter based	29
1.6.2 การกรองสัญญาณเชิงพื้นที่ (Spatial domain filtering)	30
1.6.3 การกรองสัญญาณด้วยวิธีการแปลงโดเมน (transform domain method)	33
1.6.4 การกำจัดสัญญาณรบกวนในภาพถ่ายด้วยอัลกอริทึมประเภทการเรียนรู้เชิงลึก	39
1.6.5 Convolution neural network (CNN)	42
1.6.6 Autoencoder (AE)	43
1.6.7 Residual network	43
1.6.8 GANs	46
1.7 Deep learning framework สำหรับการกำจัดสัญญาณรบกวนในภาพดิจิทัล	48
1.7.1 Noise2Clean	49
1.7.2 Noise2Noise	50

บทที่ 2 วิธีการวิจัย	53
2.1 ข้อมูลที่ใช้ในการทดลอง.....	53
2.2 การวัดคุณภาพของภาพถ่ายดิจิทัลสำหรับเปรียบเทียบผลการทดลองในงานวิจัยนี้.....	56
2.2.1 Peak signal to noise ratio (PSNR).....	56
2.2.2 Structural similarity (SSIM) index	56
2.3 อธิบายทฤษฎีและหลักการของ edge-perceptual loss สำหรับการกำจัดสัญญาณรบกวนด้วยการเรียนรู้เชิงลึก.....	57
2.4 อธิบายทฤษฎีและหลักการของ self-validation Noise2Noise framework.....	65
2.5 ทฤษฎีและหลักการทดลองวิเคราะห์การฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและลดทอนความละเอียดของภาพ	70
บทที่ 3 ผลการทดลองและอภิปรายผล.....	79
3.1 การทดลองที่ 1 การใช้ edge-perceptual loss สำหรับการกำจัดสัญญาณรบกวนในภาพถ่าย	79
3.2 การทดลองที่ 2 การใช้ self-validation Noise2Noise framework สำหรับการกำจัดสัญญาณรบกวน	87
3.3 การทดลองที่ 3 การวิเคราะห์การทดลองฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและลดทอนความละเอียดของภาพ	96
บทที่ 4 วิเคราะห์ผลการทดลอง	104
4.1 การวิเคราะห์ผลการทดลอง edge-perceptual loss สำหรับการกำจัดสัญญาณรบกวนในภาพถ่าย.....	104
4.2 การวิเคราะห์ผลการทดลอง self-validation Noise2Noise framework	106
4.3 การวิเคราะห์ผลการทดลองวิเคราะห์การฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและลดทอนความละเอียดของภาพ	108
บทที่ 5 สรุปผลการทดลอง	111
5.1 สรุปผลการทดลอง edge-perceptual loss สำหรับ image denoising.....	111
5.2 สรุปผลการทดลอง self-validation Noise2Noise framework	111
5.3 สรุปผลการวิเคราะห์ผลการทดลองวิเคราะห์การฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและลดทอนความละเอียดของภาพ	112
5.4 สรุปผลการศึกษาวิจัยการฟื้นฟูภาพถ่ายด้วยเทคนิคการเรียนรู้เชิงลึก.....	114
บรรณานุกรม	116

ภาคผนวก 1 การตีพิมพ์เผยแพร่ผลงาน.....	127
ภาคผนวก 2 การทดลองเปรียบเทียบ Peak-Signal-to-Noise ratio ระหว่าง traditional method และ deep learning method.....	132
ประวัติผู้เขียน	135

รายการตาราง

หน้า

ตาราง 2-1 สัญญาณรบกวนที่ใช้ในการทดลองสำหรับ 4 สถานการณ์.....	68
ตาราง 3-1 ผลการเปรียบเทียบ PSNR ของแต่ละอัลกอริทึมในการกำจัด Gaussian noise และ Impulse.....	80
ตาราง 3-2 ผลการเปรียบเทียบ PSNR ของการกำจัดสัญญาณรบกวน Gaussian ในสถานะแสงมาก และแสงน้อย.....	85
ตาราง 3-3 เปรียบเทียบผล PSNR ของ 4 สถานการณ์ที่ได้ตั้งค่าสำหรับ self-validation.....	88
ตาราง 3-4 เปรียบเทียบผล PSNR ของ self-validation framework กับ framework อื่นๆ.....	90
ตาราง 3-5 เปรียบเทียบผล PSNR ของแต่ละ framework การฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจาก สัญญาณรบกวนและความละเอียดต่ำ	96
ตาราง 3-6 ผลการฟื้นฟูความภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและการลดทอน คุณภาพ จำนวน 6 ครั้งจาก NIND dataset ที่ทำการเพิ่มขนาด x2, x4 และ x8 เท่า.....	99
ตาราง 3-7 ผลการฟื้นฟูความภาพถ่ายที่มีสัญญาณรบกวนและการลดทอนคุณภาพ จำนวน 6 ครั้ง จาก SIDD dataset ที่ทำการเพิ่มขนาด x2, x4 และ x8 เท่า	100

รายการภาพประกอบ

หน้า

ภาพประกอบ 1-1 ตัวอย่างการถูกรบกวนจากสัญญาณรบกวน.....	18
ภาพประกอบ 1-2 block diagram การทำงานของระบบรับภาพดิจิทัล.....	23
ภาพประกอบ 1-3 การกระจายแบบ Gaussian.....	24
ภาพประกอบ 1-4 ตัวอย่างภาพถ่ายที่ถูกรบกวนด้วยสัญญาณรบกวนแบบ gaussian.....	25
ภาพประกอบ 1-5 ตัวอย่างพฤติกรรมของการถูกรบกวนด้วยสัญญาณรบกวน impulse.....	26
ภาพประกอบ 1-6 ตัวอย่างภาพถ่ายที่ถูกรบกวนด้วยสัญญาณรบกวนแบบ impulse.....	26
ภาพประกอบ 1-7 ตัวอย่างการกระจายแบบ Poisson.....	27
ภาพประกอบ 1-8 ตัวอย่างภาพถ่ายที่ถูกรบกวนด้วยสัญญาณรบกวนแบบ Poisson.....	28
ภาพประกอบ 1-9 การจัดประเภทของอัลกอริทึมในการกำจัดสัญญาณรบกวนในงานวิจัยนี้.....	29
ภาพประกอบ 1-10 low pass filter ในอุดมคติ สำหรับข้อมูลใน 2 มิติ.....	30
ภาพประกอบ 1-11 ตัวอย่างการ convolution ภาพถ่ายที่มีสัญญาณรบกวนด้วย average filter.....	31
ภาพประกอบ 1-12 ตัวอย่างการจัดกลุ่มของ block ที่มีโครงสร้างคล้ายกันใน BM3D.....	32
ภาพประกอบ 1-13 แสดงขั้นตอนการวิเคราะห์และกำจัดสัญญาณรบกวนด้วย transform domain.....	34
ภาพประกอบ 1-14 การวิเคราะห์ wavelet สำหรับข้อมูลภาพถ่าย 2 มิติ.....	35
ภาพประกอบ 1-15 wavelet transform สำหรับข้อมูลภาพถ่าย 2 มิติ.....	36
ภาพประกอบ 1-16 การใช้งาน hard thresholding และ soft thresholding.....	37
ภาพประกอบ 1-17 ขั้นตอนการใช้ PCA ในการวิเคราะห์และกำจัดสัญญาณรบกวนในภาพถ่าย.....	39
ภาพประกอบ 1-18 ตัวอย่างการทำงานของ Convolution neural networks (CNNs).....	40
ภาพประกอบ 1-19 โครงสร้างของ convolution neural network.....	42
ภาพประกอบ 1-20 โครงสร้างของ Autoencoder.....	43
ภาพประกอบ 1-21 โครงสร้าง residual unit.....	44
ภาพประกอบ 1-22 โครงสร้างของ ResNet.....	45
ภาพประกอบ 1-23 โครงสร้างของ U-net.....	45
ภาพประกอบ 1-24 Generative adversarial networks (GANs) ในงานฟื้นฟูภาพถ่าย.....	46
ภาพประกอบ 1-25 over-fitting ที่เกิดขึ้นระหว่างการ training ที่มากเกินไป.....	48

ภาพประกอบ 1-26 Noise2Clean framework.....	49
ภาพประกอบ 1-27 แนวคิดของการเรียนรู้ของ N2C framework.....	49
ภาพประกอบ 1-28 Noise2Noise framework.....	50
ภาพประกอบ 1-29 แนวคิดของการเรียนรู้ของ N2N framework.....	51
ภาพประกอบ 2-1 ขั้นตอนการเตรียมข้อมูลสำหรับการเรียนรู้ของ edge-perceptual loss	54
ภาพประกอบ 2-2 ขั้นตอนการเตรียม dataset ที่ใช้ในการทดลองที่ 2 และการทดลองที่ 3	55
ภาพประกอบ 2-3 แสดงผลกระทบของ noise ต่อ edge detection	58
ภาพประกอบ 2-4 image style transfer network ซึ่งใช้ perceptual loss ในการเรียนรู้	59
ภาพประกอบ 2-5 แสดง super-resolution generative adversarial network (SRGANs)	60
ภาพประกอบ 2-6 แสดง edge-perceptual loss framework สำหรับ image denoising.....	62
ภาพประกอบ 2-7 เปรียบเทียบผลของการตรวจจับขอบวัตถุด้วย Sobel และ Laplacian.....	64
ภาพประกอบ 2-8 self-validation training for Noise2Noise (SV-N2N) framework ที่นำเสนอ	65
ภาพประกอบ 2-9 แนวคิดของการเรียนรู้ของ SV-N2N framework	66
ภาพประกอบ 2-10 Pseudo code สำหรับการทดลอง Noise2Clean framework	69
ภาพประกอบ 2-11 Pseudo code สำหรับการทดลอง Noise2Noise framework	69
ภาพประกอบ 2-12 Pseudo code สำหรับการทดลอง Self-validation Noise2Noise framework.....	70
ภาพประกอบ 2-13 การเพิ่ม pixel ของภาพซึ่งเป็นพื้นฐานของ image super-resolution	71
ภาพประกอบ 2-14 เปรียบเทียบ 3 ขั้นตอนในการฟื้นฟูภาพถ่ายในงานวิจัยนี้	73
ภาพประกอบ 2-15 แสดงผลกระทบของสัญญาณรบกวนที่ลดลงเมื่อทำการลดและเพิ่มขนาดของ ภาพถ่าย	74
ภาพประกอบ 2-16 โครงสร้าง NLR2NSR framework สำหรับฟื้นฟูภาพถ่าย.....	77
ภาพประกอบ 3-1 แสดงกราฟเปรียบเทียบ PSNR ของแต่ละอัลกอริทึมในการกำจัด Gaussian noise	80
ภาพประกอบ 3-2 แสดงกราฟเปรียบเทียบ PSNR ของแต่ละอัลกอริทึมในการกำจัด Impulse noise	81
ภาพประกอบ 3-3 ตัวอย่างการเปรียบเทียบผลของการกำจัดสัญญาณรบกวนแบบ Gaussian และ ขอบของภาพเปรียบเทียบกับอัลกอริทึมอื่นๆ	83

ภาพประกอบ 3-4 ตัวอย่างการเปรียบเทียบผลของการกำจัดสัญญาณรบกวนแบบ Impulse และขอบ ของภาพเปรียบเทียบกับอัลกอริทึมอื่นๆ	84
ภาพประกอบ 3-5 ตัวอย่างภาพสัญญาณรบกวนแบบ Gaussian ในสภาวะแสงมากและแสงน้อย ...	85
ภาพประกอบ 3-6 กราฟแสดงผลการกำจัดสัญญาณ Gaussian ในสภาวะแสงมากและแสงน้อย.....	86
ภาพประกอบ 3-7 แสดงตัวอย่างผลการกำจัดสัญญาณรบกวนแบบ Gaussian ในสภาวะแสงมากและ แสงน้อยของ โครงสร้างการเรียนรู้เชิงลึกที่ใช้ edge-perceptual loss โครงสร้างดั้งเดิม และ โครงสร้าง การเรียนรู้แบบแข่งขันแบบ GANs.....	86
ภาพประกอบ 3-8 ผลการเปรียบเทียบการกำจัดสัญญาณรบกวนของ 4 สถานการณ์ของการตั้งค่า self-validation ที่ใช้ในการทดลอง.....	88
ภาพประกอบ 3-9 แสดงผลการเปรียบเทียบ PSNR ของ SV-N2N กับอัลกอริทึมและ framework การเรียนรู้เชิงลึกแบบ Noise2Clean และ Noise2Noise แบบดั้งเดิม	90
ภาพประกอบ 3-10 แสดงตัวอย่างการกำจัดสัญญาณรบกวนในสภาพแวดล้อมทั่วไปของแต่ละ framework.....	92
ภาพประกอบ 3-11 แสดงตัวอย่างการกำจัดสัญญาณรบกวนในภาพตัวอักษรของแต่ละ framework	93
ภาพประกอบ 3-12 แสดงตัวอย่างผลการทดลองใช้ SV-N2N ในปัญหา single image และ blind noise เปรียบเทียบอัลกอริทึมอื่นๆ	94
ภาพประกอบ 3-13 แสดงกราฟผลการเปรียบเทียบ PSNR ระหว่าง SV-N2N กับอัลกอริทึมอื่นๆ ..	95
ภาพประกอบ 3-14 เปรียบเทียบผล PSNR ระหว่างการฟื้นฟูภาพถ่ายของ 3 framework.....	96
ภาพประกอบ 3-15 แสดงภาพตัวอย่างผลการฟื้นฟูภาพถ่ายของแต่ละ framework ที่ใช้ในการ ทดลอง.....	98
ภาพประกอบ 3-16 ผล PSNR ของการฟื้นฟูความละเอียดของภาพจำนวน 6 ครั้ง ของ NIND dataset	99
ภาพประกอบ 3-17 ผล SSIM ของการฟื้นฟูความละเอียดของภาพจำนวน 6 ครั้ง ของ NIND dataset	100
ภาพประกอบ 3-18 ผล PSNR ของการฟื้นฟูความละเอียดของภาพจำนวน 6 ครั้ง ของ SIDD dataset	101

ภาพประกอบ 3-19 ผล SSIM ของการฟื้นฟูความละเอียดของภาพจำนวน 6 ครั้ง ของ SIDD dataset	101
ภาพประกอบ 3-20 แสดงผลการฟื้นฟูภาพถ่ายที่มีสัญญาณรบกวนและการลดขนาดภาพขนาด x2, x4 และ x8 ด้วย NLR2NSR framework สำหรับภาพจาก NIND dataset	102
ภาพประกอบ 3-21 แสดงผลการฟื้นฟูภาพถ่ายที่มีสัญญาณรบกวนและการลดขนาดภาพขนาด x2, x4 และ x8 ด้วย NLR2NSR framework สำหรับภาพจาก SIDD dataset	103
ภาพประกอบ 4-1 ปัญหา artifact ที่เกิดขึ้นในการเรียนรู้แบบ GANs	106

สัญลักษณ์คำย่อและตัวย่อ

DL	Deep learning
PSNR	Peak signal-to-noise ratio
SSIM	Structural Similarity Index
N2V	Nois2Void framework
N2S	Noise2Self framework
R2R	Recorruped-to-Recorruped framework
SV-N2N	Self-validation Noise2Noise framework
NLR2NSR	Noisy low-resolution to Noisy high-resolution

บทที่ 1

บทนำ


ในบทนี้จะกล่าวถึงที่มาและความสำคัญ วัตถุประสงค์ของงานวิจัย ขอบเขตการศึกษาวิจัย และทฤษฎีที่เกี่ยวข้องกับการกำจัดสัญญาณรบกวนในภาพถ่ายดิจิทัล อธิบายชนิดของสัญญาณรบกวนและการเกิดสัญญาณรบกวนในภาพถ่าย แนวทางและหลักการของกรองสัญญาณรบกวนด้วยตัวกรองสัญญาณทางดิจิทัล และการใช้การเรียนรู้เชิงลึกในการกำจัดสัญญาณรบกวน รวมไปถึง framework ของการเรียนรู้เชิงลึกที่ใช้ในงานการกำจัดสัญญาณรบกวน

1.1 ที่มาและความสำคัญ


ในปัจจุบันได้มีการใช้วิทยาการคำนวณเพื่อประมวลผลภาพ (image processing) ด้วยภาพถ่ายดิจิทัลมาใช้ประโยชน์ในงานต่างๆ เช่น การตรวจจับวัตถุ (classification) [1] และการแบ่งส่วนวัตถุของภาพ (segmentation) [2] เพื่อใช้ประโยชน์ในหลากหลายสาขาเช่น การวินิจฉัยโรคทางการแพทย์ด้วยภาพถ่าย MRI และ CT scan [3] การจับภาพพื้นที่และวัตถุด้วยภาพถ่ายทางอากาศ และภาพถ่ายดาวเทียม [4] รวมไปถึงการประมวลผลภาพเพื่อตรวจจับวัตถุในระบบอัตโนมัติต่างๆ ในชีวิตประจำวัน [5] แต่อย่างไรก็ตามการถ่ายภาพด้วยระบบดิจิทัลที่ใช้ในปัจจุบันสามารถเกิดการลดทอนคุณภาพของภาพได้จากกระบวนการแปลงสัญญาณภาพในตัวเซนเซอร์หรือการประมวลผลของกล้องถ่ายภาพ รวมไปถึงสัญญาณรบกวนที่สามารถเกิดขึ้นได้จากสัญญาณทางไฟฟ้าของอุปกรณ์ถ่ายภาพหรือสภาพแวดล้อมขณะทำการถ่ายภาพได้ [6]

การลดทอนคุณภาพของภาพถ่ายสามารถแบ่งได้เป็น 2 ลักษณะ [6] ได้แก่การถูกลดทอนจากสัญญาณรบกวน และการถูกลดทอนความคมชัดของภาพ ซึ่งปัญหาเหล่านี้สามารถเกิดขึ้นได้หลายลักษณะ โดยการถูกรบกวนที่เกิดขึ้นนี้ทำให้ภาพขาดความคมชัดและสูญเสียข้อมูลสำคัญ อย่างเช่น ขอบของวัตถุ หรือคุณลักษณะของสีที่ผิดเพี้ยนไปจากเดิมตามภาพประกอบ 1-1 ซึ่งส่งผลกระทบต่อการใช้งานในกระบวนการประมวลผลภาพได้ โดยหลักการทำงานของอุปกรณ์ถ่ายภาพมักจะรับภาพจากการรับแสงให้มาตกกระทบกับฉากหรือเซ็นเซอร์รับภาพ โดยอุปกรณ์อาจรับสัญญาณรบกวนอื่นๆ นอกเหนือจากสัญญาณภาพเข้ามาได้ สัญญาณรบกวนเหล่านี้จะถูกรวมเข้ากับสัญญาณภาพทำให้ภาพที่แสดงผลออกมาเกิดการลดทอนสัญญาณ และแม้แต่ในอุปกรณ์รับส่งสัญญาณภาพมักใช้วิธีการบีบอัดข้อมูลภาพ เมื่อการรับส่งหรือการแปลงสัญญาณภาพไม่สมบูรณ์จะทำให้ภาพถูกรบกวนหรือสูญเสียความละเอียดไป ดังนั้นการกำจัดสัญญาณรบกวนในภาพถ่าย

ดิจิทัลเป็นงานที่สำคัญอย่างหนึ่งเพื่อใช้ในการฟื้นฟูภาพถ่ายที่ได้รับความเสียหายจากการถูกรบกวนหรือการถูกลดทอนสัญญาณภาพที่เกิดขึ้น



Original



Noisy image

ภาพประกอบ 1-1 ตัวอย่างการถูกรบกวนจากสัญญาณรบกวน

ปัญหา single image และ blind noise [9, 10] เป็นปัญหาที่เป็นความท้าทายอย่างหนึ่งสำหรับงานด้านการฟื้นฟูภาพถ่ายในโลกความเป็นจริง เนื่องจากปัญหา single image เป็นลักษณะปัญหาที่ภาพถ่ายที่เกิดสัญญาณรบกวนนั้นไม่สามารถจัดหาภาพถ่ายชุดอื่นๆ ในสภาพแวดล้อมเดียวกันเพื่อนำมาหาคุณลักษณะของสัญญาณรบกวนได้อีก เช่นการจับภาพเคลื่อนไหวที่มีการเปลี่ยนแปลงของฉากหลัง สำหรับปัญหา blind noise เป็นลักษณะปัญหาของการเกิดขึ้นของสัญญาณรบกวนที่จะมีการเปลี่ยนแปลงของคุณลักษณะของสัญญาณที่ไม่แน่นอน แม้ว่าจะถ่ายภาพซ้ำในสภาพแวดล้อมเดียวกันก็อาจไม่สามารถนำมาใช้เพื่อระบุคุณลักษณะของสัญญาณรบกวนได้อย่างชัดเจน เช่นปัญหา speckle noise ในการถ่ายภาพด้วยระบบเลเซอร์ หรือจากรับภาพมีพื้นผิวขรุขระ สำหรับการเรียนรู้เชิงลึกที่อาศัยการเรียนรู้จากข้อมูลจำนวนมากจึงอาจใช้งานกับปัญหาเหล่านี้ได้ลำบาก

ในงานวิจัยนี้ได้ทำการจำแนกชนิดของอัลกอริทึมสำหรับการกำจัดสัญญาณรบกวนที่ได้ศึกษามาออกเป็น 2 ชนิดได้แก่วิธี filter-based [11, 12] และวิธี learning-based [13, 14] โดย filter-based เป็นการวิเคราะห์ลักษณะการกระจายตัวและชนิดของสัญญาณรบกวนเพื่อออกแบบ filter เพื่อกรองสัญญาณและกำจัดสัญญาณรบกวนนั้นๆ ออกจากภาพถ่าย กระบวนการนี้เปรียบเสมือนการกรองความถี่ของสัญญาณที่เป็นองค์ประกอบของสัญญาณรบกวนออกไป ซึ่งสัญญาณภาพอาจมีองค์ประกอบบางส่วนตรงกับลักษณะของสัญญาณรบกวนได้ ทำให้การกรองสัญญาณด้วย filter มักจะทำให้ห้องค์ประกอบของภาพบางส่วนหายไปด้วย โดย filtering-based ยังสามารถจำแนกย่อยได้อีก 2 ประเภทตามลักษณะการวิเคราะห์ domain ได้แก่ spatial domain filtering เป็นการออกแบบ

filter kernel เพื่อกรองสัญญาณรบกวนออกจากภาพถ่ายในเชิงพื้นที่จริง และ transform domain filtering ซึ่งเป็นการแปลงข้อมูลภาพไปอยู่ในมิติ domain อื่นๆ เพื่อแยกประกอบของสัญญาณรบกวนเพื่อกำจัดออกและแปลงกลับมาเป็นภาพในมิติเดิม อย่างไรก็ตาม filter-based ทั้งหมดมักจำเป็นต้องใช้การวิเคราะห์ประเภทของสัญญาณและปริมาณการรบกวนของสัญญาณเพื่อกำหนด threshold มาใช้ในการกำจัดสัญญาณรบกวนซึ่งมีความยุ่งยากและอาจเกิดความผิดพลาดได้

สำหรับเทคนิค learning-base และการเรียนรู้ของเครื่องจักร (machine learning) มาใช้งานในปัจจุบันเพิ่มขึ้น [15, 16] โดยอัลกอริทึมประเภท learning-based นี้สามารถแบ่งได้เป็น 2 ลักษณะของการเรียนรู้ได้แก่ การเรียนรู้โดยมีผู้สอน (supervised-learning) และการเรียนรู้โดยไม่มีผู้สอน (unsupervised-learning) ใน supervised-learning จะเป็นการใช้ชุดข้อมูลตรวจสอบ (validation) ที่เป็นเป้าหมายของผลลัพธ์มาตรวจคำตอบที่ได้จากอัลกอริทึม learning-based และใน unsupervised-learning จะให้อัลกอริทึม learning-based อนุมานคำตอบเองและไม่ป้อนคำตอบจาก validation โดยตรง เป้าหมายของอัลกอริทึม learning-based จะเรียนรู้และทำการฟื้นฟูภาพตามลักษณะการถูกรบกวนจากสัญญาณรบกวนที่ได้เรียนรู้มาแล้วซึ่งเป็นวิธีที่สะดวกกว่าการออกแบบ filter และในปัจจุบันการเปรียบเทียบจากหลายงานวิจัย [17, 18] ได้พิสูจน์ว่าการเรียนรู้ของเครื่องจักรมีประสิทธิภาพในการฟื้นฟูภาพถ่ายได้ดีกว่า filtering-base จากการรับรู้สัญญาณรบกวนจากชุดข้อมูลที่มี แต่จำเป็นต้องใช้ชุดข้อมูลจำนวนมากเพื่อให้อัลกอริทึมแบบ learning-based สามารถเข้าใจสัญญาณรบกวนนั้นๆ ทำให้อย่างไรก็ตามในบางสถานการณ์ภาพถ่ายที่ถูกรบกวนมักจะมีปัญหาเฉพาะสำหรับสภาพแวดล้อมนั้นๆ และการเรียนรู้เพื่อกำจัดสัญญาณรบกวนจากข้อมูลที่ไม่สัมพันธ์กันจากสภาพแวดล้อมอื่นอาจไม่สามารถนำมาใช้กำจัดสัญญาณรบกวนในสภาพแวดล้อมที่เป็นอยู่ได้อย่างมีประสิทธิภาพ

งานวิจัยนี้ได้ศึกษาการใช้การเรียนรู้ของเครื่องจักรในการกำจัดสัญญาณรบกวนซึ่งพบว่ามักจะใช้ loss เพียงค่าเดียวในการเรียนรู้และปรับค่าพารามิเตอร์ต่างๆ ของชุดข้อมูลสำหรับนำไปใช้กำจัดสัญญาณรบกวน ซึ่งในงานวิจัยทางการเรียนรู้เชิงลึกหลายงานวิจัย [19, 20] พบว่าการสามารถนำคุณลักษณะ (feature) อื่นๆ มากกว่า 2 ชนิด มาใช้ในการคำนวณค่า loss ในหลายมิติเพื่อเพิ่มประสิทธิภาพให้แก่การเรียนรู้เชิงลึกได้ โดยงานวิจัยนี้จึงได้ทดลองเพิ่มคุณลักษณะของขอบของวัตถุ (edge feature) มาใช้เพื่อศึกษาการเพิ่มประสิทธิภาพของการกำจัดสัญญาณรบกวนของการเรียนรู้แบบ supervise learning แต่อย่างไรก็ตามการเรียนรู้เชิงลึกยังมีปัญหาของความต้องการข้อมูล

จำนวนมากในการเรียนรู้ ซึ่งอาจเป็นปัญหาต่อประสิทธิภาพของการใช้งานได้เมื่อมีชุดข้อมูลไม่เพียงพอในการเรียนรู้ของเครื่องจักร

นอกจากนี้จากการศึกษาการใช้โครงข่ายการเรียนรู้ (deep learning network) ในงานทางด้านการจัดสัญญาณรบกวนและการฟื้นฟูภาพถ่ายหลายงานวิจัย [21, 22, 23] พบว่าเป็นการเรียนรู้ประเภท supervised-learning อาจได้ประสิทธิภาพที่ไม่ดีเมื่อขาดแคลนข้อมูลสำหรับการเรียนรู้ที่เหมาะสมตามสภาพแวดล้อมนั้นๆ เนื่องจากการถูกรบกวนและการถูกลดทอนคุณภาพในความเป็นจริงนั้นอาจไม่สามารถระบุชนิดหรือปริมาณการรบกวนที่แน่นอนได้จากปัญหา single image และ blind noise โดยอาจสามารถแก้ปัญหาได้ด้วยการนำคุณลักษณะอื่นๆ ของข้อมูลภาพมาใช้ในการเรียนรู้ได้ ซึ่งการเรียนรู้แบบนี้มักจะจัดอยู่ในประเภทการเรียนรู้แบบ unsupervised-learning เนื่องจากไม่สามารถจัดหาชุดข้อมูลผลลัพธ์ที่ถูกต้องมาใช้เป็น validation ได้ ซึ่งมีอัลกอริทึมประเภท unsupervised-learning มากมายที่สามารถกำจัดสัญญาณรบกวนออกได้โดยไม่มีอาศัยชุดข้อมูล ground truth มาเป็น validation [24]

งานวิจัยนี้จึงมีเป็นการนำแนวคิดของ Noise2Noise (N2N) framework [25] ที่เป็นการเรียนรู้แบบ self-supervised learning แบบหนึ่งที่มีการจำลองข้อมูล validation จากข้อมูลที่มีอยู่มาเรียนรู้อำนาจจัดสัญญาณรบกวนด้วยตัวเอง โดยแนวคิดของ N2N จะใช้ประโยชน์จากปรับสมดุลพารามิเตอร์ loss ของโครงสร้างการ deep learning เพื่อให้ค่า loss ของกระบวนการเรียนรู้มีค่าน้อยที่สุด เมื่อนำภาพที่มีสัญญาณรบกวนหนึ่งเข้ามาเป็น input และให้ภาพคู่เทียบซึ่งเป็นภาพที่มีสัญญาณรบกวนอีกชุดในฉากเดียวกันมาเป็น validation N2N framework จะสามารถเรียนรู้ที่จะกำจัดสัญญาณรบกวนเป็นเอาต์พุตออกมาได้จากการปรับสมดุลค่า loss สำหรับทุกชุดข้อมูลภาพที่นำมาใช้ ซึ่งเป็นประโยชน์อย่างมากสำหรับงานที่มีข้อจำกัดของปริมาณข้อมูลภาพ และปัญหา blind noise ที่ไม่สามารถระบุลักษณะของสัญญาณรบกวนได้ชัดเจน ทำให้สามารถลดจำนวนภาพในการเรียนรู้ได้ และสามารถกำจัดสัญญาณรบกวนโดยไม่จำเป็นต้องจำแนกชนิดของสัญญาณรบกวนเพื่อออกแบบ filter เพื่อกรองสัญญาณรบกวนออก แต่อย่างไรก็ตามในปัญหา single image ซึ่งเป็นปัญหาของการไม่สามารถจัดหาภาพคู่เทียบได้อีก การใช้งาน N2N framework อาจไม่สามารถใช้งานได้ เนื่องจากขาดแคลนชุดข้อมูลสำหรับขั้นตอน validation โดยมีวัตถุประสงค์ในการพัฒนาแนวคิดของ self-supervised learning สำหรับการกำจัดสัญญาณรบกวนในภาพถ่ายในปัญหา single image หรืองานที่มีปัญหาเรื่องปริมาณข้อมูลในการเรียนรู้ของเครื่องจักร โดยงานวิจัยนี้ได้นำเสนอแนวคิด self-validation สำหรับ N2N framework เพื่อให้การเรียนรู้เชิงลึกสามารถเรียนรู้

องค์ประกอบของสัญญาณรบกวนและสามารถกำจัดออกจากภาพถ่ายได้ ซึ่งแนวคิดที่ได้นำเสนอมีประโยชน์อย่างมากในสภาพแวดล้อมที่ไม่สามารถบันทึกภาพเพิ่มเติมได้ เช่นปัญหาประเภท single image และ blind noise ซึ่งเป็นอุปสรรคต่อการใช้งานอัลกอริทึม learning-based

นอกจากนี้งานวิจัยนี้ได้ศึกษาเปรียบเทียบขั้นตอนของการฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและการถูกลดความละเอียดของภาพเพื่อใช้เป็นแนวทางในการศึกษาการกำจัดสัญญาณรบกวนรวมกับการเพิ่มความละเอียดของภาพถ่ายด้วยการเรียนรู้แบบ self-supervised learning และนำเสนอ framework ที่ใช้ประโยชน์จากการลดเพิ่มขนาดของภาพถ่ายสำหรับการเรียนรู้เพื่อฟื้นฟูภาพถ่ายจากสัญญาณรบกวนและเพิ่มความละเอียดของภาพ เนื่องจากการศึกษาการใช้งานการเรียนรู้เชิงลึกทั้งกำจัดสัญญาณรบกวนและเพิ่มความละเอียดภาพพร้อมกันนั้นมักเป็นการใช้งานประเภท supervised-learning ที่มีข้อจำกัดตามที่ได้กล่าวมาแล้ว อีกทั้งหลายงานวิจัยมักไม่ได้กล่าวถึงปัญหาในความเป็นจริงที่มักเป็นปัญหา single image และปัญหา blind noise

การทดลองในรายงานการวิจัยนี้จะแบ่งออกเป็น 3 หัวข้อการทดลองหลัก โดยการทดลองที่ 1 เป็นการนำเสนอการใช้ขอบของภาพวัตถุมาช่วยในการเพิ่มความสามารถในการเรียนรู้ของการเรียนรู้เชิงลึกสำหรับการกำจัดสัญญาณรบกวน ในการทดลองที่ 2 นำเสนอแนวคิดของการกำจัดสัญญาณรบกวนในปัญหา single image ด้วย Self-validation Noise2Noise (SV-N2N) framework ที่มีพื้นฐานจาก Noise2Noise (N2N) framework ด้วยการให้การเรียนรู้เชิงลึกจำลองคู่เทียบสำหรับ validation ตัวเองจาก input ที่ได้รับขณะเรียนรู้ เพื่อแก้ปัญหาข้อจำกัดของ N2N framework และการขาดแคลนชุดข้อมูลสำหรับการเรียนรู้ และสุดท้ายการทดลองในหัวข้อที่ 3 เป็นการทดลองเปรียบเทียบ 3 framework สำหรับการฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและการสูญเสียความละเอียดของภาพเพื่อใช้เป็นแนวทางในการปรับปรุงประสิทธิภาพการฟื้นฟูภาพถ่าย อีกทั้งนำเสนอการใช้ self-validation สำหรับงานที่ต้องการกำจัดทั้งสัญญาณรบกวนและเพิ่มความละเอียดของภาพถ่ายไปพร้อมกันในปัญหา single image และ blind noise ซึ่งได้นำเสนอ Noisy low-resolution to Noisy super-resolution (NLR2NSR) framework โดยผลการทดลองของ framework ที่ได้นำเสนอนั้นสามารถใช้การฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและการลดทอนคุณภาพได้ แม้ว่าการทดลอง NLR2NSR framework

1.2 วัตถุประสงค์

- 1.2.1 เพื่อนำเสนอแนวคิดของ self-validation ของการเรียนรู้เชิงลึกในการกำจัดสัญญาณรบกวนและเพิ่มความละเอียดของภาพถ่าย
- 1.2.2 เพื่อฟื้นฟูภาพถ่ายจากทั้งสัญญาณรบกวนและเพิ่มความละเอียดของภาพจากปัญหา single image และปัญหา blind noise
- 1.2.3 เพื่อแก้ปัญหาการขาดแคลนข้อมูลในการเรียนรู้ของเครื่องจักร


1.3 ขอบเขตการวิจัย

- 1.3.1 การทดลองนี้จะใช้ชุดข้อมูลภาพมาตรฐาน ได้แก่ BSD100 [26], Set14 [27], Urban100 [28] และ SunHay80 [29] และทดสอบประสิทธิภาพด้วยชุดข้อมูล real-world dataset จาก NIND [30], SIDD [31] และ FMD [32]
- 1.3.2 การทดลองนี้ได้ทดลองการกำจัดสัญญาณรบกวน 2 ชนิด ได้แก่สัญญาณ Gaussian และ สัญญาณ Impulse
- 1.3.3 การทดลองนี้ได้เลือกใช้โครงสร้างการเรียนรู้เชิงลึก 2 แบบ ได้แก่ ResNet [33] และ U-net [34] เพื่อเป็นโครงสร้างหลักในการทดลองแนวคิดที่นำเสนอ
- 1.3.4 การทดลองนี้ได้ทำการเปรียบเทียบผลการทดลองกับอัลกอริทึมการเรียนรู้เชิงลึกอื่นๆ ได้แก่ Generative adversarial network (GANs) [35], Self2Self (S2S) framework [36], Noise2Self (N2S) framework [37], Noise2Void (N2V) framework [38], Recorrupted-to-Rcorrupted (R2R) framework [39]
- 1.3.5 การทดลองนี้ได้ทำการเปรียบเทียบผลการทดลองกับอัลกอริทึมประเภท traditional filter และ Block matching 3D (BM3D) [40] และ Non-Local mean filter (NLM) [41] และ total variation regularization (TV) algorithm [42, [43]

1.4 การเกิดสัญญาณรบกวนในภาพถ่าย

สัญญาณรบกวนและการลดทอนคุณภาพในภาพถ่ายดิจิทัลสามารถเกิดขึ้นได้จากหลายสาเหตุ [44] เช่น จากการรับส่งสัญญาณ กระบวนการในการปรับค่าของอุปกรณ์ ฯลฯ และสัญญาณรบกวนที่สามารถเกิดได้จากสภาพแวดล้อมภายในหรือภายนอกอุปกรณ์ โดยการรบกวนนี้จะรบกวนสัญญาณภาพถ่ายที่รับมา ทำให้ pixel ในภาพถ่ายแสดงผลผิดเพี้ยนจากความเป็นจริง และสัญญาณรบกวนในระบบการถ่ายภาพดิจิทัลมักจะถูกพิจารณาเป็นผลรวมของสัญญาณภาพที่ผ่าน

กระบวนการลดทอนสัญญาณและสัญญาณรบกวน โดยแสดง block diagram การทำงานตามภาพประกอบ 1-2 และแสดงสมการความสัมพันธ์ของการเกิดสัญญาณรบกวนและการลดทอนคุณภาพในภาพถ่ายในสมการที่ 1.1



ภาพประกอบ 1-2 block diagram การทำงานของระบบรับภาพดิจิทัล

$$x_i = h_i * s_i + n_i \quad (1.1)$$

- โดยที่ x_i คือสัญญาณภาพดิจิทัลที่ปรากฏให้เห็น
 h_i คือฟังก์ชันการลดทอนที่เกิดขึ้นได้ในระบบ
 s_i คือสัญญาณภาพที่ปราศจากสัญญาณรบกวน
 n_i คือสัญญาณรบกวนในระบบซึ่งขึ้นอยู่กับชนิดของแหล่งกำเนิดสัญญาณ

สมการที่ 1.1 เป็นสมการอธิบายลักษณะการถูกรบกวนของภาพถ่ายดิจิทัลใดๆ จากอุปกรณ์รับหรือถ่ายภาพ โดยสัญญาณรบกวนจะถูกพิจารณาเป็นสัญญาณที่ถูกเพิ่มเข้าไป (additive signal) และการถูกลดทอนของสัญญาณ h_i จะถูกพิจารณาเป็นการ convolution ของสัญญาณและ kernel ของฟังก์ชันการลดทอนสัญญาณที่เกิดขึ้นในระบบถ่ายภาพ ซึ่งฟังก์ชันการลดทอนนี้สามารถเกิดได้จากการเบลอ (blurring) ของสัญญาณภาพ และการเพิ่มขนาดของภาพซึ่งมีการเติม pixel โดยการประมาณค่า pixel ใหม่เข้าไป ซึ่งเป็นเหตุให้คุณลักษณะ (feature) ของภาพขาดรายละเอียดไป

1.5 ประเภทของสัญญาณรบกวนในภาพถ่าย

สัญญาณรบกวนที่เกิดขึ้นในภาพถ่ายมีอยู่ด้วยกันหลายชนิด [45, 46] ขึ้นอยู่กับแหล่งกำเนิดของสัญญาณรบกวนที่สอดคล้องกับสัญญาณไฟฟ้าในอุปกรณ์ถ่ายภาพ สภาพของตัวอุปกรณ์รับภาพหรือถ่ายภาพ และสภาพแวดล้อมที่ทำให้เกิดสัญญาณรบกวนชนิดนั้นขึ้น ซึ่งการถูกรบกวนใน


ภาพถ่ายมักจะเกิดขึ้นแบบสุ่มและมีลักษณะของการรบกวน โดยแสดงผลเป็นการเปลี่ยนแปลงค่าไป ในแต่ละ pixel ของภาพถ่ายดิจิทัล โดยในตอนนี้จะอธิบายโมเดลของสัญญาณรบกวนที่นิยมนำมา วิเคราะห์และออกแบบ filter ในปัญหาทางด้านการกำจัดสัญญาณรบกวนดังต่อไปนี้

1.5.1 สัญญาณรบกวนแบบ Gaussian


Gaussian noise หรือ white noise จะมีการกระจายตัวของสัญญาณรบกวนเป็นแบบ random normal distribution ซึ่งมีค่าเฉลี่ยของสัญญาณเท่ากับศูนย์ และมีค่า standard deviation เท่ากับหนึ่ง ตาม Probability density function ในภาพประกอบ 1-3 อธิบายตามโมเดลทางคณิตศาสตร์ในสมการ ที่ 1.2 โดย gaussian noise มักเป็นสัญญาณรบกวนทั่วไปที่เกิดจากสัญญาณไฟฟ้าของตัวอุปกรณ์ที่ เข้าไปรบกวนเซ็นเซอร์รับภาพ โดยมักเกิดจากการรับแสงธรรมชาติที่ไม่สม่ำเสมอ เช่น การปรับค่า ISO หรือรูรับแสงของกล้องถ่ายภาพ

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} \quad (1.2)$$


โดยที่ x คือ ข้อมูล ณ ตำแหน่งนั้นๆ ในภาพ
 μ คือ ค่าเฉลี่ยของชุดข้อมูล
 σ คือ standard deviation ของชุดข้อมูล



ภาพประกอบ 1-3 การกระจายแบบ Gaussian



Original image



Noisy image


ภาพประกอบ 1-4 ตัวอย่างภาพถ่ายที่ถูกรบกวนด้วยสัญญาณรบกวนแบบ gaussian

1.5.2 Impulse noise


Impulse noise หรือ salt and pepper noise จะแตกต่างจากสัญญาณรบกวนอื่นๆ ที่รบกวนทุกค่า pixel ในภาพถ่ายโดยสุ่ม แต่พฤติกรรมของ Impulse noise จะรบกวน pixel ในภาพด้วยการแทนค่า pixel เดิมด้วยค่าน้อยสุด (min) หรือค่ามากที่สุด (max) ตามความกว้างของค่าสีของ pixel ในระบบภาพ ซึ่งจะส่งผลให้บาง pixel เกิดการแสดงผลผิดปกติ ตัวอย่างเช่น หากค่าสีสูงสุดในภาพคือ 255 จะทำให้ impulse noise ที่เกิดขึ้นจะมีการแทนค่า pixel บางจุดด้วยค่า 0 หรือ 255 เป็นต้น โดยแสดงพฤติกรรมของ impulse noise ในภาพประกอบ 1-5 และตัวอย่างภาพถ่ายที่ได้รับผลกระทบจาก impulse noise ในภาพประกอบ 1-6

25	156	3	→	25	156	3
14	126	228		14	0	228
1	189	88		1	189	88

ภาพประกอบ 1-5 ตัวอย่างพฤติกรรมของการถูกรบกวนด้วยสัญญาณรบกวน impulse



Original image



Noisy image

ภาพประกอบ 1-6 ตัวอย่างภาพถ่ายที่ถูกรบกวนด้วยสัญญาณรบกวนแบบ impulse


1.5.3 Poisson noise

Poisson noise หรือ photon noise มักเป็นสัญญาณรบกวนที่เกิดอุปกรณ์ที่รับภาพในสภาพแวดล้อมที่มีการรบกวนของคลื่นสนามแม่เหล็กไฟฟ้า เช่นการใช้รังสี x-ray หรือรังสี gamma ในระบบถ่ายภาพเป็นต้น โดยรังสีเหล่านี้สามารถปล่อยอนุภาค photon ออกมารบกวนระบบรับภาพ ซึ่งระดับการถูกรบกวนในภาพถ่ายขึ้นอยู่กับความเข้มของรังสี ซึ่งสัญญาณรบกวน Poisson noise สามารถอธิบายตาม 1.3 และแสดงภาพตัวอย่างของการถูกรบกวนด้วย Poisson ในภาพประกอบ 1-8 นอกจากนี้ยังมีสัญญาณรบกวนแบบ Rayleigh noise และ Gamma noise ที่เป็นรูปแบบการกระจาย


ตัวในลักษณะคล้าย Poisson noise โดยที่ค่า λ ไม่ใช่ค่าคงที่ แต่สามารถเปลี่ยนแปลงได้ตามเงื่อนไขของสัญญาณรบกวน

$$f(x) = \frac{\lambda^x e^{-\lambda}}{x!} \quad (1.3)$$



โดยที่ $f(x)$ คือฟังก์ชันการกระจายตัวของ Poisson noise โดยเรียกว่า power function
 x คือ number of occurrences ซึ่งมีค่าเป็นจำนวนเต็ม
 λ คือ expected value



ภาพประกอบ 1-7 ตัวอย่างการกระจายแบบ Poisson



Original image



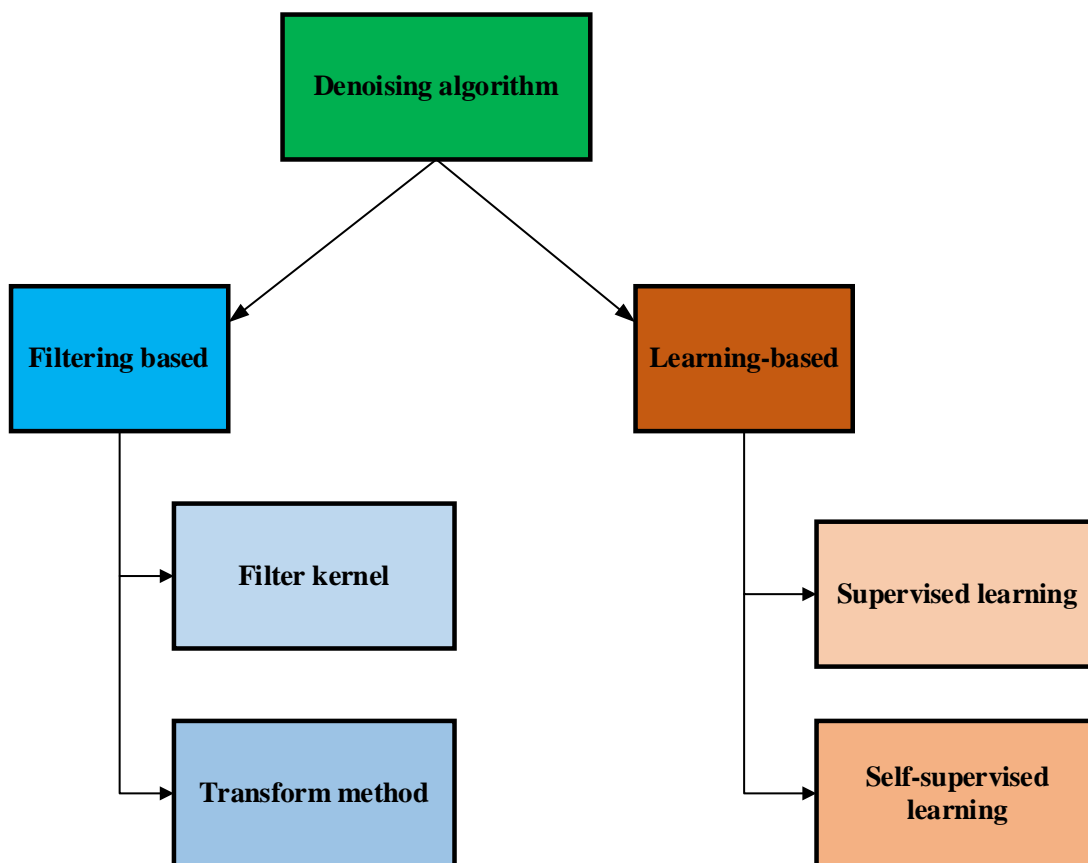
Noisy image

ภาพประกอบ 1-8 ตัวอย่างภาพถ่ายที่ถูกรบกวนด้วยสัญญาณรบกวนแบบ Poisson

1.5.4 Speckle noise

Speckle noise เป็นสัญญาณรบกวนที่เกิดขึ้นในระบบถ่ายภาพที่ใช้หลักการตกกระทบของแสงบนฉากรับภาพเช่น ภาพถ่ายอัลตราซาวด์ การถ่ายภาพของระบบ synthetic aperture radar (SAR) ซึ่งสัญญาณรบกวนชนิดนี้จะเกิดขึ้นเมื่อเกิดการกระเจิงของแสงจากการตกกระทบกับวัตถุที่มีผิวขรุขระหรือฉากรับภาพที่ไม่เรียบ ทำให้มีการเปลี่ยนแปลงความยาวคลื่นแสงกระทันหันโดยพฤติกรรมของ speckle noise จึงยากที่จะระบุพารามิเตอร์หรือสมการรูปแบบของสัญญาณรบกวนที่เกิดขึ้น และยากต่อการออกแบบ filter เพื่อกำจัดสัญญาณรบกวนชนิดนี้ เนื่องจากการเปลี่ยนแปลงที่เกิดขึ้นมีความไม่แน่นอนสูงจากทิศทางของการกระเจิงแสงและการแสดงผลของการรบกวนอาจไม่สม่ำเสมอตลอดทั้งภาพ จากความไม่แน่นอนของสัญญาณรบกวนแบบ speckle noise ที่เกิดขึ้นนี้จึงมักถูกจัดว่าเป็นปัญหาประเภท blind noise [47, 48] เนื่องจากการหาความสัมพันธ์และระบุพารามิเตอร์ของสัญญาณรบกวนที่แน่นอนได้ลำบาก

1.6 ประเภทอัลกอริทึมในการกำจัดสัญญาณรบกวนในภาพถ่ายดิจิทัล



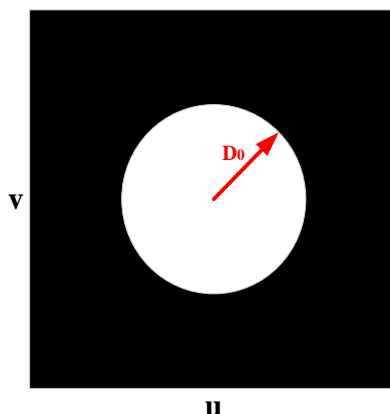
ภาพประกอบ 1-9 การจัดประเภทของอัลกอริทึมในการกำจัดสัญญาณรบกวนในงานวิจัยนี้

ในงานวิจัยนี้ได้แบ่งอัลกอริทึมสำหรับการกำจัดสัญญาณรบกวนออกเป็น 2 ประเภท ตามภาพประกอบ 1-9 ได้แก่อัลกอริทึมประเภทตัวกรอง (filter based) และการเรียนรู้เชิงลึก (learning based) ซึ่งอัลกอริทึมประเภทตัวกรองสามารถแบ่งแยกย่อยออกเป็นการกรองสัญญาณเชิงพื้นที่ (Spatial domain filtering) และการกรองสัญญาณด้วยวิธีการแปลงโดเมน (transform domain method) สำหรับอัลกอริทึมการเรียนรู้เชิงลึกสามารถแบ่งได้เป็นการเรียนรู้แบบมีผู้สอน (supervise learning) และการเรียนรู้ด้วยตัวเอง (self-supervise learning) โดยจะอธิบายหลักการของแต่ละอัลกอริทึมประเภท filter based และ learning based ในหัวข้อ 1.6.1 และ 1.6.2 ตามลำดับ

1.6.1 การกำจัดสัญญาณรบกวนในภาพถ่ายด้วยอัลกอริทึมประเภท filter based

แนวคิดของการใช้ตัวกรองหรือ filter ในการวิเคราะห์สัญญาณรบกวนที่เกิดขึ้นในภาพมักจะพิจารณาว่าสัญญาณรบกวนเป็นสัญญาณที่มีความถี่ต่ำ และสัญญาณภาพถ่ายเป็นสัญญาณ

ความถี่สูง เนื่องจากสัญญาณรบกวนนั้นมักมีรูปแบบซ้ำๆ ตลอดทั้งภาพ และค่าที่ปรากฏยังน้อยกว่าค่าของสัญญาณภาพ โดยหลักการทำงานของ filter ในการกรองสัญญาณในภาพถ่ายได้ถูกแสดงตัวอย่างตามภาพประกอบ 1-10 และตามสมการที่ 1.4 และ 1.5



ภาพประกอบ 1-10 low pass filter ในอุดมคติ สำหรับข้อมูลใน 2 มิติ

$$H(u, v) = \begin{cases} 0 & D(u, v) \leq D_0 \\ 1 & D(u, v) > D_0 \end{cases} \quad (1.4)$$

$$D(u, v) = \sqrt{u^2 + v^2} \quad (1.5)$$

โดยที่ $H(u, v)$ คือช่วงตำแหน่งที่อนุญาตหรือไม่อนุญาตให้สัญญาณผ่าน
 $D(u, v)$ คือความยาวรัศมีที่อนุญาตหรือไม่อนุญาตให้สัญญาณผ่าน

โดยหลักการกรองสัญญาณภาพซึ่งเป็นสัญญาณ 2 มิติ จะพยายามมองความแตกต่างระหว่างสัญญาณรบกวนที่เกิดขึ้นและสัญญาณภาพถ่ายที่ควรจะเป็น ซึ่งการวิเคราะห์นี้จะเป็นลักษณะของ filtering-based ซึ่งเป็นการมองสัญญาณรบกวนเป็นสัญญาณความถี่ต่ำและสัญญาณภาพเป็นสัญญาณความถี่สูง โดยการวิเคราะห์ลักษณะนี้ยังสามารถจำแนกออกได้เป็น 2 ประเภท ได้แก่ Spatial domain filtering [49, 50, 51, 52, 53] และ transform domain filtering [54, 55, 56]

1.6.2 การกรองสัญญาณเชิงพื้นที่ (Spatial domain filtering)

การวิเคราะห์สัญญาณรบกวนใน spatial domain จะเป็นการพยายามออกแบบ filter เพื่อนำมากรองสัญญาณรบกวนจากภาพถ่ายโดยตรง ตามหลักการของ low-pass filter หรือการพยายามเพื่อปรับสัญญาณภาพของภาพถ่ายให้เสมอกันซึ่งสามารถกำจัดสัญญาณรบกวนส่วนใหญ่ออกไป

ได้ดี แต่อย่างไรก็ตาม วิธีการของ filtering based มักจะไม่สนใจ feature ที่เป็นโครงสร้างของวัตถุ ภายในภาพ ทำให้ภาพที่ได้เกิดการเบลอขึ้น เนื่องจาก filter ที่ใช้ในการทำ convolution ลดทอน feature สำคัญของภาพถ่ายบางอย่างออกไปด้วย เช่น ขอบของวัตถุ เป็นต้น โดยหลักการกำจัด สัญญาณรบกวนด้วย filter kernel จะใช้การทำ convolution ระหว่าง ภาพถ่ายและ filter kernel ตาม ภาพประกอบ 1-11



ภาพประกอบ 1-11 ตัวอย่างการ convolution ภาพถ่ายที่มีสัญญาณรบกวนด้วย average filter

ในการใช้ average filter เป็นการเฉลี่ย pixel โดยรอบของ kernel ซึ่งอาจไม่เหมือนสมกับ ภาพที่มีรายละเอียดของขอบวัตถุขนาดเล็กที่มาก ดังนั้นหลักในการออกแบบ filter kernel ในแต่ละ สถานการณ์มักจะพิจารณาการกำจัดสัญญาณรบกวนกรณีที่ได้รับผลกระทบจากสัญญาณรบกวน n ชนิดเดียวกัน ซึ่งสามารถพิจารณา energy function [57] ตามสมการที่ 1.6 ในการประมาณค่า สัญญาณภาพ x

$$\hat{x} = \arg \min_x E(x) \quad (1.6)$$

โดยที่ \hat{x} คือการประมาณค่าสัญญาณภาพ
 x คือสัญญาณภาพที่ไม่มีสัญญาณรบกวน n
 $E(x)$ คือ energy function

การประมาณค่า \hat{x} ใน spatial domain สามารถพิจารณา $E(x)$ ด้วยหลักการของ probability estimation ตามหลักการของ Bayesian ตามสมการที่ 1.7 และ 1.8

$$\hat{x} = \arg \max_x P(x|y) = \arg \max_x \frac{P(y|x)P(x)}{P(y)} \quad (1.7)$$

$$\hat{x} = \arg \max_x [\log P(y|x) + \log P(x)] \quad (1.8)$$

โดยที่ $P(y|x)$ คือ likelihood function ในการพิจารณาภาพ y เมื่อทราบค่าของภาพ x
 $P(x)$ คือ probability prior ของภาพ x


ในการพิจารณาหาผลลัพธ์ \hat{x} นั้นคือการหาค่า $\log P(y|x)$ มีค่าน้อยที่สุด ซึ่งหากพิจารณาสัญญาณรบกวนเป็น AWGN สามารถพิจารณาสมการที่ 1.8 ใหม่ได้ดังสมการที่ 1.9

$$\hat{x} = \arg \min_x \|y - x\|^2 + \lambda R(x) \quad (1.9)$$

โดยที่ $\|y - x\|$ เป็น term ของ error ระหว่างภาพที่มีสัญญาณรบกวน y และภาพ x

$\lambda R(x)$ เป็น term ของค่า parameter อื่นๆ ที่ส่งผลต่อการประมาณค่า \hat{x}

สำหรับอัลกอริทึมการกำจัดสัญญาณรบกวนแบบ spatial domain เช่น block match 3D (BM3D) [40] หรือ non-local mean filter (NLM) [41] จะเป็นการพิจารณาความน่าจะเป็น probability prior ของสัญญาณรบกวน ณ ตำแหน่งอื่นๆ โดย BM3D จะพิจารณาสัญญาณรบกวน ณ ตำแหน่งที่ block มีความคล้ายคลึงกัน ตามภาพประกอบ 1-12 โดยจากภาพประกอบแสดงการจับกลุ่มของภาพที่มีโครงสร้างที่ใกล้เคียง กันเพื่อนำมาวิเคราะห์และกับจัดสัญญาณรบกวนในขั้นตอนต่อไป แต่สำหรับ NLM จะพิจารณาสัญญาณรบกวน ณ ตำแหน่งอื่นๆ ของภาพมาวิเคราะห์หาพารามิเตอร์ของสัญญาณรบกวน เนื่องจากใช้แนวคิดว่าสัญญาณรบกวนในภาพถ่ายเดียวกันควรเป็นสัญญาณรบกวนชนิดเดียวกัน



ภาพประกอบ 1-12 ตัวอย่างการจัดกลุ่มของ block ที่มีโครงสร้างคล้ายกันใน BM3D

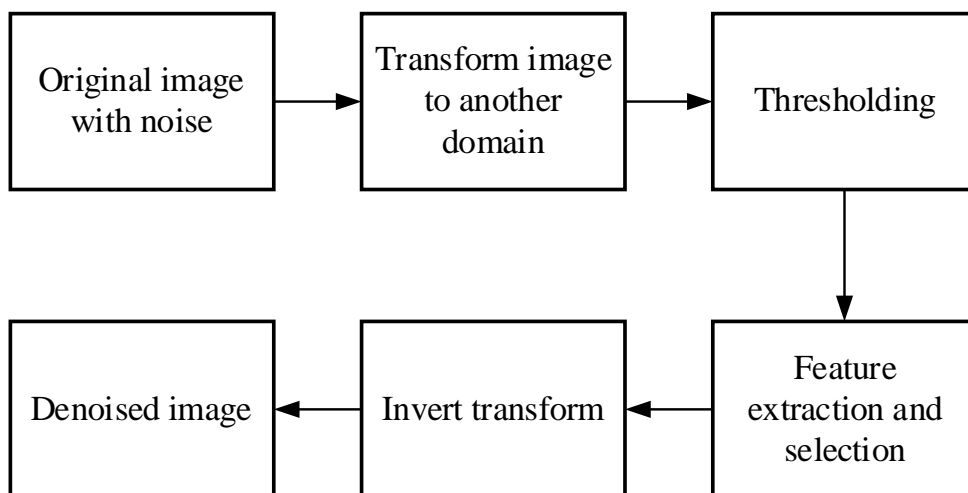
สำหรับการกำจัดสัญญาณรบกวนของ NLM จะพิจารณาลักษณะของสัญญาณรบกวนและสัญญาณภาพ โดยการใช้โครงสร้างของสัญญาณรบกวนจากหลายตำแหน่ง และใช้หลักการประมาณค่าตามสมการที่ 1.10 เพื่อหาความสัมพันธ์ของสัญญาณรบกวนนั้นๆ และกำจัดออกไป

$$w_{i,j} = \frac{1}{c_i} \left(-\frac{\|x_i - x_j\|^2}{h_i} \right) \quad (1.10)$$

โดยที่ $w_{i,j}$ คือ weight ของการกำจัดสัญญาณรบกวนนั้นๆ
 c_i คือ normalization
 h_i คือ parameter factor ขึ้นอยู่กับกระบวนการกำจัดสัญญาณรบกวนของอัลกอริทึมนั้นๆ

1.6.3 การกรองสัญญาณด้วยวิธีการแปลงโดเมน (transform domain method)

การใช้ spatial domain อาจไม่สามารถแยกองค์ประกอบของสัญญาณภาพและสัญญาณรบกวนออกจากกันได้อย่างชัดเจนและการใช้ spatial filter ทำให้ข้อมูลสัญญาณภาพถูกลดทอนไปด้วย ดังนั้นจึงต้องแปลงข้อมูลไปอยู่ในโดเมนอื่นเพื่อให้สามารถแยกองค์ประกอบของสัญญาณได้อย่างชัดเจนขึ้นด้วย transform domain ซึ่งเป็นวิธีที่สามารถแยกองค์ประกอบของสัญญาณภาพแล้วสัญญาณรบกวนได้และยังสามารถเก็บรักษา feature ที่สามารถบอกเอกลักษณ์ของสัญญาณภาพและสัญญาณรบกวนได้ โดย transform domain ที่มักถูกนำมาใช้ในงานทางการกำจัดสัญญาณรบกวนได้แก่ wavelet transform [55, 56] และ principle component analysis (PCA) [58, 59] ในการวิเคราะห์โครงสร้างของภาพถ่ายด้วยการใช้ transform domain จะแสดงในภาพประกอบ 1-13



ภาพประกอบ 1-13 แสดงขั้นตอนการวิเคราะห์และกำจัดสัญญาณรบกวนด้วย transform domain

wavelet transform [60] เป็นฟังก์ชันอธิบายโครงสร้างสัญญาณที่ประกอบด้วยสัญญาณย่อยหลายๆ สัญญาณมารวมกันและสามารถหาเอกลักษณ์ของสัญญาณนั้นๆ ได้ โดย wavelet จะถูกกำหนดนิยามโดยสมการพื้นฐานที่ 1.11

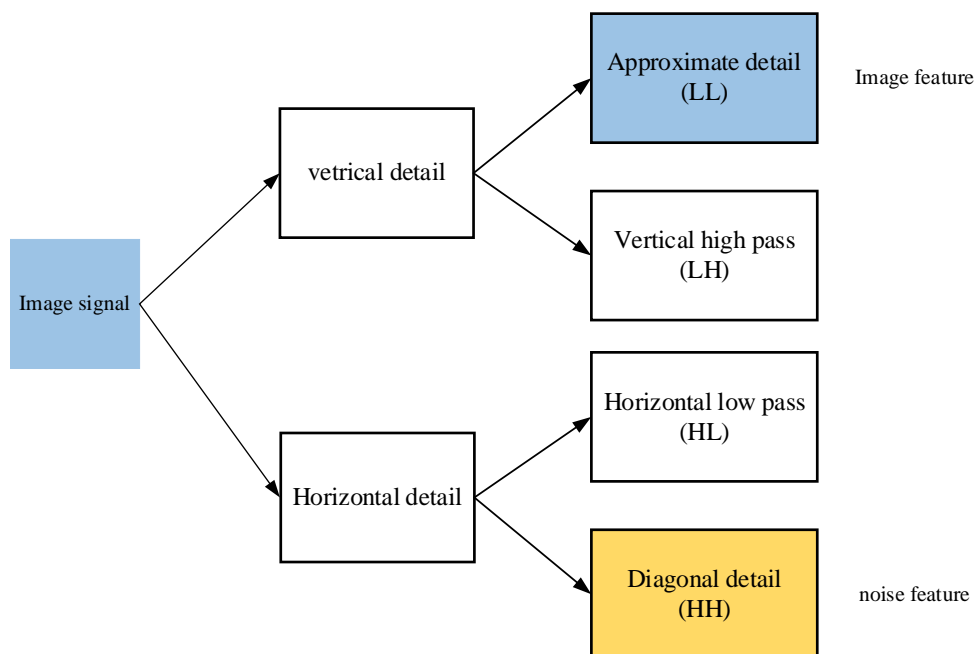
$$x(t) = \sum_{k=-\infty}^{\infty} c(k)\phi(t - k) + \sum_{j=0}^{\infty} \sum_{k=-\infty}^{\infty} d(j, k)2^{\frac{j}{2}}\psi(2^j t - k) \quad (1.11)$$

โดยที่ $x(t)$ คือสัญญาณที่ปรากฏ

$c(k)$ คือค่า coefficient เชิง scale

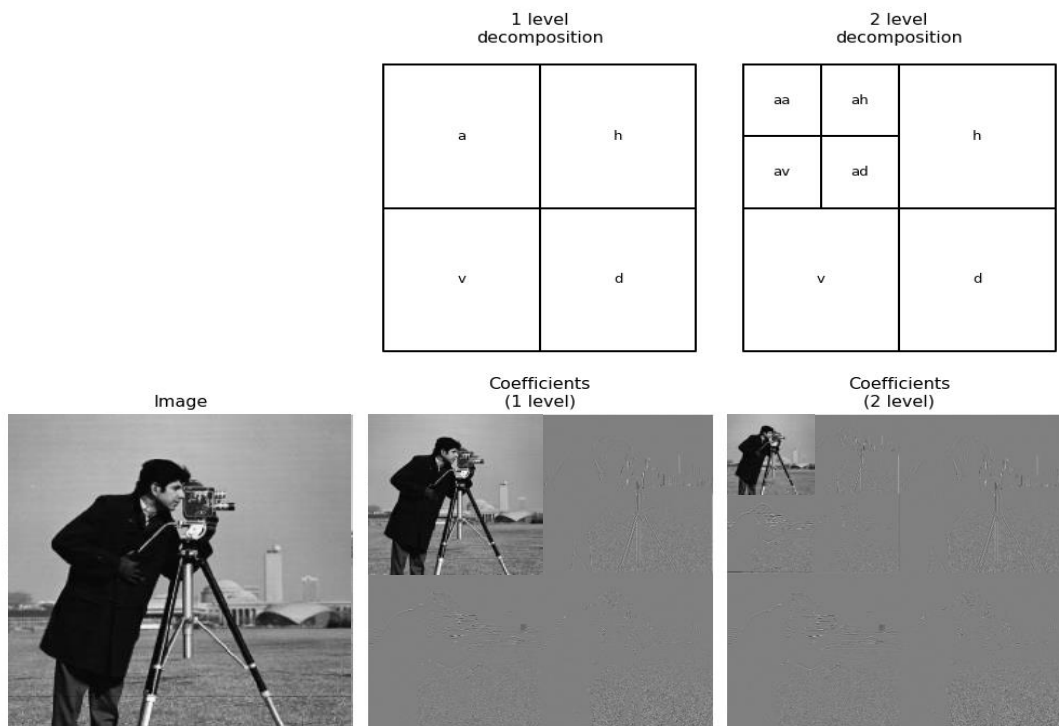
$d(j, k)$ คือค่า coefficient เชิง wavelet

wavelet transform สามารถแบ่งการใช้งานและการคำนวณออกได้เป็น 2 รูปแบบ ได้แก่ Continuous wavelet transform (CWT) และ Discrete wavelet transform (DWT) โดยในงานทางด้าน image processing จะใช้นิยามของ DWT มาใช้ในการวิเคราะห์สัญญาณต่างๆ ในภาพ ด้วยการแบ่งองค์ประกอบความถี่สูงและความถี่ต่ำ โดยในงานด้าน image denoising สามารถใช้ประโยชน์ในการแยกแยะสัญญาณรบกวนออกจากสัญญาณภาพได้ โดยการใช้ Wavelet สำหรับงานทาง image processing ซึ่งเป็นข้อมูล 2 มิติ จะเป็นการวิเคราะห์ wavelet ตามแกนแนวนอน (horizontal) และแนวตั้ง (vertical) โดยแบ่งการวิเคราะห์เป็น 4 โครงสร้างดังที่แสดงในภาพประกอบ 1-14



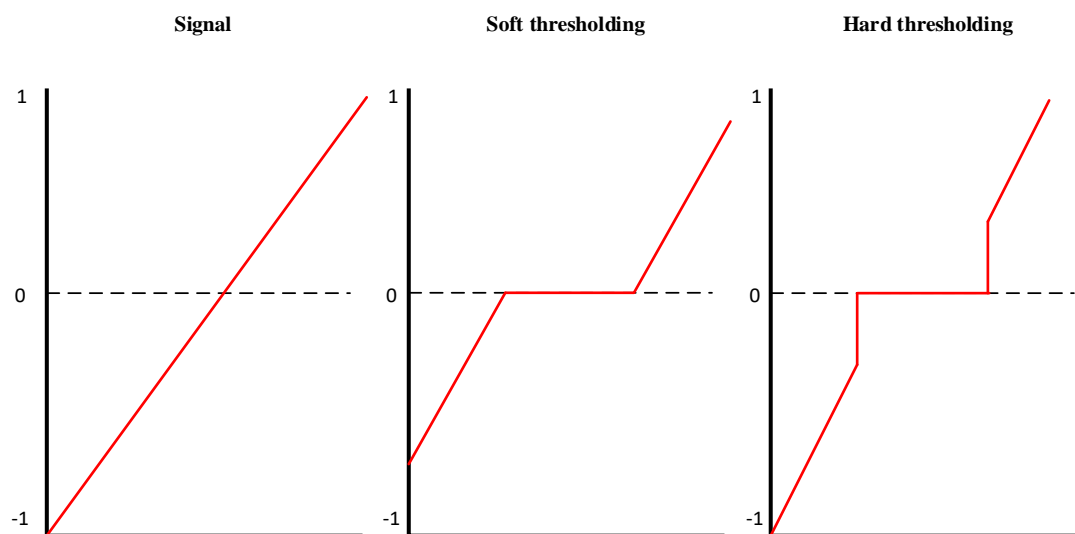
ภาพประกอบ 1-14 การวิเคราะห์ wavelet สำหรับข้อมูลภาพถ่าย 2 มิติ

จากแนวคิดของการใช้ wavelet ในการแยกองค์ประกอบของภาพในภาพประกอบ 1-14 การใช้ wavelet ในการแยกองค์ประกอบระหว่างสัญญาณรบกวนและสัญญาณภาพถ่ายเป็น 2 องค์ประกอบ โดยหลักการแล้ว wavelet จะเป็นการแปลงข้อมูลภาพให้ไปอยู่ใน transform domain ตามภาพประกอบ 1-15 ซึ่งเป็นการมองสัญญาณรบกวนเป็นองค์ประกอบความถี่สูง และสัญญาณภาพเป็นองค์ประกอบความถี่ต่ำ โดยสามารถแบ่งสัญญาณภาพต่อไปได้เรื่อย ๆ ไม่รู้จบ



ภาพประกอบ 1-15 wavelet transform สำหรับข้อมูลภาพถ่าย 2 มิติ

จากที่ได้กล่าวมานั้น wavelet transform สามารถใช้องค์ประกอบเชิงความถี่ของสัญญาณภาพแยกสัญญาณภาพและสัญญาณรบกวนออกจากกันได้ ซึ่งสามารถสามารถแบ่งแยกสัญญาณได้ไม่รู้จักเป็นลำดับชั้นของ coefficient โดยการใช้งานในการกำจัดสัญญาณรบกวนจำเป็นต้องกำหนดค่า thresholding เพื่อกรองค่าสัญญาณรบกวนที่ต้องการกำจัดออก โดยการกำหนด thresholding ของ wavelet transform สามารถแบ่งออกเป็น 2 ชนิด [61] ได้แก่ hard thresholding และ soft thresholding ตามตัวอย่างภาพประกอบ 1-16 โดยอธิบายอธิบายความสัมพันธ์ตามสมการที่ 1.12 และ 1.13



ภาพประกอบ 1-16 การใช้งาน hard thresholding และ soft thresholding

- hard thresholding กำหนดโดย

$$\hat{w} = \begin{cases} w, & |w| \geq \lambda \\ 0, & |w| < \lambda \end{cases} \quad (1.12)$$

- soft thresholding กำหนดโดย

$$\hat{w} = \begin{cases} \text{sgn}(w)(|w| - \lambda), & |w| \geq \lambda \\ 0, & |w| < \lambda \end{cases} \quad (1.13)$$

โดยที่ w คือค่า weight ที่นำไปใช้ในการกำหนดค่าการแสดงผลของ wavelet
 λ คือค่า threshold ที่กำหนด

สำหรับ Principle component analysis (PCA) เป็นเทคนิคการแยกองค์ประกอบ feature ของข้อมูล ด้วยหลักการ projection ข้อมูลในโดเมนการกระจายตัวของข้อมูลในโดเมนใหม่ ซึ่งสามารถใช้ในการวิเคราะห์แยกองค์ประกอบสัญญาณรบกวนและสัญญาณภาพในภาพถ่ายได้ โดยหลักการใช้ PCA ในภาพถ่ายสามารถทำได้ด้วยการหาค่า eigen value และ eigen matrix ของภาพถ่ายซึ่งได้จากการคำนวณค่า covariance ของภาพตามสมการที่ 1.14 และ 1.15

$$y_i = \text{cov}^{-1}(X) \cdot x_i \quad (1.14)$$

$$\text{cov}(X_i, X_j) = \frac{1}{n-1} \sum_i^n (X_i - \bar{x}_i)(X_j - \bar{x}_j) \quad (1.15)$$

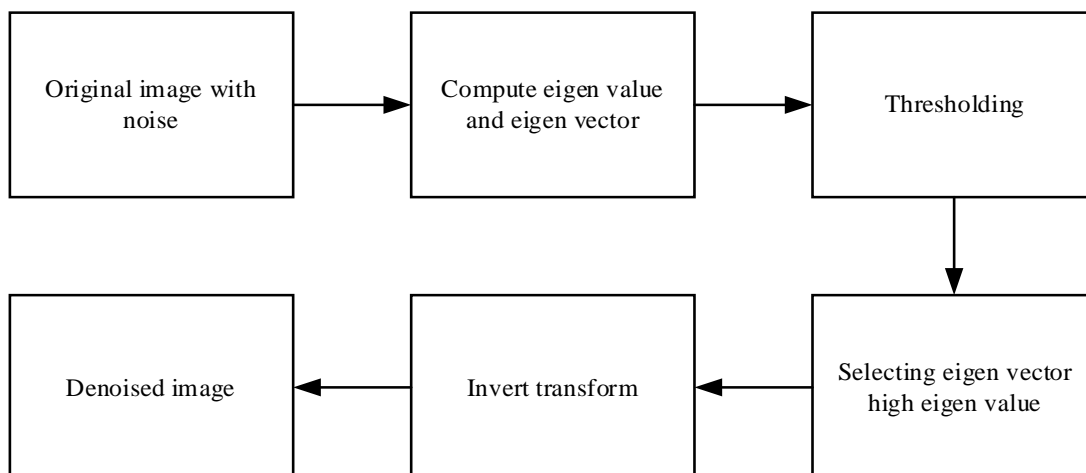
โดยที่ y_i คือ ภาพ output กำจัดสัญญาณรบกวนออกไปแล้ว
 x_i คือ ภาพ input ที่มีสัญญาณรบกวน
 $\text{cov}^{-1}(X_i, X_j)$ คือ invert covariance matrix ของภาพ input

ในการกำจัดสัญญาณรบกวนจะนำค่า covariance ของภาพถ่ายที่คำนวณเหล่านี้มาใช้คำนวณค่า eigen value และ eigen matrix ที่เกี่ยวข้องที่สอดคล้องตามสมการที่ 1.16 โดยข้อมูลที่มีค่า eigen value ที่ต่ำกว่า threshold จะถูกพิจารณาเป็นองค์ประกอบของสัญญาณรบกวนและจะถูกกำจัดออก หลังจากนั้นจะทำ invert transform กลับมาเป็นภาพถ่ายที่กำจัดสัญญาณรบกวนออกแล้วตามภาพประกอบ 1-17

$$Av = \lambda v \quad (1.16)$$

โดยที่ A คือ transformation matrix ซึ่งเป็นข้อมูลภาพที่ถูกแปลงไปใน domain ใหม่
 λ คือ eigenvalue ของ A
 v คือ eigenvector ของ A

ค่า eigenvalue ที่คำนวณนี้จะบอกค่าลักษณะเฉพาะที่สำคัญของชุดข้อมูลที่ทำกรแปลงโดเมน ซึ่งสามารถใช้จัดลำดับความสำคัญของข้อมูลใน transform domain และเลือกกำจัดออกไปได้ แต่อย่างไรก็ตาม eigenvalue อาจไม่สามารถนำมาใช้อธิบายความสัมพันธ์ของข้อมูลใน domain ปกติดั้งเดิมของข้อมูลได้ จึงยากต่อการทำความเข้าใจสัญญาณรูปภาพและสัญญาณรบกวนที่อยู่ใน transform domain



ภาพประกอบ 1-17 ขั้นตอนการใช้ PCA ในการวิเคราะห์และกำจัดสัญญาณรบกวนในภาพถ่าย

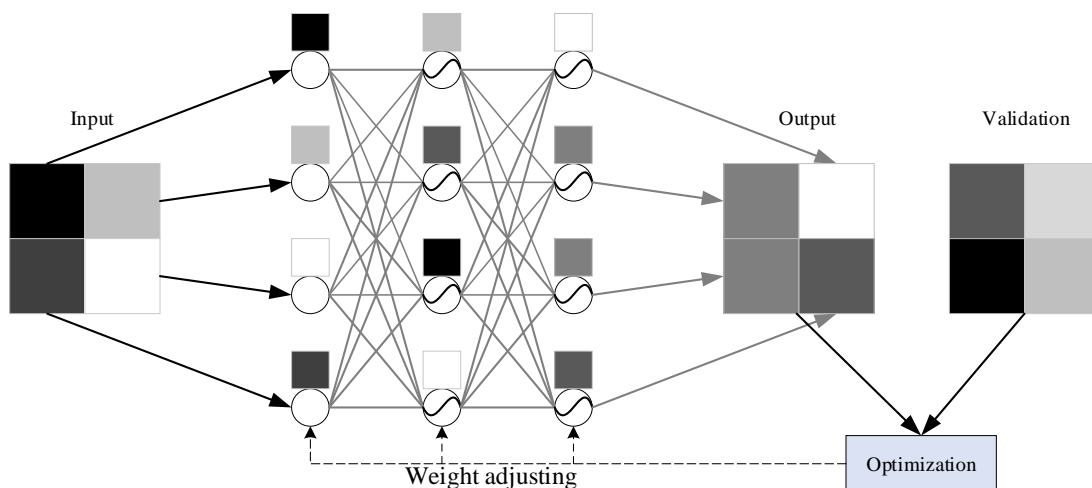
1.6.4 การกำจัดสัญญาณรบกวนในภาพถ่ายด้วยอัลกอริทึมประเภทการเรียนรู้เชิงลึก

แนวคิดของการใช้วิธีการกรองสัญญาณด้วย filter เป็นวิธีการที่ง่าย แต่อย่างไรก็ตามมักจะทำให้สัญญาณสำคัญของภาพถูกรองออกไปบางส่วนด้วยเนื่องจากเป็นสัญญาณที่มีความถี่หรือคุณลักษณะตรงกับสัญญาณรบกวน นอกจากนี้การใช้งาน filter จำเป็นต้องกำหนดค่าพารามิเตอร์และกำหนดเกณฑ์ thresholding ด้วยตัวเองในหลายๆ ขั้นตอน ซึ่งส่งผลอย่างมากต่อประสิทธิภาพการกำจัดสัญญาณรบกวนจากการกำหนดเกณฑ์ที่ผิดพลาด ด้วยเหตุนี้เทคนิค deep learning ในภาพประกอบ 1-18 ซึ่งเป็นการป้อนข้อมูลให้คอมพิวเตอร์เรียนรู้องค์ประกอบของภาพและสัญญาณรบกวนจึงเป็นเทคนิคที่ได้รับความนิยมอย่างมากในปัจจุบัน เนื่องจากสามารถนำมาใช้ในงานที่สัญญาณรบกวนมีความเฉพาะเจาะจงได้ดี และให้ผลลัพธ์ที่มีประสิทธิภาพสูงกว่าวิธี filter โดยในสวนนี้จะเป็นการอธิบายโครงสร้าง deep learning ที่ได้มีการนำมาใช้ในการกำจัดสัญญาณรบกวนต่างๆ โดยหลักการทำงานของ CNN จะเป็นการทำ convolution หรือ cross-correlation ระหว่างข้อมูล input และ kernel จากพารามิเตอร์ weight เพื่อแปลงข้อมูลใหม่เพื่อใช้เป็นข้อมูล input สำหรับชั้นซ่อนถัดไปเรื่อยๆ ซึ่งผลลัพธ์ที่ได้ในแต่ละชั้นซ่อน (hidden layer) จะขึ้นอยู่กับค่าพารามิเตอร์ weight ที่เกิดขึ้นในขณะนั้นตามสมการที่ 1.17 โดยค่าพารามิเตอร์ weight นี้เป็นพารามิเตอร์ที่ปรับค่าได้ตามข้อมูลที่ได้รับขณะเรียนรู้

$$f(x; W; b) = f(W^T x + b) \quad (1.17)$$

โดยที่ x คือ input ของ node ในชั้นนั้นๆ

W คือ weight เป็นพารามิเตอร์ที่สามารถปรับค่าตามการเรียนรู้ได้
 b คือ bias เป็นพารามิเตอร์ที่ไม่สามารถปรับค่าได้



ภาพประกอบ 1-18 ตัวอย่างการทำงานของ Convolution neural networks (CNNs)

จากภาพประกอบ 1-18 อธิบายวิธีการทำงานของการเรียนรู้เชิงลึกด้วยหลักการของ Convolution neural network (CNN) ซึ่งเป็นโครงสร้างการเรียนรู้เชิงลึกพื้นฐานที่ต่อยอดมาจาก multilayer perceptron (MLP) โดย CNN จะเป็นการสกัด feature (feature extraction) ของข้อมูลภาพไปเรื่อย ๆ เพื่อให้ได้ลักษณะของข้อมูลที่เด่นชัดในแต่ละชั้นซ่อน เพื่อนำไปหาผลลัพธ์สุดท้ายของ output ที่ต้องการ โดยจะต้องมีการนำชุดข้อมูลตรวจสอบ (validation) มาเป็นตัวเปรียบเทียบความถูกต้องของผลลัพธ์ของ output ที่ได้ ซึ่งจะมีการนำผลลัพธ์จากการเปรียบเทียบไปใช้ในกระบวนการ backpropagation ในการปรับค่าพารามิเตอร์ weight ของชั้นซ่อนในโครงสร้าง CNN ซึ่งประกอบด้วยการคำนวณค่า loss และการทำ optimization [62] โดยการบวนการปรับค่าพารามิเตอร์นี้จะทำซ้ำไปเรื่อย ๆ จนกว่าจะได้ผลลัพธ์ที่ต้องการหรือเข้าเงื่อนไขที่กำหนด

ในการคำนวณ loss ของโครงสร้างการเรียนรู้เชิงลึกจะเป็นการเปรียบเทียบผลลัพธ์ output ที่ได้จากโครงสร้างและคำตอบที่แน่นอนของชุดข้อมูลตรวจสอบเพื่อวัดความถูกต้องของ output โดยปกติแล้วมักจะใช้ loss function ตามสมการที่ 1.18 และ 1.19

$$L_1 = \sum_{i=1}^n |y_{true} - y_{pred}| \quad (1.18)$$

$$L_2 = \sum_{i=1}^n (y_{true} - y_{pred})^2 \quad (1.19)$$

- โดยที่ L_1 คือ mean absolute error loss
 L_2 คือ mean squared error loss
 y_{true} คือ validation สำหรับเปรียบเทียบความถูกต้องของ output
 y_{pred} คือ output ของโครงสร้างการเรียนรู้เชิงลึก

หลังจากคำนวณ loss จากการเปรียบเทียบ output กับ validation แล้ว จะนำค่า loss มาใช้ในกระบวนการปรับปรุงค่าพารามิเตอร์หรือ weight ของชั้นซ่อนในโครงสร้างการเรียนรู้เชิงลึกตามสมการที่ 1.20


$$W_{new} = W_{old} + \eta \frac{\partial L}{\partial w} \quad (1.20)$$

- โดยที่ W_{new} คือค่า weight ใหม่ที่ถูกปรับแล้ว
 W_{old} คือค่า weight ในรอบการ training ก่อนหน้า
 L คือ loss function ตามสมการที่ 1.18 และ 1.19
 x_i คือ input ของ network
 y_i คือ output ของ network

การปรับปรุงค่าพารามิเตอร์ของการเรียนรู้เชิงลึกหรือการปรับค่า weight นั้น ปกติแล้วจะปรับทุกๆ weight ของทุก node ในชั้นซ่อนด้วยสมการที่ 1.20 ซึ่งหากโครงสร้างการเรียนรู้เชิงลึกที่ใช้งานมีจำนวนชั้นซ่อนที่มากจะทำให้ขั้นตอนของการปรับปรุงค่าพารามิเตอร์ต้องใช้เวลาที่มากตามไปด้วย จึงทำให้การคำนวณของการเรียนรู้เชิงลึกมีความซับซ้อนที่สูงมากเมื่อเทียบกับการคำนวณของการ convolution ด้วย kernel filter

ในการใช้งานโครงสร้างการเรียนรู้เชิงลึก จะคำนึงถึงวัตถุประสงค์ของการจัดวางและเรียงตัวของชั้นซ่อนที่ใช้ โดยปกติแล้วโครงสร้างการเรียนรู้เชิงลึกจะสามารถนำมาใช้วิเคราะห์คุณลักษณะของข้อมูล (feature) ที่เกิดขึ้นในแต่ละชั้นซ่อนได้ ซึ่งโครงสร้างการเรียนรู้เชิงลึกมีการหลากหลายโครงสร้าง [63] ในส่วนนี้จะนำเสนอรูปแบบของโครงสร้างพื้นฐานการเรียนรู้เชิงลึกที่นำมาใช้ในการวิจัยการฟื้นฟูภาพถ่ายดิจิทัลในงานวิจัยนี้ดังนี้


1.6.5 Convolution neural network (CNN)



ภาพประกอบ 1-19 โครงสร้างของ convolution neural network

Convolution neural network (CNN) [64, 64] ในภาพประกอบ 1-19 เป็น โครงสร้างการ เรียนรู้เชิงลึก (deep learning) พื้นฐานที่พัฒนามาจาก multiple layer perceptron (MLP) ซึ่งมีชั้นซ่อน (hidden layer) หลายชั้นประกอบกัน โดยชั้นซ่อนแต่ละชั้นจะมีขนาดที่เท่ากัน ซึ่งใช้สำหรับการ สกัดคุณลักษณะ (feature) ของข้อมูล เมื่อพิจารณาตัวอย่างการสกัดคุณลักษณะของข้อมูลภาพ โดย ในชั้นที่ลึกขึ้นคุณลักษณะของภาพที่สกัดออกมาจะมีรายละเอียดของวัตถุในภาพที่ชัดเจนมากขึ้น ทำให้อัลกอริทึมการเรียนรู้เชิงลึกสามารถวิเคราะห์และแยกแยะประเภทของคุณลักษณะที่สกัด ออกมาได้ดีขึ้น โดยโครงสร้างแบบ CNN ที่นิยมนำมาใช้ในงานการสกัดคุณลักษณะของภาพ สำหรับใช้งานประเภททางด้านประมวลผลภาพมีอยู่หลายโครงสร้าง เช่น โครงสร้าง VGGs [66] , AlexNet [67] , DenseNet [68] และอื่นๆ

1.6.6 Autoencoder (AE)



ภาพประกอบ 1-20 โครงสร้างของ Autoencoder

Autoencoder (AE) [69, 70] มีหลักการทำงานเช่นเดียวกับ CNN แต่การจัดเรียงโครงสร้างของ AE จะมีการลดขนาดพารามิเตอร์ weight และจำนวน node ข้อมูลในแต่ละชั้นซ่อนที่ลึกลงไปเรื่อย ๆ โดยจะเรียกโครงสร้างที่ลดจำนวนพารามิเตอร์นี้ว่า encoder และจะเพิ่มจำนวนพารามิเตอร์ของชั้นซ่อนอีกครั้งในฝั่งโครงสร้างที่เรียกว่า decoder ตามภาพประกอบ 1-20 โดยชั้นซ่อนที่อยู่ตรงกลางของ AE จะเรียกว่า coder layer ซึ่งเป็นชั้นที่มีจำนวนพารามิเตอร์น้อยที่สุด ซึ่งทำให้โครงสร้างของ AE สามารถลดตัวแปรที่ใช้ได้ โดย coder layer จะเป็นการสกัด feature ที่สำคัญของข้อมูล input ซึ่งสามารถนำไปใช้ในการจำแนกและหาผลลัพธ์ต่อไปได้จากกระบวนการเรียนรู้เพื่อปรับค่าพารามิเตอร์ weight


1.6.7 Residual network

Residual network [33] เป็นโครงสร้างส่วนเสริมของการเรียนรู้เชิงลึกซึ่งไม่ใช่โครงสร้างหลัก โดยมีแนวคิดมาจากปัญหาในโครงสร้างหลักของการเรียนรู้เชิงลึกที่ใช้ในปัจจุบันได้แก่ CNN และ AE ที่แม้ว่าสามารถเพิ่มประสิทธิภาพด้วยการเพิ่มจำนวนชั้นซ่อน (hidden layer) จะเพิ่มความแม่นยำในการคำนวณที่มากยิ่งขึ้น แต่ในความเป็นจริงนั้นการเพิ่มจำนวนชั้นซ่อนที่มากเกินไปจะทำให้โครงสร้าง network เกิดปัญหา vanishing gradient ขึ้น [33, 34] ซึ่งเป็นปัญหานี้เกิดจากการที่ค่าพารามิเตอร์ weight ของชั้นซ่อนที่อยู่ลึกลงไปของ network จะมีการเปลี่ยนแปลงค่าน้อยมากหรือ

อาจไม่เปลี่ยนแปลงค่าเลขขณะอยู่ในขั้นตอน training ซึ่งเป็นผลให้ประสิทธิภาพที่ได้จากการเพิ่มจำนวนชั้นซ่อนนั้นอาจไม่ดีเท่าที่ควร โดยแสดงปัญหาของการที่ค่า weight ไม่มีการปรับค่าขณะเรียนรู้ตามสมการที่ 1.21

$$W_{new} = W_{old} ; \frac{\partial e}{\partial w} \approx 0 \quad (1.21)$$

Residual network เป็นการนำ feature หรือข้อมูลของชั้นซ่อนก่อนหน้ามาป้อนกลับเข้าไปในชั้นซ่อนถัดๆ ไปตามภาพประกอบที่ 1.19 ซึ่งวิธีการนี้สามารถป้องกันปัญหา vanishing gradient ได้ตามสมการที่ 1.22 และ 1.23




ภาพประกอบ 1-21 โครงสร้าง residual unit


$$W_{new} = W_{old} + \eta \left(\frac{\partial e}{\partial w} + \frac{\partial x}{\partial w} \right) \quad (1.22)$$

$$W_{new} = W_{old} + \eta \frac{\partial x}{\partial w} ; \frac{\partial e}{\partial w} = 0 \quad (1.23)$$

ทั้ง CNN และ AE สามารถเกิดปัญหา vanishing gradient ได้ ทำให้มีการนำเสนอ ResNet [33] และ U-net [34] ตามภาพประกอบ 1-22 และภาพประกอบ 1-23 ซึ่งเป็นการนำแนวคิดของ residual network มาช่วยปรับปรุงโครงสร้างเดิมเพื่อเพิ่มประสิทธิภาพให้แก่ระบบการเรียนรู้ของ network เอง



ภาพประกอบ 1-22 โครงสร้างของ ResNet

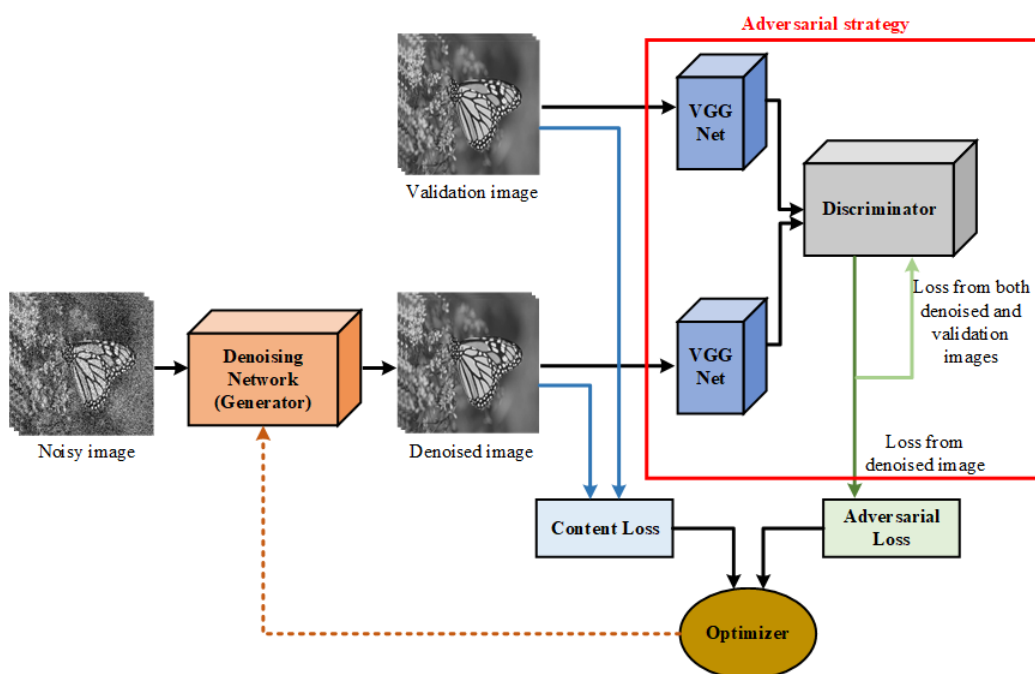


ภาพประกอบ 1-23 โครงสร้างของ U-net

แม้ว่า Residual network จะสามารถเพิ่มประสิทธิภาพของโครงสร้างการเรียนรู้เชิงลึกได้ โดยสามารถทำให้ loss ของโครงสร้างการเรียนรู้เชิงลึกคู่เข้าจุดต่ำกว่าโครงสร้างแบบเดิมได้ แต่อย่างไรก็ตามในการใช้งานจริงไม่สามารถระบุได้ชัดเจนว่าเมื่อไหร่ค่า loss จากการเรียนรู้จะต่ำที่สุด เนื่องจากไม่สามารถระบุจุดสิ้นสุดการเรียนรู้ที่แน่ชัดได้นั่นเอง โดยอาจสามารถแก้ปัญหานี้ได้ด้วยการใช้ stopping criteria เช่นการกำหนดจำนวนรอบ หรือการใช้ early stopping เมื่อ loss ของคุณลักษณะที่ใช้วัดอื่นๆ อยู่ในระดับที่กำหนด

1.6.8 GANs

Generative adversarial networks (GANs) [35] ในภาพประกอบ 1-24 เป็นโครงสร้างของ network การเรียนรู้เชิงลึกที่ประกอบด้วย network ย่อย 2 networks ได้แก่ generator และ discriminator โดย generator มีหน้าที่รับ input และเรียนรู้เพื่อสร้าง output ให้มีลักษณะเหมือนชุด validation ให้มากที่สุด โดยมี discriminator ตรวจสอบค่อยตรวจสอบ โดย discriminator จะมีหน้าที่ตรวจจับว่าภาพไหนที่เป็นภาพจาก generator หรือจาก validation ในแต่ละรอบการเรียนรู้ ซึ่งเป็นแนวคิดนี้จะสามารถเพิ่มขีดความสามารถของ generator ได้ จากการแข่งขันกันเอาชนะกันของ 2 network (competitive learning)



ภาพประกอบ 1-24 Generative adversarial networks (GANs) ในงานฟื้นฟูภาพถ่าย

การเรียนรู้ของ GANs จะอาศัยหลักการของทฤษฎี zero-sum game theory ซึ่งเป็นหลักการนับคะแนนสำหรับผู้ชนะและหักคะแนนสำหรับผู้แพ้ในแต่ละรอบ โดยใช้ในการปรับ weight ของ network ด้วยหลักการดังกล่าว โดยจะได้ความสัมพัทธ์ของการเรียนรู้ตามสมการที่ 1.24 และ 1.25 สำหรับคำนวณค่า loss ของ generator และ discriminator ตามลำดับ

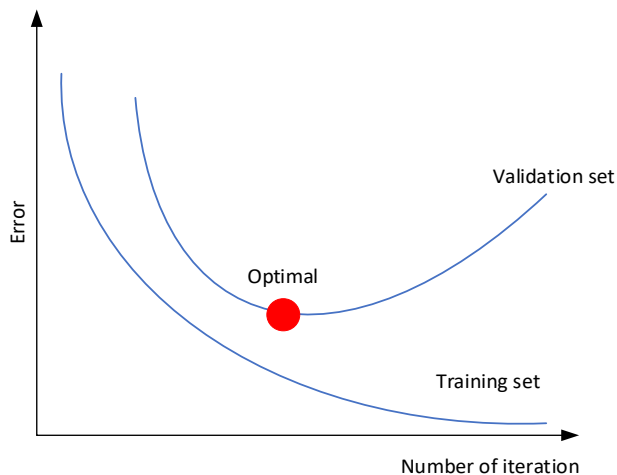
$$L_{generator} = \min[\log(1 - D(G(z)))] \tag{1.24}$$

$$L_{discriminator} = \max [\log(D(x)) + \log(1 - D(G(z)))] \quad (1.25)$$

โดยที่ $L_{generator}$ คือ loss ของ generator network
 $L_{discriminator}$ คือ loss ของ discriminator network
 $D(x)$ คือความน่าจะเป็นที่ discriminator จำแนกข้อมูลจาก validation ได้
 $G(z)$ คือข้อมูลหลอกที่ generator สร้างขึ้น เพื่อแข่งขันกับ discriminator

แม้ว่าการเรียนรู้ของ GANs จะมีแนวคิดเพิ่มประสิทธิภาพของโครงสร้างการเรียนรู้ด้วยการแข่งขัน อย่างไรก็ตามมักจะเกิดปัญหา over-fitting [71] ซึ่งเกิดจากการพยายามเอาชนะกันของ generator และ discriminator ทำให้ loss ของ network ขณะ training มีการแกว่งไปมาที่สูงในแต่ละรอบ ทำให้ได้ผลลัพธ์และจุดจบของการเรียนรู้ที่ไม่แน่นอนของกระบวนการเรียนรู้ เนื่องจากไม่สามารถระบุได้อย่างชัดเจนว่ากระบวนการ training นั้นควรจะหยุดที่ตรงไหน นอกจากนี้ในบางกรณี generator ไม่สามารถเอาชนะ discriminator ได้ เนื่องจากภาพที่ต้องการให้ generator สร้างข้อมูลเลียนแบบนั้นมีความซับซ้อนมากเกินไปจน generator ไม่อาจสร้างเลียนแบบได้อย่างสมบูรณ์

จากการที่ได้นำเสนอปัญหาของการใช้งานโครงสร้างการเรียนรู้เชิงลึก พบว่าปัญหา over-fitting เป็นปัญหาที่สำคัญอย่างหนึ่ง เนื่องจากเป็นปัญหาที่ส่งผลกระทบต่อประสิทธิภาพของผลลัพธ์ output ของการเรียนรู้เชิงลึกโดยตรง และในหลายสถานการณ์อาจไม่สามารถระบุจุดสิ้นสุดการเรียนรู้ได้ชัดเจนจึงต้องปล่อยให้กระบวนการเรียนรู้ดำเนินต่อไป และเพื่อให้โครงสร้างการเรียนรู้เชิงลึกมีประสิทธิภาพดียิ่งขึ้นจึงต้องเรียนรู้ด้วยข้อมูลจำนวนมาก และมักต้องเรียนรู้ชุดข้อมูลเดิมซ้ำๆ หลายรอบเพื่อให้ได้ผลลัพธ์ที่ดีขึ้น แต่อย่างไรก็ตามในความเป็นจริงนั้น การเรียนรู้ด้วยชุดข้อมูลเดิมมากเกินไปจนความจำป็นจะทำให้โครงสร้างการเรียนรู้เชิงลึกเกิดปัญหา over-fitting ซึ่งเกิดจากการเรียนรู้ที่ยึดติดกับโครงสร้างข้อมูลเดิม ๆ ที่ป้อนเข้าไปในกระบวนการเรียนมากเกินไป และเมื่อนำชุดข้อมูลใหม่ที่ไม่เคยผ่านการเรียนรู้มาก่อนและมีคุณลักษณะข้อมูลต่างออกไป อาจทำให้การเรียนรู้เชิงลึกแสดงผลลัพธ์ออกมาได้ไม่ดีเท่าที่ควร ซึ่งปัญหา over-fitting เป็นปัญหาของประสิทธิภาพการเรียนรู้ชุดข้อมูลตรวจสอบ (validation) ที่ไม่สัมพันธ์กับข้อมูลทดสอบ (testing) ตามภาพประกอบ 1-25



ภาพประกอบ 1-25 over-fitting ที่เกิดขึ้นระหว่างการ training ที่มากเกินไป

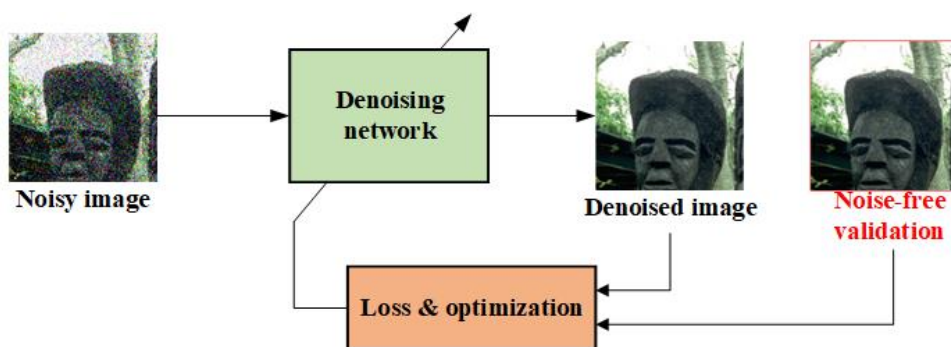
เพื่อแก้ปัญหา over-fitting และจุดสิ้นสุดการเรียนรู้ เทคนิค early stopping [72] จึงเป็นเทคนิคในการหาจุดเหมาะสม (optimal) สำหรับหาจำนวนรอบในการ training ชุดข้อมูล เพื่อป้องกันปัญหา over-fitting จากการเรียนรู้ที่มากเกินไป โดยปกติแล้วขณะเรียนรู้เราสามารถเก็บผลการเรียนรู้ในแต่ละรอบได้ ซึ่งสามารถนำมาตรวจสอบหาจุด optimal ของกระบวนการเรียนรู้นั้นๆ ได้ และการใช้คุณลักษณะบางอย่างที่เหมาะสมกับปัญหาของงาน จึงจะสามารถบอกถึงจุดที่ผลลัพธ์ output มีความคล้ายกับชุด validation ได้เช่นกัน เช่น การใช้โครงสร้างขอบของวัตถุ การวัดค่า contrast ของสีเทียบกับ validation และอื่นๆ เป็นต้น

1.7 Deep learning framework สำหรับการกำจัดสัญญาณรบกวนในภาพดิจิทัล

ในงานวิจัย Noise2Noise [25] ได้จำแนกรูปแบบ framework การเรียนรู้เชิงลึกของการกำจัดสัญญาณรบกวนออกเป็น 2 ชนิดได้แก่ วิธีการเรียนรู้การแปลงภาพที่มีสัญญาณรบกวน (noisy image) ไปเป็นภาพไม่มีสัญญาณรบกวน (clean image) โดยตรง โดยเรียกการเรียนรู้แบบนี้ว่า Noise2Clean (N2C) framework [73, 74, 75, 76] และวิธีการแปลงภาพที่มีสัญญาณรบกวนในโดเมนหนึ่งไปเป็นภาพที่สัญญาณรบกวนในอีกโดเมนหนึ่งจากชุดข้อมูลที่มีสัญญาณรบกวนอื่นๆ โดยเรียกการเรียนรู้นี้ว่า Noise2Noise (N2N) framework [25, 77, 78] โดยจะอธิบายการทำงานของ N2C และ N2N ดังนี้

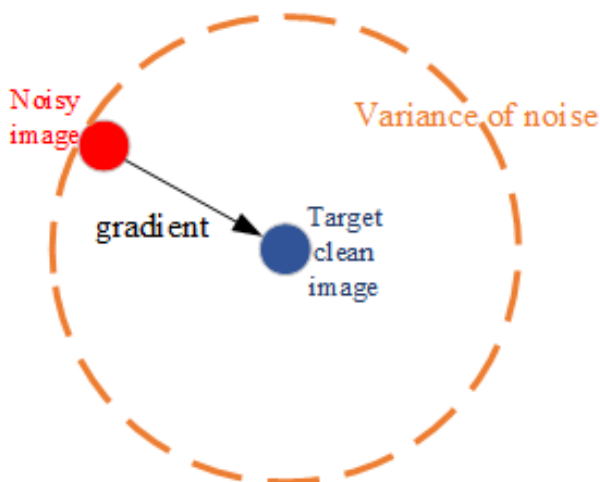
1.7.1 Noise2Clean

การฟื้นฟูภาพถ่ายและกำจัดสัญญาณรบกวนด้วยการเรียนรู้เชิงลึกแบบดั้งเดิมมักจะใช้ชุดข้อมูลในการเรียนรู้ที่ประกอบด้วยภาพถ่ายที่มีสัญญาณรบกวนเป็น input และชุดข้อมูลภาพที่ปราศจากสัญญาณรบกวนสำหรับการ validation ซึ่งการเรียนรู้เชิงลึกในลักษณะนี้จะเป็นการเรียนรู้การ transfer จาก noisy domain ไปยัง noise-free domain โดยตรง จึงเรียกการเรียนรู้ลักษณะนี้ว่า Noise2Clean (N2C) ดังภาพประกอบ 1-26



ภาพประกอบ 1-26 Noise2Clean framework

การเรียนรู้ของการเรียนรู้เชิงลึกสามารถอธิบายการ transform ได้ในภาพประกอบ 1-27 และสมการที่ 1.26 โดยที่ N2C ในกระบวนการ training จะพยายาม transfer ค่า pixel ของภาพให้เหมือน pixel ณ ตำแหน่งนั้นๆ ของชุดข้อมูล validation หรือ clean target เมื่อผ่านการเรียนรู้หลายรอบ N2C สามารถที่จะประมาณค่าสีได้ถูกต้องแม่นยำมากยิ่งขึ้น



ภาพประกอบ 1-27 แนวคิดของการเรียนรู้ของ N2C framework

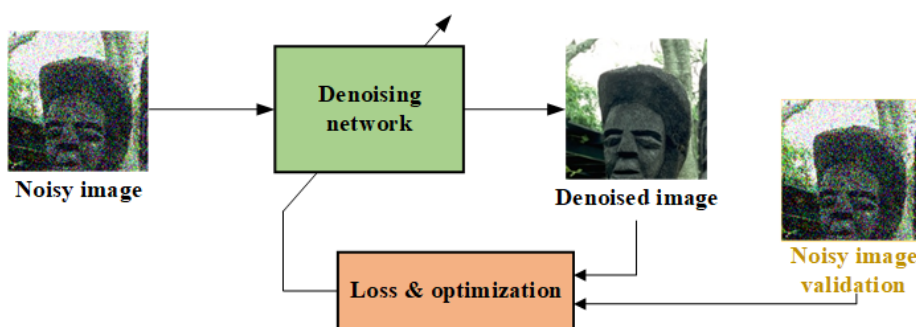
$$\operatorname{argmin}_{\theta} \sum_{i=1}^N |f_{\theta}(x_n + n_i) - (x_n)|^2 \quad (1.26)$$

โดยที่ f_{θ} คือ output ของ network การเรียนรู้
 x_n คือภาพ validation ที่ใช้ในการ training
 n_i คือสัญญาณ noise ของในการ training

แต่อย่างไรก็ตามแม้ว่า N2C จะสามารถกำจัดสัญญาณรบกวนจากระบวนการ training ชุดข้อมูลที่มีอยู่ได้ดี แต่หากนำไปใช้กับชุดข้อมูลใหม่ที่มีโครงสร้างของสัญญาณรบกวนต่างออกไปจะทำให้ N2C มีประสิทธิภาพที่ลดลงได้ เนื่องจากการ training ด้วยวิธี N2C จะทำให้ network มักจะ fit กับชุดข้อมูลที่ใช้ training ได้ นอกจากนี้ปัญหาในบางกรณีที่ไม่สามารถจัดหาชุดข้อมูลภาพที่ปราศจากสัญญาณรบกวนได้ เช่น กรณีปัญหา single image หรือ blind noise ก็จะไม่สามารถใช้ N2C framework ในลักษณะนี้มากำจัดสัญญาณรบกวนและฟื้นฟูภาพถ่ายได้

1.7.2 Noise2Noise

จากปัญหาการขาดแคลนชุดข้อมูลสำหรับการเรียนรู้และข้อจำกัดของการเรียนรู้ด้วยวิธี N2C framework ที่ไม่อาจใช้งานได้ จึงได้มีแนวคิดของ Noise2Noise (N2N) ดังภาพประกอบ 1-28 ซึ่งเป็น framework สำหรับ transform noisy domain หนึ่งไปยังอีก noisy domain หนึ่ง



ภาพประกอบ 1-28 Noise2Noise framework

โดยหลักการของ N2N framework จะอาศัยประโยชน์ความเป็น generalize ของการเรียนรู้ของการเรียนรู้เชิงลึกเอง ซึ่งขณะเรียนรู้ชุดข้อมูลที่ป้อนเข้าไปในกระบวนการเรียนรู้ ตัวโครงสร้างการเรียนรู้เชิงลึกจะพยายามปรับสมดุลของพารามิเตอร์เพื่อให้สามารถหาผลลัพธ์ที่เหมาะสมที่สุด (optimal point) สำหรับที่ข้อมูลที่ใช้ในการเรียนรู้ โดยปกติแล้วในงานทางด้านฟื้นฟูภาพถ่ายมักจะเป็นข้อมูลภาพถ่ายที่มักจะมีรายละเอียดของคุณลักษณะของชุดข้อมูลที่สูง ทำให้กระบวนการเรียนรู้

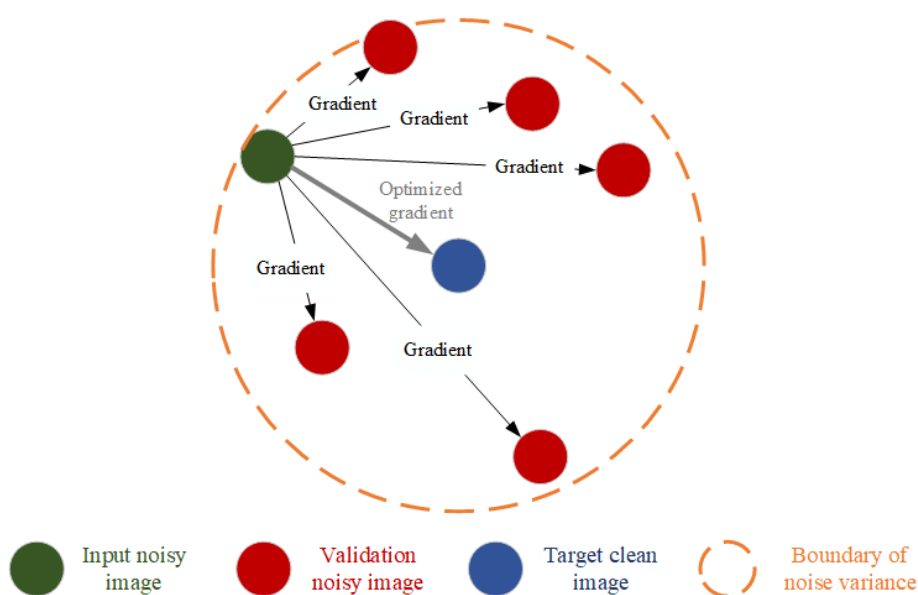
ไม่สามารถ transfer ข้อมูล input ไปเป็น validation ได้อย่างสมบูรณ์ ซึ่งเมื่อวัดค่า error ของการเรียนรู้จะไม่เท่ากับศูนย์แบบอุดมคตินั่นเอง ตามสมการที่ 1.27 และ 1.28

$$\operatorname{argmin}_{\theta} \sum_{i=1}^N |f_{\theta}(x_n + n_{i,1}) - (x_n + n_{i,2})|^2 \quad (1.27)$$

$$f_{\theta}(n_{i,1}) - n_{i,2} \approx 0 \quad (1.28)$$

- โดยที่ f_{θ} คือ output ของ network
 x_n คือภาพ validation ที่ใช้ในการเรียนรู้ของการเรียนรู้เชิงลึก
 n_i คือสัญญาณ noise ของในการ training

จากแนวคิดการใช้ประโยชน์จากความเป็น generalize ของกระบวนการเรียนรู้ จึงสามารถทำให้โครงสร้างการเรียนรู้เชิงลึกกำจัดสัญญาณรบกวนในลักษณะคล้ายกับการนำข้อมูล input และ validation มาหาค่าเฉลี่ยกันนั่นเอง ซึ่งแสดงแผนภาพแนวคิดของ N2N framework ตามภาพประกอบ 1-29



ภาพประกอบ 1-29 แนวคิดของการเรียนรู้ของ N2N framework

จากภาพประกอบ 1-29 การเรียนรู้ของ N2N framework จะพยายามเรียนรู้การ transfer ภาพ input domain ไปยังภาพ validation อื่นๆ แต่เนื่องจาก validation นั้นมีหลาย domain ด้วยกัน และ

สมมุติฐานว่าสัญญาณรบกวนของกระบวนการเรียนรู้ของภาพ input และ validation นี้อยู่ใน distribution ของสัญญาณรบกวนเดียวกัน ดังนั้นกระบวนการเรียนรู้ที่เกิดขึ้น N2N framework จึงพยายามเฉลี่ยผลลัพธ์ที่เกิดขึ้นเพื่อให้ค่า loss การเรียนรู้ต่ำที่สุด

บทที่ 2

วิธีการวิจัย

ในบทนี้จะนำเสนอทฤษฎีบทที่ใช้ในการทดลอง อธิบายข้อมูล (dataset) ที่ใช้และการจัดการกับข้อมูลในการวิจัย การวัดผลที่ใช้ในการวิจัย และขั้นตอนการทดลองซึ่งจะแบ่งออกเป็น 3 การทดลองย่อยได้แก่ การทดลอง edge-perceptual loss สำหรับการกำจัดสัญญาณรบกวน การทดลอง self-validation Noise2Noise framework และการทดลองเปรียบเทียบการฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและการลดทอนความละเอียดของภาพถ่าย โดยจะอธิบายการตั้งค่าการทดลองสำหรับวิเคราะห์ผลการทดลองต่อไปในบทที่ 3


2.1 ข้อมูลที่ใช้ในการทดลอง

ในการทดลองนี้ได้ใช้ชุดข้อมูลภาพมาตรฐานสำหรับงานทางด้าน image processing ซึ่งประกอบด้วยข้อมูลจาก 4 แหล่งได้แก่ BSD100 (100 รูป) [26] Set14 (14 รูป) [27] Urban100 (100 รูป) [28] และ SunHay80 (80 รูป) [29] โดยอธิบายลักษณะของข้อมูลภาพดังนี้

- BSD100 (Berkeley Segmentation Dataset) เป็นชุดข้อมูลที่นิยมนำมาใช้ในงาน segmentation และ boundary detection ประกอบด้วย 100 รูป ที่มีภาพวัตถุต่างๆ ภายในภาพ โดยมักถูกนำมาใช้ในงานประเภทการฟื้นฟูภาพถ่ายในหลายงานวิจัย
- Set14 เป็นชุดข้อมูลภาพสำหรับงานทางการประมวลผลภาพทั่วไป ซึ่งประกอบด้วย 14 รูป และมักถูกนำมาใช้ในงานทางการฟื้นฟูภาพถ่ายต่างๆ ทั้งงาน image denoising และ image super-resolution
- Urban100 เป็นชุดข้อมูลรูปภาพประเภทตึกและสิ่งก่อสร้างต่างๆ ประกอบด้วย 100 รูป โดยมักเป็นภาพที่มีลักษณะเด่นชัดในเรื่องของขอบและมุมของภาพ ซึ่งสามารถนำมาใช้ในงานด้านการประมวลผลภาพทั่วไปเช่นกัน
- SunHay80 เป็นข้อมูลภาพถ่าย ซึ่งเป็นภาพทิวทัศน์ตามสถานที่ต่างๆ โดยประกอบด้วย 80 ภาพ และมีการนำมาใช้ในงานทางการประมวลผลภาพ

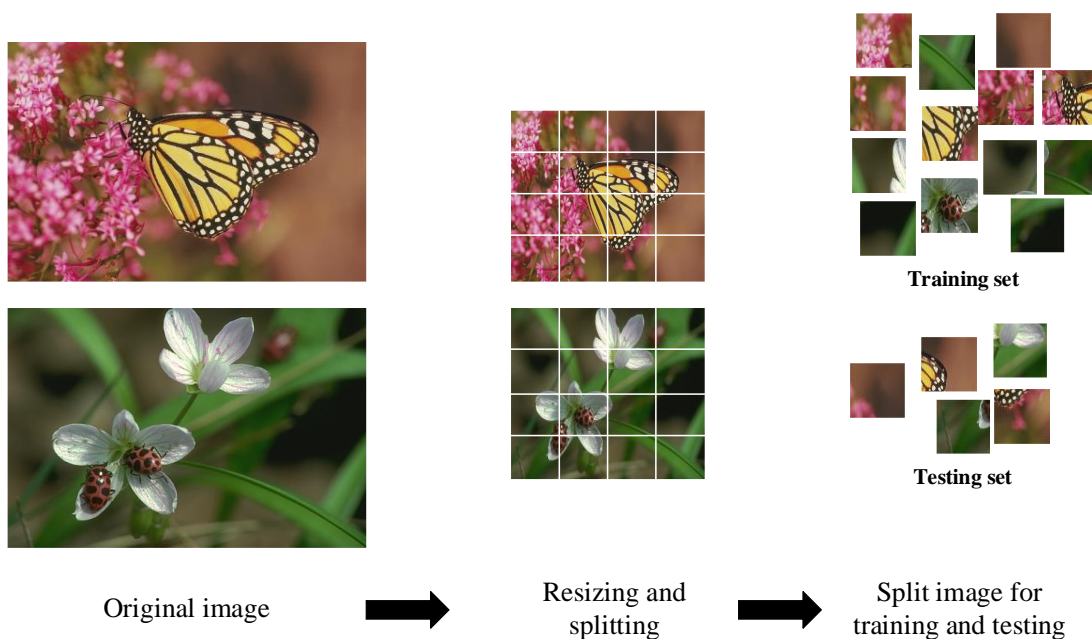
โดยภาพทั้งหมดจะถูกนำมารวมกันและปรับขนาดรูปใหม่เป็น 256 x 256 pixel โดยจะแปลงเป็น grayscale สำหรับการทดลองที่ 1 การทดลอง edge-perceptual loss สำหรับกำจัดสัญญาณ

รบกวน ซึ่งจำเป็นต้องใช้ภาพ grayscale ในการหาขอบของวัตถุ โดยแบ่งภาพสำหรับการ training จำนวน 235 ภาพ (เท่ากับ 80%) และภาพสำหรับการ testing จำนวน 59 ภาพ (เท่ากับ 20%)



ภาพประกอบ 2-1 ขั้นตอนการเตรียมข้อมูลสำหรับการเรียนรู้ของ edge-perceptual loss

สำหรับการทดลองที่ 2 การทดลอง self-validation Noise2Noise (SV-N2N) framework และการทดลองที่ 3 การทดลองเปรียบเทียบการฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและลดทอนความละเอียดของภาพจะใช้ภาพสีตามต้นฉบับของ dataset โดยจะทำ augmentation ด้วยการตัดภาพจากขนาดดั้งเดิมทั้งหมดมาเป็น 128x128 pixel ซึ่งจะได้ภาพสำหรับการทดลองทั้งหมด 8,836 ภาพ ซึ่งจะสุ่มแบ่งเป็นภาพสำหรับการ training 7,068 ภาพ (80% ของภาพทั้งหมด) และภาพสำหรับการ testing จำนวน 1,768 (20% ของภาพทั้งหมด)



ภาพประกอบ 2-2 ขั้นตอนการเตรียม dataset ที่ใช้ในการทดลองที่ 2 และการทดลองที่ 3

สำหรับการทดลองเปรียบเทียบการกำจัดสัญญาณรบกวนกับอัลกอริทึม unsupervised-learning อื่นๆ จะเปรียบเทียบด้วยการใช้ชุดข้อมูล real-world dataset ทั้งหมด 3 แหล่งดังนี้

- NIND dataset [30] เป็นชุดข้อมูลภาพถ่ายจากฉากจริง ซึ่งจับภาพด้วยความหลากหลายของค่า ISO ที่ใช้ในการถ่ายภาพ ซึ่งสัญญาณรบกวนที่เกิดขึ้นจะเกิดจากการปรับค่า ISO ของกล้องถ่ายภาพที่สูง และจะใช้ค่า ISO ต่ำสุดที่ค่า 100 เป็น ground truth สำหรับใช้อ้างอิงภาพที่ไม่มีสัญญาณรบกวน
- SIDD dataset [31] เป็นชุดข้อมูลจากการถ่ายภาพด้วยระดับความเข้มแสงที่ต่างกัน รวมทั้งถ่ายจากเดียวกับด้วยกล้อง smartphone หลายๆ ยี่ห้อ ภาพ ground truth จะเป็นค่าเฉลี่ยของ pixel จากกล้องถ่ายภาพทั้งหมด
- Fluorescence Microscopy Denoising (FMD) dataset [32] เป็นสัญญาณรบกวนประเภท Poisson-Gaussian ของภาพ fluorescence microscopy จากเซลล์และสิ่งมีชีวิตขนาดเล็ก โดยที่มีระดับการถูกรบกวนหลากหลายระดับ และใช้ค่าเฉลี่ยเป็น ground truth ในการเปรียบเทียบผลการกำจัดสัญญาณรบกวน

2.2 การวัดคุณภาพของภาพถ่ายดิจิทัลสำหรับเปรียบเทียบผลการทดลองในงานวิจัยนี้

โดยปกติแล้วการวัดประสิทธิภาพของอัลกอริทึมในการฟื้นฟูภาพถ่ายสามารถทำได้ด้วยการเปรียบเทียบผลลัพธ์ของ output กับ validation สำหรับงานวิจัยนี้ได้ใช้การวัดประสิทธิภาพของอัลกอริทึมด้วยวิธี peak signal to noise ratio (PSNR) และ structural similarity (SSIM) index [79] โดยจะอธิบายการคำนวณของแต่ละวิธีดังนี้

2.2.1 Peak signal to noise ratio (PSNR)

การวัด PSNR ในภาพถ่ายจะเป็นการวัดความถูกต้องของ pixel ทุกตำแหน่งระหว่างภาพ output ของอัลกอริทึมและตัวเปรียบเทียบหรือ validation โดย PSNR เปรียบเป็นค่ากำลัง (power) ของสัญญาณภาพที่เป็นไปได้ต่อกำลังของสัญญาณรบกวนซึ่งส่งผลต่อภาพที่แสดงออกมาให้เห็นในการคำนวณจะใช้ mean squared error ในสมการที่ 2.1 ก่อนนำมาคำนวณเป็นค่า PSNR ในสมการที่ 2.2

$$MSE = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n (X(i,j) - Y(i,j))^2 \quad (2.1)$$

$$PSNR = 20 \log \left(\frac{L}{MSE} \right) \quad (2.2)$$

โดยที่ $X(i,j)$ และ $Y(i,j)$ คือตำแหน่ง pixel ของภาพ X และภาพ Y
 L คือค่าสีโดยขึ้นอยู่กับ format ของภาพนั้นๆ

2.2.2 Structural similarity (SSIM) index

เป็นการคำนวณการวัดคุณภาพของภาพโดยมองถึงความคล้ายคลึงกัน (similarity) ของโครงสร้าง ซึ่งใช้การคำนวณจาก 3 คุณลักษณะ (feature) ของภาพถ่าย ได้แก่ ความสว่างของภาพ (luminance) ความเปรียบต่าง (contrast) และ โครงสร้าง (structure) โดยแสดงการคำนวณด้วยสมการที่ 2.3 - 2.5

$$SSIM(X, Y) = [l(X, Y)]^2 \cdot [c(X, Y)]^2 \cdot [s(X, Y)]^2 \quad (2.3)$$

$$SSIM(X, Y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (2.4)$$

$$\sigma_{xy} = \sum_{i=1}^N (x_i - \mu_x)(y_i - \mu_y) \quad (2.5)$$

โดยที่ μ_x และ μ_y	คือค่าเฉลี่ยของ pixel ในภาพ X และภาพ Y
σ_x และ σ_y	คือค่า standard deviation ของภาพ X และภาพ Y
σ_{xy}	คือค่า standard deviation ของภาพ X เปรียบเทียบกับภาพ Y


ในการใช้งาน PSNR และ SSIM สามารถนำมาเปรียบเทียบผลลัพธ์ที่เกิดขึ้นกับอัลกอริทึมอื่นๆ ได้ ซึ่งในงานวิจัยนี้จะใช้ PSNR เป็นค่าเปรียบเทียบหลักสำหรับทุกการทดลอง เพื่อเปรียบเทียบประสิทธิภาพความแม่นยำของแต่ละอัลกอริทึม สำหรับค่า SSIM จะนำมาใช้เปรียบเทียบความถูกต้องเพิ่มเติมในการทดลองที่ 2 และ 3 เนื่องจากการเปรียบเทียบ PSNR สำหรับการทดลองการเรียนรู้แบบ supervised-learning นั้นอาจมีผิดพลาดในเรื่องของสิ่งที่ผิดเพี้ยนไปกว่าการเรียนรู้แบบ supervised-learning ซึ่งมีความต้องการวัดผลเชิงโครงสร้างด้วย

2.3 อธิบายทฤษฎีและหลักการของ edge-perceptual loss สำหรับการกำจัดสัญญาณรบกวนด้วยการเรียนรู้เชิงลึก

ในงานวิจัยนี้ได้นำเสนอการเพิ่มคุณลักษณะของขอบของวัตถุ (edge) มาช่วยเพิ่มประสิทธิภาพของการเรียนรู้ เนื่องจากการใช้เพียง loss function จากการคำนวณค่า pixel-wise เพียงอย่างเดียวอาจไม่เพียงพอต่อประสิทธิภาพที่ดีของการกำจัดสัญญาณรบกวนของการเรียนรู้เชิงลึก ประกอบกับการศึกษาผลกระทบของ noise ต่อการทำ edge detection [80] ตามภาพประกอบ 2-3 พบว่าเมื่อระดับของ noise เพิ่มขึ้นจะทำให้การหาขอบของภาพวัตถุขาดความชัดเจนมากขึ้น เนื่องจากสัญญาณรบกวนที่เกิดขึ้นในภาพถ่ายจะรบกวนคุณลักษณะต่างๆ ของภาพได้โดยเฉพาะคุณลักษณะของขอบของวัตถุภายในภาพ งานวิจัยนี้จึงได้สังเกตเห็นถึงประโยชน์ของการใช้คุณลักษณะของขอบของวัตถุ (edge feature) มาเป็นส่วนหนึ่งของการคำนวณ loss ของการเรียนรู้เป็น edge-perceptual loss



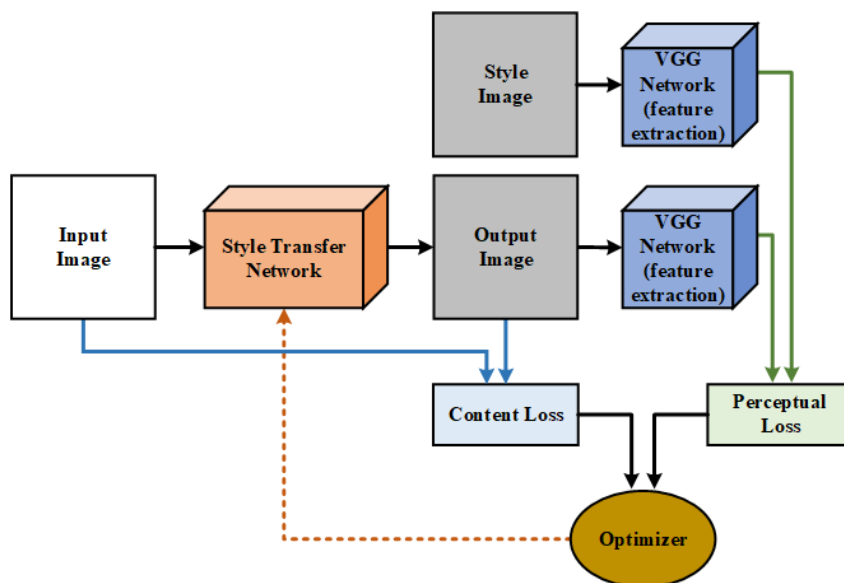
Clean image



Gaussian noise image

ภาพประกอบ 2-3 แสดงผลกระทบของ noise ต่อ edge detection

แนวคิดของ perceptual loss ได้ถูกนำเสนอใน [81] สำหรับงาน image style transfer ตามภาพประกอบ 2-4 ซึ่งเป็นการใช้ multiply loss function แบบหนึ่งเพื่อคำนวณความคล้ายกัน (similarity) ของภาพ 2 ภาพที่มีรูปแบบ (style) ของลักษณะภาพต่างกัน โดยในงาน image style transfer ต้องการแปลงภาพ input ที่มี style แบบหนึ่งให้ดูเหมือน style ของภาพ style image validation ซึ่งการใช้งาน perceptual loss จึงเป็นการปรับสมดุลของค่า loss ที่เปรียบเทียบกับ input และ validation ให้มีค่าน้อยที่สุด



ภาพประกอบ 2-4 image style transfer network ซึ่งใช้ perceptual loss ในการเรียนรู้

จากภาพประกอบ 2-4 image style transfer network จะนำภาพ input เข้าไปใน style transfer network เพื่อเรียนรู้การเปลี่ยน style ของภาพผ่านการเปรียบเทียบภาพ output กับภาพ input เดิม และ style image validation โดยค่า loss ในการเปรียบเทียบ output และ input เดิมจะเรียกว่า content loss และ loss ที่เกิดจากการเปรียบเทียบภาพ output กับ style image คือ perceptual loss ซึ่งการคำนวณ perceptual loss มักจะใช้การสกัดคุณลักษณะ (feature extraction) ด้วย VGG network [66] สำหรับลดความซับซ้อนของคุณลักษณะของภาพ

ในการเรียนรู้ซึ่งลึกสำหรับที่ใช้ perceptual loss จะนำ loss ทั้ง 2 ค่าที่ได้กล่าวไปแล้วมาคำนวณรวมกันเพื่อปรับสมดุลของ loss ที่เกิดขึ้นในมีค่าน้อยที่สุดด้วยกระบวนการเรียนรู้ โดยใช้สมการคำนวณ perceptual loss นี้ตามสมการที่ 2.6

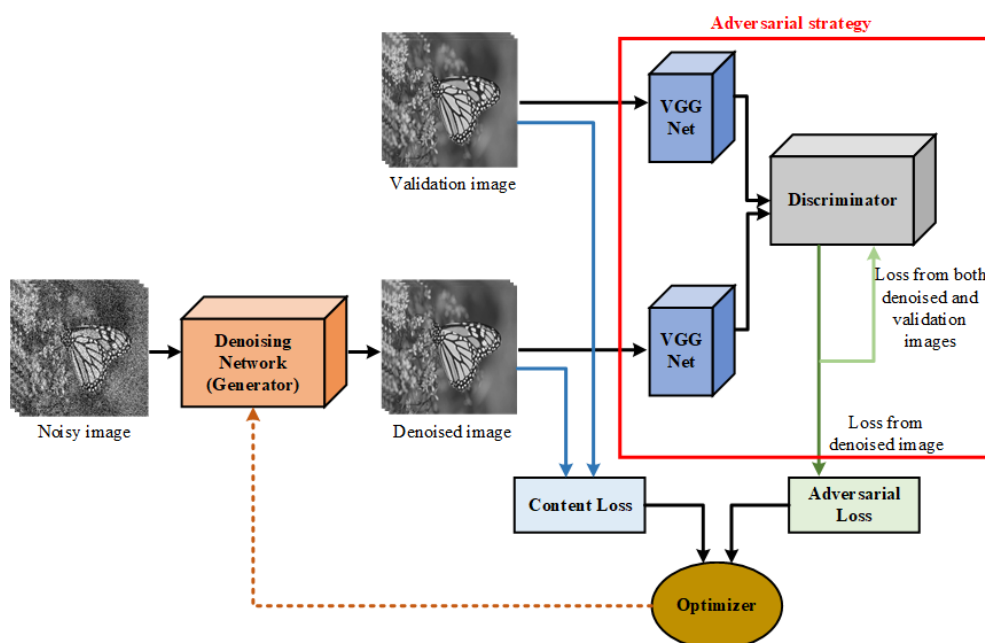
$$l_{total} = \alpha l_{content} + \beta l_{perceptual} \quad (2.6)$$

โดยที่ $l_{content}$	คือค่า loss ของ output เทียบกับ input
$l_{perceptual}$	คือค่า loss ของ output เทียบกับ validation
α และ β	คือค่าน้ำหนักหรือ ratio ของสัดส่วนการใช้ loss ในการเรียนรู้

ในการคำนวณ l_{total} ของการเรียนรู้จะมีการกำหนดสัดส่วน ratio ของการคำนวณ loss ที่ใช้ ซึ่งขึ้นอยู่กับงานที่ต้องการ และผลลัพธ์ที่ได้มักขึ้นอยู่กับข้อกำหนดสัดส่วน α และ β นี้ ทำให้

เป็นเรื่องยากที่จะกำหนด ratio เพื่อให้ได้ลักษณะของผลลัพธ์ตามที่ต้องการ แต่อย่างไรก็ตาม content loss จะมีผลกระทบต่อการเรียนรู้มากกว่า edge loss เนื่องจาก content loss นับเป็นคุณลักษณะ high-level feature อย่างหนึ่งที่สามารถวัดค่าความแม่นยำของค่าสีในภาพได้ แต่ edge loss สำหรับแนวคิดของงานวิจัยนี้เป็นการนำ low-level feature เช่น โครงสร้างมาใช้เสริมกระบวนการเรียนรู้ ทำให้การทดลองนี้ได้กำหนดค่าสัดส่วน ratio ของการใช้งาน content loss ที่ 70% และ edge loss ที่ 30%

ในงาน super-resolution generative adversarial network (SRGANs) [35] ซึ่งเป็นการนำ GANs network มาใช้ในการเพิ่มความละเอียดของภาพ (super-resolution) ได้มีการนำแนวคิดของ perceptual loss มาใช้ในกระบวนการเรียนรู้ของโครงสร้างการเรียนรู้เชิงลึกดังกล่าวประกอบ 2-5 โดยจะให้ generator network สร้าง output ที่เป็นภาพความละเอียดสูง และป้อนให้ discriminator ตรวจสอบ ซึ่งเป็นกระบวนการเรียนรู้แบบแข่งขันเพื่อเพิ่มประสิทธิภาพให้แก่การเพิ่มความละเอียดของภาพที่ได้จาก generator



ภาพประกอบ 2-5 แสดง super-resolution generative adversarial network (SRGANs)

ความแตกต่างแตกต่างของ SRGANs กับงาน image style transfer คือ จะมีการใช้ discriminator network มาเป็นตัวคำนวณ loss ฟังก์ชัน $l_{perceptual}$ ซึ่งเป็นค่า loss จากการแข่งขันของตัว GANs เอง ทำให้ loss ที่เกิดขึ้นนี้เปลี่ยนเป็น $l_{perceptual}^{SR}$ นั่นคือการที่ discriminator เป็น network

ที่สามารถ training ได้ (trainable network) ขณะที่ VGG network ของ style transfer network จะมีหน้าที่ในการสกัดตัวแปลเพียงเท่านั้น ทำให้ไม่สามารถเรียนรู้และปรับพารามิเตอร์ได้ โดย SRGANs ยังมีการใช้สัดส่วนน้ำหนัก α และ β ตามแนวคิดของ perceptual loss ของ style transfer network ดังเดิมอยู่ โดย perceptual loss ของ GANs เป็นการรวมกันของ content loss และ adversarial loss ซึ่งแสดงในสมการที่ 2.7

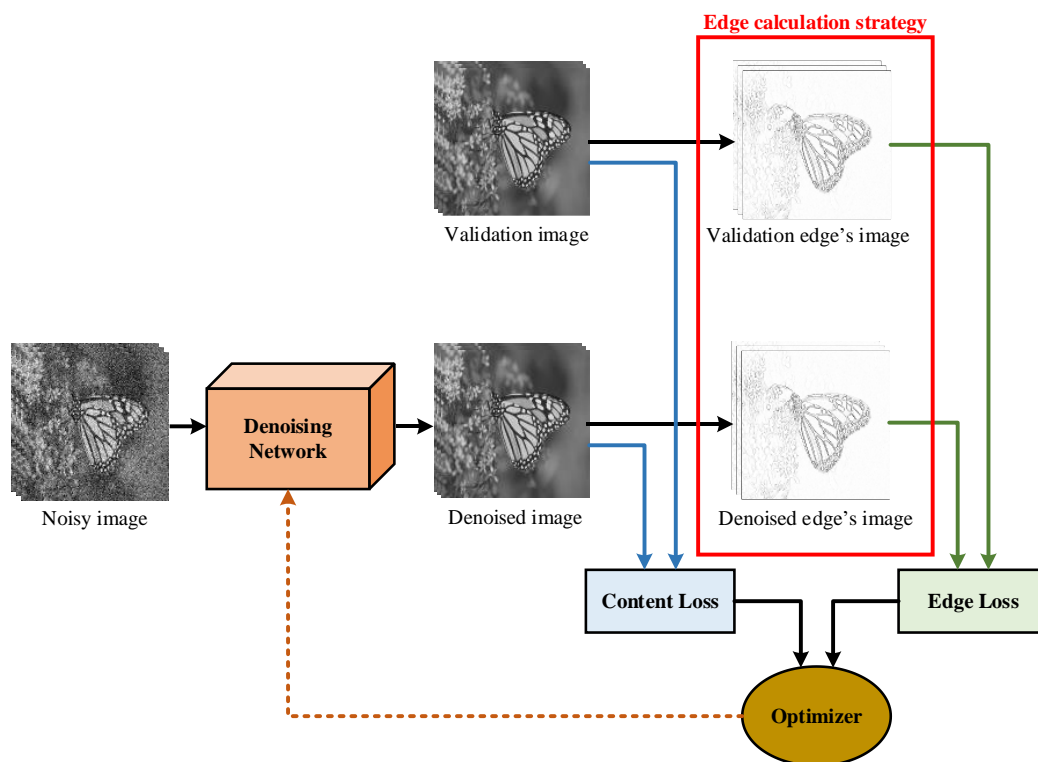
$$l_{total}^{SR} = \alpha l_{content}^{SR} + \beta l_{adversarial}^{SR} \quad (2.7)$$

โดยที่ l_{total}^{SR}	คือ loss รวมของการเรียนรู้เพื่อนำไปปรับ weight ให้กับ generator
$l_{content}^{SR}$	คือ loss ที่เกิดจากการคำนวณ pixel-wise loss
$l_{adversarial}^{SR}$	คือ loss ที่เกิดจากการตรวจจับของ discriminator
α และ β	คือสัดส่วน ratio ของการนำค่า loss มาใช้งานในการเรียนรู้

SRGANs [35] สามารถเพิ่มประสิทธิภาพให้กับการเพิ่มความละเอียดของภาพได้ดี เมื่อเทียบกับงานวิจัยก่อนหน้าที่เป็นการใช้การเรียนรู้ด้วยโครงสร้าง network และ loss function ค่าเดียว ซึ่งแสดงให้เห็นว่าการเรียนรู้แบบแข่งขันสามารถทำให้ SRGANs เพิ่มประสิทธิภาพของการเพิ่มความละเอียดของภาพได้ด้วยการคำนวณ loss function 2 ค่า แต่อย่างไรก็ตาม SRGANs ยังมีปัญหา overfitting ซึ่งเป็นปัญหาที่เกิดขึ้นใน GANs network อยู่แล้ว เป็นผลให้บางครั้ง SRGANs สร้างภาพที่ผิดปกติขึ้นมา และเรียกผลกระทบนี้ว่าการเกิด artifact ขึ้นในภาพที่สร้างด้วยการเรียนรู้แบบ GANs โดยจะอธิบายในผลการทดลองของบทที่ 3 ต่อไป

จากที่ได้กล่าวมาข้างต้นว่า SRGANs นั้นมีปัญหา overfitting ที่มักเกิดได้ง่ายจากการแข่งขันของโครงสร้างการเรียนรู้เชิงลึก 2 ตัว และการเพิ่มคุณลักษณะมาใช้ในการคำนวณค่า loss ของการเรียนรู้สามารถเพิ่มความความสามารถของการเรียนรู้เชิงลึกได้ ทำให้งานวิจัยนี้จึงได้นำเสนอ edge-perceptual loss มีพื้นฐานแนวคิดจากการใช้ multiply loss function ในการเพิ่มประสิทธิภาพให้แก่กระบวนการเรียนรู้ด้วยการใช้แนวคิดของ perceptual loss เพื่อคำนวณหา loss ที่มีค่าน้อยที่สุดสำหรับกระบวนการเรียนรู้การกำจัดสัญญาณรบกวนด้วยโครงสร้างการเรียนรู้เพียงโครงสร้างเดียว เพื่อลดปัญหา overfitting โดย denoising network จะเรียนรู้การกำจัดสัญญาณรบกวนด้วยการนำ

output มาคำนวณ content loss และ edge loss เพื่อนำมาใช้ปรับ weight ของโครงสร้าง network ด้วยแนวคิด perceptual loss ผ่าน optimizer ตามภาพประกอบ 2-6



ภาพประกอบ 2-6 แสดง edge-perceptual loss framework สำหรับ image denoising

การใช้ denoising network เพียงโครงสร้างเดียวมาเรียนรู้การกำจัดสัญญาณรบกวน ทำให้ในการคำนวณ loss จึงมีความซับซ้อนที่ต่ำ เนื่องจากการนำ output จาก denoising network มาคำนวณหา content loss และ edge loss ได้โดยตรง และการใช้คุณลักษณะของขอบของวัตถุ (edge feature) มีลักษณะเป็น low-level feature ในตัวเองอยู่แล้ว จึงไม่มีความจำเป็นต้องใช้การสกัดคุณลักษณะหรือ feature extraction แบบ image-style transfer หรือ SRGANs มาใช้ลดความซับซ้อนของคุณลักษณะภาพ ทำให้สามารถนำ edge feature ที่ได้นี้มาคำนวณหา edge loss ซึ่งเป็น pixel-wise ของภาพขอบวัตถุได้ง่าย โดยการคำนวณ loss จะยังคงใช้ในรูปแบบเดียวกับ image style transfer และ SRGANs ตามสมการที่ 2.8

$$l_{total} = \alpha l_{content} + \beta l_{edge} \quad (2.8)$$

โดยที่ l_{total} คือ loss รวมของการเรียนรู้

$l_{content}$	คือ loss จาก pixel-wise ของ output และ validation
l_{edge}	คือ loss จาก pixel-wise ของขอบวัตถุ output และ validation
α และ β	คือสัดส่วน ratio ที่กำหนดการใช้งานค่า loss ในระบบ

แม้ว่าในงาน [82] ได้มีการใช้ AE network เป็น high-level feature module เพื่อสังเคราะห์ข้อมูลขอบของภาพวัตถุ เพื่อนำมาใช้สำหรับกระบวนการเรียนรู้เพิ่มเติมสำหรับให้โครงสร้างการเรียนรู้เชิงลึกเข้าใจองค์ประกอบของขอบภาพวัตถุได้เพิ่มขึ้น นอกเหนือจากการป้อนภาพ input เข้าไปอย่างเดียวกแล้ว แต่เนื่องจากโครงสร้างของ AE นั้นมีคุณสมบัติของการลดทอนสัญญาณ input ซึ่งสามารถกำจัดสัญญาณรบกวนออกได้บ้าง แต่สามารถสกัดคุณลักษณะของภาพในแต่ละชั้นซ่อนได้ แต่อย่างไรก็ตามการเรียนรู้ด้วย high-level feature ก็ไม่ได้นำ feature ดังกล่าวมาคำนวณค่า loss ซึ่งนับเป็นส่วนสำคัญของการตรวจวัดความถูกต้องการเรียนรู้ของการเรียนรู้เชิงลึก

โดยปกติการหาขอบของวัตถุในภาพถ่ายสามารถหาได้จากการเปลี่ยนแปลงคุณลักษณะของภาพวัตถุ ตัวอย่างเช่น สี ความเข้มแสงหรือความสว่าง ฯลฯ ของภาพซึ่งเกิดระหว่างขอบของวัตถุกับพื้นหลัง โดยจะกำหนดสมการความสัมพันธ์ของการหาขอบของวัตถุได้จากสมการที่ 2.9

$$\nabla I(x, y) = \begin{bmatrix} \frac{\partial I}{\partial x}(x, y) \\ \frac{\partial I}{\partial y}(x, y) \end{bmatrix} \quad (2.9)$$

โดยที่ $\frac{\partial I}{\partial x}(x, y)$	คือความเปลี่ยนแปลงของแสงตามแนวแกน x
$\frac{\partial I}{\partial y}(x, y)$	คือความเปลี่ยนแปลงของแสงขอบของวัตถุตามแนวแกน y

ในการคำนวณหาขอบของวัตถุสามารถใช้ค่า gradient [80] ตามแนวแกน x และ y มาใช้งานได้ตามสมการที่ 2.10 และ 2.11


$$g = \sqrt{g_x^2 + g_y^2} \quad (2.10)$$

$$\theta = \tan^{-1} \left(\frac{g_x}{g_y} \right) \quad (2.11)$$

โดยที่ g_x	คือค่า gradient ตามแนวแกน x
g_y	คือค่า gradient ตามแนวแกน y

θ คือมุมของ gradient ณ ตำแหน่งนั้นๆ

ในงานวิจัยนี้ได้ทำการเปรียบเทียบผลของอัลกอริทึม edge detection เบื้องต้นเพื่อพิจารณาอัลกอริทึมของการตรวจจับขอบของวัตถุที่สามารถนำมาใช้ในงาน edge-perceptual loss ที่นำเสนอนี้ได้ โดยพิจารณาผลการทำ edge detection ด้วย Sobel edge detection และ Laplacian edge detection ดังภาพประกอบ 2-7



ภาพประกอบ 2-7 เปรียบเทียบผลของการตรวจจับขอบวัตถุด้วย Sobel และ Laplacian

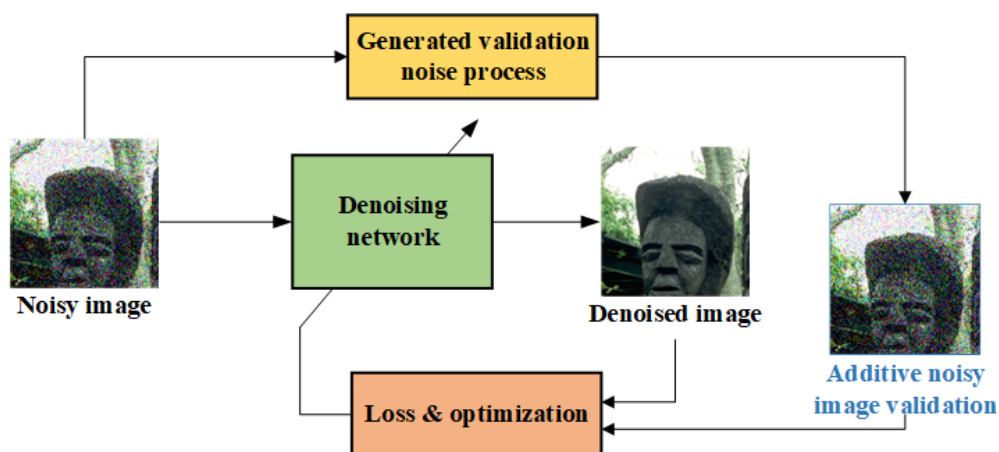
จากผลการเปรียบเทียบในภาพประกอบ 2-7 แสดงให้เห็นว่า Laplacian edge detection ให้ผลแสดงของขอบวัตถุที่มีความชัดเจนกว่าของ Sobel edge detection ซึ่งอาจจะส่งผลของการสกัดคุณลักษณะขอบในการเรียนรู้ของ edge-perceptual loss ได้ ดังนั้นในงานวิจัยนี้จึงได้พิจารณาเลือกใช้ Laplacian edge detection มาเป็นอัลกอริทึมในการสกัดคุณลักษณะของขอบวัตถุเพื่อนำไปคำนวณ edge loss ที่ใช้ในสมการที่ 2.8 โดยการทดลองจะทำการเปรียบเทียบผล PSNR กับอัลกอริทึมประเภท filtering based ได้แก่ BM3D และ NLM และ learning based ได้แก่ ResNet, U-net และ GANs

แต่อย่างไรก็ตามการเรียนรู้ของ edge-perceptual loss ที่นำเสนอนี้มาช่วยเพิ่มประสิทธิภาพในการเรียนรู้ของการเรียนรู้เชิงลึกสำหรับกำจัดสัญญาณรบกวน แต่ยังคงจำเป็นต้องใช้ข้อมูลภาพจำนวนมากเพื่อเรียนรู้การฟื้นฟูภาพเช่นเดียวกัน ทำให้อาจใช้งาน edge-perceptual loss ได้ไม่มี

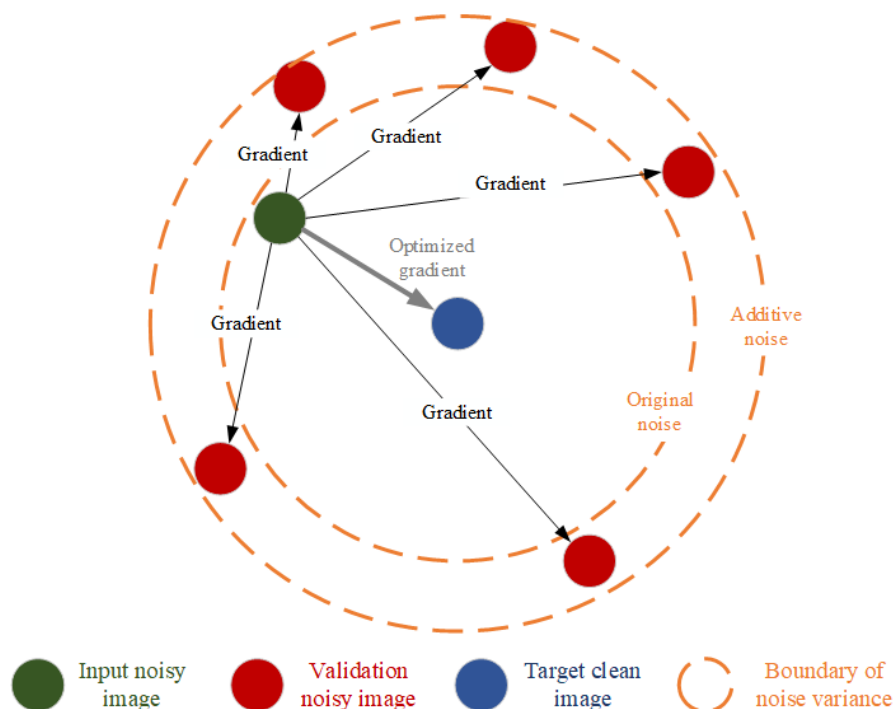
ประสิทธิภาพเมื่อต้องประสบปัญหาในงานประเภท single image และ blind noise ที่เกิดขึ้นในภาพถ่าย ดังนั้นจึงได้นำเสนอกระบวนการของ unsupervised learning เพื่อกำจัด blind noise และแก้ปัญหา single image

2.4 อธิบายทฤษฎีและหลักการของ self-validation Noise2Noise framework

จากบท 1 ได้กล่าวถึงการเรียนรู้ของการเรียนรู้เชิงลึกเพื่อจำกัดสัญญาณรบกวนในภาพถ่าย ซึ่งสามารถทำได้ด้วย 2 framework ได้แก่ N2C framework และ N2N framework โดย N2N framework สามารถทำลายข้อจำกัดของ N2C ที่ต้องใช้คู่ของภาพ input และ validation ที่มีและไม่มีสัญญาณรบกวนมาใช้ในกระบวนการเรียนรู้ โดย N2N framework สามารถเรียนรู้การกำจัดสัญญาณรบกวนด้วยการใช้เพียงคู่ของภาพสัญญาณรบกวนจากจากเดียวกันมาเป็นภาพ input และอีกหนึ่งภาพมาเป็น validation แต่อย่างไรก็ตาม N2N framework ยังมีข้อจำกัดกรณีที่ไม่สามารถหาคู่ของภาพสัญญาณรบกวนอีกชุดได้ เช่นในกรณีของปัญหา single image และ blind noise ซึ่งเป็นเรื่องยากต่อการกำหนด model ของสัญญาณรบกวนสำหรับออกแบบ filter kernel เพื่อกำจัดสัญญาณรบกวน ดังนั้นในงานวิจัยนี้จึงได้นำเสนอ self-validation training Noise2Noise (SV-N2N) framework ในภาพประกอบ 2-8 เป็น unsupervised learning โดยเป็นการสร้างภาพสัญญาณรบกวนใหม่ขึ้นมาใช้สำหรับเป็น validation เพื่อให้การใช้ N2N framework สามารถเรียนรู้การกำจัดสัญญาณรบกวนแม้ไม่มีภาพ validation อื่นๆ และแสดงภาพแนวคิดของ transform domain ขณะเรียนรู้ของการใช้ SV-N2N framework ในการเรียนรู้การกำจัดสัญญาณรบกวนในภาพประกอบ 2-9



ภาพประกอบ 2-8 self-validation training for Noise2Noise (SV-N2N) framework ที่นำเสนอ



ภาพประกอบ 2-9 แนวคิดของการเรียนรู้ของ SV-N2N framework

โดยจากแนวคิดของ SV-N2N framework ในภาพประกอบ 2-9 จะใช้ additive noise เพิ่มสัญญาณรบกวนใหม่เข้าไปในภาพเพื่อสร้าง validation image สำหรับกระบวนการเรียนรู้ จากกระบวนการเรียนรู้ของ N2N framework ที่สามารถเรียนรู้การกำจัดสัญญาณรบกวนได้นั้น โดย additive noise ที่เติมเข้าไปจะสร้างข้อมูล validation มาเรียนรู้ด้วยตัวเองได้ ซึ่งยังคงมีคุณสมบัติของ distribution เดิมของสัญญาณรบกวนเริ่มต้น โดยสามารถพิจารณาได้ตามสมการที่ 2.12 - 2.15 เพื่อพิสูจน์ว่าภาพที่สร้างขึ้นใหม่สามารถใช้ในการเรียนรู้ในการกำจัดสัญญาณรบกวนชนิด Gaussian ได้

$$f_X(x) = \frac{1}{\sqrt{2\pi}\sigma_x} \exp\left\{-\frac{(a-\mu_x)^2}{2\sigma_x^2}\right\} \quad (2.12)$$

$$f_Z(z) = f_A(a) + f_b(b) \quad (2.13)$$

$$f_Z(z) = \int_{-\infty}^{\infty} f_A(a)f_B(z-a)da \quad (2.14)$$

$$f_Z(z) = \frac{1}{\sqrt{2\pi(\sigma_a^2+\sigma_b^2)}} \exp\left\{-\frac{(z-\mu_a\mu_b)^2}{2(\sigma_a^2+\sigma_b^2)}\right\} \quad (2.15)$$

โดยที่ $f_Z(z)$ คือ function ของสัญญาณรบกวนแบบ Gaussian

σ_x คือค่า standard deviation ของสัญญาณรบกวนแบบ Gaussian

เนื่องจากสัญญาณรบกวนแบบ Gaussian จะรบกวนแบบสุ่มในแต่ละ pixel ของภาพถ่าย ทำให้สามารถพิจารณา additive noise เป็นการเพิ่มปริมาณ pixel ที่ถูกรบกวนด้วยค่าเฉลี่ย ซึ่งเป็นการเพิ่มความสูงของกราฟการแจกแจงปกติของ Gaussian noise จากสมการที่ 2.15 แสดงให้เห็นว่าแนวคิดของการป้อน additive noise เข้าไปในภาพเพื่อสร้างภาพสัญญาณรบกวนใหม่สามารถทำได้กับสัญญาณประเภท Gaussian ซึ่งในงานวิจัยนี้จะใช้เทคนิคนี้ได้ทดลองการกำจัดสัญญาณรบกวนประเภท Gaussian และสัญญาณ Impulse ต่อไปในหัวข้อการทดลองในบทต่อไป โดยในงานวิจัยนี้จะตั้งสมมุติฐานของการได้รับข้อมูลภาพถ่ายที่ใช้ในการเรียนรู้ 2 กรณีได้แก่ กรณีสามารถได้รับข้อมูลภาพจำนวนหลายภาพซึ่งรับสัญญาณรบกวนได้หลายค่า (กรณี dynamic noise) เช่นจากภาพถ่าย X-ray หรือภาพถ่ายดาวเทียม ณ ตำแหน่งเดิม และกรณี single image ซึ่งสามารถรับภาพได้เพียงครั้งเดียว (กรณี static noise) เช่น จากการถ่ายภาพจากกล้องถ่ายภาพทั่วไป

อย่างไรก็ตามการเพิ่ม additive noise ที่มากเกินไป ทำให้ช่วงความกว้าง (range) ของสัญญาณรบกวนมีการเปลี่ยนแปลงและจะทำลายคุณสมบัติของ Gaussian noise มากเกินไปด้วย เนื่องจาก range ของสัญญาณภาพดิจิทัลนั้นมีขอบเขตจำกัด เป็นเหตุให้การเรียนรู้การกำจัดสัญญาณรบกวนของโครงสร้างการเรียนรู้ SV-N2N framework ได้ ดังนั้นงานวิจัยนี้จึงได้ตั้งค่าการทดลองเพื่อทดสอบความสามารถของแนวคิดของ SV-N2N framework ในสถานการณ์ที่เป็นไปได้ ซึ่งการเติมสัญญาณรบกวน additive noise เข้าไปนั้นจะมีด้วยกัน 2 ลักษณะ ได้แก่ การเติมสัญญาณรบกวนแบบค่าคงที่ (static) และการเติมสัญญาณรบกวนแบบสุ่มหลายค่า (dynamic) โดยที่ภาพที่มีสัญญาณรบกวนทางฝั่ง input ขณะเรียนรู้ก็สามารถเป็นภาพข้อมูลที่มีสัญญาณแบบสุ่มหลายค่าหรือเป็นค่าคงที่ได้เช่นเดียวกัน ทำให้การทดลองนี้แบ่งลักษณะการเรียนรู้ของ SV-N2N โดย dynamic input noise คือกรณีที่สามารถหาภาพหลายชุดมา training ได้ และ static input noise สามารถนับเป็นปัญหา single image ที่มีเพียงภาพเดียว ซึ่งสามารถจำลองที่เป็นไปได้ 4 สถานการณ์ดังนี้

- dynamic input noise input and static additive validation noise (DNSV)

ในสถานการณ์นี้จะเกิดขึ้นเมื่อให้ network เรียนรู้ภาพถ่ายสัญญาณรบกวนหลายๆ ภาพซึ่งแต่ละภาพจะมีสัญญาณรบกวนที่ต่างกัน (dynamic noise) มาใช้เป็น input โดยที่ใช้ SV-N2N จะ

ทำการเพิ่มสัญญาณรบกวนที่มีการกระจายตัวเหมือนกันเพื่อสร้าง validation สำหรับการ training โดยการทดลองนี้จะใช้ dynamic noise ที่ $\sigma = 10-50$ และ static noise ที่ $\sigma = 10$

- dynamic input noise input and dynamic additive validation noise (DNDV)

ในสถานการณ์นี้จะใช้ในสถานการณ์ที่มีภาพภาพถ่ายสัญญาณรบกวนหลายๆ หลายค่าระหว่าง $\sigma = 10-50$ มาเป็น input เช่นเดียวกับ DNSV แต่จะต่างกันที่การสร้าง validation จะใช้การสุ่มสัญญาณรบกวนที่มีการกระจายตัวระหว่าง $\sigma = 10-50$ มาเพิ่มเข้าไปในภาพ input

- static input noise and static additive validation noise (SNSV)

ในสถานการณ์นี้จะจำลองว่าภาพ input ถูกรบกวนด้วยสัญญาณที่มีการกระจายตัวแบบเดียวกันทุกภาพ ซึ่งการทดลองนี้จะใช้ $\sigma = 50$ เป็น input สำหรับการ training โดยสร้าง validation ด้วยการเติม สัญญาณรบกวน $\sigma = 10$ สำหรับทุกภาพ input

- static input noise and dynamic additive validation noise (SNDV)

สถานการณ์นี้จะจำลอง input แบบเดียวกับ SNSV ด้วยสัญญาณรบกวน $\sigma = 50$ แต่จะสร้างข้อมูลสำหรับ validation ด้วย dynamic noise ที่ $\sigma = 10-50$ เข้าไปใน input

ตาราง 2-1 สัญญาณรบกวนที่ใช้ในการทดลองสำหรับ 4 สถานการณ์

สถานการณ์	สัญญาณรบกวน input	สัญญาณรบกวน validation
1. DNSV	Dynamic noise $\sigma = 10-50$	Static noise $\sigma = 10$
2. DNDV	Dynamic noise $\sigma = 10-50$	Dynamic noise $\sigma = 10-50$
3. SNSV	Static noise $\sigma = 50$	Static noise $\sigma = 10$
4. SNDV	Static noise $\sigma = 50$	Dynamic noise $\sigma = 10-50$

ในการทดลองที่ 2 จะเป็นการทดลองเปรียบเทียบผล PSNR ของ SV-N2N framework กับ framework อื่นๆ ได้แก่ BM3D ซึ่งเป็นวิธีแบบ filtering-based การเรียนรู้ของการเรียนรู้เชิงลึกด้วย Noise2Clean (N2C) framework และการเรียนรู้แบบ Noise2Noise (N2N) framework ซึ่งได้อธิบายการทำงานของอัลกอริทึม N2C, N2N และ SV-N2N ที่ใช้ในการทดลองใน Pseudo code ตามภาพประกอบ 2-10 ถึงภาพประกอบ 2-12 ตามลำดับ

Input: noisy image (\mathbf{N}) and validation image (\mathbf{V})

Output: denoised image (\mathbf{D})

Define the network f , learning rate (η), batch size (\mathbf{B}) and stopping criteria (\mathbf{S})

While error (e) > criteria (\mathbf{S})

For $\mathbf{N} \rightarrow$ in \mathbf{B}

$\mathbf{D} = f(\mathbf{N})$

Compute loss: $e = L(\mathbf{D}, \mathbf{V})$

Update the weight (W) of the network: $W_{\text{new}} = W_{\text{old}} + \eta \frac{de}{dW}$

End

End

ภาพประกอบ 2-10 Pseudo code สำหรับการทดลอง Noise2Clean framework

Input: noisy image (\mathbf{N}_I) and another noisy domain image (\mathbf{N}_V)

Output: denoised image (\mathbf{D})

Define the network f , learning rate (η), batch size (\mathbf{B}) and stopping criteria (\mathbf{S})

While error (e) > criteria (\mathbf{S})

For $\mathbf{N} \rightarrow$ in \mathbf{B}

$\mathbf{D} = f(\mathbf{N})$

Compute loss: $e = L(\mathbf{D}, \mathbf{N}_V)$

Update the weight (W) of the network: $W_{\text{new}} = W_{\text{old}} + \eta \frac{de}{dW}$

End

End

ภาพประกอบ 2-11 Pseudo code สำหรับการทดลอง Noise2Noise framework

Input: noisy image (N_I) and generate another noisy validation image by adding a small noise to noisy image (N_I) as N_G

Output: denoised image (D)

Define the network f , learning rate (η), batch size (B) and stopping criteria (S)

While error (e) > criteria (S)

For $N \rightarrow$ in B

 Get the denoised image by network's output: $D = f(N)$

 Compute loss: $e = L(D, N_G)$

 Update the weight (W) of the network: $W_{\text{new}} = W_{\text{old}} + \eta \frac{de}{dW}$

End

End

ภาพประกอบ 2-12 Pseudo code สำหรับการทดลอง Self-validation Noise2Noise framework

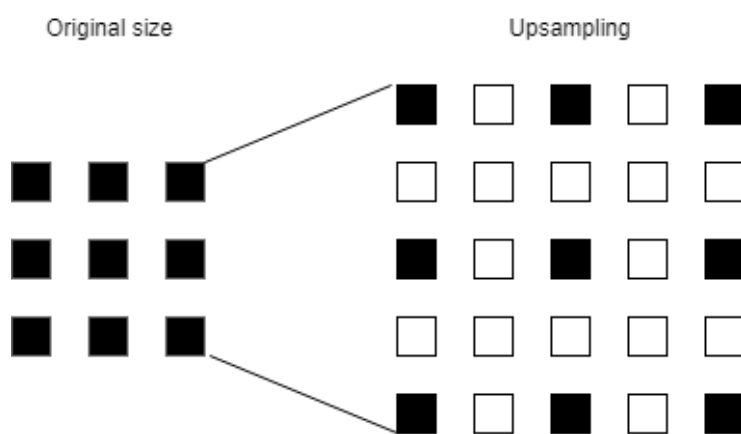
2.5 ทฤษฎีและหลักการทดลองวิเคราะห์การฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและลดทอนความละเอียดของภาพ

ในงานด้านการฟื้นฟูภาพถ่ายความละเอียดต่ำ (super-resolution) [61] เป็นงานอีกประเภทที่มีความสำคัญในปัจจุบัน เนื่องจากความต้องการเพิ่มความละเอียดของภาพถ่ายรวมไปถึงวิดีโอสำหรับอุปกรณ์ต่างๆ ในปัจจุบันนั้นเพิ่มสูงขึ้น แต่เนื่องจากการถ่ายภาพด้วยเทคโนโลยีเก่าที่ให้ความละเอียดที่ต่ำกว่าในปัจจุบัน จึงเป็นเหตุผลให้งานประเภท super-resolution เข้ามามีบทบาทมากขึ้นในปัจจุบัน โดยงานประเภท super-resolution (SR) ถูกพิจารณาเป็นปัญหาหนึ่งของการฟื้นฟูภาพถ่ายนอกเหนือจากสัญญาณรบกวนที่เกิดขึ้นในภาพถ่าย เมื่อพิจารณาจาก block diagram ในภาพประกอบ 1-2 และสมการที่ 1.1 ในบทที่ 1 เราสามารถพิจารณาพฤติกรรมของการลดทอนความละเอียดของภาพได้ดังสมการที่ 2.16

$$x_i = (h_i * s_i)_\downarrow + n_i \quad (2.16)$$

โดยที่ x_i	คือสัญญาณภาพที่ปรากฏ
$(h_i * s_i)_\downarrow$	คือรูปแบบความสัมพันธ์ของการลดทอนความละเอียดของภาพ
n_i	คือสัญญาณรบกวน

สมการที่ 2.16 แสดงถึงกระบวนการในการสูญเสียความละเอียดของภาพในเชิงคณิตศาสตร์ ซึ่งจากสมการสูญเสียความละเอียดจะมีความสอดคล้องกันกับการลดทอนคุณภาพของภาพด้วยการเบลอภาพด้วย filter (h_i) โดยเป็นการทำให้ภาพเกิดการสูญเสียรายละเอียดของขอบวัตถุในภาพ และสามารถเกิดขึ้นได้จากกระบวนการกำจัดสัญญาณรบกวน n_i ด้วย filter แต่งานทางด้าน super-resolution จะมีความแตกต่างจากการสูญเสียคุณลักษณะของขอบวัตถุด้วย filter ด้วยวัตถุประสงค์ของความต้องการเพิ่มขนาดของภาพทำให้ต้องเพิ่มค่า pixel ใหม่เข้าไปในภาพถ่าย ซึ่ง pixel ที่เพิ่มมาใหม่นี้อาจไม่สามารถรักษาคุณลักษณะของขอบวัตถุในภาพได้ดั้งเดิม ทำให้การแสดงผลของภาพจึงเกิดการเบลอออกมาได้

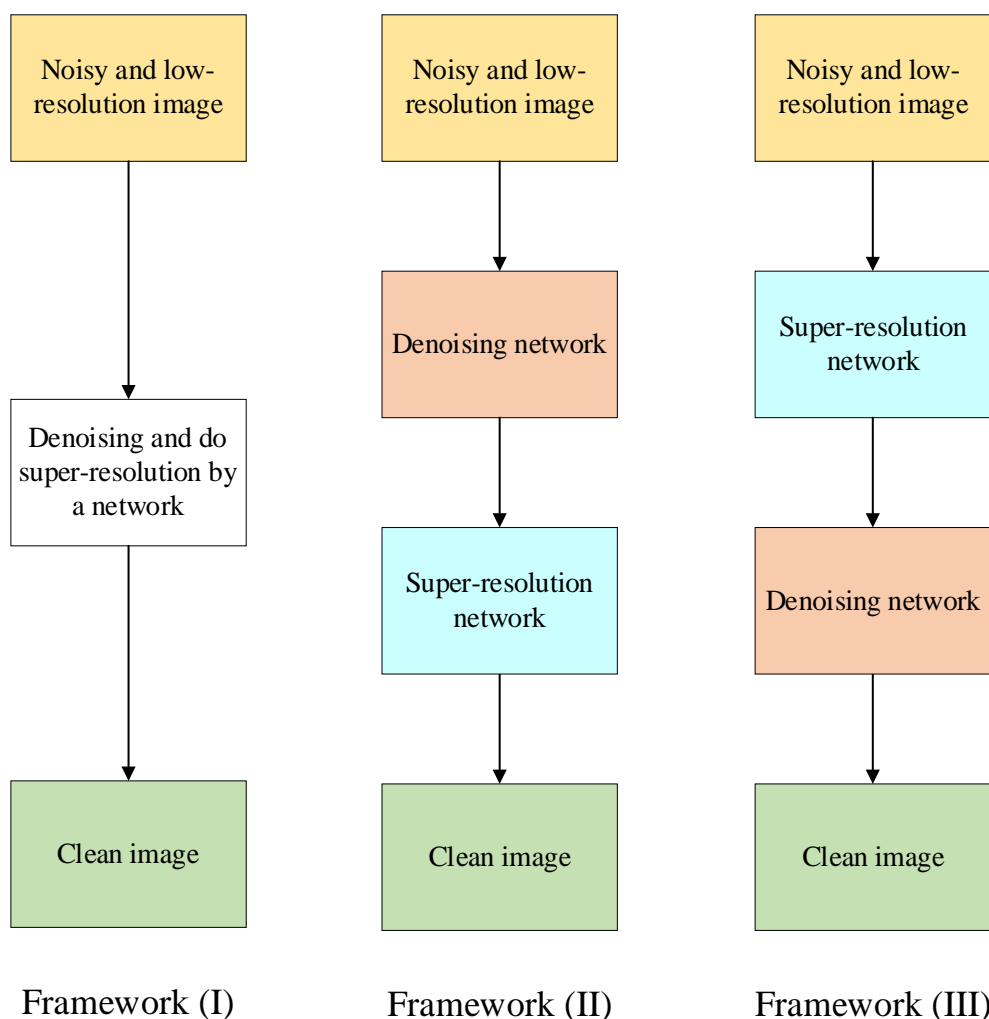


ภาพประกอบ 2-13 การเพิ่ม pixel ของภาพซึ่งเป็นพื้นฐานของ image super-resolution

โดยปกติแล้วการเพิ่มความละเอียดของภาพในงาน super-resolution สามารถทำได้ด้วยการเติมค่า pixel ใหม่เข้าไปในภาพถ่ายตามภาพดังภาพประกอบ 2-13 เพื่อให้ภาพมีขนาดที่เพิ่มขึ้น และใช้เทคนิคการประมาณค่าสีที่ควรจะเป็นสำหรับ pixel ที่เพิ่มลงไป โดยเทคนิคพื้นฐานของการประมาณค่าสีสำหรับ pixel ที่เพิ่มลงไปในภาพถ่ายในงาน super-resolution สามารถใช้เทคนิคการประมาณค่า (interpolation) ด้วยการหาค่าเฉลี่ยของค่า pixel ที่อยู่โดยรอบของ pixel ใหม่ที่เพิ่มเข้าไป แต่อย่างไรก็ตามเทคนิค interpolation แบบดั้งเดิมนี้มักจะทำให้ภาพที่ผ่านการขยายขนาดด้วยวิธีนี้จะสูญเสียรายละเอียดของขอบวัตถุไปด้วย เนื่องจากไม่สามารถรักษาคุณลักษณะของขอบวัตถุในภาพได้ ทำให้ในปัจจุบันเทคนิคการเรียนรู้ด้วยการเรียนรู้เชิงลึกจึงได้รับความนิยมมากกว่า เนื่องจากสามารถเพิ่มประสิทธิภาพและสามารถเก็บรักษาคุณลักษณะของขอบวัตถุได้ดีกว่าจากการเรียนรู้จากชุดข้อมูลที่ใช้ในการเรียนรู้ได้

ปัญหาของการลดทอนคุณภาพของภาพถ่ายนั้นอาจสามารถเกิดขึ้นได้พร้อมกันจากโมเดลทางคณิตศาสตร์ของการลดทอนคุณภาพของภาพถ่ายดิจิทัลในสมการที่ 2.16 ตามที่ได้นำเสนอไปแล้วนั้น กล่าวคือปัญหาของการลดทอนคุณภาพของภาพถ่ายดิจิทัลสามารถเกิดสัญญาณรบกวนและการถูกลดขนาดของสัญญาณภาพ ซึ่งการลดทอนทั้งหมดสามารถเกิดได้จากสภาพแวดล้อมคุณภาพของอุปกรณ์ รวมไปถึงกระบวนการต่างของการบันทึกภาพและการรับส่งข้อมูล แต่การใช้งานอัลกอริทึมการเรียนรู้เชิงลึกรวมไปถึงการเรียนรู้ของเครื่องจักรนั้นมักจะพิจารณาให้หนึ่งอัลกอริทึมแก้ปัญหาสำหรับหนึ่งปัญหาเพียงเท่านั้น

จากที่ได้กล่าวถึงงานทางด้านกราฟฟิเคิลและปัญหาที่สามารถเกิดขึ้นจริงของการเกิดสัญญาณรบกวนและการถูกลดทอนคุณภาพของภาพถ่ายในเวลาเดียวกัน การทดลองในส่วนนี้จึงมีความต้องการศึกษาผลกระทบของการฟื้นฟูภาพถ่ายในการเพิ่มความละเอียดของภาพและกำจัดสัญญาณรบกวนไปพร้อมกันด้วยเทคนิคการเรียนรู้เชิงลึก นอกจากนี้งานวิจัยนี้ต้องการลำดับของการฟื้นฟูภาพถ่ายของการกำจัดสัญญาณรบกวนและการเพิ่มความละเอียดของภาพซึ่งส่งผลต่อคุณภาพของภาพที่ได้ทำการฟื้นฟู โดยงานวิจัยนี้จะแบ่งการทดลองใน 3 กรณีได้แก่ กรณีที่ 1 คือการกำจัดสัญญาณรบกวนพร้อมกับการเพิ่มความละเอียดของภาพด้วยโครงสร้างการเรียนรู้เชิงลึกเดียว กรณีที่ 2 คือการกำจัดสัญญาณรบกวนก่อนการเพิ่มความละเอียดภาพ และกรณีที่ 3 คือการเพิ่มความละเอียดภาพก่อนกำจัดสัญญาณรบกวน โดยได้อธิบายการทดลองทั้ง 3 กรณีในภาพประกอบ 2-14




ภาพประกอบ 2-14 เปรียบเทียบ 3 ขั้นตอนในการฟื้นฟูภาพถ่ายในงานวิจัยนี้

ภาพประกอบ 2-14 เปรียบเทียบโครงสร้างทั้ง 3 ที่ใช้ในการทดลอง โดยโครงสร้าง framework (I) เป็นลักษณะของการพยายามให้หนึ่งโครงสร้างการเรียนรู้เชิงลึกเรียนรู้ทั้งการกำจัดสัญญาณรบกวนและการเพิ่มขนาดภาพถ่ายดิจิทัลในตัวเอง สำหรับโครงสร้างการเรียนรู้ framework (II) เป็นการใช้งานสองโครงสร้างการเรียนรู้เชิงลึกในการกำจัดสัญญาณรบกวนและเพิ่มขนาดภาพถ่ายแบบแยกหน้าที่กัน โดยให้กำจัดสัญญาณรบกวนก่อนการเพิ่มขนาดภาพ สำหรับ framework (III) จะเป็นการใช้งานสองโครงสร้างการเรียนรู้เชิงลึกเช่นเดียวกับ framework (II) แต่จะให้ทำการเพิ่มความละเอียดของภาพถ่ายก่อนการกำจัดสัญญาณรบกวน

สำหรับการทดลองต่อมาของหัวข้อการทดลองนี้เป็นการทดลองการลดขนาด (Downsampling) และ (Upsampling) ภาพถ่ายมาใช้ในการเรียนรู้การกำจัดสัญญาณรบกวน

เนื่องจากการเพิ่มขนาดของภาพนั้นสามารถส่งผลกระทบต่อสัญญาณหรือคุณลักษณะของภาพถ่ายได้ตามตัวอย่างในภาพประกอบ 2-15



ภาพประกอบ 2-15 แสดงผลกระทบของสัญญาณรบกวนที่ลดลงเมื่อทำการลดและเพิ่มขนาดของภาพถ่าย

จากภาพประกอบ 2-15 แสดงผลการทบทวนของสัญญาณรบกวนที่ลดลงเมื่อทำการลดและขนาดของภาพ 2 และ 4 เท่า เมื่อทำการลดและเพิ่มขนาดกลับมาจะทำให้ห้อยค์ประกอบของสัญญาณรบกวนที่มีในภาพถ่ายลดลงไปด้วย ดังนั้นการเพิ่มขนาดของภาพถ่ายจึงมีผลกระทบต่อ kernel การลดทอนของภาพถ่ายตามสมการที่ 2.17

$$X_i = K_i S_i + N_i \quad (2.17)$$

โดยที่ X_i คือสัญญาณภาพที่ปรากฏ
 S_i คือสัญญาณภาพที่ไม่มีการรบกวน
 N_i คือสัญญาณรบกวน
 K_i คือฟังก์ชันการลดทอนคุณลักษณะของภาพถ่าย

เมื่อพิจารณา K_i นั้นสามารถแยกประเภทของการลดทอนในภาพถ่ายได้ 2 แบบ ได้แก่ ฟังก์ชันการลดเพิ่มขนาดภาพและการเบลอภาพ ตามสมการที่ 2.18

$$K_i = D_i B_i \quad (2.18)$$

โดยที่ D_i คือฟังก์ชันการลดขนาดภาพถ่าย
 B_i คือฟังก์ชันการเบลอภาพถ่าย

เนื่องจากแนวคิดของการเรียนรู้เชิงลึกเป็นการแปลง domain หนึ่งไปอีก domain หนึ่ง เมื่อพิจารณาหลักการของการลดและเพิ่มขนาด (Down sampling และ Up sampling) ของการทำ super-resolution พบว่า kernel K_i ควรมีค่าเท่ากันตามสมการที่ 2.19 จากการเรียนรู้ของการเรียนรู้เชิงลึกที่ต้องการผลลัพธ์ที่เหมือนกันในสถานะการที่มีสัญญาณรบกวน N_i เหมือนกัน

$$\{D_S B_f\}_i = \{D_S B_f\}_j \quad (2.19)$$

โดยที่ $\{D_S B_f\}_i$ คือ kernel ของการลดขนาดของภาพจากขนาดภาพดั้งเดิม
 $\{D_S B_f\}_j$ คือ kernel ของการเพิ่มขนาดกลับมาจากภาพที่ผ่านการลดขนาด

จากความสัมพันธ์นี้สามารถนำมากำหนดรูปแบบการเรียนรู้ของเครื่องจักรสำหรับแนวคิดของ self-validation ได้ตามการทดลองที่ 2 ด้วยหลักการเพิ่มลดขนาดของภาพถ่าย เนื่องด้วยการเรียนรู้เชิงลึกจะเรียนรู้ด้วยการ minimize ค่า loss ตามสมการที่ 2.20

$$\min_{\theta} L(X, R_S(Y)) \quad (2.20)$$

โดยที่ L คือ loss ของการเรียนรู้
 X คือภาพ validation
 $R_S(Y)$ คือภาพผลลัพธ์ของการเรียนรู้

ในงานวิจัยประเภท super resolution [83] มักประกอบไปด้วยการวิเคราะห์ปัญหา deblurring และ super-resolution ด้วยเทคนิค deep learning โดยที่การ deblurring และ super-resolution สามารถอธิบายได้ในเชิงความสัมพันธ์ Fourier transform จากการทำ convolution ภายในของการเรียนรู้เชิงลึกเองตามสมการที่ 2.21

$$Y(i, j) = H(i, j)X(i, j) \quad (2.21)$$

โดยที่ $Y(i, j)$ คือ Fourier transform ของภาพผลลัพธ์

$X(i, j)$ คือ Fourier transform ของภาพ input

$H(i, j)$ คือ Fourier transform ของ kernel การลดทอน

ดังนั้นสำหรับพหุคูณของการเรียนรู้เชิงลึกสามารถกำจัด term ของ $H(i, j)$ ออกไปได้
ดังนี้

$$X'(i, j) \approx \frac{H(i, j)X(i, j)}{H'(i, j)} \approx X(i, j) \quad (2.22)$$

โดยที่ $X'(i, j)$ คือผลลัพธ์ของการฟื้นฟูภาพถ่าย

$X(i, j)$ คือภาพที่ไม่มีการรบกวน

$H'(i, j)$ คือ invert kernel สำหรับลบ $H(i, j)$

อย่างไรก็ตามในระบบถ่ายภาพที่ได้รับผลกระทบการรบกวนของสัญญาณที่ไม่รู้จักหรือปัญหา single image และ blind noise จะทำให้การเรียนรู้ของการเรียนรู้เชิงลึกเพื่อหา $H'(i, j)$ เกิดการคลาดเคลื่อนได้ เนื่องจากสัญญาณรบกวนนับว่าเป็น high-frequency ของระบบภาพเช่นเดียวกัน ซึ่งการ deconvolution ซึ่งนับเป็นการทำ high-pass filter จะทำให้สัญญาณรบกวนถูกขยายและมีการเปลี่ยนแปลงคุณลักษณะไปด้วย จากผลกระทบของสัญญาณรบกวนที่กล่าวมานี้ ทำให้การทำ super-resolution ไม่สามารถละเลยองค์ประกอบของสัญญาณรบกวนออกไปได้ เนื่องจากคุณสมบัติของ high-frequency มีค่ามากกว่า $H'(i, j)$ จะทำให้ไม่สามารถกำจัดสัญญาณรบกวนออกได้ อีกทั้งการเปลี่ยนแปลงคุณสมบัติของข้อมูลจากการทำ convolution จะยิ่งทำให้สัญญาณรบกวนถูกขยายสัญญาณเพิ่มขึ้นด้วย แม้ว่าการเรียนรู้เชิงลึกด้วยชุดข้อมูลจำนวนมากจะสามารถช่วยในการเรียนรู้เพื่อสร้าง $H'(i, j)$ มากำจัดสัญญาณรบกวนได้ดี แต่ก็สามารถเป็นเหตุให้การเรียนรู้เชิงลึกมักเกิด overfitting ที่สามารถกำจัดสัญญาณได้ดีเฉพาะสัญญาณรบกวนที่ได้เรียนรู้เท่านั้น แต่ปัญหา single image และ blind noise ไม่อาจสามารถเรียนรู้เพื่อกำจัดสัญญาณรบกวนได้ง่าย เมื่อพิจารณาทฤษฎี Wiener deconvolution [84] สามารถพิจารณาการทำ convolution ตามสมการที่ 2.23 - 2.24

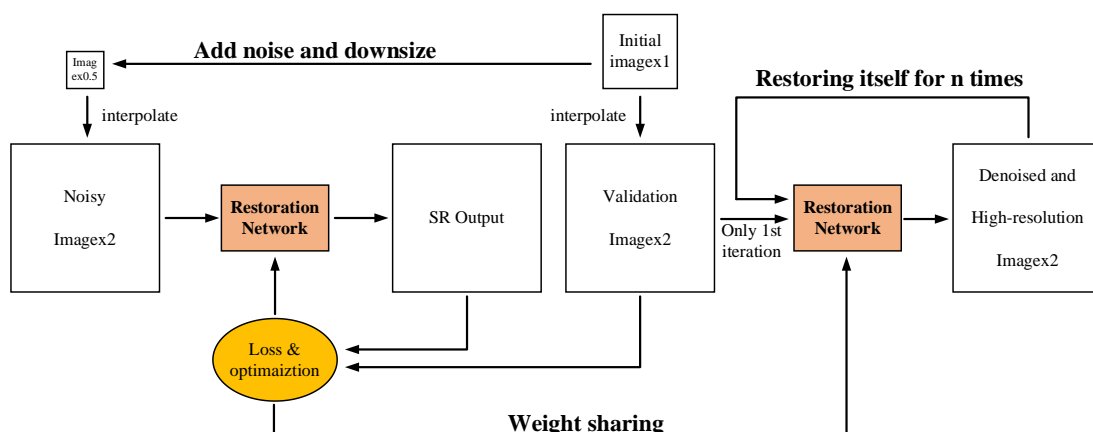
$$X'(u, v) = \frac{Y(u, v)}{H(u, v)} \left[\frac{1}{1 + \frac{NSR(u, v)}{|H(u, v)|^2}} \right] \quad (2.23)$$

$$NSR(u, v) = \frac{|N(u, v)|^2}{|X(u, v)|^2} \quad (2.24)$$

โดยที่	$X'(u, v)$	คือภาพผลลัพธ์ของการ convolution
	$Y(u, v)$	คือภาพที่มีสัญญาณรบกวนที่ต้องการกำจัด
	$X(u, v)$	คือภาพที่ไม่มีสัญญาณรบกวน
	$N(u, v)$	คือสัญญาณรบกวนที่สามารถวัดค่าได้

จากทฤษฎี Wiener deconvolution จำเป็นต้องทราบค่าของสัญญาณรบกวนและภาพที่ไม่มีสัญญาณรบกวนซึ่งสามารถเรียนรู้ด้วยวิธี supervise-learning ได้ แต่อาจไม่สามารถแก้ปัญห single image และ blind noise ได้ เนื่องจาก single image และ blind noise ไม่ทราบค่าที่แท้จริงของสัญญาณภาพ รวมไปถึงชนิดและระดับของสัญญาณรบกวนที่เกิดขึ้น ดังนั้นสัญญาณรบกวนที่เกิดขึ้นในภาพถ่ายส่งผลกระทบต่ออย่างยิ่งต่อการทำ super-resolution ของการเรียนรู้เชิงลึก และเป็นปัญหาอย่างยิ่งต่อการกำจัดสัญญาณรบกวนในปัญหา single image และ blind noise

โดยงานวิจัยนี้ต้องการนำเสนอ NLR2NSR framework สำหรับการเรียนรู้ด้วยตัวเองแบบ self-validation สำหรับฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและการลดทอนความละเอียดของภาพตามภาพประกอบ 2-16



ภาพประกอบ 2-16 โครงสร้าง NLR2NSR framework สำหรับฟื้นฟูภาพถ่าย

framework ในภาพประกอบ 2-16 ได้ใช้ประโยชน์จากการลดทอนสัญญาณรบกวนด้วยการย่อขยายภาพมาใช้ร่วมกับ self-validation ของภาพตัวเอง ด้วยการป้อนสัญญาณรบกวน additive noise เพื่อให้การเรียนรู้เชิงลึกสามารถเรียนรู้ด้วยตัวเอง ซึ่งเรียนรู้การแปลงภาพ noisy low-

resolution ไปเป็น noisy high-resolution (NLR2NSR framework) โดยตัวโครงสร้างการเรียนรู้เชิงลึกนี้มีลักษณะคล้ายกับโครงสร้างการเรียนรู้ zero-shot learning [85] แต่จะมีกระบวนการป้อน output กลับเข้าไปเป็น input ใหม่เพื่อปรับความคมชัดและกำจัดสัญญาณรบกวนเพิ่มเติม อย่างไรก็ตามการเรียนรู้ลักษณะนี้เป็นการพยายามให้การเรียนรู้เชิงลึกเรียนรู้การกำจัดสัญญาณรบกวนไปพร้อมกับการเพิ่มความละเอียดของภาพถ่ายไปพร้อมกัน ซึ่งกระบวนการเรียนรู้แบบนี้อาจทำให้เกิด overfitting ได้ง่าย

ในการทดลองจะทำการตั้งค่าด้วยการใช้ real-world dataset จาก NIND, SIDD และ FMD โดยใช้ภาพที่ถ่ายด้วยค่า ISO 100 เป็นภาพ ground truth สำหรับการ testing และใช้ภาพที่ถ่ายด้วยค่า ISO 25600 เป็นภาพที่มีสัญญาณรบกวนและต้องการกำจัดสัญญาณรบกวนพร้อมกับเพิ่มความละเอียดเป็น input ของการทดลองนี้ ในกระบวนการเรียนรู้ภาพ input จะถูกลดขนาดเพื่อใช้เป็นภาพเริ่มต้น (initial image) และนำมาใช้เป็นข้อมูล validation ขณะเรียนรู้ โดยที่ input จะเป็นภาพ initial image ที่ลดขนาดลงมาอีกครั้งพร้อมกับเพิ่มสัญญาณรบกวน additive noise เพื่อให้เรียนรู้ด้วยตัวเองตามแนวคิดของ self-validation ได้ ในขณะที่ training อยู่ นั้น restoration network จะเรียนรู้จนกว่ากระบวนการ training สิ้นสุด และจะนำภาพเริ่มต้น เข้ามาเป็น input เพื่อทำการฟื้นฟูต่อเนื่องตามจำนวนรอบที่ได้ตั้งค่าไว้

บทที่ 3

ผลการทดลองและอธิปรายผล


ในบทนี้จะแสดงผลการทดลองและอธิปรายผลของการทดลองที่ได้อธิบายวิธีการทดลองไว้แล้วในบทที่ 2 ซึ่งประกอบด้วย 3 การทดลองย่อยได้แก่ การทดลองที่ 1 การทดลอง edge-perceptual loss สำหรับการกำจัดสัญญาณรบกวนในภาพถ่าย การทดลองที่ 2 การทดลอง self-validation Noise2Noise (SV-N2N) framework สำหรับการกำจัดสัญญาณรบกวน และการทดลองที่ 3 การทดลองวิเคราะห์ framework การฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและการลดทอนความละเอียดของภาพ

3.1 การทดลองที่ 1 การใช้ edge-perceptual loss สำหรับการกำจัดสัญญาณรบกวนในภาพถ่าย

การทดลองนี้ได้เปรียบเทียบผลการกำจัดสัญญาณรบกวน 2 ชนิดได้แก่ Gaussian noise และ Impulse noise ซึ่งกำหนดการใช้ content loss/edge loss ไว้ที่ 70%/30% โดยตารางที่ 3.1 แสดงผลการเปรียบเทียบ PSNR ของแต่ละอัลกอริทึมซึ่งเป็นการเปรียบเทียบระหว่างอัลกอริทึม filtering-based ได้แก่ BM3D และ NLM และอัลกอริทึมการเรียนรู้เชิงลึกซึ่งใช้โครงสร้าง ResNet และ U-net แบบโครงสร้างดั้งเดิม นอกจากนี้ยังมี ResNet-G และ U-net-G ซึ่งเป็นการนำ ResNet และ U-net มาใช้ในโครงสร้างการเรียนรู้แบบแข่งขันของ GANs โดยการเปรียบเทียบกับ GANs เพื่อวัดประสิทธิภาพของอัลกอริทึมที่มีการใช้งาน multiple loss function เช่นเดียวกับ edge-perceptual loss ที่นำเสนอ สำหรับอัลกอริทึม edge-perceptual loss ในการทดลองนี้ได้ใช้ ResNet-P และ U-net-P ซึ่งเป็น ResNet และ U-net ที่ใช้การคำนวณ edge loss ตามที่ได้นำเสนอไปแล้ว โดยได้แสดงกราฟการเปรียบเทียบผลการทดลองการกำจัด Gaussian noise และ impulse noise ในตาราง 3-1 และนำมาแสดงผลเป็นกราฟเปรียบเทียบในภาพประกอบ 3-1 และภาพประกอบ 3-2


ตาราง 3-1 ผลการเปรียบเทียบ PSNR ของแต่ละอัลกอริทึมในการกำจัด Gaussian noise และ Impulse

Algorithm		Gaussian ($\sigma=50$)	Impulse (50%)
Traditional	BM3D	22.85 (2.29)	16.58 (2.00)
	NLM	22.49 (2.12)	16.37 (1.85)
Deep learning	ResNet	27.04 (2.19)	30.86 (4.17)
	ResNet-G	24.31 (0.99)	25.49 (0.73)
	ResNet-P	27.75 (2.13)	31.12 (3.76)
	U-net	26.88 (2.30)	27.66 (3.40)
	U-net-G	25.49 (3.38)	32.46 (4.61)
	U-net-P	26.54 (2.15)	28.47 (3.52)



ภาพประกอบ 3-1 แสดงกราฟเปรียบเทียบ PSNR ของแต่ละอัลกอริทึมในการกำจัด Gaussian noise

ภาพประกอบ 3-1 แสดงผลการทดลองการกำจัดสัญญาณรบกวนประเภท Gaussian noise โดยผลการทดลองใช้วิธี filter-based ของ BM3D และ NLM ได้ผล PSNR ที่ใกล้เคียงกัน แต่มีผล PSNR ที่ต่ำกว่าเมื่อเปรียบเทียบกับวิธีการเรียนรู้เชิงลึก สำหรับอัลกอริทึมการเรียนรู้เชิงลึกพบว่า ทั้ง ResNet และ U-net แบบดั้งเดิมได้ผลการกำจัดสัญญาณรบกวน Gaussian มีค่า PSNR ที่ใกล้เคียงกัน โดยที่ ResNet-G และ U-net-G มีผลการกำจัดสัญญาณรบกวนประเภท Gaussian ที่ต่ำกว่าโครงสร้างการเรียนรู้เชิงลึกแบบดั้งเดิมและการใช้ edge-perceptual loss และจากผลการทดลองการใช้ edge-perceptual loss สามารถเพิ่ม PSNR ของโครงสร้างการเรียนรู้เชิงลึกของ ResNet ได้เล็กน้อย แต่อย่างไรก็ตาม U-net-P ยังได้ผลที่ต่ำกว่า U-net แบบดั้งเดิมเล็กน้อย




ภาพประกอบ 3-2 แสดงกราฟเปรียบเทียบ PSNR ของแต่ละอัลกอริทึมในการกำจัด Impulse noise


สำหรับการทดลองกำจัดสัญญาณรบกวนประเภท impulse noise ในภาพประกอบ 3-2 วิธี filtering-based ของอัลกอริทึม BM3D และ NLM ได้ผล PSNR ที่ใกล้เคียงกัน แต่ได้ผลการกำจัดสัญญาณรบกวนต่ำกว่าอัลกอริทึมการเรียนรู้เชิงลึก สำหรับการเปรียบเทียบกันระหว่างอัลกอริทึมการเรียนรู้เชิงลึกนั้น ได้ผลการใช้ ResNet สามารถกำจัดสัญญาณรบกวนแบบ Impulse ที่ดีกว่า U-net ในกรณีของการใช้โครงสร้างดั้งเดิมและการใช้ edge-perceptual loss ใน ResNet-P และ U-net-P

ซึ่งจากการทดลองพบว่าการใช้ ResNet-P และ U-net-P มีผล PSNR ที่ดีกว่าโครงสร้าง ResNet และ U-net ดั้งเดิมเล็กน้อย ซึ่งแสดงให้เห็นว่าการใช้ edge-perceptual loss สามารถเพิ่มประสิทธิภาพให้แก่การเรียนรู้เชิงลึกได้ สำหรับ ResNet-G และ U-net-G ซึ่งเป็น โครงสร้างการเรียนรู้แบบแข่งขัน พบว่า ResNet-G มีผล PSNR ที่น้อยกว่า ResNet แบบดั้งเดิม และ ResNet-P ที่ใช้ edge-perceptual loss แต่สำหรับ U-net-G มีผล PSNR ที่ดีกว่า U-net ดั้งเดิมและ U-net-P ที่ใช้การคำนวณ edge-perceptual loss

ภาพประกอบ 3-3 และภาพประกอบ 3-4 แสดงตัวอย่างของการเปรียบเทียบผลการทดลอง กำจัดสัญญาณรบกวนประเภท Gaussian noise และ impulse noise ตามลำดับ โดยแสดงผลของการ ทำ edge detection ของภาพ output ของแต่ละอัลกอริทึม ซึ่งแสดงให้เห็นว่าอัลกอริทึมประเภท filtering-based สามารถรักษาคูณลักษณะของวัตถุได้น้อยกว่าอัลกอริทึมการเรียนรู้เชิงลึก และจาก ภาพประกอบพบว่า ResNet-G และ U-net-G ซึ่งเป็นการเรียนรู้แบบแข่งขันของ GANs สามารถเก็บ รักษาคูณลักษณะของขอบวัตถุได้ดีกว่าการเรียนรู้แบบดั้งเดิมและการเรียนรู้ด้วยการใช้ edge-perceptual loss ซึ่งสอดคล้องกับผลการทดลองวัด PSNR ของตาราง 3-1 สำหรับการเปรียบเทียบผล การกำจัดและผลของ edge detection ของ impulse noise แสดงให้เห็นว่าการเรียนรู้เชิงลึกนั้นมี ประสิทธิภาพที่ดีกว่าอัลกอริทึม filtering-based โดยที่ ResNet-P และ U-net-P สามารถเก็บรักษาคูณลักษณะของขอบวัตถุได้ใกล้เคียงกับ ResNet และ U-net แบบดั้งเดิม โดยที่การเรียนรู้แบบ แข่งขันของ ResNet-G และ U-net-G ไม่สามารถเก็บรักษาคูณลักษณะของขอบวัตถุได้ ถึงแม้ว่า U-net-G จากผลการทดลองในภาพประกอบ 3-2 จะได้ผล PSNR เฉลี่ยที่ดีกว่า ResNet และ ResNet-P




ภาพประกอบ 3-3 ตัวอย่างการเปรียบเทียบผลของการกำจัดสัญญาณรบกวนแบบ Gaussian และขอบของภาพเปรียบเทียบกับอัลกอริทึมอื่นๆ



ภาพประกอบ 3-4 ตัวอย่างการเปรียบเทียบผลของการกำจัดสัญญาณรบกวนแบบ Impulse และขอบของภาพเปรียบเทียบกับอัลกอริทึมอื่นๆ

นอกจากนี้การทดลองนี้ยังได้ศึกษาผลกระทบของสภาพแวดล้อมที่ส่งผลต่อการทำ edge detection ซึ่งอาจส่งผลต่อการใช้งาน edge-perceptual loss ตามภาพประกอบ 3-5 เนื่องจากการสูญเสียคุณลักษณะของขอบวัตถุในภาพไป ซึ่งได้แสดงผลของการทำ edge detection ของภาพถ่ายที่มีสัญญาณรบกวนในสถานะแสงมากและแสงน้อย โดยงานวิจัยนี้ได้ทำการตั้งค่าการทดลองด้วยการปรับ enhance module factor ใน Pillow ที่ 0.5 สำหรับสถานะแสงมาก และใช้ค่า 8 สำหรับสถานะแสงน้อย




ภาพประกอบ 3-5 ตัวอย่างภาพสัญญาณรบกวนแบบ Gaussian ในสภาวะแสงมากและแสงน้อย

ในการทดลองนี้จะใช้วิธีวัดผลด้วย PSNR ของการกำจัดสัญญาณรบกวน Gaussian noise ในสภาวะแสงมาและแสงน้อยในตารางผล PSNR ในตาราง 3-2 และแสดงกราฟเปรียบเทียบในภาพประกอบ 3-6 นอกจากนี้ได้แสดงภาพผลลัพธ์ตัวอย่างของการทำ edge detection ในภาพ output ของแต่ละอัลกอริทึมในภาพประกอบ 3-7


ตาราง 3-2 ผลการเปรียบเทียบ PSNR ของการกำจัดสัญญาณรบกวน Gaussian ในสภาวะแสงมาก และแสงน้อย

algorithm	สภาวะแสงมาก	สภาวะแสงน้อย
ResNet	30.85	30.04
ResNet-G	26.87	24.12
ResNet-P	30.59	29.9
U-net	30.25	30.04
U-net-G	25.17	27.33
U-net-P	30.16	29.85



ภาพประกอบ 3-6 กราฟแสดงผลการกำจัดสัญญาณ Gaussian ในสภาวะแสงมากและแสงน้อย

จากผลการทดลองพบว่าในสภาวะที่มีแสงมากจะให้ผล PSNR ของการกำจัดสัญญาณรบกวนที่มากกว่าสภาวะแสงน้อยเล็กน้อย โดย ResNet และ U-net แบบดั้งเดิม และ ResNet และ U-net ที่ใช้ edge-perceptual loss ให้ผล PSNR มีค่าใกล้เคียงกัน สำหรับการทดลองใช้ ResNet-G และ U-net-G ซึ่งเป็นการเรียนรู้แบบแข่งขันจะได้ผล PSNR น้อยกว่าโครงสร้างการเรียนรู้เชิงลึกแบบดั้งเดิมและการใช้ edge-perceptual loss โดยที่ ResNet-G จะจัดการกับสภาวะที่มีแสงมากได้ดีกว่า U-net-G ขณะที่ U-net-G จะสามารถจัดการสภาวะที่มีแสงน้อยได้ดีกว่า ResNet-G



ภาพประกอบ 3-7 แสดงตัวอย่างผลการกำจัดสัญญาณรบกวนแบบ Gaussian ในสภาวะแสงมากและแสงน้อยของโครงสร้างการเรียนรู้เชิงลึกที่ใช้ edge-perceptual loss โครงสร้างดั้งเดิม และโครงสร้างการเรียนรู้แบบแข่งขันแบบ GANs

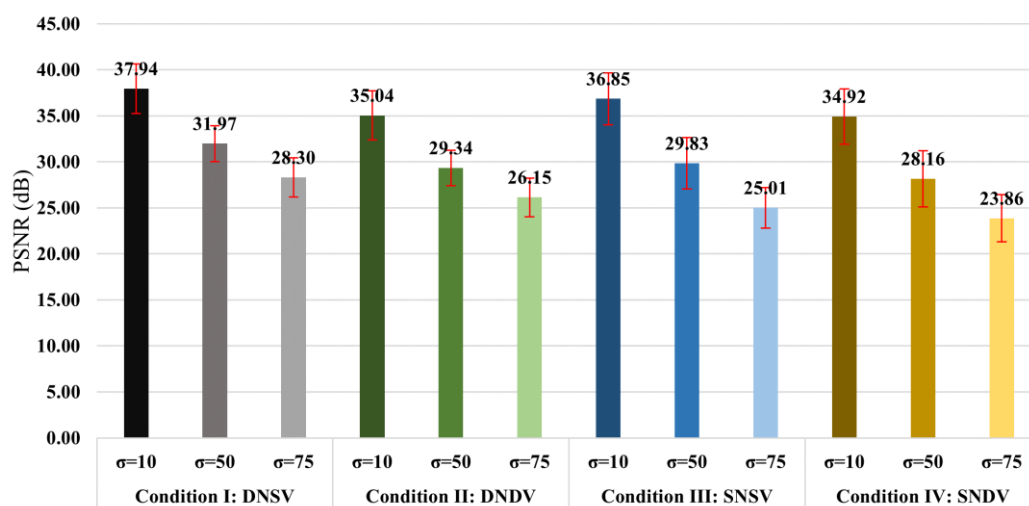
ภาพประกอบ 3-7 ได้แสดงตัวอย่างของการกำจัดสัญญาณรบกวนในสถานะแสงมากและแสงน้อยของแต่ละโครงสร้างการเรียนรู้เชิงลึก จากภาพตัวอย่างพบว่าในสถานะที่สูญเสียคุณลักษณะของขอบวัตถุไปทั้งโครงสร้างการเรียนรู้เชิงลึกแบบดั้งเดิม และโครงสร้างที่ใช้ edge-perceptual loss ให้ผลที่ใกล้เคียงกัน แต่โครงสร้างการเรียนรู้เชิงลึกแบบแข่งขันใน ResNet-G และ U-net-G จะทำให้ความสว่างของภาพเปลี่ยนแปลงไปด้วยเมื่อทำการกำจัดสัญญาณรบกวน

3.2 การทดลองที่ 2 การใช้ self-validation Noise2Noise framework สำหรับกำจัดสัญญาณรบกวน

ในส่วนนี้จะแสดงผลการทดลองแนวคิดของ self-validation Noise2Noise (SV-N2N) framework ในการทดลองกำจัดสัญญาณรบกวนประเภท Gaussian และ impulse ในลำดับแรกจะเป็นการทดลองกำจัดสัญญาณรบกวนใน 4 สถานการณ์ซึ่งได้อธิบายการตั้งค่าการทดลองในบทที่ 2 ไว้แล้วนั้น โดยจะแสดงผลการทดลองวัดค่า PSNR และ SSIM ของการกำจัดสัญญาณรบกวนในตาราง 3-3 และแสดงผลเป็นกราฟเปรียบเทียบในภาพประกอบ 3-8 โดยการทดลองนี้ได้ทดลองกำจัดสัญญาณรบกวนแบบ Gaussian noise 3 แบบ ได้แก่ $\sigma=10, 50$ และ 75

ตาราง 3-3 เปรียบเทียบผล PSNR ของ 4 สถานการณ์ที่ได้ตั้งค่าสำหรับ self-validation

Condition	noise level	PSNR	SSIM
DNSV	$\sigma=10$	37.94 (2.70)	0.95
	$\sigma=50$	31.97 (1.94)	0.87
	$\sigma=75$	28.30 (2.12)	0.81
DNDV	$\sigma=10$	35.04 (2.65)	0.93
	$\sigma=50$	29.34 (1.94)	0.75
	$\sigma=75$	26.14 (2.11)	0.63
SNSV	$\sigma=10$	36.85 (2.82)	0.94
	$\sigma=50$	29.83 (2.79)	0.87
	$\sigma=75$	25.00 (2.22)	0.70
SNDV	$\sigma=10$	34.92 (2.99)	0.94
	$\sigma=50$	28.16 (3.05)	0.84
	$\sigma=75$	23.86 (2.56)	0.75



ภาพประกอบ 3-8 ผลการเปรียบเทียบการกำจัดสัญญาณรบกวนของ 4 สถานการณ์ของการตั้งค่า self-validation ที่ใช้ในการทดลอง


ตาราง 3-3 และภาพประกอบ 3-8 แสดงการเปรียบเทียบผล PSNR ของ 4 สถานการณ์ จากผลการทดลองพบว่าสถานการณ์ DNSV ซึ่งเป็นการตั้งค่าช่วงสัญญาณรบกวนแบบ dynamic ระหว่าง $\sigma=10-50$ และ additive noise validation ที่ $\sigma=10$ เดิมเข้าไปในภาพ input เพื่อใช้เป็น validation ในกระบวนการเรียนรู้ ให้ผลการทดลองกำจัดสัญญาณรบกวนที่มีค่า PSNR มากที่สุด ซึ่งให้ผลการกำจัดสัญญาณรบกวนมากที่สุดในทุกๆ ค่าของสัญญาณรบกวนแบบ Gaussian noise สำหรับกรณี DNDV จะเป็นการใช้ dynamic ระหว่าง $\sigma=10-50$ สำหรับจำลองภาพ input และ additive noise ที่เดิมเข้าไปใน input สำหรับทำ self-validation จะให้ผลการทดลองวัด PSNR ต่ำกว่า DNSV

สำหรับกรณี SNSV และ SNDV จะเป็นการตั้งค่าที่เป็นสัญญาณรบกวน input ค่าเดียว โดยการทดลองได้ใช้สัญญาณ Gaussian $\sigma=50$ ในภาพ input โดยที่ใช้ static Gaussian $\sigma=10$ สำหรับสร้าง self-validation ของ SNSV และ dynamic Gaussian $\sigma=10-50$ สำหรับสร้าง self-validation ใน SNDV ซึ่งการตั้งค่าแบบ SNSV และ SNDV ที่ใช้ static noise ค่าเดียวมาเป็น input เป็นกรณีที่ตรงกับปัญหาของ single image และ blind noise ที่มักใช้สมมุติฐานของการถูกรบกวนที่สม่ำเสมอในสถานะแวดล้อมของการถ่ายภาพ โดยจากผลการทดลองพบว่าค่าการตั้งค่าแบบ SNSV จะให้ผลการทดลองที่ดีกว่า SNDV แต่อย่างไรก็ตาม SNSV ยังมีผลการทดลองที่ต่ำกว่า DNSV

จากการทดลองเปรียบเทียบ 4 สถานการณ์ของการตั้งค่า self-validation พบว่ากรณี DNSV ได้ผลการทดลองที่ดีที่สุด โดยจะนำ DNSV มาเปรียบเทียบกับอัลกอริทึมอื่นๆ เนื่องจากอัลกอริทึมที่นำมาใช้เปรียบเทียบผลการทดลองจะเป็นอัลกอริทึมที่มีการตั้งค่าด้วยการเรียนรู้จากชุดข้อมูลจำนวนมากอยู่แล้ว ทำให้เพื่อให้การทดลองนี้สอดคล้องกับการตั้งค่าการเรียนรู้ของอัลกอริทึมอื่นๆ ที่ใช้เปรียบเทียบจึงได้เลือกใช้ DNSV ซึ่งเป็นการตั้งค่าการทดลองด้วยสัญญาณรบกวนแบบ Gaussian หลายค่าในกระบวนการเรียนรู้ ดังนั้นงานวิจัยนี้จึงนำ DNSV มาเป็นตัวแทนของ SV-N2N กับอัลกอริทึมอื่นๆ โดยการเปรียบเทียบผลนี้ได้ใช้อัลกอริทึมประเภท filtering-based ซึ่งใช้ BM3D และอัลกอริทึมแบบ denoising framework ของการเรียนรู้เชิงลึกซึ่งได้อธิบายไปแล้วได้แก่ N2C และ N2N โดยแสดงผลการเปรียบเทียบ PSNR ในตาราง 3-4 และกราฟเปรียบเทียบผลในภาพประกอบ 3-9

ตาราง 3-4 เปรียบเทียบผล PSNR ของ self-validation framework กับ framework อื่นๆ


algorithm	noise level	PSNR	SSIM
BM3D	$\sigma=10$	35.59 (3.47)	0.91
	$\sigma=50$	29.33 (2.43)	0.84
	$\sigma=75$	24.10 (1.22)	0.53
N2C	$\sigma=10$	41.24 (3.38)	0.97
	$\sigma=50$	33.81 (2.37)	0.89
	$\sigma=75$	30.33 (1.44)	0.84
N2N	$\sigma=10$	39.50 (2.65)	0.96
	$\sigma=50$	32.79 (1.94)	0.88
	$\sigma=75$	29.21 (2.11)	0.83
SV-N2N (DNSV)	$\sigma=10$	37.94 (2.70)	0.95
	$\sigma=50$	31.97 (1.94)	0.87
	$\sigma=75$	28.30 (2.12)	0.81




ภาพประกอบ 3-9 แสดงผลการเปรียบเทียบ PSNR ของ SV-N2N กับอัลกอริทึมและ framework การเรียนรู้เชิงลึกแบบ Noise2Clean และ Noise2Noise แบบดั้งเดิม

จากผลการทดลอง แสดงผลการเปรียบเทียบ PSNR และ SSIM ของแต่ละอัลกอริทึมและ framework ประเภท N2C N2N และ SV-N2N ที่ได้นำเสนอ พบว่า N2C framework ที่เป็นการใช้ภาพ ground truth ที่ไม่มีสัญญาณรบกวนมาเป็น validation ได้ผลการกำจัดสัญญาณรบกวนที่ดีที่สุด โดยที่ N2N framework ให้ผลการกำจัดสัญญาณรบกวนรองลงมาและมากกว่า SV-N2N โดยที่ BM3D ซึ่งเป็นตัวแทนของอัลกอริทึมแบบ filtering-based ได้ผลการกำจัดสัญญาณรบกวนที่ต่ำที่สุด แม้ว่า SV-N2N framework จะได้ผลการทดลองที่ต่ำกว่า N2C และ N2N แบบดั้งเดิม แต่จากผลการทดลองแสดงให้เห็นว่า SV-N2N สามารถใช้กำจัดสัญญาณรบกวนได้โดยที่มีประสิทธิภาพต่ำกว่า N2C และ N2N ดั้งเดิมเล็กน้อยเท่านั้น และยังให้ผลการกำจัดสัญญาณรบกวนที่ดีกว่า filtering-based ในการทดลองนี้

ภาพประกอบ 3-10 และภาพประกอบ 3-11 แสดงตัวอย่างภาพที่ถูกกำจัดสัญญาณรบกวนออกไปแล้วแสดงให้เห็นว่าการใช้ SV-N2N สามารถกำจัดสัญญาณรบกวนและยังรักษาคุณภาพของภาพถ่ายได้ แม้ว่าผลการวัด PSNR จะให้ผลที่น้อยกว่า N2C และ N2N อยู่เล็กน้อย ซึ่งผลการทดลองกำจัดสัญญาณที่มีค่าสูงขึ้นเช่น Gaussian $\sigma=75$ ในภาพตัวอย่าง SV-N2N สามารถให้ผลการกำจัดสัญญาณรบกวนที่ใกล้เคียงกับ N2C และ N2N ยิ่งขึ้น และยังสามารถเก็บรักษารายละเอียดของภาพได้ดีกว่า BM3D ซึ่งเป็นอัลกอริทึมแบบ filtering-based

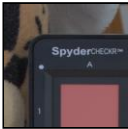
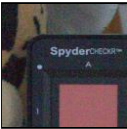
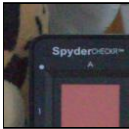
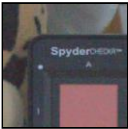

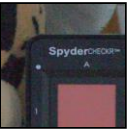
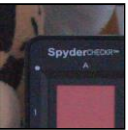

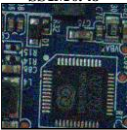




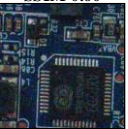














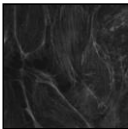
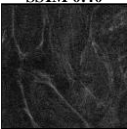
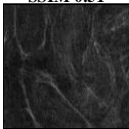
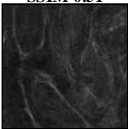

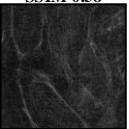
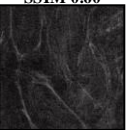


ภาพประกอบ 3-10 แสดงตัวอย่างการกำจัดสัญญาณรบกวนในสภาพแวดล้อมทั่วไปของแต่ละ framework




ภาพประกอบ 3-11 แสดงตัวอย่างการกำจัดสัญญาณรบกวนในภาพตัวอักษรของแต่ละ framework

นอกจากนี้งานวิจัยนี้ได้ทำการเปรียบเทียบผลลัพธ์ของ SV-N2N กับอัลกอริทึม single image denoising และ unsupervised-learning อื่นๆ โดยได้แสดงผลการเปรียบเทียบในภาพประกอบ 3-12 ซึ่งใช้ชุดข้อมูลภาพ real-world noisy image จาก NIND, SIDD และ FMD dataset

	Ground trust	Noisy	N2V	N2S	R2R	S2S	SV-N2N
NIND 1							
		PSNR 22.20 SSIM 0.48	PSNR 26.88 SSIM 0.61	PSNR 23.33 SSIM 0.51	PSNR 26.04 SSIM 0.54	PSNR 26.15 SSIM 0.55	PSNR 26.33 SSIM 0.60
NIND 2							
		PSNR 17.70 SSIM 0.33	PSNR 20.82 SSIM 0.53	PSNR 16.29 SSIM 0.39	PSNR 20.59 SSIM 0.50	PSNR 19.83 SSIM 0.49	PSNR 21.02 SSIM 0.54
SIDD 1							
		PSNR 21.14 SSIM 0.39	PSNR 28.43 SSIM 0.72	PSNR 24.72 SSIM 0.65	PSNR 26.02 SSIM 0.51	PSNR 26.71 SSIM 0.57	PSNR 26.23 SSIM 0.57
SIDD 2							
		PSNR 21.37 SSIM 0.40	PSNR 25.24 SSIM 0.51	PSNR 26.06 SSIM 0.51	PSNR 26.63 SSIM 0.53	PSNR 26.70 SSIM 0.58	PSNR 26.84 SSIM 0.60
FMD 1							
		PSNR 24.38 SSIM 0.33	PSNR 29.49 SSIM 0.62	PSNR 31.87 SSIM 0.75	PSNR 29.03 SSIM 0.63	PSNR 27.92 SSIM 0.57	PSNR 28.71 SSIM 0.59

ภาพประกอบ 3-12 แสดงตัวอย่างผลการทดลองใช้ SV-N2N ในปัญหา single image และ blind noise เปรียบเทียบอัลกอริทึมอื่นๆ

จากการแสดงผลการทดลองในภาพประกอบ 3-12 พบว่า SV-N2N มีความสามารถในการกำจัดสัญญาณรบกวนได้ดีเมื่อเปรียบเทียบกับอัลกอริทึมอื่นๆ โดยได้แสดงผลการเปรียบเทียบผลของการทดลองในกราฟเปรียบเทียบ PSNR ของแต่ละอัลกอริทึมในภาพประกอบ 3-13



ภาพประกอบ 3-13 แสดงกราฟผลการเปรียบเทียบ PSNR ระหว่าง SV-N2N กับอัลกอริทึมอื่นๆ

จากการเปรียบเทียบผลการทดลองในภาพประกอบ 3-13 พบว่าสำหรับภาพสี RGB ของ NIND และ SIDD dataset โดยอัลกอริทึม N2V, R2R, S2S และ SV-N2N จะได้ผลการทดลองที่ใกล้เคียงกันและดีกว่าอัลกอริทึม N2S เนื่องจากลักษณะการสร้างข้อมูลมาใช้ในการเรียนรู้ของ R2R, S2S และ SV-N2N มีลักษณะใกล้เคียงกัน ซึ่งเป็นการเฉลี่ยสัญญาณรบกวนจากการเรียนรู้การจำลองภาพถ่าย ในขณะที่ N2V เป็นการใช้เทคนิค blind-spot kernel เพื่อ manipulate ภาพโดยตรงขณะเรียนรู้ผ่านชั้นซ่อนของโครงสร้างการเรียนรู้เชิงลึก สำหรับ N2S จะเป็นการใช้การเรียนรู้เชิงลึกกำหนดค่า kernel ในการกำจัดสัญญาณรบกวนได้ผลลัพธ์ที่แย่กว่าอัลกอริทึมอื่นๆ เนื่องจากการใช้ kernel filter ปกติของ traditional filter มากำจัดสัญญาณรบกวนโดยไม่ได้มีการปรับค่าพารามิเตอร์ภายในของ filter kernel การเรียนรู้ของ N2S เป็นเพียงการปรับขนาดของ kernel เท่านั้น ซึ่งทำให้การกำจัดสัญญาณรบกวนด้วยการ convolution ปกติอาจส่งผลกระทบต่อความละเอียดของภาพที่ลดลงได้ สำหรับการกำจัดสัญญาณรบกวนใน FMD dataset ซึ่งเป็น gray scale มีความซับซ้อนที่น้อยกว่าจึงทำให้การกำจัดสัญญาณรบกวนมีประสิทธิภาพค่อนข้างดีสำหรับทุกอัลกอริทึม โดยที่ N2V ให้ผลลัพธ์ของการกำจัดสัญญาณรบกวนที่ดีกว่าอัลกอริทึมอื่นๆ เนื่องจาก blind-spot kernel ของ N2V สามารถเฉลี่ยผลลัพธ์ของสัญญาณรบกวนได้ดีกว่าการสร้างข้อมูล validation ของอัลกอริทึมอื่นๆ ซึ่งการสร้างข้อมูลภาพ validation อาจส่งผลกระทบต่อารลดทอนรายละเอียดภาพของ gray scale เนื่องจากคุณลักษณะของข้อมูลที่น้อยกว่าภาพ RGB


3.3 การทดลองที่ 3 การวิเคราะห์การทดลองฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและลดทอนความละเอียดของภาพ

ในการทดลองนี้ ได้แบ่งการฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและการลดทอนความละเอียดของภาพด้วยการเรียนรู้เชิงลึก โดยจะแบ่งการฟื้นฟูออกเป็น 3 framework ซึ่งได้อธิบายไว้แล้วในภาพประกอบ 2-14 ของบทที่ 2 ซึ่งได้แก่ การใช้โครงสร้างการเรียนรู้เชิงลึก 1 โครงสร้างในการเรียนรู้และกำจัดสัญญาณรบกวนการและเพิ่มความละเอียดของภาพถ่ายใน framework I (normal) การกำจัดสัญญาณรบกวนก่อนเพิ่มความละเอียดของภาพถ่ายใน framework II (dn+sr) และการเพิ่มความละเอียดของภาพก่อนการกำจัดสัญญาณรบกวนใน framework III (sr+dn) การทดลองจะวัดผลเปรียบเทียบ PSNR ของภาพของแต่ละ framework ใน

ตาราง 3-5 และภาพประกอบ 3-14 ดังนี้

ตาราง 3-5 เปรียบเทียบผล PSNR ของแต่ละ framework การฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและความละเอียดต่ำ

	Normal	Denoised before Super-resolution (dn+sr)	Super-resolution before Denoised (sr+dn)
PSNR	15.97 (2.47)	26.48 (9.34)	16.27 (2.11)



ภาพประกอบ 3-14 เปรียบเทียบผล PSNR ระหว่างการฟื้นฟูภาพถ่ายของ 3 framework


ใน Framework I (normal) ขณะอยู่ในกระบวนการเรียนรู้สามารถจัดการสัญญาณรบกวนและเพิ่มความละเอียดของภาพได้ดี แต่เมื่อนำ model ของโครงสร้างมาใช้งานพบว่าไม่สามารถ

จัดการกับชุดข้อมูลใหม่ที่ไม่เคยเห็นมาก่อนได้ เกิดปัญหา overfitting เป็นผลให้ผลลัพธ์ของการทดลองมีผล PSNR ของการฟื้นฟูภาพถ่ายที่ต่ำ ขณะที่ Framework II (dn+sr) จะกำจัดสัญญาณรบกวนก่อนการเพิ่มความละเอียดของภาพ พบว่าสามารถให้ผลการฟื้นฟูภาพถ่ายที่ดีกว่าทุก Framework ที่ใช้ในการทดลองนี้ และ framework III (sr+dn) ที่พยายามเพิ่มความละเอียดของภาพถ่ายก่อนการกำจัดสัญญาณรบกวนจะให้ผลการฟื้นฟูภาพถ่ายที่ต่ำเช่นเดียวกับ Framework I เมื่อพิจารณาค่า standard deviation (sd) ของ output พบว่าแม้ว่า framework II จะให้ผล PSNR มากที่สุดแต่มีความไม่แน่นอนของผลลัพธ์ที่สูง

เมื่อพิจารณาภาพตัวอย่าง output ในภาพประกอบ 3-15 จะเห็นว่าภาพ (A) เป็นภาพจากการใช้โครงสร้างการเรียนรู้เดียวมาทำงานทั้งการกำจัดสัญญาณรบกวนและเพิ่มความละเอียดของภาพถ่ายจะยังไม่สามารถจัดการกับภาพที่ยังไม่ได้เรียนรู้ได้ สำหรับ (B) เป็นตัวอย่างภาพของการกำจัดสัญญาณรบกวนก่อนการเพิ่มความละเอียดของภาพถ่ายที่ให้ผล PSNR สูงกว่า framework อื่นๆ แต่มีค่า sd ที่สูงกว่าเช่นกัน เนื่องจากรายละเอียดของภาพมีความผิดเพี้ยนไปจาก ground truth แม้ว่าจะสามารถกำจัดสัญญาณรบกวนออกได้แต่จะเสียรายละเอียดของภาพถ่ายไปด้วย สำหรับ (C) เป็นตัวอย่างของการเพิ่มความละเอียดภาพก่อนกำจัดสัญญาณรบกวน พบว่าการตั้งค่า framework ในลักษณะนี้ไม่สามารถฟื้นฟูภาพถ่ายได้ เนื่องจากภาพตัวอย่างนี้ denoising network ที่รับภาพที่เพิ่มความละเอียดมาจาก super-resolution network ไม่สามารถลดสัญญาณรบกวนของภาพได้ จึงส่งผลให้สัญญาณรบกวนในภาพถ่ายยังคงอยู่ตามภาพตัวอย่างที่ได้แสดงไว้



(A) ผลลัพธ์ของการเรียนรู้กำจัดสัญญาณรบกวนและเพิ่มความละเอียดพร้อมกัน



(B) ผลลัพธ์ของการกำจัดสัญญาณรบกวนก่อนเพิ่มความละเอียด



(C) ผลลัพธ์ของการเพิ่มความละเอียดก่อนการกำจัดสัญญาณรบกวน


ภาพประกอบ 3-15 แสดงภาพตัวอย่างผลการฟื้นฟูภาพถ่ายของแต่ละ framework ที่ใช้ในการทดลอง

แม้ว่าจากผลการทดลองแสดงให้เห็นว่าการพยายามกำจัดสัญญาณรบกวนและเพิ่มความละเอียดพร้อมกันไม่อาจสามารถฟื้นฟูคุณภาพของภาพถ่ายได้ดี แต่อย่างไรก็ตามในปัญหา single image และ blind noise ก็ไม่สามารถแบ่งแยกการฟื้นฟูภาพถ่ายด้วย Framework II และ III ได้ เนื่องจากข้อจำกัดของปริมาณข้อมูล ทำให้งานวิจัยนี้ได้นำเสนอ self-validation framework สำหรับการกำจัดสัญญาณรบกวนและเพิ่มความละเอียดภาพถ่ายดังที่ได้อธิบายไว้ในภาพประกอบ 2-16 โดยการทดลองนี้ได้ใช้การฟื้นฟูภาพถ่ายที่มีสัญญาณรบกวนและต้องการเพิ่มขนาด x2, x4 และ x8 เท่า ซึ่งใช้ภาพการทดลองจาก NIND และ SSID dataset โดยการตั้งค่าการทดลองนี้จะใช้ภาพขนาด


512x512 เป็นขนาดเป้าหมายของการทดลองซึ่งได้แสดงภาพรวมขั้นตอนการ และทำการเรียนรู้ 30 รอบในการฟื้นฟูความละเอียด 1 ครั้ง โดยการทดลองนี้ได้แสดงผลของการฟื้นฟูทั้งหมด 6 ครั้ง ตามตาราง 3-6 และตาราง 3-7 และแสดงกราฟผล PSNR และ SSIM ของ NIND และ SIDD dataset ใน

ตาราง 3-6 ผลการฟื้นฟูคุณภาพภาพที่ได้รับผลกระทบจากสัญญาณรบกวนและการลดทอนคุณภาพ จำนวน 6 ครั้งจาก NIND dataset ที่ทำการเพิ่มขนาด x2, x4 และ x8 เท่า

NIND dataset	R1	R2	R3	R4	R5	R6
PSNR x2	18.22 (2.50)	15.64 (2.35)	13.12 (1.97)	11.08 (1.44)	9.65 (0.97)	8.71 (0.65)
SSIM x2	20.96 (2.63)	20.25 (2.62)	19.17 (2.59)	17.94 (2.49)	16.68 (2.31)	15.47 (2.07)
PSNR x4	25.48 (3.11)	26.47 (3.33)	25.98 (3.46)	25.10 (3.55)	24.18 (3.58)	23.34 (3.59)
SSIM x4	0.17 (0.08)	0.11 (0.06)	0.07 (0.04)	0.04 (0.03)	0.03 (0.02)	0.02 (0.02)
PSNR x8	0.28 (0.10)	0.25 (0.09)	0.22 (0.09)	0.18 (0.08)	0.15 (0.07)	0.12 (0.06)
SSIM x8	0.55 (0.11)	0.68 (0.12)	0.73 (0.14)	0.75 (0.16)	0.75 (0.18)	0.75 (0.20)




ภาพประกอบ 3-16 ผล PSNR ของการฟื้นฟูความละเอียดของภาพจำนวน 6 ครั้ง ของ NIND dataset




ภาพประกอบ 3-17 ผล SSIM ของการฟื้นฟูความละเอียดของภาพจำนวน 6 ครั้ง ของ NIND dataset

ตาราง 3-7 ผลการฟื้นฟูความภาพถ่ายที่มีสัญญาณรบกวนและการลดทอนคุณภาพ จำนวน 6 ครั้ง จาก SIDD dataset ที่ทำการเพิ่มขนาด x2, x4 และ x8 เท่า

SIDD dataset	R1	R2	R3	R4	R5	R6
PSNR x2	19.54 (1.06)	16.77 (1.10)	14.19 (1.09)	12.20 (0.90)	10.93 (0.66)	10.13 (0.46)
SSIM x2	24.59 (1.16)	24.08 (1.16)	22.95 (1.17)	21.54 (1.18)	19.97 (1.21)	18.33 (1.25)
PSNR x4	27.34 (1.22)	28.65 (1.18)	27.82 (1.25)	27.14 (1.30)	26.69 (1.32)	26.36 (1.34)
SSIM x4	0.15 (0.03)	0.10 (0.02)	0.07 (0.02)	0.05 (0.01)	0.04 (0.01)	0.03 (0.01)
PSNR x8	0.38 (0.05)	0.36 (0.05)	0.31 (0.05)	0.26 (0.04)	0.21 (0.04)	0.16 (0.03)
SSIM x8	0.56 (0.06)	0.74 (0.05)	0.79 (0.04)	0.80 (0.05)	0.81 (0.05)	0.81 (0.05)

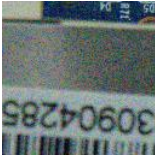
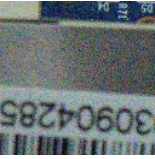
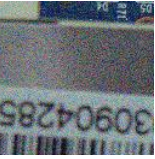
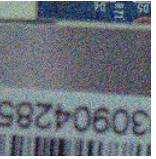
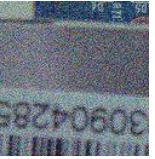
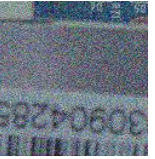
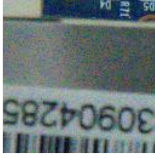
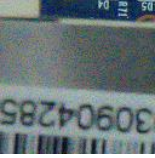
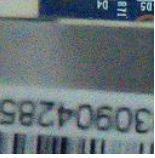
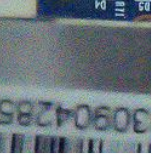










ภาพประกอบ 3-18 ผล PSNR ของการฟื้นฟูความละเอียดของภาพจำนวน 6 ครั้ง ของ SIDD dataset
















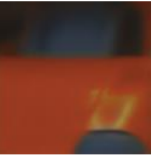




ภาพประกอบ 3-19 ผล SSIM ของการฟื้นฟูความละเอียดของภาพจำนวน 6 ครั้ง ของ SIDD dataset

ภาพประกอบ 3-18 และ ภาพประกอบ 3-19 แสดงกราฟผลลัพธ์ของการฟื้นฟูความละเอียดของภาพ x2, x4 และ x8 เท่าของ NIND และ SIDD dataset ตามลำดับ จากผลการทดลองเพิ่มความละเอียดภาพที่มีสัญญาณรบกวนขนาด x2 และ x4 เท่า พบว่าเมื่อทำการฟื้นฟูความละเอียดซ้ำๆ ผลของ PSNR และ SSIM จะลดต่ำไปเรื่อย ๆ ในขณะที่ผลการทดลองเพิ่มขนาด x8 เท่า จะให้ผลการวัด PSNR ดีที่สุดที่รอบที่ 2 และผลของ SSIM มีการเพิ่มขึ้นอย่างต่อเนื่องทุกรอบ

	Round 1	Round 2	Round 3	Round 4	Round 5	Round 6
x2						
	PSNR 20.42 SSIM 0.25	PSNR 17.44 SSIM 0.17	PSNR 15.07 SSIM 0.11	PSNR 12.48 SSIM 0.06	PSNR 10.25 SSIM 0.05	PSNR 9.03 SSIM 0.04
x4						
	PSNR 23.28 SSIM 0.35	PSNR 22.84 SSIM 0.33	PSNR 21.75 SSIM 0.31	PSNR 20.33 SSIM 0.25	PSNR 18.32 SSIM 0.21	PSNR 16.93 SSIM 0.17
x8						
	PSNR 28.35 SSIM 0.66	PSNR 29.71 SSIM 0.79	PSNR 29.38 SSIM 0.84	PSNR 28.57 SSIM 0.91	PSNR 26.73 SSIM 0.89	PSNR 25.99 SSIM 0.91

ภาพประกอบ 3-20 แสดงผลการฟื้นฟูภาพถ่ายที่มีสัญญาณรบกวนและการลดขนาดภาพขนาด x2, x4 และ x8 ด้วย NLR2NSR framework สำหรับภาพจาก NIND dataset

	Round 1	Round 2	Round 3	Round 4	Round 5	Round 6
x2						
	PSNR 18.95 SSIM 0.17	PSNR 16.49 SSIM 0.11	PSNR 14.18 SSIM 0.09	PSNR 14.02 SSIM 0.06	PSNR 10.97 SSIM 0.05	PSNR 10.08 SSIM 0.04
x4						
	PSNR 23.85 SSIM 0.40	PSNR 24.88 SSIM 0.38	PSNR 23.12 SSIM 0.34	PSNR 21.9 SSIM 0.28	PSNR 19.61 SSIM 0.24	PSNR 18.56 SSIM 0.18
x8						
	PSNR 27.57 SSIM 0.57	PSNR 29.45 SSIM 0.72	PSNR 27.10 SSIM 0.81	PSNR 27.80 SSIM 0.81	PSNR 26.78 SSIM 0.82	PSNR 26.47 SSIM 0.81

ภาพประกอบ 3-21 แสดงผลการฟื้นฟูภาพถ่ายที่มีสัญญาณรบกวนและการลดขนาดภาพขนาด x2, x4 และ x8 ด้วย NLR2NSR framework สำหรับภาพจาก SIDD dataset

จากผลการทดลองในภาพประกอบ 3-20 และภาพประกอบ 3-21 แสดงให้เห็นว่าวิธีการที่นำเสนอสามารถเพิ่มความละเอียดของภาพถ่ายได้พร้อมทั้งสามารถกำจัดสัญญาณรบกวนออกจากภาพถ่ายในปัญหา single image ได้ แต่อย่างไรก็ตามผลการทดลองนี้ได้แสดงจำนวนการฟื้นฟูภาพถ่ายด้วยการนำผลลัพธ์ output กลับเข้ามาป้อนเป็น input ของการเรียนรู้เชิงลึกใหม่ เนื่องจากการเรียนรู้ด้วยภาพถ่ายเดียวที่แม้ว่าจะทำให้การเรียนรู้เชิงลึกเกิด overfitting ได้ แต่สำหรับปัญหา single image จะเป็นผลดีต่อการฟื้นฟูภาพถ่ายด้วยหลักการ unsupervised ด้วย self-validation เมื่อใช้ในจำนวนรอบที่เหมาะสม

บทที่ 4

วิเคราะห์ผลการทดลอง

บทนี้จะเป็นการวิเคราะห์ผลที่เกิดขึ้นของผลการทดลองในบทที่ 3 ซึ่งจะอธิบายที่มาที่ไปของสาเหตุที่เกิดขึ้นของผลลัพธ์การทดลอง โดยจะอธิบายเปรียบเทียบกับอัลกอริทึมและ framework อื่นๆ โดยจะแยกการวิเคราะห์เป็น 3 หัวข้อตามการทดลองในบทที่ 3 ดังนี้

4.1 การวิเคราะห์ผลการทดลอง edge-perceptual loss สำหรับการกำจัดสัญญาณรบกวนในภาพถ่าย


ในผลการทดลองของการเปรียบเทียบ edge-perceptual loss กับ filtering-based พบว่าการใช้ filtering-based ในการกำจัดสัญญาณรบกวนเป็นวิธีที่เร็วและง่าย เนื่องจากการคำนวณที่ซับซ้อนน้อยกว่าการเรียนรู้เชิงลึก แต่อย่างไรก็ตามการ filtering-based อาจมีความผิดพลาดจากการเลือกใช้ filter kernel ที่สอดคล้องกับชนิดของสัญญาณรบกวนที่ต้องการกำจัด เนื่องจากการประมาณค่าของ noise เพื่อเลือก kernel ที่เหมาะสมเป็นเรื่องที่ยาก นอกจากนี้ filtering-based มักจะทำให้ลักษณะของขอบในภาพจางหายไปจากการทำ convolution ซึ่งเป็นการลดทอนคุณภาพของสัญญาณภาพอย่างหนึ่งจากผลของการกรองสัญญาณภาพที่มีองค์ประกอบของสัญญาณตรงกับสัญญาณรบกวน ทำให้ค่า PSNR ในการกำจัดสัญญาณรบกวนด้วย filtering-based มีค่าต่ำกว่าวิธี learning-based ซึ่งสามารถปรับตัวด้วยการเรียนรู้ชนิดของสัญญาณรบกวนที่ต้องการกำจัดได้ จากการทดลองนี้วิธี filtering-based มักจะกำจัดสัญญาณชนิด Gaussian ได้ดีกว่าสัญญาณชนิดอื่นๆ เนื่องจาก BM3D และ NLM ที่นำมาใช้ทดลองมักใช้ filter หรือ kernel ที่เข้ากันได้กับสัญญาณชนิด Gaussian เนื่องจากเป็นสมมติฐานของสัญญาณรบกวนโดยทั่วไปที่เกิดในภาพมักจะถูกพิจารณาเป็นสัญญาณแบบ Gaussian ในการกำจัดสัญญาณรบกวนด้วยการเรียนรู้เชิงลึก แม้ว่าให้ผลการฟื้นฟูที่ดีกว่าการใช้ตัวกรองของ filtering-based เนื่องจากความสามารถในการปรับตัวของข้อมูลสัญญาณรบกวนที่ป้อนเข้าไปในกระบวนการเรียนรู้ แต่อย่างไรก็ตามการเรียนรู้เชิงลึกมักจะต้องใช้ข้อมูลจำนวนมากในการเรียนรู้คุณลักษณะของสัญญาณรบกวนที่ต้องกำจัดออกไป ทำให้ในบางครั้งอาจไม่เหมาะสมกับสถานการณ์ที่ขาดแคลนชุดข้อมูลเพื่อใช้ในกระบวนการเรียนรู้

จากการทดลองใช้งาน edge-perceptual loss ที่ได้นำเสนอไปนั้น การใช้ edge-perceptual loss สามารถเพิ่มประสิทธิภาพให้แก่โครงสร้างการเรียนรู้ของ ResNet-P และ U-net-P ได้เล็กน้อยเมื่อเทียบกับโครงสร้างดั้งเดิมของ ResNet และ U-net เนื่องจากการเพิ่มคุณลักษณะของขอบวัตถุ

สามารถเพิ่มประสิทธิภาพของโครงสร้างการเรียนรู้เชิงลึกได้ เมื่อนำ ResNet-P และ U-net-P มาเปรียบเทียบกับ ResNet-G และ U-net-G นั้นพบว่าในกรณีของสัญญาณรบกวน Gaussian การใช้ ResNet-P และ U-net-P ยังให้ประสิทธิภาพที่ดีกว่า เนื่องจาก ResNet-G และ U-net-G เป็นการเรียนรู้แบบแข่งขันของโครงสร้าง GANs ซึ่งมักจะไม่แน่นอนของผลลัพธ์ในโครงสร้าง generator ที่สูง สำหรับกรณีกำจัดสัญญาณรบกวน impulse โครงสร้าง U-net-G กลับให้ผลลัพธ์ที่ดีกว่า เพราะว่า U-net เป็นโครงสร้างในการสกัดคุณลักษณะสำคัญของภาพซึ่งจัดการกับสัญญาณ impulse ได้ดีกว่าสัญญาณ Gaussian เนื่องจากสัญญาณ impulse จะรบกวนเพียงบางจุดของ pixel ในภาพถ่าย และยังคงคุณลักษณะของ pixel ที่ไม่ได้ถูกรบกวนอยู่ เป็นผลให้ U-net ยังคงสามารถสกัดคุณลักษณะของภาพถ่ายที่สำคัญออกมาได้ ในขณะที่การใช้ ResNet-G จะเป็นการสกัดคุณลักษณะของภาพที่จะมีการคงขนาดของตัวแปลในแต่ละชั้นซ่อนอาจทำให้คุณลักษณะที่ถูกรบกวนจากสัญญาณรบกวนอยู่แล้วและสกัดออกมานั้นจะมีการสูญเสียคุณภาพของคุณลักษณะของภาพไปด้วย และด้วยเหตุผลนี้จึงทำให้การใช้การคำนวณ loss จาก edge-perceptual loss สามารถเติมคุณลักษณะของขอบวัตถุที่สูญเสียไปกลับคืนมาได้บ้าง

จากผลการทดลองยังพบว่า U-net-G ในการกำจัดสัญญาณรบกวนแบบ impulse นั้นให้ค่า standard deviation ของผลลัพธ์ output ที่สูงเนื่องจากการเรียนรู้แบบแข่งขันที่ทำให้แม้ว่าจะสามารถทำให้ generator สามารถเรียนรู้การกำจัดสัญญาณรบกวนแบบ impulse ได้ดีสำหรับ U-net-G เนื่องจากโครงสร้างของ U-net เองสามารถกำจัดสัญญาณรบกวนได้ด้วยคุณสมบัติของ Autoencoder ซึ่งสัญญาณรบกวนแบบ impulse จะมีการรบกวนขอบของภาพวัตถุต่อเนื่องน้อยกว่าสัญญาณรบกวนแบบ Gaussian ที่รบกวน pixel ของภาพทั้งหมด แต่เนื่องจากปัญหาในขณะที่เรียนรู้นั้นจะมีการแข่งขันกันเองของ generator และ discriminator ทำให้ในขณะที่เรียนรู้อันนี้ 2 โครงสร้างจะพยายามเอาชนะกันและกัน ส่งผลให้ค่า loss ที่เกิดขึ้นของ generator มีความไม่แน่นอนของผลลัพธ์นั่นเอง เนื่องจาก GANs มักจะใช้ cross-entropy มาคำนวณ loss ของการแข่งขันภายในโครงสร้าง กล่าวคือแม้ว่าการเรียนรู้แบบแข่งขันจะให้คะแนนสำหรับผู้ชนะและหักคะแนนสำหรับผู้แพ้ในแต่ละรอบการเรียนรู้ แต่คะแนนที่เกิดขึ้นก็จะถูกนำมาคำนวณ loss ด้วย cross-entropy ซึ่งจะต้องมีผลรวมของเหตุการณ์เท่ากับ 1 เสมอ ทำให้เกิดเหตุการณ์ที่บางครั้ง generator สามารถเอาชนะ discriminator ได้ ทุกชุดข้อมูลแล้วจะส่งผลให้ไม่มีการเปลี่ยนแปลงค่า entropy ที่นำมาใช้คำนวณ content loss ของการเรียนรู้ของระบบต่อ และเมื่อ discriminator สามารถกลับมาเอาชนะ generator ได้อีกครั้งจะทำให้มีการเปลี่ยนแปลง entropy ที่สูงกลับมา จึงเป็นเหตุผลที่ทำให้ค่า loss ที่เกิดขึ้นมีความไม่แน่นอน

ที่สูงจากการวัดค่า standard deviation ซึ่งปัญหาที่เกิดขึ้นนี้ถูกนับว่าเป็นปัญหา overfitting ของโครงสร้างการเรียนรู้เชิงลึกแบบหนึ่ง ซึ่งเกิดขึ้นในโครงสร้างการเรียนรู้แบบ GANs และปัญหา overfitting จากการแข่งขันนี้ยังส่งผลให้ภาพ output ที่ได้จากการกำจัดสัญญาณรบกวนของ GANs มีความผิดเพี้ยนไปในบางภาพเช่นกันตามตัวอย่างในภาพประกอบ 4-1 ซึ่งความผิดปกตินี้จะเรียกว่า การเกิด artifact ขึ้นในภาพของ GANs จากปัญหาที่เกิดขึ้นของ GANs นี้จึงทำให้การใช้ edge-perceptual loss สามารถป้องกันปัญหา overfitting ได้แม้ว่า edge-perceptual loss และ SRGANs จะมีการใช้แนวคิดของ perceptual loss แบบเดียวกัน



ภาพประกอบ 4-1 ปัญหา artifact ที่เกิดขึ้นในการเรียนรู้แบบ GANs

4.2 การวิเคราะห์ผลการทดลอง self-validation Noise2Noise framework

แนวคิดของ SV-N2N ที่นำเสนอ นั้นจะมีการป้อนสัญญาณรบกวนค่าเล็กๆ เพื่อสร้างข้อมูล validation สำหรับการเรียนรู้ด้วยตัวเองของการเรียนรู้เชิงลึกในการกำจัดสัญญาณรบกวน โดยในงานวิจัยได้ทำการทดลองพฤติกรรมของสัญญาณรบกวนที่ได้เติมเข้าไปซึ่งแบ่งเป็น 2 กรณีคือการเติมด้วยสัญญาณรบกวนแบบค่าคงที่ และการเติมสัญญาณรบกวนแบบสุ่มหลายค่า ทำให้การทดลองนี้ได้กำหนดรูปแบบของการเรียนรู้ของการเรียนรู้เชิงลึกที่เป็นไปได้ทั้งหมด 4 แบบ ได้แก่ DNSV DNDV SNSV และ SNDV โดยที่ DNSV และ DNDV จะเป็นรูปแบบการเรียนรู้เมื่อภาพ input เป็นสัญญาณแบบสุ่มหลายค่า (dynamic noise) ขณะที่ SNSV และ SNDV จะเป็นรูปแบบของภาพ input แบบคงคคงที่ (fixed noise) ซึ่งลักษณะของ SNSV และ SNDV จะมีความใกล้เคียงกับกรณีสัญญาณรบกวนแบบ blind noise และ single image มากที่สุด

สำหรับผลการทดลองเปรียบเทียบผลลัพธ์ทั้ง 4 รูปแบบนี้การป้อน additive noise ด้วยค่าคงที่ของ DNSV และ SNSV จะได้ผลการกำจัดสัญญาณรบกวนที่ดีกว่า DNDV และ SNDV ที่เป็นการสุ่มค่าสัญญาณรบกวนแบบหลายค่าเข้าไป เนื่องจากสัญญาณรบกวน additive noise ยังคง

สามารถทำให้การเรียนรู้เชิงลึกรับรู้ถึงลักษณะของสัญญาณรบกวนที่เกิดขึ้นในภาพ input ได้ดีและมีความผันผวนของการรับรู้ที่ต่ำเนื่องจากสัญญาณรบกวนของ validation ที่สร้างขึ้นมีองค์ประกอบของสัญญาณรบกวน additive noise ที่คงที่ ในขณะที่การใช้ additive noise แบบหลายค่าจะส่งผลให้การรับรู้ของการเรียนรู้การกำจัดสัญญาณรบกวนที่ความผันผวนสูง และคลาดเคลื่อนได้จากการเปลี่ยนแปลงบ่อยๆ ของข้อมูล validation จากการมีสัญญาณรบกวนหลายค่าแบบสุ่มของ additive noise สำหรับการเปรียบเทียบผลการทดลองของ DNSV และ SNSV พบว่า DNSV จะให้ผลการกำจัดสัญญาณรบกวนที่ดีกว่า SNSV เนื่องจาก DNSV จะเป็นลักษณะข้อมูลในการเรียนรู้ที่ประกอบด้วยสัญญาณรบกวนหลายๆ ช่วง ทำให้โครงสร้างการเรียนรู้เชิงลึกสามารถเข้าใจลักษณะของสัญญาณรบกวนได้กว้างมากขึ้นขณะเรียนรู้ แต่ SNSV จะทำให้กระบวนการเรียนรู้รับรู้เพียงสัญญาณรบกวนที่มีการกระจายตัวเพียงแบบเดียวที่ป้อนให้ทาง input เท่านั้น แต่อย่างไรก็ตามรูปแบบการเรียนรู้ด้วย SNSV จะมีความใกล้เคียงกับลักษณะปัญหาของ single image และปัญหา blind noise ที่ภาพถ่ายมักได้รับการถูกรบกวนจากสัญญาณรบกวนค่าเดียวแต่ไม่ทราบค่าพารามิเตอร์เท่านั้น ทำให้รูปแบบการเรียนรู้ด้วย SNSV นี้จะมีประโยชน์ต่อการนำไปใช้ในการกำจัดสัญญาณรบกวนที่ไม่ทราบค่าด้วยการเรียนรู้เชิงลึกได้ดีกว่า DNSV นอกจากนี้การทดลองได้ใช้สัญญาณรบกวนค่าเล็กเนื่องจากในงานการกำจัดสัญญาณรบกวนในภาพถ่ายจะเป็นเป็นลักษณะข้อมูลที่มีขอบเขตของค่าสัญญาณภาพที่แน่นอน เป็นผลให้เมื่อการเติมสัญญาณรบกวนที่ค่าสูงเกิดไปจะไปทำลายเอกลักษณ์ของสัญญาณ Gaussian noise ที่ใช้ในการทดลองได้ จากการที่ค่าต่ำสุด (min) และค่าสูงสุด (max) ของสัญญาณมีค่าที่สูงขึ้นมาเกิดไปนั่นเอง

เนื่องจากอัลกอริทึมและ framework ของการเรียนรู้เชิงลึกอื่นๆ ที่นำมาเปรียบเทียบยังคงใช้ข้อมูล input ในการเรียนรู้จำนวนมาก ดังนั้นในการเปรียบเทียบผลการทดลองของ SV-N2N กับอัลกอริทึมอื่นๆ จะใช้รูปแบบการเรียนรู้แบบ DNSV ที่เป็นการป้อนสัญญาณรบกวนหลายๆ ค่ามาใช้งาน โดยผลการทดลองยังคงแสดงให้เห็นว่า N2C framework ซึ่งเป็นการเรียนรู้เชิงลึกแบบปกติที่ใช้รูป validation ซึ่งเป็นภาพที่ปราศจากสัญญาณรบกวนจาก ground truth ดังเดิมมาใช้เรียนรู้จะให้ผลการกำจัดสัญญาณรบกวนดีกว่าอัลกอริทึมหรือ framework อื่นๆ เนื่องจากขณะเรียนรู้ N2C framework สามารถมองเห็นผลลัพธ์ที่ถูกต้องได้จึงเรียนรู้ได้ดีกว่าอัลกอริทึมและ framework อื่นๆ ในขณะที่ N2N framework ใช้คู่ของภาพที่มีสัญญาณรบกวนแบบเดียวกัน 2 ชุดข้อมูลมาเป็น input และ validation ขณะเรียนรู้ ทำให้โครงสร้างการเรียนรู้เชิงลึกพยายามเรียนรู้การ transfer ภาพให้มีค่า loss ของระบบน้อยที่สุดในขณะเรียนรู้ เป็นผลให้การทำงานของ N2N framework เปรียบเสมือน

การหาค่าเฉลี่ยของภาพ input และ validation เนื่องจากเป็นวิธีที่จะได้ค่า loss ของระบบที่ต่ำที่สุดสำหรับ SV-N2N ที่นำเสนอ นั้นจะสร้าง validation ขึ้นมาเอง ซึ่งทำให้โครงสร้างการเรียนรู้เชิงลึกแยกแยะความแตกต่างของสัญญาณรบกวน input ได้เองด้วยการเรียนรู้ และยังคงมีพฤติกรรมเช่นเดียวกับ N2N framework ที่เป็นแม่แบบของ SV-N2N นั่นคือ ในขณะที่เรียนรู้ SV-N2N จะพยายามเรียนรู้การคงค่า loss ของระบบให้มีค่าต่ำที่สุด แต่เนื่องจาก additive noise ที่เติมเข้าไปในการสร้าง validation อาจไปรบกวนคุณลักษณะของสัญญาณรบกวนของ input เดิมไปบ้างเป็นเหตุให้ SV-N2N ประเมินค่าสัญญาณรบกวนได้ผิดพลาด ซึ่งเป็นผลมาจากการใช้ additive noise ค่าที่ใหญ่เกินความจำเป็น ซึ่งเป็นปัญหาในทำนองเดียวกันที่ทำให้การเติม additive noise แบบสุ่มหลายค่าของ DNDV และ SNDV มีประสิทธิภาพที่ด้อยกว่า DNSV

นอกจากนี้ในการเปรียบเทียบผลการทดลองกับ unsupervised learning อื่นๆ ใน real-world dataset แสดงให้เห็นว่าแนวคิดของ SV-N2N สามารถเพิ่มความสามารถในการกำจัดสัญญาณรบกวนได้เช่นเดียวกับ unsupervised learning อื่นๆ จากการจำลอง validation data เพื่อเรียนรู้ด้วยตัวเอง

4.3 การวิเคราะห์ผลการทดลองวิเคราะห์การฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและลดทอนความละเอียดของภาพ

การทดลองในส่วนนี้เป็นวิเคราะห์ประสิทธิภาพของการฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและการลดทอนคุณภาพของภาพถ่ายตามโมเดลการลดทอนคุณภาพของภาพถ่ายในสมการที่ 2.16 ซึ่งสามารถเกิดขึ้นได้พร้อมกัน จากผลการทดลองนี้ Framework I เป็นการให้โครงสร้างการเรียนรู้เชิงลึกพยายามกำจัดสัญญาณรบกวนและเพิ่มความละเอียดของภาพถ่ายพร้อมกัน พบว่าได้ประสิทธิภาพที่ต่ำ เนื่องมาจากภาพถ่ายที่ถูกรบกวนนั้นเป็นภาพที่ถูกรบกวนทั้ง noise domain และ blur domain ซึ่งโครงสร้างการเรียนรู้เชิงลึกพยายามที่จะฟื้นฟูคุณลักษณะของภาพโดยพยายามให้ loss ต่ำที่สุด แต่เนื่องจากปัญหาที่เกิดขึ้นเป็นผลมาจาก 2 โดเมนทั้งจาก noise domain และ blurring domain ตามสมการที่ 2.16 จากการลดขนาดภาพ เป็นผลให้เกิด overfitting ในขณะที่เรียนรู้ได้ และเมื่อนำโครงสร้างการเรียนรู้เชิงลึกที่ผ่านการเรียนรู้ไปใช้งานกับภาพถ่ายที่ไม่เคยเรียนรู้จะไม่สามารถฟื้นฟูภาพถ่ายได้ดีเท่าที่ควร สำหรับ framework II เป็นการให้ 2 โครงสร้างการเรียนรู้เชิงลึกแยกทำงานกับ โดยให้โครงสร้างการเรียนรู้ที่ 1 กำจัดสัญญาณรบกวนออกจากภาพก่อนนำไปเพิ่มความละเอียด พบว่าได้ประสิทธิภาพสูงที่สุดจากทั้ง 3 framework

เนื่องจากสัญญาณรบกวนจะไปรบกวนคุณลักษณะของของวัตถุในภาพได้ ดังนั้นเมื่อกำจัดสัญญาณรบกวนนี้ออกไปจะส่งผลให้ขอบวัตถุในภาพมีความชัดเจนขึ้นและส่งผลดีต่อการทำ super-resolution ใน โครงสร้างการเรียนรู้เชิงลึกที่ 2 เพื่อเพิ่มความละเอียดของภาพ แต่อย่างไรก็ตามการกำจัดสัญญาณรบกวนมักจะทำให้รายละเอียดของขอบวัตถุในภาพถ่ายสูญหายไปด้วยบางส่วน จึงทำให้การเพิ่มขนาดภาพถ่ายของ โครงสร้างการเรียนรู้เชิงลึกที่ 2 ไม่สามารถกู้คืนรายละเอียดในส่วนนี้ได้ เป็นผลให้คุณภาพของการฟื้นฟูภาพถ่ายอาจได้ผลที่ไม่สูงมากนัก และมีความไม่แน่นอนสูงจากการวัดค่า standard deviation ใน framework III จะใช้ 2 โครงสร้างการเรียนรู้เชิงลึก โดยจะให้ โครงสร้างการเรียนรู้ที่ 1 เพิ่มความละเอียดของภาพถ่ายก่อนการกำจัดสัญญาณรบกวนด้วย โครงสร้างการเรียนรู้ที่ 2 พบว่าการเพิ่มความละเอียดของภาพถ่ายที่มีสัญญาณรบกวนคือการเพิ่มรายละเอียดของขอบวัตถุในภาพ ซึ่งส่งผลให้ร่องรอยของสัญญาณรบกวนถูกเพิ่มพูนรายละเอียด และสัญญาณรบกวนมีการเปลี่ยนแปลงคุณลักษณะไปด้วย ทำให้โครงสร้างการเรียนรู้เชิงลึกที่ 2 ไม่สามารถกำจัดสัญญาณรบกวนที่เปลี่ยนแปลงไปนี้ได้ เนื่องจากไม่เข้าใจคุณลักษณะของสัญญาณรบกวนใหม่นี้ จึงไม่สามารถแก้ปัญหาการฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและการลดทอนคุณภาพได้

อย่างไรก็ตามแม้ว่า Framework I จะเกิด overfitting กับชุดข้อมูลที่ไม่เคยเห็นมาก่อนก็ตาม แต่สำหรับกรณีนำมาใช้เพื่อเรียนรู้การกำจัดสัญญาณรบกวนในปัญหา single image และ blind noise นั้นสามารถละเลยปัญหา overfitting นี้ได้ เนื่องจากในการทดลองนี้เป็นการใช้ self-validation ในการกำจัดสัญญาณรบกวนในภาพถ่ายชุดเดียวแล้วนั้น ส่งผลให้โครงสร้างการเรียนรู้เชิงลึกสามารถเข้าใจรายละเอียดและคุณลักษณะของภาพได้ดี จากผลการทดลองใน framework ของการเรียนรู้แบบ self-validation สำหรับการกำจัดสัญญาณรบกวนและเพิ่มความละเอียดของภาพนั้นแสดงให้เห็นว่า overfitting จากการเรียนรู้และฟื้นฟูภาพถ่ายเพียงภาพเดียวสามารถฟื้นฟูรายละเอียดของภาพถ่ายที่ได้รับผลกระทบของสัญญาณรบกวนได้จากการเรียนรู้ self-validation ในลักษณะเดียวกับ SV-N2N ในการทดลองที่ 2 อีกทั้งการนำภาพผลลัพธ์กลับเข้ามาเป็น input ใหม่สามารถที่จะเพิ่มความคมชัดของภาพได้มากขึ้น แม้ว่ามีข้อจำกัดของการทำซ้ำที่ได้แสดงในผลการทดลองก็ตาม เนื่องจากการสัญญาณรบกวนที่เป็นองค์ประกอบ high-frequency ตามทฤษฎี Fourier transform จะถูกขยาดกลับมาและมีการเปลี่ยนแปลงคุณลักษณะไปด้วย

ต่อมาได้เสนอแนวคิดของการฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากทั้งสัญญาณรบกวนและการลดคุณภาพ จึงได้นำเสนอแนวคิด NLR2NSR framework ตามภาพประกอบ 2-16 ซึ่งเป็นการใช้

ประโยชน์จากการลดขนาดภาพถ่าย ซึ่งเปรียบเสมือนการกรองสัญญาณรบกวน และใช้แนวคิดของ self-validation มาใช้ในการเรียนรู้ของการเรียนรู้เชิงลึก และทำการ sharing ค่า weight ของโครงสร้างการเรียนรู้เชิงลึกเพื่อนำมาใช้ในการฟื้นฟูภาพถ่ายด้วยตัวมันเอง จากการทดลองนี้พบว่า NLR2NSR สามารถกำจัดสัญญาณรบกวนพร้อมทั้งเพิ่มความละเอียดของภาพถ่ายได้ นอกจากนี้การนำภาพ output เข้ามาฟื้นฟูซ้ำยังสามารถเพิ่มความละเอียดเพิ่มเติมให้แก่ภาพถ่ายได้เช่นกัน แม้ว่าจะทำได้ด้วยจำนวนครั้งที่จำกัดก็ตาม เนื่องจากหากการกรองสัญญาณในระหว่างขั้นตอนการเรียนรู้ ออกไม่หมด ยังเป็นเหตุให้การฟื้นฟูความละเอียดของภาพซ้ำหลายๆ รอบจะส่งผลให้สัญญาณรบกวนที่เหลืออยู่ถูกขยายและเปลี่ยนแปลงคุณสมบัติไปด้วยตามทฤษฎี Wiener convolution ที่ได้เสนอไปในบทที่ 2 และจากกราฟผลการทดลองได้แสดงให้เห็นถึงความสามารถของการฟื้นฟูภาพถ่ายของการนำผลลัพธ์มาฟื้นฟูซ้ำ พบว่าเป็นวิธีที่ได้ผลดีสำหรับ single image ที่เรียนรู้ด้วยเทคนิค self-validation ที่ได้นำเสนอนี้ แต่จะสามารถฟื้นฟูซ้ำได้เพียงระดับหนึ่งเท่านั้น เนื่องจากกราฟการทดลองแสดงให้เห็นถึงผลของ PSNR ที่ลดลงเมื่อทำการฟื้นฟูคุณภาพซ้ำ และยังเป็นการแสดงให้เห็นว่าปัญหา overfitting อาจไม่ได้เป็นอุปสรรคสำหรับ การเรียนรู้แบบ unsupervised ในปัญหา single image และ blind noise

บทที่ 5

สรุปผลการทดลอง

5.1 สรุปผลการทดลอง edge-perceptual loss สำหรับ image denoising

งานวิจัยในหัวข้อนี้ต้องการศึกษาการเพิ่มประสิทธิภาพของการเรียนรู้เชิงลึกด้วยการเพิ่มคุณลักษณะเพื่อนำไปใช้ในการคำนวณค่า loss ของกระบวนการเรียนรู้ ซึ่งจากการศึกษาพบว่าสัญญาณรบกวนสามารถส่งผลกระทบต่อในการหาขอบของวัตถุ ทำให้งานวิจัยนี้เลือกศึกษาการนำคุณลักษณะของขอบวัตถุมาใช้คำนวณค่า loss ร่วมกับ loss ปกติซึ่งเป็น pixel-wise loss โดยได้เรียกการใช้งาน loss 2 ค่าร่วมกันนี้ว่า edge-perceptual loss ซึ่งใช้แนวคิดของ perceptual loss ที่เป็นการนำ loss 2 ค่ามาใช้ปรับพารามิเตอร์ในการเรียนรู้ของเครื่องจักร และได้มีการเปรียบเทียบผลกับโครงสร้างการเรียนรู้เชิงลึกแบบแข่งขันของ generative adversarial network (GANs) ซึ่งมีการใช้การคำนวณแบบ perceptual loss จาก loss 2 ค่าเช่นเดียวกัน โดยผลการทดลอง edge-perceptual loss สามารถเพิ่มประสิทธิภาพให้กับโครงสร้างการเรียนรู้เชิงลึกได้เล็กน้อยเมื่อเทียบกับโครงสร้างการเรียนรู้เชิงลึกแบบเดิมที่ใช้การคำนวณเพียง pixel-wise loss และ edge-perceptual loss มีประสิทธิภาพที่ดีกว่า GANs เนื่องจาก edge-perceptual loss เป็นการเรียนรู้ด้วยโครงสร้างการเรียนรู้เชิงลึกเพียง 1 โครงสร้างเท่านั้น ในขณะที่ GANs เป็นการเรียนรู้แบบแข่งขันของโครงสร้างการเรียนรู้เชิงลึก 2 โครงสร้าง ทำให้สามารถเกิดผลกระทบของ overfitting ได้ง่ายกว่า นอกจากนี้การใช้คุณลักษณะของขอบวัตถุในภาพมีการคำนวณที่ซับซ้อนน้อยกว่าการสกัดคุณลักษณะจากการใช้โครงสร้างการเรียนรู้เชิงลึกแบบ GANs เช่นเดียวกัน แต่อย่างไรก็ตามงานวิจัย edge-perceptual loss นี้ยังมีการกำหนดสัดส่วนของการใช้งานการคำนวณระหว่าง pixel-wise ซึ่งใช้เป็น content-loss และ perceptual loss ที่ใช้ pixel-wise จากภาพขอบวัตถุ ซึ่งเกิดข้อผิดพลาดได้ง่ายจากการตั้งค่า อีกทั้ง edge-perceptual loss ยังจำเป็นต้องใช้ข้อมูลในการเรียนรู้จำนวนมาก ทำให้ไม่เหมาะสมกับการกำจัดสัญญาณรบกวนในปัญหา blind noise และ single image

5.2 สรุปผลการทดลอง self-validation Noise2Noise framework

งานวิจัยในหัวข้อนี้เป็นการพยายามหาวิธีการกำจัดสัญญาณรบกวนในภาพถ่ายด้วยการเรียนรู้เชิงลึกสำหรับปัญหา single image และ blind noise โดยงานวิจัยนี้ได้นำเสนอ self-validation Noise2Noise (SV-N2N) framework ซึ่งได้นำแนวคิดของ Noise2Noise (N2N) framework ที่มีความสามารถในการเรียนรู้การกำจัดสัญญาณรบกวนได้จากแนวคิดการใช้คู่ของสัญญาณรบกวน

ชนิดเดียวกัน 2 ภาพจากแหล่งเดียวกันและสามารถเก็บภาพซ้ำได้มาเป็น input และ validation โดยวิธีการของ N2N framework นี้สามารถเรียนรู้การกำจัดสัญญาณรบกวนโดยไม่จำเป็นต้องอาศัยข้อมูล ground truth เลย ซึ่งมีประโยชน์อย่างมากในสถานการณ์ที่สามารถถ่ายภาพซ้ำๆ โดยที่ฉากถ่ายภาพที่เป็น static screen หรือก็คือองค์ประกอบของภาพไม่มีการเปลี่ยนแปลง ซึ่งสามารถแก้ปัญหา blind noise ที่ไม่ทราบพารามิเตอร์และชนิดของสัญญาณรบกวนที่เกิดขึ้นในภาพได้ดี แต่อย่างไรก็ตามสำหรับสถานการณ์ที่วัตถุหรือกล้องต้องเคลื่อนไหวบ่อยๆ อาจไม่สามารถใช้การเรียนรู้แบบ N2N framework นี้ได้ โดยงานวิจัยนี้จึงได้นำเสนอแนวคิดของ self-learning มาใช้งานร่วมกับ N2N framework ด้วยการสร้างข้อมูลสำหรับ validation ขึ้นมาจากภาพ input เพื่อใช้ให้โครงสร้างการเรียนรู้เชิงลึกสามารถเรียนรู้ได้โดยใช้ข้อมูลในการเรียนรู้เพียงเล็กน้อยเท่านั้น โดยการทดลองพบว่าการสร้างภาพ validation ควรใช้ static noise ที่กำหนดพารามิเตอร์ของตัวแปรในสัญญาณรบกวนที่คงที่จะได้ประสิทธิภาพดีกว่าการใช้ dynamic noise ที่กำหนดพารามิเตอร์แบบสุ่ม เนื่องจากการเรียนรู้เชิงลึกแยกแยะความแตกต่างระหว่างสัญญาณ input และ validation ได้ดีกว่า นอกจากนี้การตั้งค่าการเรียนรู้แบบ SNSV ซึ่งเป็นการใช้ single noise และสร้าง validation ด้วยการป้อน static noise เป็นวิธีสามารถกำจัดสัญญาณรบกวนของปัญหา single image และ blind noise ได้ดีโดยไม่จำเป็นต้องใช้ชุดข้อมูลจำนวนมาก เนื่องจากวิธีการนี้สามารถใช้ SV-N2N framework ที่นำเสนอมาเรียนรู้และกำจัดสัญญาณรบกวนที่เฉพาะเจาะจงในแต่ละภาพถ่ายได้ แต่อย่างไรก็ตาม SV-N2N framework ยังมีประสิทธิภาพที่ต่ำกว่า Noise2Clean (N2C) framework ซึ่งเป็นการเรียนรู้ของการเรียนรู้เชิงลึกแบบดั้งเดิมที่อาศัย noise-free ground truth มาเป็น validation นอกจากนี้การสร้าง validation ขึ้นมาเองของ SV-N2N framework จำเป็นต้องกำหนดค่าและชนิดของสัญญาณรบกวนขึ้นมาเองซึ่งอาจมีความยุ่งยาก ความผิดพลาด และไม่เหมาะสมในการตั้งค่าพารามิเตอร์ในส่วนนี้ได้ สำหรับการเปรียบเทียบผลลัพธ์การกำจัดสัญญาณรบกวนกับอัลกอริทึม unsupervised learning อื่นๆ พบว่า SV-N2N สามารถให้ประสิทธิภาพได้ดีเทียบเท่ากับอัลกอริทึมอื่นๆ ที่นำมาทดลอง จากการที่เป็นแนวคิดของการจำลองข้อมูล validation data เช่นเดียวกัน

5.3 สรุปผลการวิเคราะห์ผลการทดลองวิเคราะห์การฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากสัญญาณรบกวนและลดทอนความละเอียดของภาพ

ในการทดลองนี้ต้องการศึกษาการฟื้นฟูภาพถ่ายที่ได้รับผลกระทบทั้งการลดทอนคุณภาพและสัญญาณรบกวนในภาพพร้อมกัน และเนื่องจากการเรียนรู้เชิงลึกในปัจจุบันมักใช้เรียนรู้ในการ

กำจัดสัญญาณรบกวนหรือเพิ่มความละเอียดของภาพอย่างใดอย่างหนึ่งเพียงโดเมนปัญหาเดียวเท่านั้น โดยงานวิจัยนี้ได้ทดลองเปรียบเทียบประสิทธิภาพของผล PSNR ของทั้ง 3 framework ที่ได้กำหนดไว้ จากการทดลองแสดงให้เห็นว่าในกรณีที่กำหนดให้ 1 โครงสร้างการเรียนรู้เชิงลึกแก้ปัญหาของทั้ง 2 โดเมนปัญหา เมื่อภาพถ่ายได้รับผลกระทบจากนั้นสัญญาณรบกวนและการลดทอนคุณภาพพร้อมกันยังเป็นปัญหาที่ยากต่อการฟื้นฟูภาพถ่ายให้มีสภาพปกติดั้งเดิม เพราะการทดลองแสดงผลลัพธ์ให้เห็นว่าโครงสร้างการเรียนรู้เชิงลึกในปัจจุบันยังไม่สามารถที่จะกำจัดสัญญาณรบกวนพร้อมการเพิ่มความละเอียดในตัวได้เนื่องจากปัญหา overfitting ที่เกิดขึ้นในกระบวนการเรียนรู้หลายโดเมนปัญหาพร้อมกัน แม้ว่าในกระบวนการเรียนรู้จะสามารถให้ผลลัพธ์การเรียนรู้ที่ loss ลดลงในแต่ละรอบการเรียนรู้ แต่เมื่อนำมาใช้งานกับชุดข้อมูลใหม่ที่ไม่เคยเห็นกลับไม่สามารถแสดงผลลัพธ์ที่ดีออกมาได้ สำหรับกรณีที่แยกโครงสร้างการเรียนรู้เชิงลึก 2 โครงสร้างสำหรับการกำจัดสัญญาณรบกวนและการเพิ่มความละเอียดของภาพแยกกัน หากเลือกกำจัดสัญญาณรบกวนออกก่อนการเพิ่มความละเอียดจะได้ผลลัพธ์ที่ดีกว่าการพยายามเพิ่มความละเอียดของภาพก่อนกำจัดสัญญาณรบกวน เนื่องจากการลดสัญญาณรบกวนจะส่งเสริมการเพิ่มคุณลักษณะของวัตถุของภาพถ่าย โดยโครงสร้างการเรียนรู้เชิงลึกจะพยายามเข้าใจคุณลักษณะของวัตถุเพื่อประมาณค่า pixel ที่เหมาะสมเข้าไปเติมค่าที่ควรจะเป็นของลายเส้นของวัตถุในภาพถ่ายนั้นๆ และหากพยายามเพิ่มความละเอียดก่อนกำจัดสัญญาณรบกวน ผลของการมีอยู่ของสัญญาณรบกวนจะทำให้โครงสร้างการเรียนรู้เชิงลึกที่เพิ่มความละเอียดภาพทำการเปลี่ยนแปลงคุณลักษณะของสัญญาณรบกวนไปด้วย เป็นผลให้โครงสร้างการเรียนรู้เชิงลึกที่ทำการกำจัดสัญญาณรบกวนไม่สามารถกำจัดออกไปได้ เนื่องจากสัญญาณรบกวนที่เปลี่ยนแปลงไปนี้ไม่ตรงกับคุณลักษณะของสัญญาณรบกวนที่ได้ทำการเรียนรู้มา

นอกจากนี้การทดลองในส่วนนี้ได้นำเสนอแนวคิดของ NSR2NLR framework เพื่อใช้ประโยชน์ของการลดขนาดภาพในการกำจัดสัญญาณรบกวน พร้อมทั้งแนวคิด self-validation ที่ได้นำเสนอเช่นเดียวกับการทดลองในหัวข้อที่ 2 และยังนำเสนอแนวคิดของการนำ output ที่ได้ฟื้นฟูซ้ำ เพื่อเพิ่มความละเอียด จากการทดลองพบว่าวิธีการที่นำเสนอสามารถใช้ลดสัญญาณรบกวนและเพิ่มความละเอียดของภาพได้ และการนำ output กลับมาฟื้นฟูซ้ำขณะเรียนรู้ก็ยังสามารถเพิ่มประสิทธิภาพของ PSNR ได้ แต่มีข้อจำกัดของจำนวนการทำซ้ำ เนื่องจากผลกระทบของสัญญาณรบกวนที่กำจัดออกไม่หมด จะทำให้สัญญาณรบกวนกลับมาได้อีกหากฟื้นฟูซ้ำหลายๆ ครั้ง ดังนั้น

การกำจัดสัญญาณรบกวนออกจากภาพให้หมดก่อนการเพิ่มความละเอียดของภาพยังคงเป็นงานที่สำคัญอย่างมากต่อการฟื้นฟูภาพถ่ายสำหรับงานที่มีปัญหาของ single image และ blind noise

5.4 สรุปผลการศึกษาวิจัยการฟื้นฟูภาพถ่ายด้วยเทคนิคการเรียนรู้เชิงลึก

งานวิจัยนี้ได้ศึกษาผลกระทบของสัญญาณรบกวนในภาพถ่ายซึ่งส่งผลให้การวิเคราะห์ห่าจผิดพลาดจากการนำภาพที่มีสัญญาณรบกวน ไปใช้งานประมวลผลภาพ โดยงานวิจัยนี้ได้ศึกษาเทคนิคฟื้นฟูภาพถ่ายด้วยเทคนิคการเรียนรู้เชิงลึกซึ่งมีประสิทธิภาพดีกว่าการใช้ filtering-based algorithm เนื่องจากการเรียนรู้เชิงลึกเป็น learning-based ที่สามารถปรับตัวตามข้อมูลที่ใช้ในการเรียนรู้ได้ดีกว่า filtering-based และเนื่องจากปัจจุบัน คอมพิวเตอร์มีประสิทธิภาพในการคำนวณที่สูงขึ้น ทำให้การเรียนรู้เชิงลึกจึงเป็นวิธีที่ได้รับความนิยมเพิ่มขึ้นอย่างมากในหลายแขนง โดยในการทดลองแรกของงานวิจัยนี้ได้นำเสนอ edge-perceptual loss ซึ่งเป็นการเพิ่มคุณลักษณะของขอบวัตถุในภาพเพื่อเพิ่มประสิทธิภาพของการกำจัดสัญญาณรบกวนในการเรียนรู้ของการเรียนรู้เชิงลึก เนื่องจากการเรียนรู้เชิงลึกจะสามารถมีประสิทธิภาพในการทำงานที่หากได้รับการเปรียบเทียบผลลัพธ์ในหลายมิติ นอกเหนือจาก pixel-wise loss เพียงอย่างเดียว โดยผลการทดลองสามารถพิสูจน์ได้ว่าคุณลักษณะของขอบวัตถุในภาพสามารถเพิ่มประสิทธิภาพให้แก่โครงสร้างการเรียนรู้เชิงลึกแบบเดิมได้ และสามารถเอาชนะ โครงสร้าง GANs ซึ่งมักเกิดปัญหา over-fitting ได้ง่าย แต่อย่างไรก็ตาม ปัญหาของการเรียนรู้เชิงลึกมักเป็นการใช้ข้อมูลจำนวนมากในการเรียนรู้ ซึ่งการนำเสนอ edge-perceptual loss ยังไม่สามารถแก้ปัญหาตรงจุดนี้ได้ ด้วยเหตุนี้งานวิจัยนี้จึงได้ศึกษาการแก้ปัญหาของการใช้งานการเรียนรู้เชิงลึกในการกำจัดสัญญาณรบกวนที่มักมีปัญหามาจากการมีข้อมูลสำหรับใช้ในการเรียนรู้ไม่เพียงพอ โดยได้นำเสนอ self-validation Noise2Noise (SV-N2N) framework ซึ่งเป็นการสร้างชุดข้อมูล validation ขึ้นมาเพื่อให้โครงสร้างการเรียนรู้เชิงลึกสามารถเรียนรู้ด้วยตัวเอง และจากผลการทดลอง SV-N2N framework ที่นำเสนอสามารถแก้ปัญหาการใช้ข้อมูลจำนวนมากในการเรียนรู้ของการเรียนรู้เชิงลึก และสามารถต่อยอดในการแก้ปัญหา single image และ blind noise ได้ ถึงแม้ว่าประสิทธิภาพโดยรวมของ SV-N2N ยังต่ำกว่าการเรียนรู้แบบ Noise2Clean ซึ่งเป็นวิธีการเรียนรู้แบบปกติของการเรียนรู้เชิงลึก สำหรับการทดลองสุดท้ายจะเกี่ยวข้องกับปัญหาของภาพถ่ายดิจิทัลที่สามารถถูกรบกวนได้จากทั้งสัญญาณรบกวนและการถูกลดทอนคุณภาพพร้อมกัน โดยงานวิจัยนี้ได้ทำการเปรียบเทียบ 3 framework ของการฟื้นฟูภาพถ่ายดิจิทัล เพื่อศึกษาข้อจำกัดและประเมินปัญหาของแต่ละ framework ที่ได้นำมาทดลอง และลำดับความสำคัญ

ของการฟื้นฟูภาพถ่ายที่ถูกลดทอนคุณภาพและเกิดสัญญาณรบกวน แม้ว่าจากผลการทดลองอาจไม่สามารถฟื้นฟูภาพถ่ายได้ดีเท่าที่ควร เนื่องจากปัญหาการเกิด overfitting ที่มาจากการพยายามให้โครงสร้างการเรียนรู้เชิงลึกทำงานมากกว่า 1 งาน ซึ่งเป็นข้อจำกัดของการทำงานของโครงสร้างการเรียนรู้เชิงลึกที่ยังสามารถเรียนรู้ได้เพียงโดเมนปัญหาเดียวสำหรับ 1 โครงสร้างการเรียนรู้เท่านั้น โดยต่อมงานวิจัยนี้ได้นำเสนอ NLR2NSR เพื่อใช้ประโยชน์จากการลดขนาดภาพ self-validation รวมไปถึงการสามารถละเลยปัญหา overfitting ของการป้อน single image ขณะเรียนรู้ ซึ่งผลการทดลองสามารถให้ผลลัพธ์ที่ดีในการฟื้นฟูภาพถ่าย แม้ว่าสัญญาณรบกวนสำหรับปัญหา single image และ blind noise จะไม่สามารถกำจัดออกได้หมด และอาจเป็นปัญหาของ NLR2NSR ได้ แต่ก็สามารถทำให้ฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากทั้งสัญญาณรบกวน และการลดทอนคุณภาพ ด้วยวิธีการ unsupervised learning จากแนวคิด self-supervised ได้ และงานวิจัยนี้สามารถสรุปผลได้ว่า เมื่อต้องการฟื้นฟูภาพถ่ายที่ได้รับผลกระทบจากทั้งสัญญาณรบกวนและการลดทอนคุณภาพ การเลือกกำจัดสัญญาณรบกวนในภาพก่อนการเพิ่มความละเอียดของภาพจะได้ผลการฟื้นฟูภาพถ่ายที่ดีกว่าการเพิ่มความละเอียดของภาพก่อนการกำจัดสัญญาณรบกวน

บรรณานุกรม

- [1] S. Ghose, N. Singh, and P. Singh, "Image denoising using deep learning: Convolutional neural network," in *2020 10th International Conference on Cloud Computing, Data Science Engineering (Confluence)*, 2020, pp. 511–517.
- [2] S. Minaee, Y. Boykov, F. Porikli, A. Plaza, N. Kehtarnavaz, and D. Terzopoulos, "Image segmentation using deep learning: A survey," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 44, no. 7, pp. 3523–3542, 2022.
- [3] L. Fan, F. Zhang, H. Fan, and C. Zhang, "Brief review of image denoising techniques," *Visual Computing for Industry, Biomedicine, and Art*, vol. 2, no. 1, p. 7, Jul. 2019.
- [4] W. R. Moskola i, W. Abdou, A. Dipanda, and Kolyang, "Application of deep learning architectures for satellite image time series prediction: A review," *Remote Sensing*, vol. 13, no. 23, 2021. [Online]. Available: <https://www.mdpi.com/2072-4292/13/23/4822>
- [5] D. Dhall, R. Kaur, and M. Juneja, "Machine learning: A review of the algorithms and its applications," in *Proceedings of ICRIC 2019*, P. K. Singh, A. K. Kar, Y. Singh, M. H. Kolekar, and S. Tanwar, Eds. Cham: Springer International Publishing, 2020, pp. 47–63.
- [6] M. Motwani, M. Gadiya, R. Motwani, and F. Harris, "Survey of image denoising techniques," 01 2004.
- [7] A. K. Boyat and B. K. Joshi, "A review paper: Noise models in digital image processing," *Signal Image Processing: An International Journal (SIPIJ)*, vol. 6, no. 2, April 2015.
- [8] O. Joshua, T. Ibiyemi, and B. Adu, "A comprehensive review on various types of noise in image processing," *International Journal of Scientific and Engineering Research*, vol. 10, pp. 388–393, 11 2019.

- [9] R. S. Jebur, C. S. Der, and D. A. Hammood, "A review and taxonomy of image denoising techniques," in *2020 6th International Conference on Interactive Digital Media (ICIDM)*, 2020, pp. 1–6.
- [10] A. E. Ilesanmi and T. O. Ilesanmi, "Methods for image denoising using convolutional neural network: a review," *Complex & Intelligent Systems*, vol. 7, no. 5, pp. 2179–2198, Oct. 2021.
- [11] G. Capobianco, C. Cerrone, A. Di Placido, D. Durand, L. Pavone, D. D. Russo, and F. Sebastiano, "Image convolution: a linear programming approach for filters design," *Soft Computing*, vol. 25, no. 14, pp. 8941–8956, Jul 2021. [Online]. Available: <https://doi.org/10.1007/s00500-021-05783-5>
- [12] S. Ghosh and K. N. Chaudhury, "Kernel-based image filtering: Fast algorithms and applications," in *2019 IEEE International Conference on Image Processing (ICIP)*, 2019, pp. 3018–3019.
- [13] I. H. Sarker, "Deep learning: A comprehensive overview on techniques, taxonomy, applications and research directions," *SN Computer Science*, vol. 2, no. 6, pp. 420, Aug 2021. [Online]. Available: <https://doi.org/10.1007/s42979-021-00815-1>
- [14] L. Alzubaidi, J. Zhang, A. J. Humaidi, A. Al-Dujaili, Y. Duan, O. Al-Shamma, J. Santamaria, M. A. Fadhel, M. Al-Amidie, and L. Farhan, "Review of deep learning: concepts, cnn architectures, challenges, applications, future directions," *Journal of Big Data*, vol. 8, no. 1, pp. 53, Mar 2021. [Online]. Available: <https://doi.org/10.1186/s40537-021-00444-8>
- [15] X. V. Wang, J. S. Pinter, Z. Liu, and L. Wang, "A machine learning-based image processing approach for robotic assembly system," *Procedia CIRP*, vol. 104, pp. 906–911, 2021.
- [16] P. P. Shinde and S. Shah, "A Review of Machine Learning and Deep Learning Applications," in *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*, pp. 1-6, 2018. doi: 10.1109/ICCUBEA.2018.8697857.

- [17] A. Limshuebchuey, R. Duangsoithong, and M. Saejia, "Comparison of image denoising using traditional filter and deep learning methods," in *2020 17th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, 2020, pp. 193–196.
- [18] B. Liu and J. Liu, "Overview of image denoising based on deep learning," *Journal of Physics: Conference Series*, vol. 1176, no. 2, p. 022010, mar 2019. [Online]. Available: <https://dx.doi.org/10.1088/1742-6596/1176/2/022010>
- [19] C. Xu, C. Lu, X. Liang, J. Gao, W. Zheng, T. Wang, and S. Yan, "Multi-loss regularized deep neural network," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 26, no. 12, pp. 2273–2283, 2016.
- [20] A. BenTaieb, J. Kawahara, and G. Hamarneh, "Multi-loss convolutional networks for gland analysis in microscopy," in *2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI)*, 2016, pp. 642–645.
- [21] M. Chang, Q. Li, H. Feng, and Z. Xu, "Spatial-adaptive network for single image denoising," in *Computer Vision – ECCV 2020*, A. Vedaldi, H. Bischof, T. Brox, and J.-M. Frahm, Eds. Cham: Springer International Publishing, 2020, pp. 171–187.
- [22] S. Xu, X. Chen, Y. Tang, S. Jiang, X. Cheng, and N. Xiao, "Learning from multiple instances: A two-stage unsupervised image denoising framework based on deep image prior," *Applied Sciences*, vol. 12, no. 21, 2022. [Online]. Available: <https://www.mdpi.com/2076-3417/12/21/10767>.
- [23] W. Yang, X. Zhang, Y. Tian, W. Wang, J. -H. Xue and Q. Liao, "Deep Learning for Single Image Super-Resolution: A Brief Review," in *IEEE Transactions on Multimedia*, vol. 21, no. 12, pp. 3106–3121, Dec. 2019, doi: 10.1109/TMM.2019.2919431.

- [24] K. Raza and N. K. Singh, “A tour of unsupervised deep learning for medical image analysis,” 2018. [Online]. Available: <https://arxiv.org/abs/1812.07715>
- [25] J. Lehtinen, J. Munkberg, J. Hasselgren, S. Laine, T. Karras, M. Aittala, and T. Aila, “Noise2noise: Learning image restoration without clean data,” 2018. [Online]. Available: <https://arxiv.org/abs/1803.04189>.
- [26] D. Martin, C. Fowlkes, D. Tal, and J. Malik, “A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics,” in *Proceedings Eighth IEEE International Conference on Computer Vision. ICCV 2001*, vol. 2, 2001, pp. 416–423 vol.2.
- [27] R. Zeyde, M. Elad, and M. Protter, “On single image scale-up using sparserepresentations,” in *Curves and Surfaces*, J.-D. Boissonnat, P. Chenin, A. Cohen, C. Gout, T. Lyche, M.-L. Mazure, and L. Schumaker, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, pp. 711–730.
- [28] J.-B. Huang, A. Singh, and N. Ahuja, “Single image super-resolution from transformed self-exemplars,” in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, pp. 5197–5206.
- [29] L. Sun and J. Hays, “Super-resolution from internet-scale scene matching,” in *2012 IEEE International Conference on Computational Photography (ICCP)*, 2012, pp. 1–12.
- [30] B. Brummer and C. D. Vleeschouwer, “Natural image noise dataset,” in *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. IEEE, jun 2019.
- [31] A. Abdelhamed, S. Lin, and M. S. Brown, “A high-quality denoising dataset for smartphone cameras,” in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018, pp. 1692–1700.

- [32] Y. Zhang, Y. Zhu, E. Nichols, Q. Wang, S. Zhang, C. Smith, and S. Howard, "A poisson-gaussian denoising dataset with real fluorescence microscopy images," in *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019, pp. 11 702–11 710.
- [33] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770–778.
- [34] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," in *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, N. Navab, J. Hornegger, W. M. Wells, and A. F. Frangi, Eds. Cham: Springer International Publishing, 2015, pp. 234–241.
- [35] C. Ledig, L. Theis, F. Huszar, J. Caballero, A. Cunningham, A. Acosta, A. Aitken, A. Tejani, J. Totz, Z. Wang, and W. Shi, "Photo-realistic single image super-resolution using a generative adversarial network," 2016. [Online]. Available: <https://arxiv.org/abs/1609.04802>
- [36] Y. Quan, M. Chen, T. Pang, and H. Ji, "Self2self with dropout: Learning self-supervised denoising from single image," in *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020, pp. 1887–1895.
- [37] J. Batson and L. Royer, "Noise2self: Blind denoising by self-supervision," 2019. [Online]. Available: <https://arxiv.org/abs/1901.11365>.
- [38] A. Krull, T.-O. Buchholz, and F. Jug, "Noise2void - learning denoising from single noisy images," 2018. [Online]. Available: <https://arxiv.org/abs/1811.10980>.
- [39] T. Pang, H. Zheng, Y. Quan, and H. Ji, "Recorrupted-to-recorrupted: Unsupervised deep learning for image denoising," in *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2021, pp. 2043–2052.
- [40] A. A. Yahya, J. Tan, B. Su, M. Hu, Y. Wang, K. Liu, and A. N. Hadi, "Bm3d image denoising algorithm based on an adaptive filtering," *Multimedia Tools and Applications*, vol. 79, no. 27,

- pp. 20 391–20 427, Jul 2020. [Online]. Available: <https://doi.org/10.1007/s11042-020-08815-8>.
- [41] A. Buades, B. Coll, and J.-M. Morel, “A non-local algorithm for image denoising,” in *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR’05)*, vol. 2, 2005, pp. 60–65 vol. 2.
- [42] D. N. H. Thanh, V. B. S. Prasath, L. M. Hieu, and S. Dvoenko, “An adaptive method for image restoration based on high-order total variation and inverse gradient,” *Signal, Image and Video Processing*, vol. 14, no. 6, pp. 1189–1197, Sep 2020. [Online]. Available: <https://doi.org/10.1007/s11760-020-01657-9>
- [43] N. M. Hue, D. N. H. Thanh, L. T. Thanh, N. Ngoc Hien, and V. B. Surya Prasath, “Image denoising with overlapping group sparsity and second order total variation regularization,” in *2019 6th NAFOSTED Conference on Information and Computer Science (NICS)*, 2019, pp. 370–374.
- [44] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770–778.
- [45] T. Julliand, V. Nozick, and H. Talbot, “Image noise and digital image forensics,” in *Digital-Forensics and Watermarking*, Y.-Q. Shi, H. J. Kim, F. PerezGonzalez, and I. Echizen, Eds. Cham: Springer International Publishing, 2016, pp. 3–17.
- [46] A. Boyat and B. Joshi, “A review paper: Noise models in digital image processing,” *Signal Image Processing: An International Journal*, vol. 6, 05 2015.
- [47] P. Arulpandy and M. Pricilla, “Speckle noise reduction and image segmentation based on a modified mean filter,” *Computer Assisted Methods in Engineering and Science*, vol. 27, no. 4, pp. 221–239, 2020. [Online]. Available: <https://comes.ippt.pan.pl/index.php/comes/article/view/290>

- [48] R. Ren, Z. Guo, Z. Jia, J. Yang, N. K. Kasabov, and C. Li, "Speckle noise removal in image-based detection of refractive index changes in porous silicon microarrays," *Scientific Reports*, vol. 9, no. 1, p. 15001, Oct 2019. [Online]. Available: <https://doi.org/10.1038/s41598-019-51435-y>
- [49] N. He and K. Lu, "Images denoising by improved non-local means algorithm," in *Theoretical and Mathematical Foundations of Computer Science*, Q. Zhou, Ed. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011, pp. 33–39.
- [50] S. Paris, P. Kornprobst, J. Tumblin, and F. Durand, "Bilateral Filtering: Theory and Applications," 2009.
- [51] M. Gabbouj, E. J. Coyle, and N. C. Gallagher, "An overview of median and stack filtering," *Circuits, Systems and Signal Processing*, vol. 11, no. 1, pp. 7–45, Mar 1992. [Online]. Available: <https://doi.org/10.1007/BF01189220>
- [52] Q. Su, Y. Wang, Y. Li, C. Zhang, P. Lang, and X. Fu, "Image denoising based on wavelet transform and bm3d algorithm," in *2019 IEEE 4th International Conference on Signal and Image Processing (ICSIP)*, 2019, pp. 999–1003.
- [53] A. Buades, B. Coll, and J.-M. Morel, "Non-Local Means Denoising," *Image Processing online*, vol. 1, pp. 208–212, 2011.
- [54] L. Navarro and J. Molimard, "Directional Denoising Using Fourier Spectrum Cloning," *Fourier Transforms - Century of Digitalization and Increasing Expectations*, Dec. 2019, doi: 10.5772/intechopen.85519.
- [55] S. Raghay, K. Bnou, and A. Hakim, "A wavelet denoising approach based on unsupervised learning model," *EURASIP Journal on Advances in Signal Processing*, 07 2020.

- [56] S. Gopinathan, K. Radhakrishnan, and T. P., “Wavelet and fft based image denoising using non-linear filters,” *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 5, pp. 1018–1026, 10 2015.
- [57] Y. LeCun, S. Chopra, R. Hadsell, M. Ranzato, and F. J. Huang, “A tutorial on energy-based learning,” in *Predicting Structured Data*, MIT Press, 2006.
- [58] S. Routray, A. Ray, and C. Mishra, “An efficient image denoising method based on principal component analysis with learned patch groups,” *Signal Image and Video Processing*, vol. 13, pp. 1405–1412, 10 2019.
- [59] L. Zhang, W. Dong, D. Zhang, and G. Shi, “Two-stage image denoising by principal component analysis with local pixel grouping,” *Pattern Recognition*, vol. 43, no. 4, pp. 1531–1549, 2010. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0031320309003677>
- [60] A. Osadchiy, A. Kamenev, V. Saharov, and S. Chernyi, “Signal Processing Algorithm Based on Discrete Wavelet Transform,” *Designs*, vol. 5, pp. 41, 07 2021.
- [61] L. Jing-yi, L. Hong, Y. Dong, and Z. Yan-sheng, “A New Wavelet Threshold Function and Denoising Application,” *Mathematical Problems in Engineering*, vol. 2016, pp. 1–8, 2016.
- [62] C. Gambella, B. Ghaddar, and J. Naoum-Sawaya, “Optimization problems for machine learning: A survey,” *European Journal of Operational Research*, vol. 290, no. 3, pp. 807–828, 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S037722172030758X>
- [63] A. T. G. Tapeh and M. Z. Naser, “Artificial intelligence, machine learning, and deep learning in structural engineering: A scientometrics review of trends and best practices,” *Archives of Computational Methods in Engineering*, vol. 30, no. 1, pp. 115–159, Jan 2023. [Online]. Available: <https://doi.org/10.1007/s11831-022-09793-w>

- [64] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of a convolutional neural network," in *2017 International Conference on Engineering and Technology (ICET)*, 2017, pp. 1–6.
- [65] S. Indolia, A. Goswami, S. Mishra, and P. Asopa, "Conceptual understanding of convolutional neural network- a deep learning approach," *Procedia Computer Science*, vol. 132, pp. 679–688, 01 2018.
- [66] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," 2014. [Online]. Available: <https://arxiv.org/abs/1409.1556>.
- [67] A. Krizhevsky, I. Sutskever, and G. Hinton, "Imagenet classification with deep convolutional neural networks," *Neural Information Processing Systems*, vol. 25, 01 2012.
- [68] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," 2016. [Online]. Available: <https://arxiv.org/abs/1608.06993>
- [69] K. Bajaj, D. K. Singh, and M. A. Ansari, "Autoencoders based deep learner for image denoising," *Procedia Computer Science*, vol. 171, pp. 1535–1541, 2020, third International Conference on Computing and Network Communications (CoCoNet'19). [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1877050920311431>
- [70] W. Wang, Y. Huang, Y. Wang, and L. Wang, "Generalized autoencoder: A neural network framework for dimensionality reduction," in *2014 IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2014, pp. 496–503.
- [71] C. Shorten and T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," *Journal of Big Data*, vol. 6, no. 1, p. 60, Jul 2019. [Online]. Available: <https://doi.org/10.1186/s40537-019-0197-0>

- [72] Y. Bai, E. Yang, B. Han, Y. Yang, J. Li, Y. Mao, G. Niu, and T. Liu, "Understanding and improving early stopping for learning with noisy labels," 2021. [Online]. Available: <https://arxiv.org/abs/2106.15853>
- [73] K. Zhang, W. Zuo, Y. Chen, D. Meng, and L. Zhang, "Beyond a gaussian denoiser: Residual learning of deep CNN for image denoising," *IEEE Transactions on Image Processing*, vol. 26, no. 7, pp. 3142–3155, jul 2017.
- [74] Y. Li, K. Zhang, W. Shi, Y. Miao, and Z. Jiang, "A novel medical image denoising method based on conditional generative adversarial network," *Computational and Mathematical Methods in Medicine*, vol. 2021, pp. 1–11, 09 2021.
- [75] S. Guo, Z. Yan, K. Zhang, W. Zuo, and L. Zhang, "Toward convolutional blind denoising of real photographs," 2018. [Online]. Available: <https://arxiv.org/abs/1807.04686>
- [76] S. Lefkimmiatis, "Universal denoising networks: A novel cnn architecture for image denoising," 2017. [Online]. Available: <https://arxiv.org/abs/1711.07807>
- [77] S.-K. Kang, S.-Y. Yie, and J.-S. Lee, "Noise2noise improved by trainable wavelet coefficients for pet denoising," *Electronics*, vol. 10, p. 1529, 06 2021.
- [78] D. Wu, K. Kim, and Q. Li, "Low-dose ct reconstruction with noise2noise network and testing-time fine-tuning," *Medical Physics*, vol. 48, 11 2021.
- [79] A. M. Eskicioglu and P. S. Fisher, "Image quality measures and their performance," in *IEEE Transactions on Communications*, vol. 43, no. 12, pp. 2959-2965, Dec. 1995.
- [80] S. Bhardwaj and A. Mittal, "A Survey on Various Edge Detector Techniques," *Procedia Technology*, vol. 4, pp. 220–226, 2012.

- [81] L. A. Gatys, A. S. Ecker, and M. Bethge, “Image style transfer using convolutional neural networks,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 2414–2423.
- [82] D. Liu, B. Wen, J. Jiao, X.-M. Liu, and Z. Wang, “Connecting image denoising and high-level vision tasks via deep learning,” *IEEE Transactions on Image Processing*, vol. 29, pp. 3695–3706, 12 2020.
- [83] H. Chen, X. He, L. Qing, Y. Wu, C. Ren, R. E. Sheriff, and C. Zhu, “Real-world single image super-resolution: A brief review,” *Information Fusion*, vol. 79, pp. 124–145, 2022. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1566253521001792>
- [84] J. Dong, S. Roth, and B. Schiele, “Deep wiener deconvolution: Wiener meets deep learning for image deblurring,” 2021. [Online]. Available: <https://arxiv.org/abs/2103.09962>
- [85] A. Shocher, N. Cohen, and M. Irani, “Zero-shot super-resolution using deep internal learning,” 06 2018, pp. 3118–3126

ภาคผนวก 1
การตีพิมพ์เผยแพร่ผลงาน

Comparison of Image Denoising using Traditional Filter and Deep Learning Methods

Asavaron Limshuebchuey
 Department of Electrical Engineering,
 Faculty of Engineering
 Prince of Songkla University
 Hat Yai, Songkhla, 90112, Thailand
 Email: 6010130022@email.psu.ac.th

Rakkrit Duangsoithong
 Department of Electrical Engineering,
 Faculty of Engineering
 Prince of Songkla University
 Hat Yai, Songkhla, 90112, Thailand
 Email: rakkrit.d@psu.ac.th

Mongkol Saejia
 Department of Electrical Engineering,
 Faculty of Engineering
 Prince of Songkla University
 Hat Yai, Songkhla, 90112, Thailand
 Email: smongkol@eng.psu.ac.th

Abstract—Image technology often uses in our everyday life. It is useful for many applications such as telecommunication system, automation system in self-driving vehicles, surveillance system and medical research area. However, the image can be interrupted by noise from the environment or electric signal that distorts the detail of the image. In recent years, there had been many image denoising algorithms. Generally, they can be divided into 2 types: traditional filter and deep learning method. This research presents a comparison of the image denoising algorithm using peak signal-to-noise ratio (PSNR) between traditional and deep learning methods on Gaussian noise and Salt and pepper noise condition. Moreover, this experiment also compared the PSNR value of deep learning between noise image to noise image (N2N) learning scheme and noise image to clean image (N2C) learning scheme. According to the results, deep learning method has PSNR value higher than traditional method and N2C learning scheme has PSNR value higher than N2N learning scheme.

Index Terms—Image denoising, Deep learning, Traditional filter, Gaussian noise, Salt and pepper noise

I. INTRODUCTION

Noisy image is a crucial problem of image processing tasks in many applications. It can be occurred by low light condition or electrical signal from device or malfunction of the camera sensor. The problem from noise can take high cost of time and money to re-record a new image. Normally, the image denoising can be divided into 2 types: traditional and deep learning methods.

In traditional image denoising methods [1], [2], [3], they use filter kernel as shown in Fig.1 to convolve the image in order to remove the noise from the image. However, the detail in output image can be degraded.

Recently, the deep learning technique for image denoising shown in Fig.2 has been applied to many applications. Convolution neural networks (CNN) [4] and autoencoder [5] are one of the deep learning methods that can be used to remove the noise in the images [6].

Basically, the deep learning methods for image denoising can be divided into 2 types by learning schemes: noise image to clean image (N2C) learning scheme [7] in Fig.3(A) and noise image to noise image (N2N) learning scheme [8] in Fig.3(B). N2C learning scheme learns the original image from pair of noise images and validated clean images. N2N learning scheme generates noise images to other noise images with the




Fig. 1. Image denoising using traditional method




Fig. 2. Image denoising using deep learning method

same noise distribution and removes noise by averaging input and output images.

The result of each algorithms are compared with peak signal-to-noise ratio (PSNR) and the complexity of each image denoising algorithms.

II. LITERATURE REVIEW

For traditional method, there are many algorithms remove noise by using kernel. In 2005, Buades et al. [1] developed non-local mean filter algorithm for removing the noise that splits the original image as many blocks and uses distance between pixels as the weight to estimate pixel value in the image. In 2006, Dabov et al. proposed block matching 3D [3]. It assumes that the image consists of many blocks that they have same detail. These blocks can group and filter them to remove noise. Bilateral filter [2] was presented by Sylvain et al. in 2009. It considers image into 3 components for filter the noise: normalization factor (mean of pixel of the image), space weight (width of normal distribution of Gaussian) and range weight (range of intensity of pixel in image).

In recent years, computers are more powerful in computation. For image denoising, there are many algorithms that are

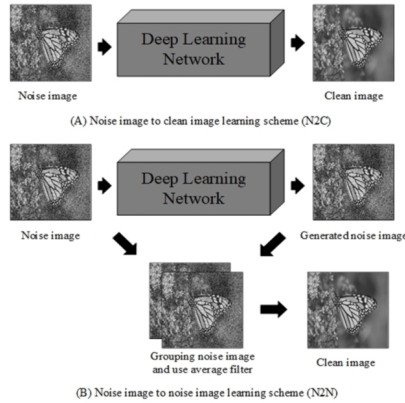


Fig. 3. Comparison of noise to clean image and noise to noise image learning scheme.

developed by using deep learning networks. In 2008, Vincent et al. [5] presented an autoencoder that extracts features by reducing the number of nodes in hidden layers. However, this method not only reduces noise from image but also degrades some detail of images. In generally, deep learning has same problem that is the vanishing gradient problem [10]. It was presented by Glorot and Bengio in 2010. To solve this problem, He et al. proposed ResNet [9] is a CNN with skip connected layer call residual network (ResNet) in 2016. This network is used information from previous layer and current layer of network to feed into next layers. The network was Understood the information of previous layer that can solve vanishing gradient problem and restore the detail of the image. Moreover, a skip connected layer was used in an autoencoder that was presented by Mao et al. [11] in 2016. It provides information by feeding features from previous layer that can protect information loss from reducing features in encoder process.

There is a concept to remove noise that is generating noisy image and removing noise by averaging them. In 2017, Zhang et al. [7] used denoising convolution neural network (DnCNN) to learn characteristic of noise in the image and try to remove them from the image. In 2018, Lehtinen et al. [8] proposed Noise2Noise algorithm that uses information from an input noise image to create a noisy image that has the same noise characteristic. It can remove noise from the image by average input and output images.

III. THEORY

Noise in digital image [12] can occur by the camera sensor that get some noise signal from the electrical noise or light changing from the light sources. This experiment focuses on the Gaussian noise and the Salt and pepper noise.

Gaussian noise can be occurred by adding the Gaussian signal in an image follow in Equation.1. It interrupts image pixels and degrades image quality.

$$y = x + n \quad (1)$$

Where y is the observed image that includes noise. x is the original cleaned image without noise. n is Gaussian noise that interrupts the image pixels.

Salt and pepper noise or impulse noise is the noise that displays maximum (white pixel) and minimum (black pixel) value in the image. When the sensor of the camera gets this noise, The noise will replace value in image pixels.

This research divides denoising algorithms into 2 types as shown in Table. I: traditional method and deep learning method. In traditional method, the experiment uses Non-local mean filter, Bilateral filter and Block matching 3D. For deep learning method, the experiment divides into 2 types of learning scheme: N2N and N2C learning scheme algorithms. For N2N algorithm, the experiment uses DnCNN algorithm to learn noise pattern from noisy image data and N2N algorithm with ResNet (CNN with skip connected) and U-Net (autoencoder with skip connected) to learn noisy image generation. For N2C learning scheme, this experiment also uses ResNet and U-Net [13] by using clean images as validation data for training.

TABLE I
TYPE OF DENOISING ALGORITHM IN THIS EXPERIMENT.

Traditional	Deep learning	
	N2N	N2C
Non-Local mean filter	N2N-ResNet	N2C-ResNet
Bilateral filter	N2N-U-Net	N2C-U-Net
Block Matching 3D	DnCNN	-

A. Traditional method

1) *Non-Local Mean filter* [1]: is developed from mean filter. It divides the image input to sub-images and computes the distance of sub-images as weights Equation.2. Then, these weights be used to evaluate pixel values in the image to remove noise.

$$W(i, j) = e^{-\frac{d^2}{h^2}} \quad (2)$$

Where $W(i, j)$ is the weight of between target pixel and sub-image pixel in the image. d is distance of target pixel and each pixel in the image. h is constant.

2) *Bilateral filter* [2]: uses a Gaussian filter to get filtered image and considers 3 components of the image and filtered image: normalization factor, space weight (G_{σ_s}) and range weight (G_{σ_r}). The noise be removed by using Equation.3.

$$BF[I]_p = \frac{1}{W_p} \sum_{x_i \in S} G_{\sigma_s}(x_i - x) G_{\sigma_r}(I_{x_i} - I_x) \quad (3)$$

Where W_p is normalization factor. x and x_i are center pixels and pixels around the center pixel in filtering kernel. I_x and I_{x_i} are intensity of the original image and filtered image.

3) *Block Matching 3D* [3]: is an algorithm that search nearby sub-image blocks that are similarly. Mean difference (MD) in Equation.4 is used to measure similarity of sub-image blocks. These similar blocks are grouped as the 3D matrix and are filtered to remove noise.

$$MD = \frac{1}{N^2} \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} |C_{ij} - R_{ij}| \quad (4)$$

Where N is number of pixels in searching kernel. C_{ij} and R_{ij} are position of pixel in block C and block R, respectively.

B. Deep learning method

1) *DnCNN* [7]: as shown in Fig.4. It uses convolution neural network to learn the characteristic of noise and can be distinguished the noise pixels and image pixels to remove noise.




Fig. 4. Example of DnCNN network.

2) *Residual CNN* [9]: as shown in Fig.5. It uses skip connected layer that connects previous hidden layer to deeply layer in the network. It can protect the weight value in deep layer from vanishing gradient problem while the network is training.




Fig. 5. Example of ResNet network.

3) *Residual autoencoder* [11], [13]: as shown in Fig.6. It uses skip connected layer in autoencoder to protect the vanishing gradient problem because of lacking information in hidden layer. The problem occurs by decreasing the number of nodes in hidden layer.




Fig. 6. Example of U-Net network.

IV. EXPERIMENTAL SETUP

This experiment uses 2 datasets: Set14 [14] 14 images and BSD300 [15] 100 images on size 128x128 with gray scale levels and add the zero-mean of the Gaussian noise with

$\sigma=25$ and $\sigma=50$ and the Salt and Pepper noise with 25% and 50% of noise replacement to generate noisy image data. The experimental results are evaluated by using peak signal-to-noise ratio (PSNR) [16] Equation.5 in dB unit to compare the original clean images with the output denoising results of traditional methods, N2N and N2C learning schemes.

$$PSNR = 10 \log_{10} \left(\frac{R^2}{MSE} \right) \quad (5)$$

Where R is maximum value of pixel that the experiment use 255 of gray scale. MSE is mean square error of all the pixels in an image.

For N2N learning schemes, this experiment uses Denoising CNN (DnCNN) algorithm [7] and Noise to Noise (N2N) algorithm [8] with ResNet (N2N-RN) 16 layers and with U-net (N2N-UN) 9 layers to learn and remove the noise.

For N2C learning schemes, both of N2N algorithms (N2N-RN and N2N-UN) are applied by changing clean image as validate data instead (N2C-RN and N2C-UN).

V. EXPERIMENTAL RESULT

Table II and III present the result of image denoising for the Gaussian noise condition. Table IV and V show the result of image denoising for the Salt and pepper noise condition. The results show that deep learning algorithm has more PSNR value for noise removing than traditional method.

The Gaussian denoising ($\sigma=25$) results in Table II, the Bilateral filter has the highest PSNR for the traditional method at 22.11dB but less than N2N(UN) and N2C(UN) that have PSNR 30.78dB and 31.14dB, respectively. Gaussian denoising ($\sigma=50$) results in Table III shows the result that BM3D has higher PSNR than other traditional methods at 14.58dB and N2N(RN) and N2C(RN) has PSNR 27.63dB and 27.98dB, respectively.

The Salt and pepper denoising (25% replacement) results in Table IV shows that BM3D has the highest PSNR at 11.48dB for traditional method. N2N(RN) and N2C(RN) are the highest PSNR at 38.70dB and 39.51dB for N2N and N2C, respectively. The Salt and pepper denoising (50% replacement) results in Table V, BM3D has the highest PSNR at 9.77dB. DnCNN and N2C(RN) have higher PSNR than other algorithms at 37.24dB and 31.00dB, respectively.

The result between N2C has higher PSNR than N2N. U-net has higher PSNR removing results than Resnet in N2N. However, both of these networks have similar results for N2C.

VI. DISCUSSION

Form experimental results, traditional methods use filter-based to remove noise from the images. They provide PSNR value lower than deep learning because they degrade some detail of the images. Deep learning methods can learn details of pixels to remove noise and remain more details of the image than traditional method.

Comparison of N2N and N2C learning schemes, N2C algorithm has higher PSNR value than N2N algorithm because N2C algorithm uses clean pixel of images as validation data

TABLE II
THE RESULT OF REMOVING GAUSSIAN NOISE WITH $\sigma=25$ OF EACH ALGORITHM.

Algorithm		Set14	BSD300	Avg	
Traditional filter	BM3D	20.31(0.75)	20.4(0.82)	20.36	
	NLM	20.96(0.77)	20.68(0.63)	20.82	
	Bilateral	22.20(0.54)	22.02(0.43)	22.11	
Deep learning	Noise to noise	DnCNN	28.94(2.22)	28.63(2.37)	28.79
		N2N(RN)	29.66(1.53)	29.65(1.60)	29.66
		N2N(UN)	30.70(1.93)	30.86(2.03)	30.78
	Noise to clean	N2C(RN)	31.26(2.00)	30.93(2.13)	31.10
		N2C(UN)	31.16(1.98)	31.12(2.17)	31.14

TABLE III
THE RESULT OF REMOVING GAUSSIAN NOISE WITH $\sigma=50$ OF EACH ALGORITHM.

Algorithm		Set14	BSD300	Avg	
Traditional filter	BM3D	14.55(0.55)	14.60(0.59)	14.58	
	NLM	6.16(1.97)	7.05(2.13)	6.61	
	Bilateral	6.19(1.93)	7.01(2.09)	6.60	
Deep learning	Noise to noise	DnCNN	25.62(2.14)	25.77(2.41)	25.70
		N2N(RN)	27.62(1.93)	27.64(2.15)	27.63
		N2N(UN)	26.60(1.84)	26.79(1.98)	26.70
	Noise to clean	N2C(RN)	27.99(2.16)	27.96(2.34)	27.98
		N2C(UN)	27.61(2.09)	27.84(2.30)	27.73

TABLE IV
THE RESULT OF REMOVING SALT AND PEPPER NOISE WITH 25% REPLACEMENT OF EACH ALGORITHM.

Algorithm		Set14	BSD300	Avg	
Traditional filter	BM3D	11.45(0.29)	11.5(0.29)	11.48	
	NLM	4.97(1.21)	5.45(1.12)	5.21	
	Bilateral	6.19(1.93)	7.01(2.09)	6.60	
Deep learning	Noise to noise	DnCNN	31.85(10.8)	32.42(10.0)	32.14
		N2N(RN)	38.69(4.44)	38.7(3.78)	38.70
		N2N(UN)	35.41(3.88)	35.82(3.21)	35.62
	Noise to clean	N2C(RN)	39.67(5.08)	39.34(4.15)	39.51
		N2C(UN)	33.85(3.00)	32.10(2.62)	32.98

TABLE V
THE RESULT OF REMOVING SALT AND PEPPER NOISE WITH 50% REPLACEMENT OF EACH ALGORITHM.

Algorithm		Set14	BSD300	Avg	
Traditional filter	BM3D	9.76(0.09)	9.77(0.09)	9.77	
	NLM	4.19(0.72)	4.45(0.61)	4.32	
	Bilateral	6.19(1.92)	7.01(2.09)	6.60	
Deep learning	Noise to noise	DnCNN	31.19(5.31)	31.29(3.78)	31.24
		N2N(RN)	30.18(3.79)	30.37(3.35)	30.28
		N2N(UN)	26.87(2.66)	27.43(2.50)	27.15
	Noise to clean	N2C(RN)	30.96(3.97)	31.04(3.52)	31.00
		N2C(UN)	28.38(3.16)	28.89(2.76)	28.64

that N2C algorithm can observe the correct result of the images and restore pixels correctly. N2N algorithm generates another noise image as validation data. The network learns to transform a noise image to another noise image that has the same characteristic of noise. The problem of N2N occurs when the same pixel position of generated noise images are replaced with another noise. It means that the correct value of the original image may have been lost and the network hardly knows the correct value of the image pixel.

Moreover, the network applied with ResNet has higher

PSNR value than DnCNN and U-net for the Gaussian noise with $\sigma=25$ and $\sigma=50$ and the Salt and pepper noise with 25% replacement because U-net is the autoencoder that decreases number of features in hidden layer that make network are lack of some information. However, DnCNN has high PSNR result than other for the Salt and pepper noise with 50% replacement.

VII. CONCLUSION

This research presents the comparison of image denoising algorithms between traditional filter method and two types of deep learning methods: N2N and N2C algorithms. From the experimental results, deep learning provides higher PSNR for removing the noise from images than traditional method. According to the results, N2C algorithm restores and remains the image details better than N2N algorithm. ResNet architecture has higher PSNR than U-Net architecture. However, deep learning method has high complexity to calculate.

REFERENCES

- [1] A. Buades, B. Coll, and J. Morel, "A non-local algorithm for image denoising," in 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), 2005, vol. 2, pp. 60-65 vol. 2.
- [2] P. Sylvain, K. Pierre, T. Jack, and D. Frédo, Bilateral Filtering: Theory and Applications (Bilateral Filtering: Theory and Applications). now, 2009, p. 1.
- [3] K. Dabov, A. Foi, V. Katkovnik, and K. Egiazarian, "Image denoising with block-matching and 3D filtering," Proceedings of SPIE - The International Society for Optical Engineering, vol. 6064, pp. 354-365, 02/02 2006.
- [4] R. Yamashita, M. Nishio, R. K. G. Do, and K. Togashi, "Convolutional neural networks: an overview and application in radiology," Insights into Imaging, vol. 9, no. 4, pp. 611-629, 2018/08/01 2018.
- [5] P. Vincent, H. Larochelle, Y. Bengio, and P.-A. Manzagol, Extracting and composing robust features with denoising autoencoders. 2008, pp. 1096-1103.
- [6] P.-Y. Liu and E. Lam, Image Reconstruction Using Deep Learning. 2018.
- [7] K. Zhang, W. Zuo, Y. Chen, D. Meng, and L. Zhang, "Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising," IEEE Transactions on Image Processing, vol. 26, no. 7, pp. 3142-3155, 2017.
- [8] J. Lehtinen, J. Munkberg, J. Hasselgren, S. Laine, T. Karras, M. Aittala, and T. Aila, "Noise2Noise: Learning image restoration without clean data," in ICML, pp. 2965-2974, 2018.
- [9] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 770-778.
- [10] X. Glorot and Y. Bengio, "Understanding the difficulty of training deep feedforward neural networks," Journal of Machine Learning Research - Proceedings Track, vol. 9, pp. 249-256, 01/01 2010.
- [11] X.-J. Mao, C. Shen, and Y.-B. Yang, "Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections," presented at the Proceedings of the 30th International Conference on Neural Information Processing Systems, Barcelona, Spain, 2016.
- [12] A. Boyat and B. Joshi, "A Review Paper: Noise Models in Digital Image Processing," Signal Image Processing : An International Journal, vol. 6, 05/13 2015.
- [13] O. Ronneberger, P. Fischer, and T. Brox, U-Net: Convolutional Networks for Biomedical Image Segmentation. 2015, pp. 234-241.
- [14] R. Zeyde, M. Elad, and M. Protter, On Single Image Scale-Up Using Sparse-Representations. 2010, pp. 711-730.
- [15] D. Martin, C. Fowlkes, D. Tal, and J. Malik, A Database of Human Segmented Natural Images and its Application to Evaluating Segmentation Algorithms and Measuring Ecological Statistics. 2001, pp. 416-423 vol.2.
- [16] A. Horé and D. Ziou, "Image Quality Metrics: PSNR vs. SSIM," in 2010 20th International Conference on Pattern Recognition, 2010, pp. 2366-2369.

ภาคผนวก 2

**การทดลองเปรียบเทียบ Peak-Signal-to-Noise ratio ระหว่าง traditional method และ
deep learning method**

ตารางที่ 1 ผลการเปรียบเทียบการกำจัดสัญญาณรบกวนประเภท Gaussian noise $\sigma=25$ ระหว่าง traditional algorithm และ deep learning algorithm

Algorithm		Set14	BSD300	Average	
Traditional	BM3D	20.31 (0.75)	20.40 (0.82)	20.36	
	NLM	20.96 (0.77)	20.68 (0.63)	20.82	
	Bilateral	22.20 (0.54)	22.02 (0.43)	22.11	
Deep learning	N2N	N2N(ResNet)	29.66 (1.53)	29.65 (1.60)	29.66
		N2N(U-net)	30.70 (1.93)	30.86 (2.03)	30.78
	N2C	N2N(ResNet)	31.26 (2.00)	30.93 (2.13)	31.10
		N2N(U-net)	31.16 (1.98)	31.12 (2.17)	31.14

ตารางที่ 2 ผลการเปรียบเทียบการกำจัดสัญญาณรบกวนประเภท Gaussian noise $\sigma=50$ ระหว่าง traditional algorithm และ deep learning algorithm

Algorithm		Set14	BSD300	Average	
Traditional	BM3D	14.55(0.55)	14.60(0.59)	14.58	
	NLM	6.16(1.97)	7.05(2.13)	6.61	
	Bilateral	6.19(1.93)	7.01(2.09)	6.60	
Deep learning	N2N	N2N(ResNet)	27.62(1.93)	27.64(2.15)	27.63
		N2N(U-net)	26.60(1.84)	26.79(1.98)	26.70
	N2C	N2N(ResNet)	27.99(2.16)	27.96(2.34)	27.98
		N2N(U-net)	27.61(2.09)	27.84(2.30)	27.73

ตารางที่ 3 ผลการเปรียบเทียบการกำจัดสัญญาณรบกวนประเภท Impulse noise 25% replacement
ระหว่าง traditional algorithm และ deep learning algorithm

Algorithm		Set14	BSD300	Average	
Traditional	BM3D	11.45 (0.29)	11.50 (0.29)	11.48	
	NLM	4.97 (1.21)	5.45 (1.12)	5.21	
	Bilateral	6.19 (1.93)	7.01 (2.09)	6.60	
Deep learning	N2N	N2N(ResNet)	38.69 (4.44)	38.70 (3.78)	38.70
		N2N(U-net)	35.41 (3.88)	35.82 (3.21)	35.62
	N2C	N2N(ResNet)	39.67 (5.08)	39.34 (4.15)	39.51
		N2N(U-net)	33.85 (3.00)	32.10 (26.2)	32.98

ตารางที่ 4 ผลการเปรียบเทียบการกำจัดสัญญาณรบกวนประเภท Impulse noise 50% replacement
ระหว่าง traditional algorithm และ deep learning algorithm

Algorithm		Set14	BSD300	Average	
Traditional	BM3D	9.76 (0.09)	9.77 (0.09)	9.77	
	NLM	4.19 (0.72)	4.45 (0.61)	4.32	
	Bilateral	6.19 (1.92)	7.01 (2.09)	6.60	
Deep learning	N2N	N2N(ResNet)	30.18 (3.79)	30.37 (3.35)	30.28
		N2N(U-net)	26.87 (2.66)	27.43 (2.50)	27.15
	N2C	N2N(ResNet)	30.95 (3.97)	31.04 (3.52)	31.00
		N2N(U-net)	28.38 (3.16)	28.89 (2.76)	28.64

ประวัติผู้เขียน

ชื่อ สกุล	นายอัครณ ลิ่มสืบเชื้อ		
รหัสประจำตัวนักศึกษา	6010130022		
วุฒิการศึกษา			
	วุฒิ	ชื่อสถาบัน	ปีที่สำเร็จการศึกษา
	วิศวกรรมศาสตรบัณฑิต (วิศวกรรมไฟฟ้า)	มหาวิทยาลัยสงขลานครินทร์	2556
	วิศวกรรมศาสตรมหาบัณฑิต (วิศวกรรมไฟฟ้า)	มหาวิทยาลัยสงขลานครินทร์	2559

ทุนการศึกษา

ทุน โครงการศูนย์การศึกษาสำหรับภูมิภาคอาเซียนตอนล่าง สำหรับนักศึกษาระดับปริญญาเอก
มหาวิทยาลัยสงขลานครินทร์
ทุนอุดหนุนการวิจัยเพื่อวิทยานิพนธ์ บัณฑิตวิทยาลัย มหาวิทยาลัยสงขลานครินทร์

การตีพิมพ์เผยแพร่ผลงาน

A. Limshuebchuey, R. Duangsoithong and M. Saejia, "Comparison of Image Denoising using
Traditional Filter and Deep Learning Methods," *2020 17th International Conference on
Electrical Engineering/Electronics, Computer, Telecommunications and Information
Technology (ECTI-CON)*, 2020, pp. 193-196