

การแบ่งส่วนอวัยวะด้วยโครงข่ายประสาทเทียมแบบ U-Net ของอวัยวะ  
กระเพาะปัสสาวะและกระดูกต้นขาที่มีความเสี่ยงจากรังสีรักษาพร้อมทั้งการ  
สร้างโครงสร้างอวัยวะสามมิติ

ORGAN SEGMENTATION USING U-NET NEURAL NETWORKS OF THE  
BLADDER AND FEMUR ORGANS AT RISK FROM RADIOTHERAPY AND  
THREE-DIMENSIONAL ORGAN RECONSTRUCTION



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรดุษฎีบัณฑิต

สาขาวิชาวิศวกรรมชีวการแพทย์

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2566

KMITL-2023-EN-D-318-149

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ORGAN SEGMENTATION USING U-NET NEURAL NETWORKS OF THE  
BLADDER AND FEMUR ORGANS AT RISK FROM RADIOTHERAPY AND  
THREE-DIMENSIONAL ORGAN RECONSTRUCTION



A THESIS SUBMITTED IN PARTIAL FULFILLMENT  
OF THE REQUIREMENT FOR THE DEGREE OF  
DOCTOR OF ENGINEERING IN BIOMEDECAL ENGINEERING  
SCHOOL OF ENGINEERING  
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG  
2023  
KMITL-2023-EN-D-318-149

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



**COPYRIGHT 2023**

**SCHOOL OF ENGINEERING**

**KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG**

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

|                                    |  |
|------------------------------------|--|
| หัวข้อวิทยานิพนธ์                  | การแบ่งส่วนอวัยวะด้วยโครงข่ายประสาทเทียมแบบ U-Net ของอวัยวะกระเพาะปัสสาวะและกระดุกต้นขาที่มีความเสี่ยงจากรังสีรักษาพร้อมทั้งการสร้างโครงสร้างอวัยวะสามมิติ |
| นักศึกษา                           | นางสาวกมลฉัตร อภิวัฒน์กุล  |
| รหัสนักศึกษา                       | 63601005   |
| ปริญญา                             | วิศวกรรมศาสตรดุษฎีบัณฑิต   |
| สาขาวิชา                           | วิศวกรรมชีวการแพทย์  |
| พ.ศ.                               | 2566   |
| อาจารย์ที่ปรึกษาวิทยานิพนธ์        | รศ.ดร.ภัทรพงษ์ ผาสุขกิจ  |
| อาจารย์ที่ปรึกษาวิทยานิพนธ์ (ร่วม) | รศ.นพ.พิทยา คำนกุลชัย  |

### บทคัดย่อ

วิทยานิพนธ์ฉบับนี้ จัดทำขึ้นเพื่อศึกษาวิจัยเกี่ยวกับการแบ่งส่วนกระเพาะปัสสาวะและกระดุกต้นขาข้างซ้ายที่เป็นอวัยวะที่มีความเสี่ยงจากรังสีรักษาด้วยการเรียนรู้เชิงลึกพร้อมทั้งนำผลที่ได้มาสร้างแบบจำลองโครงสร้างสามมิติ การทดลองมีทั้งหมด 8 กรณี ประกอบด้วย การทดลองของกระเพาะปัสสาวะ 3 กรณี และการทดลองของกระดุกต้นขาข้างซ้าย 5 กรณี โดยแต่ละกรณีมีขั้นตอนการเตรียมชุดข้อมูลล่วงหน้าแตกต่างกัน จากผลการทดลองพบว่าชุดข้อมูลกระเพาะปัสสาวะที่ผ่านการดำเนินการด้วยเทคนิควินโดวส์เลเวลลิง เทคนิคฮิสโตแกรมอีควอไลเซชัน การทำให้เรียบด้วยเกาส์เซียน และการครีออป ให้ผลลัพธ์การฝึกฝนแบบจำลองเรียนรู้เชิงลึกที่มีประสิทธิภาพสูงสุดด้วยค่าสัมประสิทธิ์ความคล้ายคลึงไดซ์ (Dice Similarity Coefficient: DSC) เท่ากับ 95.15% และค่าจุดตัดเหนือยูเนียน (Intersection over Union: IoU) เท่ากับ 91.10% ในขณะที่ชุดข้อมูลกระดุกต้นขาข้างซ้ายที่ผ่านการดำเนินการด้วยวินโดวส์เลเวลลิง การครีออป และเสริมคุณลักษณะ (ท่านอนของคนไข้) ด้วยค่าสัมประสิทธิ์คุณลักษณะเท่ากับ 5 แทนท่านอนหงาย และเท่ากับ 10 แทนท่านอนคว่ำ ให้ค่า DSC และ IoU สูงสุดเท่ากับ 88.25% และ 80.85% ซึ่งผลการประเมินความคล้ายคลึงของโครงสร้างสามมิติก็ได้ค่าสูงสุดเช่นกันด้วยค่าสเปกตรัม แองเกอ์ แมปเปอร์ (Spectral Angle Mapper) และหน่วยวัดดัชนีความคล้ายคลึงกันของโครงสร้าง (Structural Similarity Index Measure) ในช่วง 0.076 – 0.160 และ 0.698 – 0.839 สำหรับกระเพาะปัสสาวะ กับ 0.117 – 0.215 และ 0.701 – 0.732 สำหรับกระดุกต้นขาข้างซ้าย และผลการวัดระยะห่างเฮาส์ดอร์ฟของแบบจำลองของกระเพาะปัสสาวะมีส่วนขาดหายไปสูงสุด 3.36 มิลลิเมตร และส่วนที่เกิน 1.40 มิลลิเมตร ส่วนแบบจำลองของกระดุกต้นขาข้างซ้ายขาดหายไปสูงสุด 5.91 มิลลิเมตร และส่วนที่เกิน 1.72 มิลลิเมตรเท่านั้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

|                          |   |
|--------------------------|---|
| <b>Thesis</b>            | Organ Segmentation using U-Net Neural Networks of the Bladder and Femur Organs at Risk from Radiotherapy and Three-Dimensional Organ Reconstruction |
| <b>Student</b>           | Miss. Kamonchat Apivanichkul  |
| <b>Student ID</b>        | 63601005  |
| <b>Degree</b>            | Doctor of Engineering   |
| <b>Program</b>           | Biomedical Engineering  |
| <b>Year</b>              | 2023  |
| <b>Thesis Advisor</b>    | Assoc. Prof. Dr. Pattarapong Phasukkit  |
| <b>Thesis Co-advisor</b> | Assoc. Prof. Pittaya Dankulchai   |

## ABSTRACT

This thesis focuses on researching deep learning-based segmentation of bladder and left femur, which are organs at risk in radiotherapy, coupled with 3D model structure reconstruction. This research investigates the bladder and left femur as target organs through 8 experiments: 3 involving the bladder and 5 involving the left femur, each with distinct preprocessing for individual cases. In the bladder experiment, the segmentation model achieved the highest Dice Similarity Coefficient (95.15%) and Intersection over Union (91.10%) using a dataset with preprocessing including window leveling, histogram equalization, Gaussian smoothing, and cropping. For the left femur case, the segmentation model yielded the highest DSC of 88.25% and IoU of 80.85% with a dataset employing window leveling, cropping, and attribute augmentation (patient positioning during CT scanning) using feature coefficients (5 for supine position and 10 for prone position). The predicted 3D reconstruction images in both cases exhibit the highest similarity scores using spectral angle mapper (SAM) and structural similarity index measure (SSIM): 0.076 – 0.160 and 0.698 – 0.839 for the bladder, and 0.117 – 0.215 and 0.701 – 0.732 for the left femur. Additionally, the 3D bladder model's assessment via Hausdorff distance indicates a maximum missing part distance of 3.36 mm and a maximum excess part of 1.40 mm. Similarly, the 3D left femur model shows a maximum missing part distance of 5.91 mm and a maximum excess part of 1.72 mm.

## กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ดีด้วยความอนุเคราะห์จากอาจารย์ที่ปรึกษา รศ.ดร.ภัทรพงษ์ ผาสุขกิจ ให้ความช่วยเหลือ เสนอแนะแนวทางและคำชี้แนะช่วยแก้ไขปัญหาเกี่ยวกับการทำวิจัย แนะนำผู้เชี่ยวชาญให้คำปรึกษาด้านต่าง ๆ ตลอดจนการวางแผนงานต่าง ๆ ให้อย่างเป็นขั้นตอน ความเป็นห่วงเป็นใยในการทำวิทยานิพนธ์ฉบับนี้ อีกทั้งมอบความรู้ โอกาสและประสบการณ์ที่ดีแก่ข้าพเจ้า ผู้ทำวิจัยรู้สึกซาบซึ้งในความอนุเคราะห์จากท่านและขอกราบขอบพระคุณเป็นอย่างสูง

ขอขอบคุณ รุ่นพี่รุ่นน้องใน Burn Lab ที่คอยช่วยเหลือ สนับสนุน และให้กำลังใจมาโดยตลอด รวมทั้งเอื้ออำนวยในหลาย ๆ อย่างที่เป็นประโยชน์อย่างยิ่งสำหรับงานวิจัย

ขอขอบคุณคณะกรรมการสอบทุกท่านที่กรุณาแนะนำและชี้แนะแนวทาง

ขอขอบพระคุณนางลัดดาวัลย์ อภิวัฒน์ชัชกุล ผู้เป็นมารดาของข้าพเจ้า และนายพัฒนะ อภิวัฒน์ชัชกุล ผู้เป็นบิดา และครอบครัวที่คอยอยู่เคียงข้าง ให้การสนับสนุนและกำลังใจตลอดมา

ผู้วิจัยหวังเป็นอย่างยิ่งว่างานวิจัยฉบับนี้จะสามารถเป็นประโยชน์แก่ผู้สนใจศึกษา เกิดการเรียนรู้และแนวคิด ตลอดจนการนำไปประยุกต์ใช้ต่อยอดเพื่อให้เกิดการพัฒนานวัตกรรมและเทคโนโลยีสำหรับการแบ่งส่วนบนภาพถ่ายทางการแพทย์มากยิ่งขึ้น

กมลฉัตร อภิวัฒน์ชัชกุล

# สารบัญ

|   | หน้า |
|---|------|
| บทคัดย่อภาษาไทย.....  | I    |
| บทคัดย่อภาษาอังกฤษ.....   | II   |
| กิตติกรรมประกาศ.....  | III  |
| สารบัญ.....   | IV   |
| สารบัญตาราง.....  | VII  |
| สารบัญรูป.....  | VIII |
| <br>  |      |
| บทที่ 1 บทนำ.....   | 1    |
| 1.1 ความเป็นมาและความสำคัญของปัญหา.....   | 1    |
| 1.2 วัตถุประสงค์ของการวิจัย.....  | 2    |
| 1.3 สมมติฐานของการวิจัย.....  | 2    |
| 1.4 ขอบเขตของการวิจัย.....  | 2    |
| 1.5 ขั้นตอนการดำเนินงานวิจัย.....   | 2    |
| บทที่ 2 หลักการและทฤษฎีที่เกี่ยวข้อง.....   | 4    |
| 2.1 ภาพถ่ายเอกซเรย์คอมพิวเตอร์ (X-ray Computed Tomography Image: CT-Scan) ...         | 4    |
| 2.1.1 พื้นฐานของการถ่ายภาพเอกซเรย์คอมพิวเตอร์ (Principle of Computed Tomography)..... | 5    |
| 2.1.2 การสร้างภาพใหม่ (Image Reconstruction) และการประมวลผล (Processing)....          | 14   |
| 2.1.3 คุณภาพของภาพซีที (CT Image Quality).....  | 23   |
| 2.1.4 ความสัมพันธ์เชิงระนาบของภาพเอกซเรย์คอมพิวเตอร์.....                             | 26   |
| 2.1.5 โครงสร้างของแฟ้มข้อมูลภาพถ่ายเอกซเรย์คอมพิวเตอร์.....                           | 29   |
| 2.2 การแบ่งส่วนรูปภาพทางการแพทย์ (Medical Image Segmentation).....                    | 30   |
| 2.2.1 การแบ่งส่วนแบบแมนนวล (Manual Segmentation).....                                 | 31   |
| 2.2.2 การแบ่งส่วนแบบกึ่งอัตโนมัติ (Semi-automatic Segmentation).....                  | 31   |
| 2.2.3 การแบ่งส่วนแบบอัตโนมัติ (Automatic Segmentation).....                           | 37   |
| 2.3 กระบวนการประมวลผลภาพ (Image Processing).....                                      | 38   |
| 2.3.1 เทคนิคฮิสโตแกรมอีควอลไลเซชัน (Histogram equalization).....                      | 38   |
| 2.3.2 การปรับให้เรียบด้วยเกาส์เซียน (Gaussian smoothing).....                         | 41   |
| 2.3.3 วินโดวส์เลเวลลิง (Window Leveling).....   | 42   |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# สารบัญ (ต่อ)

หน้า

|         |  |    |
|---------|--|----|
| 2.3.4   | คณิตสัณฐานวิทยา (Mathematical Morphology).....   | 44 |
| 2.3.5   | วิธีการฉายฮิสโตแกรม (Histogram Projection).....  | 47 |
| 2.4     | การเรียนรู้เชิงลึก (Deep Learning) โครงข่ายประสาทเทียมแบบสังวัตนาการ<br>(Convolution Neural Network: CNN) และโครงสร้าง U-Net (U-Net Architecture)..... | 49 |
| 2.4.1   | การเรียนรู้เชิงลึก (Deep Learning).....  | 49 |
| 2.4.2   | โครงข่ายประสาทแบบสังวัตนาการ (Convolution Neural Network: CNN).....  | 67 |
| 2.4.3   | โครงข่ายประสาทแบบ U-Net.....   | 71 |
| 2.5     | การสร้างแบบจำลองสามมิติ (3D Model Reconstruction) และวิธีการการประเมินความ<br>เหมือน (Similarity Evaluation Metrics).....                              | 74 |
| 2.5.1   | ขั้นตอนวิธีการต่อกันของลูกบาศก์ (Marching cubes algorithm).....  | 74 |
| 2.5.2   | เทคนิคทำให้เมชเรียบด้วยลาปลาเซียน (Mesh smoothing technique: Laplacian<br>smoothing).....  | 77 |
| 2.6     | วิธีการการประเมิน (Evaluation metrics).....  | 78 |
| 2.6.1   | คะแนน F1 (F1-score).....   | 78 |
| 2.6.2   | ค่าสัมประสิทธิ์ความคล้ายคลึงไดซ์ (Dice Similarity Coefficient: DSC) และจุดตัด<br>เหนือยูเนียน (Intersection over Union: IoU).....                      | 80 |
| 2.6.3   | สเปกตรัม แองเกอร์ แมปเปอร์ (Spectral Angle Mapper: SAM).....   | 81 |
| 2.6.4   | หน่วยวัดดัชนีความคล้ายคลึงกันของโครงสร้าง (Structural Similarity Index<br>Measure: SSIM).....  | 82 |
| 2.6.5   | ระยะพื้นผิว (Surface Distance).....  | 83 |
| 2.7     | ทบทวนวรรณกรรม.....   | 84 |
| บทที่ 3 | ระเบียบวิธีวิจัย.....  | 87 |
| 3.1     | กลุ่มตัวอย่างในการศึกษาวิจัย.....  | 87 |
| 3.2     | ระบบซอฟต์แวร์เพื่อเตรียมชุดข้อมูลเอกซเรย์คอมพิวเตอร์.....  | 87 |
| 3.3     | ขั้นตอนการเตรียมชุดข้อมูลล่วงหน้า (Preprocessing) สำหรับการฝึกฝน.....  | 89 |
| 3.3.1   | ขั้นตอนปรับปรุงคุณภาพของภาพเอกซเรย์คอมพิวเตอร์.....  | 89 |
| 3.3.2   | การแบ่งชุดข้อมูลเอกซเรย์คอมพิวเตอร์.....   | 96 |

## สารบัญ (ต่อ)

หน้า

|   |     |
|---|-----|
| 3.4 ระบบซอฟต์แวร์เพื่อการสร้างและทดลองแบบจำลองระบบการเรียนรู้เชิงลึกสำหรับการแบ่งส่วนอวัยวะ.....  | 96  |
| 3.5 การประเมินผลการทดลอง .....  | 99  |
| 3.5.1 การประเมินประสิทธิภาพการทำงานของโมเดลระบบการเรียนรู้เชิงลึก.....  | 99  |
| 3.5.2 การประเมินโครงสร้างอวัยวะสามมิติ .....  | 100 |
| บทที่ 4 ผลการวิเคราะห์ข้อมูล .....  | 101 |
| 4.1 การประเมินประสิทธิภาพการแบ่งส่วนอวัยวะของแบบจำลองเรียนรู้เชิงลึก .....  | 101 |
| 4.1.1 แบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะ .....  | 101 |
| 4.1.2 แบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดุกต้นขาข้างซ้าย ....  | 106 |
| 4.2 การประเมินแบบจำลองโครงสร้างอวัยวะสามมิติ .....  | 113 |
| 4.3 ระยะเวลาพื้นผิว .....   | 120 |
| บทที่ 5 สรุปผลการวิจัย และข้อเสนอแนะ.....   | 126 |
| 5.1 สรุปผลการวิจัย .....  | 126 |
| 5.1.1 สรุปผลการศึกษาระบบการประมวลผลภาพ ระบบการเรียนรู้เชิงลึก และโครงสร้าง<br>โครงข่ายมาประยุกต์ใช้เพื่อสร้างขั้นตอนวิธีสำหรับแบ่งส่วนอวัยวะที่มีความเสี่ยงจากรังสีรักษา<br>..... | 126 |
| 5.1.2 สรุปผลการพัฒนาขั้นตอนวิธีสำหรับการแบ่งส่วนอวัยวะที่มีความเสี่ยงจากรังสีด้วย<br>ระบบการเรียนรู้เชิงลึก.....  | 126 |
| 5.1.3 สรุปผลเสนอแนวทางการเพิ่มประสิทธิภาพให้กับโครงข่ายประสาทเทียมสำหรับแบ่ง<br>ส่วนอวัยวะที่มีความเสี่ยงจากรังสีรักษา .....  | 127 |
| 5.1.4 สรุปผลการนำผลการแบ่งส่วนที่ได้มาสร้างเป็นแบบจำลองโครงสร้างสามมิติ.....  | 127 |
| 5.2 ข้อเสนอแนะ .....  | 128 |
| เอกสารอ้างอิง .....   | 130 |
| ประวัติผู้เขียน .....   | 139 |

# สารบัญตาราง

| ตารางที่   | หน้า |
|--|------|
| ตารางที่ 2.1 ค่าหน่วยเฮาส์ฟิลด์และช่วงค่าทั่วไปของเนื้อเยื่อและองค์ประกอบอื่น ๆ .....  | 10   |
| ตารางที่ 2.2 ฟังก์ชันกระตุ้นที่นิยมใช้กับโครงข่ายประสาท .....  | 56   |
| ตารางที่ 3.1 พารามิเตอร์ที่กำหนดในขั้นตอนการถ่ายภาพเอกซเรย์คอมพิวเตอร์ของคนไข้ .....   | 87   |
| ตารางที่ 3.2 ไฮเปอร์พารามิเตอร์ในขั้นตอนการฝึกฝนแบบจำลองโครงข่ายประสาทเทียมแบบ U-Net .....   | 98   |
| ตารางที่ 4.1 ผลการประเมินประสิทธิภาพแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะ .....   | 102  |
| ตารางที่ 4.2 ผลการประเมินประสิทธิภาพแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกต้นขาข้างซ้าย .....  | 107  |
| ตารางที่ 4.3 ผลการประเมินความคล้ายคลึงระหว่างแบบจำลองโครงสร้างสามมิติของกระเพาะปัสสาวะด้วยตัววัดสเปกตรัม แองเกอร์ แมปเปอร์ (SAM) หน่วยวัดดัชนีความคล้ายคลึงกันของโครงสร้าง (SSIM) .....      | 114  |
| ตารางที่ 4.4 ผลการประเมินความคล้ายคลึงระหว่างแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้ายด้วยตัววัดสเปกตรัม แองเกอร์ แมปเปอร์ (SAM) หน่วยวัดดัชนีความคล้ายคลึงกันของโครงสร้าง (SSIM) ..... | 115  |
| ตารางที่ 4.5 ระยะห่างเฮาส์ดอร์ฟระหว่างแบบจำลองโครงสร้างสามมิติของผลลัพธ์ที่ได้จากแบบจำลองเชิงลึกกับผลลัพธ์ตามความเป็นจริง .....  | 121  |

# สารบัญรูป

| รูปที่   | หน้า |
|--|------|
| รูปที่ 2.1 การสร้างรังสีเอกซเรย์ (ก) ท่อเอกซเรย์ (ข) ภาพถ่ายเอกซเรย์ทรวงอก.....  | 5    |
| รูปที่ 2.2 แผนผังอุปกรณ์ตรวจจับของการเอกซเรย์คอมพิวเตอร์แบบทั่วไปซึ่งติดตั้งแถวตรวจจับ 320 แถว ที่มีความหนาของแต่ละหน่วยของอุปกรณ์ตรวจจับ 0.5 มิลลิเมตร ที่ไอโซเซ็นเตอร์ (Isocenter) และแต่ละแถวถูกแบ่งออกเป็น 896 ชั้น.....   | 6    |
| รูปที่ 2.3 การสังเคราะห์ภาพเอกซเรย์คอมพิวเตอร์แสดงให้เห็นการส่งผ่านของรังสีเอกซ์ผ่านร่างกายคนไข้โดย (ก) ใช้แถวอุปกรณ์ตรวจจับรองรับ 800-900 เอเลเมนต์ (ข) การหมุนของหลอดรังสีเอกซ์และอุปกรณ์ตรวจจับ และ (ค) อุปกรณ์ตรวจจับมีจำนวนมากในรูปแสดง $\times$ แถวอุปกรณ์ตรวจจับ..... | 7    |
| รูปที่ 2.4 แสดงแผนผังของชิ้นส่วนทางกายวิภาค (ซ้าย) และการแสดงภาพที่สอดคล้องกัน (ขวา) ซึ่งแสดงวอเคลเซลและพิกเซลทั่วไปในการถ่ายภาพเอกซเรย์คอมพิวเตอร์.....   | 7    |
| รูปที่ 2.5 แผนผังการรับปริมาณรังสีส่งผ่านร่างกายตามกฎของเบียร์.....  | 8    |
| รูปที่ 2.6 พื้นฐานของการลดทอนลำรังสีเอกซ์ในเมทริกซ์ $4 \times 4$ แต่ละเอเลเมนต์ในเมทริกซ์สามารถมีค่าสัมประสิทธิ์การลดทอนต่างกัน.....   | 9    |
| รูปที่ 2.7 ความละเอียดของระดับเฉดสีเทาตามความลึกบิต.....   | 11   |
| รูปที่ 2.8 แสดงการครอบคลุมที่เพิ่มขึ้นของเครื่องเอกซเรย์คอมพิวเตอร์ความเร็วสูงเมื่อมีแถวอุปกรณ์ตรวจจับชนิดแอคทีฟมากขึ้น.....   | 13   |
| รูปที่ 2.9 โครงสร้างของแถวและองค์ประกอบของอุปกรณ์ตรวจจับแบบ 16 แถว.....  | 14   |
| รูปที่ 2.10 (ก) ฉายรังสีในมุมที่ $0$ องศา $90$ องศา และ $180$ องศา และ (ข) โซโนแกรมผลลัพธ์.....  | 15   |
| รูปที่ 2.11 ความเข้มรังสีส่งผ่านตัวกลางที่มีค่าสัมประสิทธิ์ลดทอนที่แตกต่างกัน.....   | 15   |
| รูปที่ 2.12 แสดงการสร้างขึ้นใหม่ด้วยการฉายย้อนกลับ.....  | 16   |
| รูปที่ 2.13 แสดงผลการฉายภาพย้อนกลับแบบมีตัวกรองอย่างต่อเนื่องเพื่อสร้างโดเมนปริภูมิที่ดีขึ้นใหม่และการฉายภาพย้อนกลับแบบมีตัวกรองในมุมต่าง ๆ จำนวน 1, 2, 4, 8, 16, 32, 64, 256 และ 1024 ครั้ง.....  | 18   |
| รูปที่ 2.14 แสดงโซโนแกรมของวัตถุจำลองซึ่งถูกสร้างขึ้นโดยการคำนวณการแปลงเรดอน ผลลัพธ์ถูกสร้างขึ้นใหม่โดยใช้การฉายย้อนกลับและขั้นตอนวิธีการฉายย้อนกลับแบบกรอง.....   | 18   |
| รูปที่ 2.15 ลักษณะทางเรขาคณิตของการสร้างปริมาณรังสีส่งผ่าน พิกัดคาร์ทีเซียน $(x, y)$ ใช้กับปริภูมิภาพ $f$ พิกัดที่ใช้กับการฉายภาพ $p$ คือ $t$ ซึ่งเป็นระยะทางจากรังสีเอกซ์ที่ฉายไปยังจุดไอโซเซ็นเตอร์ และ $\theta$ คือ มุมการฉายภาพ.....                                     | 19   |

## สารบัญรูป (ต่อ)

| รูปที่   | หน้า |
|--|------|
| รูปที่ 2.16 การสแกน CT ให้การสุมตัวอย่างแบบกระจายอย่างสม่ำเสมอในพิกัดเชิงขั้วของปริภูมิ พูเรียร์ 2 มิติ การแปลงเป็นการสุมแบบกระจายปกติในพิกัดคาร์ทีเซียนนั้นซับซ้อน โดยเฉพาะอย่างยิ่งที่ความถี่สูง (ห่างจากจุดกำเนิด) .....  | 20   |
| รูปที่ 2.17 การสร้างใหม่แบบวนซ้ำ (ก) ขั้นตอนวิธี ART สำหรับ 4 พิกเซล (ข) การวัดการลดทอน (ค) การประมาณเริ่มต้นสร้างขึ้นโดยการแบ่งการวัดจากมุมมองแรกเท่า ๆ กันตามเส้นทางรังสี (ง-ฉ) ค่าประมาณนี้ได้รับการปรับซ้ำเพื่อให้ตรงกับค่าที่วัดได้ในแต่ละมุมมองที่ต่อเนื่องกันโดยจะหยุดปรับค่าเมื่อค่าวัดการส่งผ่านที่คาดการณ์โดยค่าประมาณปัจจุบันนั้น ตรงกับค่าวัดจริงทั้งหมดภายในขอบเขตที่ตั้งไว้ล่วงหน้า .....  | 22   |
| รูปที่ 2.18 เปรียบเทียบผลกระทบของการตั้งกระแสไฟฟ้า (ก) กระแสไฟฟ้าได้ภาพที่มีสัญญาณรบกวนมาก และ (ข) กระแสไฟฟ้าสูงได้ภาพที่มีสัญญาณรบกวนน้อย .....   | 24   |
| รูปที่ 2.19 เปรียบเทียบผลกระทบกรณีกำหนดค่าความหนาของสไลด์ (ก) ความหนาน้อยมีความละเอียดเชิงพื้นที่สูง แต่สัญญาณรบกวนสูง และ (ข) ความหนามากมีความละเอียดเชิงพื้นที่น้อย และสัญญาณรบกวนน้อย .....   | 25   |
| รูปที่ 2.20 การกำหนดค่าความหนาสไลด์กับระยะห่างระหว่างกึ่งกลางสไลด์ (ก) ตั้งให้เท่ากัน (ข) ตั้งความหนาน้อยกว่า และ (ค) ตั้งความหนามากกว่า .....   | 25   |
| รูปที่ 2.21 ตัวอย่างผลลัพธ์การตั้งค่า FOV (ก) 40 เซนติเมตร และ (ข) 8 เซนติเมตร .....   | 26   |
| รูปที่ 2.22 ความสัมพันธ์เชิงพิกัดระหว่างสามระนาบของภาพถ่ายเอกซเรย์คอมพิวเตอร์ (ก) ตัวอย่างการวางตำแหน่งภาพสไลด์บนทั้งสามระนาบซึ่งทุกส่วนสามารถเชื่อมต่อกันได้พอดี (ข) ภาพสไลด์บนระนาบในแนวตั้งแบ่งซ้ายขวา (ค) ภาพสไลด์บนระนาบตามแกน (ง) ภาพสไลด์บนระนาบแบ่งหน้าหลัง .....  | 27   |
| รูปที่ 2.23 (ก) ค่าพิกัดตามแกน $x$ ของระนาบตามแกนเทียบเท่ากับค่าพิกัดตามแกน $x$ ในระนาบแบ่งหน้าหลัง (ข) ค่าพิกัดตามแกน $x$ ของระนาบตามแกนเทียบเท่ากับลำดับสไลด์ในระนาบในแนวตั้งแบ่งซ้ายขวา (ค) ค่าพิกัดแกน $y$ ของระนาบตามแกนเทียบเท่ากับค่าพิกัดแกน $x$ ในระนาบในแนวตั้งแบ่งซ้ายขวา (ง) ค่าพิกัดแกน $y$ ของระนาบตามแกนเทียบเท่ากับลำดับสไลด์ในระนาบแบ่งหน้าหลัง และ (จ) ค่าพิกัดแกน $y$ ของระนาบในแนวตั้งแบ่งซ้ายขวาและระนาบแบ่งหน้าหลังเทียบเท่ากับลำดับสไลด์ในระนาบตามแกน ..... | 28   |
| รูปที่ 2.24 ผังการแปลงนามสกุลไฟล์และลักษณะไฟล์ข้อมูลของ DICOM กับ NifTi .....  | 30   |
| รูปที่ 2.25 การแบ่งส่วนด้วยเทคนิคตั้งระดับเกณฑ์ (Threshold=0.4) .....  | 32   |
| รูปที่ 2.26 แสดงการดำเนินการของเทคนิคการเติบโตของพื้นที่ (ก) จุดเริ่มต้นของการเติบโตของพื้นที่ (ข) การเติบโตพื้นที่หลังจากผ่านไปหลายรอบ .....  | 33   |

## สารบัญรูป (ต่อ)

| รูปที่  | หน้า |
|---|------|
| รูปที่ 2.27 แสดงการรวมและการแยกพื้นที่ (ก) เริ่มด้วยการตั้งภาพทั้งหมดเป็นพื้นที่เดียว (ข) แบ่งครั้งแรกเป็นสี่ส่วน (ค) แบ่งครั้งที่สอง (ง) รวมพื้นที่ที่มีความเป็นเนื้อเดียวกัน .....  | 34   |
| รูปที่ 2.28 ผลการตรวจจับขอบของตัวดำเนินการที่แตกต่างกัน (ก) ดั้งเดิม (ข) โซเปซ X (ค) โซเปซ Y (ง) โซเบล (จ) เคิร์สซ (ฉ) โรเบิร์ตซ (ช) แคนนี่ (ซ) ลาปลาเซียน .....  | 36   |
| รูปที่ 2.29 การแบ่งส่วนภาพสมองเอ็มอาร์ (ก) ภาพปกติ (ข) การแบ่งส่วนโดยใช้ขั้นตอนวิธี K-means .....   | 37   |
| รูปที่ 2.30 แผนผังกระบวนการของเทคนิคฮิสโทแกรมอีควอไลเซชัน .....   | 39   |
| รูปที่ 2.31 แสดงภาพสไลด์ซีทีของพื้นที่บริเวณกระเพาะปัสสาวะ (ก) ก่อนปรับปรุงความเปรียบต่างด้วยเทคนิคฮิสโทแกรมอีควอไลเซชัน และ (ข) หลังปรับปรุงความเปรียบต่างด้วยเทคนิคฮิสโทแกรมอีควอไลเซชัน .....  | 40   |
| รูปที่ 2.32 เคอร์เนลเกาส์เซียนที่มีลักษณะแบบรัศมีสมมาตร (ก) เคอร์เนลขนาด 3x3 กับ $\sigma = 5$ (ข) เคอร์เนลขนาด 5x5 กับ $\sigma = 7$ และ (ค) เคอร์เนลขนาด 7x7 กับ $\sigma = 3$ .....   | 42   |
| รูปที่ 2.33 ภาพสไลด์เอกซเรย์คอมพิวเตอร์ในระนาบตามแกน (ก) ภาพสไลด์เอกซเรย์คอมพิวเตอร์ต้นฉบับ (ข) ภาพเอกซเรย์คอมพิวเตอร์ในรูปแบบของภาพ 8 บิต ที่ไม่ผ่านการดำเนินการวินโดวส์เลเวลลิง และ (ค) ภาพเอกซเรย์คอมพิวเตอร์ในรูปแบบของภาพ 8 บิต หลังผ่านการดำเนินการวินโดวส์เลเวลลิง ..... | 44   |
| รูปที่ 2.34 องค์ประกอบโครงสร้างแบบแบน (ค่าไบนารี) .....   | 45   |
| รูปที่ 2.35 การกัดเซาะเจดสีเทาด้วยองค์ประกอบโครงสร้างแบบแบนขนาด 3x3 .....   | 46   |
| รูปที่ 2.36 การขยายเจดสีเทาด้วยองค์ประกอบโครงสร้างแบบแบนขนาด 3x3 .....  | 47   |
| รูปที่ 2.37 ผลการฉายฮิสโทแกรมใน (ก) แนวนอนและ (ข) แนวตั้งของ (ค) ภาพกระดูกต้นขา กับกระดูกเชิงกราน (Pelvic Girdle Bone) .....  | 49   |
| รูปที่ 2.38 การถอดรอยเชิงเส้นอย่างง่ายและเส้นการถอดรอยเหมาะสมที่สุด .....   | 51   |
| รูปที่ 2.39 แบบจำลองของการถอดรอยเชิงพหุคูณ .....  | 52   |
| รูปที่ 2.40 โครงข่ายประสาทแบบหลายชั้น .....   | 53   |
| รูปที่ 2.41 การดำเนินการภายในนิรอนเทียมในชั้นซ่อน .....   | 54   |
| รูปที่ 2.42 การแพร่ไปข้างหน้า .....   | 55   |
| รูปที่ 2.43 กราฟผลลัพธ์ (ก) ฟังก์ชันซิกมอยด์ (ข) ฟังก์ชันไฮเบอร์โบลิก เทนเจนท์ (ค) ฟังก์ชันเรคติไฟด์ ลิเนียร์ ยูนิท (ง) ฟังก์ชันพาราเมตริกเรคติไฟด์ ลิเนียร์ ยูนิท และ (จ) ฟังก์ชันซอฟต์แวร์แม็กซ์ .....  | 57   |

## สารบัญรูป (ต่อ)

| รูปที่  | หน้า |
|---|------|
| รูปที่ 2.44 การแพร่ย้อนกลับ กรณีพิจารณาที่ชั้นนำออก.....  | 60   |
| รูปที่ 2.45 การแพร่ย้อนกลับ กรณีพิจารณาที่ชั้นซ่อน.....   | 61   |
| รูปที่ 2.46 โครงสร้างโครงข่ายประสาทแบบสังวัตนาการ.....  | 67   |
| รูปที่ 2.47 การสังวัตนาการด้วยเคอร์เนลด้วยจำนวนแกนเนลเท่ากับข้อมูลนำเข้า สร้างฟังก์ชันลักษณะหนึ่งแกนเนล และจำนวนเคอร์เนลกำหนดจำนวนแกนเนลของฟังก์ชันลักษณะ (ฝังสี่เหลี่ยมและสี่เหลี่ยม).....   | 68   |
| รูปที่ 2.48 สังวัตนาการด้วยเคอร์เนลขนาด 3x3.....  | 69   |
| รูปที่ 2.49 (ก) การเสริมเต็มเท่ากับ 1 และ (ข) ค่าก้าวขนาด 2.....  | 70   |
| รูปที่ 2.50 ขนาดฟังก์ชันลักษณะที่ถูกลดด้วยการรวมขนาด 2x2 จำนวนก้าวเท่ากับ 1 ด้วยฟังก์ชันค่ามาก.....   | 71   |
| รูปที่ 2.51 โครงข่ายประสาทแบบ U-Net.....  | 72   |
| รูปที่ 2.52 ตัวอย่างการดำเนินการของชั้นสังวัตนาการสลับเปลี่ยน (ก) เคอร์เนลขนาด 2x2 จำนวนก้าวเท่ากับ 2 ไม่เสริมเต็ม (ข) เคอร์เนลขนาด 2x2 จำนวนก้าวเท่ากับ 1 ไม่เสริมเต็ม (ค) เคอร์เนลขนาด 2x2 จำนวนก้าวเท่ากับ 2 เสริมเต็มเท่ากับ 1..... | 73   |
| รูปที่ 2.53 การต่อข้อมูลจากเส้นเชื่อมโยงข้าม.....   | 74   |
| รูปที่ 2.54 การต่อกันของลูกบาศก์.....   | 75   |
| รูปที่ 2.55 รูปทรงสามเหลี่ยม 14 รูปแบบ.....   | 76   |
| รูปที่ 2.56 การทำให้เมชเรียบด้วยลาปลาเซียน ตำแหน่งของจุดยอดภายในเมชถูกเปลี่ยน (ก) เมชเริ่มต้น (ข) หลังทำให้เรียบด้วยลาปลาเซียน.....   | 78   |
| รูปที่ 2.57 ขั้นตอนวิธีลาปลาเซียนที่ช่วยให้ทอรัสที่มีสัญญาณรบกวน.....   | 78   |
| รูปที่ 2.58 ความเที่ยง (Precision) และ การเรียกคืน (Recall).....  | 80   |
| รูปที่ 2.59 ตัวอย่างการพล็อตสองมิติของสเปกตรัมรูปภาพทำนายกับรูปภาพอ้างอิงจากข้อมูลสองแถบ.....   | 82   |
| รูปที่ 2.60 แผนผังของระบบการวัดดัชนีความคล้ายคลึงกันของโครงสร้าง.....   | 83   |
| รูปที่ 3.1 หน้าโฮมเพจ (Home page) ของระบบวางแผนการรักษา (ยี่ห้อ Varian).....  | 88   |
| รูปที่ 3.2 หน้าระบบวางแผนการรักษารุ่น Eclipse สำหรับการคอนทัวร์.....  | 88   |
| รูปที่ 3.3 โปรแกรม 3D Slicer.....   | 89   |
| รูปที่ 3.4 ขั้นตอนการเตรียมชุดข้อมูลเอกซเรย์คอมพิวเตอร์.....  | 89   |
| รูปที่ 3.5 ภาพเอกซเรย์คอมพิวเตอร์ (ก) ภาพต้นฉบับ และ (ข) ภาพหลังดำเนินการเทคนิคฮิสโตแกรมอีควอไลเซชัน.....   | 91   |

## สารบัญรูป (ต่อ)

| รูปที่  | หน้า |
|---|------|
| รูปที่ 3.6 ภาพเอกซเรย์คอมพิวเตอร์ (ก) ภาพก่อนและ (ข) ภาพหลังดำเนินการทำให้เรียบด้วยเกาส์เซียน .....   | 91   |
| รูปที่ 3.7 ผังกระบวนการกำหนดพิกัดสำหรับกรอบภาพในการครีอปของชุดข้อมูลกระเพาะปัสสาวะ .....  | 93   |
| รูปที่ 3.8 ผลลัพธ์การครีอปของชุดข้อมูลกระเพาะปัสสาวะ (ก) ภาพสไลด์บนระนาบในแนวตั้งแบ่งซ้ายขวา (ข) ระนาบแบ่งหน้าหลัง และ (ค) ระนาบตามแกน .....  | 93   |
| รูปที่ 3.9 (ก) ขั้นตอนการเตรียมชุดข้อมูลล่วงหน้า (Preprocessing) สำหรับชุดข้อมูลกระเพาะปัสสาวะ (ข) ผลลัพธ์การครีอปในสามระนาบและลูกบาศก์หลังถูกหรือป .....                                       | 94   |
| รูปที่ 3.10 ผังกระบวนการกำหนดพิกัดสำหรับกรอบภาพในการครีอปของชุดข้อมูลกระดูกต้นขาข้างซ้ายและขนาดใหม่หลังจากครีอปภาพ .....  | 95   |
| รูปที่ 3.11 ตัวอย่างการเสริมคุณลักษณะบนภาพสไลด์เอกซเรย์คอมพิวเตอร์ .....  | 96   |
| รูปที่ 3.12 ตัวอย่างการเสริมคุณลักษณะด้วย (ก) ค่าสัมประสิทธิ์คุณลักษณะเท่ากับ 5 สำหรับทำนอนหงาย และ (ข) ค่าสัมประสิทธิ์คุณลักษณะเท่ากับ 10 สำหรับทำนอนคว่ำของชุดข้อมูลกระดูกต้นขาข้างซ้าย ..... | 96   |
| รูปที่ 3.13 โครงสร้างโครงข่ายประสาทเทียมแบบ U-Net ขนาด 5 ชั้น .....   | 98   |
| รูปที่ 4.1 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะในกรณีที่ 1 .....   | 102  |
| รูปที่ 4.2 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะในกรณีที่ 2 .....   | 104  |
| รูปที่ 4.3 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะในกรณีที่ 3 .....   | 105  |
| รูปที่ 4.4 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกต้นขาข้างซ้ายในกรณีที่ 1 .....  | 108  |
| รูปที่ 4.5 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกต้นขาข้างซ้ายในกรณีที่ 2 .....  | 109  |
| รูปที่ 4.6 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกต้นขาข้างซ้ายในกรณีที่ 3 .....  | 110  |
| รูปที่ 4.7 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกต้นขาข้างซ้ายในกรณีที่ 4 .....  | 111  |

## สารบัญรูป (ต่อ)

| รูปที่  | หน้า |
|---|------|
| รูปที่ 4.8 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกต้นขาข้างซ้ายในกรณีที่ 5.....   | 112  |
| รูปที่ 4.9 แสดงมุมมองไอโซเมตริก (Isometric) ของแบบจำลองโครงสร้างสามมิติของ (ก) กระเพาะปัสสาวะและ (ข) กระดูกต้นขาข้างซ้าย.....   | 113  |
| รูปที่ 4.10 ภาพแบบจำลองโครงสร้างสามมิติของผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะและกระดูกต้นขาข้างซ้ายในกรณีที่ 1 .....                | 118  |
| รูปที่ 4.11 ภาพแบบจำลองโครงสร้างสามมิติของผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะและกระดูกต้นขาข้างซ้ายในกรณีที่ 2 .....                | 118  |
| รูปที่ 4.12 ภาพแบบจำลองโครงสร้างสามมิติของผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะและกระดูกต้นขาข้างซ้ายในกรณีที่ 3 .....                | 119  |
| รูปที่ 4.13 ภาพแบบจำลองโครงสร้างสามมิติของผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะในกรณีที่ 3 และกระดูกต้นขาข้างซ้ายในกรณีที่ 4 .....    | 119  |
| รูปที่ 4.14 ภาพแบบจำลองโครงสร้างสามมิติของผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะในกรณีที่ 3 และกระดูกต้นขาข้างซ้ายในกรณีที่ 5 .....    | 120  |
| รูปที่ 4.15 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระเพาะปัสสาวะจากแบบจำลองเชิงลึกในกรณีที่ 1 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง .....      | 122  |
| รูปที่ 4.16 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระเพาะปัสสาวะจากแบบจำลองเชิงลึกในกรณีที่ 2 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง .....      | 122  |
| รูปที่ 4.17 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระเพาะปัสสาวะจากแบบจำลองเชิงลึกในกรณีที่ 3 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง .....      | 123  |
| รูปที่ 4.18 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้ายจากแบบจำลองเชิงลึกในกรณีที่ 1 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง ..... | 123  |

## สารบัญรูป (ต่อ)

| รูปที่  | หน้า |
|---|------|
| รูปที่ 4.19 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้ายจากแบบจำลองเชิงลึกในกรณีที่ 2 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง ..... | 124  |
| รูปที่ 4.20 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้ายจากแบบจำลองเชิงลึกในกรณีที่ 3 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง ..... | 124  |
| รูปที่ 4.21 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้ายจากแบบจำลองเชิงลึกในกรณีที่ 4 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง ..... | 125  |
| รูปที่ 4.22 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้ายจากแบบจำลองเชิงลึกในกรณีที่ 5 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง ..... | 125  |



# บทที่ 1

## บทนำ

### 1.1 ความเป็นมาและความสำคัญของปัญหา

รังสีรักษา (Radiotherapy) เป็นหนึ่งในวิธีบำบัดรักษาโรคมะเร็งที่นิยมในปัจจุบัน ประมาณ 50% ของคนไข้โรคมะเร็งเข้ารับการรักษาดังกล่าว [1] โดยการให้รังสีพลังงานสูงฉายไปที่ตำแหน่งของเซลล์มะเร็งเพื่อทำลายสารพันธุกรรมภายในเซลล์มะเร็งและทำให้เซลล์เสียหายหรือตายไป แต่ในขณะเดียวกันเซลล์ปกติโดยรอบก็มีโอกาสได้รับผลกระทบจากรังสีก่อให้เกิดผลข้างเคียงตามมา เพื่อให้ผลกระทบนั้นเกิดขึ้นน้อยที่สุดขณะที่รังสีทำลายเซลล์มะเร็งได้มากที่สุด แพทย์เฉพาะทางด้านมะเร็งวิทยา (Oncologists) จึงจำเป็นต้องมีการคำนวณปริมาณรังสีและกำหนดทิศทางรังสีให้เหมาะสมในขั้นตอนการวางแผนการรักษา ซึ่งหนึ่งในขั้นตอนนั้นคือการวาดคอนทัวร์ (Contour) กำหนดบริเวณก้อนมะเร็งและอวัยวะรอบ ๆ [2]

หว่าการวาดคอนทัวร์นั้นถือเป็นกระบวนการที่กินเวลาค่อนข้างนานจากปัจจัยต่าง ๆ เช่น ชนิดของโรคมะเร็ง จำนวนอวัยวะที่ต้องวาด ความคมชัดของภาพถ่ายทางการแพทย์ ความเชี่ยวชาญของแพทย์ เป็นต้น ซึ่งใช้เวลาตั้งแต่ 30 นาที ถึง 12 ชั่วโมงโดยประมาณ แม้ในปัจจุบันมีการพัฒนาและประยุกต์ใช้อัลกอริทึมทางคณิตศาสตร์เข้ามาช่วย แต่สุดท้ายแพทย์รังสีก็จำเป็นต้องมาปรับแต่งด้วยมืออีกครั้งเพื่อความถูกต้องแม่นยำ ปัญหาเรื่องเวลาจึงยังคงเป็นประเด็นที่ต้องการการแก้ไข เพื่อให้คนไข้ได้เข้ารับการรักษาที่เร็วขึ้น รวมทั้งไม่กลายเป็นกองงานสะสมของแพทย์รังสี ซึ่งแนวทางแก้ไขในเวลานี้ต่างมุ่งไปที่กระบวนการแบ่งส่วนอัตโนมัติ (Automatic Segmentation) ด้วยกระบวนการเรียนรู้เชิงลึก (Deep Learning) [3-5]

ดังนั้นผู้วิจัยจึงมีแนวคิดในการศึกษาวิจัยและพัฒนาโครงข่ายประสาทแบบสังวัตนาการ (Convolution Neural Network) เพื่อสร้างขั้นตอนวิธีสำหรับการแบ่งส่วนอวัยวะที่มีความเสี่ยงโดยอัตโนมัติเพื่อหวังลดระยะเวลาในการทำงานของแพทย์รังสี โดยผู้วิจัยเลือกวิจัยโครงข่าย U-Net ซึ่งมีประสิทธิภาพสูงสำหรับงานด้านการแบ่งส่วนจากภาพ รวมทั้งวิเคราะห์และปรับปรุงชุดข้อมูลเนื่องจากข้อมูลมีอิทธิพลอย่างมากต่อกระบวนการเรียนรู้เชิงลึก เลือกอวัยวะเป้าหมายจากอวัยวะที่มีความเสี่ยงซึ่งต้องผ่านการทำคอนทัวร์เป็นปกติในเคสผู้ป่วยมะเร็งภายในช่องท้องส่วนล่าง อันได้แก่ กระเพาะปัสสาวะ (Bladder) กระดูกต้นขา (Femur) และลำไส้ใหญ่ส่วนปลาย (Rectum) โดยชุดข้อมูลที่ใช้เป็นเคสคนไข้จริงที่ได้รับการสนับสนุนจากโรงพยาบาล เนื่องจากสรีระทางร่างกายนั้นแตกต่างกันไปตามเชื้อชาติ เพื่อให้สามารถนำมาประยุกต์ใช้กับโรงพยาบาลในประเทศไทยได้จริงจึงเห็นควรยึดฐานข้อมูลของคนไข้ชาวไทยหรือเชื้อสายเอเชียมากกว่า

## 1.2 วัตถุประสงค์ของการวิจัย

1.2.1 เพื่อศึกษากระบวนการประมวลผลภาพ ระบบการเรียนรู้เชิงลึก และโครงสร้างโครงข่าย มาประยุกต์ใช้เพื่อสร้างขั้นตอนวิธีสำหรับแบ่งส่วนอวัยวะที่มีความเสี่ยงจากรังสีรักษา

1.2.2 เพื่อพัฒนาขั้นตอนวิธีสำหรับการแบ่งส่วนอวัยวะที่มีความเสี่ยงจากรังสีด้วยระบบการเรียนรู้เชิงลึก

1.2.3 เพื่อเสนอแนวทางการเพิ่มประสิทธิภาพให้กับโครงข่ายประสาทเทียมสำหรับแบ่งส่วนอวัยวะที่มีความเสี่ยงจากรังสีรักษา

1.2.4 เพื่อศึกษาการนำผลการแบ่งส่วนที่ได้มาสร้างเป็นแบบจำลองโครงสร้างสามมิติ

## 1.3 สมมติฐานของการวิจัย

การปรับปรุงคุณภาพของชุดข้อมูลโดยอาศัยกระบวนการประมวลผลภาพ และการเพิ่มข้อมูลคุณสมบัติภายนอกที่ไม่ปรากฏในภาพเข้าไปก่อนเริ่มกระบวนการฝึกฝนแบบจำลองการเรียนรู้เชิงลึก สามารถเพิ่มประสิทธิภาพของขั้นตอนวิธีสำหรับการแบ่งส่วนอวัยวะที่มีความเสี่ยงโดยอัตโนมัติซึ่งสร้างจากระบบการเรียนรู้เชิงลึกได้

## 1.4 ขอบเขตของการวิจัย

สร้างขั้นตอนวิธีสำหรับการแบ่งส่วนอวัยวะที่มีความเสี่ยงโดยอัตโนมัติด้วยระบบการเรียนรู้เชิงลึกสำหรับอวัยวะหลายชนิด อันได้แก่ กระเพาะปัสสาวะและกระดูกต้นขาข้างซ้าย ที่มีประสิทธิภาพมากกว่า 80% พร้อมทั้งนำผลลัพธ์มาสร้างเป็นแบบจำลองโครงสร้างสามมิติขึ้นมาได้

## 1.5 ขั้นตอนการดำเนินงานวิจัย

โครงการวิจัยนี้ประกอบด้วยกระบวนการดำเนินงาน ดังนี้

1. วางแผนและศึกษาข้อมูลจากแหล่งอ้างอิงและบทความวิจัยที่เกี่ยวข้อง
2. ดำเนินเรื่องขอรับข้อมูลจากเคสคนไข้จริงจากโรงพยาบาลศิริราช
3. รวบรวมและปรับแต่งชุดข้อมูลที่ได้รับจากโรงพยาบาลเพื่อให้เหมาะสมต่อการฝึกฝนแบบจำลองการเรียนรู้เชิงลึก
4. ออกแบบกระบวนการและโครงสร้างเครือข่ายระบบการเรียนรู้เชิงลึกเพื่อการแบ่งส่วนอวัยวะ
5. ทดลองฝึกฝนแบบจำลอง
6. เก็บรวบรวมผลการประเมินประสิทธิภาพของแบบจำลอง สร้างแบบจำลองโครงสร้างสามมิติและอภิปรายผลการศึกษา

การแบ่งส่วนอวัยวะด้วยการเรียนรู้เชิงลึกของอวัยวะที่มีความเสี่ยงจากรังสีรักษาพร้อมทั้งการ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สร้างโครงสร้างอวัยวะสามมิติ ได้อธิบายเนื้อหาของบทต่าง ๆ ดังต่อไปนี้

บทที่ 1 บทนำ ในบทนี้ได้กล่าวถึง ความเป็นมาและความสำคัญ วัตถุประสงค์ของการวิจัย สมมติฐานของการวิจัย ขอบเขตการวิจัย รวมถึงขั้นตอนดำเนินงานวิจัย

บทที่ 2 หลักการและทฤษฎีที่เกี่ยวข้อง กล่าวถึง แนวทางหลักการและทฤษฎีที่เกี่ยวข้องกับการศึกษาวิจัย รวมไปถึงการทบทวนวรรณกรรมที่มีความสัมพันธ์เกี่ยวข้องกับงานวิจัย ทั้งนี้รูปทุกรูปที่นำมาใส่ในบทได้มีการระบุแหล่งอ้างอิงเป็นที่เรียบร้อย ยกเว้นรูปที่เป็นของผู้วิจัยเองที่ไม่ได้ระบุแหล่งอ้างอิง

บทที่ 3 ระเบียบวิธีวิจัย กล่าวถึง กระบวนการและขั้นตอนการดำเนินการทดลอง

บทที่ 4 ผลการทดลอง กล่าวถึง ผลประเมินประสิทธิภาพของแบบจำลองเรียนรู้เชิงลึกสำหรับงานแบ่งส่วนอวัยวะที่มีความเสี่ยงอัตโนมัติ ซึ่งผ่านการฝึกฝนตามกรณีศึกษาที่ได้กล่าวไว้ในบทที่ 3 และผลลัพธ์ในรูปแบบของแบบจำลองสามมิติจากผลการตัดแบ่ง

บทที่ 5 สรุปผลการทดลอง อภิปรายผล และข้อเสนอแนะ อธิบายถึงสรุปผลการวิจัย และข้อเสนอแนะรวมถึงแนวทางในการพัฒนาการวิจัยต่อไป เพื่อผลลัพธ์ที่มีความแม่นยำและใกล้เคียงความเป็นจริงมากยิ่งขึ้น

## บทที่ 2


# หลักการและทฤษฎีที่เกี่ยวข้อง

ในบทนี้ อธิบายถึงหลักการและทฤษฎีของภาพเอกซเรย์คอมพิวเตอร์ กระบวนการแบ่งส่วน กระบวนการประมวลผลภาพ กระบวนการเรียนรู้เชิงลึก หลักการสร้างแบบจำลองสามมิติ และขั้นตอนวิธีสำหรับการประเมินผลงานวิจัย ซึ่งถูกนำมาประยุกต์ใช้สำหรับการแบ่งส่วนอวัยวะอัตโนมัติ จากภาพถ่ายทางการแพทย์ในวิทยานิพนธ์ฉบับนี้ รวมถึงทบทวนวรรณกรรมที่เกี่ยวข้อง

### 2.1 ภาพถ่ายเอกซเรย์คอมพิวเตอร์ (X-ray Computed Tomography Image : CT-Scan)

การสร้างภาพถ่ายทางการแพทย์ริเริ่มขึ้นในปี ค.ศ. 1895 จากการค้นพบรังสีเอกซ์ของนักฟิสิกส์ชาวเยอรมัน วิลเฮล์ม ค็อนราท เรินท์เกิน [6] ในขณะที่ทำการทดลองเกี่ยวกับผลกระทบของลำแสงอิเล็กตรอน (รังสีแคโทด) โดยการปล่อยไฟฟ้าผ่านก๊าซความดันต่ำ รังสีเอกซ์เกิดจากการคลายพลังงานของอิเล็กตรอนหลังจากอนุภาคอิเล็กตรอนถูกยิงใส่แผ่นโลหะ เช่น ทังสเตน เนื่องจากการชนทำให้การโคจรอิเล็กตรอนรอบนิวเคลียสมีการเปลี่ยนแปลงตำแหน่ง อิเล็กตรอนที่มีพลังงานสูงกว่าย้ายมาอยู่ในวงโคจรพลังงานต่ำ จึงต้องปล่อยพลังงานส่วนเกินออกมาในรูปแบบของคลื่นแม่เหล็กไฟฟ้า ซึ่งก็คือรังสีเอกซ์ รูปที่ 2.1 แสดงให้เห็นการเกิดรังสีเอกซ์ภายในท่อสุญญากาศ ปัจจุบันเครื่องฉายรังสีเอกซ์ในโรงพยาบาลและโรงงานอุตสาหกรรมประยุกต์ใช้การเร่งอนุภาคที่มีประจุไฟฟ้า ด้วยความเร็วสูงนี้ อนุภาคที่มีประจุไฟฟ้าจะปลดปล่อยพลังงานออกมาในรูปแบบคลื่นแม่เหล็กไฟฟ้าที่มีความถี่สูงเพียงพอจะเป็นรังสีเอกซ์

รังสีเอกซ์มีคุณสมบัติในการทะลุผ่านวัตถุสิ่งของและร่างกายมนุษย์ เมื่อรังสีเอกซ์ผ่านเข้าสู่ร่างกาย กราด 1 ครั้ง เนื้อเยื่อต่าง ๆ อวัยวะภายในรวมทั้งกระดูกจะดูดซับรังสีไว้ โดยดูดซับในปริมาณที่แตกต่างกันขึ้นอยู่กับค่าการลดทอน (Attenuation) กับความหนาแน่นของสสารนั้น ๆ ภาพเอกซเรย์ที่ได้จึงมีพื้นที่เฉดสีขาวและดำที่แตกต่างกัน เช่น แคลเซียมในกระดูกสามารถดูดซับรังสีเอกซ์ได้มากที่สุดจึงทำให้มองเห็นภาพเอกซเรย์กระดูกเป็นสีขาว ส่วนคาร์บอน ไฮโดรเจน และไนโตรเจนในเนื้อเยื่อและอวัยวะภายในดูดซับรังสีได้น้อยกว่าจึงมองเห็นภาพเป็นสีเทา ในขณะที่ออกซิเจนดูดซับรังสีได้น้อยที่สุดจึงมองเห็นปอดเป็นสีขาว [7-10]



รูปที่ 2.1 การสร้างรังสีเอกซเรย์ (ก) ท่อเอกซเรย์ (ข) ภาพถ่ายเอกซเรย์ทรวงอก  
(ที่ มา : [https://www.meddean.luc.edu/lumen/meded/medicine/pulmonar/cxr/atlas/-cxr\\_atlas\\_f.htm](https://www.meddean.luc.edu/lumen/meded/medicine/pulmonar/cxr/atlas/-cxr_atlas_f.htm))

เนื่องจากภาพเอกซเรย์ดั้งเดิมมีความคมชัดไม่เพียงพอสำหรับงานวิจัยหลายงาน จึงได้มีการพัฒนาเทคนิคสร้างภาพถ่ายทางการแพทย์อื่น ๆ ขึ้นมา หนึ่งในนั้น คือ เทคนิคการถ่ายภาพเอกซเรย์คอมพิวเตอร์ (Computed Tomography : CT) หรือที่รู้จักในชื่อการสแกนด้วยเอกซเรย์คอมพิวเตอร์ตามแนวแกน (Computerized Axial Tomography : CAT) ถูกคิดค้นในปี ค.ศ. 1973 [6] โดย กอดเฟรย์ เฮานส์ฟีลด์ [11] พัฒนาจากวิธีการใช้รังสีเอกซ์ที่จำกัดแค่การสร้างภาพแนวระนาบตามแกน (Axial) ของสมองในแขนงประสาทรังสีวิทยา ไปสู่รูปแบบการถ่ายภาพสามมิติทั่วร่างกายที่หลากหลายสำหรับการใช้งานต่าง ๆ ทั้งเนื่องกวิทยา รังสีวิทยาหลอดเลือด หทัยวิทยา ภูมิวิทยา และรังสีร่วมรักษา โดยอาศัยรังสีเอกซ์สร้างภาพตัดขวางของร่างกายขึ้นจากการวัดค่าสัมประสิทธิ์การลดทอนรังสี (Attenuation Coefficient) ของอวัยวะแต่ละชนิดและองค์ประกอบต่าง ๆ ในร่างกาย การเอกซเรย์คอมพิวเตอร์ถูกใช้เพื่อการวินิจฉัยและการติดตามศึกษาคนไข้เพื่อวางแผนการรักษาด้วยรังสีหรือแม้แต่คัดกรองกลุ่มประชากรที่มีสุขภาพดีแต่มีปัจจัยเสี่ยงเฉพาะ ในหัวข้อต่อไปจะอธิบายรายละเอียดเกี่ยวกับกระบวนการได้มาซึ่งภาพเอกซเรย์คอมพิวเตอร์และองค์ประกอบต่าง ๆ ภายในภาพ

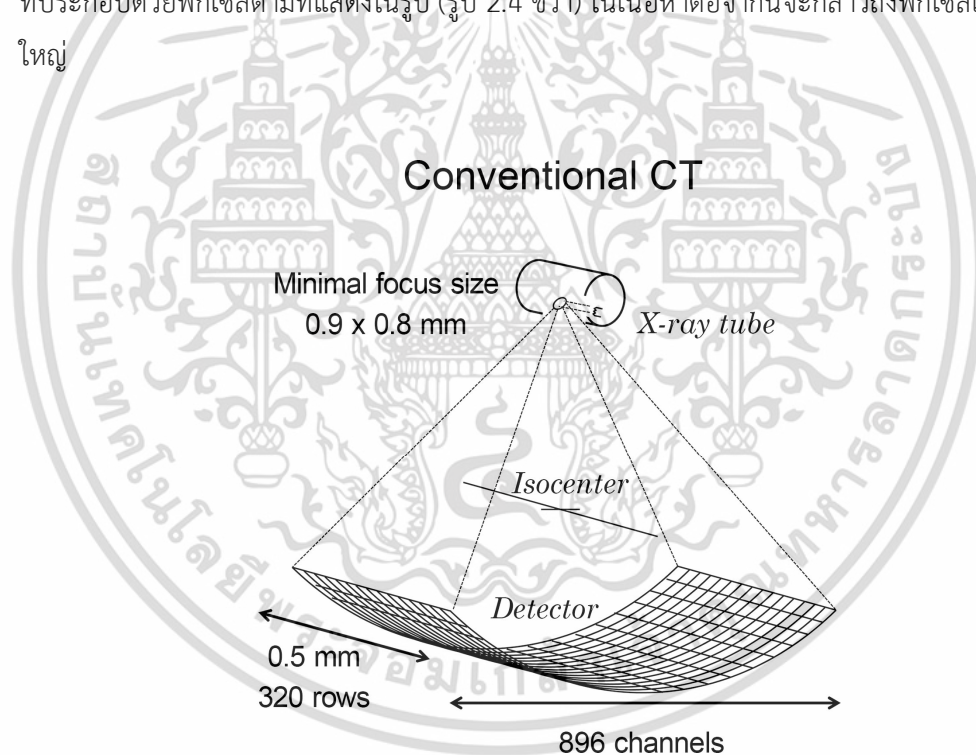
### 2.1.1 พื้นฐานของการถ่ายภาพเอกซเรย์คอมพิวเตอร์ (Principle of Computed Tomography)

#### 2.1.1.1 การฉายรังสีเอกซ์ (X-ray Projection) การลดทอนและการได้มาซึ่งปริมาณรังสีส่งผ่าน (Acquisition of Transmission Profiles)

กระบวนการในการได้มาซึ่งภาพเอกซเรย์คอมพิวเตอร์นั้น มีส่วนเกี่ยวข้องกับการวัดปริมาณรังสีเอกซ์ที่ทะลุผ่านร่างคนไข้เพื่อนำมาสร้างภาพถ่ายดิจิทัล ปริมาณรังสี (Profiles) ในแต่ละ

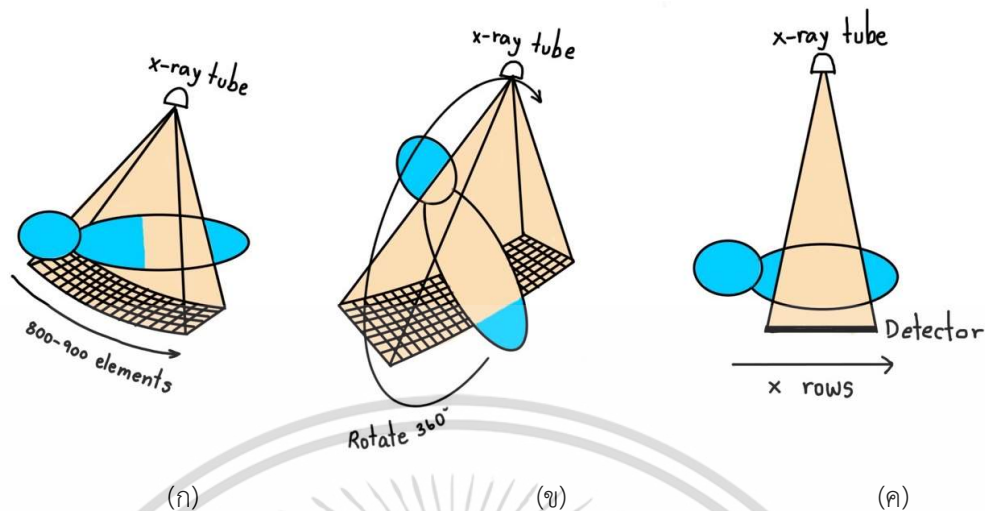
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาพได้มาโดยการใช้อุปกรณ์ตรวจจับแบบโค้งเป็นหลัก ซึ่งปกติแล้วอุปกรณ์ตรวจจับประกอบด้วย  
 เอลเมนต์ในการตรวจจับ 800 ถึง 900 ตัว เรียกว่า แถวอุปกรณ์ตรวจจับ (Detector Row) (รูปที่  
 2.2) การหมุนของหลอดรังสีเอกซ์และแถวอุปกรณ์ตรวจจับรอบตัวคนไข้เป็นไปในลักษณะซิงโครไนต์  
 (Synchronize) [6] ทำให้ได้รับภาพถ่ายมาเป็นจำนวนมาก การใช้แถวอุปกรณ์ตรวจจับนับสิบหรือ  
 หลักร้อยเรียงกันตามระนาบการหมุนมีส่วนช่วยให้กระบวนการสังเคราะห์ภาพเสร็จเร็วขึ้น (รูปที่ 2.3)  
 ปริมาณรังสีส่งผ่านที่ได้มาถูกนำไปใช้ขึ้นโครงสร้างภาพถ่ายเอกซเรย์คอมพิวเตอร์ใหม่ ซึ่งภาพเอกซเรย์  
 คอมพิวเตอร์ประกอบด้วยเมทริกซ์ภาพทรงสี่เหลี่ยมจัตุรัสที่มีขนาดตั้งแต่ 256x256 ถึง 1024x1024  
 พิกเซล เนื่องจากสไลด์ภาพเอกซเรย์คอมพิวเตอร์มีความหนาจำกัด แต่ละพิกเซลจึงแทนด้วยเอล  
 เมนต์ปริมาตรขนาดเล็ก หรือที่เรียกว่า วอคเซล (Voxel) ขนาดของวอคเซลขึ้นอยู่กับขนาดของ  
 เมทริกซ์ ขอบเขตการมองเห็น (Field of View : FOV) ที่เลือกก่อนทำการฉายรังสี และความหนา  
 ของสไลด์เอกซเรย์คอมพิวเตอร์ (รูป 2.4) [12] ซึ่งตอนแสดงขึ้นจอมักปรากฏอยู่ในรูปแบบภาพสองมิติ  
 ที่ประกอบด้วยพิกเซลตามที่แสดงในรูป (รูป 2.4 ขวา) ในเนื้อหาต่อจากนี้จะกล่าวถึงพิกเซลเป็นส่วน  
 ใหญ่




รูปที่ 2.2 แผนผังอุปกรณ์ตรวจจับของการเอกซเรย์คอมพิวเตอร์แบบทั่วไปซึ่งติดตั้งแถวตรวจจับ 320  
 แถว ที่มีความหนาของแต่ละหน่วยของอุปกรณ์ตรวจจับ 0.5 มิลลิเมตร ที่ไอโซเซ็นเตอร์ (Isocenter)  
 และแต่ละแถวถูกแบ่งออกเป็น 896 ชั้น

(ที่มา : Onishi H., *et al.* "Phantom study of in-stent restenosis at high-spatial-resolution  
 CT.", *Radiology*, vol. 289 no.1, 2018. pp. 255-260.)



รูปที่ 2.3 การสังเคราะห์ภาพเอกซเรย์คอมพิวเตอร์แสดงให้เห็นการส่งผ่านของรังสีเอกซ์ผ่านร่างกายคนไข้โดย (ก) ใช้แถวอุปกรณ์ตรวจจับรองรับ 800-900 เอเลเมนต์ (ข) การหมุนของหลอดรังสีเอกซ์และอุปกรณ์ตรวจจับ และ (ค) อุปกรณ์ตรวจจับมีจำนวนมากในรูปแสดง x แถวอุปกรณ์ตรวจจับ




รูปที่ 2.4 แสดงแผนผังของชิ้นส่วนทางกายวิภาค (ซ้าย) และการแสดงภาพที่สอดคล้องกัน (ขวา) ซึ่งแสดงวอลเซลและพิกเซลทั่วไปในการถ่ายภาพเอกซเรย์คอมพิวเตอร์ (ที่มา : Tino R, *et al.* “The interlace deposition method of bone equivalent material extrusion 3D printing for imaging in radiotherapy.”, *Materials & Design*, vol. 199, 2021. pp. 109439.)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ค่าที่ใส่ลงในฟิสิกเซลเป็นค่าการลดทอนรังสีของเนื้อเยื่อที่เกี่ยวข้องหรือถ้าให้เจาะจงเนื้อเยื่อเฉพาะส่วนมากกว่านั้นก็จะสัมพันธ์กับค่าสัมประสิทธิ์การลดทอนเชิงเส้น (Linear Attenuation Coefficient :  $\mu$ ) ในหน่วย  $m^{-1}$  ซึ่งขึ้นอยู่กับองค์ประกอบของวัตถุ เช่น อวัยวะหรือสิ่งกีดขวาง ความหนาแน่นของวัตถุและความเข้มโฟตอน ตามกฎของเบียร์ (Beer's Law) [6, 13, 14] ดังสมการ

$$I(x) = I_0 e^{-\mu x} \quad (2.1)$$

เมื่อ  $I(x)$  คือ ค่าเข้มของลำรังสีที่ถูกลดทอน  $I_0$  คือ ค่าความเข้มรังสีตั้งต้น และ  $x$  คือ ความหนาของวัตถุ ทว่ากฎของเบียร์เป็นเพียงคำอธิบายการลดทอนของลำรังสีเริ่มต้นและไม่ได้คำนึงถึงการกระจายของรังสีที่เกิดขึ้น



รูปที่ 2.5 แผนผังการรับปริมาณรังสีส่งผ่านร่างกายตามกฎของเบียร์

เมื่อลำรังสีเอกซ์ทะลุผ่านคนไข้ เนื้อเยื่อต่างชนิดกันมีค่าสัมประสิทธิ์การลดทอนเชิงเส้นที่แตกต่างกัน ถ้าเส้นทางผ่านตัวคนไข้มีช่วงตั้งแต่ 0 ถึง  $d$  ดังนั้นแล้วความเข้มของลำรังสีที่ถูกลดทอนก็จะส่งผ่านในระยะทางเท่ากับ  $d$  จึงสามารถเขียนสมการได้ใหม่ว่า


$$I(d) = I_0 e^{-\int_0^d \mu(x) dx} \quad (2.2)$$

ตามที่กล่าวมาว่าภาพเอกซเรย์คอมพิวเตอร์ประกอบด้วยเมทริกซ์ฟิสิกเซลหรือว็อกเซลในเชิงปริมาตร สร้างจากค่าสัมประสิทธิ์การลดทอนเชิงเส้นที่แตกต่างกัน ในรูปที่ 2.6 แสดงเมทริกซ์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ขนาด  $4 \times 4$  ซึ่งแทนการวัดการส่งผ่านตามเส้นทางหนึ่งทาง สำหรับการแยกแยะดังกล่าวสมการสำหรับการลดทอนสามารถแสดงเป็น :

$$I(d) = I_0 e^{-\sum_{i=1}^4 \mu_i \Delta x} \quad (2.3)$$



รูปที่ 2.6 พื้นฐานของการลดทอนลำรังสีเอกซ์ในเมทริกซ์  $4 \times 4$  แต่ละเอเลเมนต์ในเมทริกซ์สามารถมีค่าสัมประสิทธิ์การลดทอนต่างกัน

จากที่กล่าวมาสามารถเห็นได้ว่าข้อมูลพื้นฐานที่จำเป็นต่อการเอกซเรย์คอมพิวเตอร์ คือ ความเข้มของลำรังสีเอกซ์ก่อนและหลังถูกลดทอน ( $I_0$  และ  $I(d)$ ) จากนั้นใช้เทคนิคการขึ้นโครงภาพใหม่ (Image Reconstruction Technique) เพื่อให้ได้เมทริกซ์ค่าสัมประสิทธิ์การลดทอนเชิงเส้น ซึ่งเป็นพื้นฐานของภาพเอกซเรย์คอมพิวเตอร์

#### 2.1.1.2 หน่วยแฮสฟิลด์ (Hounsfield Units)

ในภาพเอกซเรย์คอมพิวเตอร์นั้น เมทริกซ์ค่าสัมประสิทธิ์การลดทอน ( $\mu_{material}$ ) ถูกแปลงให้เป็นเมทริกซ์ของค่าหน่วยแฮสฟิลด์ ( $HU_{material}$ ) โดยใช้ค่าสัมประสิทธิ์การลดทอนเชิงเส้นของน้ำบริสุทธิ์หรือน้ำกลั่น [15] ที่อุณหภูมิห้อง ( $\mu_{water}$ ) เป็นจุดอ้างอิงสำหรับการกำหนดสเกลค่าหน่วยแฮสฟิลด์ [14]

$$HU_{material} = \frac{\mu_{material} - \mu_{water}}{\mu_{water}} \times 1000 \quad (2.4)$$

ดังนั้นค่าหน่วยแฮสฟิลด์ของน้ำจึงเท่ากับศูนย์ และค่าหน่วยแฮสฟิลด์ของอากาศเท่ากับ -1000 และหากค่าหน่วยแฮสฟิลด์เท่ากับ 1 จะเทียบได้กับ 0.1% ของค่าสัมประสิทธิ์เชิงเส้นของน้ำ อย่างไรก็ตามองค์ประกอบส่วนอื่น ๆ นอกจากน้ำและอากาศแล้ว ความสัมพันธ์ระหว่างค่า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สัมประสิทธิ์การลดทอนเชิงเส้นและความเข้มโฟตอนจะไม่ใช่เชิงเส้น เมื่อความเข้มของโฟตอนของรังสีเอกซ์เปลี่ยนไป คุณสมบัติการลดทอนของสารเหล่านี้ก็จะเบี่ยงเบนไปจากความสัมพันธ์เชิงเส้นแบบธรรมดา จึงเป็นเหตุให้ ค่าหน่วยแฮสฟิลด์ของส่วนอื่น ๆ ที่ในที่นี้หมายถึงอวัยวะหรือส่วนประกอบอื่น ๆ ภายในร่างกายมนุษย์แปรผันไปตามค่าแรงดันไฟฟ้าของหลอดรังสีเอกซ์ที่กำหนดค่าต่างกันได้ด้วย ดังนั้น ผู้เชี่ยวชาญทางการแพทย์จำเป็นต้องพิจารณาปัจจัยเหล่านี้เมื่อทำการวิเคราะห์การเอกซเรย์คอมพิวเตอร์ เพื่อระบุเนื้อเยื่อและโครงสร้างต่าง ๆ ภายในร่างกายอย่างแม่นยำ

ตารางที่ 2.1 ค่าหน่วยแฮสฟิลด์และช่วงค่าทั่วไปของเนื้อเยื่อและองค์ประกอบอื่น ๆ


| องค์ประกอบ             | ค่าหน่วยแฮสฟิลด์ (HU) |
|------------------------|-----------------------|
| กระดูก                 | +1000 (+300 to +2500) |
| ตับ                    | +60 (+50 to +70)      |
| เลือด                  | +55 (+50 to +60)      |
| ไต                     | +30 (+20 to +40)      |
| กล้ามเนื้อ             | +25 (+10 to +40)      |
| สมองส่วนสีเทา          | +35 (+30 to +40)      |
| สมองส่วนสีขาว          | +25 (+20 to +30)      |
| กรวยไต [16]            | +10 (-4 to +17)       |
| กระเพาะปัสสาวะ [16-18] | +7 (-3 to +32)        |
| น้ำ                    | 0                     |
| ไขมัน                  | -90 (-100 to -80)     |
| ปอด                    | -750 (-950 to -600)   |
| อากาศ                  | -1000                 |

ความลึกบิตที่น้อยที่สุดที่ควรใส่ในพิกเซล คือ 12 บิต สามารถสร้างค่าหน่วยแฮสฟิลด์ที่มีช่วงตั้งแต่ -1024 HU ถึง +3071 HU ซึ่งครอบคลุมเนื้อเยื่อที่เกี่ยวข้องทางคลินิกส่วนใหญ่ ถ้าขยายสเกลขึ้นให้มีความลึกบิตเป็น 14 บิต ก็จะสามารถเพิ่มสเกลค่าหน่วยแฮสฟิลด์ ขึ้นไปเป็น +15,359 HU ด้วยวิธีนี้จะทำให้สอดคล้องกับอวัยวะหรือองค์ประกอบที่มีความหนาแน่นสูงและค่าสัมประสิทธิ์การลดทอนเชิงเส้นสูง ยังมีความลึกบิตสูง ความละเอียดของเฉดสีเทาที่ยังสูง (รูปที่ 2.7)

ภาพเอกซเรย์คอมพิวเตอร์ มักถูกแสดงขึ้นหน้าจอมอนิเตอร์โดยใช้ภาพสเกลสีเทาขนาด 8 บิต ซึ่งมีค่าทั้งหมดเพียง 256 ค่าเท่านั้น แต่ค่าหน่วยแฮสฟิลด์จะถูกแปลงค่าเชิงจับคู่ให้อยู่ในช่วงหน้าต่าง 8 บิต ความกว้างหน้าต่างเป็นตัวกำหนดช่วงของค่าหน่วยแฮสฟิลด์ (ช่วงที่แสดงตั้งแต่สีขาว

ไปสีดำ) และระดับหน้าต่างเป็นตัวกำหนดจุดกึ่งกลางของค่าหน่วยเฮาส์ฟิลด์ในช่วงความกว้างหน้าต่างที่เลือก สามารถใช้วิธีปรับค่านี้นี้เพื่อให้ได้ภาพที่ดีที่สุดต่อการอ่านและวิเคราะห์ภาพหรือง่ายต่อการดูเนื้อเยื่อที่สนใจ อย่างไรก็ตามการตั้งค่าที่ต่างกันของความกว้างและระดับหน้าต่างทำเพื่อแสดงภาพเนื้อเยื่ออ่อน เนื้อเยื่อปอด หรือกระดูก

ในทางคลินิกอาจเกิดการเบี่ยงเบนอย่างมากระหว่างค่า HU ที่คาดไว้และที่สังเกตได้สาเหตุของความไม่ถูกต้องดังกล่าวอาจเป็นเพราะค่าหน่วยเฮาส์ฟิลด์ในฟิลเตอร์สำหรับขึ้นรูปใหม่ขนาดของ FOV และตำแหน่งภายใน FOV ที่สแกน นอกจากนี้ อาร์ติแฟก (Artifact) ในภาพก็อาจเป็นอีกหนึ่งปัจจัยที่ส่งผลต่อความถูกต้องของค่าหน่วยเฮาส์ฟิลด์ และจากการศึกษาวิจัย แม้จะดำเนินการถ่ายภาพด้วยเครื่องสแกนเครื่องเดียวกันก็อาจได้ค่าหน่วยเฮาส์ฟิลด์ในเนื้อเยื่อชนิดเดียวกันแตกต่างกันได้ตามเวลาในแต่ละช่วง ยิ่งหากมาจากเครื่องสแกนคนละเครื่อง อาจแตกต่างกันอย่างมีนัยสำคัญ



รูปที่ 2.7 ความละเอียดของระดับเฉดสีเทาตามความลึกบิต

(ที่มา : Jayamani J., et al. "Determination of computed tomography number of high-density materials in 12-bit, 12-bit extended and 16-bit depth for dosimetric calculation in treatment planning system.", Journal of Radiotherapy in Practice, vol.18 no.3, 2019. pp. 285-294.)

#### 2.1.1.3 ระบบการสร้างภาพ CT : อุปกรณ์ตรวจจับ (Detectors)

ลักษณะทางกายภาพสำคัญของอุปกรณ์ตรวจจับของเครื่องถ่ายภาพเอกซเรย์คอมพิวเตอร์คือ มีประสิทธิภาพด้านการตรวจจับดีเยี่ยมและตอบสนองเร็ว ปัจจุบันนิยมใช้อุปกรณ์ตรวจจับชนิดตัวกลางที่เป็นของแข็งเพราะสามารถตรวจจับได้เกือบร้อยเปอร์เซ็นต์ โดยทั่วไปแล้วอุปกรณ์ตรวจจับชนิดนี้เป็นผลึกเรืองแสงเมื่อทำปฏิกิริยากับรังสีเอกซ์จะเกิดการเรืองแสงขึ้น ซึ่งแสงนี้จะถูกแปลงเป็น

สัญญาณไฟฟ้าโดยโพลีไดโอดที่ติดไว้ที่ด้านหลังของผลึกเรืองแสง และจะติดตั้งตะแกรงป้องกันการกระเจิงที่ด้านหน้าของอุปกรณ์ตรวจจับซึ่งประกอบด้วยแผ่นแถบเล็ก ๆ ที่ทำจากวัสดุที่มีคุณสมบัติลดทอนสูง เช่น ทังสเตน เรียงต่อกันตามแนวแกนในแนวตั้ง (แกน Z) ของเครื่องสแกน CT

แถวอุปกรณ์ตรวจจับประกอบด้วยหลายพันเซลล์ (Dels) ที่แยกโดยแผ่นกั้นในแนวรัศมีภายในแต่ละช่อง (Septa) เพื่อป้องกันไม่ให้แสงที่เกิดขึ้นในเซลล์ตัวหนึ่งถูกตรวจพบโดยเซลล์ข้างเคียง อุปกรณ์ตรวจจับเอกซเรย์คอมพิวเตอร์ที่สมบูรณ์แล้วประกอบไปด้วยโมดูลอุปกรณ์ตรวจจับจำนวนมากที่ติดตั้งติดกันตามแนวโค้ง

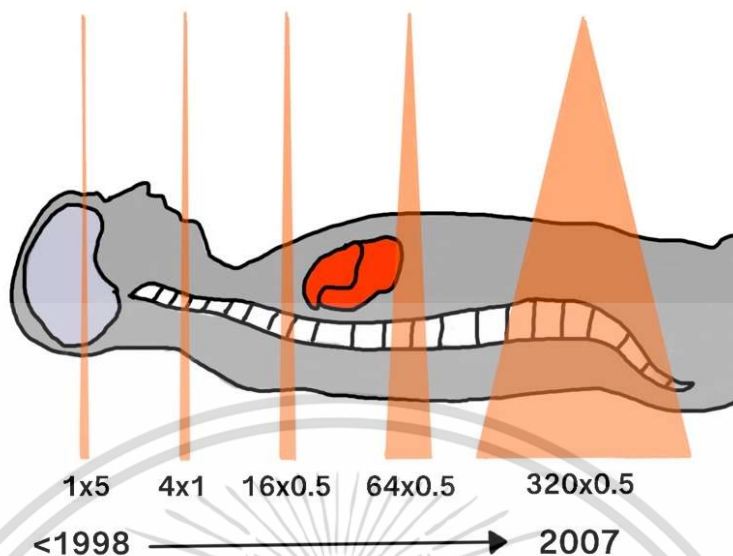
ใช้เดลเพื่อวัดข้อมูลปริมาณรังสีส่งผ่าน ( $I(d)$ ) ในขณะที่เดลที่อยู่นอก FOV ถูกใช้เพื่อวัดปริมาณรังสีที่ยังไม่ถูกลดทอน ( $I(O)$ )

ความละเอียดเชิงพื้นที่ (Spatial Resolution : D) ที่ต้องการภายในภาพที่ขึ้นโครงสร้างใหม่ผ่านเทคนิคการสร้างภาพใหม่ขึ้นอยู่กับจำนวนและขนาดของเซลล์ตามส่วนโค้งอุปกรณ์ตรวจจับขนาดของเซลล์ตามแกน Z จำนวนมุมการฉายรังสี และขนาดจุดโฟกัส (Focal Spot) ของหลอดรังสีเอกซ์ ซึ่งจำนวนที่น้อยที่สุดของเดล (Number of Dels) ที่ครอบคลุมขอบเขตการมองเห็นแบบเฉพาะเจาะจงสามารถประมาณได้ตามสมการที่ 2.5 เพื่อให้ได้ความละเอียดเชิงพื้นที่ที่ต้องการในหน่วยมิลลิเมตร

$$\text{Number of dels} = \frac{2FOV}{D} \quad (2.5)$$

เช่น สำหรับขอบเขตการมองเห็น 400 มิลลิเมตร ต้องการเดลโดยประมาณ 800 เดล เพื่อให้ได้ความละเอียดเชิงพื้นที่ขนาด 1 มิลลิเมตร ภายในภาพที่สร้างขึ้น ความละเอียดเชิงพื้นที่สามารถเพิ่มขึ้นได้ด้วยการหมุน 360 องศา โดยการตัดแปลงเชิงเรขาคณิตในการจัดเรียงเดลเพียงเล็กน้อย หรือการขยับเลื่อนเดลด้วยระยะเท่ากับหนึ่งในสี่ของขนาดเดลสามารถเพิ่มความละเอียดเชิงพื้นที่ได้สองเท่า ในเครื่องเอกซเรย์คอมพิวเตอร์จึงมีการเลื่อนเดลประมาณนี้ และตามหลักการแล้วจำนวนมุมการถ่ายภาพที่ต้องการสามารถประมาณได้ด้วยจำนวนเดลที่ต้องการ ด้วยแถวอุปกรณ์ตรวจจับที่ใช้ในปัจจุบันอยู่ที่ 800–1,000 เดล ครอบคลุมขอบเขตการมองเห็นที่ 400 มิลลิเมตร ทำให้ได้ความละเอียดเชิงพื้นที่ที่ดีกว่าหนึ่งมิลลิเมตร

รูปที่ 2.8 แสดงให้เห็นว่าเครื่องเอกซเรย์คอมพิวเตอร์ความเร็วสูงโดยใช้อุปกรณ์ตรวจจับปริมาณมาก (Multi-Detector CT : MDCT) เพิ่มพื้นที่ครอบคลุมขึ้นเมื่อมีแถวอุปกรณ์ตรวจจับแอคทีฟมากขึ้น การได้ข้อมูลมาของเครื่องเอกซเรย์คอมพิวเตอร์ที่มีอุปกรณ์ตรวจจับ 1 แถว จะครอบคลุมพื้นที่ประมาณ 5 มิลลิเมตร เมื่อเปลี่ยนเป็น 4 แถว ความละเอียดตามแกนแนวตั้ง (Vertical Spatial Resolution) จะพัฒนาขึ้นมาก เช่น ขนาด  $4 \times 1$  มิลลิเมตร ความละเอียดเชิงพื้นที่ตามแกนแนวตั้งกลายเป็น 1.25 มิลลิเมตร แทน 5 มิลลิเมตร




รูปที่ 2.8 แสดงการครอบคลุมที่เพิ่มขึ้นของเครื่องเอกซเรย์คอมพิวเตอร์ความเร็วสูงเมื่อมีแกวอุปกรณ์ตรวจจับชนิดแอคทีฟมากขึ้น

ในทางปฏิบัติเครื่องเอกซเรย์คอมพิวเตอร์ด้วยอุปกรณ์ตรวจจับสี่แกวเป็นตัวเลือกหลักสำหรับเพิ่มความละเอียดตามแนวตั้ง รวมทั้งยังใช้เพื่อเพิ่มพื้นที่ครอบคลุมตามแนวตั้งด้วย เช่น เลือกใช้  $4 \times 2 = 8$  มิลลิเมตร หรืออาจใช้  $4 \times 4 = 16$  มิลลิเมตร นอกจากขนาดพื้นที่ครอบคลุมมากขึ้นยังช่วยให้เวลาที่ใช้ในการสแกนสั้นลงด้วย เครื่องเอกซเรย์คอมพิวเตอร์ด้วยอุปกรณ์ตรวจจับจำนวน 16 และ 64 แกว จะได้พื้นที่ครอบคลุมเป็น  $16 \times 0.5 = 8$  มิลลิเมตร และ  $64 \times 0.5 = 32$  มิลลิเมตร ตามลำดับ ค่า 0.5 มิลลิเมตร หมายถึง ขนาดของเซลล์ตามแกน Z เครื่องสแกนเหล่านี้ให้ความละเอียดเชิงพื้นที่ตามแกนแนวตั้งที่ยอดเยี่ยม การสร้างภาพ 3 มิติที่มีคุณภาพสูง และในขณะเดียวกันก็ลดเวลาในการสแกนลงด้วย ถึงอย่างนั้น เครื่องสแกน MDCT ที่มีแกวเครื่องตรวจจับแบบแอคทีฟมากถึง 64 แกวก็ไม่ได้ครอบคลุมอวัยวะทั้งหมด และเพื่อให้ครอบคลุมช่วงที่กำหนด การสแกนโดยทั่วไปจึงดำเนินการแบบเกลียวด้วยการหมุนหลาย ๆ รอบขณะที่เตียงคนไข้เคลื่อนที่ ส่วนเครื่องเอกซเรย์คอมพิวเตอร์ที่ใช้อุปกรณ์ตรวจจับ 320 แกว แค่หมุนรอบเดียวก็ครอบคลุมอวัยวะต่าง ๆ ได้แล้วในพื้นที่ 160 มิลลิเมตร เช่น สมองหรือหัวใจภายในการหมุนรอบเดียว

รูปที่ 2.9 แสดงให้เห็นโครงสร้างของแกวและองค์ประกอบของอุปกรณ์ตรวจจับที่มี 16 แกว โดยแต่ละแกวประกอบด้วยเซลล์ขนาด 2 มิลลิเมตร ครอบคลุมพื้นที่ 32 มิลลิเมตร

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 2.9 โครงสร้างของแถวและองค์ประกอบของอุปกรณ์ตรวจจับแบบ 16 แถว

### 2.1.2 การสร้างภาพใหม่ (Image Reconstruction) และการประมวลผล (Processing)

หลักการของเครื่องเอกซเรย์คอมพิวเตอร์ คือ อาศัยการสร้างภาพใหม่จากข้อมูลการถ่ายภาพที่ได้จากการเก็บข้อมูลแต่ละครั้ง ปล่อยรังสีผ่านคนไข้ไปยังอุปกรณ์ตรวจจับที่อยู่ฝั่งตรงข้าม หลอดหมุนรอบตัวคนไข้พร้อมกับปล่อยรังสีและตัวตรวจจับก็เก็บข้อมูลมาพร้อม ๆ กัน ข้อมูลที่ได้จากการเคลื่อนของหลอดจะเพิ่มขึ้นทีละชั้นในหน่วยขององศา ซึ่งแต่ละหน่วยถือเป็นการฉาย 1 ครั้ง โดยข้อมูลชั้นอยู่กับค่าสัมประสิทธิ์การลดทอนรังสีจึงเป็นเหตุผลที่แต่ละจุดมีปริมาณรังสีส่งผ่านปรากฏไม่เท่ากัน [19]

ปริมาณรังสีส่งผ่านที่ตรวจจับได้ในมุมต่าง ๆ ตามการหมุนของหลอดรังสีเอกซ์และอุปกรณ์ตรวจจับรอบ ๆ คนไข้ จะถูกจัดเก็บไว้ในรูปแบบของซินโนแกรม (Sinogram) ถือเป็นวัตถุดิบพื้นฐานสำหรับการสร้างภาพเอกซเรย์คอมพิวเตอร์ขึ้นมาใหม่ในรูปแบบของภาพดิจิทัล โดยเริ่มจากการนำมาแปลงค่าด้วยเทคนิคการแปลงฟูเรียร์ (Fourier Transform) ก่อน แล้วจึงค่อยสร้างภาพด้วยขั้นตอนวิธีสร้างภาพซึ่งปัจจุบันมีหลายวิธี ได้แก่ การฉายย้อนกลับ (Back Projection) การฉายย้อนกลับแบบกรอง (Filtered Back Projection) การสร้างใหม่แบบวนซ้ำ (Iterative Reconstruction) เป็นต้น หลังจากกระบวนการสร้างภาพใหม่แล้ว ภาพที่ได้จะมีการกำหนดค่าเลขซีที (CT Number) หรือหน่วยเฮาส์ฟิลด์ ซึ่งคำนวณมาจากผลต่างของค่าสัมประสิทธิ์การลดทอนของตัวกลางที่ตำแหน่งต่าง ๆ กับน้ำต่อค่าสัมประสิทธิ์การลดทอนของน้ำ


รูปที่ 2.10 ฉายรังสีสามทางซึ่งเท่ากับมุมทอรังสีที่ 0 องศา 90 องศา และ 180 องศา (ซ้าย) และ ซินโนแกรมผลลัพธ์ (ขวา) แสดงเส้นโครงทั้งหมดซ้อนทับกัน



รูปที่ 2.10 (ก) ฉายรังสีในมุมที่ 0 องศา 90 องศา และ 180 องศา และ (ข) ไซโนแกรมผลลัพธ์

### 2.1.2.1. การฉายย้อนกลับ (Back projection)

อิงตามสมการ (2.1) สำหรับคำนวณหาความเข้มรังสีส่งผ่านหลังทะลุผ่านร่างกายคนไข้ ในความเป็นจริงลำรังสีต้องผ่านองค์ประกอบหลายอย่างในร่างกายมนุษย์ ซึ่งมีค่าสัมประสิทธิ์การลดทอนที่แตกต่างกัน ดังที่แสดงในรูปที่ 2.11 และสมการที่ 2.6




รูปที่ 2.11 ความเข้มรังสีส่งผ่านตัวกลางที่มีค่าสัมประสิทธิ์ลดทอนที่แตกต่างกัน

$$I_{out} = I_{in} e^{-(\mu_1 x_1 + \mu_2 x_2 + \mu_3 x_3 + \dots + \mu_n x_n)} \quad (2.6)$$

การฉายย้อนกลับเป็นกระบวนการพื้นฐานที่มีกระบวนการทางคณิตศาสตร์ที่ไม่ซับซ้อน กระบวนการนี้สามารถเรียกว่า ‘วิธีการรวมค่า (Summation Method)’ สามารถอธิบายได้ด้วยวิธีการเชิงตัวเลข

สมมติพิจารณาลำรังสีเอกซ์สี่สายที่ผ่านวัตถุซึ่งไม่ทราบว่าเป็นอะไร ในมุมที่ต่างกันสร้างปริมาณรังสีส่งผ่านหรือรังสีการฉาย (Projection profiles) ขึ้นมา 4 ค่า ( $P_1, P_2, P_3, P_4$ ) (รูปที่ 2.12) ใช้ปริมาณเหล่านี้มาสร้างภาพวัตถุขึ้นใหม่โดยการฉายย้อนกลับให้อยู่ในรูปแบบของภาพที่สอดคล้องกัน ( $BP_1, BP_2, BP_3, BP_4$ ) การสร้างขึ้นใหม่เกี่ยวกับการรวมภาพที่ถูกคำนวณฉายย้อนกลับเหล่านี้ให้อยู่ในรูปของภาพวัตถุ [19]



รูปที่ 2.12 แสดงการสร้างชิ้นใหม่ด้วยการฉายย้อนกลับ

(ที่มา : Seeram, E. Computed Tomography-E-Book: Physical Principles, Patient Care, Clinical Applications, and Quality Control. 4th Edition. Missouri : Elsevier Inc. 2016.)

การฉายย้อนกลับสามารถอธิบายได้ด้วยเมทริกซ์  $2 \times 2$

$$\begin{bmatrix} \mu_1 & \mu_2 \\ \mu_3 & \mu_4 \end{bmatrix}$$

จากเมทริกซ์เขียนสมการแยกได้ตามค่าสัมประสิทธิ์การลดทอน ( $\mu$ ) 4 ค่า

$$I_1 = I_0 e^{-(\mu_1 + \mu_2)x} \quad (2.7)$$

$$I_2 = I_0 e^{-(\mu_3 + \mu_4)x} \quad (2.8)$$

$$I_3 = I_0 e^{-(\mu_1 + \mu_3)x} \quad (2.9)$$

$$I_4 = I_0 e^{-(\mu_2 + \mu_4)x} \quad (2.10)$$

เมื่อ  $I_1, I_2, I_3$  และ  $I_4$  คือ ค่าความเข้มรังสีหลังผ่านตัวกลางที่มีค่าสัมประสิทธิ์ลดทอน และ  $x$  คือ ขนาดหรือระยะของพื้นที่ที่มีค่าสัมประสิทธิ์ลดทอนนั้น ๆ

คำนวณแก้ไขสมการเหล่านี้จนได้เป็นเมทริกซ์ใหม่ขึ้นมา เทคนิคการฉายย้อนกลับมีประสิทธิภาพ โดยการวัดแต่ละครั้งได้รับการประมวลผลเพียงครั้งเดียว และการคำนวณที่ค่อนข้างง่าย แต่มีข้อบกพร่องอยู่ตรงที่ภาพที่ออกมาจะพร่ามัว โดยมีความละเอียดเชิงพื้นที่ต่ำ ปัญหานี้ค่อนข้างพบเห็นได้ชัด การเบลอนี้เป็นผลตามธรรมชาติของการสแกนและกระบวนการฉายย้อนกลับ นักวิทยาศาสตร์จึงได้ต่อยอดเพื่อแก้ไขข้อบกพร่องนี้ คือ ใช้กระบวนการทางคณิตศาสตร์ที่เรียกว่าการกรอง (Filtering)

#### 2.1.2.2. การฉายย้อนกลับแบบกรอง (Filtered Back Projection)

กระบวนการทางคณิตศาสตร์ที่จำเป็นต่อการฉายย้อนกลับแบบกรอง มีด้วยกัน 4 ขั้นตอน คือ [14]


1. ฟูเรียร์หนึ่งมิติของปริภูมิเรดอน
2. ตัวกรองความถี่สูง (High Pass Filter)
3. ฟูเรียร์ผกผันเพื่อให้ได้ปริภูมิเรดอนที่ปรับปรุงปริมาณรังสีการฉายแล้ว
4. การฉายย้อนกลับเพื่อสร้างโครงสร้างใหม่ของวัตถุที่ถูกวัด

รูปที่ 2.13 แสดงวิธีการใช้การฉายภาพย้อนกลับแบบมีตัวกรองอย่างต่อเนื่องในมุมต่าง ๆ เพื่อสร้างโดเมนปริภูมิคุณภาพดีขึ้นใหม่ โดยขั้นนี้สามารถใช้การสังวัตนาการ (Convolution) กับปริมาณรังสีในโดเมนเรดอนโดยตรงด้วยเคอร์เนลที่เหมาะสมแทนได้ ส่วนรูปที่ 2.14 แสดงผลลัพธ์เปรียบเทียบระหว่างการใช้ขั้นตอนวิธีการฉายย้อนกลับทั่วไปกับการฉายย้อนกลับแบบกรอง

ปริภูมิภาพ (Image Space) ปกติแล้วจะถูกแทนในรูปแบบของตารางปกติ ให้ปริภูมิภาพสองมิติแทนด้วย  $f(x, y)$  โดย  $(x, y)$  คือ ระบบพิกัดคาร์ทีเซียน การฉายเดี่ยวหนึ่งมิติของปริภูมิภาพสองมิติด้วยที่มีรังสีเท่ากันและรังสีขนานให้เส้นหนึ่งเส้นในปริภูมิเรดอน แสดงเป็นเส้นโค้ง  $p(t, \theta)$  โดยที่  $t$  คือ ระยะทางจากรังสีเอกซ์ที่ฉายไปยังจุดศูนย์กลางไอโซเซนเตอร์ เรียกว่า เป็นจุดในพื้นที่ซึ่งจุดกึ่งกลางรังสีของลำรังสีวิ่งผ่านและ  $\theta$  คือ มุมฉายภาพ (รูปที่ 2.15) ตามทฤษฎีสไลด์กลางหรือทฤษฎีสไลด์ฟูเรียร์ระบุว่า การแปลงฟูเรียร์ในการฉายแบบขนานของปริภูมิภาพที่มุม  $\theta$  จะสร้างเส้นหนึ่งภายในปริภูมิฟูเรียร์สองมิติ  $F(u, v)$  ในมุมเดียวกับ  $\theta$  เรียกปริภูมิสองมิติว่า ปริภูมิ  $k$  (K-vector Space) หรือปริภูมิเวกเตอร์คลื่น (Wave Vector Space) หรือปริภูมิฟูเรียร์ (Fourier Space : F)

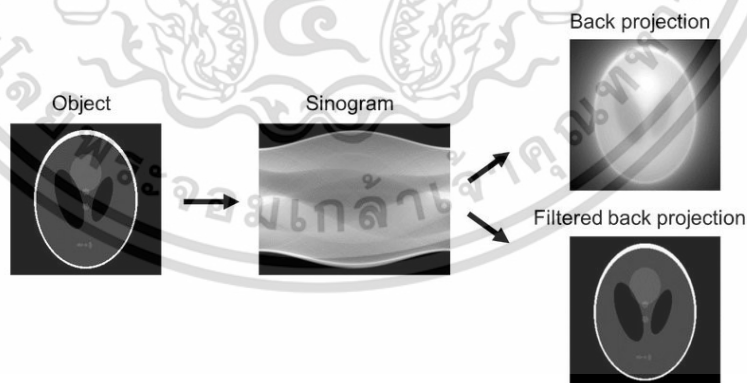
สมมติว่าให้มุม  $\theta$  เท่ากับ 0 การฉายภาพ  $p(x, 0)$  และเส้นที่สอดคล้องในปริภูมิเรดอน เขียนสมการได้ว่า

$$p(x, 0) = \int_{-\infty}^{+\infty} f(x, y) dy \quad (2.11)$$



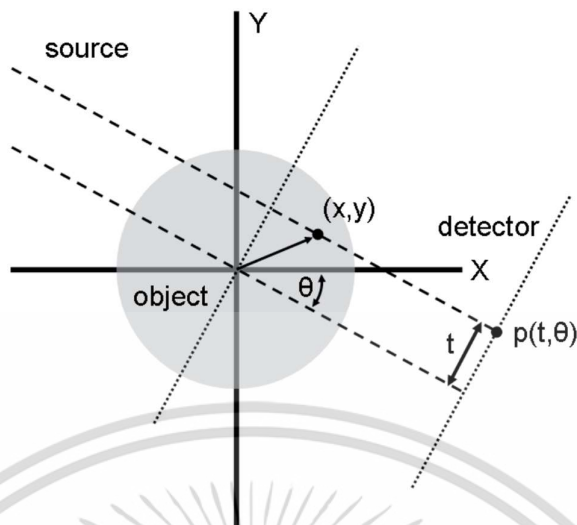
รูปที่ 2.13 แสดงผลการฉายภาพย้อนกลับแบบมีตัวกรองอย่างต่อเนื่องเพื่อสร้างโดเมนปริภูมิที่ดีขึ้นใหม่และการฉายภาพย้อนกลับแบบมีตัวกรองในมุมต่าง ๆ จำนวน 1, 2, 4, 8, 16, 32, 64, 256 และ 1024 ครั้ง

(ที่มา : Dance D.R., Christofides S., Maidment A.D.A, McLean I.D. and Ng K.H. Diagnostic radiology physics: A handbook for teachers and students. Vienna : International Atomic Energy Agency, 2014.)



รูปที่ 2.14 แสดงไซน์แกรมของวัตถุจำลองซึ่งถูกสร้างขึ้นโดยการคำนวณการแปลงเรดอน ผลลัพธ์ถูกสร้างขึ้นใหม่โดยใช้การฉายย้อนกลับและขั้นตอนวิธีการฉายย้อนกลับแบบกรอง

(ที่มา : Vamvakeros, A., Operando chemical tomography of packed bed and membrane reactors for methane processing., 2017. PhD Thesis. UCL (University College London))



รูปที่ 2.15 ลักษณะทางเรขาคณิตของการสร้างปริมาณรังสีส่งผ่าน พิกัดคาร์ทีเซียน  $(x, y)$  ใช้กับปริภูมิภาพ  $f$  พิกัดที่ใช้กับการฉายภาพ  $p$  คือ  $t$  ซึ่งเป็นระยะทางจากรังสีเอกซ์ที่ฉายไปยังจุดไอโซเซนเตอร์ และ  $\theta$  คือ มุมการฉายภาพ

(ที่มา : Dance D.R., Christofides S., Maidment A.D.A, McLean I.D. and Ng K.H. Diagnostic radiology physics: A handbook for teachers and students. Vienna : International Atomic Energy Agency, 2014.)

การแปลงฟูเรียร์หนึ่งมิติในส่วนของ  $x$  ของการฉาย  $p(x, 0)$  ที่มุม  $\theta$  เท่ากับ 0 สามารถอธิบายได้ว่า

$$P(u) = \int_{-\infty}^{+\infty} p(x, 0) e^{-i2\pi ux} dx = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) e^{-i2\pi ux} dx dy \quad (2.12)$$

และ การแปลงฟูเรียร์สองมิติ ( $F(u, v)$ ) ของปริภูมิภาพสองมิติ ( $f(x, y)$ ) ที่  $v=0$  คือ

$$\begin{aligned} F(u, v)|_{v=0} &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) e^{-i2\pi(ux+vy)} dx dy |_{v=0} \\ &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) e^{-i2\pi ux} dx dy \end{aligned} \quad (2.13)$$

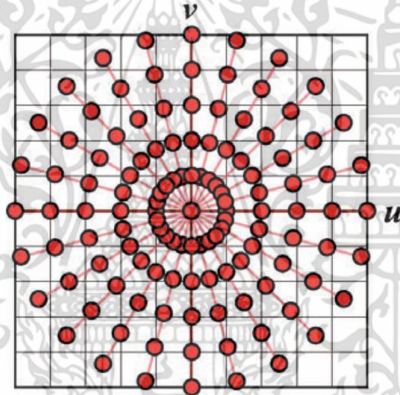
ดังนั้นจึงเป็นที่ชัดเจนว่าการแปลงฟูเรียร์หนึ่งมิติใน  $x$  ของการฉายที่มุม  $\theta = 0$  เทียบเท่ากับ การแปลงฟูเรียร์สองมิติ ( $F(u, v)$ ) ของปริภูมิภาพสองมิติ ( $f(x, y)$ ) ที่  $v=0$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$P(u) = F(u, v)|_{v=0} \quad (2.14)$$

ทำให้สามารถสรุปได้ว่า การสร้างภาพใหม่สามารถทำได้โดยเริ่มจากการสร้างปริภูมิฟูเรียร์สองมิติ ( $F(u, v)$ ) โดยฟูเรียร์หนึ่งมิติหลาย ๆ ตัวของปริมาณรังสีการฉายที่วัดภายใต้มุมการฉายต่าง ๆ ตามด้วยฟูเรียร์ผกผันสองมิติในปริภูมิภาพสองมิติ

การสุ่มปริภูมิฟูเรียร์สองมิติจากฟูเรียร์หนึ่งมิติของการฉายทำให้ได้ปริภูมิฟูเรียร์สองมิติในพิกัดขั้วปกติ ก่อนทำฟูเรียร์ผกผันสองมิติในปริภูมิภาพ จุดกระจายปกติในปริภูมิฟูเรียร์สองมิติเชิงขั้วจะต้องถูกแปลงเป็นจุดกระจายอย่างสม่ำเสมอในปริภูมิฟูเรียร์สองมิติแบบคาร์ทีเซียน การแปลงจากเชิงขั้วไปเป็นคาร์ทีเซียนอาจสร้างอาร์ติแฟกในภาพที่สร้างขึ้นใหม่ได้ เนื่องจากข้อเท็จจริงที่ว่า การสุ่มตัวอย่างปริภูมิฟูเรียร์แบบสองมิตินั้นหนาแน่นกว่าตรงบริเวณรอบจุดกำเนิด (ความถี่ต่ำ) และการสุ่มตัวอย่างจะห่างจากจุดกำเนิด (ความถี่สูง) มากขึ้นเรื่อย ๆ (รูปที่ 2.16)



รูปที่ 2.16 การสแกน CT ให้การสุ่มตัวอย่างแบบกระจายอย่างสม่ำเสมอในพิกัดเชิงขั้วของปริภูมิฟูเรียร์ 2 มิติ การแปลงเป็นการสุ่มแบบกระจายปกติในพิกัดคาร์ทีเซียนนั้นซับซ้อน โดยเฉพาะอย่างยิ่งที่ความถี่สูง (ห่างจากจุดกำเนิด)

(ที่มา : Dance D.R., Christofides S., Maidment A.D.A, McLean I.D. and Ng K.H. Diagnostic radiology physics: A handbook for teachers and students. Vienna : International Atomic Energy Agency, 2014.)

เพื่อให้ความถูกต้องเพิ่มขึ้นและสามารถใช้งานได้จริง จึงใช้การฉายย้อนกลับแบบกรอง วิธีนี้เริ่มด้วยฟูเรียร์หนึ่งมิติในปริภูมิภาพ จากนั้นสร้างปริภูมิฟูเรียร์ที่สอดคล้องขึ้น แต่การสุ่มปริภูมิฟูเรียร์สองมิติ ( $F(u,v)$ ) แสดงบนตารางเชิงขั้วโดยใช้การแปลงพิกัด ดังนี้

$$u = \omega \cos \theta \quad (2.15)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$v = \omega \sin \theta \quad (2.16)$$

การสร้างภาพขึ้นใหม่ ด้วยเทคนิคการฉายย้อนกลับแบบกรอง สามารถเขียนได้ว่า

$$f(x, y) = \int_0^\pi \int_{-\infty}^{+\infty} P(\omega, \theta) |\omega| e^{i2\pi\omega t} d\theta d\omega \quad (2.17)$$

โดยที่  $P(\omega, \theta)$  คือ การแปลงฟูเรียร์หนึ่งมิติของการฉายภาพหนึ่งมิติที่มุม  $\theta$  และ  $|\omega|$  เรียกว่าตัวกรองสัญญาณรบกวนในโดเมนความถี่

ในทางปฏิบัติ สามารถใช้ตัวกรองต่างชนิดกันในการสร้างภาพขึ้นใหม่ได้ขึ้นอยู่กับคุณลักษณะภาพที่ต้องการ ตัวกรองหรือเคอร์เนลสังวัตนาการ ในการฉายย้อนกลับแบบกรองซึ่งในทางทฤษฎีแล้วการสร้างใหม่ที่เหมาะสมที่สุด คือ ตัวกรองแรมป์ (Ramp Filter) ให้ความละเอียดเชิงพื้นที่ที่ดีที่สุดในการสร้างขึ้นใหม่ อย่างไรก็ตามตัวกรองชนิดนี้ยังให้ระดับสัญญาณรบกวนที่ค่อนข้างสูงในภาพที่สร้างใหม่อีกด้วย ตัวกรองที่ 'ดีที่สุด' ในทางทฤษฎีดังกล่าวในทางคลินิกเรียกว่าตัวกรองชาร์ป (Sharp) หรือกระดูก (Bone) บ่อยครั้งที่มีการใช้ตัวกรองเพื่อลดระดับสัญญาณรบกวนในภาพที่สร้างใหม่

### 2.1.2.3. การสร้างใหม่แบบวนซ้ำ (Iterative Reconstruction)

ขั้นตอนวิธีแบบวนซ้ำนี้เรียกว่าเทคนิคการสร้างภาพใหม่โดยอาศัยพีชคณิต (Algebraic Reconstruction Technique : ART) แสดงให้เห็นสำหรับชิ้นส่วนเมทริกซ์  $2 \times 2$  ในรูปที่ 2.17ข-2.17จ รูปที่ 2.17ข แสดงค่าการลดทอนของพิกเซลจริงในวงเล็บ ซึ่งแน่นอนว่าไม่ทราบก่อนสร้างใหม่ และค่าการวัดที่ได้มาแต่ละรายการ กระบวนการเริ่มต้นด้วยการวัดมุมมองแรก ( $l_1 = 12$  และ  $l_2 = 12$ ) และสมมติว่าค่าการลดทอนเหล่านี้เกิดขึ้นอย่างสม่ำเสมอตามแนวรังสี ทำให้ได้ค่าประมาณภาพแรก (รูปที่ 2.17ค) ต่อไป การวัดมุมมองที่สองจะถูกนำมาใช้ ( $l_3$  และ  $l_4$ ) และค่าเหล่านี้จะถูกเปรียบเทียบกับค่าการลดทอนรวมที่เกิดขึ้นหากค่าประมาณแรกถูกต้อง ค่าประมาณทำนายว่า  $l_3$  และ  $l_4$  แต่ละอันควรมีค่าเท่ากับ 12 (รูปที่ 2.17ค) ค่าที่วัดได้จริง คือ 16 และ 8 ตามลำดับ ถัดไปค่าประมาณแรกจะปรับให้ตรงกับค่าจริงของ  $l_3$  และ  $l_4$  ดังนั้น การปรับสำหรับการวัดแต่ละครั้งของมุมมองที่สองจะคำนวณโดยการลบค่าที่คาดการณ์ไว้โดยการประมาณการครั้งแรกออกจากค่าจริง ในกรณีนี้  $16-12 = +4$  สำหรับ  $l_3$  และ  $8-12 = -4$  สำหรับ  $l_4$

การปรับค่าเหล่านี้จะถูกแบ่งเท่า ๆ กันตามแนวรังสีโดยบวก 2 เข้ากับ  $\mu_1$  และ  $\mu_2$  (ปรับทั้งหมดเป็น +4) และลบ 2 ออกจาก  $\mu_3$  และ  $\mu_4$  (ปรับทั้งหมดเป็น -4) ทำให้ได้ค่าประมาณที่สอง (รูปที่ 2.17ง) กระบวนการนี้ดำเนินต่อไปในลักษณะนี้โดยค่าจริงสำหรับแต่ละมุมมองจะถูกเปรียบเทียบกับค่าที่คาดการณ์โดยการประมาณการล่าสุด สำหรับมุมมองที่สาม (การวัด 5) ค่าประมาณที่สองทำนายค่าการลดทอนที่  $12 (8 + 4)$  ค่าจริง คือ 14 ดังนั้น การปรับทั้งหมด +2 จะ



สองของจำนวนโฟตอนที่มีส่วนในการวัด

องค์ความรู้นี้ (Poisson Distribution) สามารถอธิบายปัญหาเกี่ยวกับ ART ได้ว่า ไม่มีวิธีการประเมินว่าภาพที่ ART สร้างขึ้นจะตรงกับการวัดทั้งหมดอย่างแน่นอน เนื่องจากการวัดมีข้อผิดพลาดแบบสุ่ม ดังนั้น ART มักถูกยกเลิกหลังจากพบค่าประมาณที่ตรงกับการวัดทั้งหมดภายในค่าความคลาดเคลื่อนที่ยอมรับได้เท่านั้น [20]

### 2.1.3 คุณภาพของภาพซีที (CT Image Quality)

ความละเอียดของความเปรียบต่างต่ำที่ข้อยืดหยุ่นของภาพ CT คือ ลักษณะเด่นที่สุดที่ทำให้การถ่ายภาพเอกซเรย์คอมพิวเตอร์แตกต่างจากการถ่ายภาพรังสีรูปแบบอื่น ๆ ที่ไม่ใช่โทโมกราฟี ความละเอียดของความเปรียบต่างต่ำเป็นความสามารถในการตรวจจับโครงสร้างที่ให้ความแตกต่างของสัญญาณเพียงเล็กน้อยเมื่อเทียบกับสภาพแวดล้อมโดยตรง สัญญาณรบกวนเป็นข้อจำกัดหลักของความละเอียดของความเปรียบต่างต่ำและอาจลดลงได้ด้วยการเพิ่มคุณภาพภาพโดยใช้กลยุทธ์ต่าง ๆ โดยทั่วไป พารามิเตอร์หลักในกระบวนการเอกซเรย์คอมพิวเตอร์ คือ ค่าแรงดัน ค่ากระแสไฟฟ้า เวลาในการหมุน [14] ความหนาของสไลด์ ขอบเขตการมอง และจำนวนการฉายรังสี โดยมีรายละเอียดดังต่อไปนี้

#### 2.1.3.1. แรงดันไฟฟ้า (kV)

การใช้ค่าแรงดันที่สูงในช่วง 120-140 kV ช่วยให้รังสีส่งผ่านได้ดีและสร้างสัญญาณที่อุปกรณ์ตรวจจับสามารถเก็บรวบรวมได้อย่างเพียงพอ ทำให้ได้ภาพที่คมชัด สำหรับการใช้งานแบบพิเศษ อย่างการศึกษาเพิ่มความคมชัดและการตรวจในแผนกกุมารเวชศาสตร์ อาจใช้แรงดันน้อยลงมาเป็นในช่วง 80-100 kV แม้ว่าจากการศึกษาจะแสดงให้เห็นว่าการใช้แรงดันต่ำจะทำให้สัญญาณรบกวนในภาพเพิ่มขึ้นแต่ก็ช่วยให้ปริมาณรังสีที่ต้องใช้ลดลงอย่างมีนัยสำคัญ โดยไม่ทำให้คุณภาพของภาพลดลงมากจนเกินไป [21-22]

#### 2.1.3.2. กระแสไฟฟ้าที่ผ่านหลอดรังสีเอกซ์กับเวลาที่ปล่อยรังสี (mAs)

ค่าพารามิเตอร์นี้ คือ การวัดกระแสไฟฟ้าหรือพลังงานรังสี (ในหน่วยมิลลิแอมแปร์) ที่ผลิตในช่วงเวลาที่กำหนด (วินาที) ผ่านหลอดเอกซเรย์ ค่าที่กำหนดส่งผลต่อปริมาณรังสีที่คนไข้จะได้รับ รวมถึงสัญญาณรบกวนภายในภาพที่สร้างขึ้นใหม่

การตั้งค่ากระแสไฟฟ้าน้อยอาจทำให้ภาพที่ได้มีสัญญาณรบกวนจำนวนมาก หากเพิ่มค่ากระแสไฟฟ้านั้นจะช่วยเพิ่มคุณภาพและความคมชัดให้กับภาพเอกซเรย์คอมพิวเตอร์ด้วยสัญญาณรบกวนที่เกิดขึ้นน้อยลง (รูปที่ 2.18) แต่ในเวลาเดียวกันก็เพิ่มปริมาณรังสีที่คนไข้จะได้รับ ถือว่าเป็นปัจจัยเสี่ยงต่อสุขภาพของคนไข้ ดังนั้นค่ากระแสไฟฟ้าจึงถูกจำกัดโดยการพิจารณาปริมาณรังสีของคนไข้รวมไปถึงเวลาสแกนที่นานและความจุความร้อนของหลอดรังสีเอกซ์ และเพื่อหลีกเลี่ยงอาร์ติแฟก


เนื่องจากการเคลื่อนไหวเวลาในการหมุนควรวัดที่เท่าที่จะเป็นไปได้

### 2.1.3.3. ความหนาของสไลด์ (Slice Thickness)

ความหนาของสไลด์ คือ ความหนาของภาพที่สร้างขึ้นใหม่ เอเลเมนต์ของอุปกรณ์ตรวจจับเป็นตัวกำหนดความหนาของภาพสไลด์เอกซเรย์คอมพิวเตอร์ในกระบวนการสร้างภาพ ความหนาจะเป็นสัดส่วนผกผันกับปริมาณรังสีที่คนไข้ได้รับ ดังนั้นหากกำหนดค่าความหนาของสไลด์น้อยความละเอียดเชิงพื้นที่หรือก็คือจำนวนข้อมูลภายในภาพจะมีอยู่สูง สามารถมองเห็นภาพภายในร่างกายได้อย่างชัดเจน แต่ในเวลาเดียวกันก็ทำให้สัญญาณรบกวนในภาพเพิ่มขึ้น (รูปที่ 2.19) อีกทั้งยังเพิ่มจำนวนภาพสไลด์ในการสแกนหนึ่งครั้ง ทำให้ต้องใช้พื้นที่หน่วยความจำในเครื่องคอมพิวเตอร์มากขึ้น


การกำหนดค่าความหนาสูงเหมาะกับงานที่มีความต้องการรายละเอียดโครงสร้างสูง เช่น โครงสร้างภายในหูชั้นในหรือพยาธิสภาพภายในเนื้อปอด (Lung Parenchyma) และต้องการนำเสนอในรูปแบบสามมิติ ส่วนค่าความหนาน้อยเหมาะกับงานศึกษาเนื้อเยื่ออ่อนทั่วไปที่ดำเนินการประมวลผลภาพแบบสองมิติภายหลังกระบวนการสร้างภาพ

นอกจากนี้ระยะห่าง (หน่วยมิลลิเมตร) ระหว่างจุดกึ่งกลางสไลด์ภาพที่สร้างขึ้นใหม่ที่อยู่ติดกัน (Increment/Interval) ในทิศทาง z (รูปที่ 2.20) ก็เป็นอีกเงื่อนไขหนึ่งที่ส่งผลต่อคุณภาพของภาพเอกซเรย์คอมพิวเตอร์ หากกำหนดความหนาสไลด์น้อยกว่าระยะห่าง (รูปที่ 2.20ข) ก็มีโอกาสรายละเอียดบางส่วนหล่นหายหรือไม่ชัดเจนเนื่องจากช่องว่างที่เกิดขึ้น มักเกิดขึ้นบ่อยครั้งกับชิ้นส่วนหรือรอยโรคที่มีขนาดเล็ก ในขณะที่ถ้ากำหนดความหนามากกว่าระยะห่าง (รูปที่ 2.20ค) จะสร้างภาพที่ซ้อนทับกันให้รายละเอียดทางกายวิภาคศาสตร์ที่ดีขึ้น ตลอดจนการประมวลผลภายหลังแบบสองมิติและสามมิติคุณภาพสูง เนื่องจากสามารถเก็บรายละเอียดของชิ้นส่วนเล็ก ๆ ที่มีโอกาสหลุดรอดสายตาหรือไม่ชัดเจนไปได้ เช่น รอยโรคขนาดเล็ก [23]




รูปที่ 2.18 เปรียบเทียบผลกระทบของการตั้งกระแสไฟฟ้า (ก) กระแสไฟฟ้าต่ำได้ภาพที่มีสัญญาณรบกวนมาก และ (ข) กระแสไฟฟ้าสูงได้ภาพที่มีสัญญาณรบกวนน้อย

(ที่มา : Utumporn Puangragsa, CT image for radiotherapy planning [Slide], Medicine Siriraj Hospital)



รูปที่ 2.19 เปรียบเทียบผลกระทบกรณีกำหนดค่าความหนาของสไลด์ (ก) ความหนาน้อยมีความละเอียดเชิงพื้นที่สูง แต่สัญญาณรบกวนสูง และ (ข) ความหนามากมีความละเอียดเชิงพื้นที่น้อยและสัญญาณรบกวนน้อย  
 (ที่มา : Utumporn Puangragsa, CT image for radiotherapy planning [Slide], Medicine Siriraj Hospital)



รูปที่ 2.20 การกำหนดค่าความหนาสไลด์กับระยะห่างระหว่างกึ่งกลางสไลด์ (ก) ตั้งให้เท่ากัน (ข) ตั้งความหนาน้อยกว่า และ (ค) ตั้งความหนามากกว่า  
 (ที่มา : <https://www.youtube.com/watch?v=KGPSH4GiHLw>)


2.1.3.4. ขอบเขตการมอง

พารามิเตอร์ขอบเขตการมองทำหน้าที่กำหนดพื้นที่ของกายวิภาคที่แสดงภายในภาพ เอกซเรย์คอมพิวเตอร์ตลอดจนความละเอียดเชิงพื้นที่ ความละเอียดเชิงพื้นที่โดยปกติจะเพิ่มขึ้นด้วยการตั้งค่าขอบเขตการมองน้อย ๆ เพราะยิ่งค่าน้อยขนาดของพิกเซลจะยิ่งเล็กลง ขนาดพิกเซลสามารถคำนวณด้วยสมการ


$$Pixel\ size = \frac{FOV}{Matrix\ size} \tag{2.18}$$

เช่น ตั้ง FOV เท่ากับ 40 cm สร้างภาพขนาดเมทริกซ์เท่ากับ 512x512 จะได้ขนาด

พิกเซล คือ 0.78 มิลลิเมตร แต่ถ้า FOV เท่ากับ 8 cm จะได้ขนาดพิกเซลเท่ากับ 0.16 มิลลิเมตร (ตามรูปที่ 2.21).



(ก)



(ข)

**รูปที่ 2.21** ตัวอย่างผลลัพธ์การตั้งค่า FOV (ก) 40 เซนติเมตร และ (ข) 8 เซนติเมตร (ที่มา : Utumporn Puangragsa, CT image for radiotherapy planning [Slide], Medicine Siriraj Hospital)

#### 2.1.3.5. จำนวนการฉายรังสี (Number Projections) และเวลาฉายรังสี (Scan Time)

จากเนื้อหาที่ได้กล่าวมาเบื้องต้น ยังทำการฉายรังสีหลายรอบ ภาพที่สร้างขึ้นใหม่ที่ได้ก็จะยิ่งชัดเจนและมีความละเอียดสูง แต่ก็ทำนองเดียวกับการเพิ่มกระแสไฟในหลอดเอกซเรย์ กล่าวคือคนไข้จะได้รับปริมาณรังสีสูงด้วยเช่นกัน [24]

#### 2.1.4 ความสัมพันธ์เชิงระนาบของภาพเอกซเรย์คอมพิวเตอร์


หลังจากผ่านกระบวนการสร้างภาพใหม่จะได้รับภาพดิจิทัลที่มีรายละเอียดของโครงสร้างภายในร่างกาย คือ ชุดข้อมูลเอกซเรย์คอมพิวเตอร์ (CT Scan) เป็นชุดข้อมูลสามมิติ อันประกอบไปด้วยภาพสไลด์สองมิติจำนวนนับร้อย ๆ สไลด์เรียงลำดับกันไปตามแนวระนาบสามระนาบ ได้แก่ ระนาบในแนวตั้งแบ่งซ้ายขวา (Sagittal Plane) (รูป 2.22ข) ระนาบตามแกน (Axial Plane) (รูป 2.22ค) และระนาบแบ่งหน้าหลัง (Coronal Plane) (รูป 2.22ง) ในรูปที่ 2.22ก แสดงให้เห็นความสัมพันธ์เชิงพิกัดเชื่อมโยงกันของภาพสไลด์ของทั้งสามแกนระนาบ เห็นได้ว่าองค์ประกอบต่าง ๆ ภายในแต่ละภาพของแต่ละระนาบสามารถเชื่อมต่อกันได้พอดีซึ่งภายหลังสามารถนำมาสร้างเป็นโครงสร้างสามมิติผ่านขั้นตอนวิธีเชิงเรขาคณิต เพื่อใช้ในการวิเคราะห์ทางการแพทย์ได้ นอกจากนี้ในการดำเนินการบนภาพสไลด์ เช่น การตัดขอบเพื่อลดขนาดภาพสไลด์ จำเป็นต้องพิจารณาถึงความสัมพันธ์นี้ขณะกำหนดพิกัดต้นกำเนิดของกรอบภาพด้วย เพื่อป้องกันความคลาดเคลื่อนระหว่างกระบวนการสร้างโครงสร้างสามมิติขึ้นมาใหม่

หากสมมติให้ภาพสไลด์ของแต่ละระนาบประกอบด้วยแกน  $x$  (แกนตามแนวนอน) และแกน  $y$  (แกนตามแนวตั้ง) ความสัมพันธ์เชิงมิติสามารถสรุปได้ดังนี้

1. ค่าพิกัดตามแกน  $x$  ของระนาบตามแกนเทียบเท่ากับลำดับสไลด์ในระนาบในแนวตั้งแบ่ง


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- ซ้ายขวาและค่าพิกัดตามแกน  $x$  ในระนาบแบ่งหน้าหลัง
2. ค่าพิกัดแกน  $y$  ของระนาบตามแกนเทียบเท่ากับลำดับสไลด์ในระนาบแบ่งหน้าหลังและค่าพิกัดแกน  $x$  (หรือ แกน  $Y$  ตามรูปที่ 2.22ค) ในระนาบในแนวตั้งแบ่งซ้ายขวา
  3. ค่าพิกัดแกน  $y$  (หรือ แกน  $Z$  ตามรูปที่ 2.22ข) ของระนาบในแนวตั้งแบ่งซ้ายขวาเทียบเท่ากับลำดับสไลด์ในระนาบตามแกนและค่าพิกัดแกน  $y$  (หรือ แกน  $Z$  ตามรูปที่ 2.22ง) ของระนาบแบ่งหน้าหลัง




รูปที่ 2.22 ความสัมพันธ์เชิงพิกัดระหว่างสามระนาบของภาพถ่ายเอกซเรย์คอมพิวเตอร์ (ก) ตัวอย่างการวางตำแหน่งภาพสไลด์บนทั้งสามระนาบซึ่งทุกส่วนสามารถเชื่อมต่อกันได้พอดี (ข) ภาพสไลด์บนระนาบในแนวตั้งแบ่งซ้ายขวา (ค) ภาพสไลด์บนระนาบตามแกน (ง) ภาพสไลด์บนระนาบแบ่งหน้าหลัง


ในรูป 2.23ข แสดงลำดับสไลด์ของระนาบในแนวตั้งแบ่งซ้ายขวา โดยพิกัดที่ 0 ( $x_0$ ) คือจุดเริ่มต้นของแต่ละแกนที่สไลด์ลำดับ 100, 200, 300 และ 400 ( $Slice_{100}, Slice_{200}, Slice_{300}$  และ  $Slice_{400}$ ) ตรงกับพิกัดแกน  $x$  ของระนาบตามแกนที่ 100, 200, 300 และ 400 ( $x_{100}, x_{200}, x_{300}$  และ  $x_{400}$ ) รูป 2.23ง แสดงลำดับสไลด์ของระนาบแบ่งหน้าหลัง โดยพิกัดที่ 0 ( $y_0$ ) คือจุดเริ่มต้นของแต่ละแกนที่สไลด์ลำดับ 100, 200, 300 และ 400 ( $Slice_{100}, Slice_{200}, Slice_{300}$  และ  $Slice_{400}$ ) ตรงกับพิกัดแกน  $y$  ของระนาบตามแกนที่ 100, 200, 300 และ 400 ( $y_{100}, y_{200}, y_{300}$  และ  $y_{400}$ ) และรูปที่ 2.23จ แสดงให้เห็นว่าพิกัดแกน  $y$  ของระนาบในแนวตั้งแบ่งซ้ายขวาและระนาบแบ่งหน้าหลังที่พิกัด 45, 75 และ 100 ( $y_{45}, y_{75}$  และ  $y_{100}$ ) ตรงกับลำดับของสไลด์ในระนาบตามแกนที่ลำดับ 45, 75 และ 100 ( $Slice_{45}, Slice_{75}$  และ  $Slice_{100}$ )




(ก)



(ข)




(ค)



(ง)

Y-coordinate of sagittal plane

Y-coordinate of coronal plane



(จ)

รูปที่ 2.23 (ก) ค่าพิกัดตามแกน x ของระนาบตามแกนเทียบเท่ากับค่าพิกัดตามแกน x ในระนาบแบ่งหน้าหลัง (ข) ค่าพิกัดตามแกน x ของระนาบตามแกนเทียบเท่ากับลำดับสไลด์ในระนาบในแนวตั้งแบ่งซ้ายขวา (ค) ค่าพิกัดแกน y ของระนาบตามแกนเทียบเท่ากับค่าพิกัดแกน x ในระนาบในแนวตั้งแบ่งซ้ายขวา (ง) ค่าพิกัดแกน y ของระนาบตามแกนเทียบเท่ากับลำดับสไลด์ในระนาบแบ่งหน้าหลัง และ (จ) ค่าพิกัดแกน y ของระนาบในแนวตั้งแบ่งซ้ายขวาและระนาบแบ่งหน้าหลังเทียบเท่ากับลำดับสไลด์ในระนาบตามแกน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2.1.5 โครงสร้างของแฟ้มข้อมูลภาพถ่ายเอกซเรย์คอมพิวเตอร์

### 2.1.5.1 Digital Imaging and Communications in Medicine (DICOM)

ไฟล์ไดคอม (DICOM) หรือ .dcm เป็นโปรโตคอลมาตรฐานที่ได้รับการยอมรับในระดับสากลสำหรับการจัดการ การจัดเก็บ การพิมพ์ และการส่งข้อมูลภาพถ่ายทางการแพทย์ชนิดต่าง ๆ อาทิ ภาพเอกซเรย์คอมพิวเตอร์ ภาพอัลตราซาวด์ หรือภาพเอ็มอาร์ไอ (Magnetic Resonance Imaging : MRI) เป็นต้น รูปแบบไฟล์ไดคอมมีความเป็นรูปแบบเดียวกัน และสามารถส่งข้อมูลกับภาพถ่ายไปยังระบบที่สามารถรองรับไฟล์นามสกุลไดคอมผ่านเครือข่ายได้ ซึ่งทำให้ไฟล์ตัวนี้สามารถรวมเข้ากับระบบเครือข่ายข้อมูลหรือบันทึกข้อมูลทางการแพทย์ที่มีขนาดใหญ่กว่าได้

ภายในไฟล์บรรจุด้วยข้อมูลระบุตัวผู้ป่วย หมายเลขอ้างอิง ระบบพิกัดอ้างอิง วันที่ รายงานบันทึก แอตทริบิวต์ของรูปภาพซึ่งครอบคลุมถึงขนาดพิกเซล และตัวรูปภาพเอง ที่สำคัญภายในขอบเขตของไฟล์ไดคอมข้อมูลเมตา (ข้อมูลคนไข้และคำอธิบายที่สมบูรณ์ที่สุดของขั้นตอนทั้งหมดที่ใช้ในการสร้างภาพที่เกิดขึ้นในแง่ของโปรโตคอลการได้ข้อมูลมาและพารามิเตอร์ในขั้นตอนสร้างภาพ) และข้อมูลพิกเซล (ข้อมูลรูปภาพ) ไม่สามารถแยกออกจากกันได้ ดังนั้น ภาพไดคอมจึงสามารถระบุตัวผู้ป่วยที่ตรวจได้เสมอ ไฟล์มักจะมีขนาดค่อนข้างใหญ่ไม่เกิน 30 เมกะไบต์ ซึ่งสามารถบีบอัดไฟล์เพื่อลดขนาดภาพโดยใช้โปรโตคอลแบบไม่สูญเสียข้อมูล การตรวจสอบภาพไดคอมจำเป็นต้องใช้ซอฟต์แวร์ที่สอดคล้องกับไฟล์ตัวนี้ ซึ่งพบได้ทั้งที่สถานีตรวจวัดภาพรังสีวิทยาแบบดิจิทัลและเวิร์กสเตชันตรวจสอบภาพ [25-26]

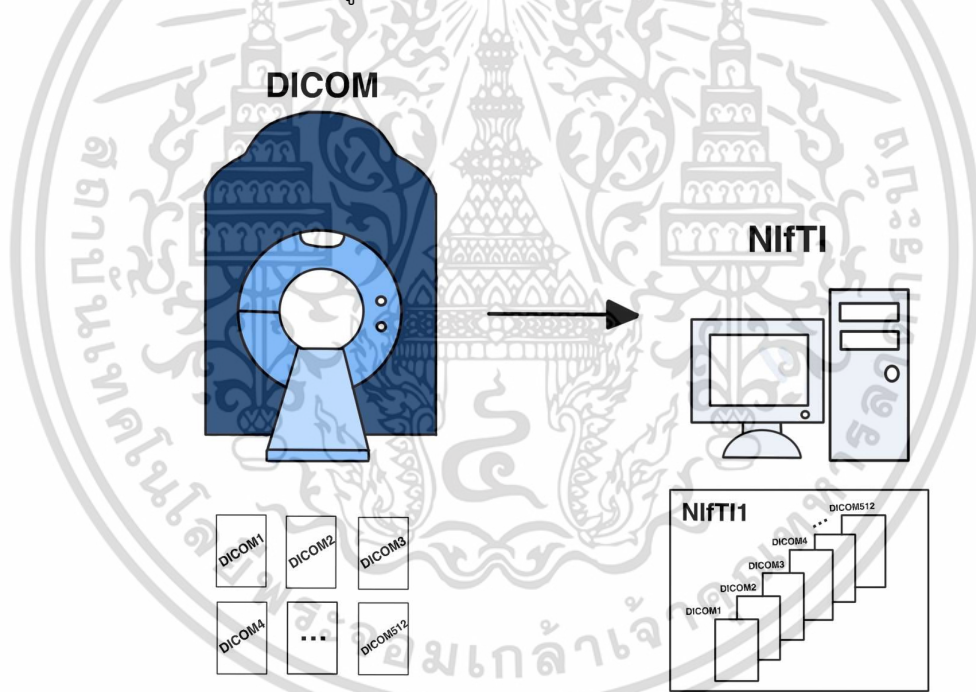
### 2.1.5.2 Neuroimaging Informatics Technology Initiative (NifTI)

นิฟตี (NifTI) เป็นรูปแบบไฟล์ที่สร้างขึ้นเมื่อต้นทศวรรษ 2000 โดยคณะกรรมการประจำสถาบันสุขภาพแห่งชาติ มีวัตถุประสงค์เพื่อสร้างรูปแบบสำหรับการสร้างภาพระบบประสาทโดยยังคงข้อดีของรูปแบบการวิเคราะห์ไว้ ขณะที่กำลังจุดอ่อนไป ไฟล์นิฟตีสามารถมองว่าเป็นรูปแบบการวิเคราะห์ที่ปรับปรุงขึ้นใหม่ รูปแบบนี้เติมฟิลด์บางส่วนที่ไม่ได้ใช้หรือใช้น้อยซึ่งมีอยู่ในส่วนหัวของโปรแกรมวิเคราะห์ 7.5 เพื่อจัดเก็บข้อมูลใหม่ เช่น การวางแผนภาพโดยมีเจตนาที่จะหลีกเลี่ยงความคลุมเครือจากซ้าย-ขวาในการศึกษาสมอง นอกจากนี้นิฟตียังรองรับประเภทข้อมูลที่ไม่ได้พิจารณาในรูปแบบวิเคราะห์ เช่น 16 บิตที่ไม่ได้พิจารณาค่าลบ (unsigned 16-bit) แม้ว่ารูปแบบจะอนุญาตให้จัดเก็บข้อมูลส่วนหัวและข้อมูลพิกเซลในไฟล์แยกกัน แต่โดยทั่วไปแล้วรูปภาพจะถูกบันทึกเป็นไฟล์ “.nii” ไฟล์เดียวซึ่งส่วนหัวและข้อมูลพิกเซลถูกรวมเข้าด้วยกัน

รูปแบบนิฟตีช่วยให้สามารถจัดเก็บการวางแผนของปริมาณภาพในพื้นที่ได้สองทาง อันแรกประกอบด้วยการหมุนและการเลื่อนเพื่อใช้ในการฝังพิกัดวอกเซลกับกรอบอ้างอิงของสแกนเนอร์ การเปลี่ยนแปลง “วัตถุแข็งแรง” นี้เข้ารหัสโดยใช้ "ควอเทอร์เนียน" วิธีที่สองใช้เพื่อบันทึกพารามิเตอร์ 12 ตัวของการแปลงเชิงเส้นทั่วไป ซึ่งกำหนดการจัดตำแหน่งของโครงข้อมูลภาพให้เป็นระบบพิกัดมาตรฐานหรือแม่แบบ

รูปแบบนิฟตีได้เข้ามาแทนที่การวิเคราะห์ในการวิจัยภาพทางประสาทอย่างรวดเร็วโดยถูกนำมาใช้เป็นรูปแบบเริ่มต้นโดยชุดซอฟต์แวร์สาธารณสุขสมบัติที่แพร่หลายมากที่สุด เช่น FSL, SPM และ AFNI รูปแบบนี้รองรับโดยโปรแกรมดูและซอฟต์แวร์วิเคราะห์ภาพมากมาย เช่น 3D Slicer, ImageJ และ OsiriX [27]

ปกติไฟล์นิฟตีจะถูกแปลงมาจากไฟล์ไดคอม เมื่อเทียบกับไฟล์ไดคอมที่ในหนึ่งไฟล์จะบรรจุข้อมูลเมตาเกี่ยวกับข้อมูลสไลด์เอกซเรย์คอมพิวเตอร์เพียงหนึ่งสไลด์ในหนึ่งระนาบเท่านั้น ทำให้ชุดสแกนเอกซเรย์คอมพิวเตอร์หนึ่งชุดมีไฟล์ไดคอมหลายไฟล์ ไฟล์นิฟตีจะบรรจุข้อมูลสไลด์เอกซเรย์คอมพิวเตอร์ทั้งหมดในทุกแกนลงในไฟล์เดียวโดยมีการจัดลำดับไว้ภายในพร้อมเรียกใช้งาน ดังนั้นหากต้องการเรียกเปิดในโปรแกรมสำหรับรันโค้ด เช่น โปรแกรมไพธอน (Python) โดยที่ลำดับสไลด์ไม่มีการเปลี่ยนแปลงหรือเรียงไว้แล้ว รูปแบบไฟล์นิฟตีจะเหมาะสมต่อการเรียกใช้มากกว่า รูปที่ 2.24 แสดงผังการแปลงนามสกุลไฟล์จากเริ่มต้นด้วยไฟล์ไดคอมจากเครื่องสแกนไปเป็นไฟล์นิฟตีก่อนแสดงบนจอมอนิเตอร์และลักษณะข้อมูลแบบที่เป็นไดคอม (แยกไฟล์) กับแบบนิฟตี (รวมไฟล์)



รูปที่ 2.24 ผังการแปลงนามสกุลไฟล์และลักษณะไฟล์ข้อมูลของ DICOM กับ NifTi

## 2.2 การแบ่งส่วนรูปภาพทางการแพทย์ (Medical Image Segmentation)

การแบ่งส่วน (Segmentation) คือ การแยกพิกเซลหรือพื้นที่ที่ต้องการออกมาจากส่วนอื่น ๆ ในภาพเพื่อการวิเคราะห์ในขั้นตอนต่อไปถือว่าเป็นส่วนสำคัญของขั้นตอนกระบวนการประมวลผลภาพทางการแพทย์ส่วนใหญ่ โดยทั่วไปการแบ่งส่วนสามารถแบ่งได้ 2 ประเภท ประเภทแรกคือพื้นที่ที่สนใจ (Region of Interest) เป็นอวัยวะหรือบริเวณทั่ว ๆ ไป เช่น สมองหรือตับ ประเภทที่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สองเป็นส่วนเฉพาะ เช่น เนื้องอกหรือรอยโรคที่ปรากฏในอวัยวะนั้น ๆ ซึ่งประเภทแรกใช้เพื่อทำให้ภาพเป็นบรรทัดฐาน (Normalization) หรือไม่ก็ระบุตำแหน่งของโรคตามอวัยวะที่มันตั้งอยู่ ส่วนประเภทที่สองใช้เพื่อกำหนดพื้นที่ที่สนใจจากคุณลักษณะที่สกัดออกมา [28]

ผลลัพธ์จากการแบ่งส่วนภาพระบุค่านิยามหรือฉลากลงไปในแต่ละพิกเซลของวัตถุที่สนใจหรือวัตถุเฉพาะ แบ่งแยกเป็นพื้นหน้า-พื้นหลัง ซึ่งรูปแบบของค่านิยามสามารถแบ่งได้หลายแบบ เช่น แบบไบนารี ค่านิยามหรือฉลากมักอยู่ในรูปแบบ 0 สำหรับพื้นหลังและ 1 เป็นพื้นหน้า ในกรณีของการแบ่งส่วน K อาร์เรย์ (K-ary Segmentation) จะประกอบด้วยฉลาก 1-K โดย K คือ จำนวนของภาพวัตถุเป้าหมายที่ตัดแบ่ง เป็นต้น

ในอีกมุมหนึ่งสามารถจำแนกเทคนิคของกระบวนการแบ่งส่วนได้ตามจำนวนการโต้ตอบของผู้ใช้กับระบบการตัดแบ่งกลุ่ม ซึ่งแบ่งออกเป็นแบบแมนนวล แบบกึ่งอัตโนมัติและแบบอัตโนมัติ [29]

### 2.2.1 การแบ่งส่วนแบบแมนนวล (Manual Segmentation)

การแบ่งส่วนแบบแมนนวล คือ กระบวนการที่ผู้ใช้ทำเครื่องหมายระบุพื้นที่ของวัตถุด้วยมือ โดยการวาดคอนทัวร์วัตถุที่ต้องการหรือใช้เทคนิคที่คล้ายคลึงกันเพื่อสร้างพื้นที่คลุมวัตถุ กระบวนการนี้กินเวลาและหากรูปภาพมีองค์ประกอบและโครงสร้างที่ละเอียดและมีความยากในการตีความ เช่น ภาพถ่ายทางการแพทย์ จำเป็นต้องอาศัยความรู้และความเชี่ยวชาญเฉพาะของแพทย์ ดังนั้นแพทย์จึงต้องเป็นผู้ดำเนินการในการกำหนดพื้นที่ส่งผลให้สูญเสียเวลาที่ควรนำไปปฏิบัติหน้าที่ในสถานพยาบาล การวิจัยเวลาในการแบ่งส่วนจะแตกต่างกันไปตามปัจจัยต่าง ๆ เช่น ปริมาณเนื้องอก จำนวนอวัยวะที่สนใจ ความซับซ้อนของบริเวณที่สนใจ และมุมของลำแสง ระยะเวลาการทำคอนทัวร์อยู่ระหว่าง 30 นาที ถึง 12 ชั่วโมง ขึ้นอยู่กับชนิดโรคมะเร็งและระยะโรค อาจต้องใช้เวลา 5 ถึง 10 ชั่วโมงสำหรับการแบ่งส่วนแบบแมนนวลบนภาพสแกนระบบประสาท [30] ใช้เวลาถึง 2 ชั่วโมงสำหรับการแบ่งส่วนหนึ่งโครงสร้างของสมองในภาพ MRI อาจใช้เวลาเป็นสัปดาห์กว่าจะตัดแบ่งโครงสร้างหลักทั้งหมดของสมอง [29]

### 2.2.2 การแบ่งส่วนแบบกึ่งอัตโนมัติ (Semi-automatic Segmentation)

วิธีการแบ่งส่วนแบบกึ่งอัตโนมัติหรือแบบโต้ตอบเป็นแนวทางที่เป็นไปได้อีกทางโดยดึงศักยภาพของทั้งวิธีการแบบอัตโนมัติและแบบแมนนวลออกมารวมกันให้ดีที่สุด อาศัยเทคโนโลยีที่ขับเคลื่อนด้วยขั้นตอนวิธี [30] ในการกำหนดขอบเขตวัตถุอย่างแม่นยำร่วมกับความสามารถของผู้ใช้ที่เข้าใจภาพในระดับสูงและสามารถจดจำวัตถุที่เกี่ยวข้องแต่ละชิ้นและตำแหน่งของวัตถุได้ การแบ่งส่วนแบบกึ่งอัตโนมัติมีจุดมุ่งหมายเพื่อเอาชนะข้อบกพร่องของการแบ่งกลุ่มอัตโนมัติซึ่งอาจล้มเหลวในวัตถุที่มีขอบเขตไม่ชัดเจน ในขณะที่ลดเวลาในการโต้ตอบกับผู้ใช้และหวังลดความแปรปรวนระหว่างผู้ดำเนินการตัดแบ่งคนเดียวกับผู้ดำเนินการหลายคน (Inter- and Intraobserver Variability) แต่อย่างไรก็ตาม ความแปรปรวนระหว่างผู้ดำเนินการก็ยังคงอยู่เนื่องจากการแบ่งส่วนแบบแมนนวลและ

การตั้งค่าของขั้นตอนวิธีจะมีอิทธิพลต่อผลลัพธ์ [28]

เทคนิคหลัก ๆ ในหมวดหมู่นี้มีด้วยกัน 4 เทคนิค ได้แก่ ตั้งระดับเกณฑ์ (Thresholding Method) อิงพื้นที่ (Region-based) อิงเส้นขอบ (Edge-based) และการจัดกลุ่ม (Clustering)

### 2.2.2.1 การแบ่งส่วนโดยตั้งระดับเกณฑ์ (Thresholding Segmentation)

วิธีการตั้งระดับเกณฑ์แบ่งส่วนภาพโดยแบ่งความเข้มภาพออกเป็นสองเขต กำหนดค่าความเข้มที่ต้องการขึ้นมาเพื่อใช้เป็น ‘เกณฑ์’ แบ่งแยกคลาสตามที่ต้องการ การแบ่งส่วนสำเร็จด้วยการรวมกลุ่มพิกเซลที่มีความเข้มมากกว่าเกณฑ์ที่ตั้งไว้ให้อยู่ในคลาสหนึ่ง ส่วนพิกเซลที่เหลือจัดให้อยู่ในอีกคลาสหนึ่ง รูปที่ 2.25 แสดงการแบ่งส่วนด้วยการกำหนดเกณฑ์เท่ากับ 0.4 แยกเป็นภาพไบนารี โดยพื้นที่ของสมองเป็นพื้นหน้า หากมีเกณฑ์มากกว่าหนึ่งค่าเรียกว่า การตั้งระดับหลายเกณฑ์ (Multithresholding) [31]

สามารถเขียนสมการโดยทั่วไปได้ว่า

$$g(x, y) = \begin{cases} 1 & \text{if } f(x, y) > T \\ 0 & \text{if } f(x, y) \leq T \end{cases} \quad (2.19)$$

โดย  $g(x, y)$  คือ ภาพผลลัพธ์  $f(x, y)$  คือ ภาพนำเข้า (Input Image) และ  $T$  คือ ค่าระดับเกณฑ์ที่ตั้งไว้



รูปที่ 2.25 การแบ่งส่วนด้วยเทคนิคตั้งระดับเกณฑ์ (Threshold=0.4)

(ที่มา : Sahoo P. K., Soltani S. and Wong A. K. C., “A survey of thresholding techniques”, Comput.Vis. Graph. Im. Proc., vol. 41, no. 2, pp. 233–260, 1988.)

มีหลายขั้นตอนวิธีสำหรับการเลือกระดับเกณฑ์ เช่น ขั้นตอนวิธีโอซี (Otsu's Algorithm) ขั้นตอนวิธีการตั้งระดับเกณฑ์ตามฮิสโทแกรม เป็นต้น วิธีตั้งระดับเกณฑ์ถือว่าเป็นวิธีที่ง่ายและใช้ได้ผลกับภาพที่โครงสร้างต่าง ๆ มีความเข้มหรือคุณลักษณะเชิงปริมาณอื่น ๆ แตกต่างกันอย่างชัดเจน การ


ตั้งเกณฑ์มักดำเนินการโดยผู้ใช้นั้นมากกว่าแม้มีวิธีแบบอัตโนมัติให้เลือกใช้ การกำหนดด้วยผู้ใช้จะขึ้นอยู่กับประสบการณ์ด้วยสายตาของผู้ใช้เอง การกำหนดเกณฑ์มักถูกใช้เป็นขั้นตอนเริ่มต้นในลำดับของการดำเนินการประมวลผลภาพ เช่น กรณีใช้กับภาพดิจิทัลตรวจมะเร็งเต้านมแบ่งแยกเนื้อเยื่อสุขภาพดีกับเนื้อเยื่อออกจากกัน ข้อเสีย คือ สร้างได้เพียงสองคลาสเท่านั้นและไม่สามารถใช้ได้กับภาพหลายขานเนล (Channel) นอกจากนี้ยังไม่คำนึงเรื่องลักษณะเชิงพื้นที่ด้วยทำให้ไวต่อสัญญาณรบกวนและความเข้มไม่สม่ำเสมอ ด้วยเหตุผลเหล่านี้จึงมีการเสนอการตั้งระดับเกณฑ์ร่วมกับข้อมูลความเข้มเฉพาะจุดและความเชื่อมโยงกัน

### 2.2.2.2 การแบ่งส่วนโดยอิงพื้นที่ (Region-based Segmentation)

เทคนิคอิงพื้นที่อาศัยการทำงานโดยแยกหน้าที่การแบ่งส่วนออกเป็นหลายขั้นตอนและดำเนินการอย่างเป็นลำดับขั้น ซึ่งขั้นตอนเหล่านั้น ได้แก่ การเติบโตของพื้นที่ (Region Growing) กับการรวมและการแยกพื้นที่ (Region Merging and Splitting)

#### 1. การเติบโตของพื้นที่ (Region Growing)


ขั้นตอนนี้ คือ การใช้ขีดหรือเมล็ดซึ่งหมายถึงพิกเซลหนึ่งช่องหรือหลายพื้นที่เป็นจุดเริ่มต้น ซึ่งตำแหน่งกำหนดโดยตัวผู้ใช้งาน [31] จากนั้นค่อย ๆ ขยับขยายไปรวมกับพิกเซลข้างเคียงที่มีคุณลักษณะเหมือนหรือคล้ายกัน เช่น ความสว่าง สี และพื้นผิว จนกว่าจะไม่มีพิกเซลที่สามารถรวมเข้าด้วยกันได้ ตัวอย่างขั้นตอนวิธีที่อิงหลักการนี้ เช่น ฟัซซีลอจิก (Fuzzy Logic) ในรูปที่ 2.26 แสดงการขยายของขีดออกไปยังพิกเซลข้างเคียงของเทคนิคการเติบโตของพื้นที่ [32]



(n) Start of Growing a Region

● Seed Pixel

← Direction of Growth



(ข) Growing Process After a Few Iterations

■ Grown Pixels

✚ Pixels Being Considered

รูปที่ 2.26 แสดงการดำเนินการของเทคนิคการเติบโตของพื้นที่ (ก) จุดเริ่มต้นของการเติบโตของพื้นที่ (ข) การเติบโตพื้นที่หลังจากผ่านไปหลายรอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แตกต่างจากวิธีการตั้งค่าระดับเกณฑ์ที่เทคนิคนี้มักรวมอยู่ในชุดดำเนินการของการประมวลผลภาพสำหรับการวิเคราะห์โครงสร้างขนาดเล็กและเรียบง่าย จุดด้อยของเทคนิคนี้ คือ มีความไวต่อสัญญาณรบกวนทำให้พื้นที่ที่ขยายออกมีช่องโหว่หรืออาจขาดการเชื่อมต่อกัน แต่ในทางกลับกันผลกระทบของปริมาณบางส่วนก็ทำให้ส่วนที่ขาดกันกลับมาต่อกันได้

สามารถเขียนสมการได้ว่า


$$g(x,y) = \begin{cases} 1 & \text{if } |S(x,y) - f(x,y)| \leq T \\ 0 & \text{if otherwise} \end{cases} \quad (2.20)$$

โดย  $S(x,y)$  คือ อาร์เรย์ของขีดหรือพื้นที่ที่ขีดขยาย

## 2. การรวมและการแยกพื้นที่ (Region Merging and Splitting)

พื้นฐานของการรวมพื้นที่คล้ายคลึงกับการเติบโตของพื้นที่ เว้นแต่ว่าการรวมพื้นที่นั้นวัดความเหมือนกันโดยการตัดสินจากความแตกต่างระหว่างค่าเฉลี่ยสีเทาของพิกเซลภายในพื้นที่ที่ได้รับจากการขยายพื้นที่รอบก่อนกับพิกเซลที่อยู่ติดกัน ถ้าความต่างมีค่าน้อยกว่าระดับเกณฑ์  $T$  ที่ตั้งไว้ถือว่ามีความเหมือนกัน การรวมพื้นที่สามารถใช้เพื่อแก้ปัญหาคำสั่งสูญเสียด้านสัญญาณรบกวนและการบิดบังวัตถุและยังส่งผลดีต่อการควบคุมสเกลแบ่งส่วนและการประมวลข้อมูลแบบพิเศษที่แตกต่างจากปกติ อย่างไรก็ตาม การคำนวณลักษณะนี้ค่อนข้างหนักและกฎการหยุดไม่แน่ชัด ตัวอย่างเทคนิคที่อิงตามพื้นที่ เช่น ขั้นตอนวิธีลุ่มแม่น้ำ (Watershed Algorithm) [32]

ส่วนการแยกพื้นที่เป็นเทคนิคที่เริ่มต้นด้วยการให้ภาพทั้งหมดเป็นพื้นที่เดียว (รูปที่ 2.27ก) และแบ่งซ้ำ ๆ ออกเป็นส่วนย่อย ๆ (รูปที่ 2.27ข-2.27ค) ตามเกณฑ์ความเป็นเนื้อเดียวกัน ความท้าทายหลักของการแยกส่วน คือ การกำหนดเกณฑ์ความเป็นเนื้อเดียวกันให้เหมาะสมของการแยก และหลีกเลี่ยงการแบ่งส่วนมากเกินไปหรือน้อยเกินไป แยกจนกว่าจะทำต่อไม่ได้แล้วจึงทำการรวมพื้นที่ที่อยู่ติดกันตามคุณลักษณะที่เหมือนหรือคล้ายกัน (รูปที่ 2.27ง)



รูปที่ 2.27 แสดงการรวมและการแยกพื้นที่ (ก) เริ่มด้วยการตั้งภาพทั้งหมดเป็นพื้นที่เดียว (ข) แบ่งครั้งแรกเป็นสี่ส่วน (ค) แบ่งครั้งที่สอง (ง) รวมพื้นที่ที่มีความเป็นเนื้อเดียวกัน

### 2.2.2.3 การแบ่งส่วนโดยอิงเส้นขอบ (Edge-based Segmentation)

เทคนิคการแบ่งส่วนโดยอิงเส้นขอบเกิดจากการตรวจจับและระบุเส้นขอบของวัตถุต่าง ๆ ภายในภาพ เส้นขอบในที่นี้หมายถึงตำแหน่งหรือบริเวณที่ระดับของสีเทาเปลี่ยนไปอย่างฉับพลัน ก่อให้เกิดความไม่ต่อเนื่องกันของความเข้มกลายเป็นเส้นขอบเขตแบ่งแยกระหว่างสองพื้นที่ [32] การตรวจจับสามารถทำได้ด้วยสองวิธีการหลัก หนึ่งใน คือ ตรวจจับโดยคำนวณค่าอนุพันธ์อันดับหนึ่งของความเข้มได้ค่าที่มากกว่าเกณฑ์ที่กำหนด อย่างเช่น วิธีโซเบล (Sobel) และสอง คือ ตรวจจับโดยการคำนวณอนุพันธ์อันดับสองได้ว่ามีค่าจุดตัดเท่ากับศูนย์ เช่น วิธีลาปลาซเซียน (Laplacian) [33] นอกจากนี้วิธีนี้ยังมีการตรวจจับรูปแบบอื่นอีกหลายแบบขึ้นอยู่กับตัวกรอง เช่น แคนนี่ (Canny) เป็นต้น

#### 1. วิธีโซเบล (Sobel Edge Detection)

การหาขอบภาพโดยวิธีโซเบล คือ การใช้ตัวกรองเกรเดียนขนาด  $3 \times 3$  ที่ในทางเทคนิคแล้ว คือ ตัวกรองแยกความแตกต่างแบบไม่ต่อเนื่อง ข้อดีของการใช้ตัวกรองที่มีขนาดเป็นเลขคี่คือ ตัวกรองจะถูกจัดให้อยู่กึ่งกลางพอดีสามารถให้ค่าประมาณที่อิงตามพิกเซลตรงกลางได้ วิธีโซเบลอาศัยการสังวัตนาการด้วยตัวกรองขนาดเล็ก สามารถแยกส่วนได้และค่าภายในตัวกรองเป็นค่าจำนวนเต็มทั้งหมด ในทิศทางแนวนอน (Horizontal Direction) และแนวตั้ง (Vertical Direction) คำนวณประมาณค่าอนุพันธ์ของฟังก์ชันความเข้มของภาพสองค่า คือ ค่าการเปลี่ยนแปลงในทิศแนวนอน ( $\Delta x$ ) และการเปลี่ยนแปลงในแนวตั้ง ( $\Delta y$ ) [34]

ตัวกรองโซเบลสำหรับตรวจจับเส้นขอบสามารถเขียนได้ดังนี้

$$\Delta x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad \Delta y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}$$

#### 2. วิธีลาปลาเซียน (Laplacian) [35]

วิธีนี้จะหาขอบด้วยอนุพันธ์อันดับสอง ลาปลาเซียน (Laplacian) เป็นตัวดำเนินการที่ง่ายที่สุดในรูปแบบของการคำนวณอนุพันธ์อันดับสองด้วยการสร้างตัวกรองแบบไม่มีทิศทางมาช่วยในการปรับความคมของเส้นขอบให้ชัดเจนยิ่งขึ้น อนุพันธ์ลำดับสองสร้างความแตกต่างได้ชัดเจนกว่าอนุพันธ์อันดับหนึ่งโดยสมการของลาปลาเซียน คือ


$$L(x, y) = \frac{\partial^2 I}{\partial x^2} + \frac{\partial^2 I}{\partial y^2} \quad (2.21)$$

แต่เนื่องจากมีความไวต่อสัญญาณรบกวนจึงจำเป็นต้องนำการปรับให้เรียบด้วยตัว

กรองเกาส์เซียน (Gaussian Smoothing Filter) มาช่วยจนได้ออกมาเป็นวิธีที่เรียกว่า LoG (Laplacian of Gaussian) ดังสมการ

$$LoG(x, y) = -\frac{1}{\pi\sigma^4} \left[1 - \frac{x^2+y^2}{2\sigma^2}\right] e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2.22)$$

ผลลัพธ์จากวิธีการต่าง ๆ ได้แสดงให้เห็นในรูปที่ 2.28 [32]



รูปที่ 2.28 ผลการตรวจจับขอบของตัวดำเนินการที่ต่างกันไป (ก) ดั้งเดิม (ข) โซเบล (ค) โซเบล (ง) โซเบล (จ) เคอร์เนล (ฉ) โรเบิร์ตซ (ช) แคนนี่ (ซ) ลาลลาเซียน (ที่มา : Yu Y., *et al.* “Techniques and challenges of image segmentation : A review.” Electronics, vol.12 no.5, 2023. pp. 1199.)


#### 2.2.2.4 การแบ่งส่วนด้วยการจัดกลุ่ม (Clustering)

ขั้นตอนวิธีการจัดกลุ่มโดยพื้นฐานแล้วทำหน้าที่เหมือนกับวิธีการจำแนกประเภทโดยไม่ต้องใช้ข้อมูลฝึกอบรม (Training Data) ดังนั้นจึงเรียกว่าวิธีการแบบไม่มีผู้สอน (Unsupervised Methods) เพื่อชดเชยการขาดข้อมูลฝึกอบรม วิธีการจัดกลุ่มดำเนินการโดยสลับไปมาระหว่างการแบ่งส่วนรูปภาพและการกำหนดลักษณะของคุณสมบัติของแต่ละคลาสวนเป็นรอบ ๆ ซึ่งในแง่หนึ่งวิธีการจัดกลุ่มฝึกฝนตัวเองโดยใช้ข้อมูลที่มีอยู่

สามขั้นตอนวิธีการจัดกลุ่มที่ใช้กันทั่วไป ได้แก่ ขั้นตอนวิธี K-means ขั้นตอนวิธีฟัซซี C-mean (Fuzzy C-means Algorithm) และขั้นตอนวิธีอีเอ็ม (Expectation Maximization Algorithm : EM Algorithm) ขั้นตอนวิธีการจัดกลุ่ม K-mean จัดกลุ่มข้อมูลโดยคำนวณความเข้มเฉลี่ยสำหรับแต่ละคลาสวนซ้ำ ๆ กันและทำการแบ่งส่วนด้วยการแยกแยะแต่ละพิกเซลเป็นคลาสที่ค่าเฉลี่ยใกล้เคียงที่สุด รูปที่ 2.29 ข แสดงให้เห็นผลลัพธ์การใช้ขั้นตอนวิธี K-means บนภาพสมอเอ็ม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อาร์ (รูปที่ 2.29ก) โดยแบ่งเป็นสามคลาสจากน้ำหล่อเลี้ยงสมองและไขสันหลัง (สีเทาเข้ม) เนื้อเทา (สีเทาอ่อน) และเนื้อขาว (สีขาว) ในส่วนของขั้นตอนวิธีฟัซซี C-mean ถูกเหมารวมกับขั้นตอนวิธีการจัดกลุ่ม K-mean โดยอาศัยทฤษฎีของฟัซซีเซต (Fuzzy Set Theory) ส่วนขั้นตอนวิธีอีเอ็มใช้หลักการการจัดกลุ่มเดียวกันกับสมมติฐานพื้นฐานว่า ข้อมูลเป็นไปตามแบบจำลองการผสมแบบเกาส์ (Gaussian Mixture Model) วนซ้ำระหว่างการคำนวณความน่าจะเป็นหลังปรับ (Posterior Probability) และการคำนวณค่าประมาณความเป็นไปได้สูงสุดของค่าเฉลี่ย ความแปรปรวนร่วมและค่าสัมประสิทธิ์การผสมของแบบจำลองส่วนผสม



(ก)

(ข)

รูปที่ 2.29 การแบ่งส่วนภาพสมองเอ็มอาร์ (ก) ภาพปกติ (ข) การแบ่งส่วนโดยใช้ขั้นตอนวิธี K-means (ที่มา : Pham D. L., Xu C. and Prince J. L., “Current methods in medical image segmentation.”, Annual review of biomedical engineering, vol.2 no.1, 2000. pp.315-337.)

แม้ว่าขั้นตอนวิธีการจัดกลุ่มไม่ต้องการข้อมูลการฝึกอบรมแต่จำเป็นต้องมีการแบ่งส่วนเริ่มต้นหรือเทียบเท่าพารามิเตอร์เริ่มต้น ขั้นตอนวิธีอีเอ็มได้แสดงให้เห็นถึงความไวต่อการเริ่มต้นมากกว่าขั้นตอนวิธี K-means และขั้นตอนวิธีฟัซซี C-means ซึ่งขั้นตอนวิธีการจัดกลุ่มไม่ได้รวมการสร้างแบบจำลองเชิงพื้นที่โดยตรง ดังนั้นจึงค่อนข้างไวต่อสัญญาณรบกวนและความเข้มที่ไม่สม่ำเสมอ [31]

### 2.2.3 การแบ่งส่วนแบบอัตโนมัติ (Automatic Segmentation)

เทคนิคการแบ่งส่วนแบบอัตโนมัติไม่อาศัยการตอบโต้จากผู้ใช้และสามารถแบ่งได้เป็นสองแบบคือ เรียนรู้กับไม่เรียนรู้ วิธีนี้สามารถลดความเหลื่อมล้ำทางด้านความเชี่ยวชาญส่วนบุคคลอีกทั้งอำนวยความสะดวกให้แก่ผู้ใช้งาน และไม่จำกัดแค่ผู้เชี่ยวชาญเป็นผู้ใช้เท่านั้น เมื่อเร็ว ๆ นี้ระบบการเรียนรู้เชิงลึกได้รับความนิยมอย่างมากในฐานะรากฐานของการสร้างระบบปัญญาประดิษฐ์ โดยการ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แบ่งส่วนจะดำเนินการโดยโครงข่ายประสาทเทียมที่ได้รับการฝึกฝนด้วยกลุ่มข้อมูลที่ติดป้ายกำกับ (Label) สถาปัตยกรรมโครงข่ายที่ได้รับความนิยมสำหรับงานแบ่งส่วน คือ สถาปัตยกรรมโครงข่ายแบบ U-Net ข้อดีของวิธีการนี้ คือ เมื่อขั้นตอนวิธีถูกสร้างแล้วการแบ่งส่วนสามารถทำได้ค่อนข้างเร็วซึ่งขึ้นอยู่กับภาพ อาจใช้เวลาไม่กี่วินาทีถึงนาที แต่โดยปกติจะเร็วกว่ากรณีที่ใช้ต้องใช้ตอบด้วยตัวเอง ข้อเสียของการเรียนรู้เชิงลึก คือ โดยปกติแล้วต้องใช้ข้อมูลที่มีป้ายกำกับจำนวนมากเพื่อฝึกแบบจำลองให้มีความถูกต้องและแม่นยำ ใช้เวลาฝึกนานและฮาร์ดแวร์พิเศษ (GPU) ในการสร้างแบบจำลอง วิธีการเหล่านี้มักได้รับการฝึกอบรมเกี่ยวกับการแบ่งส่วนจากผู้ดำเนินการทำชุดข้อมูลเพียงคนเดียว หมายความว่าแบบจำลองที่สร้างขึ้นจะเอนเอียงไปตามข้อมูลต้นทางจากผู้สร้างชุดข้อมูล แนวทางการเรียนรู้อาจไม่สามารถสรุปได้ดีเนื่องจากขั้นตอนวิธีที่ได้รับการฝึกอบรมในชุดข้อมูลเฉพาะอาจทำงานได้ไม่ดีนักในชุดข้อมูลอื่น นอกจากนี้ การแบ่งส่วนที่ใช้สำหรับเป็นข้อมูลการฝึกอบรมยังคงต้องทำโดยใช้วิธีแมนนวลหรือกึ่งอัตโนมัติ [28] ซึ่งรายละเอียดเกี่ยวกับระบบการเรียนรู้เชิงลึกและสถาปัตยกรรมโครงข่ายแบบ U-Net ถูกอธิบายในหัวข้อถัดไป

## 2.3 กระบวนการประมวลผลภาพ (Image Processing)

การประมวลผลภาพเป็นกระบวนการแปลงภาพและจัดการภาพเพื่อให้ได้มาซึ่งข้อมูลที่มีประโยชน์สำหรับนำไปประยุกต์ใช้ในงานต่าง ๆ ไม่ว่าจะเป็นการลดสัญญาณรบกวนที่เกิดจากขั้นตอนสร้างภาพหรือการเพิ่มความเปรียบต่างให้แก่ภาพที่มีความละเอียดต่ำ สามารถทำได้ทั้งก่อนและหลังการดำเนินการหลัก ระบบการประมวลผลนี้อาศัยเทคนิคหลายอย่าง เช่น เทคนิคการตั้งระดับเกณฑ์ที่เป็นวิธีที่เรียบง่ายที่สุดในการสร้างภาพไปนารีตามที่ได้อธิบายรายละเอียดไว้ในหัวข้อ 2.2.2.1

ในวิทยานิพนธ์นี้จะยกรายละเอียดของเทคนิคประมวลผลภาพ 5 เทคนิค ประกอบด้วย เทคนิคฮิสโทแกรมอีควอลไลเซชัน (Histogram Equalization) การปรับให้เรียบด้วยเกาส์เซียน (Gaussian Smoothing) เทคนิควินโดวส์เลเวลลิง (Window Leveling) คณิตศาสตร์ฐานวิทยา (Mathematical Morphology) และการฉายฮิสโทแกรม (Histogram Projection)

### 2.3.1 เทคนิคฮิสโทแกรมอีควอลไลเซชัน (Histogram Equalization)

รูปร่างของฮิสโทแกรมสัมพันธ์กับภาพที่แสดงออกมา ภาพที่มีดีมิ่งมีกราฟฮิสโทแกรมในลักษณะที่กราฟกระจุกอยู่บริเวณที่ค่าความเข้มต่ำ ๆ ซึ่งเป็นค่าที่ให้โทนที่มืด เช่นเดียวกับภาพที่สว่าง กราฟฮิสโทแกรมจะไปกระจุกรวมอยู่ที่ค่าความเข้มพิกเซลสูง ๆ ที่เป็นค่าที่ให้โทนที่สว่าง ภาพที่ความเปรียบต่างต่ำจะมีกราฟฮิสโทแกรมแคบและตำแหน่งมักอยู่ช่วงกลาง ๆ ของค่าความเข้มพิกเซลทั้งหมด ในขณะที่ภาพที่มีความเปรียบต่างสูงจะมีช่วงความถี่ของความเข้มกว้างและการกระจายของพิกเซลไม่ต่างกันมากมีค่าความเข้มแคบไม่กี่ค่าที่อาจมีจำนวนพิกเซลสูงกว่าค่าอื่น [36]


ฮิสโทแกรมอีควอลไลเซชัน (Histogram Equalization) เป็นเทคนิคปรับปรุงภาพที่นำมาใช้บ่อย ๆ ในงานภาพถ่ายทางการแพทย์ [37] โดยการปรับเปลี่ยนการกระจายความเข้มพิกเซลให้มี

ช่วงกว้างครอบคลุมสเกลค่าความเข้มตามจำนวนบิตของภาพนั้น ๆ มากขึ้น ไม่ทำให้ในภาพบรรจุเพียงค่าความเข้มช่วงแคบ ๆ ที่เป็นลักษณะของภาพความเปรียบต่างต่ำดังที่อธิบายมาในข้างต้น เทคนิคนี้คือการแจกแจงความน่าจะเป็นสะสม (Cumulative Distribution Function : **CDF**) ซึ่งหาได้จากการรวมฮิสโทแกรมของค่าความเข้มพิกเซล ( $h(I)$ ) แบบสะสม ตามสมการที่ 2.23 [38]

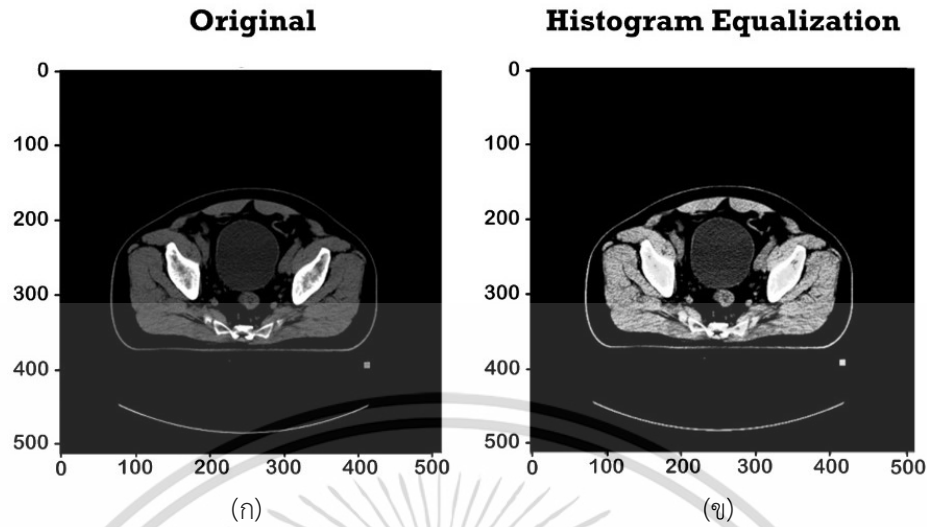
$$CDF(I) = \sum_{I=0}^{\text{number of bin}} h(I) \quad (2.23)$$

โดยภาพรวมแล้วกระบวนการของเทคนิคฮิสโทแกรมอีควอไลเซชัน (รูปที่ 2.30) เริ่มต้นด้วยการคำนวณฮิสโทแกรมของภาพนำเข้าซึ่งแสดงถึงความถี่ของแต่ละค่าความเข้มพิกเซลภายในภาพ ต่อด้วยคำนวณค่าการแจกแจงความน่าจะเป็นสะสมของค่าความเข้มพิกเซล ( $CDF(I)$ ) จากนั้นดำเนินการทำให้ค่าการแจกแจงความน่าจะเป็นสะสมที่หามาได้ให้เป็นบรรทัดฐานและขยายเต็มช่วงความเข้ม เช่น 0 ถึง 255 สำหรับภาพเฉดสีเทาขนาด 8 บิต สร้างเป็นฟังก์ชันเชื่อมโยงค่าความเข้ม (Intensity Mapping Function :  $f(I)$ ) หรือเรียกอีกอย่างว่าตารางค้นหา (Lookup Table : LUT) จากนั้นในขั้นตอนสุดท้ายใช้ฟังก์ชันเชื่อมโยงค่าความเข้มที่สร้างขึ้นมาแปลงค่าความเข้มดั้งเดิมในภาพนำเข้าให้เป็นค่าความเข้มใหม่ ซึ่งช่วยปรับการกระจายค่าความเข้มของพิกเซลให้ใหม่และทำให้กราฟฮิสโทแกรมสะสมกลายเป็นเชิงเส้นเพื่อให้ได้ภาพที่สมดุลและชัดเจนมากขึ้น

ภาพ 2.31(ก) และภาพ 2.31(ข) แสดงภาพสไลด์ซีทีของบริเวณกระเพาะปัสสาวะก่อนและหลังการปรับปรุงความเปรียบต่างโดยเทคนิคฮิสโทแกรมอีควอไลเซชันซึ่งเห็นได้ว่าเทคนิคนี้ช่วยปรับปรุงความเปรียบต่างทำให้เห็นความแตกต่างระหว่างบริเวณกระเพาะปัสสาวะ เนื้อเยื่ออวัยวะโดยรอบได้อย่างชัดเจน



รูปที่ 2.30 แผนผังกระบวนการของเทคนิคฮิสโทแกรมอีควอไลเซชัน



รูปที่ 2.31 แสดงภาพสไลด์ซีทีของพื้นที่บริเวณกระเพาะปัสสาวะ (ก) ก่อนปรับปรุงความเปรียบต่างด้วยเทคนิคฮิสโทแกรมอีควอไลเซชัน และ (ข) หลังปรับปรุงความเปรียบต่างด้วยเทคนิคฮิสโทแกรมอีควอไลเซชัน

สำหรับฟังก์ชันเชื่อมโยงค่าความเข้มในเทคนิคฮิสโทแกรมอีควอไลเซชันที่มีบทบาทสำคัญในเทคนิคนี้สามารถสร้างได้หลายวิธี เช่น แบบธรรมดา คือ การทำให้ค่าการแจกแจงความน่าจะเป็นสะสมเป็นบรรทัดฐานด้วยวิธีต่าง ๆ แบบวิธีการปรับฮิสโทแกรมในแบบที่ปรับตัวเองได้ (Contrast Limited Adaptive Histogram Equalization : CLAHE) คือ การแบ่งพื้นที่สำหรับดำเนินการฮิสโทแกรมอีควอไลเซชันออกเป็นพื้นที่ย่อย ๆ สร้างฟังก์ชันตามแต่ละพื้นที่ย่อย แบบปรับแต่ง คือ การปรับแต่งวิธีการสร้างฟังก์ชันเชื่อมโยงเองอย่างการประยุกต์ใช้กระบวนการขยายช่วงของระดับความเข้มแสง (Contrast Stretching) เป็นต้น และแบบฟังก์ชันเชื่อมโยงแบบไม่เป็นเชิงเส้น

นอกจากนี้ยังมีรูปแบบการปรับค่าใหม่ที่ไม่ได้สร้างฟังก์ชันเชื่อมโยงค่าความเข้ม [36] สำหรับค่าตัวแปรสุ่มไม่ต่อเนื่องสามารถทำงานด้วยความน่าจะเป็นและการรวมค่าแทนที่จะทำงานด้วยฟังก์ชันความหนาแน่นของความน่าจะเป็น (Probability Density Functions) และค่าเต็มจำนวนความน่าจะเป็นของการเกิดระดับความเข้ม  $I_k$  ในภาพดิจิทัลนั้นประมาณค่าได้ตามสมการ 2.24

$$p_I(I_k) = \frac{n_k}{MN} \quad (2.24)$$

เมื่อ  $MN$  คือจำนวนพิกเซลทั้งหมดในภาพ  $n_k$  คือ จำนวนพิกเซลที่มีค่าความเข้ม  $I_k$  โดย  $I_k \in [0, L - 1]$  และ  $p_I(I_k)$  คือ ฮิสโทแกรมของภาพที่ถูกทำให้เป็นบรรทัดฐานแล้ว ดังนั้น สมการไม่ต่อเนื่องของการแปลงค่าสามารถเขียนได้ว่า

$$S_k = T(I_k) = (L - 1) \sum_{j=0}^k p_I(I_j) \quad k = 0, 1, 2, \dots, L - 1 \quad (2.25)$$

เมื่อ  $T(I_k)$  คือ ฟังก์ชันเพิ่มขึ้นแบบโมโนโทนิค (Monotonic Increasing Function)  $L$  คือ จำนวนระดับความเข้มที่เป็นไปได้ภายในภาพ เช่น 256 ของภาพ 8 บิต ดังนั้น ภาพนำออกจะได้มาโดยใช้สมการ 2.24 เพื่อเชื่อมโยงแต่ละพิกเซลในภาพนำเข้าที่มีความเข้ม  $I_k$  เข้ากับพิกเซลที่สอดคล้องกันโดยมีระดับ  $S_k$  ในภาพนำออก ซึ่งเรียกว่า การแปลงฮิสโทแกรมอีควอไลเซชันหรือการแปลงฮิสโทแกรมเชิงเส้น [36]

การเลือกฟังก์ชันเชื่อมโยงความเข้มขึ้นอยู่กับข้อกำหนดและคุณลักษณะเฉพาะของภาพที่กำลังประมวลผล วิธีการแตกต่างกันอาจให้ผลลัพธ์กับภาพที่แตกต่างกันและอาจเหมาะกับรูปภาพและแอปพลิเคชันประเภทต่าง ๆ ไม่เหมือนกัน สิ่งสำคัญ คือ ต้องพิจารณาลักษณะของข้อมูลภาพและผลลัพธ์การปรับปรุงที่ต้องการ

### 2.3.2 การปรับให้เรียบด้วยเกาส์เซียน (Gaussian Smoothing)


เทคนิคการปรับให้เรียบด้วยเกาส์เซียนถูกใช้เพื่อลดสัญญาณรบกวนหรือลดการเปลี่ยนแปลงความเข้มอย่างฉับพลัน [36] โดยใช้การสังวัตนาการรูปภาพด้วยเคอร์เนลเกาส์เซียน (Gaussian Kernel หรือ Filter :  $G(x, y)$ ) เป็นเคอร์เนลไม่ต่อเนื่องซึ่งได้มาจากฟังก์ชันเกาส์เซียนสองมิติแบบต่อเนื่อง [39] ที่นิยามได้ดังนี้

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2.26)$$

เมื่อ  $\pi$  เท่ากับ 3.1415  $\sigma$  คือ ค่าเบี่ยงเบนมาตรฐานของการกระจายเกาส์เซียน  $e$  คือ จำนวนของออยเลอร์ (Euler's Number) เท่ากับ 2.7182 ส่วน  $x$  และ  $y$  คือ พิกัดของพิกเซลตำแหน่งของคอลัมน์และแถว จุดกึ่งกลางของตัวกรองอยู่ที่พิกัด (0,0)

การประมาณแบบไม่ต่อเนื่องสำหรับฟังก์ชันต่อเนื่องนี้กำหนดได้ด้วยพารามิเตอร์อิสระสองตัว คือ ขนาดของตัวกรองที่ต้องการและค่าเบี่ยงเบนมาตรฐานของฟังก์ชันเกาส์เซียน ทั้งสองค่าเป็นตัวควบคุมระดับของการเบลอของภาพ เคอร์เนลที่ถูกออกแบบนั้นถูกกำหนดให้น้ำหนักของพิกเซลกึ่งกลางมีค่ามากกว่าพิกเซลข้างเคียงและในบรรดาพิกเซลข้างเคียงด้านบน ล่าง ซ้าย และขวามีน้ำหนักที่สูงกว่าพิกเซลข้างเคียงในแนวทแยง [40] จึงถูกเรียกว่าเป็นเคอร์เนลที่มีลักษณะเป็นทรงกลมสมมาตรหรือแบบรัศมีสมมาตร (รูปที่ 2.32) อีกทั้งตัวกรองชนิดนี้ยังสามารถแยกกันได้

จากรูปที่ 2.32 เห็นได้ว่าเคอร์เนลเกาส์เซียนถูกทำให้เป็นบรรทัดฐานโดยการหารด้วยค่าผลรวมน้ำหนักภายในเคอร์เนลทำให้ได้ผลรวมของค่าน้ำหนักใหม่ทั้งหมดเท่ากับ 1



รูปที่ 2.32 เคอร์เนลเกาส์เซียนที่มีลักษณะแบบรีซีมมาตร (ก) เคอร์เนลขนาด  $3 \times 3$  กับ  $\sigma = 5$  (ข) เคอร์เนลขนาด  $5 \times 5$  กับ  $\sigma = 7$  และ (ค) เคอร์เนลขนาด  $7 \times 7$  กับ  $\sigma = 3$

การทำให้เป็นบรรทัดฐานนี้ทำเพื่อให้มั่นใจว่า ค่าความเข้มของภาพหลังปรับให้เรียบอยู่ในช่วงเดียวกับภาพต้นฉบับ หากเคอร์เนลไม่ได้ถูกทำให้เป็นบรรทัดฐาน ภาพเบลอที่ได้อาจสว่างหรือมืดกว่าต้นฉบับอย่างเห็นได้ชัดซึ่งนำไปสู่อาร์ติแฟกที่ไม่ต้องการ เขียนนิยามการทำให้เคอร์เนลเกาส์เซียนเป็นบรรทัดฐานได้ว่า

$$G_{norm}(x, y) = \frac{1}{\sum W_i} G(x, y) \quad (2.27)$$

เมื่อ  $G_{norm}(x, y)$  คือ เคอร์เนลเกาส์เซียนที่ผ่านการทำให้เป็นบรรทัดฐานและ  $\sum W_i$  คือ ผลรวมของค่าน้ำหนักทั้งหมดในเคอร์เนลเกาส์เซียน

### 2.3.3 วินโดวส์เลเวลลิง (Window Leveling)

วินโดวส์เลเวลลิง คือ หนึ่งในเทคนิคปรับภาพถ่ายทางการแพทย์ ควบคุมความสว่างและความเปรียบต่างของภาพซึ่งสำหรับภาพถ่ายเอกซเรย์คอมพิวเตอร์ดำเนินการผ่านหน่วยเฮาส์ฟิลด์เสมือนเป็นค่าความเข้มในภาพทั่วไป โดยปกติภาพถ่ายทางการแพทย์มีช่วงค่าหน่วยเฮาส์ฟิลด์กว้างมากทำให้แสดงบนหน้าจอจอมอนิเตอร์ได้ไม่ชัดเจนเนื่องจากถูกจำกัดด้วยช่วงไดนามิกของจอมอนิเตอร์ทั่วไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เทคนิคนี้สามารถใช้แก้ไขปัญหานี้ได้รวมถึงใช้เพื่อปรับความเปรียบต่างหรือต้องการเน้นโครงสร้างใด โดยเฉพาะด้วยการกำหนด “หน้าต่าง” แบบเฉพาะเจาะจงขึ้นมา หน้าต่างในที่นี้หมายถึงช่วงค่าความเข้มช่วงหนึ่ง que เลือกมาจากช่วงความเข้มทั้งหมดเพื่อแสดงผล

พารามิเตอร์ในเทคนิคนี้ ประกอบด้วยพารามิเตอร์ระดับหน้าต่าง (Window Level : WL) ซึ่งหมายถึง จุดกึ่งกลางของหน้าต่างที่เป็นค่าหน่วยเฮาส์ฟิลด์ตรงกลางของช่วงที่ต้องการแสดงซึ่งทำหน้าที่ควบคุมความสว่างกับพารามิเตอร์ความกว้างหน้าต่าง (Window Width : WW) หมายถึง ช่วงของค่าหน่วยเฮาส์ฟิลด์ที่ต้องการแสดงซึ่งทำหน้าที่ควบคุมความคมชัด

การกำหนดหน้าต่างสามารถทำได้ด้วยการเลือกระดับหน้าต่างและความกว้างหน้าต่างที่ต้องการขึ้นมาก่อน และคำนวณหาค่าความเข้มมาสองค่าที่ใช้เป็นขอบบนและขอบล่างของหน้าต่าง ตั้งให้เป็นค่าหน่วยเฮาส์ฟิลด์ต่ำสุด ( $HU_{min}$ ) และสูงสุด ( $HU_{max}$ ) ซึ่งคำนวณได้จากสมการ 2.28 และ 2.29 ตามลำดับ [41]

$$HU_{min} = (WL - 0.5) - \left(\frac{WW-1}{2}\right) \quad (2.28)$$

$$HU_{max} = (WL - 0.5) + \left(\frac{WW-1}{2}\right) \quad (2.29)$$

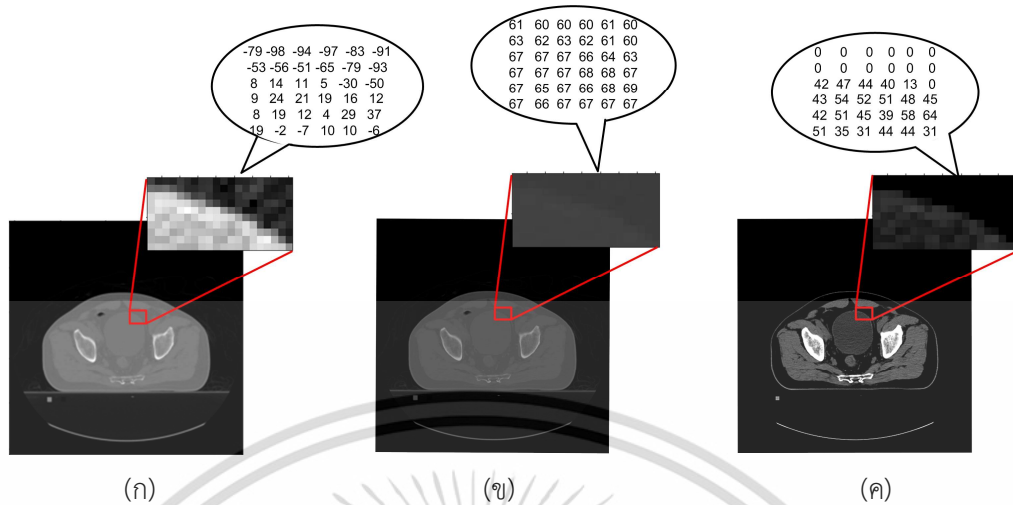
จากนั้นแปลงค่าหน่วยเฮาส์ฟิลด์เดิมให้อยู่ในช่วงที่ต้องการ เช่น ช่วงของภาพ 8 บิต 16 บิต หรือ 32 บิต เป็นต้น โดยค่าที่น้อยกว่าค่าหน่วยเฮาส์ฟิลด์ต่ำสุด ( $HU_{min}$ ) และค่าที่มากกว่าค่าหน่วยเฮาส์ฟิลด์สูงสุด ( $HU_{max}$ ) ถูกแปลงเป็นค่าความเข้มต่ำสุด ( $y_{min}$ ) และค่าความเข้มสูงสุด ( $y_{max}$ ) ของช่วงค่าใหม่ทั้งหมดตามลำดับ ในขณะที่ค่าหน่วยเฮาส์ฟิลด์เดิมตั้งแต่ค่าหน่วยเฮาส์ฟิลด์ต่ำสุดถึงค่าหน่วยเฮาส์ฟิลด์สูงสุดจะถูกแปลงด้วยสมการแปลงเชิงเส้น (Linear Transformation) สมการ 2.30 [41]

$$y_i = \left(\frac{x_i - (WL - 0.5)}{WW - 1}\right) \times (y_{max} - y_{min}) + y_{min} \quad (2.30)$$

เมื่อ  $y_i$  คือ ค่าความเข้มนำออก เช่น ความเข้ม 0 ถึง 255 และ  $x_i$  คือ ค่าหน่วยเฮาส์ฟิลด์นำเข้าโดย  $i$  หมายถึง หมายเลขพิกเซล

รูปที่ 2.33(ก) แสดงภาพสไลด์เอกซเรย์คอมพิวเตอร์ต้นฉบับในระนาบตามแกน ในขณะที่รูปที่ 2.33(ข) และ 2.33(ค) แสดงภาพเอกซเรย์คอมพิวเตอร์ในรูปแบบของภาพ 8 บิต ที่ไม่ผ่านวินโดวส์เลเวลลิ่งกับหลังผ่านวินโดวส์เลเวลลิ่งแล้ว ซึ่งเห็นได้ว่า ภาพที่ผ่านการทำวินโดวส์เลเวลลิ่งมีคุณภาพและความคมชัดเห็นโครงสร้างต่าง ๆ ได้อย่างชัดเจน รวมทั้งความแตกต่างของค่าความเข้มก็แบ่งแยกบริเวณเส้นขอบได้ชัดเจนใกล้เคียงกับต้นฉบับมากกว่ากรณีไม่ทำวินโดวส์เลเวลลิ่ง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.33 ภาพสไลด์เอกซเรย์คอมพิวเตอร์ในระนาบตามแกน (ก) ภาพสไลด์เอกซเรย์คอมพิวเตอร์ต้นฉบับ (ข) ภาพเอกซเรย์คอมพิวเตอร์ในรูปแบบของภาพ 8 บิต ที่ไม่ผ่านการดำเนินการวินโดวส์เลเวลลิง และ (ค) ภาพเอกซเรย์คอมพิวเตอร์ในรูปแบบของภาพ 8 บิต หลังผ่านการดำเนินการวินโดวส์เลเวลลิง

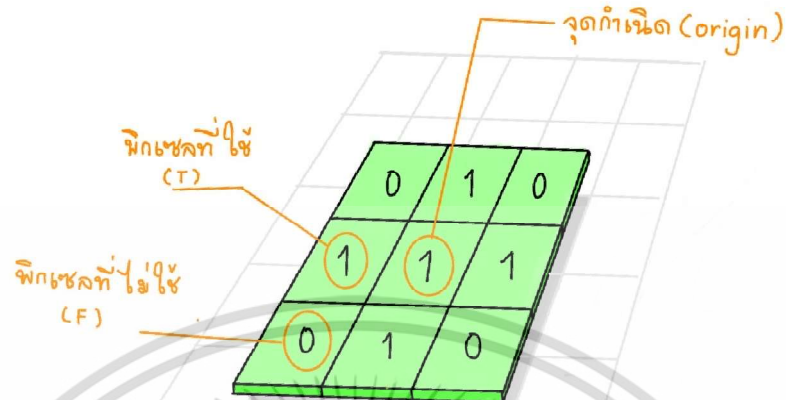
#### 2.3.4 คณิตสัณฐานวิทยา (Mathematical Morphology)

ในการประมวลผลภาพ สัณฐานวิทยาถูกใช้กับกลุ่มพิกเซลสองประเภท คือ กลุ่มออบเจ็กต์ที่หมายถึงวัตถุภายในภาพที่เป็นเป้าหมายดำเนินการกับกลุ่มองค์ประกอบโครงสร้าง (Structuring Element : SE) ที่เป็นเมทริกซ์หรืออาร์เรย์ทรงสี่เหลี่ยมขนาดเล็กกว่าภาพ กำหนดให้เป็นได้ทั้งพื้นหน้าและพื้นหลัง ทั้งนี้ ค่าต่าง ๆ ที่ใส่ไว้ในองค์ประกอบโครงสร้างจะไม่ให้ความสำคัญก็ได้หรือใส่เป็นค่าเท่ากับค่าที่ต้องการประเมินนิพจน์ก็ได้ รูปทรงภายในสามารถกำหนดได้ตามความเหมาะสม

ตัวดำเนินการของคณิตสัณฐานวิทยาโดยพื้นฐานมี 2 การดำเนินการ คือ การกัดเซาะ (Erosion) และการขยาย (Dilation) ต่อมามีการพัฒนารูปแบบดำเนินการอื่น ๆ ขึ้นจากตัวดำเนินการพื้นฐาน ซึ่งที่มักเห็นบ่อย ๆ คือ การเปิด (Opening) และการปิด (Closing)

เนื่องจากวิทยานิพนธ์นี้วิจัยเกี่ยวกับภาพถ่ายทางการแพทย์เป็นหลักซึ่งเป็นภาพเฉดสีเทา ดังนั้นขั้นตอนวิธีของคณิตสัณฐานวิทยาที่ใช้สำหรับงานวิจัยจึงเป็นขั้นตอนวิธีสำหรับภาพเฉดสีเทา โดยเฉพาะ หลักการทำงานบางส่วนแตกต่างจากปกติที่กระทำกับภาพไบนารี องค์ประกอบโครงสร้างของสัณฐานวิทยาสำหรับภาพเฉดสีเทามีสองแบบ ได้แก่ แบบแบน (Flat) (รูปที่ 2.34) และแบบไม่แบน (Nonflat) ทั้งนี้ แบบไม่แบนไม่ค่อยเป็นที่นิยมในทางปฏิบัติ รายละเอียดต่อจากนี้จึงเน้นไปที่องค์ประกอบโครงสร้างแบบแบนเป็นหลัก โครงสร้างแบบแบนเป็นเมทริกซ์ค่าไบนารีสองมิติหรือหลายมิติ ค่าไบนารีภายในใช้แทนค่าตัดสินใจการคำนวณสัณฐานวิทยา หากค่าเท่ากับ 1 (เป็นจริง) หมายถึง นำมาพิจารณา ส่วนค่าเท่า 0 (เป็นเท็จ) หมายถึง ไม่นำมาพิจารณา และค่ากึ่งกลางเมทริกซ์

แทนเป็นจุดกำเนิด



รูปที่ 2.34 องค์ประกอบโครงสร้างแบบแบน (ค่าไบนารี)

#### 1. การกัดเซาะเฉดสีเทา (Grayscale Erosion)

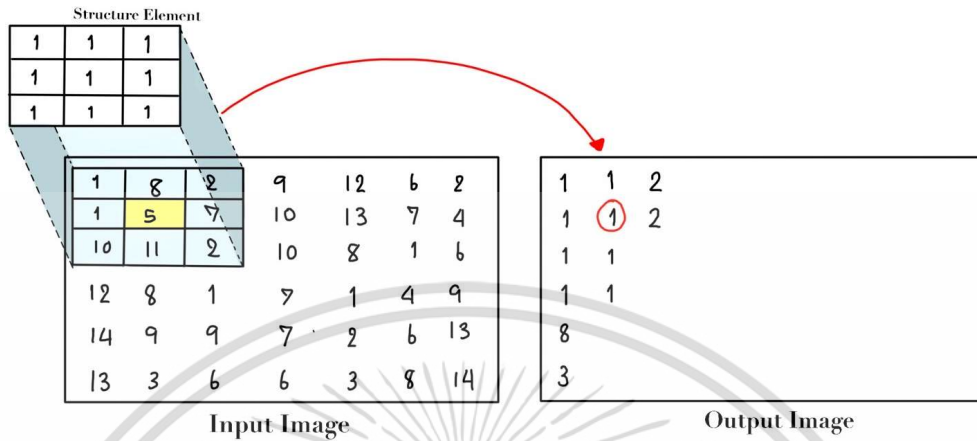
การกัดเซาะเฉดสีเทาในภาพ ( $f$ ) ด้วยองค์ประกอบโครงสร้างแบบแบน ( $B$ ) ที่ตำแหน่ง  $(x, y)$  ดำเนินการด้วยการวางทับองค์ประกอบโครงสร้างลงบนภาพให้ซ้อนทับกัน เริ่มจากมุมบนซ้าย การกัดเซาะที่ตำแหน่งใด ๆ จะถูกกำหนดโดยการเลือกค่าความเข้มต่ำสุดของภาพในพื้นที่ที่ตรงกับองค์ประกอบโครงสร้างซ้อนทับอยู่ ตัวอย่างเช่น องค์ประกอบโครงสร้างมีขนาด  $3 \times 3$  และมีค่าเท่ากับ 1 ทั้งหมด การได้ค่ากัดเซาะมาต้องค้นหาค่าความเข้มที่ต่ำที่สุดในจำนวนเก้าค่าที่อยู่ในพื้นที่  $3 \times 3$  ขององค์ประกอบโครงสร้างแล้วระบุให้ค่านั้นอยู่ในตำแหน่งเดียวกับจุดกำเนิดขององค์ประกอบโครงสร้างในภาพนำออก แล้วดำเนินการในรูปแบบเดียวกันขณะที่เพิ่มค่า  $x$  และ  $y$  เพื่อเลื่อนองค์ประกอบโครงสร้างให้ผ่านทุกพิกเซลบนภาพ ผลที่ได้ขึ้นอยู่กับรูปทรงที่กำหนดลงในองค์ประกอบโครงสร้าง แต่จะออกมาในลักษณะที่ว่าขอบของวัตถุในภาพถูกลบออกหรือเจือจางลง รูปที่ 2.35 แสดงตัวอย่างการกัดเซาะเฉดสีเทาด้วยองค์ประกอบโครงสร้างแบบแบนขนาด  $3 \times 3$

ในรูปแบบสมการการกัดเซาะที่ตำแหน่ง  $(x, y)$  ของภาพด้วยองค์ประกอบโครงสร้างเขียนได้ว่า

$$[f \ominus B](x, y) = \min_{(s,t) \in B} \{f(x + s, y + t)\} \quad (2.31)$$

เมื่อ  $s$  และ  $t$  หมายถึง ระยะห่างจากจุดกำเนิด  $(x, y)$  ขององค์ประกอบโครงสร้างแบบ

แบน



รูปที่ 2.35 การกัดเซาะเจดสีเทาด้วยองค์ประกอบโครงสร้างแบบแบนขนาด 3x3

2. การขยายเจดสีเทา (Grayscale Dilation)

การขยายเจดสีเทาในภาพ ( $f$ ) ด้วยองค์ประกอบโครงสร้างแบบแบน ( $B$ ) ที่ตำแหน่ง ( $x, y$ ) ดำเนินการด้วยการวางทับองค์ประกอบโครงสร้างลงบนภาพให้ซ้อนทับกัน เริ่มจากมุมบนซ้าย การขยายที่ตำแหน่งใด ๆ ถูกกำหนดโดยการเลือกค่าความเข้มสูงสุดของภาพภายในพื้นที่ซ้อนทับด้วย  $\hat{B}$  และนำค่าที่เลือกมาวางในภาพนำออกตรงพิกัดของจุดกำเนิดของ  $\hat{B}$  ที่ ( $x, y$ ) รูปที่ 2.36 แสดงตัวอย่างการขยายเจดสีเทาด้วยองค์ประกอบโครงสร้างแบบแบนขนาด 3x3 สามารถเขียนเป็นสมการได้ว่า

$$[f \oplus B](x, y) = \max_{(s,t) \in \hat{B}} \{f(x - s, y - t)\} \tag{2.32}$$

เมื่อ  $\hat{B}$  คือ องค์ประกอบโครงสร้างที่ถูกสะท้อนกลับ (Reflected Flat Structure Element)



2. การฉายฮิสโทแกรมตามแนวตั้ง (Vertical Histogram Projection : VHP) คือ การคำนวณนับจำนวนพิกเซลของค่าความเข้มแต่ละระดับตามแกนแนวตั้งของภาพไล่ไปที่ละคอลัมน์ ขั้นตอนการทำงานของวิธีนี้ มีดังนี้

1. เลือกแกนที่ต้องการคำนวณโดยพื้นฐานแล้วจะแบ่งได้สองแกน คือ ตามแกนแนวนอนแทนด้วย “แถว (Rows)” กับแกนแนวตั้งแทนด้วย “คอลัมน์ (Column)” ของภาพ
2. แยกแกนตามทีเลือก ถ้าเป็นแนวนอนให้แยกตามแถว ถ้าเป็นแนวตั้งให้แยกตามคอลัมน์
3. คำนวณฮิสโทแกรมในแต่ละแถวและแต่ละคอลัมน์ นับจำนวนพิกเซลของความเข้มแต่ละระดับ โดยทั่วไปจะแปลงค่าให้อยู่ในช่วง 0 ถึง 255 ของภาพ 8 บิต ผลที่ได้ คือ ความถี่ของแต่ละค่าความเข้มในแต่ละลำดับแกน
4. แสดงผลภาพที่ฉายฮิสโทแกรมเป็นพล็อตแสดงให้เห็นว่าค่าความเข้มมีการกระจายตามแกนอย่างไร (รูปที่ 2.37ก - 2.37ข) สำหรับแกนแนวนอน แกน Y คือ ลำดับแถว และแกน X คือ ความถี่พิกเซลของค่าความเข้มหรือค่าฮิสโทแกรมของค่าความเข้มนั้น ส่วนในแกนแนวตั้ง (รูปที่ 2.37ก) แกน X คือลำดับของคอลัมน์ และแกน Y คือความถี่พิกเซลของค่าความเข้มหรือค่าฮิสโทแกรมของค่าความเข้ม (รูปที่ 2.37ข)

ตัวอย่างการประยุกต์ใช้งานข้อมูลที่ได้จากวิธีนี้ในกระบวนการประมวลผลภาพ เช่น งานตรวจจับข้อความ การแก้ไขการปรับเปลี่ยนตำแหน่ง และการแบ่งส่วนพื้นที่ เป็นต้น

ในการเขียนสมการ สำหรับการฉายฮิสโทแกรมตามแนวนอน (HHP) สามารถแทนภาพสองมิติเป็นเมทริกซ์ แล้วคำนวณความถี่ความเข้มพิกเซลของแต่ละแถว สามารถเขียนสมการได้ว่า [45]

$$H(i, k) = \sum [I(i, j) == k] \quad (2.35)$$

ในทำนองเดียวกันสมการของการฉายฮิสโทแกรมตามแนวตั้ง (VHP) ไล่คำนวณไปตามคอลัมน์ สามารถเขียนได้ว่า

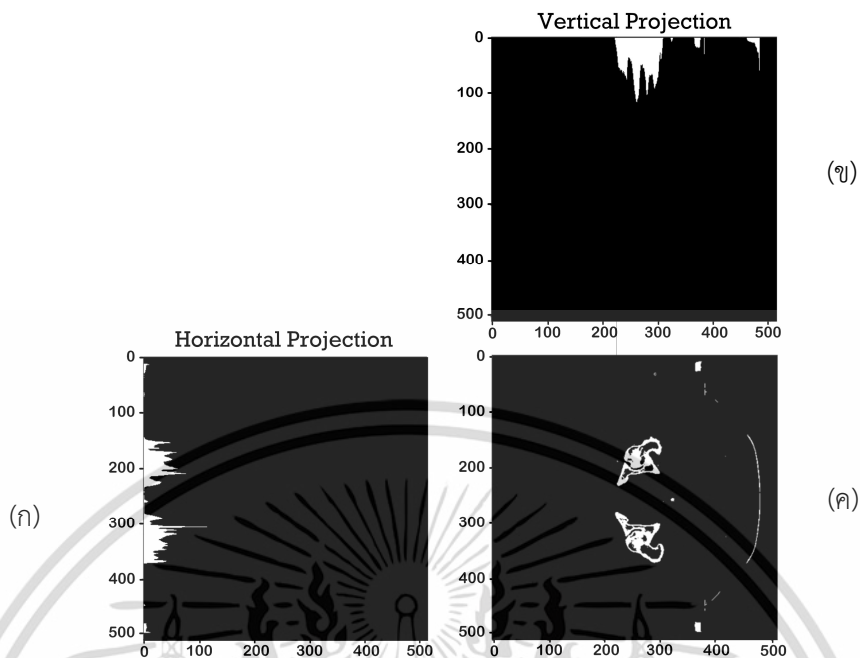
$$H(j, k) = \sum [I(i, j) == k] \quad (2.36)$$

โดย  $I(i, j)$  คือ ความเข้มพิกเซลที่แถวที่  $i$  และคอลัมน์  $j$

$H(i, k)$  คือ ความถี่หรือจำนวนพิกเซลที่มีความเข้มเท่ากับ  $k$  ในแถวที่  $i$

$H(j, k)$  คือ ความถี่หรือจำนวนพิกเซลที่มีความเข้มเท่ากับ  $k$  ในคอลัมน์ที่  $j$

$k$  คือ ค่าความเข้มที่ต้องการนับจำนวนพิกเซล



รูปที่ 2.37 ผลการฉายฮิสโทแกรมใน (ก) แนวนอนและ (ข) แนวตั้งของ (ค) ภาพกระดูกต้นขากับกระดูกเชิงกราน (Pelvic Girdle Bone)

## 2.4 การเรียนรู้เชิงลึก (Deep Learning) โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolution Neural Network : CNN) และ โครงสร้าง U-Net (U-Net Architecture)

### 2.4.1 การเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้เชิงลึก คือ หนึ่งในขั้นตอนวิธีการของการเรียนรู้ของเครื่อง (Machine Learning) เพื่อกลายเป็นหัวใจหลักในการแสดงประสิทธิภาพของปัญญาประดิษฐ์ (Artificial Intelligence : AI) ดำเนินการและจัดการปัญหาต่าง ๆ ด้วยโครงข่ายประสาทแบบหลายชั้นที่เลียนแบบการทำงานของโครงข่ายประสาทของมนุษย์หรือนิวรอน (Neurons) อีกหนึ่งจุดเด่นของการเรียนรู้เชิงลึกที่โดดเด่นกว่าขั้นตอนวิธีการเรียนรู้ของเครื่องแบบดั้งเดิม คือ การสกัดคุณลักษณะอัตโนมัติจากชุดข้อมูลตัวอย่าง โดยการสกัดคุณลักษณะถือเป็นกระบวนการของโครงข่ายในการตัดสินใจว่าลักษณะเฉพาะใดของชุดข้อมูลที่สามารถใช้เป็นตัวบ่งชี้เพื่อติดป้ายกำกับข้อมูลนั้น ๆ ได้อย่างน่าเชื่อถือ [46]

ขั้นตอนวิธีสำหรับการเรียนรู้ของเครื่องมีการพัฒนาอย่างต่อเนื่องก่อนจะกลายมาเป็นวิธีการเรียนรู้เชิงลึกที่ถูกใช้อย่างแพร่หลายในปัจจุบัน เริ่มจาก การถดถอยเชิงเส้น (Linear Regression) การถดถอยเชิงพหุคูณ (Multiple Linear Regression) การถดถอยแบบลอจิสติก (Logistic Regression) การถดถอยแบบลอจิสติกกอนเนกนาม (Multinomial Logistic Regression) และโครงข่ายประสาท (Neural Network) โดยสังเขป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 2.4.1.1. การถดถอยเชิงเส้น (Linear Regression)

คลาสของการถดถอยที่พบมากที่สุดและธรรมดาที่สุด กระบวนการดำเนินโดยประมาณค่าสัมประสิทธิ์เชิงปริมาณที่ดีที่สุดของสมการเชิงเส้นทั้งแบบที่มีตัวแปรอิสระหรือค่านำเข้าที่เรียกอีกอย่างว่าคุณลักษณะหรือตัวแปรทำนายซึ่งโดยทั่วไปแสดงในรูปของ “x” ตัวเดียวหรือมากกว่า ซึ่งให้การทำนายค่าตัวแปรตามหรือค่านำออกสามารถเรียกอีกอย่างว่าเป้าหมายหรือผลลัพธ์ โดยทั่วไปจะแสดงในรูปของ “y” หรือในที่นี้แทนค่าตัวแปรตามที่ทำนายได้ว่าเป็น “ $\hat{y}$ ” รูปแบบของการถดถอยเชิงเส้นสามารถแบ่งได้ตามจำนวนของตัวแปรอิสระและตัวแปรตาม [47]

**การถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression)** รูปแบบอย่างง่ายของการถดถอยเชิงเส้นซึ่งถือว่าการเรียนรู้ของเครื่องประเภทการเรียนรู้แบบมีผู้สอน (Supervised Learning) ชนิดแบบการถดถอยทางสถิติ เมื่อป้อนชุดข้อมูลเข้าไปให้โปรแกรมเรียนรู้ ตัวแปรอิสระ (x) และตัวแปรตาม ( $\hat{y}$ ) จะถูกนำไปคำนวณด้วยสถิติทางคณิตศาสตร์ หาความสัมพันธ์ระหว่างตัวแปรตามหนึ่งค่ากับตัวแปรอิสระหนึ่งค่า ตามสมการ (2.37) [48]

$$\hat{y} = w_0 + w_1 x \quad (2.37)$$


เมื่อ  $w_1$  คือ ความชันหรือเกรเดียนต์ของเส้นและ  $w_0$  คือ ค่าคงที่ สองค่านี้เป็นค่าที่ต้องหาเพื่อให้ได้สมการเชิงเส้นที่ดีที่สุดสำหรับทำนายค่าตัวแปรตามต่าง ๆ ตามข้อมูลของตัวแปรอิสระ สมการให้ผลลัพธ์เป็นเส้นตรงที่แสดงถึงความสัมพันธ์ระหว่างตัวแปรตามและตัวแปรอิสระ ถ้าเส้นตรงบนแผนภาพการกระจายลากผ่านทุกจุดโดยไม่มีระยะห่างหรือมีระยะห่างระหว่างเส้นและจุดน้อยถือว่าการนั้นดีที่สุด (รูปที่ 2.38) ความชันของเส้นบ่งชี้ถึงทิศทางของความสัมพันธ์ระหว่างตัวแปรขนาดของผลกระทบต่อตัวแปร อัตราการเปลี่ยนแปลง และการทำนาย

ค่า  $w_0$  กับ  $w_1$  ถูกปรับเปลี่ยนไปเรื่อย ๆ จนกว่าจะได้ค่าความผิดพลาดที่น้อยที่สุดออกมาซึ่งค่าความผิดพลาดที่นิยมใช้ในขั้นตอนวิธีการถดถอยเชิงเส้นแบบง่ายมักใช้ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Squared Error : MSE) (สมการ 2.38)

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.38)$$

เมื่อ  $\hat{y}_i$  คือ ค่าผลลัพธ์ที่ทำนายได้ ค่า  $y_i$  คือ ค่าผลลัพธ์ตามความเป็นจริง และ n คือ จำนวนข้อมูลทั้งหมด

# Linear Regression



รูปที่ 2.38 การถดถอยเชิงเส้นอย่างง่ายและเส้นการถดถอยเหมาะสมที่สุด

## การถดถอยเชิงพหุคูณ (Multiple Linear Regression)

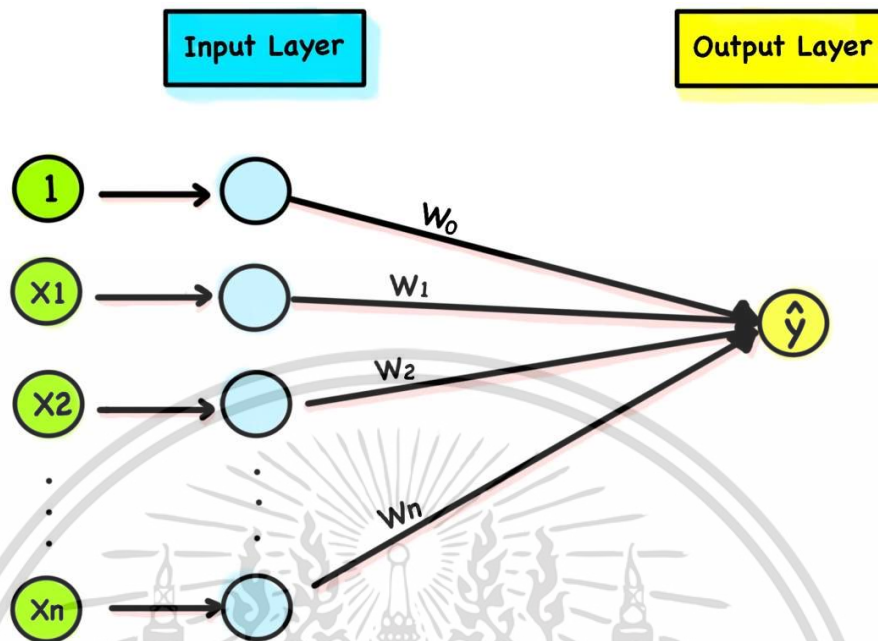
เมื่อมีค่าตัวแปรอิสระตั้งแต่สองตัวขึ้นไปต่อการทำนายค่าตัวแปรตามหนึ่งตัว เรียกการวิเคราะห์ความสัมพันธ์ระหว่างทั้งสองกลุ่มตัวแปรและประมาณค่าสัมประสิทธิ์เพื่อสร้างสมการนี้ว่า การถดถอยเชิงพหุคูณ (Multiple Linear Regression) สามารถเขียนสมการใหม่ตัดแปลงจากสมการ 2.37 ได้ว่า [46-48]

$$\hat{y} = w_0 + w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_nx_n \quad (2.39)$$

โดย  $w_1, \dots, w_n$  หมายถึง ค่าความชัน และ  $w_0$  หมายถึง ค่าคงที่  $x_n$  คือ ค่าตัวแปรอิสระหรือค่านำเข้า และ  $\hat{y}$  คือ ค่าที่ทำนายออกมาได้

แบบจำลองของการถดถอยพหุคูณ (รูปที่ 2.39) แสดงให้เห็นเซลล์ประสาทหรือนิวรอนด้วยปม (Node) และการเชื่อมต่อด้วยเส้นเชื่อมที่กำกับด้วยค่าสัมประสิทธิ์หรือในทางการเรียนรู้เชิงลึก เรียกค่าเหล่านี้ว่า ค่าน้ำหนัก (Weight) ค่าสัมประสิทธิ์บนค่าเส้นเชื่อมคำนวณกับค่านำเข้าจากปมต้นทางไปรวมที่ปม ( $\hat{y}$ ) ที่เดียว การใช้ตัวแปรอิสระหลายตัวช่วยส่งเสริมให้แบบจำลองหรือขั้นตอนวิธีที่สร้างขึ้นมีความซับซ้อนขึ้นสามารถเข้าหาข้อมูลได้มากขึ้นส่งผลให้ประสิทธิภาพการทำนายเพิ่มมากยิ่งขึ้นเมื่อเทียบกับวิธีการถดถอยเชิงเส้นอย่างง่าย สมมติอย่างตอนเลือกซื้อคอมพิวเตอร์ใหม่ กรณีที่รู้รายละเอียดอย่างข้อมูลจำเพาะของเครื่อง ราคา รุ่น และอื่น ๆ ก็ช่วยให้ตัดสินใจได้ง่ายขึ้นว่าขึ้นไหนดีที่สุดในงานองเดียวกับการคาดการณ์ ยิ่งได้รับข้อมูลวิเคราะห์ละเอียดขึ้นเท่าใด การคาดการณ์ยิ่งสมเหตุสมผลและมีความแม่นยำ ถือว่าเป็นตัวเสริมการตัดสินใจ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



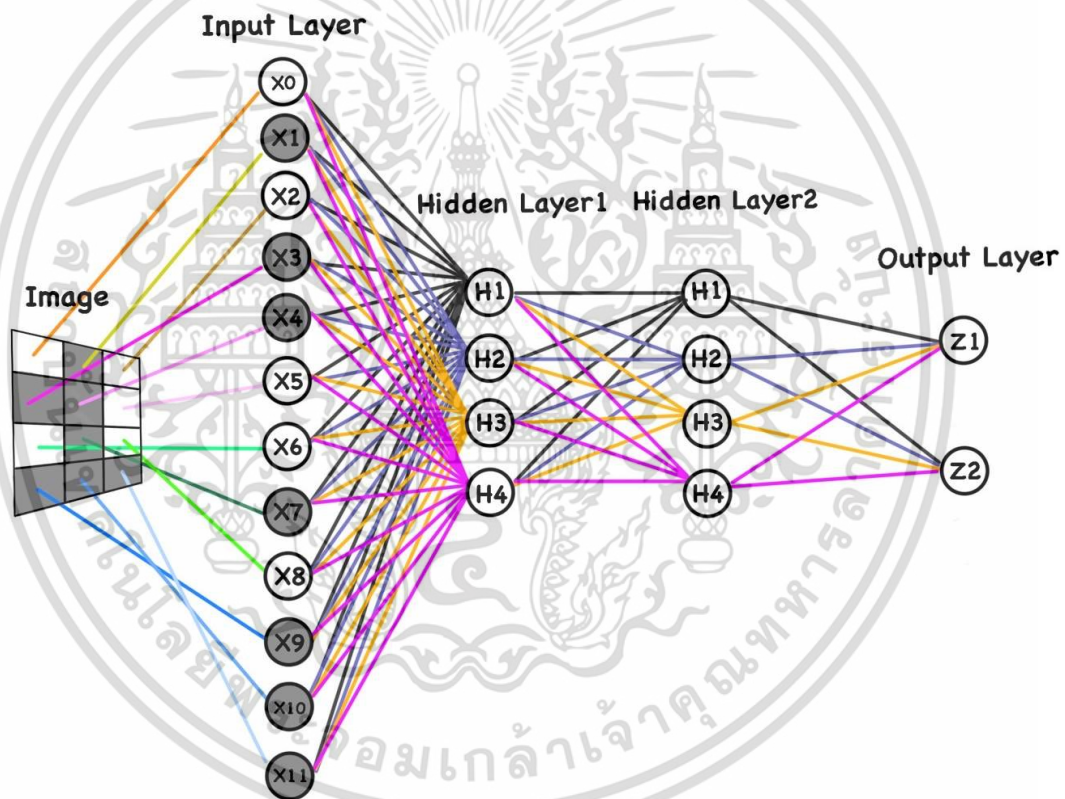
รูปที่ 2.39 แบบจำลองของการถดถอยเชิงพหุคูณ

ปัญหาที่มักพบยามเลือกใช้ขั้นตอนวิธีนี้ คือ การเลือกตัวแปรต่าง ๆ ที่ใช้เพื่อให้ได้การคาดการณ์ที่แม่นยำที่สุดเท่าที่จะเป็นไปได้ แน่แน่นอนว่าควรเลือกตัวแปรที่เกี่ยวข้องทั้งหมด แต่อย่างไรก็ตาม มักเป็นไปได้เพราะนอกจากความซับซ้อนของสมการแล้วยังมาจากปัจจัยอื่น [48] เช่น การรวมตัวแปรที่ไม่ได้มีส่วนสนับสนุนการถดถอยอย่างมีนัยสำคัญเป็นเพียงการเพิ่มข้อผิดพลาดของการคาดการณ์ผลลัพธ์ รวมทั้งเพิ่มค่าใช้จ่ายในการเฝ้าติดตามตัวแปรจำนวนมากให้สูงขึ้นและรบกวนความเสถียรของสมการ ยิ่งจำนวนตัวแปรในสมการน้อยลงเท่าใด สมการก็มีเสถียรภาพและเชื่อถือได้มากขึ้นเท่านั้น นอกจากการถดถอยเชิงพหุคูณที่ทำนายตัวแปรตามค่าเดียวแล้วยังมีขั้นตอนวิธีการถดถอยหลายตัวแปร (Multivariate Regression) ที่เป็นคำนิยามเชิงกว้างของเทคนิคทางสถิติที่เกี่ยวข้องกับการสร้างแบบจำลองความสัมพันธ์ระหว่างตัวแปรตามหลายตัวกับตัวแปรอิสระหลายตัวทั้งในแบบเชิงเส้นและไม่เป็นเชิงเส้น ในกรณีนี้ คือ การทำนายผลลัพธ์หลายตัวโดยอาศัยตัวแปรอิสระหลายตัว สำหรับการเรียนรู้ของเครื่องการถดถอยประเภทนี้รวมถึงการถดถอยแบบลอจิสติก (Logistic Regression) การถดถอยแบบลอจิสติกอนเนกนาม (Multinomial Logistic Regression)

#### 2.4.1.2. โครงข่ายประสาท (Neural Network)

จากที่ได้กล่าวมาในหัวข้อที่แล้ว การเรียนรู้เชิงลึกอาศัยประโยชน์จากโครงข่ายประสาทแบบหลายชั้นที่จำลองเลียนแบบเซลล์ประสาทในมนุษย์เพื่อสร้างขั้นตอนวิธีสำหรับงานปัญญาประดิษฐ์ด้านต่าง ๆ ขึ้นมา โครงข่ายประสาทจัดเป็นแบบจำลองเชิงคอมพิวเตอร์มีองค์ประกอบ

หน่วยพื้นฐานที่เรียกว่า ปม (Node) นิวรอนเทียม (Artificial Neuron) หรือเรียกง่าย ๆ ว่า นิวรอน (Neuron) แสดงด้วยสัญลักษณ์ทรงกลมในรูปที่ 2.40 โดยนำมาจัดเรียงเป็นชั้น ๆ ประกอบกันเป็นชั้นนำเข้า (Input Layer) หนึ่งชั้น ชั้นซ่อน (Hidden Layer) ตั้งแต่หนึ่งชั้นขึ้นไปซึ่งคำนิยามว่าหลายชั้นในโครงข่ายประสาทก็มาจากจำนวนของชั้นนี้ และชั้นนำออก (Output Layer) หนึ่งชั้น จัดว่าเป็นองค์ประกอบโครงสร้างชั้นพื้นฐานสำหรับโครงข่ายประสาท การจัดเรียงลักษณะนี้ให้ความสามารถในการแยกแยะข้อมูลซึ่งพฤติกรรมของโครงข่ายประสาทได้รับอิทธิพลมาจากจำนวนนิวรอน จำนวนชั้น และรูปแบบการเชื่อมโยงระหว่างชั้น ซึ่งในแต่ละชั้นสามารถมีจำนวนนิวรอนแตกต่างกันได้และมีการเชื่อมต่ออย่างสมบูรณ์กับชั้นที่อยู่ติดกัน การเชื่อมโยงระหว่างนิวรอนในแต่ละชั้นก่อตัวเป็นผังจำลองตามที่แสดงในรูปที่ 2.40



รูปที่ 2.40 โครงข่ายประสาทแบบหลายชั้น

สำหรับข้อมูลนำเข้าที่เป็นชุดข้อมูลสำรวจ นิวรอนแต่ละหน่วยในชั้นนำเข้าบรรจุข้อมูลของแต่ละเงื่อนไขของการสำรวจนั้น ๆ ในขณะที่กรณีรูปภาพ แต่ละนิวรอนในชั้นนำเข้าบรรจุค่าความเข้มพิกเซล หนึ่งพิกเซลต่อหนึ่งนิวรอน ตามที่แสดงในรูปที่ 2.40

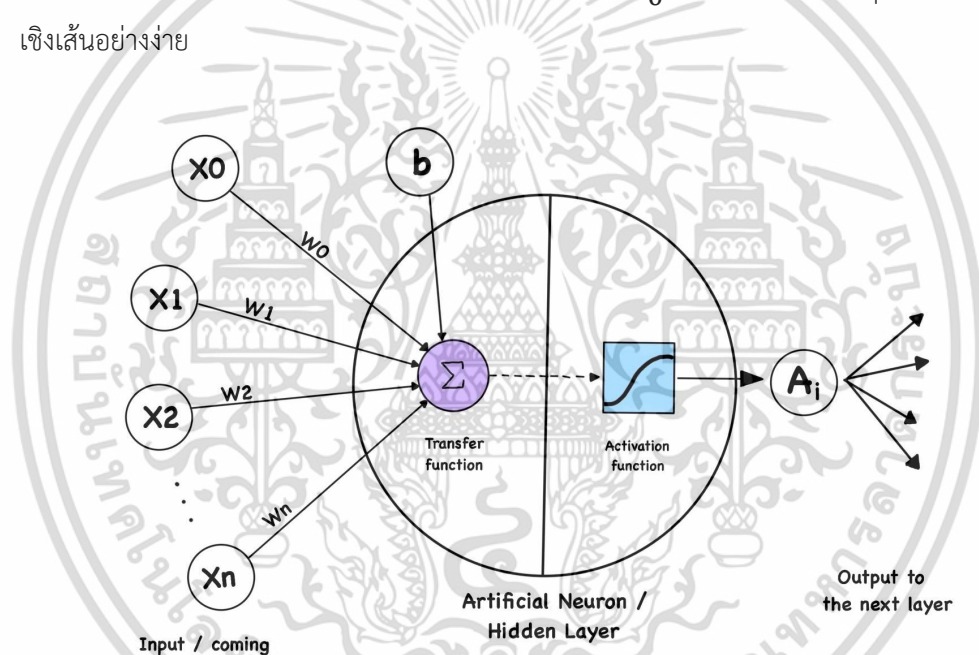
เมื่อชั้นนำเข้าจัดเรียงข้อมูลพร้อมแล้วทำการส่งผ่านข้อมูลเหล่านั้นเข้านิวรอนในชั้นซ่อนถัดไปผ่านเส้นเชื่อม (สัญลักษณ์ลูกศรในรูป 2.44) ซึ่งมีค่าน้ำหนัก ( $W_i$ ) คอยถ่วงค่านำเข้าระหว่าง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ส่งผ่าน (ผลคูณจุดระหว่างน้ำหนักกับคุณลักษณะนำเข้า) ในแต่ละนิวรอนของชั้นซ่อนได้รับข้อมูลจากนิวรอนทุกตัวในชั้นนำเข้า (รูปที่ 2.40 และรูปที่ 2.41) ภายในนิวรอนเทียมมีสองตัวดำเนินการเริ่มจากการรวมเชิงเส้น (รูปที่ 2.41 ฟังก์ชัน) กล่าวถึงผลรวมของค่านำเข้าที่ถ่วงน้ำหนักรวมกับค่าไบแอส (Bias) สามารถนิยามค่านำออกได้ว่า

$$Z = \sum w_i x_i + b \quad (2.40)$$

เมื่อ  $w_i$  คือ เวกเตอร์ของค่านำหนักทั้งหมดที่วางเข้าสู่ นิวรอน  $i$  และ  $x_i$  คือ เวกเตอร์ของค่านำเข้าทั้งหมดที่เข้าสู่ นิวรอน  $i$  ส่วน  $b$  เป็นค่าคงที่ที่เพิ่มเข้าไปในแต่ละชั้นซึ่งจำเป็นต้องหาค่าที่เหมาะสมเหมือนกับที่ต้องหาค่านำหนัก เทียบเท่ากับ  $1 \cdot w_0$  ในขั้นตอนวิธีก่อน ๆ อย่างการถดถอยเชิงเส้นอย่างง่าย



รูปที่ 2.41 การดำเนินการภายในนิวรอนเทียมในชั้นซ่อน

ค่าไบแอส ( $b$ ) เป็นค่าสเกลาร์ที่เพิ่มเข้าแต่ละนิวรอนในชั้นซ่อนเพื่อให้แน่ใจว่าอย่างน้อยในแต่ละนิวรอนได้รับการกระตุ้นโดยไม่ต้องกังวลเรื่องความแรงของสัญญาณ ค่าไบแอสช่วยให้เรียนรู้เกิดขึ้นได้ในกรณีสัญญาณต่ำ ค่าเหล่านี้ทำให้โครงข่ายพยายามตีความหรือปรับพฤติกรรมใหม่แล้วค่านี้อีกแก่ไขระหว่างการเรียนรู้เช่นเดียวกับค่านำหนักเพื่อหาค่าที่เหมาะสมที่สุด

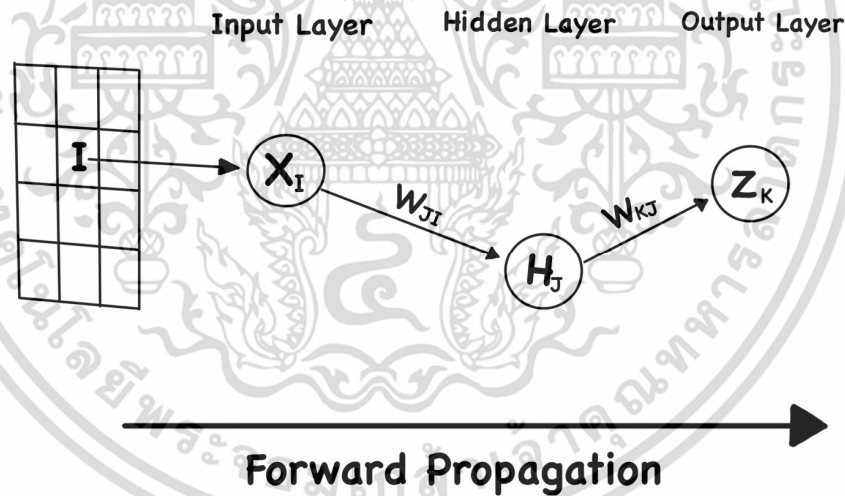
ผลลัพธ์จากการรวมเชิงเส้นถูกส่งไปยังฟังก์ชันอีกตัวภายในนิวรอนเทียม คือ ฟังก์ชันกระตุ้น (Activation Function :  $g$ ) การดำเนินการในส่วนนี้ช่วยให้สามารถสร้างผลลัพธ์ในรูปแบบที่แตกต่างกันได้หรือก็คือเปลี่ยนจากผลลัพธ์เชิงเส้นให้เป็นแบบไม่เป็นเชิงเส้นได้ ถือเป็นหัวใจสำคัญที่ทำ

ให้โครงข่ายประสาทสามารถให้คำตอบหรือนำออกที่ซับซ้อนตรงกับโลกความเป็นจริงได้  
 ค่านำออกของนิวรอนเทียม ( $A_i$ ) จากฟังก์ชันกระตุ้นเขียนสมการได้ว่า

$$A_i = g(\sum w_i x_i + b) \quad (2.41)$$

จากนั้นค่านำออกนี้จะถูกส่งผ่านไปยังชั้นซ่อนถัดไปหรือชั้นนำออกผ่านเส้นเชื่อมต่อกับ  
 นิวรอนเทียมอื่น ๆ ซึ่งคุณด้วยน้ำหนักบนเส้นเชื่อมกลายเป็นค่านำเข้าต่อไป

กระบวนการลักษณะนี้เรียกว่า การแพร่ไปข้างหน้า (Forward Propagation) (รูปที่ 2.42)  
 ในหนึ่งรอบการแพร่ไปข้างหน้าจะได้รับคำตอบหรือค่านำออกออกมา ทว่าในรอบแรกความถูกต้อง  
 ของคำตอบมักไม่แม่นยำเนื่องจากค่าน้ำหนักและค่าไบแอสยังไม่เหมาะสมพอ ดังนั้นโครงข่ายประสาท  
 จำเป็นต้องมีขั้นตอนการฝึกฝนเพื่อเรียนรู้ชุดข้อมูลฝึกฝนและปรับค่าน้ำหนักกับค่าไบแอสในโครงข่าย  
 เพื่อให้ได้ค่าความผิดพลาดน้อยที่สุดและให้คำตอบที่ถูกต้องที่สุด ซึ่งการปรับค่าเหล่านี้เป็นวิธีหลักของ  
 โครงข่ายประสาทสำหรับเรียนรู้ข้อมูลใหม่ และขั้นตอนวิธีเรียนรู้ระหว่างการฝึกฝนเรียกว่า การฝึกฝน  
 แบบแพร่กลับ (Backpropagation Training หรือ Backpropagation Learning)



รูปที่ 2.42 การแพร่ไปข้างหน้า

### 2.4.1.3. ฟังก์ชันการกระตุ้น (Activation Function)

บางทีเรียกว่า ฟังก์ชันส่งผ่าน (Transfer Function) ทำหน้าที่ตัดสินใจว่าจะส่งสัญญาณ  
 นำออกออกไปในรูปแบบใด ควบคุมพฤติกรรมของนิวรอนเทียม และเปลี่ยนผลลัพธ์จากการรวมเชิง  
 เส้นในแต่ละชั้นให้กลายเป็นไม่เป็นเชิงเส้น การแปลงแบบไม่เชิงเส้นจำนวนมากแต่ไม่ใช่ทั้งหมดที่ใช้ใน  
 โครงข่ายประสาทเทียมแปลงข้อมูลเป็นช่วงที่เอื้ออำนวยต่อการนำไปใช้ต่อหรือนำไปสู่ผลลัพธ์ที่

ต้องการ เช่น 0 ถึง 1 หรือ -1 ถึง 1 [46, 49]

การเลือกใช้ฟังก์ชันแบบใดจะขึ้นอยู่กับลักษณะของระบบที่นำเอาโครงข่ายประสาทเทียมไปประยุกต์ใช้ ฟังก์ชันกระตุ้นนี้มีหลายตัวที่นิยมใช้ได้แก่

ตารางที่ 2.2 ฟังก์ชันกระตุ้นที่นิยมใช้กับโครงข่ายประสาท

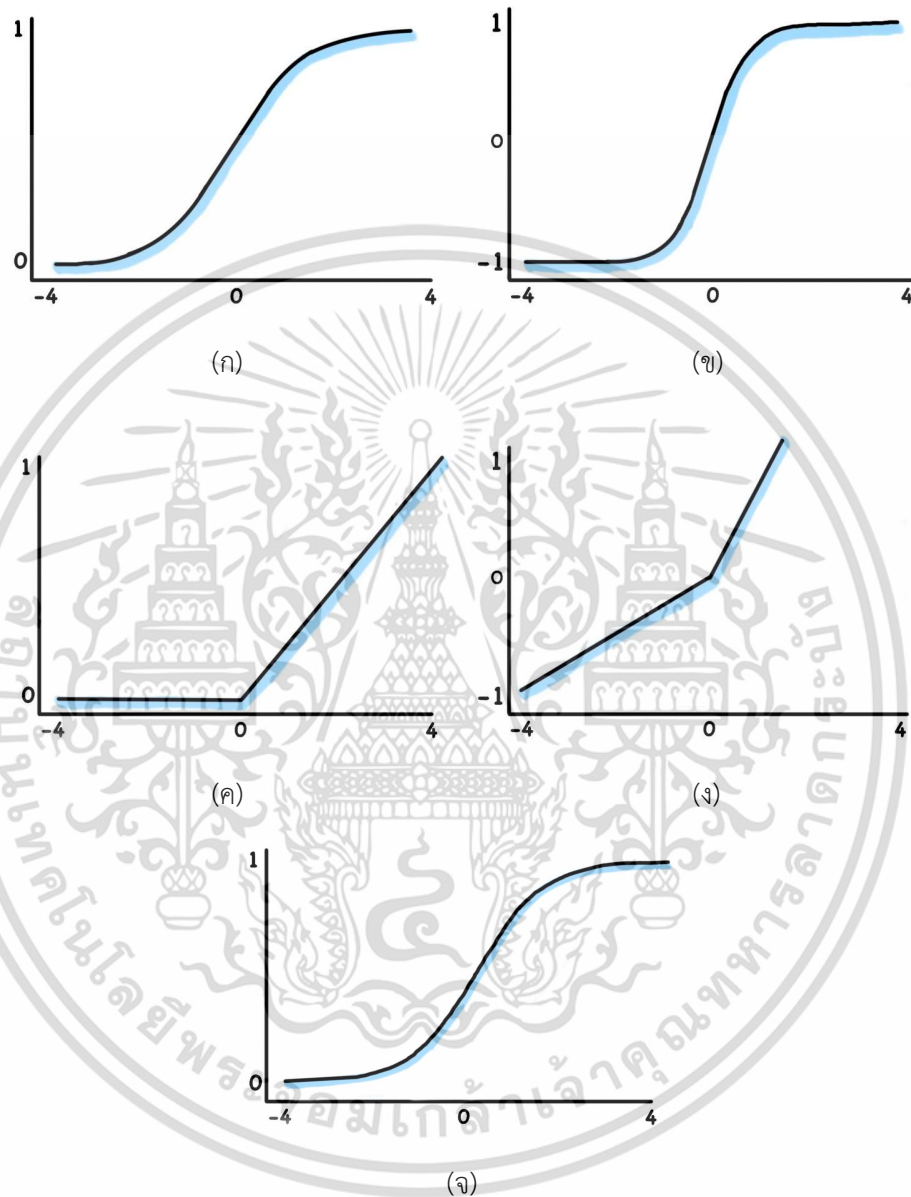
| ฟังก์ชันการกระตุ้น   | สมการ  | ผลลัพธ์  |
|--|--|--|
| 1. ฟังก์ชันซิกมอยด์<br>(Sigmoid Function)  | $\text{sigmoid}(x) = \frac{1}{1 + e^{-x}}$   | ให้ค่าได้ตั้งแต่ 0 ถึง 1 เป็นค่าต่อเนื่อง ซึ่งเหมาะกับการใช้เป็นค่าความเป็นไปได้ แล้วแปลงออกมาเป็นค่าสำหรับจำแนกประเภท |
| 2. ฟังก์ชันไฮเปอร์โบลิกแทนเจนต์ (Hyperbolic Tangent : tanh)                              | $\text{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$   | ให้ค่าผลลัพธ์ อยู่ในช่วง -1 ถึง 1  |
| 3. ฟังก์ชันเรกติไฟด์ ลีเนียร์ ยูนิท (Rectified Linear Unit - ReLU)                       | $\text{relu}(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases}$ | ให้ค่าเท่ากับ 0 เมื่อ คำนำเข้าเป็นค่าติดลบ และให้ค่าตามคำนำเข้า เมื่อคำนำเข้ามากกว่าหรือเท่ากับ 0                      |
| 4. ฟังก์ชันพาราเมตริกเรกติไฟด์ ลีเนียร์ ยูนิท (Parametric Rectified Linear Unit : PReLU) | $f(x) = \begin{cases} x & \text{if } x > 0 \\ ax & \text{otherwise} \end{cases}$             | ให้ค่าตามคำนำเข้า เมื่อคำนำเข้ามากกว่า 0 และให้ค่าเป็นผลคูณแอลฟากับค่านั้น ๆ ในกรณีอื่น ๆ                              |
| 5. ฟังก์ชันซอฟต์แม็กซ์ (Softmax Functon)   | $\frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$   | ให้ค่าความน่าจะเป็น ที่ผลรวมทั้งหมดเท่ากับ 1   |

ฟังก์ชันซิกมอยด์มีคุณสมบัติการใช้งานที่ใกล้เคียงกับแบบจำลองทางชีวภาพ ง่ายต่อการตีความ ฟังก์ชันนี้เหมือนการแปลงลอจิสติกทั้งหมดสามารถลดค่าที่มากเกินไปหรือค่าผิดปกติในข้อมูล โดยไม่ต้องลบออก คุณสมบัติของฟังก์ชันไฮเปอร์โบลิก แทนเจนต์จะเหมาะกับงานที่ค่านำหนักติดลบ และฟังก์ชันเรกติไฟด์ ลีเนียร์ ยูนิท ทำให้ระบบสามารถคำนวณได้เร็ว

ในส่วนของฟังก์ชันซอฟต์แม็กซ์เป็นลักษณะทั่วไปของการลดลอจิสติกเนื่องจากสามารถนำไปใช้กับข้อมูลต่อเนื่องมากกว่าจะจัดประเภทไบนารี และสามารถมีขอบเขตการตัดสินใจ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ได้หลายแบบจึงสามารถจัดการกับระบบติดป้ายกำกับหลายคลาส มักพบฟังก์ชันนี้ในงานแยกแยะประเภทหลายคลาส



รูปที่ 2.43 กราฟผลลัพธ์ (ก) ฟังก์ชันซิกมอยด์ (ข) ฟังก์ชันไฮเบอร์โบลิก เทนเจนท์ (ค) ฟังก์ชันเรกติไฟต์ ลิเนียร์ ยูนิท (ง) ฟังก์ชันพาราเมตริกเรกติไฟต์ ลิเนียร์ ยูนิท และ (จ) ฟังก์ชันซอฟต์แมกซ์

#### 2.4.1.4. การฝึกฝนแบบแพร่กลับ (Backpropagation Training)

การฝึกฝนการแพร่ย้อนกลับหรือการเรียนรู้แบบแพร่ย้อนกลับ คือ การรวมกันของขั้นตอนวิธีการแพร่ย้อนกลับ (Backpropagation Algorithm) กับขั้นตอนวิธีการหาค่าที่เหมาะสมที่สุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

(Optimization Algorithm)

1. ขั้นตอนวิธีการแพร่ย้อนกลับ

เริ่มจากการแพร่ย้อนกลับส่งผ่านค่าความผิดพลาดจากชั้นนำออกกลับไปยังชั้นก่อนหน้า เพื่อสังเกตค่าความผิดพลาดในแต่ละชั้นและคำนวณเกรเดียนต์ของฟังก์ชันการสูญเสีย (Loss Function) เทียบกับพารามิเตอร์ของแบบจำลองที่สามารถเรียนรู้ได้ (คำนวณน้ำหนักกับค่าไบแอส) จากนั้นใช้ขั้นตอนวิธีการหาค่าเหมาะที่สุดเพื่อปรับค่าพารามิเตอร์เหล่านี้ใหม่โดยอิงค่าเกรเดียนต์ที่คำนวณได้

ในขั้นตอนวิธีการแพร่ย้อนกลับใช้กฎลูกโซ่ (Chain Rule) สำหรับคำนวณเกรเดียนต์ของฟังก์ชันการสูญเสียเทียบค่าน้ำหนักหรือไบแอส ซึ่งพูดได้ว่าเทียบเท่ากับการหาค่าอนุพันธ์ของค่าความผิดพลาดเทียบกับค่าน้ำหนักหรือเทียบกับค่าไบแอสที่ละตัวในโครงข่ายประสาท การฝึกฝนจะสังเกตค่าความผิดพลาดจากผลลัพธ์ที่ได้ในแต่ละรอบการฝึก คิววิเคราะห์ไปที่ละบมลัยย้อนกลับจากชั้นนำออกไปยังชั้นนำเข้าโดยสมมติว่าค่าความผิดพลาด ณ บมใด ๆ ( $E_d$ )

ตั้งสมการคำนวณเกรเดียนต์ได้ว่า

$$\frac{\partial E_d}{\partial w_{ji}} = \frac{\partial E_d}{\partial net_j} \frac{\partial net_j}{\partial w_{ji}} \quad (2.42)$$

เมื่อ  $w_{ji}$  คือ ค่าน้ำหนักที่เชื่อมระหว่างนิวรอนนำเข้าที่  $i$  ไปนิวรอนที่  $j$  ในชั้นถัดไป และ  $net_j$  คือ ผลรวมของค่าน้ำเข้าทั้งหมดสำหรับนิวรอนที่  $j$

นิพจน์ของ  $\frac{\partial E_d}{\partial net_j}$  สามารถแยกได้ 2 กรณี ดังนี้ [49-50]

กรณีพิจารณาที่ชั้นนำออก (รูปที่ 2.44) พิจารณา  $\frac{\partial E_d}{\partial net_j}$  โดยใช้กฎลูกโซ่เทียบค่านำออกที่คำนวณมาจากนิวรอน  $j$  จะได้ว่า

$$\frac{\partial E_d}{\partial net_j} = \frac{\partial E_d}{\partial \hat{y}_j} \frac{\partial \hat{y}_j}{\partial net_j} \quad (2.43)$$

สมมติว่าใช้ฟังก์ชันการสูญเสียเป็นค่าเฉลี่ยความผิดพลาดกำลังสอง (สมการ 2.38)

$$E_d = \frac{1}{2} \sum_{k \in \text{outputs}} (y_k - \hat{y}_k)^2 \quad (2.44)$$

เมื่อ  $y$  คือ ค่าเป้าหมายหรือค่านำออกที่ต้องการ และ  $\hat{y}$  คือ ค่านำออกที่คาดคะเนออกมาได้

แทนในสมการ (2.41)

$$\begin{aligned}
 \frac{\partial E_d}{\partial ne_j} &= \frac{\partial \left( \frac{1}{2} \sum_{k \in \text{outputs}} (y_k - \hat{y}_k)^2 \right)}{\partial \hat{y}_j} \frac{\partial \hat{y}_j}{\partial ne_j} \\
 &= \frac{\partial \left( \frac{1}{2} (y_j - \hat{y}_j)^2 \right)}{\partial \hat{y}_j} \frac{\partial \hat{y}_j}{\partial net_j} \\
 &= -(y_j - \hat{y}_j) \frac{\partial \hat{y}_j}{\partial net_j}
 \end{aligned} \tag{2.45}$$

สมมติว่าใช้หน่วยซิกมอยด์ (Sigmoid Unit) ดังนั้น

$$\hat{y}_j = \frac{1}{1 + e^{-net_j}} \tag{2.46}$$

แทนค่า (2.43) ใน (2.42) จะได้

$$\begin{aligned}
 \frac{\partial E_d}{\partial net_j} &= -(y_j - \hat{y}_j) \frac{\partial \hat{y}_j}{\partial net_j} \\
 &= -(y_j - \hat{y}_j) \frac{\partial \left( \frac{1}{1 + e^{-net_j}} \right)}{\partial net_j} \\
 &= -(y_j - \hat{y}_j) \left( \frac{1}{1 + e^{-net_j}} \right) \left( 1 - \frac{1}{1 + e^{-net_j}} \right) \\
 &= -(y_j - \hat{y}_j) \hat{y}_j (1 - \hat{y}_j)
 \end{aligned} \tag{2.47}$$

แทนค่า (2.44) ใน (2.40) จะได้

$$\begin{aligned}
 \frac{\partial E_d}{\partial w_{ji}} &= -(y_j - \hat{y}_j) \hat{y}_j (1 - \hat{y}_j) \frac{\partial net_j}{\partial w_{ji}} \\
 \frac{\partial E_d}{\partial w_{ji}} &= -(y_j - \hat{y}_j) \hat{y}_j (1 - \hat{y}_j) \frac{\partial (\sum_i w_{ji} x_{ji})}{\partial w_{ji}} \\
 \frac{\partial E_d}{\partial w_{ji}} &= -(y_j - \hat{y}_j) \hat{y}_j (1 - \hat{y}_j) x_{ji}
 \end{aligned} \tag{2.48}$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

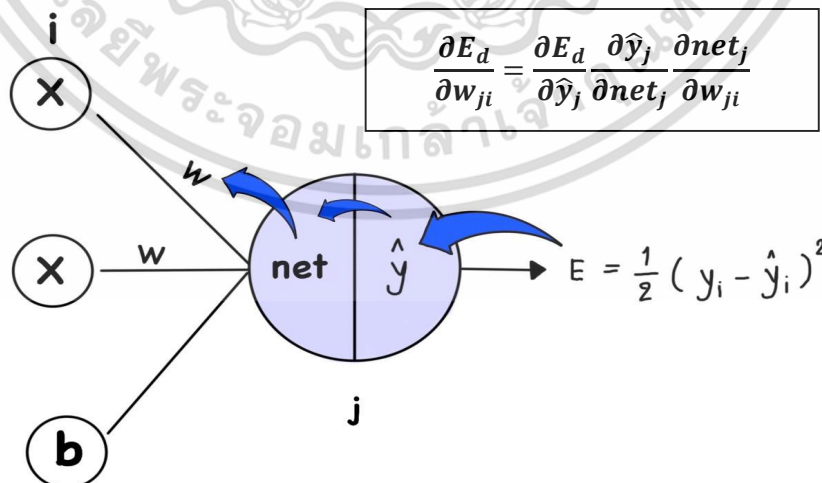
เมื่อ  $x_{ji}$  คือ ค่านำเข้าที่รับมาจากนิวรอนที่  $i$  ไปที่นิวรอน  $j$  ในชั้นถัดไป

กรณีที่พิจารณาที่ชั้นซ่อน (รูปที่ 2.45) พิจารณา  $\frac{\partial E_d}{\partial net_j}$  โดยใช้กฎลูกโซ่เทียบค่าผลรวมของค่านำเข้าทั้งหมดสำหรับแต่ละนิวรอน จะได้ว่า

$$\begin{aligned}
 \frac{\partial E_d}{\partial net_j} &= \sum_{k \in \text{Downstream}(j)} \frac{\partial E_d}{\partial net_k} \frac{\partial net_k}{\partial net_j} \\
 &= \sum_{k \in \text{Downstream}(j)} -\delta_k \frac{\partial net_k}{\partial net_j} \\
 &= \sum_{k \in \text{Downstream}(j)} -\delta_k \frac{\partial net_k}{\partial o_j} \frac{\partial \hat{y}_j}{\partial net_j} \\
 &= \sum_{k \in \text{Downstream}(j)} -\delta_k w_{kj} \frac{\partial \hat{y}_j}{\partial net_j} \\
 &= \hat{y}_j (1 - \hat{y}_j) \sum_{k \in \text{Downstream}(j)} -\delta_k w_{kj} \quad (2.49)
 \end{aligned}$$

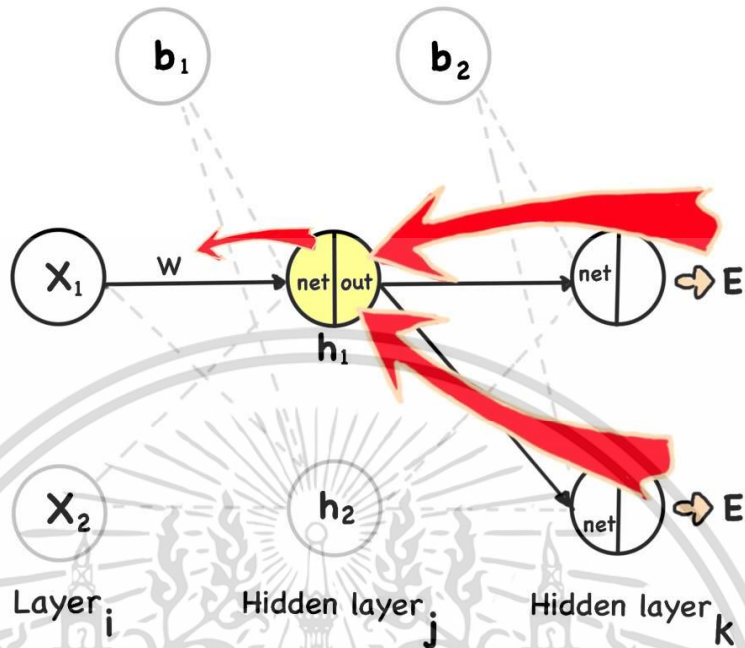
เมื่อแทนค่า (2.49) ใน (2.42)

$$\begin{aligned}
 \frac{\partial E_d}{\partial w_{ji}} &= \left[ \hat{y}_j (1 - \hat{y}_j) \sum_{k \in \text{Downstream}(j)} -\delta_k w_{kj} \right] \frac{\partial net_j}{\partial w_{ji}} \\
 \frac{\partial E_d}{\partial w_{ji}} &= \left[ \hat{y}_j (1 - \hat{y}_j) \sum_{k \in \text{Downstream}(j)} -\delta_k w_{kj} \right] x_{ji} = -\delta_j x_{ji} \quad (2.50)
 \end{aligned}$$



รูปที่ 2.44 การแพร่ย้อนกลับ กรณีพิจารณาที่ชั้นนำออก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



$$\frac{\partial E_d}{\partial net_j} = \sum_{k \in \text{Downstream}(j)} \frac{\partial E_d}{\partial net_k} \frac{\partial net_k}{\partial net_j}$$

รูปที่ 2.45 การแพร่ย้อนกลับ กรณีพิจารณาที่ชั้นซ่อน

เมื่อ  $\text{Downstream}(j)$  คือ เซตของนิวรอนทั้งหมดที่นำเข้าสู่นิวรอน  $j$  และ  $\delta_j$  คือ ค่าความผิดพลาดของนิวรอน  $j$

อัตราความผิดพลาดของชั้นนำออกและชั้นซ่อนสามารถสรุปได้ดังนี้

$$\text{ชั้นนำออก} \quad \delta_k = \hat{y}_k (1 - \hat{y}_k) (y_k - \hat{y}_k) \quad (2.51)$$

$$\text{ชั้นซ่อน} \quad \delta_h = \hat{y}_h (1 - \hat{y}_h) \sum_{k \in \text{outputs}} \delta_k w_{kh} \quad (2.52)$$

เมื่อ  $\text{outputs}$  คือ เซตจำนวนทั้งหมดที่อยู่ในชั้นนำออก

หากพิจารณากรณีฟังก์ชันกระตุ้น จะเขียนสมการได้ใหม่ว่า

$$\text{ชั้นนำออก} \quad \delta_k = f'(net_k) (y_k - \hat{y}_k) \quad (2.53)$$

$$\text{ชั้นซ่อน} \quad \delta_h = f'(net_h) \sum_{k \in \text{outputs}} \delta_k w_{kh} \quad (2.54)$$

เมื่อ  $\text{outputs}$  คือ เซตจำนวนทั้งหมดที่อยู่ในชั้นนำออก

รายละเอียดที่กล่าวมานั้น ยกตัวอย่างฟังก์ชันการสูญเสียเป็นค่าเฉลี่ยความผิดพลาดกำลังสอง แต่ในความเป็นจริงมีฟังก์ชันการสูญเสียหลายชนิดที่นำมาใช้ได้ขึ้นอยู่กับวัตถุประสงค์ว่าใช้ในงานจำพวกคาดการณ์ แยกแยะ หรืออื่น ๆ เช่น [46]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 1.1. ค่าความผิดพลาดเฉลี่ยสัมบูรณ์ (Mean Absolute Error :MAE)

อีกหนึ่งทางเลือกของการคำนวณค่าการสูญเสียแบบค่าเฉลี่ยความผิดพลาดกำลังสอง คือ ค่าความผิดพลาดเฉลี่ยสัมบูรณ์ (MAE) ดังสมการ

$$Error_{MAE} = \frac{1}{2N} \sum_{i=1}^N \sum_{j=1}^M |\hat{y}_{ij} - y_{ij}| \quad (2.55)$$

เมื่อ  $\hat{y}_{ij}$  คือ คำนำออกที่ทำนายหรือคาดคะเนออกมา  $y_{ij}$  คือ คำนำออกที่ต้องการหรือนำออกตามความจริง ค่า  $N$  คือ จำนวนนำเข้าหรือจำนวนตัวอย่าง และ  $M$  คือ จำนวนนำออก

### 1.2. ค่าเฉลี่ยความผิดพลาดลอการิทึมกำลังสอง (Mean Squared Logarithmic

Error : MSLE)

ค่าความผิดพลาดอีกประเภทหนึ่งของการถดถอยแสดงถึงความแตกต่างสัมพัทธ์ (Relative Difference) ระหว่างคำนำออกที่ต้องการกับค่าที่ได้จากการคาดคะเนของแบบจำลอง

$$Error_{MSLE} = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M (\log \hat{y}_{ij} - \log y_{ij})^2 \quad (2.56)$$

### 1.3. ค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage

Error : MAPE)

วิธีหาค่าความผิดพลาดด้วยการคำนวณร้อยละความผิดพลาดในการคาดคะเนโดยไม่คำนึงถึงเครื่องหมาย หากได้ค่านำออกมาต่ำ หมายถึง แบบจำลองมีความแม่นยำสูง เขียนสมการได้ดังนี้

$$Error_{MAPE} = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M \frac{100 \times |\hat{y}_{ij} - y_{ij}|}{y_{ij}} \quad (2.57)$$

### 1.4. ค่าความผิดพลาดไบนารี ครอส เอนโทรปี (Binary Cross-entropy Loss)

เป็นหนึ่งในวิธีคำนวณค่าความผิดพลาดในแบบจำลองการเรียนรู้เชิงลึกประเภทแยกแยะ (Classification) เพื่อความสะดวกทางคณิตศาสตร์ เมื่อต้องจัดการกับผลคูณของความน่าจะเป็นปกติจะแปลงให้เป็นค่าล็อก (Log) ของความน่าจะเป็น กำหนดเป็นค่าติดลบเพื่อให้สมการนี้สอดคล้องกับการสูญเสียหรือความผิดพลาด วิธีนี้ใช้สำหรับกรณีที่มีคำนำออกสองตัว อย่างเช่น การถดถอยแบบลอจิสติก

$$Error_{\text{binary cross entropy}} = -y \cdot \log(\hat{y}) - (1 - y) \cdot \log(1 - \hat{y}) \quad (2.58)$$

### 1.5. ค่าความผิดพลาดครอส เอนโทรปี (Cross-entropy loss)

จากวิธีคำนวณแบบไบนารี คลอส เอนโทรปีสำหรับนำออกสองตัว เมื่อมีการเพิ่มจำนวนนำออกเป็นหลายคลาส จะปรับสมการค่าความผิดพลาดเป็นแบบครอส เอนโทรปี โดยเขียนสมการได้ว่า

$$Error_{\text{cross entropy}} = -y \cdot \log(\hat{y}) \quad (2.59)$$

## 2. ขั้นตอนวิธีการหาค่าที่เหมาะสมที่สุด

หลังจากได้ค่าเกรเดียนต์ของค่าน้ำหนักและค่าไบแอสแต่ละตัวมาแล้วนำค่าที่ได้มาใช้เพื่อปรับค่าน้ำหนักและค่าไบแอสใหม่ ค่าเกรเดียนต์เหล่านี้บ่งชี้ถึงทิศทางและขนาดของการเปลี่ยนแปลงที่จำเป็นเพื่อให้ได้ค่าฟังก์ชันการสูญเสียที่น้อยที่สุดและพัฒนาประสิทธิภาพให้กับแบบจำลองเรียนรู้เชิงลึก ซึ่งกระทำผ่านขั้นตอนวิธีการหาค่าที่เหมาะสมที่สุด [49]

การหาค่าความเหมาะสมที่สุดมีขั้นตอนวิธีหลายแบบในทางคณิตศาสตร์ แต่ขั้นตอนวิธีที่เป็นที่นิยมในระบบการเรียนรู้เชิงลึก คือ ขั้นตอนวิธีในตระกูลเคลื่อนลงตามความชัน (Gradient Descent) จัดอยู่ในประเภทขั้นตอนวิธีหาค่าความเหมาะสมที่สุดลำดับที่หนึ่ง (First Order Optimization Algorithms)

**ขั้นตอนวิธีการเคลื่อนลงตามความชัน (Gradient Descent Algorithm)** วิธีการอิงกับอนุพันธ์อันดับที่หนึ่งของฟังก์ชันการสูญเสียเทียบกับค่าน้ำหนัก ถือว่าเป็นวิธีการที่เรียบง่ายที่สุดในขั้นตอนวิธีของตระกูลนี้โดยค่าน้ำหนักตัวใหม่สามารถคำนวณได้ด้วยสมการ

$$W_{\text{new}} = W_{\text{old}} - lr \frac{\partial E}{\partial w} \quad (2.60)$$

เมื่อ  $lr$  คือ อัตราการเรียนรู้ (Learning Rate) เป็นตัวควบคุมจำนวนการปรับค่าน้ำหนักให้ลู่ออกสู่จุดต่ำสุด เสมือนเป็นค่าสัมประสิทธิ์ปรับขนาดของขั้นการปรับค่า ถ้ากำหนดอัตราการเรียนรู้ไว้สูง ๆ จะส่งผลให้การปรับค่าเป็นไปอย่างก้าวกระโดด ปรับครั้งละมาก ๆ ทำให้ค่าน้ำหนักลู่ออกจุดต่ำสุดได้เร็ว แต่ก็ทำให้เสี่ยงต่อการพลาดค่าที่ดีที่สุด (ค่าความผิดพลาดที่ต่ำที่สุด) หากตั้งค่าน้อย ๆ จะใช้เวลาในการปรับค่านานแต่มีความละเอียดมากกว่าอัตราการเรียนรู้สูง ๆ  $W_{\text{new}}$  คือ ค่าน้ำหนักที่ปรับใหม่  $W_{\text{old}}$  คือ ค่าน้ำหนักตัวเก่า และ  $\frac{\partial E}{\partial w}$  คือ เกรเดียนต์ความผิดพลาดเทียบกับค่าน้ำหนัก

ตระกูลย่อยของการเคลื่อนลงตามความชัน (Gradient Descent) ประกอบด้วย

### 2.1 การเคลื่อนลงตามความชันแบบสโตแคสติก (Stochastic Gradient Descent :

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

SGD)

เป็นขั้นตอนวิธีที่คำนวณด้วยเกรเดียนต์ของฟังก์ชันการสูญเสียเทียบกับค่าน้ำหนักสำหรับข้อมูลตัวอย่างแต่ละตัวและปรับค่าน้ำหนักใหม่หลังจากผ่านข้อมูลตัวอย่างแต่ละตัวแล้ว ยกตัวอย่างเช่น ข้อมูลฝึกฝนเป็นรูปภาพ วิธีนี้จะพิจารณาทีละภาพ หนึ่งภาพต่อหนึ่งการปรับค่าใหม่ ต่อหนึ่งรอบ แตกต่างกับขั้นตอนวิธีการเคลื่อนลงตามความชัน (Gradient Descent) ที่พยายามปรับค่าน้ำหนักโดยใช้ชุดข้อมูลทั้งหมดคำนวณเกรเดียนต์ของฟังก์ชันการสูญเสียทั้งหมด และปรับค่าน้ำหนักหนึ่งครั้งหลังจากผ่านชุดข้อมูลทั้งหมดแล้ว สามารถเขียนสมการได้ว่า

$$w_{t+1} = w_t - lr \frac{\partial E}{\partial w} \quad (2.61)$$

เมื่อ  $t$  คือ จำนวนครั้งหรือช่วงเวลา

ในทุกครั้งที่มีการปรับปรุง ค่าพารามิเตอร์ที่ได้มาใหม่จะมีความแปรปรวนสูงและส่งผลกระทบต่อฟังก์ชันการสูญเสีย แปรผันไปตามความเข้มต่าง ๆ โดยขั้นตอนเหล่านี้เป็นสิ่งที่ดีเพราะช่วยให้สามารถค้นพบค่าที่น้อยที่สุดได้ แต่วิธีนี้มีปัญหา คือ ยิ่งลู่ลงต่ำเท่าไร ค่าที่ได้ก็ยิ่งแปรปรวนและซับซ้อนมากยิ่งขึ้น

## 2.2 การเคลื่อนลงตามความชันแบบมินิแบตช์ (Mini Batch Gradient Descent)

เนื่องจากวิธีแบบสโตแคสติกมีความแปรปรวนสูงเมื่อลู่ลงต่ำจึงมีการพัฒนาวิธีซึ่งรวมข้อดีของทั้งวิธีการเคลื่อนที่ตามความชันและแบบสโตแคสติกชื่อว่า การเคลื่อนลงตามความชันแบบมินิแบตช์ (Mini Batch Gradient Descent) ด้วยขั้นตอนวิธีนี้แบบจำลองเรียนรู้เชิงลึกจะปรับค่าน้ำหนักด้วยการคำนวณด้วยค่าเกรเดียนต์ของกลุ่มชุดข้อมูลตัวอย่างที่แบ่งไว้ มักแบ่งเป็นจำนวน  $2^n$  ข้อมูล อาจที่ละ 32 64 และ 128 เป็นต้น เขียนสมการได้ว่า

$$w_{t+1} = w_t - lr \frac{\partial E}{\partial w(B(i))} \quad (2.62)$$

โดย  $B(i)$  คือ ชุดข้อมูลสุ่มจากชุดข้อมูลตัวอย่างฝึกฝน

## 2.3 โมเมนตัม (Momentum)

ขั้นตอนวิธีโมเมนตัมถูกคิดค้นเพื่อเร่งความเร็วในการหาค่าความเหมาะสมที่สุดของการเคลื่อนลงตามความชันแบบสโตแคสติกโดยการให้ความสำคัญในการพุ่งไปยังทิศทางที่ใกล้จุดกลางมากที่สุดก่อน แล้วทำให้ทิศทางที่ไม่เกี่ยวข้องลดความสำคัญลงส่งผลให้เกิดทิศทางที่ “ถูกต้อง” ด้วยการเพิ่มตัวแปรโมเมนตัม ‘ $\beta$ ’ เข้ามาในการปรับปรุงทิศทางในแต่ละครั้ง ดังสมการ

$$m_t = \beta m_{t-1} + (1 - \beta) \frac{\partial E}{\partial w_t} \quad (2.63)$$

ปรับปรุงค่าน้ำหนักด้วย

$$w_{t+1} = w_t - lr(m_t) \quad (2.64)$$

ซึ่งค่าโมเมนต์นิยมตั้งไว้ที่ 0.9 หรือน้อยกว่านั้น

2.4 การเคลื่อนลงตามความชันแบบปรับค่าได้ (Adaptive Gradient Algorithm : Adagrad)

ขั้นตอนวิธีนี้สามารถปรับค่าอัตราการเรียนรู้ให้เหมาะสมกับพารามิเตอร์ได้ ปรับอัตราเรียนรู้ให้ต่ำ ๆ ในกรณีที่ค่าพารามิเตอร์อย่างค่าน้ำหนักถูกปรับใหม่บ่อย ๆ เพื่อให้ค่อย ๆ ปรับค่า และปรับอัตราเรียนรู้ให้สูง ๆ สำหรับกรณีที่ค่าน้ำหนักถูกปรับใหม่ไม่บ่อยเพื่อให้สามารถปรับค่าแบบก้าวกระโดด ทั้งนี้ ค่าอัตราการเรียนรู้ถูกเปลี่ยนทุก ๆ ครั้งด้วยการหารกับค่ารากที่สองของ  $v$  ที่เป็นผลรวมของค่าคำนวณเกรเดียนต์ตัวปัจจุบันกับในอดีตตามจำนวน  $t$  ครั้ง ดังสมการ

$$w_{t+1} = w_t - \frac{lr}{\sqrt{v_t + \epsilon}} \cdot \frac{\partial E}{\partial w_t} \quad (2.65)$$

โดยที่

$$v_t = v_{t-1} + \left[ \frac{\partial E}{\partial w_t} \right]^2 \quad (2.66)$$

เมื่อ  $\epsilon$  คือ ค่าเกลี่ย (smoothing term) เพื่อเลี่ยงไม่ใหหารด้วย 0

2.5 การปรับค่าเดลต้า (Adaptive Delta : AdaDelta)

ขั้นตอนวิธีปรับค่าเดลต้าเป็นตัวต่อยอดมาจากขั้นตอนวิธีการเคลื่อนลงตามความชันแบบปรับค่าได้โดยสามารถลบปัญหาอัตราการเรียนรู้ลดลงเรื่อย ๆ ในขณะที่ค่ารอบการเรียนรู้ (Epoch) เพิ่มขึ้นที่เกิดขึ้นในวิธีแบบปรับค่าได้ โดยเปลี่ยนจากใช้พารามิเตอร์อัตราการเรียนรู้เป็นค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซับซ้อน (Exponential Moving Average) ของค่ารากที่สองของเดลต้า (Delta :  $D$ ) ที่หมายถึง ความแตกต่างระหว่างค่าน้ำหนักตัวปัจจุบันกับตัวใหม่

$$w_{t+1} = w_t - \frac{\sqrt{D_{t-1} + \epsilon}}{\sqrt{v_t + \epsilon}} \cdot \frac{\partial E}{\partial w_t} \quad (2.67)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยที่

$$D_t = \beta D_{t-1} + (1 - \beta)(\Delta w_t)^2 \quad (2.68)$$

$$v_t = \beta v_{t-1} + (1 - \beta) \left[ \frac{\partial E}{\partial w_t} \right]^2 \quad (2.69)$$

## 2.6 การประมาณค่าช่วงเวลาปรับตัว (Adaptive Moment Estimation : Adam)

เป็นตัวหาค่าความเหมาะสมที่สุดที่สามารถปรับอัตราการเรียนรู้สำหรับพารามิเตอร์ในแต่ละครั้งได้และยังสามารถแก้ปัญหาอัตราการเรียนรู้เล็กลงเรื่อย ๆ (Decaying) ในแต่ละขั้นที่ผ่านมาได้เหมือนกับขั้นตอนวิธีปรับค่าเดลต้า อีกทั้งยังอธิบายการเกิดค่าแปรปรวนในการลู่อู่เข้าของการเคลื่อนที่ที่ผ่านมาเหมือนกับขั้นตอนวิธีโมเมนตัม นับเป็นขั้นตอนวิธีซึ่งรวมข้อดีของวิธีการก่อนหน้ามาทั้งหมด

เขียนสมการได้ว่า

$$w_{t+1} = w_t - \frac{lr}{\sqrt{\hat{v}_t + \epsilon}} \cdot \hat{m}_t \quad (2.70)$$

โดยที่

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (2.71)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (2.72)$$

เป็นตัวประมาณค่าแก้ไขไบแอส ในช่วงเวลาที่หนึ่งและสอง และ

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \left( \frac{\partial E}{\partial w_t} \right) \quad (2.73)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) \left[ \frac{\partial E}{\partial w_t} \right]^2 \quad (2.74)$$

โดยมักกำหนดให้ค่า  $lr$  เท่ากับ 0.001 ค่า  $\beta_1$  เท่ากับ 0.9 ค่า  $\beta_2$  เท่ากับ 0.999 และค่า  $\epsilon$  เท่ากับ  $10^{-8}$

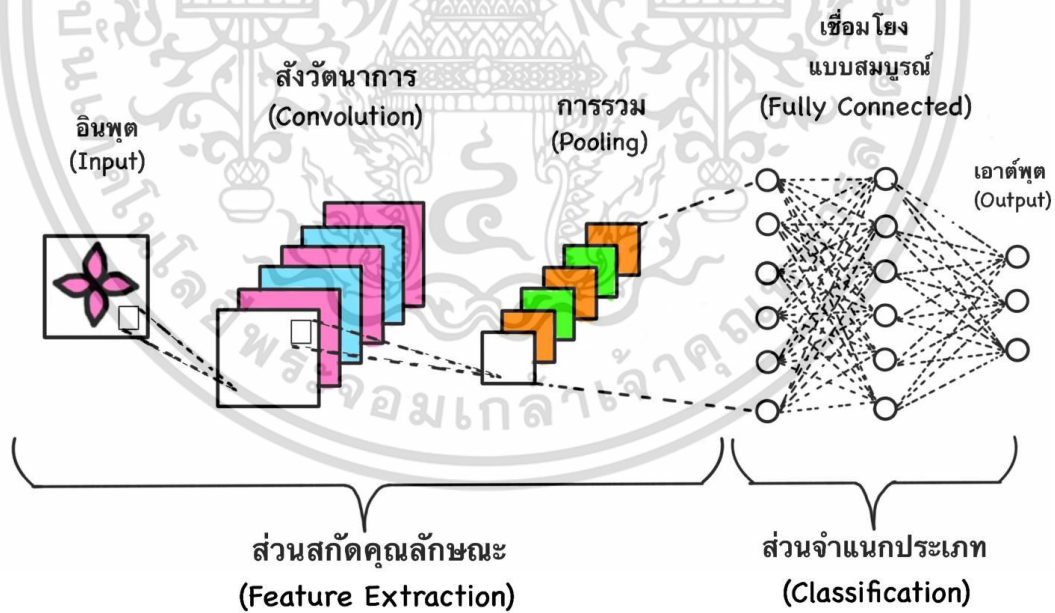
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ทั้งนี้ สำหรับการเปลี่ยนแปลงค่าไบแอสก็สามารถใช้วิธีการเดียวกับการเปลี่ยนแปลงค่าน้ำหนักทั้งหมดที่กล่าวมาได้

#### 2.4.2 โครงข่ายประสาทแบบสังวัตนาการ (Convolution Neural Network : CNN)

โครงข่ายประสาทแบบทั่วไปนั้น นิวรอนแต่ละตัวในชั้นนำเข้าจะเชื่อมต่อเข้ากับทุกนิวรอนในชั้นถัดไปเรียกการเชื่อมต่อแบบนี้ว่า ชั้นเชื่อมโยงแบบสมบูรณ์ (Fully-connected Layer) อาจจะมีหนึ่งหรือสองชั้นหรือมากกว่านั้น แต่สำหรับโครงข่ายประสาทแบบสังวัตนาการไม่ใช่ชั้นเชื่อมโยงแบบสมบูรณ์จนกว่าจะถึงชั้นช่วงท้าย ๆ ที่เป็นชั้นกลุ่มสุดท้ายของโครงข่าย ส่วนชั้นก่อนหน้านั้นจะเป็นชั้นสังวัตนาการ (Convolution Layer) (รูปที่ 2.46) เป็นหลักซึ่งเป็นที่มาของชื่อโครงข่ายนี้

แต่ละชั้นในโครงข่ายใช้รูปแบบของตัวกรองแตกต่างกันไปและรวมผลลัพธ์นั้นส่งต่อไปยังชั้นต่อไป ระหว่างการฝึกฝนตัวโครงข่ายเรียนรู้ค่าต่าง ๆ ของตัวกรองเหล่านี้โดยอัตโนมัติ ในหมวดของการตัดแยกภาพตัวโครงข่ายสามารถเรียนรู้เพื่อตรวจจับเส้นขอบจากข้อมูลพิกเซลดิบในชั้นแรก แล้วใช้เส้นขอบเหล่านี้ตรวจจับรูปทรงในชั้นที่สอง และใช้รูปทรงพวกนี้เพื่อตรวจจับคุณลักษณะที่ระดับสูงขึ้นไป เช่น โครงสร้างใบหน้า ชิ้นส่วนของรถ ในชั้นที่ลึกลงไปของโครงข่าย และในชั้นสุดท้ายโครงข่ายประสาทแบบสังวัตนาการใช้คุณลักษณะระดับสูงเหล่านี้สำหรับคาดคะเนหรือทำนายเนื้อหาของภาพออกมา



รูปที่ 2.46 โครงสร้างโครงข่ายประสาทแบบสังวัตนาการ

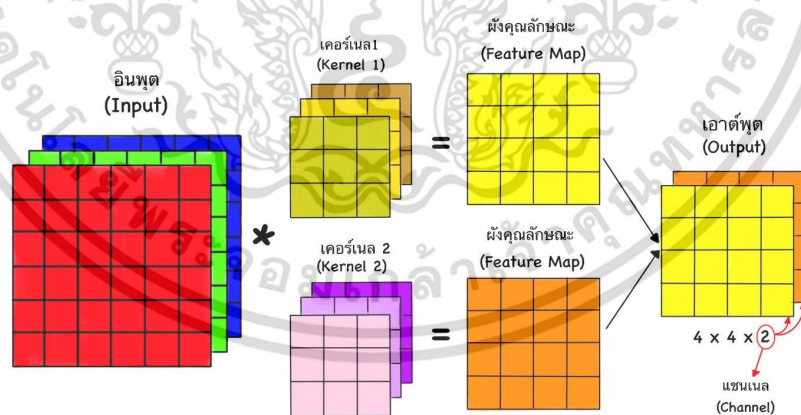
การใช้โครงข่ายประสาทแบบสังวัตนาการมีคุณประโยชน์สองประการ คือ ความคงที่เฉพาะจุด (Local Invariance) ช่วยให้จัดประเภทวัตถุภายในภาพโดยไม่คำนึงว่าวัตถุนั้นปรากฏที่ตำแหน่งใด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และความเป็นองค์ประกอบศิลป์ (Compositionality) ได้จากคุณลักษณะที่แต่ละตัวกรองในโครงข่ายประกอบด้วยร่างต่อฟิล์มเฉพาะจุด (Local Patch) ของคุณลักษณะระดับต่ำซึ่งใช้เป็นตัวแทนของคุณลักษณะที่ระดับสูงกว่า ด้วยองค์ประกอบนี้ทำให้โครงข่ายสามารถเรียนรู้คุณลักษณะที่หลากหลายมากขึ้น กล่าวคือ โครงข่ายประสาทแบบสังวัตนาการสามารถสร้างคุณลักษณะระดับสูงขึ้นมาได้จากคุณลักษณะระดับต่ำ [51]

รูปที่ 2.46 แสดงโครงข่ายประสาทแบบสังวัตนาการซึ่งแบ่งการทำงานออกเป็นสองส่วน ส่วนที่ทำหน้าที่สกัดข้อมูลคุณลักษณะกับส่วนที่ทำหน้าที่จำแนกประเภท ส่วนแรกประกอบด้วยชั้นสังวัตนาการกับชั้นการรวม (Pooling Layer)

**ชั้นสังวัตนาการ** ถือเป็นหลักการดำเนินการสังวัตนาการด้วยเคอร์เนล (Kernel) ขนาดเล็กกับภาพนำเข้าที่มีขนาดใหญ่กว่า เกิดเป็นการเชื่อมโยงภายในพื้นที่ที่เล็ก ๆ เฉพาะจุดขนาดเท่าเคอร์เนลช่วยลดจำนวนการเชื่อมต่อและจำนวนน้ำหนักลงจากแบบโครงข่ายประสาทปกติ สำหรับเคอร์เนลหรือตัวกรองในงานนี้ คือ เมทริกซ์ทรงสี่เหลี่ยมจัตุรัสซึ่งภายในบรรจุค่าน้ำหนักที่สามารถเรียนรู้ได้ ระหว่างการฝึกฝนค่าเหล่านี้ถูกปรับใหม่เพื่อให้สามารถตรวจจับเส้นขอบและโครงสร้างคล้ายบล็อบ (Blob-Like Structures) [51] ในขั้นต้นได้และสามารถตรวจจับวัตถุระดับสูง เช่น ใบหน้า ทमा แมว และอื่น ๆ ได้ในขั้นที่ลึกลงไป ในขณะที่ภาพนำเข้าอาจมีความลึกหรือแชนเนล (Channel) มากกว่าหนึ่ง เช่น ภาพสี ประกอบด้วย 3 แชนเนล จำเป็นต้องขยายเคอร์เนลให้ครอบคลุมทุกแชนเนลและสร้างหนึ่งผังคุณลักษณะ (Feature Map) ออกมา หากต้องการเพิ่มแชนเนลในผังคุณลักษณะสามารถทำได้ด้วยการเพิ่มจำนวนเคอร์เนล (รูปที่ 2.47)



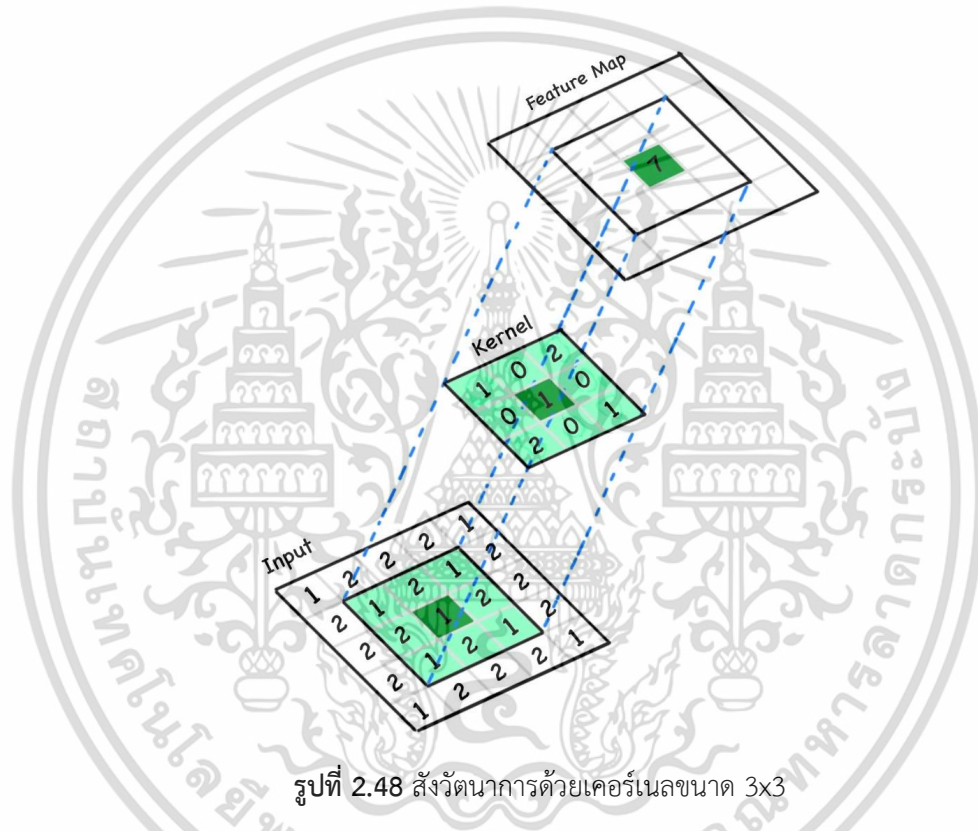
รูปที่ 2.47 การสังวัตนาการด้วยเคอร์เนลด้วยจำนวนแชนเนลเท่ากับข้อมูลนำเข้า สร้างผังคุณลักษณะหนึ่งแชนเนล และจำนวนเคอร์เนลกำหนดจำนวนแชนเนลของผังคุณลักษณะ (ผังสีเหลืองและสีส้ม)

หลังจากกำหนดจำนวนและขนาดของเคอร์เนลแล้วดำเนินการสังวัตนาการด้วยการวางทาบเคอร์เนลลงบนเมทริกซ์นำเข้า เช่น เมทริกซ์ภาพ เป็นต้น จากนั้นคำนวณผลรวมของผลคูณระหว่างค่า

น้ำหนักในคอร์เนลกับค่าเมทริกซ์ในตำแหน่งเดียวกัน จากนั้นวางค่านำออกบนผังคุณลักษณะในตำแหน่งเดียวกับจุดกำหนด (Origin) ของคอร์เนล (รูปที่ 2.48) ดังสมการ

$$S(i,j) = (I * K)(i,j) = \sum_m \sum_n K(i - m, j - n)I(m,n) \quad (2.75)$$

เมื่อ  $I$  คือ ภาพนำเข้า  $K$  คือ คอร์เนล  $mn$  คือ ตำแหน่งแถวและคอลัมน์ในภาพนำเข้า  $(i, j)$  คือ ตำแหน่งพิกเซลบนผังคุณลักษณะ และ  $S$  คือ ผังคุณลักษณะ



รูปที่ 2.48 สังวัตนาการด้วยคอร์เนลขนาด 3x3

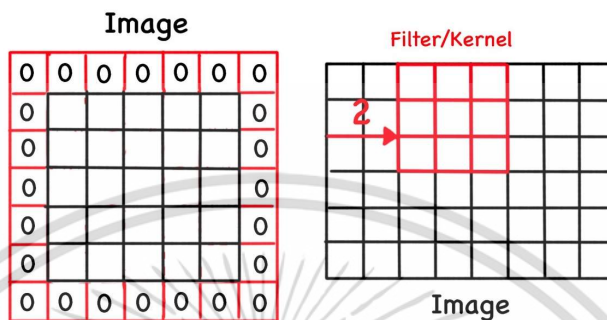
เมื่อได้ค่านำออกแล้วก็เลื่อนคอร์เนลไปทางขวา คำนวณค่านำออกอีกค่า จากนั้นเลื่อนต่อจนสุดขอบภาพแล้วขยับลงมาในตำแหน่งซ้ายสุดของภาพแล้วคำนวณซ้ำไปเรื่อย ๆ จนคอร์เนลเลื่อนผ่านทั้งภาพ แต่การดำเนินการแบบนี้ตำแหน่งจุดกำเนิดของคอร์เนลจะไม่ผ่านกรอบรอบนอกของภาพเป็นเหตุให้ขนาดของผังคุณลักษณะเล็กลงจากขนาดนำเข้า ดังนั้นเพื่อคงขนาดดั้งเดิมไว้ต้องอาศัยการเสริมเต็ม (Padding) (รูปที่ 2.49ก) เพิ่มกรอบรอบนอกของเข้าไปอีกชั้นหนึ่งด้วยค่า 0 เนื่องจากค่า 0 ไม่ส่งผลต่อผลลัพธ์หรือเรียกว่าเป็นค่าที่ถูกเมินและนอกจากค่าเสริมเต็มแล้วยังมีอีกหนึ่งพารามิเตอร์ที่มีผลต่อขนาดผลลัพธ์ นั่นคือ ค่าก้าว (Stride) เป็นพารามิเตอร์กำหนดจำนวนช่องในการเลื่อนคอร์เนล (รูปที่ 2.49ข)

การกำหนดขนาดของค่าเสริมเต็ม ( $p$ ) กับค่าก้าว ( $S$ ) รวมทั้งขนาดคอร์เนล ( $k$ ) และภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

นำเข้า ( $n_{in}$ ) ช่วยให้กำหนดขนาดของฟังก์ชันลักษณะ ( $n_{out}$ ) ด้วยสมการ

$$n_{out} = \left\lfloor \frac{n_{in} + 2p - k}{s} \right\rfloor + 1 \quad (2.76)$$



รูปที่ 2.49 (ก) การเสริมเต็มเท่ากับ 1 และ (ข) ค่าก้าวขนาด 2

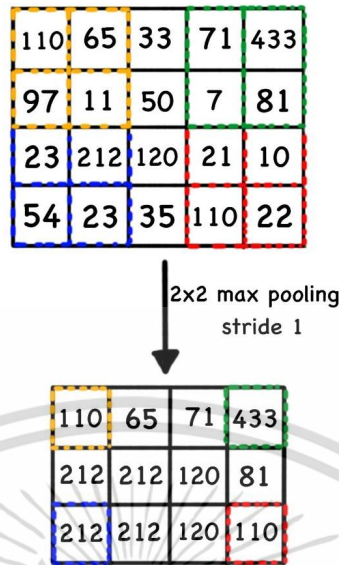
หลังเสร็จสิ้นการสร้างฟังก์ชันลักษณะดำเนินการใช้ฟังก์ชันกระตุ้นไม่เป็นเชิงเส้นเหมือนกับในโครงข่ายประสาทแบบทั่วไปสามารถใช้ได้ทุกตัวแต่ฟังก์ชันเรคตีไฟด์ ลิเนียร์ ยูนิท (ReLU) เป็นตัวนิยมที่สุดในโครงข่ายประเภทนี้ จากนั้นส่งฟังก์ชันลักษณะที่ผ่านการแปลงค่าด้วยฟังก์ชันกระตุ้นไปยังขั้นถัดไป คือ ขั้นการรวม

**ขั้นการรวม** เป็นขั้นที่สองในส่วนสกัดคุณลักษณะทำหน้าที่ลดขนาดของฟังก์ชันลักษณะที่เป็นนำเข้า ช่วยลดจำนวนพารามิเตอร์และการคำนวณในโครงข่าย รวมทั้งควบคุมการเรียนรู้เกินกว่าที่ควร (Overfitting) มักใช้ฟังก์ชันค่ามาก (Max) และค่าเฉลี่ย (Average) ในรูปที่ 2.50 แสดงการรวมค่ามาก (Max Pooling) จะเป็นการเลือกเก็บเฉพาะค่าที่มากที่สุดในพื้นที่เท่าขนาดการรวม (Pooling) และกำหนดก้าวเท่ากับหนึ่ง ส่วนการรวมค่าเฉลี่ย (Average Pooling) เก็บค่าเฉลี่ยของค่าภายในพื้นที่ตามขนาดการรวม ขนาดของฟังก์ชันลักษณะอันใหม่ที่ลดขนาดลงสามารถคำนวณได้ด้วยสมการ (2.60) ซึ่งได้รับอิทธิพลจากจำนวนก้าว ( $s$ ) และขนาดการรวม (Pool size :  $k_p$ )

$$n_{out} = \left\lfloor \frac{n_{in} - k_p}{s} \right\rfloor + 1 \quad (2.77)$$

ส่วนที่สองของโครงข่ายแบบสังวัตนาการที่ทำหน้าที่จำแนกประเภท คือ ชั้นเชื่อมโยงแบบสมบูรณ์

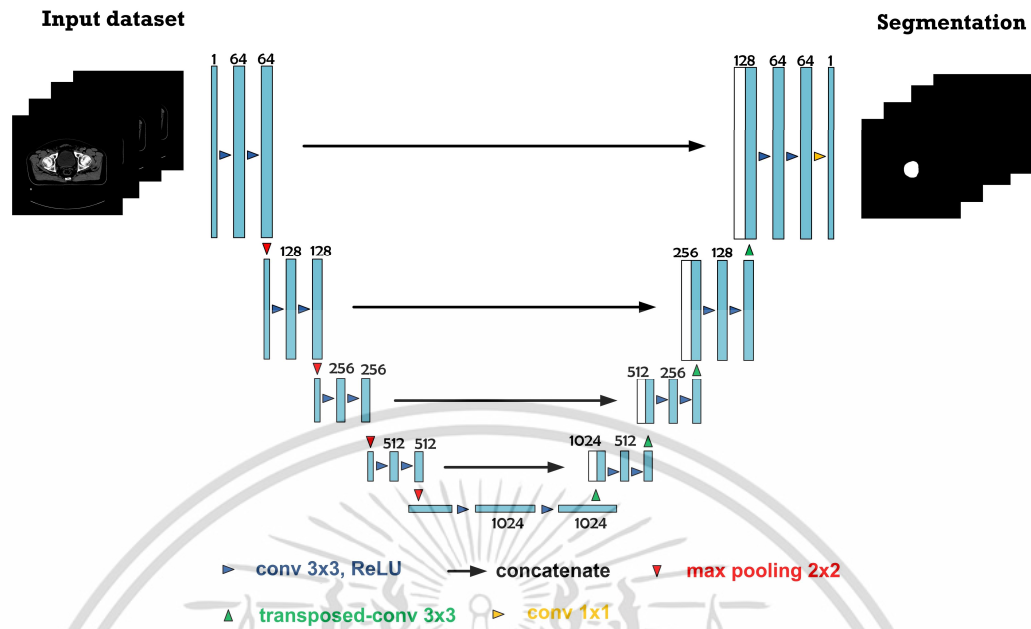
**ชั้นเชื่อมโยงแบบสมบูรณ์** มีรูปแบบดำเนินการไปตามแบบมาตรฐานของโครงข่ายประสาทแบบแพร่ไปข้างหน้าที่เคยอธิบายมาในหัวข้อ 2.4.1.2. ชั้นเชื่อมโยงแบบสมบูรณ์จะถูกลวงไว้ที่ส่วนท้ายของโครงข่ายเสมอ มักวางไว้สองชั้นก่อนใช้ฟังก์ชันซอฟต์แวร์แม็กซ์เพื่อแปลงให้เป็นค่าความน่าจะเป็นของแต่ละคลาสสำหรับจำแนกประเภท



รูปที่ 2.50 ขนาดฟังก์ชันลักษณะที่ถูกลดด้วยการรวมขนาด 2x2 จำนวนก้าวเท่ากับ 1 ด้วยฟังก์ชันค่ามาก

### 2.4.3 โครงข่ายประสาทแบบ U-Net

โครงข่ายประสาท U-Net เป็นโครงข่ายประเภทโครงข่ายประสาทแบบสังวัตนาการที่ ถูกออกแบบมาสำหรับงานแบ่งส่วนความหมาย (Semantic Segmentation) โดยมีเป้าหมายเพื่อการจัดประเภทแต่ละพิกเซลในภาพออกเป็นคลาสหรือหมวดหมู่ต่าง ๆ ในรูปที่ 2.51 แสดงโครงสร้างของโครงข่าย U-Net ที่มีรูปทรงเป็นรูปตัวยูและเป็นโครงข่ายตัวเข้ารหัส-ตัวถอดรหัส (Encoder-Decoder) ตัวเข้ารหัสจะอยู่ทางซ้ายของโครงข่ายประกอบด้วยชั้นสังวัตนาการและชั้นการรวม ทำหน้าที่จับคุณลักษณะและเรียนรู้ข้อมูลนำเข้าที่ถูกบีบอัดซึ่งรวบรวมคุณลักษณะที่จำเป็นและให้ข้อมูลมากที่สุด ในขณะที่ละทิ้งข้อมูลที่ไม่จำเป็นหรือซ้ำซ้อน ในส่วนของตัวถอดรหัสอยู่ฝั่งขวาของโครงข่ายประกอบด้วยชั้นสังวัตนาการสลับเปลี่ยน (Transpose Convolution Layer) และชั้นสังวัตนาการดำเนินการเพื่อกู้คืนความละเอียดของฟังก์ชันลักษณะกลับมาให้มีขนาดเท่าภาพนำเข้า พร้อมทั้งสกัดข้อมูลคุณสมบัติ จำแนกประเภท และติดป้ายกำกับแต่ละพิกเซลจนได้ผังการแบ่งส่วนหนาแน่นที่มีขนาดเชิงพื้นที่เหมือนกับภาพนำเข้าโดยที่แต่ละพิกเซลถูกกำหนดป้ายกำกับเฉพาะ นอกจากนี้ยังมีวิธีเสริมเพิ่มเข้ามาอย่างเส้นเชื่อมโยงข้าม (Skip Connection) ที่เชื่อมโยงฟังก์ชันลักษณะระหว่างชั้นฝั่งตัวเข้ารหัสกับชั้นฝั่งตัวถอดรหัสที่มีขนาดสัมพันธ์กันโดยตรงเพื่อรักษาข้อมูลเชิงพื้นที่แบบละเอียดในระหว่างกระบวนการเพิ่มความละเอียด (Upsampling Process)

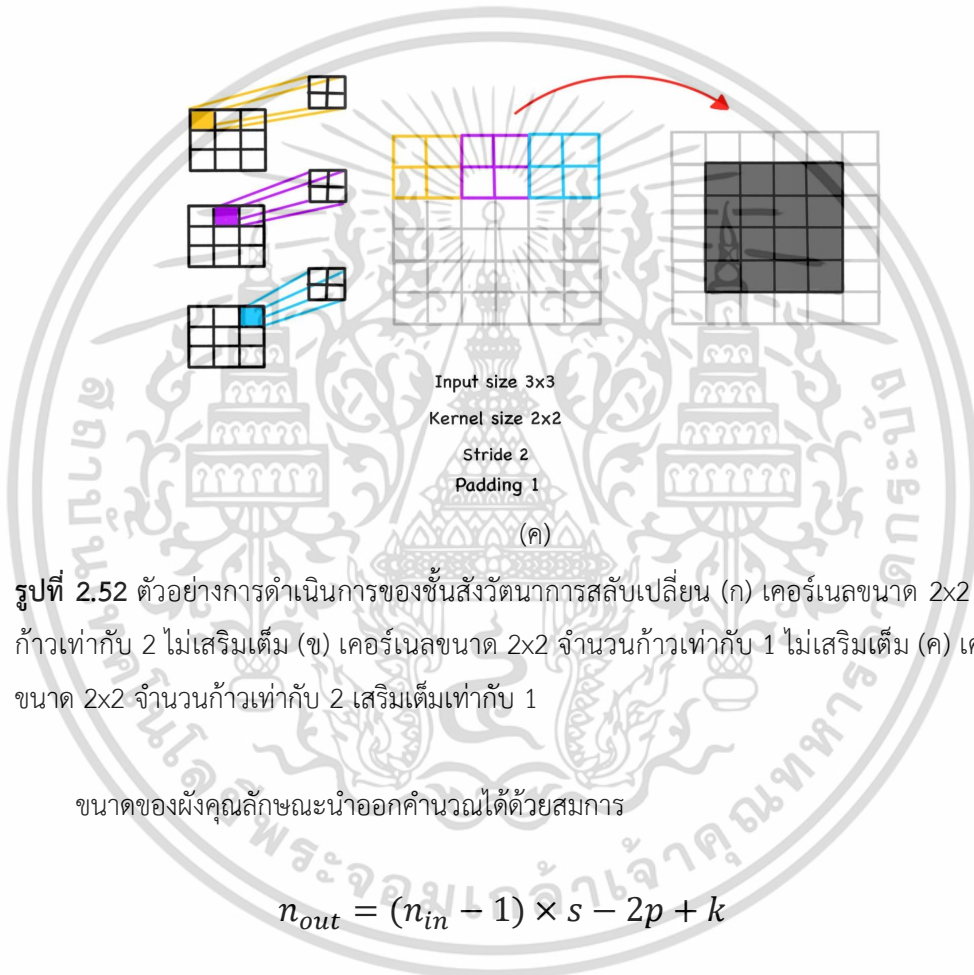
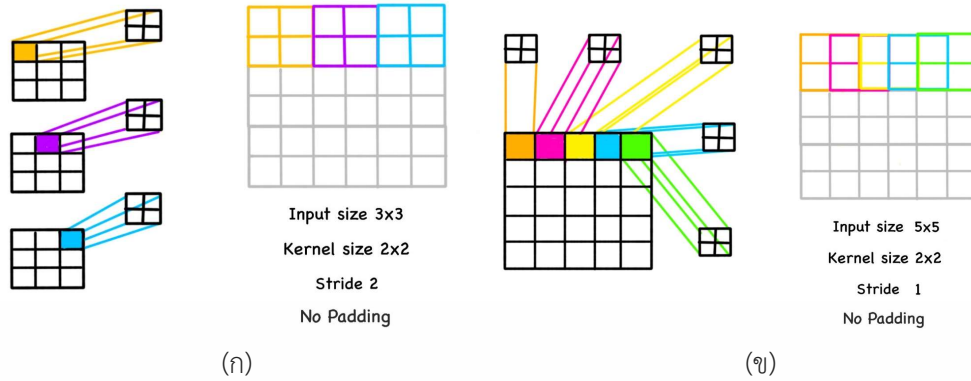


รูปที่ 2.51 โครงข่ายประสาทแบบ U-Net

### ขั้นสังวัตนาการสลับเปลี่ยน

ขั้นสังวัตนาการสลับเปลี่ยนเพิ่มขนาดของฟังก์ชันลักษณะที่ถูกลดจากชั้นการรวมในกระบวนการก่อนหน้าด้วยการสังวัตนาการ แต่การดำเนินการแตกต่างจากขั้นสังวัตนาการ เริ่มด้วยการทำงานของคอร์เนลเป็นอย่างไร จากรูปที่ 2.52 เมื่อวางทาบคอร์เนลที่บรรจุค่าน้ำหนักซ้อนทับบนผังนำเข้า แต่ละพิกเซลคูณกับค่าน้ำหนักบนคอร์เนลแต่ละค่าและวางค่าผลลัพธ์ไว้ในตำแหน่งพิกเซลเดียวกับตำแหน่งของค่าน้ำหนักบนคอร์เนลที่คูณด้วยบนผังนำออก จากนั้นเลื่อนคอร์เนลไปหนึ่งช่องเสมอ ทว่าการเลื่อนวางค่าผลลัพธ์ถัดมาจะขึ้นอยู่กับจำนวนก้าวที่กำหนด เช่น กำหนดจำนวนก้าวเท่ากับ 2 ตำแหน่งวางจะถูกเลื่อนมาสองช่อง (รูปที่ 2.52ก) แต่ถ้ากำหนดจำนวนก้าวเท่ากับ 1 หรือจำนวนใด ๆ ที่ทำให้ค่าผลคูณซ้อนทับกับค่าครั้งก่อน (รูปที่ 2.52ข) ค่าที่ซ้อนทับจะถูกคิดรวมกัน ไล่ดำเนินการซ้ำ ๆ จนได้ค่าสุดท้ายและกลายเป็นฟังก์ชันลักษณะนำออกออกมา ขนาดของผังนำออกนั้นนอกจากขนาดของคอร์เนลกับจำนวนก้าวแล้ว ขนาดของการเสริมเต็มเองก็มีผลเช่นกันและการทำงานของ การเสริมเต็มเกิดขึ้นกับผังนำออก (รูปที่ 2.52ค) เหมือนกับจำนวนก้าวโดยลบขอบของผังนำออกออก ตามขนาดการเสริมเต็ม ต่างจากขั้นสังวัตนาการที่กระทำบนผังนำเข้าและเพื่อเพิ่มขนาด

รูปที่ 2.52 แสดงให้เห็นตัวอย่างการดำเนินการของขั้นสังวัตนาการสลับเปลี่ยนภายใต้เงื่อนไข การกำหนดค่าพารามิเตอร์ด้วยค่าแตกต่างกัน




รูปที่ 2.52 ตัวอย่างการดำเนินการของชั้นสังวัตนาการสลับเปลี่ยน (ก) เคอร์เนลขนาด 2x2 จำนวนก้าวเท่ากับ 2 ไม่เสริมเต็ม (ข) เคอร์เนลขนาด 2x2 จำนวนก้าวเท่ากับ 1 ไม่เสริมเต็ม (ค) เคอร์เนลขนาด 2x2 จำนวนก้าวเท่ากับ 2 เสริมเต็มเท่ากับ 1

ขนาดของฟังก์ชันลักษณะนำออกคำนวณได้ด้วยสมการ

$$n_{out} = (n_{in} - 1) \times s - 2p + k \tag{2.78}$$

**เส้นเชื่อมโยงข้าม**

เชื่อมต่อระหว่างชั้นทั้งสองฝั่ง นำฟังก์ชันลักษณะจากฝั่งตัวเข้ารหัสมาต่อ (Concatenation) กับฟังก์ชันลักษณะของฝั่งตัวถอดรหัสที่มีขนาดเท่ากันส่งผลให้ชุดฟังก์ชันลักษณะที่เป็นนำเข้าเข้าชั้นสังวัตนาการมีแกนแนลเพิ่มขึ้นมาเป็นสองเท่าจากเดิม (รูปที่ 2.53)



รูปที่ 2.53 การต่อข้อมูลจากเส้นเชื่อมโยงข้าม

(ที่มา : <https://theaisummer.com/skip-connections/>)

### ชั้นสังวัตนาการขนาด 1x1 (1x1 Convolution Layer)

ชั้นสังวัตนาการขั้นสุดท้ายของโครงข่ายประสาทแบบ U-Net จะให้เคอร์เนลขนาด 1x1 เสมอ เพื่อลดจำนวนแชนเนลให้เท่ากับจำนวนของคลาสค่าตอบที่ต้องการจำแนกประเภท แม้ว่าชั้นนี้จะสามารถรวมแชนเนลได้แต่ไม่มีความสามารถที่จะตรวจจับโครงสร้างเชิงพื้นที่ เนื่องจากเป็นการสังวัตนาการแบบพิกเซลต่อพิกเซล ไม่ครอบคลุมพื้นที่เหมือนอย่างตอนใช้เคอร์เนลขนาดใหญ่กว่านี้ อีกอย่างการใช้เคอร์เนลขนาด 1x1 ยังทำให้ได้ค่าที่ไม่ได้รับอิทธิพลจากค่าในพิกเซลข้างเคียง


## 2.5 การสร้างแบบจำลองสามมิติ (3D Model Reconstruction) และวิธีการการประเมินความเหมือน (Similarity Evaluation Metrics)

### 2.5.1 ขั้นตอนวิธีการต่อกันของลูกบาศก์ (Marching Cubes Algorithm)

ขั้นตอนวิธีการต่อกันของลูกบาศก์นั้นจะทำการตรวจสอบแต่ละเซลล์เชิงปริมาตรและสร้างรูปสามเหลี่ยมขึ้นมาในกรณีไอโซเซอร์เฟซ (Isosurface) ตัดกับเซลล์ ดังนั้น จึงแยกกระบวนการสกัดไอโซเซอร์เฟซออกจากปริมาตรออกเป็นส่วน ๆ แล้วพิจารณาในพื้นที่แต่ละส่วนแทน แต่ละเซลล์ที่แยกออกมาประกอบด้วยสี่จุดบนภาพหนึ่งภาพและอีกสี่จุดในภาพที่ลำดับติดกัน ส่วนสำคัญของวิธีการต่อกันของลูกบาศก์ คือ การใช้ตารางค้นหาหรือตารางกรณี (Case Table) สำหรับทุกรูปสามเหลี่ยมที่เป็นไปได้สิ่งนี้ทำให้สามารถกำหนดสามเหลี่ยมของไอโซเซอร์เฟซได้เร็วขึ้นอย่างมาก จากนั้นเชื่อมต่อกัน (Grid) ระหว่างขอบเซลล์พิกเซลหรือว็อกเซลในรูปแบบของ 3 มิติ

ขั้นตอนวิธีการต่อกันของลูกบาศก์ ประกอบด้วย 6 ขั้นตอนสำหรับการดึงเอาพื้นผิววัตถุออกมาจากข้อมูลเชิงปริมาตร ดังนี้

1. สร้างจุดยอดของลูกบาศก์จากจุดภาพ 8 จุดจากแผ่นภาพ 2 ที่อยู่ติดกัน (รูปที่ 2.54)



รูปที่ 2.54 การต่อกันของลูกบาศก์

(ที่มา : Lorensen W. E. and Cline H. E. “Marching cubes : A high resolution 3D surface construction algorithm.”, Seminal graphics : pioneering efforts that shaped the field, 1998. pp. 347-353)

2. แบ่งแยกประเภทของแต่ละจุดยอดด้วยเกณฑ์ค่าไอโซเซอร์เฟซ กำหนดจุดยอดที่อยู่ด้านในและด้านนอกของพื้นผิวโดยหลักการคือ จุดยอดใดมีค่าต่ำกว่าค่าไอโซเซอร์เฟซหมายถึงอยู่ด้านใน และค่าที่สูงกว่าค่าไอโซเซอร์เฟซหมายถึงอยู่ด้านนอก

3. การกำหนดดัชนีเคส (Case Index) ของแต่ละเซลล์และกำหนดเส้นขอบที่ตัดกัน หลังจากที่กำหนดจุดยอดที่เป็นด้านนอกและด้านในได้แล้วให้แทนเป็นค่าไบนารี ค่า 1 หมายถึง ด้านใน และค่า 0 หมายถึง ด้านนอก และประกอบเป็นดัชนีตัวเลขแปดบิต หลังจากกำหนดดัชนีเคสของลูกบาศก์นั้น ๆ แล้วสามารถค้นหาหรือเทียบรูปแบบของเส้นขอบที่ตัดกันโดยไอโซเซอร์เฟซได้ตามตารางเคสรูปที่ 2.55 แสดงรูปแบบของรูปทรงสามเหลี่ยมทั้งหมด 14 รูปแบบ

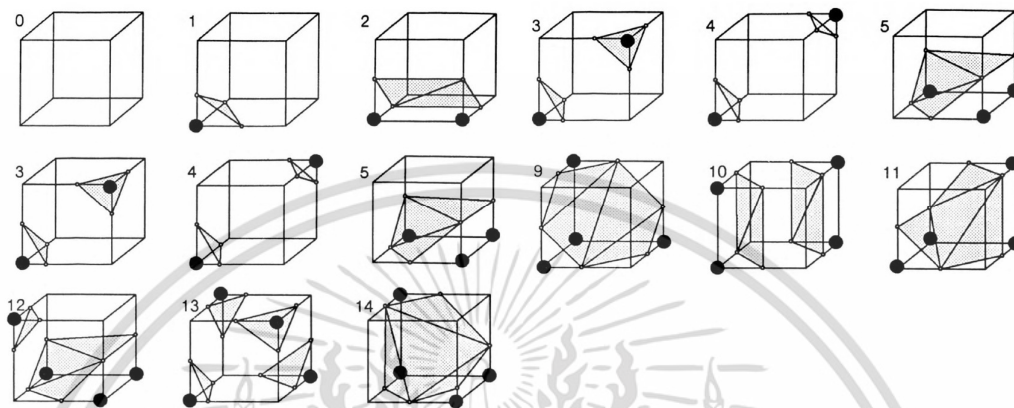
4. การคำนวณตำแหน่งจุดตัดกันบนเส้นขอบด้วยการประมาณค่าเชิงเส้น เมื่อกำหนดเส้นขอบลูกบาศก์ที่ตัดกันแล้ว คำนวณจุดตัดเหล่านั้นด้วยการประมาณค่าเชิงเส้น (สมการ 2.79 และสมการ 2.80)

$$t = \frac{\tau - V_j}{V_{j+1} - V_j} \quad (2.79)$$

$$X_e = X_j + t \cdot (X_{j+1} - X_j) \quad (2.80)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อ  $\tau$  คือ ค่าไอโซเซอร์เฟซ ค่า  $V_j$  และ  $V_{j+1}$  คือ ค่าบนจุดยอดลูกบาศก์สองจุดที่อยู่ติดกัน  $X_{j+1}$  กับ  $X_j$  แทนด้วยพิกัดของว็อกเซลตามลำดับ และ  $X_e$  คือ ตำแหน่งจุดตัดที่คำนวณด้วยการประมาณค่าเชิงเส้น



รูปที่ 2.55 รูปทรงสามเหลี่ยม 14 รูปแบบ

(ที่มา : Lorensen W. E. and Cline H. E. "Marching Cubes : A high resolution 3D surface construction algorithm.", In Seminal graphics : pioneering efforts that shaped the field, 1998. pp. 347-353)

5. สร้างเมชสามเหลี่ยมของจุดตัด นำค่าตำแหน่งจุดตัดที่ประมาณค่าได้มารวมกับแบบรูปสามเหลี่ยมที่เทียบได้จากในตารางเคส

6. คำนวณค่าเวกเตอร์แนวฉาก (Normal Vector) ของพื้นผิวที่ชี้ออกไปด้านนอก สุดท้ายต้องคำนวณค่าเวกเตอร์แนวฉากของพื้นผิวเพื่อให้สามารถแสดงภาพแบบแรเงาซึ่งแสดงรูปร่างที่สอดคล้องกันได้อย่างชัดเจน โดยปกติแล้วเวกเตอร์แนวฉากของพื้นผิวพิจารณาจากการวางแนวของรูปสามเหลี่ยม อย่างไรก็ตาม ในบริบทของการสกัดพื้นผิวอาจประมาณการไล่ระดับสีของพื้นที่สเกลาร์โดยการคำนวณความแตกต่างของความเข้ม การใช้ข้อมูลดั้งเดิมของพื้นที่สเกลาร์ทำให้ได้ค่าจำกัดความของเวกเตอร์แนวฉากของพื้นผิวที่แม่นยำมากขึ้น การคำนวณนี้ดำเนินการสำหรับจุดยอดทั้งสามของรูปสามเหลี่ยมและเป็นวิธีแก้ปัญหาง่าย ๆ ที่ใช้หาค่าเฉลี่ย [52]

นอกจากนี้ยังต้องคำนวณเวกเตอร์แนวฉากที่จุดยอดลูกบาศก์แต่ละจุดซึ่งเป็นความแตกต่างจุดกึ่งกลางด้วยเพื่อเพิ่มคุณภาพของภาพและความสมจริงของเมชผลลัพธ์ และให้ข้อมูลที่มีคุณค่าสำหรับงานแผนผังจำลอง รวมทั้งช่วยตรวจสอบการวางแนวของพื้นผิว ซึ่งเป็นสิ่งสำคัญสำหรับการโต้ตอบกับแสงและการรับรู้ในฉาก 3 มิติ โดยใช้การประมาณค่าเชิงเส้น ดังสมการ

$$G_x(i, j, k) = \frac{D(i+1, j, k) - D(i-1, j, k)}{\Delta x} \quad (2.81)$$

$$G_y(i, j, k) = \frac{D(i, j+1, k) - D(i, j-1, k)}{\Delta y} \quad (2.82)$$

$$G_k(i, j, k) = \frac{D(i, j, k+1) - D(i, j, k-1)}{\Delta z} \quad (2.83)$$

เมื่อ  $D(i + 1, j, k)$  คือความหนาแน่นที่พิกเซล  $(i, j)$  ในสไลด์  $k$  และ  $\Delta x, \Delta y, \Delta z$  คือความยาวของขอบลูกบาศก์ [53]

## 2.5.2 เทคนิคทำให้เมชเรียบด้วยลาปลาเซียน (Mesh Smoothing Technique : Laplacian Smoothing)


การทำให้เมชเรียบดำเนินการเพื่อปรับปรุงคุณภาพของแบบจำลองโครงสร้างสามมิติเพื่อให้ได้คำตอบของสมการเชิงอนุพันธ์ย่อยเฉพาะที่แม่นยำ ในขั้นตอนการปรับให้เรียบ ขั้นตอนวิธีคำนวณคุณภาพของเมชเริ่มต้นเกินจะปรับให้เรียบ ภายหลังจากปรับแล้วคำนวณคุณภาพเมชอีกครั้งจนกว่าจะได้คุณภาพที่ต้องการ

ขั้นตอนวิธีทำให้เมชเรียบด้วยลาปลาเซียนเป็นเทคนิคเฉพาะอย่างหนึ่ง มีหลักการทำงานด้วยขั้นตอนวิธีคำนวณเพื่อปรับเปลี่ยนตำแหน่งของจุดยอดภายในเมช โดยตำแหน่งใหม่ ( $p_i$ ) ของจุดยอด ( $i$ ) ถูกกำหนดด้วยค่าเฉลี่ยของตำแหน่งจุดยอดที่อยู่ติดกัน (รูปที่ 2.56)

$$p_i = \begin{cases} \frac{1}{|Adj(i)|} \sum_{j \in Adj(i)} q_j, & i \in V_{var} \\ q_i, & i \in V_{fix} \end{cases} \quad (2.84)$$


เมื่อ  $q_i$  คือ ตำแหน่งจุดปัจจุบันก่อนใช้ขั้นตอนวิธี  $q_j$  คือ ตำแหน่งจุดปัจจุบันที่อยู่ติดกัน  $Adj(i)$  คือ จุดยอดที่อยู่ติดกับจุดยอด  $i$  ส่วน  $V_{var}$  คือ จุดยอดที่สามารถย้ายได้ และ  $V_{fix}$  คือ จุดยอดที่อยู่กับที่

มีสองเทคนิคสำหรับการคำนวณตำแหน่งใหม่ ( $p_i$ ) วิธีแรกคือการปรับแต่งตำแหน่งเดิม ( $q$ ) ทั้งหมดในขั้นตอนเดียว ซึ่งทุกตำแหน่งใหม่ทุกตำแหน่งขึ้นอยู่กับชุดตำแหน่งเดิมทั้งหมด เรียกวิธีนี้ว่า รุ่นทำงานพร้อมกัน (Simultaneous version) ส่วนวิธีที่สองคือการปรับปรุงตำแหน่งใหม่ทันที วิธีนี้เรียกว่ารุ่นต่อเนื่อง (sequential version) ในกรณีนี้ ตำแหน่งอาจไม่ได้ขึ้นอยู่กับ "ชุด" ของตำแหน่งเก่าเพียงอย่างเดียว แต่อาจขึ้นอยู่กับตำแหน่งใหม่ที่คำนวณไว้ก่อนหน้านี้ด้วย ดังนั้น ผลลัพธ์ของการปรับให้เรียบหนึ่งครั้งผ่านจุดยอดทั้งหมด  $i \in V_{var}$  จะขึ้นอยู่กับลำดับการพิจารณาจุดยอด



**รูปที่ 2.56** การทำให้เมชเรียบด้วยลาปลาเซียน ตำแหน่งของจุดยอดภายในเมชถูกเปลี่ยน (ก) เมชเริ่มต้น (ข) หลังทำให้เรียบด้วยลาปลาเซียน  
(ที่มา : Aupy G., Park J. and Raghavan, “Locality-aware Laplacian mesh smoothing.”, In 2016 45th International Conference on Parallel Processing (ICPP), 2016. pp. 588-597)

รุ่นทำงานพร้อมกันจำเป็นต้องมีที่เก็บสำหรับตำแหน่งเก่า ( $q$ ) ทั้งหมดจนกว่าตำแหน่งใหม่จะถูกคำนวณออกมาเรียบร้อยแล้ว ในรูปที่ 2.57 แสดงเมชด้วย  $V_{fix} = \emptyset$  หลังจากการปรับวนซ้ำรอบที่ 1-2 และ 3 ที่ทำให้ราบด้วยขั้นตอนวิธีลาปลาเซียนเห็นได้ว่าการหดตัวอย่างรวดเร็ว ถ้าเพิ่มรอบวนซ้ำ เมชจะหดตัวเข้าหาจุดหนึ่ง ๆ [54]



**รูปที่ 2.57** ขั้นตอนวิธีลาปลาเซียนที่ช่วยให้ทอรัสที่มีสัญญาณรบกวน  
(ที่มา : Vollmer J., Mencl R. and Mueller H., “Improved laplacian smoothing of noisy surface meshes.”, In Computer graphics forum, vol. 18 no. 3, 1999. pp. 131-138)

## 2.6 วิธีประเมิน (Evaluation Metrics)

### 2.6.1 คะแนน F1 (F1 Score)

ตัววัดความถูกต้องแม่นยำของแบบจำลองการเรียนรู้เชิงลึกในการเรียนรู้ของเครื่องมีด้วยกันหลายตัว ตัววัดคะแนน F1 เป็นค่าเฉลี่ยแบบฮาร์โมนิกของความเที่ยง (Precision) และค่าการเรียก

คืน (Recall) ซึ่งถือเป็นหนึ่งในตัววัดพื้นฐานที่ถูกใช้ในหลากหลายงานวิจัย เช่น ใช้เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองเรียนรู้เชิงลึกสำหรับหลายคลาสหรือใช้เพื่อพิจารณาประสิทธิภาพของแบบจำลองสองตัว

#### 2.6.1.1 ค่าความเที่ยง (Precision)

ค่าความเที่ยงพิจารณาจากผลทำนายเชิงบวก (Positive Prediction) คิดเป็นสัดส่วนว่า บวกจริงกี่เปอร์เซ็นต์เทียบกับผลเชิงบวกทั้งหมด

$$Precision = \frac{Ture\ Positives}{Ture\ Positives+False\ Positives} \quad (2.85)$$

เมื่อ True Positive (TP) คือ จำนวนคำทำนายบวกจริง เช่น ทำนายว่า ไข้ ซึ่งในความเป็นจริงคือ ไข้ และ False Positive (FP) คือ จำนวนคำทำนายบวกเท็จ เช่น ทำนายว่า ไข้ แต่ในความเป็นจริงแล้ว ไม่ใช่

#### 2.6.1.2 ค่าการเรียกคืน (Recall)

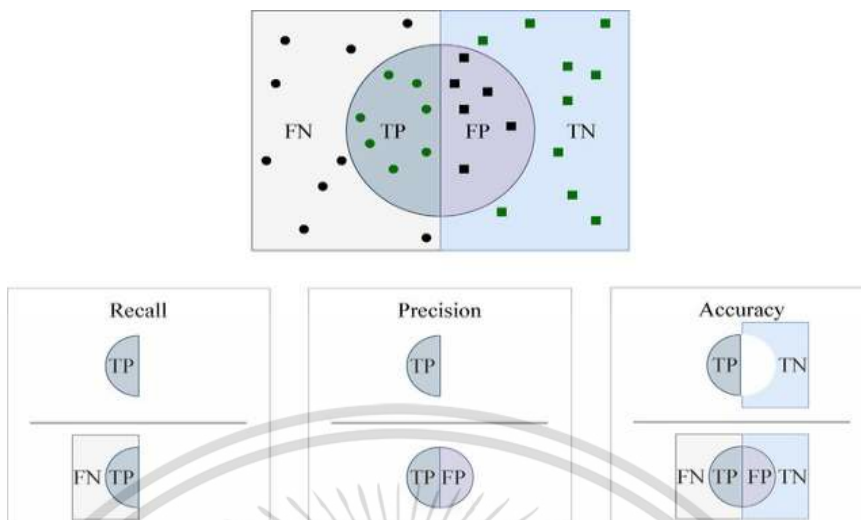
คือ การวัดค่าความแม่นยำในอีกมิติหนึ่ง ไม่ได้สนใจแค่ผลลัพธ์เชิงบวกอย่างเดียวแบบค่าความเที่ยงแต่สนใจผลลัพธ์ที่เป็นผลลบเท็จ (False Negative) ด้วย

$$Recall = \frac{Ture\ Positives}{Ture\ Positives+False\ Nagatives} \quad (2.86)$$

เมื่อ False Negative (FN) คือ จำนวนคำทำนายลบเท็จ เช่น ทำนายว่า ไม่ใช่ แต่จริง ๆ แล้วมันเป็นคำตอบที่ ไข้ [55-56]

สมการคะแนน F1 คำนวณค่าเฉลี่ยของค่าเที่ยงกับค่าเรียกคืน สามารถเขียนสมการได้ว่า

$$F1\ score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (2.87)$$



รูปที่ 2.58 ความเที่ยง (Precision) และการเรียกคืน (Recall)

(ที่มา : Maleki F., Ovens K., Najafian K., Forghani B., Reinhold C. and Forghani R., “Overview of machine learning part 1 : fundamentals and classic approaches.”, Neuroimaging Clinics, vol. 30 no.4, 2020. pp.e17-e32.)

### 2.6.2 ค่าสัมประสิทธิ์ความคล้ายคลึงไดซ์ (Dice Similarity Coefficient : DSC) และ จุดตัดเหนือยูเนียน (Intersection over Union : IoU)

การประเมินประสิทธิภาพการทำงานของการทำงานของระบบอัตโนมัติของแบบจำลองการเรียนรู้เชิงลึก มักใช้ตัววัดสองชนิด คือ ค่าสัมประสิทธิ์ความคล้ายคลึงไดซ์ (DSC) และจุดตัดเหนือยูเนียน (IoU) ซึ่งวัดความเหมือนของข้อมูลสองชุดซึ่งปกติจะใช้กับชุดข้อมูลอาร์เรย์ไบนารี

ค่าสัมประสิทธิ์ความคล้ายคลึงไดซ์ วัดระดับการทับซ้อนกันระหว่างผลลัพธ์การแบ่งส่วนที่ทำนาย (Predicted Segmentation) กับผลลัพธ์การแบ่งส่วนอ้างอิง (Ground Truth Segmentation) โดยเน้นความคล้ายคลึงกันระหว่างทั้งสองส่วนว่าตำแหน่งพิกเซลตรงกันมากน้อยเพียงใด คำนวณด้วยสองเท่าของจำนวนพิกเซลที่ซ้อนทับกันหารด้วยผลรวมจำนวนพิกเซลของผลลัพธ์การแบ่งส่วนที่ทำนายกับผลลัพธ์การแบ่งส่วนอ้างอิง (สมการ 2.88)

ส่วนจุดตัดเหนือยูเนียน วัดสัดส่วนของการซ้อนทับกันระหว่างผลลัพธ์การแบ่งส่วนที่ทำนายกับผลลัพธ์การแบ่งส่วนอ้างอิงเทียบกับขนาดหรือพื้นที่โดยรวมของพื้นที่ทั้งสองว่าสัมพันธ์กันแค่ไหน คำนวณด้วยจำนวนพิกเซลในส่วนซ้อนทับหารกับจำนวนพิกเซลรวมของทั้งสองชุดข้อมูลที่ลบจำนวนพิกเซลที่ซ้อนทับกันออกแล้ว (สมการ 2.89) [57]

ทั้งสองตัววัดสนใจการซ้อนทับในแง่พื้นที่แตกต่างกันเล็กน้อยระหว่างผลลัพธ์การแบ่งส่วนที่ทำนายได้ด้วยแบบจำลองการเรียนรู้เชิงลึกกับผลลัพธ์อ้างอิง ถ้าวัดได้ค่า 0 หมายถึง ไม่มีส่วนซ้อนทับกัน จนถึงค่า 1 หมายถึง ซ้อนทับกันได้สนิท

สามารถเขียนสมการของทั้งสองตัววัดได้ดังนี้

$$DSC(A, B) = \frac{2|A \cap B|}{|A| + |B|} \quad (2.88)$$

$$IoU(A, B) = \frac{|A \cap B|}{|A \cup B|} = \frac{|A \cap B|}{|A| + |B| - |A \cap B|} \quad (2.89)$$

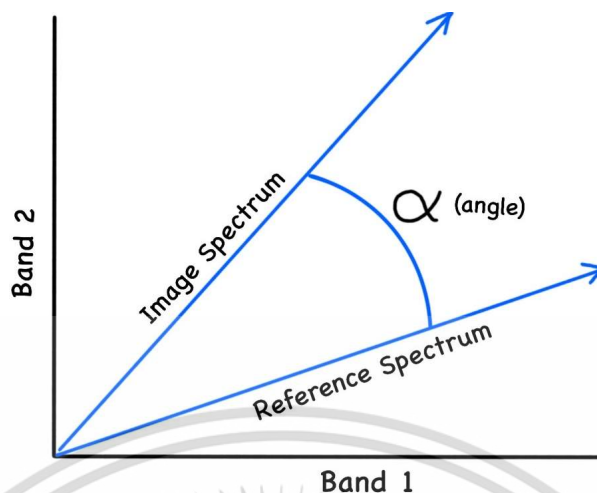
เมื่อ  $A$  คือ พื้นที่อ้างอิงบนภาพเอกซเรย์คอมพิวเตอร์ และ  $B$  คือพื้นที่ส่วนที่ทำนายออกมาได้

### 2.6.3 สเปกตรัม แองเกอร์ แมปเปอร์ (Spectral Angle Mapper : SAM)

สเปกตรัม แองเกอร์ แมปเปอร์เป็นหนึ่งในวิธีการวัดความเหมือนของภาพที่วัดจากความเหมือนของสเปกตรัมระหว่างสเปกตรัมของภาพทำนายหรือภาพที่ต้องการวัดความเหมือนกับสเปกตรัมอ้างอิง ข้อมูลอ้างอิงสามารถเป็นได้ทั้งข้อมูลจากแลปหรือจากการออกเก็บข้อมูลภาคสนามหรือสกัดมาจากรูปภาพโดยตรง ขั้นตอนวิธีวัดความเหมือนของสเปกตรัมด้วยการคำนวณค่ามุมระหว่าง 2 สเปกตรัม ที่ได้มาจากภาพทำนายและภาพอ้างอิงซึ่งสเปกตรัมเหล่านั้นถือเป็นค่าเวกเตอร์ในพื้นที่ที่มีขนาดมิติเทียบเท่ากับจำนวนแถบ (Band : nb) ระดับความเหมือนสรุปได้จากการพิจารณาขนาดมุม เพราะค่ามุมระหว่างเวกเตอร์ที่ทำการเปรียบเทียบนั้นมีความหมายเชื่อมโยงถึงความแปรปรวนของสเปกตรัมระหว่างสเปกตรัมที่ต่างกัน พูดอีกนัย คือ ความแปรปรวนระหว่างสเปกตรัมที่ต่างกันส่งผลต่อขนาดมุมระหว่างเวกเตอร์ ดังนั้น ยังมีมุมระหว่างสเปกตรัมน้อยเท่าไรความเหมือนของทั้งสองภาพก็ยิ่งมีมาก การคำนวณประกอบด้วยการใช้ค่าโคไซน์ (Cosine) ของผลคูณเชิงสเกลาร์ (Dot Product) ของสเปกตรัม [58]

$$SAM(\alpha) = \cos^{-1} \frac{\sum_{i=1}^{nb} t_i r_i}{\sqrt{\sum_{i=1}^{nb} t_i^2} \sqrt{\sum_{i=1}^{nb} r_i^2}} \quad (2.90)$$

เมื่อ  $t$  คือ สเปกตรัมพิกเซลของภาพแบบจำลองสามมิติที่สร้างขึ้นใหม่จากผลการทำนาย ค่า  $r$  คือ สเปกตรัมพิกเซลของภาพแบบจำลองสามมิติที่สร้างขึ้นใหม่จากผลลัพธ์อ้างอิงในพื้นที่คุณลักษณะ  $n$  มิติ ค่า  $nb$  คือ จำนวนแถบในภาพแบบจำลองสามมิติ และ  $\alpha$  คือ มุมระหว่างสองสเปกตรัมจากภาพแบบจำลองสามมิติจากผลการทำนายและภาพแบบจำลองสามมิติจากผลลัพธ์อ้างอิง



รูปที่ 2.59 ตัวอย่างการพล็อตสองมิติของสเปกตรัมรูปภาพทำนายกับรูปภาพอ้างอิงจากข้อมูลสองแถบ

(ที่มา : Hamza M., Thubaiti A., Dhieb M., Ali A., Garbouj M. and Ajmi M., “Dasymmetric Mapping as a Tool to Assess the Spatial Distribution of Population in Jeddah City (Kingdom of Saudi Arabia).”, Current Urban Studies, vol.4, 2016. pp. 329-342.)

#### 2.6.4 หน่วยวัดดัชนีความคล้ายคลึงกันของโครงสร้าง (Structural Similarity Index Measure : SSIM)

หน่วยวัดดัชนีความคล้ายคลึงกันของโครงสร้างเป็นอีกหนึ่งตัววัดที่เป็นที่รู้จักกันดีในงานด้านการประเมินคุณภาพของภาพ ตามทฤษฎีที่ว่า การวัดการเปลี่ยนแปลงข้อมูลโครงสร้างสามารถประมาณค่าการบิดเบือนของภาพได้ดีซึ่งวิธีนี้เป็นตัววัดแบบอ้างอิงสมบูรณ์ (Full-Reference) ที่ใช้การเลื่อนหน้าต่างสองบาน กำหนดเป็นหน้าต่าง  $X$  และ  $Y$  ที่มีขนาดและรูปร่างที่กำหนดขึ้นเองเพื่อวัดคุณภาพเฉพาะพื้นที่หรือการวัดความผิดเพี้ยนระหว่างภาพสองภาพในพื้นที่จำกัด

ขั้นตอนวิธีนี้แยกงานการวัดความคล้ายคลึงออกเป็นสามการเปรียบเทียบ คือ ความส่องสว่าง (Luminance :  $\mu$ ) ความเปรียบเทียบ (Contrast :  $\sigma$ ) และโครงสร้าง (Structure) (รูปที่ 2.60)

การเปรียบเทียบแรก คือ เปรียบเทียบความส่องสว่างด้วยการประมาณค่าเป็นค่าความเข้มเฉลี่ย การเปรียบเทียบที่สอง คือ เปรียบเทียบค่าความเปรียบเทียบ ประมาณค่าด้วยการคำนวณค่าเบี่ยงเบนมาตรฐานหรือรากที่สองของความแปรปรวนของพิกเซลทุกตัวโดยปราศจากการเอนเอียง (Unbiased) และการเปรียบเทียบตัวสุดท้าย คือ เปรียบเทียบข้อมูลโครงสร้าง โครงสร้างของวัตถุภายในภาพไม่เกี่ยวข้องกับแสง ดังนั้น จึงแยกอิทธิพลของแสงสว่างออกไปด้วยการลบความเข้มเฉลี่ยออกและทำให้สัญญาณภาพเป็นปรกติโดยค่าเบี่ยงเบนมาตรฐานของสัญญาณภาพ

เมื่อได้ฟังก์ชันเปรียบเทียบที่สามารถเปรียบเทียบภาพสองภาพด้วยพารามิเตอร์เหล่านี้ทั้งสามคุณลักษณะแล้วนำมารวมกัน จนในที่สุดก็จะได้เป็นฟังก์ชันรวม (Combination Function) ที่เรียกว่า

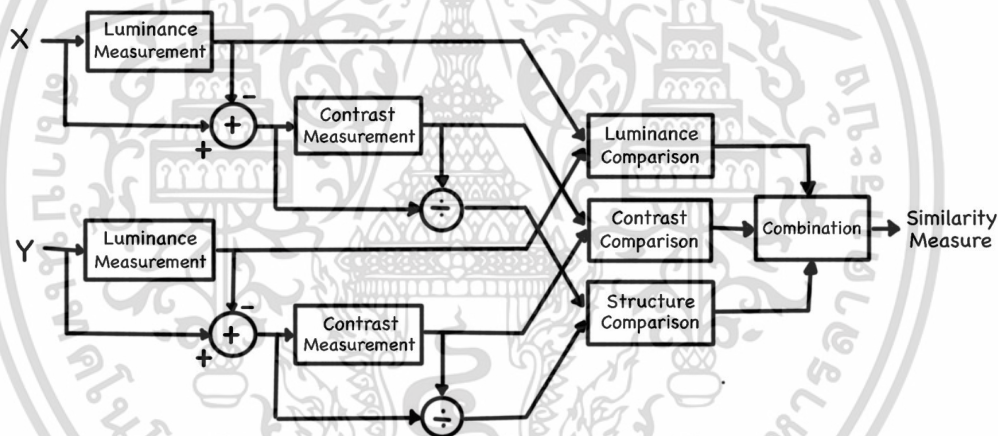
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หน่วยวัดดัชนีความคล้ายคลึงกันของโครงสร้างเพื่อให้ได้ค่าเพียงค่าเดียวที่บ่งชี้ถึงคุณภาพของภาพที่ถูกบิดเบือนหรือตัดแปลงหรือได้มาด้วยวิธีใด ๆ เทียบกับภาพอ้างอิง [59-60].

$$SSIM(x, y) = \frac{(2\mu_x\mu_y+c_1)(2\sigma_{xy}+c_2)}{(\mu_x^2+\mu_y^2+c_1)(\sigma_x^2+\sigma_y^2+c_2)} \quad (2.91)$$

เมื่อ  $\mu_x$  และ  $\mu_y$  คือ ค่าความส่องสว่างของภาพที่ต้องการเปรียบเทียบ ( $X$ ) และภาพอ้างอิง ( $Y$ )  $\sigma_{xy}$  คือ สัมประสิทธิ์สหสัมพันธ์ระหว่างสองภาพ ค่า  $\sigma_x$  และ  $\sigma_y$  คือ ค่าความแปรปรวนของภาพที่ต้องการเปรียบเทียบ ( $X$ ) และภาพอ้างอิง ( $Y$ ) และ  $c_1$  กับ  $c_2$  คือ ค่าคงที่เพื่อหลีกเลี่ยงค่านิยามเมื่อ  $\mu_x^2 + \mu_y^2$  หรือ  $\sigma_x^2 + \sigma_y^2$  เข้าใกล้ศูนย์

ค่าผลลัพธ์การประเมินของตัววัดนี้มีช่วงตั้งแต่ -1 ถึง 1 โดยที่ -1 หมายถึง ภาพทั้งสองไม่มีความเหมือนกันและ 1 หมายถึง ภาพทั้งสองเป็นภาพเดียวกัน



รูปที่ 2.60 แผนผังของระบบการวัดดัชนีความคล้ายคลึงกันของโครงสร้าง

(ที่มา : Wang Z., Bovik A. C., Sheikh H. R. and Simoncelli E. P., "Image quality assessment : from error visibility to structural similarity.", IEEE transactions on image processing, vol.13 no.4, 2004. pp. 600-612.)

### 2.6.5 ระยะพื้นผิว (Surface Distance)

ฟังก์ชันระยะพื้นผิว วัดระยะห่างระหว่างสองพื้นผิวซึ่งมักแสดงเป็นแผ่นบัง (Mask) ไบนารีสามมิติหรือพอยต์คลาวด์ (Point Cloud) ในการถ่ายภาพทางการแพทย์ พื้นผิวเหล่านี้สามารถแสดงถึงโครงสร้างทางกายวิภาคที่แบ่งส่วนหรือภาพที่ลงทะเบียน

ฟังก์ชันที่สามารถใช้วัดได้มีหลายวิธี เช่น

### 1. ระยะพื้นผิวเฉลี่ย (Mean Surface Distance : MSD)

ใช้การคำนวณระยะห่างเฉลี่ยระหว่างจุดที่สอดคล้องกันบนพื้นผิวที่สร้างจากผลการแบ่งส่วนกับพื้นผิวอ้างอิงในหน่วยมิลลิเมตร สามารถใช้บอกได้ว่าโดยเฉลี่ยแล้วพื้นผิวจะแตกต่างกันมากน้อยเพียงใดระหว่างพื้นผิวทั้งสอง [61] เขียนสมการได้ว่า

$$MSD = \frac{1}{n_s + n_{s'}} (\sum_{p=1}^{n_s} d(p, S') + \sum_{p'=1}^{n_{s'}} d(p', S)) \quad (2.92)$$

เมื่อ  $n_s$  คือ จำนวนจุดบนพื้นผิวที่สร้างขึ้นจากผลลัพธ์แบ่งส่วน ( $S$ )  $n_{s'}$  คือ จำนวนจุดบนพื้นผิวอ้างอิง ( $S'$ )  $p$  คือ จุดบนพื้นผิวที่สร้างขึ้นจากผลลัพธ์แบ่งส่วนที่กำลังพิจารณาแต่ละจุดบนพื้นผิวในลักษณะวนซ้ำเพื่อคำนวณระยะทาง และ  $p'$  คือ จุดบนพื้นผิวอ้างอิงที่กำลังพิจารณาแต่ละจุดบนพื้นผิวในลักษณะวนซ้ำเพื่อคำนวณระยะทาง  $d(p, S')$  คือ ระยะระหว่างจุด  $p$  บนพื้นผิวที่สร้างขึ้นจากผลการแบ่งส่วนกับจุดที่อยู่ใกล้ที่สุดบนพื้นผิวอ้างอิง และ  $d(p', S)$  คือ ระยะระหว่างจุด  $p'$  บนพื้นผิวอ้างอิงกับจุดที่อยู่ใกล้ที่สุดบนพื้นผิวที่สร้างขึ้นจากผลการแบ่งส่วน

### 2. ระยะห่างเฮาส์ดอร์ฟ (Hausdorff Distance : HD)

ค่าสูงสุดของเวกเตอร์เป็นความแตกต่างที่มากที่สุดระหว่างระยะห่างพื้นผิว วัดในหน่วยมิลลิเมตร สามารถคำนวณระยะห่างเฮาส์ดอร์ฟแบบสมมาตรได้ดังนี้

$$HD = \max [d(S, S'), d(S', S)] \quad (2.93)$$

เมื่อ  $d(S, S')$  เป็นค่าวัดระยะทางสูงสุดของจุดบนพื้นผิวที่สร้างขึ้นใหม่ ( $S$ ) ไปยังจุดที่ใกล้ที่สุดบนพื้นผิวอ้างอิง ( $S'$ ) และ  $d(S', S)$  เป็นวัดระยะทางสูงสุดของจุดบนพื้นผิวอ้างอิง ( $S'$ ) ไปยังจุดที่ใกล้ที่สุดบนพื้นผิวสร้างขึ้นใหม่ ( $S$ ) [61]

## 2.7 ทบทวนวรรณกรรม

สำหรับงานแบ่งส่วนทางการแพทย์ วิธีการแบบแมนวอลจะมีความน่าเชื่อถือสูงแต่ประสิทธิภาพของวิธีการนี้ก็ขึ้นอยู่กับความแปรปรวนระหว่างผู้ดำเนินการคนเดียวกับผู้ดำเนินการหลายคน ดังนั้นเพื่อรับมือกับปัญหานี้จึงมีการพัฒนาเทคนิคการแบ่งส่วนแบบกึ่งอัตโนมัติที่ประยุกต์ใช้ขั้นตอนวิธีทางคณิตศาสตร์แบบต่าง ๆ ขึ้นมา เช่น การตั้งระดับเกณฑ์ (Thresholding) เลเวลเซต (Level Set) [62] การเติบโตของพื้นที่โดยการวางเมล็ด (Seeded Region Growing) แบบจำลองคอนทัวร์แบบแอคทีฟโดยอิงพื้นที่เฉพาะส่วน (Localized Region-based Active Contour Model) วิธีการอิงการจัดกลุ่ม (Clustering-based Methods) เฉลี่ย-K [63] แต่ทั้งนี้ แม้ว่าเทคนิคเหล่านี้จะช่วยเพิ่มประสิทธิภาพการแบ่งส่วนและความน่าเชื่อถือ [62-65] แต่ความแปรปรวนก็ยังคงมีอยู่ อีกทั้งในบางกรณีก็ไม่เหมาะสม

หรือไม่มีประสิทธิภาพเพียงพอที่จะนำมาใช้กับภาพถ่ายทางการแพทย์

เพื่อจัดการกับข้อจำกัดเหล่านี้ แบบจำลองการเรียนรู้เชิงลึกจึงถูกนำมาเป็นรากฐานพัฒนาเทคโนโลยีการแบ่งส่วนภาพถ่ายทางการแพทย์อัตโนมัติด้วยโครงข่ายประสาทเทียมมีความสามารถเรียนรู้ได้ด้วยตัวเองจากชุดข้อมูลจำนวนมากและการคำนวณที่ซับซ้อนตอบสนองต่อความต้องการที่เฉพาะเจาะจงและซับซ้อนตามโลกความจริงได้ ส่งผลให้งานวิจัยเกี่ยวกับการแบ่งส่วนภาพถ่ายทางการแพทย์อัตโนมัติมีการพัฒนาอย่างต่อเนื่องและความก้าวหน้าอย่างมาก [3-5] ซึ่งนอกจากการประยุกต์ใช้โครงข่ายประสาทเทียมและการออกแบบสถาปัตยกรรมโครงข่ายแล้ว [65-78] ขั้นตอนการประมวลผลล่วงหน้าเองก็ถือว่ามีความสำคัญในการเพิ่มประสิทธิภาพการแบ่งส่วนอัตโนมัติตามการเรียนรู้เชิงลึก เป็นการแปลงข้อมูลให้อยู่ในรูปแบบที่พร้อมนำไปประมวลผลในขั้นตอนต่อไป [79]

วิธีการประมวลผลล่วงหน้าที่เคยได้รับการเสนอเพื่อปรับปรุงประสิทธิภาพของการแบ่งส่วนอัตโนมัติตามการเรียนรู้เชิงลึก ได้แก่ การปรับระดับหน้าต่าง (Window Leveling) การกรอง การจับคู่ เทคนิคฮิสโทแกรม [66] FLAIR (การลอกกะโหลก) T1 [67] การสลายตัวของเวฟเล็ต (Wavelet Decomposition) การปรับค่าความเปรียบต่าง รูปแบบไบนารีเฉพาะจุด [68] การเลือกภูมิภาคที่น่าสนใจ (ROI) การแก้ไขฟิลด์ไบแอส (Bias Field Correction) วิธีการสุ่มตัวอย่างใหม่ [69] การทำให้เป็นมาตรฐาน [66-69] และการตัดส่วนภาพบริเวณที่สนใจ (crop ROI) [70-71]

ซึ่งหลักฐานแสดงให้เห็นว่าความแม่นยำในการแบ่งส่วนเพิ่มขึ้นอย่างมีนัยสำคัญผ่านการผสมผสานของเทคนิคการประมวลผลล่วงหน้า [66-72] ดังนั้น การศึกษานี้จึงใช้ทั้งเทคนิคการประมวลผลล่วงหน้าแบบดั้งเดิมและแบบใหม่เพื่อเพิ่มความเปรียบต่างของภาพและตรวจจับอวัยวะเป้าหมาย โดยรวมจะเกี่ยวข้องกับการปรับระดับหน้าต่าง การฉายฮิสโทแกรม การตัดส่วนภาพ และการเพิ่มคุณลักษณะ

อย่างไรก็ตาม เทคนิคการประมวลผลล่วงหน้าแบบดั้งเดิมมีประโยชน์น้อยกว่าในบางกรณี เช่น การตรวจจับหรือระบุตำแหน่งอวัยวะเป้าหมายเมื่อหน่วยเฮาส์ฟิลด์ (HU) ของอวัยวะที่สนใจนั้นคล้ายหรือเหมือนกันกับอวัยวะใกล้เคียงหรือเมื่ออวัยวะเป้าหมายเป็นอวัยวะที่อยู่คู่กัน เช่น กระดูกต้นขา ไต ปอด เป็นต้น ด้วยเหตุนี้ การเสริมคุณลักษณะจึงมีความเป็นไปได้ที่จะช่วยปรับปรุงประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึกเพื่อการแบ่งส่วนภาพทางการแพทย์อัตโนมัติ ซึ่งมีงานก่อนหน้านี้นี้จำนวนมากที่ใช้เทคนิคการเสริมข้อมูลและวิธีการระบุคุณลักษณะเพื่อปรับปรุงประสิทธิภาพการจดจำวัตถุและการแบ่งส่วนในโดเมนต่าง ๆ [80-85]

ในบทความวิจัยของหยาง ชู (Yang Shu) และทีมงาน [80] แนะนำมอดูลการเข้ารหัสคุณลักษณะการรับรู้คุณลักษณะใหม่ (Attribute-aware Feature Encoding : AFE) ภายในโครงข่ายแบบมัลติทาสก์ (Multi-task Network) ในขณะที่ปรับปรุงคุณลักษณะเชิงความหมายผ่านแนวคิดเชิงบูรณาการ (Integrated Approach) ของการเข้ารหัสคุณลักษณะตระหนักรู้คุณสมบัติและวิธีเรกูลาร์ไรเซชัน (Regularization) ของการเข้ารหัสคุณลักษณะผ่านการเรียนรู้คุณลักษณะเสริมโดยมี

เป้าหมายเพื่อปรับปรุงประสิทธิภาพของงานจดจำวัตถุและการแบ่งส่วน

บทความวิจัยอ้างอิงของ Dr. Mahmud Dwi Sulistiyo และทีมงาน [81] เสนอวิธีการที่ผสมผสานเทคนิคการรับรู้คุณลักษณะและการเพิ่มข้อมูลเพื่อเพิ่มประสิทธิภาพการทำงานของวิธีการแบ่งส่วนเชิงความหมายเพื่อเอาชนะข้อจำกัดที่เกิดจากสิ่งกีดขวาง สภาพแสงที่แตกต่างกัน และวัตถุที่มีลักษณะการมองเห็นที่คล้ายคลึงกัน

ในบทความวิจัยของคุณหวัง รุ่่นเจ้อและทีมงาน [82] ได้แนะนำวิธีการแบ่งส่วนภาพทางการแพทย์ข้ามโดเมน (Cycle-consistent Cross-domain Medical Image Segmentation : CyCMIS) ที่สอดคล้องกับวัฏจักร ซึ่งใช้ประโยชน์จากวงจรเทคนิคที่สอดคล้องกันและการเสริมภาพที่หลากหลายเพื่อเพิ่มความสามารถในการถ่ายโอน ความทนทาน และการวางนัยทั่วไปของแบบจำลองแบ่งส่วน ทำให้ได้ผลลัพธ์การแบ่งภาพมีความแม่นยำและเชื่อถือได้มากขึ้น แม้จะมีข้อมูลที่มีป้ายกำกับในโดเมนเป้าหมายจำนวนจำกัดก็ตามเพื่อจัดการกับความขาดแคลนของข้อมูลที่มีคำอธิบายประกอบในโดเมนทางการแพทย์ เอาชนะความท้าทายที่เกี่ยวข้องกับค่าใช้จ่ายสูง และความพยายามในการบรรณนิทัศน์ด้วยตนเอง

อ้างอิงบทความวิจัยของ Mr. Mostafa Jahanifar และทีมงาน [83] แนะนำวิธีการที่รวมโครงข่ายประสาทเทียมแบบสังวัตนาการและการเสริมเฉพาะโดเมน ซึ่งเกี่ยวข้องกับการแปลงและการปรับปรุงเฉพาะที่ใช้กับภาพรอยโรคที่ผิวหนังเพื่อจำลองรูปแบบที่เหมือนจริง โดยมีเป้าหมายเพื่อเพิ่มขีดความสามารถในการแบ่งส่วนของรอยโรคที่ผิวหนังและเพิ่มคุณลักษณะ หวังจัดการกับความท้าทายโดยธรรมชาติของการจับความแตกต่างอย่างมีนัยสำคัญในขนาด รูปร่าง พื้นผิว และสีของรอยโรคที่ผิวหนัง

บทความวิจัยของ DR. Amjad Rehman Khan และทีมงาน [84] ได้พัฒนาแนวทางใหม่ซึ่งผสมผสานการจัดกลุ่มเฉลี่ย K กับเทคนิคการเรียนรู้เชิงลึก และการเพิ่มข้อมูลสังเคราะห์เข้าด้วยกัน วิธีการนี้เกี่ยวข้องกับการสร้างข้อมูลสังเคราะห์เพื่อเพิ่มจำนวนข้อมูลที่มีข้อมูลประกอบที่มีอย่างจำกัด รวมทั้งปรับปรุงประสิทธิภาพการแบ่งส่วนของแบบจำลองการเรียนรู้เชิงลึก โดยมีวัตถุประสงค์เพื่อเพิ่มความสามารถในการวางนัยทั่วไปของแบบจำลองการเรียนรู้เชิงลึก ปรับปรุงประสิทธิภาพการแบ่งส่วนภาพ และจัดการกับความพร้อมใช้งานที่มีจำกัดของข้อมูลฝึกฝนที่มีข้อมูลประกอบ

และบทความวิจัยของ Dr. Noguchi Shunjiro และทีมงาน [85] ได้เสนอวิธีการที่ใช้โครงข่ายแบบสังวัตนาการร่วมกับเทคนิคการเสริมข้อมูลแบบใหม่ ซึ่งรวมถึงวิธีการทั่วไป การผสม (Mixup) และการสุ่มการตัดส่วนภาพและแพตช์รูปภาพ (Random Image Cropping and Patching : RICAP) วิธีการนี้เกี่ยวข้องกับการสร้างข้อมูลสังเคราะห์เพื่อเพิ่มข้อมูลที่มีคำอธิบายประกอบที่มีจำนวนจำกัด และปรับปรุงประสิทธิภาพการแบ่งส่วนของแบบจำลองการเรียนรู้เชิงลึกเพื่อพัฒนาและประเมินขั้นตอนวิธีสำหรับการแบ่งส่วนกระดูกบนภาพถ่ายเอกซเรย์คอมพิวเตอร์ทั่วร่างกายโดยใช้โครงข่ายประสาทแบบสังวัตนาการ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 3

### ระเบียบวิธีวิจัย

#### 3.1 กลุ่มตัวอย่างในการศึกษาวิจัย

ในการศึกษาวิจัยการแบ่งส่วนอวัยวะอัตโนมัติด้วยระบบการเรียนรู้เชิงลึกนี้ ผู้วิจัยใช้ข้อมูลภาพเอกซเรย์คอมพิวเตอร์ของคนไข้เชื้อสายไทยจำนวน 120 คนที่เป็นกลุ่มโรคมะเร็งบริเวณช่วงท้องส่วนล่าง เช่น โรคมะเร็งลำไส้ใหญ่และทวารหนัก (Colorectal Cancer) มะเร็งปากมดลูก (Cervical Cancer) มะเร็งต่อมลูกหมาก (Prostate Cancer) มะเร็งไส้ตรงและไส้คด (Rectosigmoid Cancer) และมะเร็งลำไส้ตรง (Rectal Cancer) เป็นกลุ่มตัวอย่างสำหรับศึกษาวิจัย เนื่องจากอวัยวะเป้าหมายของงานวิจัยคือ กระเพาะปัสสาวะ (Bladder) และกระดูกต้นขาข้างซ้าย (Left Femur) ซึ่งทั้งสองเป็นอวัยวะที่มีความเสี่ยงจะได้รับอันตรายจากรังสีรักษาสำหรับกลุ่มโรคเหล่านี้ โดยได้รับการสนับสนุนจากโรงพยาบาลศิริราชปิยมหาราชการุณย์ในการจัดหาข้อมูลซึ่งเป็นไปตามเอกสารรับรองหมายเลข 315/2021 (Certificate of Approval (COA) no. Si 315/2021) กลุ่มคนไข้มีอายุโดยเฉลี่ย 60 ถึง 80 ปี

ทางโรงพยาบาลดำเนินการฉายรังสี และถ่ายภาพโดยใช้เครื่องเอกซเรย์คอมพิวเตอร์แบบ 4 มิติ รุ่น SOMATOM Confidence 64 Slice ยี่ห้อ SIEMENS ผลิตในประเทศเยอรมัน โดยในตารางที่ 3.1 แสดงค่าพารามิเตอร์ที่กำหนดก่อนเริ่มฉายรังสีเพื่อสร้างชุดข้อมูลภาพ

ตารางที่ 3.1 พารามิเตอร์ที่กำหนดในขั้นตอนการถ่ายภาพเอกซเรย์คอมพิวเตอร์ของคนไข้


| พารามิเตอร์                      | โหมด / ค่า |
|----------------------------------|------------|
| ค่ากระแสไฟฟ้าในหลอดเอกซเรย์ (mA) | 220 - 313  |
| ค่าความต่างศักย์ (KVp)           | 120        |
| ความหนาสไลด์ (mm)                | 3          |
| ค่าปริมาณรังสี (R/hr)            | 250        |
| โหมดกราดภาพ                      | โหมด Helix |

#### 3.2 ระบบซอฟต์แวร์เพื่อเตรียมชุดข้อมูลเอกซเรย์คอมพิวเตอร์


ข้อมูลภาพของคนไข้จากเครื่องเอกซเรย์จะถูกส่งเข้าระบบคอมพิวเตอร์วางแผนการรักษา (Treatment Planning System) (รูปที่ 3.1) เพื่อวางแผนการรักษาต่อไป สำหรับในงานวิจัยนี้จะเกี่ยวข้องกับขั้นตอนคอนทัวอวัยวะที่มีความเสี่ยง ซึ่งแพทย์เฉพาะทางด้านรังสีวิทยาเป็นผู้ดำเนินการด้วยระบบวางแผนการรักษารุ่น Eclipse (Eclipse™ Treatment Planning System) ยี่ห้อ Varian

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รุ่น 16.00.00 ผลิตในประเทศสหรัฐอเมริกา (รูปที่ 3.2) โดยใช้ชุดเครื่องมืออย่างแปรง (Brush) ในการวาดและปรับแต่งได้ออกมาเป็นข้อมูลคอนทัวร์ของแต่ละส่วนที่สนใจ ผู้วิจัยใช้ข้อมูลส่วนนี้เป็นข้อมูลตามความเป็นจริง (Ground Truth) ในระบบการเรียนรู้อัตโนมัติ ดึงข้อมูลจากระบบออกเป็นไฟล์ไดคอม (DICOM) สองไฟล์ต่อคนไข้หนึ่งราย คือ ไฟล์ที่เก็บภาพเอกซเรย์กับไฟล์ที่เก็บข้อมูลคอนทัวร์



รูปที่ 3.1 หน้าโฮมเพจ (Home Page) ของระบบวางแผนการรักษา (ยี่ห้อ Varian)

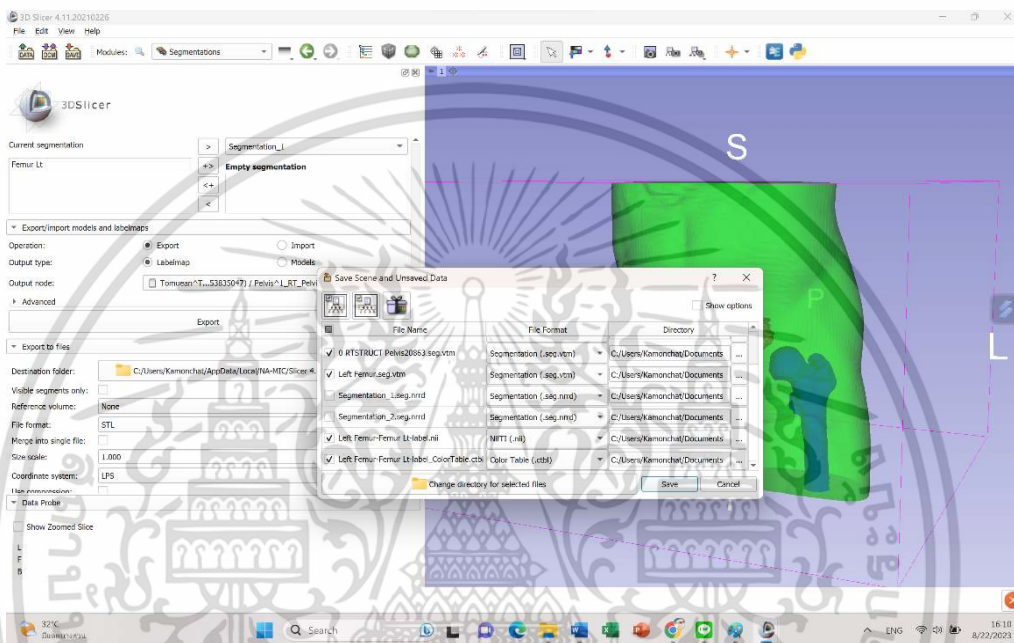


รูปที่ 3.2 หน้าระบบวางแผนการรักษา รุ่น Eclipse สำหรับการคอนทัวร์


หลังจากรวบรวมไฟล์ไดคอมจากระบบของทางโรงพยาบาลแล้ว นำเข้าโปรแกรม 3D Slicer รุ่น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.11.2021226 ผลิตในประเทศสหรัฐอเมริกา เพื่อแปลงไฟล์จากไดคอมเป็นไฟล์นิฟติ (NifTi) (รูปที่ 3.3) เพื่อความสะดวกต่อการเรียกข้อมูลเข้าซอฟต์แวร์ฝึกฝนโครงข่ายประสาทเทียมในขั้นต่อไป ทั้งยังป้องกันการตกหล่นและเรียงลำดับสไลด์ผิดพลาด เช่นเดียวกับไฟล์ไดคอม ไฟล์นิฟติเองก็ประกอบด้วยไฟล์ที่เป็นข้อมูลภาพกับไฟล์ที่เป็นข้อมูลคอนทัวร์ซึ่งในส่วนของข้อมูลคอนทัวร์สามารถแยกได้ตามชนิดอวัยวะ เป็นไปตามผังกระบวนการในรูปที่ 3.4



รูปที่ 3.3 โปรแกรม 3D Slicer



รูปที่ 3.4 ขั้นตอนการเตรียมชุดข้อมูลเอกซเรย์คอมพิวเตอร์

### 3.3 ขั้นตอนการเตรียมชุดข้อมูลล่วงหน้า (Preprocessing) สำหรับการฝึกฝน

#### 3.3.1 ขั้นตอนปรับปรุงคุณภาพของภาพเอกซเรย์คอมพิวเตอร์

ชุดข้อมูลที่ถูกนำไปฝึกฝนในแบบจำลองเรียนรู้เชิงลึกจะอยู่ในรูปแบบของไฟล์สกุล .png ขนาด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

8 บิต ที่มีช่วงค่าเพียง 256 ค่า เท่านั้น แต่ภายในไฟล์นิพติบรรจุภาพสไลด์เอกซเรย์คอมพิวเตอร์ไว้หลายร้อยสไลด์ที่มีขนาดข้อมูลดั้งเดิมใหญ่กว่ามาก ช่วงค่าหน่วยเฮาส์ฟิลด์มีตั้งแต่ -1000 HU ถึง 3000 HU โดยประมาณ เพื่อลดช่วงค่าที่กว้างเกินไป เพิ่มค่าความเปรียบต่าง และเพิ่มความคมชัดในการแสดงโครงสร้างภายในภาพเอกซเรย์จึงป้อนสไลด์เอกซเรย์คอมพิวเตอร์เข้ากระบวนการปรับหน้าต่างแสดงผลผ่านเทคนิควินโดวส์เลเวลลิง (Window Leveling) พร้อมทั้งทำให้ค่าหน่วยเฮาส์ฟิลด์เป็นบรรทัดฐานอยู่ในช่วงของค่า 8 บิต เพื่อป้องกันการบิดเบือนค่าหลังแปลงเป็นรูปภาพขนาด 8 บิต ตามสมการ 3.1 [41]

$$y_i = \left( \frac{(x_i - (WL - .5))}{(WW - 1)} + 0.5 \right) \times (y_{max} - y_{min}) + y_{min} \quad (3.1)$$

เมื่อ  $y_i$  คือ ค่าความเข้มนำออก เช่น ความเข้ม 0 ถึง 255 และ  $x_i$  คือ ความเข้มหรือค่าหน่วยเฮาส์ฟิลด์นำเข้า โดย  $i$  หมายถึงหมายเลขพิกเซล ค่า  $y_{min}$  และ  $y_{max}$  คือ ค่าความเข้มต่ำสุดและค่าความเข้มสูงสุดของช่วงค่าใหม่ทั้งหมด  $WL$  คือ ระดับหน้าต่าง และ  $WW$  คือ ความกว้างหน้าต่างที่ต้องการ ซึ่งในงานวิจัยนี้กำหนดให้  $WL$  เท่ากับ 120 HU และ  $WW$  เท่ากับ 336 HU

หลังจากได้สไลด์ภาพเอกซเรย์คอมพิวเตอร์ที่ปรับค่าภายในใหม่ ขั้นตอนต่อไปจะแบ่งแยกเป็น 2 กรณี ตามอวัยวะเป้าหมาย รายละเอียดมีดังนี้

#### 1. กระเพาะปัสสาวะ

ขั้นตอนการเตรียมชุดข้อมูลล่วงหน้าสำหรับกระเพาะปัสสาวะถัดจากขั้นตอนปรับค่าด้วยวินโดวส์เลเวลลิง คือ เน้นบริเวณโครงสร้างกระเพาะปัสสาวะให้เด่นชัดและแยกออกจากบริเวณโดยรอบ (รูปที่ 3.5) ผ่านกระบวนการประมวลผลภาพด้วยเทคนิคฮิสโทแกรมอีควอไลเซชัน เริ่มด้วยการคำนวณหาฮิสโทแกรมภายในสไลด์ภาพนั้น ๆ ตามสมการ 3.2 [38]


$$cdf(y_i) = \sum_{y_i=0}^{\text{number of bin}} h(y_i) \quad (3.2)$$

เมื่อ  $h(y_i)$  คือ ฮิสโทแกรมของค่าความเข้มที่ผ่านการแปลงด้วยเทคนิควินโดวส์เลเวลลิง จากนั้นคำนวณค่าใหม่สำหรับสร้างฟังก์ชันเชื่อมโยงค่าความเข้ม ( $f(I)$ ) เพื่อเทียบค่ากับค่าเก่าด้วยฟังก์ชันทำให้เป็นบรรทัดฐานแบบค่าต่ำสุดสูงสุด (Min-max Normalization) [86] ตามสมการ 3.3

$$f(I) = \text{round} \left( \frac{(cdf(y_i) - cdf_{min}) * (255)}{cdf_{max} - cdf_{min}} \right) \quad (3.3)$$


เมื่อ **round** คือ ฟังก์ชันการปรับให้ค่าเป็นจำนวนเต็ม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.5 ภาพเอกซเรย์คอมพิวเตอร์ (ก) ภาพต้นฉบับ และ (ข) ภาพหลังดำเนินการเทคนิคฮิสโทแกรมอีควอลไลเซชัน

ตามที่แสดงในรูปที่ 3.5 ภาพใหม่ที่ได้จากเทคนิคฮิสโทแกรมอีควอลไลเซชันมีสัญญาณรบกวนเป็นจำนวนมาก ผู้วิจัยจึงดำเนินการลดสัญญาณเหล่านั้นด้วยการทำให้เรียบด้วยเกาส์เซียน กำหนดขนาดของคอร์เนลเท่ากับ  $5 \times 5$  และค่าซิกม่าเท่ากับ 2 เพื่อลบสัญญาณรบกวนขณะที่ยังรักษารูปแบบของโครงสร้างภายในให้เหมือนเดิมที่สุด ในรูปที่ 3.6 แสดงให้เห็นผลลัพธ์การทำให้เรียบด้วยเกาส์เซียน



รูปที่ 3.6 ภาพเอกซเรย์คอมพิวเตอร์ (ก) ภาพก่อนและ (ข) ภาพหลังดำเนินการทำให้เรียบด้วยเกาส์เซียน

ขั้นตอนต่อมาเป็นการลดขนาดของสไลด์ภาพลงพร้อมกับลบข้อมูลส่วนที่ไม่จำเป็นอย่างค่า 0 ใน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

พื้นหลังสีดำออกเพื่อให้ความละเอียดของภาพยังคงเดิม จึงลดขนาดด้วยการครีอป (Crop) ซึ่งวิธีนี้จำเป็นต้องกำหนดตำแหน่งพิกัดสำหรับกรอบภาพ (Bounding Box) ครอบคลุมบริเวณที่ต้องการเก็บไว้ ผู้วิจัยได้ทำการกำหนดพิกัดสำหรับชุดสไลด์ภาพของคนไข้แต่ละคน ตามขั้นตอนที่แสดงในผังกระบวนการในรูปที่ 3.7 มีรายละเอียดดังต่อไปนี้

**ขั้นที่ 1** ส่งภาพสไลด์ที่ปรับหน้าตาแล้วเข้ากระบวนการตั้งระดับเกณฑ์ (Thresholding) ด้วยการกำหนดค่าขอบบนเท่ากับ 60 HU และค่าขอบล่างเท่ากับ 28 HU ซึ่งค่านอกเหนือจากช่วงที่กำหนดนี้ถูกลบออก

**ขั้นที่ 2** ใช้เคอร์เนลเกาส์เซียนปรับภาพให้เรียบ

**ขั้นที่ 3** ใช้คณิตศาสตร์ฐานวิทยา (Mathematical Morphology) ลบส่วนเกินที่เหลือออกจากสไลด์บนระนาบทั้งสามสำหรับสไลด์ระนาบในแนวตั้งแบ่งซ้ายขวา (Sagittal Plane) กับสไลด์ระนาบแบ่งหน้าหลัง (Coronal Plane) ใช้ตัวดำเนินการกัดเซาะเฉดสีเทา (Grayscale Erosion) ตามด้วยการขยายเฉดสีเทา (Grayscale Dilation) ส่วนสไลด์ระนาบตามแกน (Axial Plane) ดำเนินการด้วยการกัดเซาะเฉดสีเทา การเปิดเฉดสีเทา (Grayscale Opening) และการกัดเซาะเฉดสีเทา

**ขั้นที่ 4** ปรับสไลด์เอกซเรย์ให้เป็นภาพไบนารีและใช้วิธีการฉายฮิสโทแกรม (Histogram Projection) บนภาพสไลด์แต่ละสไลด์ที่ลบส่วนเกินออกไปแล้ว โดยกำหนดระดับเกณฑ์ที่จะเริ่มเก็บพิกัดเป็น 5 HU สำหรับแกน x ซึ่งเป็นแนวตั้งและ 10 HU สำหรับแกน y ซึ่งเป็นแนวนอนแล้วเก็บรวบรวมพิกัดตำแหน่งของกระเพาะปัสสาวะที่ตรวจจับได้ตัวแรกมาจากระนาบทั้งสาม

**ขั้นที่ 5** หาค่าเฉลี่ยพิกัดเพื่อกำหนดเป็นพิกัดเริ่มต้นสำหรับชุดเอกซเรย์คอมพิวเตอร์ของคนไข้แต่ละราย จากนั้นกำหนดขนาดของกรอบภาพด้วยการคำนวณค่าพิกัดแรกสุด ( $x_1, y_1$ ) และค่าพิกัดท้ายสุด ( $x_2, y_2$ ) บวกและลบค่าพิกัดเริ่มต้น ( $x_0, y_0$ )

$$\text{ภาพบนระนาบตามแกน} : x_1 = x_0 - 93, x_2 = x_0 + 83 \quad (3.4)$$

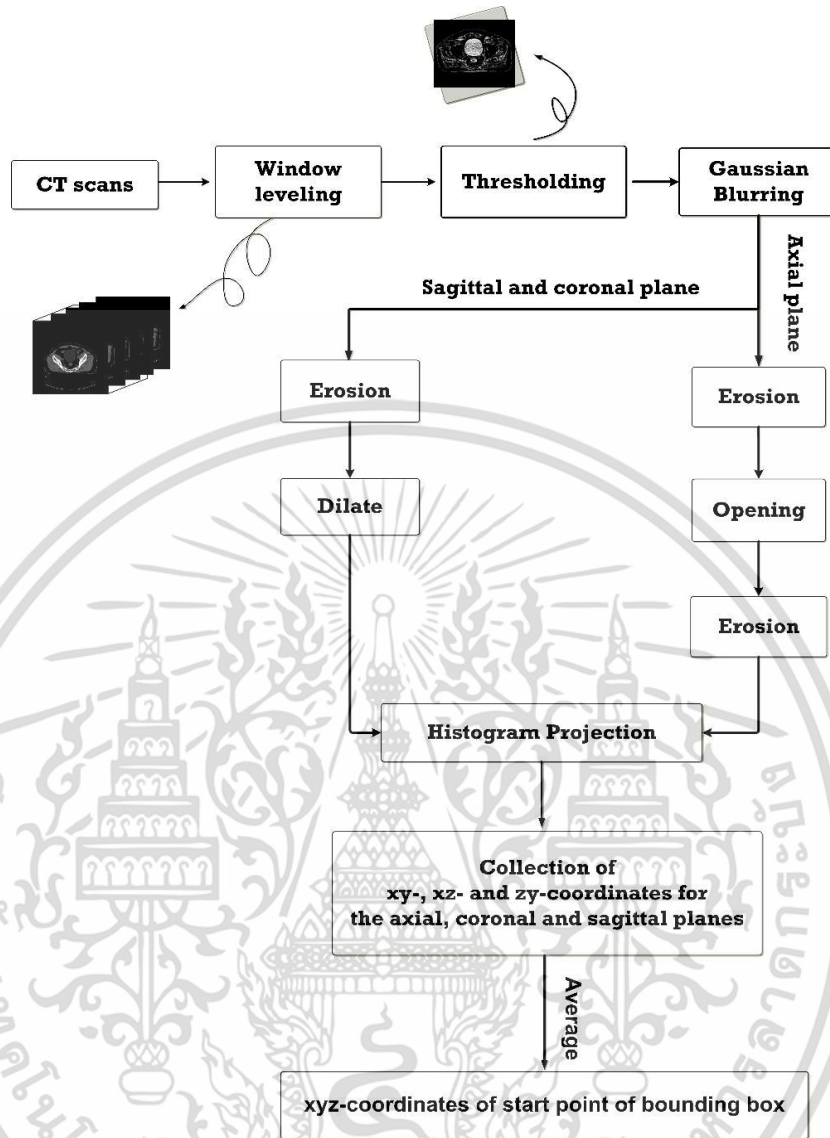
$$y_1 = y_0 - 93, y_2 = y_0 + 83 \quad (3.5)$$

ภาพบนระนาบในแนวตั้งแบ่งซ้ายขวากับสไลด์ระนาบแบ่งหน้าหลัง:


$$x_1 = x_0 - 93, x_2 = x_0 + 83 \quad (3.6)$$

$$y_1 = y_0 - 20, y_2 = y_0 + 75 \quad (3.7)$$

การครีอปทำให้ได้ขนาดของชุดข้อมูลใหม่ คือ  $176 \times 176$  พิกเซล สำหรับภาพสไลด์บนระนาบตามแกน  $176 \times 95$  พิกเซล สำหรับภาพสไลด์บนระนาบในแนวตั้งแบ่งซ้ายขวาและระนาบแบ่งหน้าหลัง รูปที่ 3.8 แสดงตัวอย่างผลลัพธ์ของภาพเอกซเรย์คอมพิวเตอร์ที่ผ่านขั้นตอนปรับปรุงคุณภาพทั้งหมดของทั้งสามระนาบ ทั้งนี้ ภาพของทั้งสามระนาบสามารถประกอบกันเป็นลูกบาศก์ได้พอดี (รูปที่ 3.9ข)




รูปที่ 3.7 ผังกระบวนการกำหนดพิกัดสำหรับกรอบภาพในการครีอของชุดข้อมูลกระเพาะปัสสาวะ




รูปที่ 3.8 ผลลัพธ์การครีอของชุดข้อมูลกระเพาะปัสสาวะ (ก) ภาพสไลด์บนระนาบในแนวตั้งแบ่งซ้ายขวา (ข) ระนาบแบ่งหน้าหลัง และ (ค) ระนาบตามแกน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(ก)



(ข)

รูปที่ 3.9 (ก) ขั้นตอนการเตรียมชุดข้อมูลล่วงหน้าสำหรับชุดข้อมูลกระเพาะปัสสาวะ (ข) ผลลัพธ์การครอปในสามระนาบและลูกบาศก์หลังถูกครอป

## 2. กระจกต้นขาข้างซ้าย

การเตรียมชุดข้อมูลล่วงหน้าสำหรับกระจกต้นขาข้างซ้าย หลังจากปรับหน้าต่างแสดงผลผ่านเทคนิควินโดวส์เลเวลลิงและปรับค่าใหม่ให้เป็นบรรทัดฐานแล้ว ชุดข้อมูลภาพจะถูกครอปลดขนาดภาพลงโดยยังคงรักษารายละเอียดไว้ การกำหนดพิกัดเพื่อสร้างกรอบภาพในการครอปเริ่มต้นด้วยการปรับหน้าต่างใหม่ด้วยค่า  $WL$  เท่ากับ 300 HU [87] และ  $WW$  เท่ากับ 400 HU เพื่อให้ภาพใหม่แสดงเฉพาะส่วนที่เป็นกระดูกเท่านั้น จากนั้นแปลงเป็นภาพไบนารี ใช้วิธีการฉายฮิสโทแกรมตรวจจับตำแหน่งของกระดูกโคนขาด้วยค่าระดับเกณฑ์เท่ากับ 2 HU ทั้งแกน  $x$  และ  $y$  เก็บรวบรวมพิกัดของแต่ละสไลด์มาแล้วหาค่าเฉลี่ยเพื่อกำหนดเป็นพิกัดเริ่มต้น  $(x_0, y_0)$  สำหรับสร้างกรอบภาพ สุดท้ายกำหนดขนาดของกรอบภาพด้วยการคำนวณค่าพิกัดแรกสุด  $(x_1, y_1)$  และค่าพิกัดท้ายสุด  $(x_2, y_2)$  บวกและลบค่าพิกัดเริ่มต้น  $(x_0, y_0)$

$$\text{ภาพบนระนาบตามแกน : } x_1 = x_0 - 0, x_2 = x_0 + 352 \quad (3.8)$$

$$y_1 = y_0 - 0, y_2 = y_0 + 208 \quad (3.9)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาพบนระนาบในแนวตั้งแบ่งซ้ายขวา:

$$x_1 = x_0 - 0, x_2 = x_0 + 208 \quad (3.10)$$

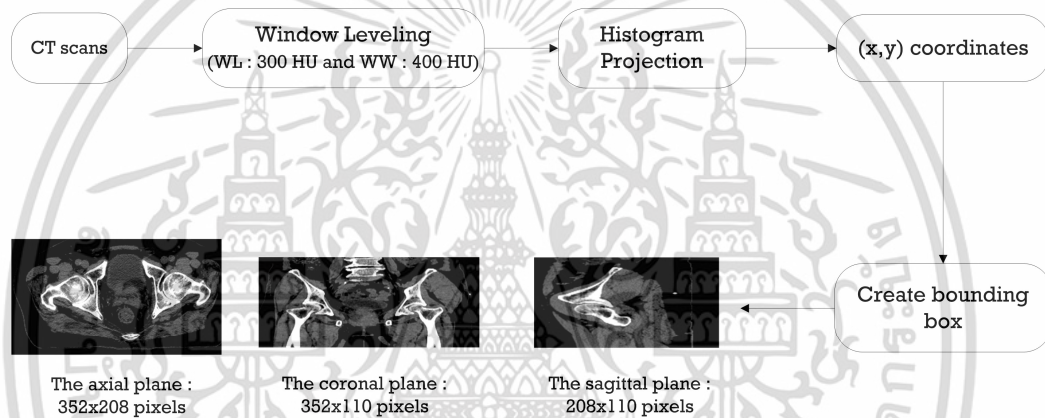
$$y_1 = y_0 - 0, y_2 = y_0 + 110 \quad (3.11)$$

ภาพบนระนาบแบ่งหน้าหลัง:

$$x_1 = x_0 - 0, x_2 = x_0 + 352 \quad (3.12)$$


$$y_1 = y_0 - 0, y_2 = y_0 + 110 \quad (3.13)$$

ผลลัพธ์ที่ได้ คือ ภาพสไลด์ขนาด 352 x 208 พิกเซล บนระนาบตามแกน 352 x 110 พิกเซล สำหรับภาพสไลด์บนระนาบแบ่งหน้าหลังและ 208 x 110 พิกเซล บนระนาบในแนวตั้งแบ่งซ้ายขวา (รูปที่ 3.10)

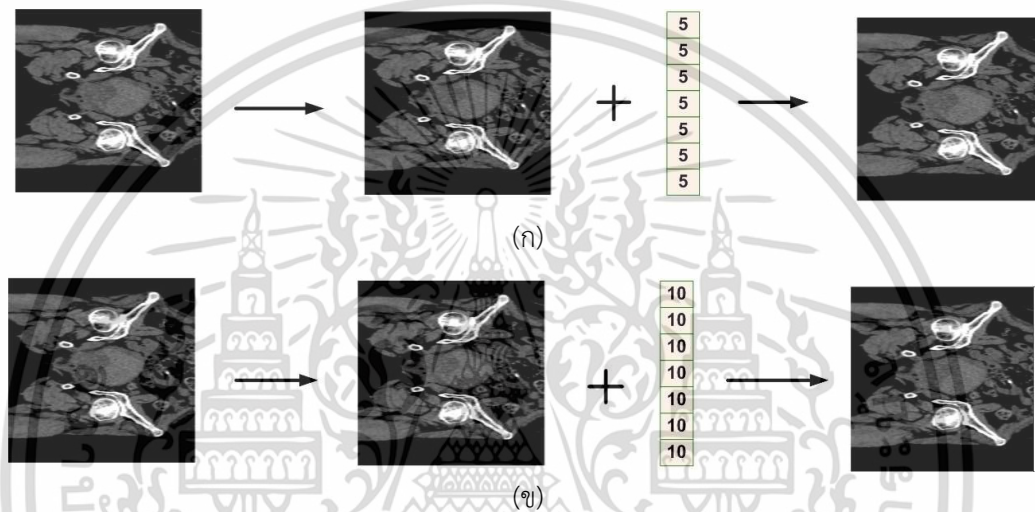


รูปที่ 3.10 ผังกระบวนการกำหนดพิกัดสำหรับกรอบภาพในการครีอปของชุดข้อมูลกระดูกต้นขาข้างซ้ายและขนาดใหม่หลังจากครีอปภาพ

จากนั้นนำภาพสไลด์เอกซเรย์คอมพิวเตอร์ขนาดใหม่มาตัดคอลัมน์สุดท้ายขวาสุดที่ไม่ซ้อนทับกับพื้นที่ของอวัยวะเป้าหมายออกแล้วเติมคอลัมน์ใหม่ที่กำหนดค่าใหม่ไว้เข้าไปแทน (รูปที่ 3.11) ซึ่งค่าในคอลัมน์ใหม่ที่ต่อเติมเข้าไปนั้นบรรจุค่าสัมประสิทธิ์คุณลักษณะภายนอกที่พิจารณาจากสภาพแวดล้อมภายนอกที่ไม่ได้ปรากฏในภาพเสริมเข้าไป ขั้นตอนนี้ คือ การเสริมคุณลักษณะ (Attribute Augmentation) ซึ่งสำหรับกรณีของกระดูกต้นขา ผู้วิจัยพิจารณาเลือกคุณลักษณะท่านอนของคนไข้ตอนฉายรังสีเพื่อถ่ายภาพ คือ ท่านอนหงาย (Supine Position) และท่านอนคว่ำ (Prone Position) เนื่องจากท่านอนของคนไข้มีอิทธิพลต่อตำแหน่งและลักษณะของกระดูกต้นขา อาจสลับจากซ้ายไปขวา กลับหัวกลับหาง มีโอกาสสับสนระหว่างกระดูกข้างซ้ายและข้างขวา ผู้วิจัยแบ่งการตั้งค่าสัมประสิทธิ์คุณลักษณะในคอลัมน์ที่เสริมเข้าไปไว้ทั้งหมด 3 กรณี คือ ท่านอนหงาย แทนด้วยค่าสัมประสิทธิ์คุณลักษณะ 1 5 (รูปที่ 3.12ก) และ 10 ในขณะที่ท่านอนคว่ำแทนด้วยค่าสัมประสิทธิ์คุณลักษณะ 2 10 (รูปที่ 3.12ข) และ 20



รูปที่ 3.11 ตัวอย่างการเสริมคุณลักษณะบนภาพสไลด์เอกซเรย์คอมพิวเตอร์



รูปที่ 3.12 ตัวอย่างการเสริมคุณลักษณะด้วย (ก) ค่าสัมประสิทธิ์คุณลักษณะเท่ากับ 5 สำหรับท่านอนหงาย และ (ข) ค่าสัมประสิทธิ์คุณลักษณะเท่ากับ 10 สำหรับท่านอนคว่ำของชุดข้อมูลกระดูกต้นขาข้างซ้าย

### 3.3.2 การแบ่งชุดข้อมูลเอกซเรย์คอมพิวเตอร์

จากชุดข้อมูลจากคนไข้จำนวน 120 คนเท่ากับข้อมูล 120 ชุด หลังผ่านขั้นตอนการเตรียมชุดข้อมูลล่วงหน้าดังที่อธิบายมาแล้วในตอนต้น นำชุดข้อมูลทั้งหมดมาแบ่งออกเป็นชุดข้อมูลฝึกฝน (Training Dataset) ชุดข้อมูลตรวจสอบ (Validation Dataset) และชุดข้อมูลทดสอบ (Test Dataset) ในอัตราส่วน 60:20:20 ประกอบด้วย ชุดข้อมูล 72 ชุด สำหรับชุดข้อมูลฝึกฝน ชุดข้อมูล 24 ชุด สำหรับชุดข้อมูลตรวจสอบ และชุดข้อมูล 24 ชุด สำหรับชุดข้อมูลทดสอบ

### 3.4 ระบบซอฟต์แวร์เพื่อการสร้างและทดลองแบบจำลองระบบการเรียนรู้เชิงลึกสำหรับการแบ่งส่วนอวัยวะ

แบบจำลองโครงข่ายประสาทเทียมเพื่อการแบ่งส่วนอวัยวะที่มีความเสี่ยงถูกสร้างขึ้นและฝึกฝนด้วยชุดข้อมูลที่เตรียมไว้โดยการเขียนโปรแกรมด้วยภาษาไพทอน (Python) บนแพลตฟอร์ม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Anaconda 3 รุ่น Python 3.9.13 ด้วยโปรแกรมประยุกต์ Jupyter Notebook รุ่น 6.4.12 ยี่ห้อ Anaconda ผลิตในประเทศสหรัฐอเมริกา เนื่องจากมีวัตถุประสงค์เพื่อการแบ่งส่วนภาพจึงเลือกสร้างโครงข่ายประสาทเทียมแบบ U-Net ใช้ชุดคำสั่งเคราส (Keras) ในการสร้างชั้น (Layer) ของโครงข่ายประสาทเทียมแบบ U-Net [68, 71, 72, 85] ทั้งชั้นนำเข้า ชั้นซ่อนซึ่งประกอบด้วยชั้นสังวัตนาการกับชั้นรวมของส่วนโครงข่ายที่หน้าที่เข้ารหัส ชั้นสังวัตนาการสลับเปลี่ยน ชั้นสังวัตนาการและชั้นต่อข้อมูล (Concatenation Layer) ของส่วนโครงข่ายที่ทำหน้าที่ถอดรหัส และชั้นนำออก ในการฝึกฝนดำเนินการบนโครงข่ายขนาด 5 ชั้น (รูปที่ 3.13) ซึ่งในหนึ่งชั้น ประกอบด้วยบล็อกการทำงานของส่วนเข้ารหัสและถอดรหัสที่มีขนาดเท่ากัน ดังนี้

**ชั้นที่ 1** ชั้นสังวัตนาการ ใช้เคอร์เนลขนาด 3x3 จำนวน 64 ตัว กับเคอร์เนลขนาด 1x1 จำนวน 1 ตัว ชั้นรวม ใช้เคอร์เนลขนาด 2x2 ชั้นสังวัตนาการสลับเปลี่ยน ใช้เคอร์เนลขนาด 3x3 และชั้นต่อข้อมูล

**ชั้นที่ 2** ชั้นสังวัตนาการ ใช้เคอร์เนลขนาด 3x3 จำนวน 128 ตัว ชั้นรวม ใช้เคอร์เนลขนาด 2x2, ชั้นสังวัตนาการสลับเปลี่ยน ใช้เคอร์เนลขนาด 3x3 และชั้นต่อข้อมูล

**ชั้นที่ 3** ชั้นสังวัตนาการ ใช้เคอร์เนลขนาด 3x3 จำนวน 256 ตัว ชั้นรวม ใช้เคอร์เนลขนาด 2x2, ชั้นสังวัตนาการสลับเปลี่ยน ใช้เคอร์เนลขนาด 3x3 และชั้นต่อข้อมูล

**ชั้นที่ 4** ชั้นสังวัตนาการ ใช้เคอร์เนลขนาด 3x3 จำนวน 512 ตัว ชั้นรวม ใช้เคอร์เนลขนาด 2x2, ชั้นสังวัตนาการสลับเปลี่ยน ใช้เคอร์เนลขนาด 3x3 และชั้นต่อข้อมูล


**ชั้นที่ 5** ชั้นสังวัตนาการ ใช้เคอร์เนลขนาด 3x3 จำนวน 1024 ตัว นอกจากนี้ยังมีชุดคำสั่ง numpy ในการคำนวณต่าง ๆ ชุดข้อมูลที่ใช้เป็นภาพซึ่งมีองค์ประกอบเป็นตัวเลขทั้งหมด และแสดงรูปภาพต่าง ๆ ด้วยชุดข้อมูล matplotlib

เมื่อเตรียมชุดข้อมูลฝึกฝนกับชุดข้อมูลตรวจสอบตามวิธีการประมวลผลล่วงหน้าซึ่งได้อธิบายไว้ในหัวข้อก่อนหน้าเรียบร้อยแล้ว ชุดข้อมูลจะแบ่งออกเป็นของกระเพาะปัสสาวะกับชุดข้อมูลของกระดูกต้นขาข้างซ้าย มีขนาดเท่ากับ 176 x 176 พิกเซล และ 352 x 208 พิกเซล และสร้างโครงสร้างโครงข่ายเสร็จแล้ว เริ่มต้นการฝึกฝนด้วยการป้อนชุดข้อมูลทั้งสองเข้าสู่แบบจำลอง กำหนดให้แต่ละชั้นสังวัตนาการที่ใช้เคอร์เนลขนาด 1x1 ใช้ฟังก์ชันซิกมอยด์เป็นฟังก์ชันกระตุ้น และใช้ฟังก์ชันเรคตีไฟต์ ลิเนียร์ ยูนิท (ReLU) เป็นฟังก์ชันกระตุ้นสำหรับชั้นสังวัตนาการอื่น ๆ จำนวนรอบการฝึกฝน 5000 รอบ อัตราการเรียนรู้ 0.001 ตั้งโบนารี คอส เอนโทรปี (Binary Cross-entropy Loss) [46] เป็นฟังก์ชันการสูญเสียสำหรับคำนวณค่าความผิดพลาดตามสมการ 3.14

$$Error_{\text{binary cross entropy}} = -y \cdot \log(\hat{y}) - (1 - y) \cdot \log(1 - \hat{y}) \quad (3.14)$$

เมื่อ  $\hat{y}$  คือ ค่านำออกที่ทำนายหรือคาดคะเนออกมา  $y$  คือ ค่านำออกที่ต้องการหรือนำออก

ตามความจริง



รูปที่ 3.13 โครงสร้างโครงข่ายประสาทเทียมแบบ U-Net ขนาด 5 ชั้น

ใช้การประมาณค่าช่วงเวลาปรับตัว (Adam) เป็นตัวหาค่าความเหมาะสมที่สุดในกระบวนการปรับค่าน้ำหนักและค่าไบแอสในแบบจำลองโครงข่ายประสาทเทียมแบบ U-Net พารามิเตอร์ต่าง ๆ เขียนสรุปในตารางที่ 3.2

ตารางที่ 3.2 ไฮเปอร์พารามิเตอร์ในขั้นตอนการฝึกฝนแบบจำลองโครงข่ายประสาทเทียมแบบ U-Net

| ไฮเปอร์พารามิเตอร์                    | ค่า                                   |                  |
|---------------------------------------|---------------------------------------|------------------|
| จำนวนรอบ (Epochs)                     | 5000                                  |                  |
| อัตราการเรียนรู้ (Learning rate)      | 0.001                                 |                  |
| ตัวหาค่าความเหมาะสมที่สุด (Optimizer) | Adam                                  |                  |
| ฟังก์ชันการสูญเสีย (Loss function)    | Binary Cross-entropy                  |                  |
| ขนาดข้อมูลนำเข้า (Input dimension)    | กระเพาะปัสสาวะ                        | 176 x 176 พิกเซล |
|                                       | กระดูกต้นขาข้างซ้าย                   | 352 x 208 พิกเซล |
| ฟังก์ชันกระตุ้น (Activation function) | Rectified linear unit (ReLU), Sigmoid |                  |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ระหว่างการฝึกฝนได้มีการตั้งเงื่อนไขหยุดการฝึกฝน เมื่อค่าความสูญเสียไม่ลดลงเกิน 10 รอบ การฝึกฝน ระบบจะหยุดการฝึกฝนโดยอัตโนมัติ และตั้งเงื่อนไขการเก็บแบบจำลองโครงข่ายประสาทเทียมแบบ U-Net ที่ผ่านการฝึกฝนรอบนั้น ๆ โดยตั้งให้ตัววัดจุดตัดเหนือยูเนียน (IoU) เป็นตัวแปรพิจารณา เมื่อได้แบบจำลองที่ประเมินค่าจุดตัดเหนือยูเนียนได้สูงขึ้นกว่าเดิม ระบบจะทำการดึงมาเก็บไว้

ทั้งขั้นตอนการประมวลผลล่วงหน้า การฝึกฝนและการทดสอบดำเนินการด้วยเครื่องซีพียู Core i9 gen 10 ที่มีความเร็วสูงสุดถึง 5.3 GHz จำนวนคอร์ 10C/20T แคช 20 MB Intel Smart Cache มีการ์ดจอ Intel UHD Graphics 630 คอนโทรลเลอร์อีเธอร์เน็ต 2.5G มีพื้นที่เก็บข้อมูลในตัว 128 GB เสริมด้วยการ์ดจอ Nvidia tesla K80 จำนวน 2 ตัว คำนวณแบบ Dual-GPU ที่ขับเคลื่อนด้วยชิป GK210 จำนวน 2 ตัว (ตัวละ 2,496 CUDA) พกพา CUDA 4,992 หน่วย Memory GDDR5 แบนด์วิดสูง 384-bit กับความจุ Memory 24 GB ค่า Clock Speed ที่ 562 MHz และการ์ดจอ Nvidia titan อีก 1 ตัว CUDA Core 3,584 หน่วย ความเร็วที่ 1.53 GHz และ 11 TFLOPS FP32

### 3.5 การประเมินผลการทดลอง

ในส่วนของ การประเมินผลการทดลองจะแบ่งออกเป็น 2 แบบ คือ

#### 3.5.1 การประเมินประสิทธิภาพการทำงานของโมเดลระบบการเรียนรู้เชิงลึก

การศึกษาวิจัยนี้ทดลองฝึกฝนแบบจำลองโครงข่ายประสาทเทียมแบบ U-Net ทั้งสิ้น 8 กรณี แบ่งออกเป็นฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะที่มีขั้นตอนการเตรียมชุดข้อมูลล่วงหน้าแตกต่างกัน 3 กรณี และการฝึกฝนด้วยชุดข้อมูลของกระดุกต้นขาข้างซ้ายที่มีขั้นตอนการเตรียมชุดข้อมูลล่วงหน้าแตกต่างกัน 5 กรณี ตามรายละเอียดด้านล่างนี้

1. ชุดข้อมูลของกระเพาะปัสสาวะ มีขั้นตอนเตรียมชุดข้อมูลล่วงหน้า ดังนี้
  - กรณีที่ 1 เทคนิควินโดวส์เลเวลลิง
  - กรณีที่ 2 เทคนิควินโดวส์เลเวลลิงและการครีอ
  - กรณีที่ 3 เทคนิควินโดวส์เลเวลลิง เทคนิคฮิสโทแกรมอีควอไลเซชัน การทำให้เรียบด้วยเกาส์เซียนและการครีอ
2. ชุดข้อมูลของกระดุกต้นขาข้างซ้าย มีขั้นตอนเตรียมชุดข้อมูลล่วงหน้า ดังนี้
  - กรณีที่ 1 เทคนิควินโดวส์เลเวลลิง
  - กรณีที่ 2 เทคนิควินโดวส์เลเวลลิงและการครีอ
  - กรณีที่ 3 เทคนิควินโดวส์เลเวลลิง การครีอ และการเสริมคุณลักษณะ (ท่านอนหงายและท่านนอนคว่ำแทนด้วยค่าสัมประสิทธิ์คุณลักษณะ 1 และ 2 ตามลำดับ)
  - กรณีที่ 4 เทคนิควินโดวส์เลเวลลิง การครีอ และการเสริมคุณลักษณะ (ท่านอนหงายและท่านนอนคว่ำแทนด้วยค่าสัมประสิทธิ์คุณลักษณะ 5 และ 10 ตามลำดับ)

- กรณีที่ 5 เทคนิควินโดวส์เลเวลลิง การครีออป และการเสริมคุณลักษณะ (ท่านอนหงายและท่านนอนคว่ำแทนด้วยค่าสัมประสิทธิ์คุณลักษณะ 10 และ 20 ตามลำดับ)

แบบจำลองโครงข่ายประสาทเทียมแบบ U-Net ที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะและชุดข้อมูลกระดูกต้นขาข้างซ้ายทั้ง 8 กรณี จะถูกประเมินประสิทธิภาพกับชุดข้อมูลทดสอบที่เตรียมไว้อีกชุดด้วยตัววัดค่าสัมประสิทธิ์ความคล้ายคลึงโคส (DSC) กับตัววัดจุดตัดเหนือยูเนียน (IoU) [57] คำนวณค่าประสิทธิภาพความแม่นยำของแบบจำลองที่ได้ ด้วยคำสั่ง `model.evaluate()` ที่มีอยู่ในชุดคำสั่งเคราส ทดสอบจำนวน 10 ครั้งแล้วคิดค่าเฉลี่ยออกมา

### 3.5.2 การประเมินโครงสร้างอวัยวะสามมิติ

นอกจากประเมินด้วยตัววัดทั้งสองชนิดแล้ว ผู้วิจัยได้สร้างแบบจำลองโครงสร้างสามมิติจากผลลัพธ์การแบ่งส่วนของแบบจำลองระบบการเรียนรู้เชิงลึกที่ผ่านการฝึกฝนมาแล้วด้วยขั้นตอนวิธีการต่อกันของลูกบาศก์ (Marching Cubes Algorithm) แต่ละแบบจำลองสามมิติถูกทำให้เรียบผ่านเทคนิคทำให้เมฆเรียบด้วยลาปลาเซียน ซึ่งกำหนดจำนวนรอบการปรับ 30 รอบ จากนั้นใช้สเปกตรัมแองเกอร์ แมปเปอร์ (SAM) หน่วยวัดดัชนีความคล้ายคลึงกันของโครงสร้าง (SSIM) ประเมินความคล้ายคลึงระหว่างแบบจำลองสามมิติจากผลลัพธ์ตามความเป็นจริงกับจากผลลัพธ์การแบ่งส่วนของแบบจำลองโครงข่ายประสาทเทียมแบบ U-Net (Predicted Result) ในมุมมอง 6 มุม ได้แก่ มุมมองด้านหน้า (Front) มุมมองด้านซ้าย (Left) มุมมองด้านหลัง (Rear) มุมมองด้านขวา (Right) มุมมองด้านบน (Top) และมุมมองด้านล่าง (Bottom)

และวัดระยะห่างเฮาส์ดอร์ฟระหว่างพื้นผิวของแบบจำลองสามมิติจากผลลัพธ์ตามความเป็นจริงและจากผลลัพธ์การแบ่งส่วนของแบบจำลองโครงข่ายประสาทเทียม [61] แสดงในลักษณะแผนผัง

## บทที่ 4

# ผลการวิเคราะห์ข้อมูล

### 4.1 การประเมินประสิทธิภาพการแบ่งส่วนอวัยวะของแบบจำลองเรียนรู้เชิงลึก

การประเมินประสิทธิภาพการแบ่งส่วนอวัยวะของแบบจำลองเรียนรู้เชิงลึกในงานศึกษาวิจัยนี้ใช้ตัววัดค่าสัมประสิทธิ์ความคล้ายคลึงไดซ์ (DSC) กับตัววัดจุดตัดเหนือยูเนียน (IoU) เป็นตัวประเมิน โดยการทดลองแบ่งออกเป็น 8 กรณี ประกอบด้วย การทดลองฝึกฝนแบบจำลองด้วยชุดข้อมูลของกระเพาะปัสสาวะที่มีขั้นตอนการเตรียมชุดข้อมูลล่วงหน้าแตกต่างกัน 3 กรณี และการฝึกฝนแบบจำลองด้วยชุดข้อมูลของกระดูกต้นขาข้างซ้ายที่มีขั้นตอนการเตรียมชุดข้อมูลล่วงหน้าแตกต่างกัน 5 กรณี

#### 4.1.1 แบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะ

จากการประเมินประสิทธิภาพด้วยชุดข้อมูลทดสอบจำนวน 10 ครั้งแล้วทำการเฉลี่ยผลออกมา ผลการประเมินที่แสดงในตารางที่ 4.1 พบว่าแบบจำลองที่ผ่านการฝึกด้วยชุดข้อมูลที่ใช้เพียงเทคนิควินโดวส์เลเวลลิง (กรณีที่ 1) ได้ค่า DSC เท่ากับ 70.93% และได้ค่า IoU เท่ากับ 61.37% ผลการแบ่งส่วนกระเพาะปัสสาวะของแบบจำลองมีการทำนายส่วนที่ไม่ใช่กระเพาะปัสสาวะออกมาด้วย และส่วนที่เป็นกระเพาะปัสสาวะซึ่งเป็นอวัยวะเป้าหมายก็ทำนายบริเวณผิวนอกออกมาไม่ค่อยสมบูรณ์ มีบางส่วนที่ขาดหายไป (รูปที่ 4.1)


ผลการประเมินของแบบจำลองที่ผ่านการฝึกด้วยชุดข้อมูลที่ใช้เทคนิควินโดวส์เลเวลลิงร่วมกับการครีอปเพื่อลดขนาดภาพลง (กรณีที่ 2) ได้ค่า DSC เท่ากับ 81.73% และได้ค่า IoU เท่ากับ 70.30% ความแม่นยำเพิ่มขึ้นจากกรณีที่ 1 มา 10.8% และ 8.93% ตามลำดับ ผลการทำนายไม่มีส่วนเกินนอกเหนือจากพื้นที่ที่เป็นของกระเพาะปัสสาวะเหมือนอย่างที่เกิดขึ้นในกรณีที่ 1 แต่การแบ่งส่วนกระเพาะปัสสาวะเองก็ไม่ได้สมบูรณ์ มีส่วนที่ขาดหายและผิวนอกไม่เรียบ (รูปที่ 4.2)

และผลการประเมินของแบบจำลองที่ผ่านการฝึกด้วยชุดข้อมูลที่ใช้เทคนิควินโดวส์เลเวลลิงเทคนิคฮิสโทแกรมอีควอไลเซชัน การทำให้เรียบด้วยเกาส์เซียน ก่อนจะทำการครีอปเพื่อลดขนาดลง (กรณีที่ 3) ได้ค่า DSC เท่ากับ 95.15% และได้ค่า IoU เท่ากับ 91.10% ความแม่นยำเพิ่มขึ้นจากกรณีที่ 1 เท่ากับ 24.22% และ 29.73% ตามลำดับ และเพิ่มขึ้นจากกรณีที่ 2 เท่ากับ 13.42% และ 20.80% ตามลำดับ ซึ่งได้ค่าประเมินประสิทธิภาพการแบ่งส่วนที่สูงที่สุด แสดงถึงความแม่นยำที่มากกว่าสองกรณีก่อนหน้านี้ ในส่วนของผลการแบ่งส่วนกระเพาะปัสสาวะบนสไลด์เอกซเรย์คอมพิวเตอร์ตามที่แสดงในรูปที่ 4.3 เห็นได้ว่าการแบ่งส่วนหรือการทำนายมีความสมบูรณ์มากกว่าสองกรณีก่อนหน้านี้ ผิวนอกเรียบ ส่วนที่ขาดหายลดน้อยลง และมีความใกล้เคียงกับคำตอบตามความเป็นจริง


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.1 ผลการประเมินประสิทธิภาพแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะ

| กรณีศึกษา | ขั้นตอนการเตรียมชุดข้อมูลล่วงหน้า  | ตัววัดประสิทธิภาพ (%) |       |
|-----------|--|-----------------------|-------|
|           |  | DSC                   | IoU   |
| กรณีที่ 1 | เทคนิคควินโตวส์เลเวลลิง  | 70.93                 | 61.37 |
| กรณีที่ 2 | เทคนิคควินโตวส์เลเวลลิงและการครีอป   | 81.73                 | 70.30 |
| กรณีที่ 3 | เทคนิคควินโตวส์เลเวลลิง เทคนิคฮิสโทแกรมอีควอไลเซชัน การทำให้เรียบด้วยเกาส์เซียนและการครีอป | 95.15                 | 91.10 |




เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.1 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะในกรณีที่ 1


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.2 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะในกรณีที่ 2



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.3 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะในกรณีที่ 3

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

#### 4.1.2 แบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกต้นขาข้างซ้าย

จากการประเมินประสิทธิภาพการแบ่งส่วนต้นขาข้างซ้ายด้วยชุดข้อมูลทดสอบจำนวน 10 ครั้งแล้วคำนวณค่าประเมินเฉลี่ยออกมา ตามผลลัพธ์ที่แสดงในตารางที่ 4.2 พบว่าแบบจำลองที่ผ่านการฝึกฝนด้วยชุดข้อมูลที่ดำเนินการเพียงเทคนิควินโดวส์เลเวลลิง (กรณีที่ 1) มีความแม่นยำต่ำ ประเมินได้เพียง 37.76% ในตัววัด DSC และ 23.90% ในตัววัด IoU ในรูปที่ 4.4 แสดงผลลัพธ์การแบ่งส่วนกระดูกต้นขาข้างซ้ายในสไลด์เอกซเรย์คอมพิวเตอร์เห็นได้ชัดว่ามีชิ้นส่วนขาดหายไปค่อนข้างมาก ปรากฏแค่ส่วนที่เป็นส่วนหัวของกระดูกต้นขา (Head of Femur) กับส่วนคอกระดูกต้นขา (Neck of Femur) และปุ่มหัวกระดูกต้นขา (Greater Trochanter of Femur) เพียงบางส่วนเท่านั้น อีกทั้งยังมีการแบ่งส่วนที่เป็นกระดูกต้นขาข้างขวาที่ไม่ใช่เป้าหมายด้วย

ผลการประเมินประสิทธิภาพการแบ่งส่วนของแบบจำลองที่ผ่านการฝึกฝนด้วยชุดข้อมูลที่ผ่านการดำเนินการวินโดวส์เลเวลลิงพร้อมทั้งลดขนาดชุดข้อมูลลงด้วยการครีอ (กรณีที่ 2) ได้ว่าตัววัด DSC ประเมินได้ค่า 58.00% และตัววัด IoU ประเมินได้ค่า 42.19% ผลลัพธ์การแบ่งส่วนบนสไลด์เอกซเรย์คอมพิวเตอร์ในรูปที่ 4.5 แสดงให้เห็นการแบ่งส่วนหรือทำนายส่วนที่เป็นกระดูกต้นขาข้างซ้ายได้ถูกต้องมากยิ่งขึ้นเมื่อเทียบกับผลลัพธ์ในกรณีที่ 1 แต่บริเวณอินเตอร์โทรแคนเทอร์ริก (Intertrochanteric Area) และปุ่มกระดูกต้นขาขนาดเล็ก (Lesser Trochanter) ขาดหายไปบางส่วนและในขณะเดียวกันก็ทำนายส่วนที่เป็นกระดูกต้นขาข้างขวาที่ไม่ใช่เป้าหมายออกมาด้วยมากพอสมควร

ในการทดลองฝึกฝนแบบจำลองกรณีที่ 3 ด้วยชุดข้อมูลที่ผ่านการดำเนินการวินโดวส์เลเวลลิงลดขนาดชุดข้อมูลลงด้วยการครีอ และเสริมคุณลักษณะด้วยท่านอนของคนไข้โดยตั้งค่าสัมประสิทธิ์คุณลักษณะเท่ากับ 1 แทนท่านอนหงายและค่าสัมประสิทธิ์คุณลักษณะเท่ากับ 2 แทนท่านอนคว่ำ ผลการประเมินประสิทธิภาพโดยตัววัด DSC และ IoU ได้เท่ากับ 61.37% และ 45.46% ตามลำดับ ซึ่งเพิ่มขึ้นจากกรณีที่ 1 มา 23.61% และ 21.56% เพิ่มจากกรณีที่ 2 มา 3.37% และ 3.27% ตามลำดับ การแบ่งส่วนบนสไลด์เอกซเรย์คอมพิวเตอร์ที่แสดงในรูปที่ 4.6 แสดงให้เห็นว่าแบบจำลองมีการทำนายส่วนของกระดูกต้นขาข้างขวาลดลงเมื่อเทียบกับกรณีที่ 2 แต่ผลการทำนายของกระดูกต้นขาข้างซ้ายนั้น ส่วนหัวกระดูกแหงไปไม่สมบูรณ์และบริเวณปลายอินเตอร์โทรแคนเทอร์ริกกับปลายของปุ่มกระดูกต้นขาขนาดเล็ก (Lesser Trochanter) ขาดหายไปบางส่วน

ผลการประเมินประสิทธิภาพการแบ่งส่วนของแบบจำลองที่ผ่านการฝึกฝนด้วยชุดข้อมูลที่ผ่านการดำเนินการวินโดวส์เลเวลลิง ลดขนาดชุดข้อมูลลงด้วยการครีอ และเสริมคุณลักษณะด้วยท่านอนของคนไข้โดยตั้งค่าสัมประสิทธิ์คุณลักษณะเท่ากับ 5 แทนท่านอนหงายและค่าสัมประสิทธิ์คุณลักษณะเท่ากับ 10 แทนท่านอนคว่ำ (กรณีที่ 4) ในตารางที่ 4.2 แสดงตัววัด DSC ประเมินได้ค่า 88.25% และตัววัด IoU ประเมินได้ค่า 80.85% เพิ่มขึ้นจากกรณีที่แทนด้วยค่าสัมประสิทธิ์ 1 และ 2 (กรณีที่ 3) มา 26.88% สำหรับตัววัด DSC และ 35.39% สำหรับตัววัด IoU ผลลัพธ์การแบ่งส่วนบน


สไลด์เอกซเรย์คอมพิวเตอร์ในรูปที่ 4.7 แสดงให้เห็นการทำนายผิดฝั่งที่น้อยลงจนแทบไม่มี ส่วนการแบ่งส่วนกระดูกต้นขาข้างซ้ายที่เป็นเป้าหมายนั้นมีความสมบูรณ์มากขึ้น ใกล้เคียงกับผลลัพธ์ตามความเป็นจริง แต่ก็ยังมีส่วนที่ขาดหายไปเล็กน้อยตรงบริเวณปลายอินเตอร์โทรแคนเทอร์ริกและปลายของปุ่มกระดูกต้นขาขนาดเล็ก

กรณีสุดท้ายประสิทธิภาพการแบ่งส่วนของแบบจำลองที่ผ่านการฝึกฝนด้วยชุดข้อมูลที่ผ่านการดำเนินการวินโดวส์เลเวลลิง ลดขนาดชุดข้อมูลลงด้วยการครีออป และเสริมคุณลักษณะด้วยท่านอนของคนไข้โดยตั้งค่าสัมประสิทธิ์คุณลักษณะเท่ากับ 10 แทนท่านอนหงายและค่าสัมประสิทธิ์คุณลักษณะเท่ากับ 20 แทนท่านอนคว่ำ (กรณีที่ 5) แสดงผลของตัววัด DSC ได้เท่ากับ 72.54% และตัววัด IoU ได้เท่ากับ 57.93% ซึ่งลดลงจากกรณีที่ 4 เท่ากับ 15.71% และ 22.92% ตามลำดับ แต่ก็ยังมากกว่ากรณีที่ 3 อยู่ 11.17% สำหรับค่า DSC และ 12.47% สำหรับค่า IoU ในรูปที่ 4.8 แสดงตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองบนสไลด์เอกซเรย์คอมพิวเตอร์เห็นได้ว่าไม่มีการแบ่งส่วนของกระดูกต้นขาข้างขวา แต่ในขณะเดียวกันส่วนของกระดูกต้นขาข้างซ้ายที่เป็นเป้าหมายเองก็ทำนายส่วนหัวของกระดูกขาดหายไปเช่นกัน รวมถึงชิ้นส่วนบริเวณปลายอินเตอร์โทรแคนเทอร์ริกและปลายปุ่มกระดูกต้นขาขนาดเล็กด้วยเล็กน้อย

**ตารางที่ 4.2** ผลการประเมินประสิทธิภาพแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกต้นขาข้างซ้าย


| กรณีศึกษา | ขั้นตอนการเตรียมชุดข้อมูลล่วงหน้า   | ตัววัดประสิทธิภาพ (%) |       |
|-----------|---|-----------------------|-------|
|           |   | DSC                   | IoU   |
| กรณีที่ 1 | เทคนิควินโดวส์เลเวลลิง  | 37.76                 | 23.90 |
| กรณีที่ 2 | เทคนิควินโดวส์เลเวลลิงและการครีออป  | 58.00                 | 42.19 |
| กรณีที่ 3 | เทคนิควินโดวส์เลเวลลิง การครีออป และการเสริมคุณลักษณะ (ท่านอนหงายและท่านอนคว่ำแทนด้วยค่าสัมประสิทธิ์คุณลักษณะ 1 และ 2 ตามลำดับ)   | 61.37                 | 45.46 |
| กรณีที่ 4 | เทคนิควินโดวส์เลเวลลิง การครีออป และการเสริมคุณลักษณะ (ท่านอนหงายและท่านอนคว่ำแทนด้วยค่าสัมประสิทธิ์คุณลักษณะ 5 และ 10 ตามลำดับ)  | 88.25                 | 80.85 |
| กรณีที่ 5 | เทคนิควินโดวส์เลเวลลิง การครีออป และการเสริมคุณลักษณะ (ท่านอนหงายและท่านอนคว่ำแทนด้วยค่าสัมประสิทธิ์คุณลักษณะ 10 และ 20 ตามลำดับ) | 72.54                 | 57.93 |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.4 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกต้นขาข้างซ้ายในกรณีที่ 1

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.5 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกต้นขาข้างซ้ายในกรณีที่ 2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.6 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกต้นขาข้างซ้ายในกรณีที่ 3

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.7 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกต้นขาข้างซ้ายในกรณีที่ 4

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



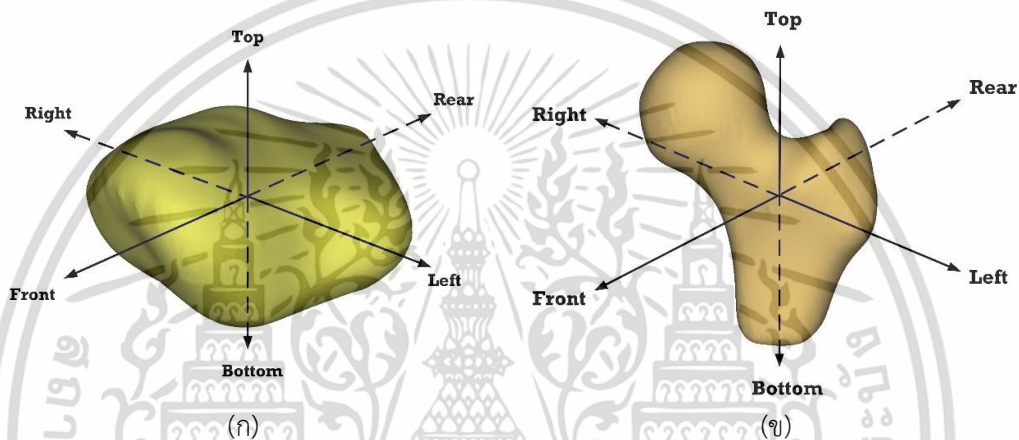
รูปที่ 4.8 ตัวอย่างผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกต้นขาข้างซ้ายในกรณีที่ 5

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.2 การประเมินแบบจำลองโครงสร้างอวัยวะสามมิติ

ผลการแบ่งส่วนบนสไลด์เอกซเรย์คอมพิวเตอร์ถูกนำมาสร้างแบบจำลองโครงสร้างสามมิติขึ้นใหม่แล้วประเมินความคล้ายคลึงกับแบบจำลองโครงสร้างสามมิติจากผลลัพธ์จริงใน 6 มุมมอง ด้วยตัววัดสเปกตรัม แองเกอร์ แมปเปอร์ (SAM) และหน่วยวัดดัชนีความคล้ายคลึงกันของโครงสร้าง (SSIM) ตามที่แสดงในตารางที่ 4.3

ในรูปที่ 4.9 แสดงมุมมองไอโซเมตริก (Isometric) ของแบบจำลองโครงสร้างสามมิติของกระดูกสันหลังและกระดูกต้นขาข้างซ้าย





















รูปที่ 4.9 แสดงมุมมองไอโซเมตริกของแบบจำลองโครงสร้างสามมิติของ (ก) กระเพาะปัสสาวะและ (ข) กระดูกต้นขาข้างซ้าย

จากการประเมินความคล้ายคลึงของแบบจำลองโครงสร้างสามมิติเทียบกับผลลัพธ์ตามความเป็นจริงพบว่า แบบจำลองโครงสร้างสามมิติของกระดูกสันหลังจากแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนในกรณีที่ 1 ได้ค่า SAM อยู่ในช่วง 0.208 – 0.295 และค่า SSIM ในช่วง 0.537 – 0.632 การเปรียบเทียบแบบจำลองโครงสร้างสามมิติของกระดูกสันหลังจากแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนในกรณีที่ 2 ได้ค่า SAM อยู่ในช่วง 0.091 – 0.177 และค่า SSIM ในช่วง 0.634 – 0.817 และผลการประเมินของแบบจำลองโครงสร้างสามมิติของกระดูกสันหลังจากแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนในกรณีที่ 3 ได้ค่า SAM อยู่ในช่วง 0.076 – 0.160 และค่า SSIM ในช่วง 0.698 – 0.839

ในส่วน of แบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้าย ผลจากแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนในกรณีที่ 1 ได้ค่า SAM อยู่ในช่วง 0.209 – 0.257 และค่า SSIM ในช่วง 0.433 – 0.544 ผลการประเมินของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้ายจากแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนในกรณีที่ 2 ได้ค่า SAM อยู่ในช่วง 0.135 – 0.236 และค่า SSIM ในช่วง 0.658 – 0.714 ผลการประเมินของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้ายจาก







แบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนในกรณีที่ 3 ได้ค่า SAM อยู่ในช่วง 0.121 – 0.223 และค่า SSIM ในช่วง 0.668 – 0.729 ผลการประเมินของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้ายจากแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนในกรณีที่ 4 ได้ค่า SAM อยู่ในช่วง 0.117 – 0.215 และค่า SSIM ในช่วง 0.701 – 0.732 และผลการประเมินของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้ายจากแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนในกรณีที่ 5 ได้ค่า SAM อยู่ในช่วง 0.120 – 0.223 และค่า SSIM ในช่วง 0.675 – 0.729

**ตารางที่ 4.3** ผลการประเมินความคล้ายคลึงระหว่างแบบจำลองโครงสร้างสามมิติของกระดูกเป็ดสวาทด้วยตัววัดสเปกตรัม แองเกอร์ แมปเปอร์ (SAM) หน่วยวัดดัชนีความคล้ายคลึงกันของโครงสร้าง (SSIM)













| ผลการประเมินความคล้ายคลึงของแบบจำลองโครงสร้างสามมิติของกระดูกเป็ดสวาท |   |   |   |  |   |   |
|---|---|---|---|--|---|---|
| กรณีที่ 1   |   |   |   |  |   |   |
|   | หน้า  | ซ้าย  | หลัง  | ขวา  | บน  | ล่าง  |
| ผลลัพธ์ตามความเป็นจริง  |   |   |   |   |   |   |
| ผลลัพธ์การทำนาย   |  |  |  |  |  |  |
| SAM   | 0.295   | 0.261   | 0.290   | 0.264  | 0.264   | 0.208   |
| SSIM  | 0.601   | 0.537   | 0.608   | 0.631  | 0.613   | 0.632   |
| ผลการประเมินความคล้ายคลึงของแบบจำลองโครงสร้างสามมิติของกระดูกเป็ดสวาท |   |   |   |  |   |   |
| กรณีที่ 2   |   |   |   |  |   |   |
|   | หน้า  | ซ้าย  | หลัง  | ขวา  | บน  | ล่าง  |
| ผลลัพธ์การทำนาย   |  |  |  |  |  |  |
| SAM   | 0.158   | 0.112   | 0.111   | 0.091  | 0.172   | 0.177   |
| SSIM  | 0.665   | 0.798   | 0.757   | 0.817  | 0.634   | 0.662   |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



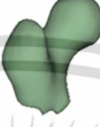















ตารางที่ 4.3 ผลการประเมินความคล้ายคลึงระหว่างแบบจำลองโครงสร้างสามมิติของกระเพาะปัสสาวะด้วยตัววัดสเปกตรัม แองเกอร์ แมปเปอร์ (SAM) หน่วยวัดดัชนีความคล้ายคลึงกันของโครงสร้าง (SSIM) (ต่อ)

| ผลการประเมินความคล้ายคลึงของแบบจำลองโครงสร้างสามมิติของกระเพาะปัสสาวะ<br>กรณีที่ 3 |   |   |   |  |   |   |
|--|---|---|---|--|---|---|
|  | หน้า  | ซ้าย  | หลัง  | ขวา  | บน  | ล่าง  |
| ผลลัพธ์<br>การทำนาย  |  |  |  |  |  |  |
| SAM  | 0.156   | 0.088   | 0.108   | 0.076  | 0.160   | 0.153   |
| SSIM   | 0.698   | 0.814   | 0.768   | 0.839  | 0.730   | 0.729   |

ตารางที่ 4.4 ผลการประเมินความคล้ายคลึงระหว่างแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้ายด้วยตัววัดสเปกตรัม แองเกอร์ แมปเปอร์ (SAM) และหน่วยวัดดัชนีความคล้ายคลึงกันของโครงสร้าง (SSIM)







| ผลการประเมินความคล้ายคลึงของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้าย<br>กรณีที่ 1 |   |   |   |  |   |   |
|---|---|---|---|--|---|---|
|   | หน้า  | ซ้าย  | หลัง  | ขวา  | บน  | ล่าง  |
| ผลลัพธ์<br>ตามความเป็นจริง  |  |  |  |  |  |  |
| ผลลัพธ์<br>การทำนาย   |  |  |  |  |  |  |
| SAM   | 0.211   | 0.214   | 0.209   | 0.223  | 0.243   | 0.257   |
| SSIM  | 0.433   | 0.454   | 0.501   | 0.532  | 0.502   | 0.544   |

ตารางที่ 4.4 ผลการประเมินความคล้ายคลึงระหว่างแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้ายข้างซ้ายด้วยตัววัดสเปกตรัม แองเกอร์ แมปเปอร์ (SAM) และหน่วยวัดดัชนีความคล้ายคลึงกันของโครงสร้าง (SSIM) (ต่อ)

| ผลการประเมินความคล้ายคลึงของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้าย<br>กรณีที่ 2 |   |   |   |  |   |   |
|---|---|---|---|--|---|---|
|   | หน้า  | ซ้าย  | หลัง  | ขวา  | บน  | ล่าง  |
| ผลลัพธ์<br>การทำนาย   |    |    |    |    |    |    |
| SAM   | 0.155   | 0.165   | 0.144   | 0.135  | 0.187   | 0.236   |
| SSIM  | 0.677   | 0.658   | 0.712   | 0.714  | 0.701   | 0.689   |
| ผลการประเมินความคล้ายคลึงของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้าย<br>กรณีที่ 3 |   |   |   |  |   |   |
|   | หน้า  | ซ้าย  | หลัง  | ขวา  | บน  | ล่าง  |
| ผลลัพธ์<br>การทำนาย   |   |   |   |   |   |   |
| SAM   | 0.162   | 0.149   | 0.152   | 0.121  | 0.223   | 0.220   |
| SSIM  | 0.668   | 0.669   | 0.708   | 0.729  | 0.688   | 0.708   |
| ผลการประเมินความคล้ายคลึงของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้าย<br>กรณีที่ 4 |   |   |   |  |   |   |
|   | หน้า  | ซ้าย  | หลัง  | ขวา  | บน  | ล่าง  |
| ผลลัพธ์<br>การทำนาย   |  |  |  |  |  |  |
| SAM   | 0.142   | 0.138   | 0.129   | 0.117  | 0.204   | 0.215   |
| SSIM  | 0.702   | 0.706   | 0.725   | 0.732  | 0.701   | 0.710   |


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

**ตารางที่ 4.4** ผลการประเมินความคล้ายคลึงระหว่างแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้ายข้างซ้ายด้วยตัววัดสเปกตรัม แองเกอร์ แมปเปอร์ (SAM) และหน่วยวัดดัชนีความคล้ายคลึงกันของโครงสร้าง (SSIM) (ต่อ)

| ผลการประเมินความคล้ายคลึงของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้าย<br>กรณีที่ 5 |   |   |   |  |   |   |
|---|---|---|---|--|---|---|
|   | หน้า  | ซ้าย  | หลัง  | ขวา  | บน  | ล่าง  |
| ผลลัพธ์<br>การทำนาย   |  |  |  |  |  |  |
| SAM   | 0.151   | 0.145   | 0.134   | 0.120  | 0.196   | 0.223   |
| SSIM  | 0.683   | 0.675   | 0.722   | 0.729  | 0.700   | 0.702   |


ในรูปที่ 4.10 แสดงภาพแบบจำลองโครงสร้างสามมิติของผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกเป่าสวและกระดูกต้นขาข้างซ้ายในกรณีที่ 1 ซึ่งแบบจำลองโครงสร้างของกระดูกเป่าสวามีส่วนที่ไม่ใช่กระดูกเป่าสวถูกสร้างขึ้นมา ส่วนของกระดูกต้นขาข้างซ้ายถูกสร้างขึ้นมาไม่สมบูรณ์ มีหลายส่วนที่ขาดหายไปอย่างเห็นได้ชัด และในรูปที่ 4.11 ผลจากกรณีศึกษาที่ 2 แบบจำลองโครงสร้างของกระดูกเป่าสวมีความสมบูรณ์มากขึ้นและไม่มีส่วนแปลกปลอมปะปนมา ในขณะที่กรณีของกระดูกต้นขาข้างซ้ายนั้นปรากฏโครงสร้างของกระดูกต้นขาข้างขวา อีกทั้งช่วงบริเวณปลายอินเตอร์โทรเคนเทอร์ริกและปลายปุ่มกระดูกต้นขาขนาดเล็กของกระดูกต้นขาข้างซ้ายยังขาดหายไปด้วย แต่เมื่อเทียบกับโครงสร้างจากกรณีศึกษาที่ 1 แล้วโครงสร้างของกระดูกต้นขาข้างซ้ายนั้นถูกสร้างขึ้นมาสมบูรณ์และเป็นรูปเป็นร่างมากกว่า

ในรูปที่ 4.12 แสดงแบบจำลองโครงสร้างสามมิติของผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกเป่าสวและกระดูกต้นขาข้างซ้าย ในกรณีศึกษาที่ 3 แบบจำลองโครงสร้างของกระดูกเป่าสวมีความสมบูรณ์ ส่วนกระดูกต้นขาข้างซ้ายจะเห็นว่าส่วนหัวเว้าแหงไปเยอะพอสมควร และยังปรากฏชิ้นส่วนของกระดูกต้นขาข้างขวาอยู่ ในรูปที่ 4.13 แบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้าย ซึ่งได้จากแบบจำลองเรียนรู้เชิงลึกในกรณีที่ 4 พบว่าโครงสร้างของกระดูกต้นขาข้างซ้ายมีความสมบูรณ์ค่อนข้างมาก รวมทั้งปรากฏชิ้นส่วนของกระดูกต้นขาข้างขวาเพียงเล็กน้อยเท่านั้น มีแค่ขาดส่วนปลายอินเตอร์โทรเคนเทอร์ริกและปลายของปุ่มกระดูกต้นขาขนาดเล็กไปเล็กน้อย



รูปที่ 4.10 ภาพแบบจำลองโครงสร้างสามมิติของผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกพะวงและกระดูกต้นขาข้างซ้ายในกรณีที่ 1

รูปที่ 4.11 ภาพแบบจำลองโครงสร้างสามมิติของผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระดูกพะวงและกระดูกต้นขาข้างซ้ายในกรณีที่ 2




รูปที่ 4.12 ภาพแบบจำลองโครงสร้างสามมิติของผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะและกระดุกต้นขาข้างซ้ายในกรณีที่ 3



รูปที่ 4.13 ภาพแบบจำลองโครงสร้างสามมิติของผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะในกรณีที่ 3 และกระดุกต้นขาข้างซ้ายในกรณีที่ 4

และในรูปที่ 4.14 แบบจำลองโครงสร้างสามมิติของกระดุกต้นขาข้างซ้าย ซึ่งได้จากแบบจำลองเรียนรู้เชิงลึกในกรณีศึกษาที่ 5 พบว่าไม่ปรากฏชิ้นส่วนของกระดุกต้นขาข้างขวา แต่ส่วนหัวของกระดุกต้นขาข้างซ้ายที่เป็นเป้าหมายก็แหงนไปด้วย รวมถึงบริเวณปลายอินเตอร์โทรแคนเทอร์ริกและปลายปุ่มกระดุกต้นขาขนาดเล็ก



รูปที่ 4.14 ภาพแบบจำลองโครงสร้างสามมิติของผลลัพธ์การแบ่งส่วนของแบบจำลองเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยชุดข้อมูลของกระเพาะปัสสาวะในกรณีที่ 3 และกระดุกต้นขาข้างซ้ายในกรณีที่ 5

### 4.3 ระยะพื้นผิว

ผู้วิจัยทำการวัดระยะห่างระหว่างพื้นผิวแบบจำลองโครงสร้างสามมิติของกระเพาะปัสสาวะกับกระดุกต้นขาข้างซ้ายกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริงของทั้งสองอวัยวะด้วยเทคนิคการวัดระยะห่างเฮาส์ดอร์ฟซึ่งได้ผลการวัดตามตารางที่ 4.5 และในรูปที่ 4.15 ถึงรูปที่ 4.17 แสดงผังสี่ที่บ่งชี้ระยะห่างระหว่างพื้นผิวบริเวณต่าง ๆ ของแบบจำลองโครงสร้างสามมิติของกระเพาะปัสสาวะในแต่ละกรณีศึกษา ส่วนในรูปที่ 4.18 ถึงรูปที่ 4.22 แสดงผังสี่ที่บ่งชี้ระยะห่างระหว่างพื้นผิวบริเวณต่าง ๆ ของแบบจำลองโครงสร้างสามมิติของกระดุกต้นขาข้างซ้ายสำหรับแต่ละกรณีศึกษาโดยค่าเป็นลบ (สีแดง) หมายถึง แบบจำลองโครงสร้างสามมิติของผลลัพธ์ที่ได้จากแบบจำลองเรียนรู้เชิงลึกบริเวณนั้นขาดหายไป ค่าเป็นศูนย์ (สีเหลือง) หมายถึง พื้นผิวแบบจำลองโครงสร้างสามมิติของผลลัพธ์ที่ได้จากแบบจำลองเรียนรู้เชิงลึกบริเวณนั้นพอดีกับพื้นผิวของแบบจำลองโครงสร้างที่เป็นผลลัพธ์ตามความเป็นจริง และค่าเป็นบวก (สีเขียว) หมายถึง แบบจำลองโครงสร้างสามมิติของผลลัพธ์ที่ได้จากแบบจำลองเรียนรู้เชิงลึกบริเวณนั้นเกินหรือเลยพื้นผิวของแบบจำลองโครงสร้างที่เป็นผลลัพธ์ตามความเป็นจริงออกมา

จากการวัดพบว่าแบบจำลองโครงสร้างสามมิติของกระเพาะปัสสาวะในกรณีที่ 1 มีระยะห่างจากพื้นผิวแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง ตั้งแต่  $-8.63$  ถึง  $3.73$  มิลลิเมตร ในกรณีที่ 2 มีระยะห่างตั้งแต่  $-8.52$  ถึง  $3.73$  มิลลิเมตร และในกรณีที่ 3 มีระยะห่างตั้งแต่  $-3.36$  ถึง  $1.40$  มิลลิเมตร ซึ่งจะเห็นว่าผลลัพธ์ของแบบจำลองเรียนรู้เชิงลึกในกรณีที่ 3 มีระยะห่างจากผลลัพธ์ที่ควรเป็นน้อยที่สุด แสดงให้เห็นแบบจำลองโครงสร้างสามมิติของผลลัพธ์การทำนายของแบบจำลองเรียนรู้เชิงลึกมีความใกล้เคียงกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง


จากการวัดพบว่าแบบจำลองโครงสร้างสามมิติของกระดุกต้นขาข้างซ้ายในกรณีที่ 1 มีระยะห่างจากพื้นผิวแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง ตั้งแต่  $-29.00$  ถึง  $10.90$

มิลลิเมตร ในกรณีที่ 2 มีระยะห่างตั้งแต่ -13.00 ถึง 0.623 มิลลิเมตร ในกรณีที่ 3 มีระยะห่างตั้งแต่ -9.00 ถึง 1.29 มิลลิเมตร ในกรณีที่ 4 มีระยะห่างจากพื้นผิวแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง ตั้งแต่ -5.91 ถึง 1.72 มิลลิเมตร และในกรณีที่ 5 มีระยะห่างตั้งแต่ -6.72 ถึง 1.69 มิลลิเมตร ซึ่งแบบจำลองโครงสร้างสามมิติของผลลัพธ์การทำงานนัยของแบบจำลองเรียนรู้เชิงลึก ในกรณีที่ 4 มีระยะห่างที่ติดลบน้อยที่สุด แสดงให้เห็นว่าแบบจำลองโครงสร้างมีส่วนที่ขาดหายไปน้อยที่สุดเมื่อเทียบกับกรณีศึกษาทั้งหมดของกระดูกต้นขาข้างซ้าย ในขณะที่ค่าเป็นบวกซึ่งหมายถึงส่วนที่ทะลุออกจากพื้นผิวของผลลัพธ์ตามความเป็นจริงนั้นครอบคลุมบริเวณน้อยกว่าผลลัพธ์ในกรณีที่ 3 และใกล้เคียงกับกรณีศึกษาที่ 5


**ตารางที่ 4.5** ระยะห่างเฮาส์ดอร์ฟที่ระหว่างแบบจำลองโครงสร้างสามมิติของผลลัพธ์ที่ได้จากแบบจำลองเชิงลึกกับผลลัพธ์ตามความเป็นจริง

| กรณีศึกษาของกระเพาะปัสสาวะ      | ระยะห่างระหว่างพื้นผิว (หน่วยมิลลิเมตร) |                 |
|---------------------------------|---|-----------------|
|                                 | ค่าที่น้อยที่สุด                        | ค่าที่มากที่สุด |
| กรณีที่ 1                       | -8.63                                   | 3.73            |
| กรณีที่ 2                       | -8.52                                   | 3.73            |
| กรณีที่ 3                       | -3.36                                   | 1.40            |
| กรณีศึกษาของกระดูกต้นขาข้างซ้าย | ระยะห่างระหว่างพื้นผิว (หน่วยมิลลิเมตร) |                 |
|                                 | ค่าที่น้อยที่สุด                        | ค่าที่มากที่สุด |
| กรณีที่ 1                       | -29.00                                  | 10.90           |
| กรณีที่ 2                       | -13.00                                  | 0.623           |
| กรณีที่ 3                       | -9.00                                   | 1.29            |
| กรณีที่ 4                       | -5.91                                   | 1.72            |
| กรณีที่ 5                       | -6.72                                   | 1.69            |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.15 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระเพาะปัสสาวะ จากแบบจำลองเชิงลึกในกรณีที่ 1 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง




รูปที่ 4.16 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระเพาะปัสสาวะ จากแบบจำลองเชิงลึกในกรณีที่ 2 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.17 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระเพาะปัสสาวะ จากแบบจำลองเชิงลึกในกรณีที่ 3 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง




รูปที่ 4.18 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้าย จากแบบจำลองเชิงลึกในกรณีที่ 1 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.19 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้าย จากแบบจำลองเชิงลึกในกรณีที่ 2 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง




รูปที่ 4.20 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระดูกต้นขาข้างซ้าย จากแบบจำลองเชิงลึกในกรณีที่ 3 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.21 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระดุกต้นขาข้างซ้าย จากแบบจำลองเชิงลึกในกรณีที่ 4 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง



รูปที่ 4.22 ผังสีแสดงระยะห่างระหว่างพื้นผิวของแบบจำลองโครงสร้างสามมิติของกระดุกต้นขาข้างซ้าย จากแบบจำลองเชิงลึกในกรณีที่ 5 เทียบกับแบบจำลองโครงสร้างสามมิติของผลลัพธ์ตามความเป็นจริง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 5

# สรุปผลการวิจัย และข้อเสนอแนะ

การศึกษาและวิเคราะห์ผลการทดลองตามขั้นตอนการทดลองและการเก็บรวบรวมผลข้อมูลจากการทดลองกรณีต่าง ๆ ตามเงื่อนไขที่ได้วางไว้ตามวัตถุประสงค์และขอบเขตของการศึกษาวิจัยในครั้งนี้ สามารถสรุปผลการศึกษาวิจัยได้ดังนี้

### 5.1 สรุปผลการวิจัย

การศึกษานี้เกี่ยวข้องกับการแบ่งส่วนอวัยวะที่มีความเสี่ยงจากรังสีรักษาด้วยระบบการเรียนรู้เชิงลึกเพื่อลดเวลาในขั้นตอนการวางแผนการรักษา และนำผลการแบ่งส่วนที่ได้มาสร้างเป็นแบบจำลองโครงสร้างสามมิติซึ่งมีผลสรุปตามวัตถุประสงค์การวิจัยดังนี้

#### 5.1.1 สรุปผลการศึกษาระบบการประมวลผลภาพ ระบบการเรียนรู้เชิงลึก และโครงสร้างโครงข่ายมาประยุกต์ใช้เพื่อสร้างขั้นตอนวิธีสำหรับแบ่งส่วนอวัยวะที่มีความเสี่ยงจากรังสีรักษา

จากการศึกษาพบว่าการใช้กระบวนการประมวลผลภาพกับภาพถ่ายทางการแพทย์ก่อนเริ่มต้นการฝึกฝนโครงข่ายระบบการเรียนรู้เชิงลึกมีส่วนช่วยในการพัฒนาและเพิ่มประสิทธิภาพของโครงข่ายการเรียนรู้เชิงลึกสำหรับการแบ่งส่วนภาพ ทั้งกระบวนการเพิ่มคุณลักษณะที่ไม่ปรากฏในภาพดั้งเดิมแต่มิฉะนั้นสำคัญต่อภาพหรือเป้าหมายเข้าไป และการเพิ่มความแปรปรวนเพื่อให้โครงข่ายเป้าหมายมีความเด่นชัดและแยกออกจากบริเวณโดยรอบด้วยเทคนิคต่าง ๆ อย่างประเภทการปรับฮิสโทแกรมและการใช้ตัวกรองต่าง ๆ ล้วนทำให้ความถูกต้องของผลลัพธ์การทำนายเพิ่มขึ้น เพราะทำให้คุณลักษณะของชุดข้อมูลฝึกฝนมีความเหมาะสมและเพียงพอสำหรับแบบจำลองโครงข่ายนำไปใช้จดจำและเชื่อมโยงความสัมพันธ์ระหว่างข้อมูลนำเข้ากับผลลัพธ์ นอกจากนี้การลดข้อมูลไม่จำเป็นอย่างพื้นหลังในภาพถ่ายทางการแพทย์โดยยังคงรายละเอียดดั้งเดิมได้อย่างวิธีการครีโอสสามารถลดภาระด้านการคำนวณ ลดระยะเวลาการฝึกฝนโครงข่าย และยังช่วยเพิ่มความแม่นยำในการทำนายของโครงข่ายได้ โครงสร้างโครงข่ายประสาทเทียมเองก็มีหลากหลายรูปแบบ จากการศึกษาพบว่า โครงสร้างโครงข่ายสังวัตนาการแบบ U-Net แบบ 5 ชั้น โดยเริ่มต้นด้วยเคอร์เนลจำนวน 64 ตัว ให้ผลลัพธ์ที่เป็นที่น่าพึงพอใจสำหรับงานแบ่งส่วนกระเพาะปัสสาวะและกระดูกต้นขาข้างซ้าย

#### 5.1.2 สรุปผลการพัฒนาขั้นตอนวิธีสำหรับการแบ่งส่วนอวัยวะที่มีความเสี่ยงจากรังสีด้วยระบบการเรียนรู้เชิงลึก

จากการทดลองใช้เทคนิคประมวลผลภาพในขั้นตอนการเตรียมชุดข้อมูลล่วงหน้าพบว่าการใช้เทคนิควินโดวส์เลเวลลิง เทคนิคฮิสโทแกรมอีควอไลเซชัน การทำให้เรียบด้วยเกาส์เซียน และ

การครีโพร่วมกัน (กรณีที่ 3) เป็นขั้นตอนที่ดีที่สุดสำหรับการเตรียมชุดข้อมูลกระเพาะปัสสาวะที่ทำให้ได้ผลการประเมินแบบจำลองโครงข่ายการเรียนรู้เชิงลึกสูงถึง 95.15% สำหรับค่า DSC และ 91.10% สำหรับค่า IoU สอดคล้องกับสมมติฐานว่าการปรับปรุงคุณภาพของชุดข้อมูลโดยใช้กระบวนการประมวลผลภาพสามารถเพิ่มประสิทธิภาพให้กับการทำนายของแบบจำลองการเรียนรู้เชิงลึกได้ นอกจากนี้การทดลองยังแสดงให้เห็นว่าการลบข้อมูลศูนย์ (พื้นหลัง) ออกไปด้วยการครีโพร่วมเพิ่มประสิทธิภาพให้แก่แบบจำลองโครงข่ายการเรียนรู้เชิงลึกอย่างมาก ส่วนแบบจำลองโครงข่ายสำหรับการแบ่งส่วนกระดูกต้นขาข้างซ้ายพบว่าหากฝึกฝนด้วยชุดข้อมูลที่ผ่านกระบวนการครีโพร่วมกับการเสริมคุณลักษณะจากท่านอนของคนไข้ด้วยค่าสัมประสิทธิ์คุณลักษณะเท่ากับ 5 แทนท่านอนหงายและ 10 แทนท่านอนคว่ำ (กรณีที่ 4) จะให้ผลลัพธ์การแบ่งส่วนที่มีความแม่นยำสูงสุดด้วยค่า DSC เท่ากับ 88.25% และค่า IoU 80.85% การทดลองนี้นอกจากแสดงให้เห็นถึงผลกระทบด้านบวกของการเสริมคุณลักษณะซึ่งสอดคล้องกับทฤษฎีของโครงข่ายการถดถอยแบบพหุคูณและหลายตัวแปรแล้วยังทำให้สามารถสรุปได้อีกว่าค่าสัมประสิทธิ์ที่ใช้แทนคุณลักษณะก็มีอิทธิพลต่อประสิทธิภาพการแบ่งส่วนด้วยเช่นกัน

### 5.1.3 สรุปผลเสนอแนวทางการเพิ่มประสิทธิภาพให้กับโครงข่ายประสาทเทียมสำหรับแบ่งส่วนอวัยวะมีความเสี่ยงจากรังสีรักษา

จากการศึกษาและทดลองฝึกฝนแบบจำลองโครงข่ายการเรียนรู้เชิงลึกภายใต้เงื่อนไขที่แตกต่างกันสรุปได้ว่า การเพิ่มประสิทธิภาพการแบ่งส่วนให้กับแบบจำลองการเรียนรู้เชิงลึกสำหรับแบ่งส่วนอวัยวะสามารถทำได้ด้วยการเสริมคุณลักษณะภายนอกที่มีผลต่อการจำแนกเป้าหมายแต่ไม่ได้มีอยู่ในชุดข้อมูลดั้งเดิมเข้าไปเพื่อลดโอกาสที่แบบจำลองการเรียนรู้เชิงลึกจะสับสนกับวัตถุชนิดอื่นที่มีคุณลักษณะใกล้เคียงหรือเป็นประเภทเดียวกันจนนำไปสู่การทำนายผิดพลาด รวมถึงการลดขนาดข้อมูลด้วยการลบพื้นหลังสีดำที่บรรจุค่าศูนย์ออกและการปรับให้เป้าหมายโดดเด่นกว่าบริเวณโดยรอบ

### 5.1.4 สรุปผลการนำผลการแบ่งส่วนที่ได้มาสร้างเป็นแบบจำลองโครงสร้างสามมิติ

จากการนำผลลัพธ์การแบ่งส่วนที่ได้จากแบบจำลองการเรียนรู้เชิงลึกบนภาพสไลด์แต่ละสไลด์มาสร้างแบบจำลองโครงสร้างสามมิติขึ้นใหม่สามารถสรุปได้ว่า ขนาดและลำดับของภาพสไลด์มีผลต่อการสร้างโครงสร้างขึ้นใหม่จำเป็นต้องมีลำดับความสัมพันธ์ที่ถูกต้อง นอกจากนี้ต้องพิจารณาพารามิเตอร์ที่ตั้งตอนถ่ายภาพอย่างระยะห่างพิกเซล (Pixel Spacing) และความหนาของสไลด์ (Slice Thickness) ด้วยเพื่อให้ได้ขนาดความยาวและความหนาของแบบจำลองโครงสร้างสามมิติที่ใกล้เคียงกับความเป็นจริง จากการประเมินความคล้ายคลึงกับแบบจำลองผลลัพธ์ตามความเป็นจริงสามารถสรุปได้ว่า แบบจำลองโครงสร้างที่สร้างขึ้นจากผลลัพธ์ของแบบจำลองการเรียนรู้เชิงลึกกรณีที่ 3 ของกระเพาะปัสสาวะกับแบบจำลองกรณีที่ 4 ของกระดูกต้นขาข้างซ้ายมีความเหมือนที่สุดโดยแบบจำลองกระเพาะปัสสาวะมีค่า SAM อยู่ในช่วง 0.076 – 0.160 และค่า SSIM ในช่วง 0.698 –

0.839 ส่วนแบบจำลองกระดูกต้นขาข้างซ้ายมีค่า SAM อยู่ในช่วง 0.117 – 0.215 และค่า SSIM ในช่วง 0.701 – 0.732 ซึ่งการวัดระยะระหว่างพื้นผิวด้วยระยะทางเฮาส์ดอร์ฟฟ์ แบบจำลองจากทั้งสองกรณีมีส่วนที่ขาดหายไปน้อยที่สุดโดยหายไป 3.36 มิลลิเมตร ในแบบจำลองกระดูกเพาเปัสสวาระ และ 5.91 มิลลิเมตร ในแบบจำลองกระดูกต้นขาข้างซ้ายและมีส่วนที่เกินมาเล็กน้อยคิดเป็นระยะที่มากที่สุดเท่ากับ 1.4 มิลลิเมตร กับ 1.72 มิลลิเมตร ในแบบจำลองกระดูกเพาเปัสสวาระและกระดูกต้นขาข้างซ้าย ตามลำดับ

เมื่อเทียบกับงานวิจัยอื่นอย่างงานวิจัยของ Liu และทีมงาน [88] นำเสนอโครงข่ายประสาทเทียมแบบสังวัตนาการซึ่งดัดแปลงด้วยนวัตกรรมพีระมิด อิน พีระมิด (Pyramid in Pyramid : PiP) สำหรับการแบ่งส่วนกระดูกเพาเปัสสวาระ ใช้ภาพ MR ของผู้ป่วยโรคกระดูกพรุนจำนวน 47 คน ได้ค่าประสิทธิภาพในการแบ่งส่วน 88.74% สำหรับค่า DSC และในงานวิจัยของ Leger และทีมงาน [89] นำเสนอผลการวิจัยการแบ่งส่วนกระดูกเพาเปัสสวาระด้วยโครงข่ายประสาทเทียมสังวัตนาการสมบูรณ์แบบ U-Net ซึ่งร่วมกับโครงข่ายประสาทเทียมอีกตัวที่ถูกฝึกฝนกับชุดข้อมูลหลากหลายระยะห่างภายในสไลด์ด้วยชุดข้อมูลฝึกฝนจำนวน 179 คน ได้ค่า DSC เท่ากับ 91.90% และค่า IoU ได้เท่ากับ 86.10% ซึ่งโครงข่ายการเรียนรู้เชิงลึกที่สร้างขึ้นร่วมกับการใช้ขั้นตอนการเตรียมการในการศึกษาวิจัยนี้ให้ผลประเมินประสิทธิภาพที่มากกว่า

ส่วนทางด้านงานวิจัยที่เกี่ยวข้องกับการแบ่งส่วนกระดูกต้นขาข้างซ้ายอย่างในงานวิจัยของ Han Zhou และทีมงาน [90] ใช้โครงข่ายประสาทเทียมที่มีพื้นฐานโครงสร้างคล้ายคลึง U-Net ฝึกฝนด้วยชุดข้อมูลเอกซเรย์คอมพิวเตอร์จากคนไข้ 33 คน ได้ผลประเมินประสิทธิภาพเท่ากับ 43.00% และ 40.00% สำหรับค่า DSC และค่า IoU ตามลำดับ และงานวิจัยของ Boyuan Peng และทีมงาน [91] นำเสนอการดัดแปลงโครงข่ายประสาทเทียมแบบ U-Net ที่เรียกว่า Mobilenet-Unet ได้ผลลัพธ์ประสิทธิภาพเท่ากับ 87.20% สำหรับค่า DSC และ 77.70% สำหรับค่า IoU ซึ่งผลจากโครงข่ายประสาทเทียมที่สร้างขึ้นร่วมกับการเสริมคุณลักษณะนั้นให้ผลลัพธ์ที่มากกว่า

## 5.2 ข้อเสนอแนะ

1. ระบบการเรียนรู้เชิงลึกมีความสามารถในการพัฒนาตัวเองได้จากข้อมูลที่ถูกป้อน ในงานวิจัยนี้ใช้ข้อมูลของคนไข้ 120 คน ซึ่งยังไม่ถือว่ามากและยังไม่เพียงพอที่จะครอบคลุมทุกเคสที่เกิดขึ้นในโลกความเป็นจริงได้ ดังนั้นการเพิ่มจำนวนข้อมูลฝึกฝนมากกว่านี้สามารถพัฒนาระบบให้มีความแม่นยำเพิ่มขึ้น

2. รูปแบบการเสริมคุณสมบัติของงานวิจัยนี้นำเสนอเพียงหนึ่งรูปแบบ อีกทั้งยังดำเนินการกับอวัยวะเป้าหมายที่เป็นกระดูกต้นขาข้างซ้ายเท่านั้นจึงสามารถพัฒนาต่อยอดการเสริมคุณลักษณะรูปแบบอื่นหรือเพิ่มจำนวนคุณลักษณะมากขึ้นเพื่อเพิ่มประสิทธิภาพของแบบจำลองโครงข่ายการเรียนรู้เชิงลึกหรือแบบจำลองโครงข่ายประสาทเทียมในอนาคตได้ รวมทั้งปรับใช้กับอวัยวะเป้าหมาย

ชนิดอื่น ๆ

3. งานวิจัยนี้ฝึกฝนเพียงโครงข่ายประสาทเทียมสังวัตนาการแบบ U-Net ยังสามารถดัดแปลงหรือพัฒนาต่อยอดแบบจำลองโครงข่ายให้สามารถทำงานได้ดียิ่งขึ้นภายใต้เงื่อนไขจำกัดที่น้อยลงและมีความแม่นยำมากขึ้นได้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## เอกสารอ้างอิง

- [1] Delaney G. P. and Barton, M. B. “Evidence-based estimates of the demand for radiotherapy.”, **Clin. Oncol.**, vol. 27 no. 2, 2015. pp. 70-76.
- [2] Barrett A., Morris S., Dobbs J. and Roques T., **Practical radiotherapy planning**. United States : CRC Press, 2009.
- [3] Lu L., Zheng Y. Carneiro G. and Yang, L. **Deep Learning and Convolutional Neural Networks for Medical Image Computing: Precision Medicine, High Performance and Large-Scale Datasets**. Switzerland : Springer International Publishing, 2017.
- [4] Lu L., Wang X., Carneiro G. and Yang, L. **Deep learning and convolutional neural networks for medical imaging and clinical informatics**. Germany: Springer International Publishing, 2019.
- [5] Abdou, M. A. (2022). “Literature review: Efficient deep neural networks techniques for medical image analysis.”, **Neural. Comput. Appl.**, Vol.34 no.8, 2022. pp. 5791-5812
- [6] William G. Bradley “History of Medical Imaging.” **Proceedings of the American Philosophical Society.**, Vol. 152 no. 3, Sep. 2008. pp. 349-361
- [7] Krishna Paudel. “**Stitching of X-ray Images.**” Ph.D. Thesis of Institutionen för informationsteknologi, Department of Information Technology, Uppsala universitet. 2012
- [8] Bushberg J. T., Seibert J. A., Leidholdt E. M. Jr., Boone J. M. **The essential physics of medical imaging**. 2nd Edition. Lippincott Williams & Wilkins, Philadelphia. 2002.
- [9] Seibert JA. “X-ray imaging physics for nuclear medicine technologists. Part 1: Basic principles of x-ray production.” **J Nucl Med Technol.**, vol. 32 no. 3, Sep. 2004. pp. 139-147
- [10] Ministry of the Environment Government of Japan. **BOOKLET to Provide Basic Information Regarding Health Effects of Radiation**. 2019
- [11] Krzysztof Iniewski. **Medical imaging Principles, detectors, and electronics**.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

New Jersey : John Wiley & Sons, Inc. 2009

[12] Prokop, Mathias, Michael Galanski, A. van der Molen and Cornelia Schaefer-Prokop. "Spiral and multislice computed tomography of the body." **Thieme.**, vol 181 no. 6, Dec. 2003.

[13] Krestel E. **Imaging Systems for Medical Diagnostics.** Berlin : Siemens AG. 1990.

[14] Dance D.R., Christofides S., Maidment A.D.A, McLean I.D. and Ng K.H. **Diagnostic radiology physics: A handbook for teachers and students. endorsed by: American association of physicists in medicine, asia-oceania federation of organizations for medical physics, european federation of organisations for medical physics.** Vienna : International Atomic Energy Agency, 2014.

[15] Chougule V.N., Mulay, Arati and Ahuja B.B. "Clinical case study: spine modeling for minimum invasive spine surgeries (MISS) using rapid prototyping." **Bone (CT)**, vol. 226, 2018. pp. 3071

[16] Basmaci I. and Sefik E. "A novel use of attenuation value (Hounsfield unit) in non-contrast CT: diagnosis of pyonephrosis in obstructed systems." **Int. Urol. Nephrol.** Vol. 52, 2020, pp. 9-14.

[17] Basmaci I., Bozkurt I. H., Editors. "A novel use of attenuation value (Hounsfield unit) in non-contrast CT: diagnosis of urinary tract infection." **Int. Urol. Nephrol.**, vol. 50, 2018, pp. 1557-1562.

[18] Mizumura N., Okumura, S., Toyoda S., Editors. "Non-traumatic bladder rupture showing less than 10 Hounsfield units of ascites." **Acute Medicine & Surgery**, vol 4 no. 2, 2017, pp. 184-189.

[19] Seeram, E. **Computed Tomography-E-Book: Physical Principles, Patient Care, Clinical Applications, and Quality Control.** 4th Edition. Missouri : Elsevier Inc. 2016.

[20] Goldman Lee W. "Principles of CT and CT Technology.", **J. Nucl. Med. Technol.**, vol.35 no.3, 2007. Pp.115-128.

[21] Tang K, Wang L, Li R, Lin J, Zheng X and Cao G. "Effect of low tube voltage on image quality, radiation dose, and low-contrast detectability at abdominal

- multidetector CT: phantom study.” **Biomed Res. Int.**, vol.2012, 2012. pp. 1-6.
- [22] El Mansouri M., Choukri A., Talbi M. and Hakam O.K. “Impact of tube voltage on radiation dose (CTDI) and image quality at chest CT examination.”, **At. Indones.**, vol.47 no.2, 2021. pp.105-109.
- [23] Thrower S. L., Al Feghali K. A. and Editors. “The effect of slice thickness on contours of brain metastases for stereotactic radiosurgery.”, **Adv. Radiat. Oncol.**, vol.6 no. 4, 2021. pp. 100708..
- [24] Zarb F., Rainford L. and McEntee M. F. “Developing optimized CT scan protocols: Phantom measurements of image quality.”, **Radiography.**, vol.17 no.2, 2011, pp.109-114.
- [25] Ian D. McLean and Jan Martensen. “Chapter 2 - Specialized Imaging.”, **Clinical Imaging (Third Edition)**, December, 2014. pp. 44-78.
- [26] Bibb R., Eggbeer D. and Paterson A. “2-Medical imaging.”, **Medical Modelling (Second Edition) Woodhead Publishing.**, 2015. pp.7-34
- [27] Larobina M. and Murino L. “Medical image file formats.”, **J. Digit. Imaging.**, vol.27, 2014. pp.200-206
- [28] Fichtinger G., Rueckert D. and Zhou S. K. (Eds.). **Handbook of Medical Image Computing and Computer Assisted Intervention.** Cambridge : Elsevier Inc. 2020.
- [29] Bc. Martin Moučka. “**Semi-automatic tools for image segmentation,**” MS. Thesis of Masaryk University. 2018
- [30] Apivanichkul K., Phasukkit P., Dankulchai P., Sittiwong W. and Jitwatcharakomol T. “Enhanced Deep-Learning-Based Automatic Left-Femur Segmentation Scheme with Attribute Augmentation.”, **Sensors**, vol. 23 no.12, 2023. pp.5720
- [31] Pham D. L., Xu C. and Prince, J. L. “Current methods in medical image segmentation.”, **Annu. Rev. Biomed. Eng.**, vol.2 no.1, 2000, pp. 315-337
- [32] Yu Ying, Wang Chunping, Editors. “Techniques and challenges of image segmentation: A review.”, **Electronics**, vol.12 no.5, 2023. pp.1199
- [33] Sonali Satonkar, Suhas Satonkar, Dr. Ulhas Patki and Dr. Ajay Kurhe. “Image

Segmentation Technique: A Systematic Literature Review.”, **Int. J. Eng. Res. Technol.**, Vol.12 no.01, January, 2023. pp. 180-185

[34] Vincent O. R. and Folorunso O. “A descriptive algorithm for sobel image edge detection.”, **Proceedings of informing science & IT education conference (InSITE)**., vol. 40, June, 2009. pp. 97-107

[35] Dharampal V. M. “Methods of image edge detection: A review.”, **J. Electr. Electron. Syst.**, vol.4 no.2, 2015. pp. 1-5

[36] Gonzalez R.C. and Woods R.E. “Chapter 3 Intensity Transformations and Spatial Filtering”, **Digital Image Processing**, 4th ed. Pearson Education, UK, 2018. pp. 133–217.

[37] Bora, D. J. “Chapter 9 Contrast improvement of medical images using advanced fuzzy logic-based technique.”, **Advanced Machine Vision Paradigms for Medical Image Analysis**, Cambridge : Academic Press, 2021. pp. 229-257.

[38] Szeliski R. **Computer vision: algorithms and applications**. 1<sup>st</sup> ed. New York : Springer-Verlag London Limited. 2010.

[39] Solomon C. and Breckon T. **Fundamentals of Digital Image Processing: A practical approach with examples in Matlab**. New Jersey : John Wiley & Sons, Inc. 2011

[40] Tyagi V. **Understanding digital image processing**. New York : Taylor & Francis Group, LLC. 2018.

[41] Innolitics. “**Window Width Attribute.**” [Online]. Available : <https://dicom.innolitics.com/ciods/us-image/voi-lut/00281051>.

[42] Gonzalez R.C. and Woods R.E. “Chapter 9 Morphological Image Processing”, **Digital Image Processing**, 4th ed. Pearson Education, UK, 2018. pp. 635–698.

[43] Huang X. and Tang Z. “Staircase Detection Algorithm Based on Projection-Histogram.”, **IMCEC 2018.**, May, 2018. pp. 1130-1133

[44] Tuba E. and Bacanin N. “An algorithm for handwritten digit recognition using projection histograms and SVM classifier.”, **TELFOR 2015**, November, 2015. pp. 464-

467

[45] Vezzani R., Baltieri D. and Cucchiara R. “HMM based action recognition with projection histogram features.”, **Recognizing Patterns in Signals, Speech, Images and Videos: ICPR 2010 Contests**, August, 2010. pp. 286-293

[46] Josh Patterson and Adam Gibson. “Chapter 2: Foundations of Neural Networks and Deep Learning.”, **Deep learning: A practitioner's approach.**, Sebastopol : O’Reilly Media, Inc. 2017. pp.41-80

[47] Alexopoulos E. C. “Introduction to multivariate regression analysis.”, **Hippokratia**, vol.14 no.Suppl 1, 2010. pp.23

[48] Nugus S. “Regression Analysis.”, **Financial Planning Using Excel: Forecasting, Planning and Budgeting Techniques**, Washington : CIMA Publishing, 2009. pp. 37-52

[49] Charu C. A. **Neural networks and deep learning: a textbook**. New York : Springer International Publishing AG. 2018.

[50] รศ.ดร. ปริญญา สงวนสัตย์. “บทที่ 6 โครงข่ายประสาทเทียม (Artificial Neural Networks)” **Artificial Intelligence with Machine Learning, AI สร้างได้ด้วยแมชชีนเลิร์นนิง**. นนทบุรี: ไอทีซี พรีเมียร์.2562 (2019). หน้า.101-144

[51] Adrian R. **Deep learning for computer vision with python**. 1st Edition. Adrian Rosebrock, PyImageSearch.com. 2017

[52] Preim B. and Botha C. P. “Chapter 6 - Surface Rendering.”, **Visual Computing for Medicine (Second Edition) Theory, Algorithms, and Applications.**, US: Morgan Kaufmann. 2014, pp. 229-267

[53] Lorensen W. E. and Cline H. E. “Marching cubes: A high resolution 3D surface construction algorithm.”. **Seminal graphics: pioneering efforts that shaped the field.**, New York : ACM SIGGRAPH, 1998. pp. 347-353

[54] Vollmer J., Mencl R. and Mueller H. “Improved laplacian smoothing of noisy surface meshes.”, **Comput. Graph. Forum.**, Vol. 18 No. 3, 1999. pp. 131-138

[55] สุเมธจตุทาจันท์ และ สมพร ปิ่นโกษา. “เปรียบเทียบผลลัพธ์ของการอนุมัตินิรนัยด้วย 3 แบบจำลองของระเบียบวิธี Machine Learning โดยใช้โปรแกรมอาร์” **การประชุมนำเสนอ**

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ผลงานวิจัยบัณฑิตศึกษาระดับชาติ ครั้งที่ 16, สิงหาคม 2564. หน้า 189-199

[56] Taha A. A. and Hanbury A. “Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool.”, **BMC Med. Imaging.**, Vol. 15 no.29, 2015, pp. 1–28

[57] Müller D., Soto-Rey I. and Kramer F. “Towards a guideline for evaluation metrics in medical image segmentation.”, **BMC Res. Notes.**, vol. 15 no.1, 2022, pp. 1-8

[58] Kruse F. A., Lefkoff A., Boardman J., Heidebrecht K., Shapiro A., Barloon P. and Goetz A. “The spectral image processing system (SIPS)—interactive visualization and analysis of imaging spectrometer data.”, **Remote Sens. Environ.**, vol.44 no.2-3, 1993, pp.145-163

[59] Wang Z., Bovik A. C., Sheikh H. R. and Simoncelli E. P. “Image quality assessment: from error visibility to structural similarity.”, **IEEE. Trans. Image. Process.**, vol.13 no.4, 2004. pp.600-612

[60] McFadden S. B. and Ward P. A. “Selecting the proper window for SSIM.”, **Image Quality and System Performance IX.**, vol.8293, 2012. pp 90-99

[61] Prados F., Ashburner J., Blaiotta C., Brosch T., Editors. “Spinal cord grey matter segmentation challenge.”, **Neuroimage**, vol.152, 2017. pp.312-329

[62] Cha K.H., Hadjiiski L., Samala R.K., Chan H.P., Caoili E.M. and Cohan R.H. “Urinary bladder segmentation in CT urography using deep-learning convolutional neural network and level sets.”, **Med. Phys.**, vol.43, 2016. pp.1882–1896.

[63] Kim Y.J., Lee S.H., Park C.M. and Kim K.G. “Evaluation of semi-automatic segmentation methods for persistent ground glass nodules on thin-section CT scans.”, **Healthc. Inform. Res.** Vol.22, 2016. pp.305–315.

[64] Starmans M.P., van der Voort S.R., Tovar J.M.C., Veenland J.F., Klein S., Niessen W.J. “Radiomics: Data mining using quantitative medical image features.”, **Handbook of Medical Image Computing and Computer Assisted Intervention**; Cambridge : Elsevier Inc. 2020. pp. 429–456

[65] Sakinis T., Milletari F., Roth H., Korfiatis P., Kostandy P., Philbrick K., Akkus Z., Xu Z., Xu D. and Erickson B.J. “Interactive segmentation of medical images through fully

convolutional neural networks.”, **arXiv preprint arXiv:1903.08205**, 2019.

[66] Islam M., Khan K.N. and Khan M.S. “Evaluation of Preprocessing Techniques for U-Net Based Automated Liver Segmentation.”, **the 2021 International Conference on Artificial Intelligence (ICAI)**, 2021. pp. 187–192.

[67] Duque P., Cuadra J. Jiménez E. and Rincón-Zamorano M. “In Data preprocessing for automatic WMH segmentation with FCNNs.” **8th International Work-Conference on the Interplay Between Natural and Artificial Computation (IWINAC 2019)**, June, 2019. pp. 452–460.

[68] Ross-Howe S. and Tizhoosh H.R. “The effects of image pre-and post-processing, wavelet decomposition, and local binary patterns on U-nets for skin lesion segmentation.”, **2018 International Joint Conference on Neural Networks (IJCNN)**, July, 2018. pp. 1–8.

[69] De Raad K., van Garderen K.A., Smits M., van der Voort S.R., Incekara F., Oei E., Hirvasniemi J., Klein S. and Starmans M.P. “The effect of preprocessing on convolutional neural networks for medical image segmentation.”, **2021 IEEE 18th International Symposium on Biomedical Imaging (ISBI)**, April, 2021. pp. 655–658.

[70] Gibson E., Giganti F., Hu Y., Bonmati E., Bandula S., Gurusamy K., Davidson B., Pereira S.P., Clarkson M.J. and Barratt “D.C. Automatic multi-organ segmentation on abdominal CT with dense V-networks.”, **IEEE Trans. Med. Imaging**, vol.37, 2018. pp. 1822–1834.

[71] Balagopal A., Kazemifar S., Nguyen D., Lin M.H., Hannan R., Owrangi A. and Jiang S. “Fully automated organ segmentation in male pelvic CT images.”, **Phys. Med. Biol.**, vol.63 no.24, 2018. pp. 245015. <https://doi.org/10.1088/1361-6560/aaf11c>.

[72] Pal D., Reddy P.B. and Roy, S. “Attention UW-Net: A fully connected model for automatic segmentation and annotation of chest X-ray.”, **Comput. Biol. Med.**, vol.150, 2022. pp.106083. <https://doi.org/10.1016/j.combiomed.2022.106083>.

[73] Paing M. P., Tungjitkusolmun, S., Bui T. H., Visitsattapongse, S. and Pintavirooj, C. “Automated segmentation of infarct lesions in T1-weighted MRI scans using variational mode decomposition and deep learning.”, **Sensors**, vol. 21 no. 6, 2021’ pp. 1952

- [74] Chen W., Wei H., Peng S., Sun J., Qiao X. and Liu, B. “HSN: hybrid segmentation network for small cell lung cancer segmentation.”, **IEEE Access**, vol. 7, 2019. pp.75591-75603
- [75] Yu C., Wang J., Peng C., Gao C., Yu G. and N. Sang, “BiSeNet: Bilateral segmentation network for real-time semantic segmentation,” **European Conference on Computer Vision**, 2018. pp. 325–341.
- [76] Hatamizadeh A., Sengupta D. and D. Terzopoulos, “End-to-end trainable deep active contour models for automated image segmentation: Delineating buildings in aerial imagery,” **European Conference on Computer Vision**, 2020. pp. 730–746.
- [77] Song Y., Huang Z., Shen C., Shi H. and Lange D. A. “Deep learning-based automated image segmentation for concrete petrographic analysis,” **Cement and Concrete Research**, vol. 135, 2020. pp. 106118,
- [78] Valanarasu J. M. J. and Patel V. M. “Unext: Mlp-based rapid medical image segmentation network,” **International Conference on Medical Image Computing and Computer-Assisted Intervention**, 2022. pp. 23-33.
- [79] Chicco D. “Ten quick tips for machine learning in computational biology.”, **BioData Min**, vol.10 no.1, 2017. pp. 35. <https://doi.org/10.1186/s13040-017-0155-3>.
- [80] Yang S., Wang Y., Chen K., Zeng W. and Fei Z. “Attribute-aware feature encoding for object recognition and segmentation.”, **IEEE Trans. Multimed.**, vol.24, 2021. pp. 3611–3623. <https://doi.org/10.1109/TMM.2021.3103605>.
- [81] Sulistiyo M.D., Kawanishi Y., Deguchi D., Ide I., Hirayama T. and Murase H. “Performance boost of attribute-aware semantic segmentation via data augmentation for driver assistance.”, **Proceedings of the 2020 8th International Conference on Information and Communication Technology (ICICT)**, June, 2020. pp. 1–6.
- [82] Wang R. and Zheng G. “CyCMIS: Cycle-consistent Cross-domain Medical Image Segmentation via diverse image augmentation.”, **Med. Image Anal.**, vol.76, 2022. pp. 102328. <https://doi.org/10.1016/j.media.2021.102328>.
- [83] Jahanifar M., Tajeddin N.Z., Koohbanani N.A., Gooya A. and Rajpoot N. “Segmentation of skin lesions and their attributes using multi-scale convolutional

neural networks and domain specific augmentations.”, **arXiv preprint arXiv:1809.10243**, 2018.

[84] Khan A.R., Khan S., Harouni M., Abbasi R., Iqbal S. and Mehmood Z. “Brain tumor segmentation using K-means clustering and deep learning with synthetic data augmentation for classification.”, **Microsc. Res. Tech.**, vol.84, 2021. pp. 1389–1399.

[85] Noguchi S., Nishio M., Yakami M., Nakagomi K. and Togashi K. “Bone segmentation on whole-body CT using convolutional neural network with novel data augmentation techniques.”, **Comput. Biol. Med.**, vol.121, 2020. pp. 103767.

[86] Dey S. “Chapter 2 Image Enhancement.”, **Python image processing cookbook: over 60 recipes to help you perform complex image processing and computer vision tasks with ease**, Packt Publishing Ltd., UK, 2020. pp. 39-79

[87] Melisa Sia. “CT.” [Online]. Available : <https://www.radiologycafe.com/radiology-basics/imaging-modalities/ct-overview/>

[88] J. Liu, L. Liu and B. Xu, Editors. “Bladder cancer multi-class segmentation in MRI with Pyramid-In-Pyramid network.”, **2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019)**, 2019. pp. 28–31

[89] L'éger J., Brion E., Javaid U., Lee J., De Vleeschouwer C. and Macq B., “Contour propagation in CT scans with convolutional neural networks, in: International Conference on Advanced Concepts for Intelligent Vision Systems.”, **Advanced Concepts for Intelligent Vision Systems: 19th International Conference (ACIVS 2018)**, September, 2018. pp. 380–391

[90] Zhou Han and Editors. “A deep learning based automatic segmentation approach for anatomical structures in intensity modulation radiotherapy.”, **Math. Biosci. Eng.**, vol.18 no.6, 2021. pp.7506-7524

[91] Peng Boyuan and Editors. “Semantic segmentation of femur bone from MRI images of patients with hematologic malignancies.”, **2020 IEEE Region 10 Conference (Tencon)**, 2020. pp. 1090-1094

## ประวัติผู้เขียน

|                  |   |
|------------------|---|
| ชื่อ-นามสกุล     | นางสาวกมลฉัตร อภิวิชัยกุล   |
| วัน เดือน ปีเกิด | 22 พฤศจิกายน 2536   |
| ที่อยู่          | 100/113 ซอย 5/2 หมู่บ้านชัยพฤกษ์1 ถนนคุ้มเกล้า แขวงลาปลาทิว เขต<br>ลาดกระบัง กรุงเทพฯ 10520   |
| ประวัติการศึกษา  | 2559 วิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมชีวการแพทย์<br>สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง<br>2560 วิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมชีวการแพทย์<br>สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง |
| ผลงานวิจัย       |   |
| พ.ศ. 2558        | Support Back For Lower Back Pain By Passive Mechanism<br>(2015 International Workshop on Smart Info-Media Systems in<br>Asia) (SISA 2015)   |
| พ.ศ. 2559        | Physiological Analysis of Back Muscles during Handling Posture<br>Using ANSYS Simulation<br>(2016 International Symposium on Multimedia and<br>Communication Technology) (ISMAT 2016)                       |
| พ.ศ. 2559        | Investigation of Back Support during Body Movement as<br>Posture and Non-Movement<br>(2016 International Workshop on Smart Info-Media Systems in<br>Asia) (SISA 2016)                                       |
| พ.ศ. 2564        | Performance Comparison of Deep Learning Approach for<br>Automatic CT Image Segmentation by Using Window Leveling<br>(The 13th Biomedical Engineering International Conference)<br>(BMEiCON-2021)            |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- พ.ศ. 2565 CT Dataset Enhancement using Additional Feature Insertion for Automatic Femur Segmentation Model Based on Deep Learning (The 14th Biomedical Engineering International Conference) (BMEiCON-2022)
- พ.ศ. 2565 The Performance Improvement of Deep Learning in Automatic Femur Segmentation using External Feature Addition (The 3rd International Conference on Science and. Technology of Emerging Materials 2022) (STEMa2022)



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้