

การจำแนกภาพเอ็มอาร์ไอของสมองโดยใช้ขั้นตอนวิธีการเรียนรู้เชิงลึก

MRI BRAIN SCAN CLASSIFICATION USING DEEP LEARNING



เกียรติชัย เลิศรุ่งวิเชียร  
ชวาลวุฒิ นุชประเสริฐ  
ปกปกรณ์ กลิ่นกาเซิน

ปัญหาพิเศษนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
ปริญญาวิทยาศาสตรบัณฑิต (วิทยาการคอมพิวเตอร์)  
ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

ปีการศึกษา 2560

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# MRI BRAIN SCAN CLASSIFICATION USING DEEP LEARNING



KHITICHAJ LERTRUNGWICHEAN  
CHAWANWUT NUCHPRASERT  
POKPAKORN KLINKASEN

A SPECIAL PROBLEM SUBMITTED IN PARTIAL FULFILLMENT OF  
THE REQUIREMENT FOR  
THE DEGREE OF BACHELOR OF SCIENCE  
(COMPUTER SCIENCE)

DEPARTMENT OF COMPUTER SCIENCE, FACULTY OF SCIENCE  
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

ACADEMIC YEAR 2017




เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อปัญหาพิเศษ การจำแนกภาพเอ็มอาร์ไอของสมองโดยใช้วิธีการเรียนรู้เชิงลึก  
MRI Brain Scan Classification Using Deep Learning

ชื่อนักศึกษา นายเกียรติชัย เลิศรุ่งวิเชียร รหัสนักศึกษา 57050186  
นายชวาลวุฒิ นุชประเสริฐ รหัสนักศึกษา 57050205  
นายปกปกรณ์ กลิ่นกาเซ็น รหัสนักศึกษา 57050214

ปริญญา วิทยาศาสตร์บัณฑิต (วิทยาการคอมพิวเตอร์)  
ภาควิชา วิทยาการคอมพิวเตอร์  
คณะ วิทยาศาสตร์  
มหาวิทยาลัย สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง (สจล.)  
ปีการศึกษา 2560  
อาจารย์ที่ปรึกษา ดร.อัคเดช อุดมชัยพร

คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง (สจล.)  
อนุมัติให้ปัญหาพิเศษนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต  
(วิทยาการคอมพิวเตอร์) ประจำปีการศึกษา 2560

คณะกรรมการสอบ	ลายมือชื่อ
ผศ.สิริลักษณ์ อนันตสถิตย์สิน ประธานกรรมการ	
ผศ. อีระ ศิริธีรากล กรรมการ	
ดร.อัคเดช อุดมชัยพร อาจารย์ที่ปรึกษา	

ลิขสิทธิของคณะวิทยาศาสตร์  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อปัญหาพิเศษ	การจำแนกภาพเอ็มอาร์ไอของสมองโดยใช้วิธีการเรียนรู้เชิงลึก			
ชื่อนักศึกษา	นายเกียรติชัย	เลิศรุ่งวิเชียร	รหัสนักศึกษา	57050186
	นายชวาลวุฒิ	นุชประเสริฐ	รหัสนักศึกษา	57050205
	นายปกปกรณ์	กลิ่นกาเซ็น	รหัสนักศึกษา	57050214
ปริญญา	วิทยาศาสตร์บัณฑิต (วิทยาการคอมพิวเตอร์)			
ภาควิชา	วิทยาการคอมพิวเตอร์			
คณะ	วิทยาศาสตร์			
มหาวิทยาลัย	สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง (สจล.)			
ปีการศึกษา	2560			
อาจารย์ที่ปรึกษา	ดร.อัคเดช อุดมชัยพร			

### บทคัดย่อ

ปัญหาพิเศษนี้นำเสนอวิธีการจำแนกภาพเอ็มอาร์ไอของสมองโดยใช้วิธีการเรียนรู้เชิงลึก รวมไปถึงการแบ่งส่วนโพรงสมองด้านข้าง (Lateral Ventricles) จากภาพเอ็มอาร์ไอสามมิติซึ่งชุดข้อมูลที่นำมาทดลองประกอบไปด้วยภาพของผู้ที่สุขภาพดี นักดนตรี และผู้ป่วยโรคลมชัก โดยใช้เทคนิคการกำหนดค่าขีดแบ่ง (Thresholding) ร่วมกับขั้นตอนวิธีแอกทีฟคอนทัวร์โมเดล (Active Contour Model) เพื่อระบุตำแหน่งของโพรงสมองด้านข้าง และจัดเก็บในรูปแบบภาพสามมิติ หลังจากนั้นใช้วิธีการเรียนรู้เชิงลึกโดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชันนอลเชิงลึกสำหรับภาพสามมิติเพื่อใช้ในการจำแนก (i) ผู้ที่เป็นโรคลมชักและไม่เป็นโรคลมชัก และ (ii) ผู้ที่เป็นนักดนตรีและผู้ที่ไม่เป็นนักดนตรี สำหรับการทดลองเปรียบเทียบเทคนิควิธีการเรียนรู้เชิงลึกโดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชันนอลเชิงลึกด้วยสถาปัตยกรรม VoxNet และ 3D NIN FC (3-D Network in Network Full Connected) ผลปรากฏว่าสถาปัตยกรรม VoxNet และ 3D NIN FC ให้ผลลัพธ์ไม่แตกต่างกันอย่างมีนัยสำคัญในแง่ของความแม่นยำสำหรับการจำแนกโรคลมชัก ส่วนการจำแนกนักดนตรี VoxNet ให้ผลลัพธ์ที่สูงกว่า 3D NIN FC ในแง่ของความแม่นยำ และให้ผลลัพธ์ที่ดีกว่าในแง่ของเวลาที่ใช้ในการประมวลผลอีกด้วย งานวิจัยนี้ สามารถนำไปช่วยวินิจฉัยทางการแพทย์ เช่น การจำแนกหรือการตรวจหาร่องรอยโรคอื่น ๆ เป็นต้น

**คำสำคัญ:** ภาพเอ็มอาร์ไอสามมิติ การแบ่งส่วนภาพ โพรงสมองด้านข้าง การจำแนกภาพ โครงข่ายประสาทเทียมแบบคอนโวลูชันนอลเชิงลึก

<b>Title</b>	MRI Brain Scan Classification Using Deep Learning	
<b>Students</b>	Mr.Khitichai Lertrungwichean	Student ID 57050186
	Mr.Chawanwut Nuchprasert	Student ID 57050205
	Mr.Pokpakorn Klinkasen	Student ID 57050214
<b>Degree</b>	Bachelor of Science (Computer Science)	
<b>Department</b>	Computer Science	
<b>Faculty</b>	Science	
<b>University</b>	King Mongkut's Institute of Technology Ladkrabang (KMITL)	
<b>Academic Year</b>	2017	
<b>Advisor</b>	Dr.Akadej Udomchaiporn	

### Abstract

This special topic proposes MRI brain scan classification using Deep Learning method. The segmentation of the lateral ventricles from 3D MRI scan using Thresholding and Active Contour techniques is also presented. The lateral ventricles is stored as 3D point cloud and then classified using two Convolutional Neural Network (CNN) models: (i) VoxNet and (ii) 3-D Network in Network Full Connected (3D NIN FC). The experimentation is conducted using two datasets: (i) Epilepsy and Non-epilepsy and (ii) Musician and Non-musician. The experimental results indicate that both VoxNet and 3D NIN FC perform excellently for Epilepsy dataset but VoxNet performs slightly better for Musician dataset in terms of both effectiveness and efficiency. The contribution of the research is that, using the proposed approach, some medical conditions can be analyzed and classified without specific knowledge from medical people.

**Keywords:** 3-D MRI scan image; Image Segmentation; Lateral Ventricles; Image Classification; Convolutional Neural Network

## กิตติกรรมประกาศ

การจัดทำปัญหาพิเศษเรื่องการจำแนกภาพเอ็มอาร์ไอของสมองโดยใช้ขั้นตอนวิธีการเรียนรู้เชิงลึกนี้สำเร็จลุล่วงไปได้ด้วยดี คณะผู้จัดทำต้องขอขอบพระคุณอาจารย์ที่ปรึกษา ดร.อัคเดช อุดมชัยพร ที่ช่วยให้คำปรึกษาและคำแนะนำที่ดีแก่คณะผู้จัดทำในการพัฒนาปรับปรุงปัญหาพิเศษนี้

ขอขอบพระคุณอาจารย์ผู้ควบคุมการสอบปัญหาพิเศษ ผศ.ศิริลักษณ์ อนันตสถิตย์สิน และ ผศ.ดร.ธีระ ศิริธีรากลุฑ ที่มีส่วนช่วยในการตรวจสอบ และให้คำแนะนำ ทำให้ปัญหาพิเศษนี้มีความสมบูรณ์มากยิ่งขึ้น

ขอขอบพระคุณสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบังที่มอบโอกาสให้ได้เข้าศึกษาในสถาบันแห่งนี้ทำให้ได้พบกับคณาจารย์และบุคลากรที่มีศักยภาพ ในการช่วยพัฒนาทักษะ และมอบความรู้ให้แก่นักศึกษา

เกียรติชัย เลิศรุ่งวิเชียร  
ชวาสุฒิ นุชประเสริฐ  
ปกปกรณ กлінняาเซ็น

# สารบัญ

	หน้า
บทคัดย่อภาษาไทย .....	ก
บทคัดย่อภาษาอังกฤษ .....	ข
กิตติกรรมประกาศ .....	ค
สารบัญ .....	ง
สารบัญตาราง .....	ฉ
สารบัญภาพ .....	ช
<b>บทที่ 1 บทนำ</b> .....	<b>1</b>
1.1 ความเป็นมาและความสำคัญของปัญหา .....	1
1.2 วัตถุประสงค์ .....	1
1.3 ขอบเขตการศึกษา .....	1
1.4 ประโยชน์ที่คาดว่าจะได้รับ .....	2
1.5 ขั้นตอนการดำเนินงาน .....	2
1.6 งบประมาณ .....	2
<b>บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง</b> .....	<b>3</b>
2.1 การสร้างภาพด้วยสนามแม่เหล็กไฟฟ้า (Magnetic Resonance Imaging: MRI) ...	3
2.2 โพรงสมองด้านข้าง (Lateral Ventricles) .....	5
2.3 วิธีการกำหนดค่าขีดแบ่ง (Thresholding) .....	8
2.3.1 การกำหนดค่าขีดแบ่ง .....	8
2.3.2 หลักการทำงานของวิธีการกำหนดค่าขีดแบ่ง .....	9
2.4 ฟลัดฟิลล์ (Flood Fill) .....	10
2.5 แอ็กทีฟคอนทัวร์โมเดล (Active Contour Model) .....	11
2.6 การปรับเท่าฮิสโตแกรมแบบปรับตัว (Adaptive Histogram Equalization) .....	12
2.7 โครงข่ายประสาทเทียมแบบคอนโวลูชันนอลเชิงลึก .....	13
2.7.1 Convolutional Layer .....	14
2.7.2 ReLU (Rectified Linear Unit) Layer .....	16
2.7.3 Pooling Layer .....	17
2.7.4 Fully Connected Layer .....	17
2.8 โครงข่ายประสาทเทียมแบบคอนโวลูชันนอลเชิงลึกสามมิติ .....	19
2.8.1 3D CNNs: VoxNet .....	19

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญ (ต่อ)

	หน้า
2.8.2 3D NIN FC (3-Dimensional Network in Network Full Connected).	21
2.9 งานวิจัยที่เกี่ยวข้อง .....	24
2.9.1 3-D MRI Brain Scan Feature Classification Using an Oct-tree Representation .....	24
2.9.2 3-D Volume of Interest Based Image Classification .....	25
2.9.3 Graph-Based Shape Analysis for MRI Classification .....	26
บทที่ 3 วิธีการดำเนินงาน .....	27
3.1 ระเบียบวิธีการดำเนินงาน .....	27
3.1.1 ศึกษาทฤษฎีที่เกี่ยวข้องและพัฒนาขั้นตอนวิธี แยกส่วนโพรงสมองด้านข้าง.....	28
3.1.2 ประเมินผลการทดลองโดยเปรียบเทียบกับขนาดของโพรงสมอง ที่ได้จากการแบ่งส่วนด้วยมือโดยผู้เชี่ยวชาญ .....	28
3.1.3 ทดสอบทางสถิติสำหรับขั้นตอนวิธีการแบ่งส่วนโพรงสมอง .....	28
3.1.4 ทดสอบการจำแนกประเภทโพรงสมองด้านข้างด้วย วิธีการเรียนรู้เชิงลึก.....	28
3.1.5 ทดสอบทางสถิติสำหรับผลการทดลองของการจำแนกโพรงสมองด้านข้าง ...	28
3.1.6 ศึกษาทฤษฎีที่เกี่ยวข้องและพัฒนาขั้นตอนวิธี แยกส่วนโพรงสมองด้านข้าง.....	28
3.2 ขั้นตอนวิธีการจำแนกประเภทโพรงสมองด้านข้าง.....	29
3.2.1 การแบ่งส่วนโพรงสมองด้านข้างจากชุดข้อมูลทั้งหมด .....	30
3.2.1.1 รับค่า Input .....	31
3.2.1.2 ปรับปรุงภาพเอ็มอาร์ไอทั้งหมดและภาพตัวกรองแรก.....	31
3.2.1.3 ขั้นตอนวิธีการแบ่งส่วนโพรงสมองด้านข้าง .....	33
3.2.1.4 ตรวจสอบโพรงสมองขั้นที่ 3 .....	34
3.2.1.5 รับค่าตำแหน่งภาพที่เกิดโพรงขั้นที่ 3 และทำการตัดออก.....	34
3.2.1.6 คำนวณปริมาตรของโพรงสมองด้านข้าง .....	35
3.2.2 การจำแนกประเภทโพรงสมองด้านข้าง.....	36
3.2.2.1 เตรียมข้อมูลโพรงสมองทั้งหมดที่ได้จากการแบ่งภาพ .....	37
3.2.2.1.1 แบ่งข้อมูลในรูปของ 10-Fold Cross Validation.....	38

## สารบัญ (ต่อ)

	หน้า
3.2.2.1.2 ปรับขนาดภาพให้มีขนาดเดียวกัน .....	43
3.2.2.1.3 แปลงข้อมูลให้อยู่ในรูปแบบ HDF5 .....	44
3.2.2.2 สร้างโมเดลเพื่อทำการจำแนก .....	46
3.2.2.3 ทดสอบและประเมินประสิทธิภาพของโมเดล.....	48
3.2.2.4 วิเคราะห์และสรุปผล .....	49
<b>บทที่ 4 ผลการดำเนินงานและการอภิปรายผล .....</b>	<b>50</b>
4.1 ผลการดำเนินงานการแบ่งส่วนโครงสมองด้านข้าง .....	50
4.2 การประเมินผลการดำเนินงานการแบ่งส่วนโครงสมองด้านข้าง .....	54
4.3 ปัญหาที่พบในการแบ่งส่วนโครงสมองด้านข้าง.....	62
4.3.1 ขนาดที่ไม่เท่ากันของภาพสแกนเอ็มอาร์ไอที่นำมาใช้ .....	62
4.3.2 มุมมองของภาพสแกนเอ็มอาร์ไอที่ไม่เหมือนกัน.....	62
4.3.3 เส้นขอบโครงสมองบางส่วนไม่ต่อเนื่องกัน .....	62
4.3.4 การประเมินผลของวิธีการแบ่งส่วนโครงสมองด้านข้าง ที่นำเสนอไม่สามารถพิจารณาจากรูปร่างของโครงสมองด้านข้างได้ .....	62
4.4 ผลการดำเนินงานการจำแนกประเภทโครงสมองด้านข้าง.....	62
4.4.1 ผลการทดลองสำหรับสถาปัตยกรรม VoxNet .....	63
4.4.2 ผลการทดลองสำหรับสถาปัตยกรรม 3D NIN FC .....	69
4.4.3 การประเมินประสิทธิภาพของโมเดล.....	75
4.5 ผลการทดสอบและประเมินประสิทธิภาพ การจำแนกประเภทโครงสมองด้านข้าง .....	83
4.5.1 การทดสอบประสิทธิภาพระหว่าง VoxNet และ 3D NIN FC ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Accuracy.....	86
4.5.2 การทดสอบประสิทธิภาพระหว่าง VoxNet และ 3D NIN FC ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Accuracy.....	87
4.5.3 การทดสอบประสิทธิภาพระหว่าง VoxNet และ 3D NIN FC ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Sensitivity.....	88

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญ (ต่อ)

	หน้า
4.5.4 การทดสอบประสิทธิภาพระหว่าง VoxNet และ 3D NIN FC ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Sensitivity.....	89
4.5.5 การทดสอบประสิทธิภาพระหว่าง VoxNet และ 3D NIN FC ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Specificity.....	90
4.5.6 การทดสอบประสิทธิภาพระหว่าง VoxNet และ 3D NIN FC ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Specificity.....	91
4.5.7 การทดสอบประสิทธิภาพระหว่าง VoxNet และ Tree-based ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Accuracy.....	92
4.5.8 การทดสอบประสิทธิภาพระหว่าง VoxNet และ Tree-based ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Accuracy.....	93
4.5.9 การทดสอบประสิทธิภาพระหว่าง VoxNet และ Tree-based ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Sensitivity.....	94
4.5.10 การทดสอบประสิทธิภาพระหว่าง VoxNet และ Spoke Based ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Sensitivity.....	95
4.5.11 การทดสอบประสิทธิภาพระหว่าง VoxNet และ Tree-based ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Specificity.....	96
4.5.12 การทดสอบประสิทธิภาพระหว่าง VoxNet และ Tree-based ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Specificity.....	97
4.6 ปัญหาที่พบในกาจำแนกประเภทโพรงสมองด้านข้าง.....	98
4.6.1 ชุดข้อมูลสำหรับคนเป็นนักดนตรีน้อยเกินไป.....	98

## สารบัญ (ต่อ)

	หน้า
4.6.2 การคำนวณภาพสามมิติและการสร้างโมเดล	
การเรียนรู้เชิงลึก (Deep Learning) ต้องใช้ทรัพยากรในการคำนวณสูง .....	98
<b>บทที่ 5 สรุปผลการดำเนินงานและข้อเสนอแนะ</b> .....	<b>99</b>
5.1 สรุปผลการดำเนินงาน .....	99
5.2 ข้อเสนอแนะ .....	99



## สารบัญตาราง

ตารางที่	หน้า
2.1 การเปรียบเทียบการตรวจด้วยเครื่องมือทางรังสีวิทยา.....	4
2.2 ตารางแสดงผลลัพธ์ในงานวิจัย 3-D MRI Brain Scan Feature Classification Using an Oct-tree Representation .....	24
2.3 ตารางแสดงผลลัพธ์การจำแนกสำหรับชุดข้อมูลนักดนตรี (Musician).....	25
2.4 ตารางแสดงผลลัพธ์การจำแนกสำหรับชุดข้อมูลโรคลมชัก (Epilepsy).....	26
4.1 การเปรียบเทียบขนาดของโพรงสมองด้านข้างที่ได้จากวิธีการที่ นำเสนอ และการแบ่งส่วนด้วยมือโดยผู้เชี่ยวชาญ.....	54
4.2 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) ด้วยสถาปัตยกรรม VoxNet สำหรับข้อมูลแบบ Epilepsy: All .....	64
4.3 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) ด้วยสถาปัตยกรรม VoxNet สำหรับข้อมูลแบบ Epilepsy: Split1.....	64
4.4 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) ด้วยสถาปัตยกรรม VoxNet สำหรับข้อมูลแบบ Epilepsy: Split2.....	65
4.5 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) ด้วยสถาปัตยกรรม VoxNet สำหรับข้อมูลแบบ Musician: All.....	66
4.6 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) ด้วยสถาปัตยกรรม VoxNet สำหรับข้อมูลแบบ Musician: Split1 .....	66
4.7 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) ด้วยสถาปัตยกรรม VoxNet สำหรับข้อมูลแบบ Musician: Split2.....	67
4.8 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่มีสุขภาพดี (Healthy) ผู้ที่เป็นนักดนตรี (Musician) และผู้ที่เป็นโรคลมชัก (Epilepsy) ด้วยสถาปัตยกรรม VoxNet สำหรับข้อมูลแบบ Healthy, Musician and Epilepsy: All.....	68
4.9 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) ด้วย สถาปัตยกรรม 3D NIN FC สำหรับข้อมูลแบบ Epilepsy: All.....	69
4.10 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) ด้วยสถาปัตยกรรม 3D NIN FC สำหรับข้อมูลแบบ Epilepsy: Split1.....	70
4.11 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) ด้วยสถาปัตยกรรม 3D NIN FC สำหรับข้อมูลแบบ Epilepsy: Split2.....	70

## สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.12	ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) ด้วยสถาปัตยกรรม 3D NIN FC สำหรับข้อมูลแบบ Musician: All..... 71
4.13	ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) ด้วยสถาปัตยกรรม 3D NIN FC สำหรับข้อมูลแบบ Musician: Split1 ..... 72
4.14	ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) ด้วยสถาปัตยกรรม 3D NIN FC สำหรับข้อมูลแบบ Musician: Split2 ..... 72
4.15	ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่มีสุขภาพดี (Healthy) ผู้ที่เป็นนักดนตรี (Musician) และผู้ที่เป็นโรคลมชัก (Epilepsy) ด้วยสถาปัตยกรรม 3D NIN FC สำหรับข้อมูลแบบ Healthy, Musician and Epilepsy: All..... 74
4.16	ตารางเปรียบเทียบผลการทดลองที่ได้จากการสร้างโมเดลจำแนกด้วยสถาปัตยกรรม VoxNet และ 3D NIN FC สำหรับข้อมูลแบบ Epilepsy: All, Epilepsy: Split1, Epilepsy: Split2, Musician: All, Musician: Split1, Musician: Split2 ..... 84
4.17	ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่มีสุขภาพดี (Healthy) ผู้ที่เป็นนักดนตรี (Musician) และผู้ที่เป็นโรคลมชัก (Epilepsy) ด้วยสถาปัตยกรรม VoxNet และ 3D NIN FC สำหรับข้อมูลแบบ Healthy, Musician and Epilepsy: All..... 85

## สารบัญภาพ

ภาพที่	หน้า
2.1 หลักการทำงานของเครื่อง MRI.....	3
2.2 ตำแหน่งที่ตั้งของโพรงสมองทั้งสามส่วน.....	6
2.3 มุมมองด้านบนของโพรงสมอง .....	6
2.4 มุมมองด้านข้างของโพรงสมอง.....	7
2.5 ตำแหน่งค่าฮิสโตแกรมที่จุดต่ำสุดที่อยู่ระหว่างจุดสูงสุด.....	8
2.6 ค่าขีดแบ่งของภาพแบบ Grayscale ขนาดแปดบิต.....	9
2.7 การกำหนด Seed Point.....	10
2.8 การเชื่อมต่อแบบ 4 จุดรอบ Seed Point (4 Connected).....	10
2.9 การเชื่อมต่อแบบ 8 จุดรอบ Seed Point (8 Connected).....	10
2.10 ตัวอย่างการใช้ แอ็กทีฟคอนทัวร์โมเดล .....	11
2.11 ภาพแสดงการปรับเท่าฮิสโตแกรมแบบปรับตัว.....	12
2.12 การทำงานของโครงข่ายประสาทแบบคอนโวลูชันอลเชิงลึก .....	14
2.13 สมการการทำ Convolution Operation ด้วยการคูณ .....	14
2.14 ตัวอย่างการทำ Convolution Operation ด้วยการคูณ.....	15
2.15 การทำ Zero Padding.....	15
2.16 กราฟแสดงลักษณะของฟังก์ชัน ReLU.....	16
2.17 ตัวอย่างการปรับค่าด้วยฟังก์ชันกระตุ้น ReLU .....	16
2.18 การทำ Max Pooling.....	17
2.19 การทำโครงข่ายประสาทเทียมใน Fully Connected Layer.....	18
2.20 โครงข่ายก่อนและหลังการทำ Dropout.....	18
2.21 Volumetric Display of Lateral Ventricles .....	19
2.22 ภาพการจำลองสถาปัตยกรรมของ 3D CNNs: VoxNet.....	20
2.23 การเปรียบเทียบระหว่าง Linear Convolution Layer และ Mlpconv Layer.....	22
2.24 โครงสร้างโดยรวมทั้งหมดของโครงข่าย NIN.....	23
2.25 กราฟเปรียบเทียบผลลัพธ์แต่ละวิธีการที่ใช้จำแนกในงานวิจัย 3-D MRI Brain Scan Feature Classification Using an Oct-tree Representation .....	25
3.1 ระเบียบวิธีการดำเนินงานของการจำแนกประเภทโพรงสมองด้วยวิธีการเรียนรู้เชิงลึก.....	27
3.2 ขั้นตอนวิธีการจำแนกประเภทโพรงสมองด้านข้างด้วยวิธีการเรียนรู้เชิงลึก .....	29

## สารบัญภาพ (ต่อ)

ภาพที่	หน้า
3.3 ขั้นตอนวิธีการแบ่งส่วนโพรงสมองด้านข้าง.....	30
3.4 ภาพแสดงลำดับการเกิดโพรงสมองด้านข้าง.....	31
3.5 ภาพก่อนและหลังการปรับค่าความเข้มแสงด้วยวิธี CLAHE .....	31
3.6 แสดงขั้นตอนการปรับปรุงตัวกรองแรก.....	32
3.7 โพรงสมองที่ติดส่วนโพรงสมองชั้นที่ 3 ในกรอบสีน้ำเงิน โดยตัวเลขมีหน่วยเป็นพิกเซล ....	34
3.8 แสดงขั้นตอนการตัดโพรงสมองชั้นที่ 3.....	34
3.9 สูตรการคำนวณหาปริมาตรโพรงสมองด้านข้าง .....	35
3.10 ขั้นตอนวิธีการจำแนกประเภทโพรงสมองด้านข้าง .....	36
3.11 ตัวอย่างโพรงสมองด้านข้างของบุคคลแต่ละประเภท.....	37
3.12 ตัวอย่างภาพ 2 มิติของโพรงสมองด้านข้าง (Lateral Ventricles).....	38
3.13 ขั้นตอนวิธีการเตรียมข้อมูลสำหรับการสร้างโมเดลเพื่อทำการจำแนก.....	38
3.14 ลำดับขั้นการแบ่งข้อมูลแบบ Epilepsy: All.....	39
3.15 ลำดับขั้นการแบ่งข้อมูลแบบ Epilepsy: Split1.....	40
3.16 ลำดับขั้นการแบ่งข้อมูลแบบ Epilepsy: Split2.....	40
3.17 ลำดับขั้นการแบ่งข้อมูลแบบ Musician: All.....	41
3.18 ลำดับขั้นการแบ่งข้อมูลแบบ Musician: Split1 .....	41
3.19 ลำดับขั้นการแบ่งข้อมูลแบบ Musician: Split2 .....	42
3.20 ลำดับขั้นการแบ่งข้อมูลแบบ Healthy, Musician and Epilepsy: All.....	42
3.21 ข้อมูลที่ถูกจัดแบ่งด้วยวิธีการ 10-Fold Cross Validation .....	43
3.22 คำสั่งการปรับภาพโพรงสมองด้านข้างทั้งหมดมีขนาดเดียวกัน .....	44
3.23 ไฟล์ผลลัพธ์ที่ได้จากการปรับภาพโพรงสมองด้านข้าง .....	44
3.24 คำสั่งการแปลงข้อมูลให้อยู่ในรูปแบบ HDF5.....	45
3.25 Text File สำหรับเส้นทางที่เก็บโพรงสมองด้านข้าง .....	45
3.26 HDF5 File ที่ได้จากการแปลง.....	46
3.27 การใช้คำสั่งสำหรับสร้างโมเดลเพื่อจำแนกผู้ที่เป็นนักดนตรี (Musician) กับผู้ที่ไม่ได้เป็นนักดนตรี (Non-musician).....	47
3.28 การใช้คำสั่งสำหรับสร้างโมเดลเพื่อจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) กับผู้ที่ไม่ได้เป็นโรคลมชัก (Non-epilepsy).....	48
3.29 ตัวอย่างการแสดงค่าของแต่ละมาตรวัดในขณะที่กำลังประมวลผลโมเดล .....	48

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่โดยไม่ได้รับอนุญาต

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญภาพ (ต่อ)

ภาพที่	หน้า
4.1 ภาพสามมิติโพรงสมองด้านข้างของสมอง sw8nr.....	51
4.2 ภาพสามมิติโพรงสมองด้านข้างของสมอง mdy.....	52
4.3 ภาพสามมิติโพรงสมองด้านข้างของสมอง hjjh.....	53
4.4. กราฟเปรียบเทียบขนาดของโพรงสมองด้านข้างที่ได้จากวิธีการที่นำเสนอ และการแบ่งส่วนด้วยมือโดยผู้เชี่ยวชาญ.....	59
4.5 กราฟค่าความแตกต่างระหว่างขนาดโพรงสมองด้านข้าง จากการแบ่งส่วนโดยผู้เชี่ยวชาญและวิธีการที่นำเสนอ เทียบกับค่าขอบล่าง (Lower Bound) และค่าขอบบน (Upper Bound).....	60
4.6 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพวิธีการแบ่งส่วนด้วย Z-test ระหว่างวิธีการที่นำเสนอและวิธีแบ่งส่วนโดยผู้เชี่ยวชาญ.....	61
4.7 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม VoxNet ด้วยการแบ่งข้อมูลแบบ Epilepsy: All ตั้งแต่ Epoch ที่ 1 ถึง 150.....	75
4.8 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม 3D NIN FC ด้วยการแบ่งข้อมูลแบบ Epilepsy: All ตั้งแต่ Epoch ที่ 1 ถึง 150.....	76
4.9 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม VoxNet ด้วยการแบ่งข้อมูลแบบ Epilepsy: Split1 ตั้งแต่ Epoch ที่ 1 ถึง 150.....	76
4.10 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม 3D NIN FC ด้วยการแบ่งข้อมูลแบบ Epilepsy: Split1 ตั้งแต่ Epoch ที่ 1 ถึง 150.....	77
4.11 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม VoxNet ด้วยการแบ่งข้อมูลแบบ Epilepsy: Split2 ตั้งแต่ Epoch ที่ 1 ถึง 150.....	77

## สารบัญภาพ (ต่อ)

ภาพที่	หน้า
4.12 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม 3D NIN FC ด้วยการแบ่งข้อมูลแบบ Epilepsy: Split2 ตั้งแต่ Epoch ที่ 1 ถึง 150 .....	78
4.13 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยสถาปัตยกรรม VoxNet ด้วยการแบ่งข้อมูลแบบ Musician: All ตั้งแต่ Epoch ที่ 1 ถึง 150 .....	78
4.14 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยสถาปัตยกรรม 3D NIN FC ด้วยการแบ่งข้อมูลแบบ Musician: All ตั้งแต่ Epoch ที่ 1 ถึง 150 .....	79
4.15 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยสถาปัตยกรรม VoxNet ด้วยการแบ่งข้อมูลแบบ Musician: Split1 ตั้งแต่ Epoch ที่ 1 ถึง 150 .....	79
4.16 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยสถาปัตยกรรม 3D NIN FC ด้วยการแบ่งข้อมูลแบบ Musician: Split1 ตั้งแต่ Epoch ที่ 1 ถึง 150 .....	80
4.17 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยสถาปัตยกรรม VoxNet ด้วยการแบ่งข้อมูลแบบ Musician: Split2 ตั้งแต่ Epoch ที่ 1 ถึง 150 .....	80
4.18 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยสถาปัตยกรรม 3D NIN FC ด้วยการแบ่งข้อมูลแบบ Musician: Split2 ตั้งแต่ Epoch ที่ 1 ถึง 150 .....	81

## สารบัญภาพ (ต่อ)

ภาพที่	หน้า
4.19 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่มีสุขภาพดี (Healthy) ผู้ที่เป็นนักดนตรี (Musician) และผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม VoxNet ด้วยการแบ่งข้อมูลแบบ Healthy, Musician and Epilepsy: All ตั้งแต่ Epoch ที่ 1 ถึง 150 .....	81
4.20 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่มีสุขภาพดี (Healthy) ผู้ที่เป็นนักดนตรี (Musician) และผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม 3D NIN FC ด้วยการแบ่งข้อมูลแบบ Healthy, Musician and Epilepsy: All ตั้งแต่ Epoch ที่ 1 ถึง 150 .....	82
4.21 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Accuracy .....	86
4.22 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Accuracy .....	87
4.23 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Sensitivity .....	88
4.24 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Sensitivity .....	89
4.25 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Specificity .....	90
4.26 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Specificity .....	91

## สารบัญภาพ (ต่อ)

ภาพที่	หน้า
4.27 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ Tree-based สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Accuracy.....	92
4.28 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ Tree-based สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Accuracy.....	93
4.29 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ Tree-based สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Sensitivity.....	94
4.30 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ Spoke Based สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Sensitivity.....	95
4.31 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ Tree-based สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Specificity.....	96
4.32 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ Tree-based สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Specificity.....	97

# บทที่ 1

## บทนำ

### 1.1 ความเป็นมาและความสำคัญของปัญหา

การสร้างภาพด้วยสนามแม่เหล็กไฟฟ้า (Magnetic Resonance Imaging: MRI) หรือการสร้างภาพด้วยเอ็มอาร์ไอแบบสามมิติ เป็นเทคโนโลยีที่มีการนำมาใช้กันอย่างแพร่หลาย ภาพเอ็มอาร์ไอมีประโยชน์สำหรับวงการแพทย์ในการวินิจฉัยโรคเฉพาะทาง เนื่องจากแพทย์สามารถนำภาพเอ็มอาร์ไอมาใช้ในการวิเคราะห์ห่อหุ้มต่าง ๆ เพื่อช่วยในการวินิจฉัยโรคสำหรับการวิเคราะห์ เนื่องจากมีงานวิจัยหลายงานวิจัยได้นำเสนอว่า รูปทรงและขนาดของโพรงสมองด้านข้าง (Lateral Ventricles) นั้นมีความสัมพันธ์กับโรคบางโรค เช่น โรคลมชัก (Epilepsy) ดังนั้นในปัญหาพิเศษนี้จึงเสนอวิธีการแบ่งส่วนโพรงสมองด้านข้างจากภาพเอ็มอาร์ไอสามมิติ และวิธีการจำแนกโพรงสมองด้านข้างด้วยวิธีการเรียนรู้เชิงลึก ซึ่งผลลัพธ์ที่ได้จากการทดลองสามารถนำไปใช้วิเคราะห์ศึกษาเพื่อทำนายโรคต่าง ๆ และหาองค์ความรู้ใหม่ต่อไปได้

### 1.2 วัตถุประสงค์ของการดำเนินงาน

- 1.) เพื่อศึกษาว่าวิธีการแบ่งส่วนของภาพวิธีไหนเหมาะสมกับการแบ่งส่วนโพรงสมองด้านข้างของสมองจากภาพเอ็มอาร์ไอสามมิติ
- 2.) เพื่อนำภาพสามมิติของโพรงสมองด้านข้างที่ได้จากการแบ่งส่วนไปใช้ศึกษาและวิเคราะห์โดยใช้การจำแนกด้วยวิธีการเรียนรู้เชิงลึก
- 3.) เพื่อนำผลลัพธ์ที่ได้มาวิเคราะห์หาองค์ความรู้ที่ได้จากการทดลองต่อไป

### 1.3 ขอบเขตการศึกษา

- 1.) ปัญหาพิเศษนี้ มุ่งเน้นไปที่การหาวิธีการแบ่งส่วนโพรงสมองด้านข้างจากภาพเอ็มอาร์ไอสามมิติ และนำส่วนโพรงสมองที่ได้มาทำการจำแนกด้วยวิธีการเรียนรู้เชิงลึก
- 2.) ชุดข้อมูลทดลองในปัญหาพิเศษนี้ ประกอบไปด้วยภาพเอ็มอาร์ไอสามมิติของสมองจำนวน 380 สมอง ประกอบไปด้วยผู้ที่มีร่างกายปกติ (Healthy) 80 สมอง ผู้ที่เป็นโรคลมชัก (Epilepsy) 260 สมองและผู้ที่เป็นนักดนตรี (Musician) 40 สมอง

#### 1.4 ประโยชน์ที่คาดว่าจะได้รับ

- 1.) ได้ทราบวิธีการที่เหมาะสมในการแบ่งส่วนโพรงสมองด้านข้างจากภาพเอ็มอาร์ไอสามมิติ
- 2.) ได้ทราบขั้นตอนวิธีของวิธีการเรียนรู้เชิงลึกที่เหมาะสมในการจำแนกส่วนของโพรงสมอง
- 3.) ได้องค์ความรู้ใหม่จากผลการทดลอง

#### 1.5 ขั้นตอนการดำเนินงาน

- 1.) ศึกษาวิธีการแบ่งส่วนของภาพเอ็มอาร์ไอสามมิติในรูปแบบต่าง ๆ และศึกษาวิธีการจำแนกข้อมูลโดยวิธีการเรียนรู้เชิงลึก
- 2.) เก็บข้อมูล/เตรียมพร้อมข้อมูล
- 3.) ทำการทดลองการแบ่งโพรงสมองด้านข้าง
- 4.) ประเมินผลและปรับปรุงผลการทดลองการแบ่งภาพโพรงสมองด้านข้าง
- 5.) ทำการทดลองการจำแนกโพรงสมองด้านข้าง
- 6.) ประเมินผลและปรับปรุงผลการทดลองการจำแนกโพรงสมองด้านข้าง
- 7.) วิเคราะห์และสรุปผลการทดลอง
- 8.) จัดทำเอกสารประกอบปัญหาพิเศษ

#### 1.6 งบประมาณ

- \$1,294.08

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

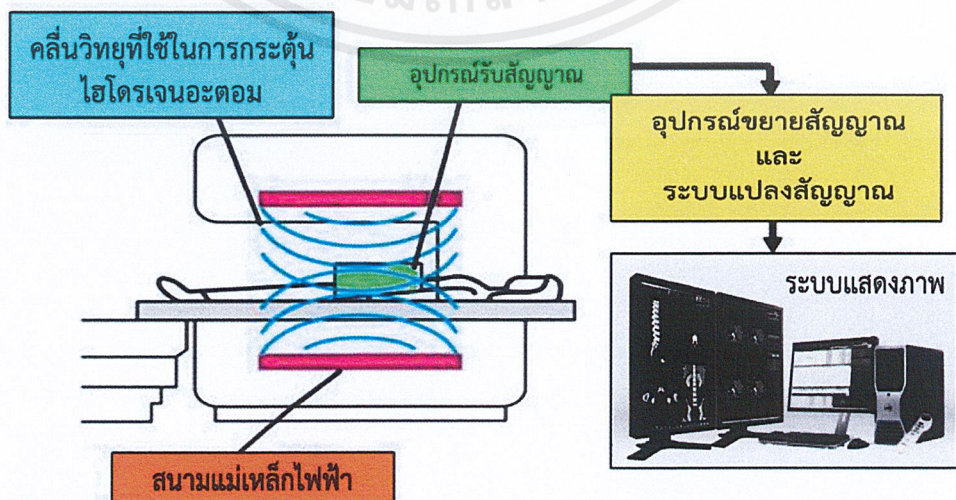
## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงทฤษฎีและงานวิจัยที่เกี่ยวข้อง ซึ่งประกอบไปด้วยการสร้างภาพด้วยสนามแม่เหล็กไฟฟ้า โพรงสมองด้านข้าง วิธีการกำหนดค่าขีดแบ่ง (Thresholding) ฟลัดฟิลล์ การปรับเท่าฮิสโตแกรมแบบปรับตัว (Adaptive Histogram Equalization) การเรียนรู้เชิงลึกด้วยวิธีการโครงข่ายประสาทแบบคอนโวลูชันนอลเชิงลึก และงานวิจัยที่เกี่ยวข้องกับการแบ่งส่วนโพรงสมองด้านข้างและการจำแนกโพรงสมอง

#### 2.1 การสร้างภาพด้วยสนามแม่เหล็กไฟฟ้า (Magnetic Resonance Imaging: MRI)

การสร้างภาพด้วยสนามแม่เหล็กไฟฟ้า ใช้ในการตรวจวินิจฉัยรอยโรคของผู้ป่วย เพื่อนำมาใช้ในการรักษาและติดตามผลการรักษา อาศัยคุณสมบัติความเป็นแม่เหล็กของไฮโดรเจนอะตอม (Hydrogen) ซึ่งเป็นส่วนประกอบหลักที่อยู่ภายในร่างกายมนุษย์ เช่น โมเลกุลของน้ำ ( $H_2O$ ) เป็นต้น เมื่อผู้รับการตรวจเข้าไปอยู่ภายใต้สนามแม่เหล็กไฟฟ้า เครื่องจะส่งสัญญาณคลื่นวิทยุที่มีความถี่จำเพาะ (Radio Frequency) เข้าไปกระตุ้นระบบอวัยวะที่จะตรวจ เมื่ออวัยวะนั้น ๆ ถูกกระตุ้น จะมีการเปลี่ยนแปลงระดับพลังงานตามกระบวนการทางฟิสิกส์ที่เรียกว่า การกำทอน (Resonance) หลังจากหยุดกระตุ้นไฮโดรเจน อะตอมภายในร่างกายมีการคายพลังงาน อุปกรณ์รับสัญญาณ จะทำหน้าที่รับสัญญาณออกมา จากนั้นแปลงเป็นสัญญาณภาพต่อไป หลักการทำงานของเครื่อง MRI แสดงดังภาพที่ 2.1



ภาพที่ 2.1 หลักการทำงานของเครื่อง MRI

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับกรู๊ปงานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เครื่องสแกน MRI ในปัจจุบันมีการนำมาใช้อย่างแพร่หลาย เนื่องจากเป็นการสร้างภาพที่มีความแม่นยำสูง ให้ภาพความแตกต่างของเนื้อเยื่อได้ดี ทำได้หลายระนาบ สามารถใช้ตรวจได้ทุกของร่างกายโดยเฉพาะอย่างยิ่งในส่วนของสมองและกระดูกสันหลังในกรณีดังกล่าว การตรวจ MRI ดีกว่าการตรวจด้วยเอกซเรย์คอมพิวเตอร์ (Computed Tomography: CT) อีกทั้ง MRI ยังมีประโยชน์มากในการตรวจผู้ป่วยเด็ก เนื่องจากไม่มีอันตรายจากรังสีที่เกิดจากการใช้เครื่องเอกซเรย์

การตรวจ MRI สามารถใช้ตรวจได้เกือบทุกระบบอวัยวะของร่างกาย ได้แก่ ระบบสมอง ระบบช่องท้องทั้งหมด ระบบกระดูก กล้ามเนื้อและข้อ เป็นต้น แต่จะมีข้อด้อยโดยเฉพาะการตรวจลำไส้ และกระเพาะอาหาร เนื่องจากในภาพ MRI รังสีแพทย์อาจจะเห็นเศษอุจจาระเป็นส่วนผิดปกติของร่างกาย เช่น ก้อนเนื้อออกได้ การตรวจอวัยวะต่าง ๆ ด้วยเครื่องมือทางรังสีวิทยาจะให้ผลลัพธ์ที่แตกต่างกันแสดงดังตารางที่ 2.1

ตารางที่ 2.1 การเปรียบเทียบการตรวจด้วยเครื่องมือทางรังสีวิทยา

บริเวณที่จะตรวจ	X-Ray	Angio	Ultrasound	CT Scan	MRI
สมอง	ไม่ได้	ไม่ได้	เฉพาะทารก	ดี	ดีมาก
กระดูกสันหลัง	ได้	ไม่ได้	ไม่ได้	ดี	ดีมาก
ปอด	ได้	ไม่ได้	ไม่ได้	ดีมาก	ดีมาก
ช่องท้อง	ได้	ไม่ได้	เฉพาะจุด	ดีมาก	ดีมาก
กระดูกข้อและเอ็น	ได้	ไม่ได้	ได้	ดี	ดีมาก
เส้นเลือดในสมอง	ไม่ได้	ดีมาก	ไม่ได้	ดี	ดี
เส้นเลือดใหญ่	ไม่ได้	ดีมาก	ได้	ดี	ดีมาก
หัวใจ	บอกได้เฉพาะขนาด	ดีมาก	ดีมาก	ดี	ดีมาก
ลำไส้และกระเพาะ	บอกได้ด้วยการกลืนแป้ง	ไม่ได้	ไม่ได้	ดี	ไม่ได้
โพรงจมูก	ได้	ไม่ได้	ไม่ได้	ดีมาก	ดีมาก
ตาและเส้นประสาท	ไม่ได้	ไม่ได้	ไม่ได้	ดี	ดีมาก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2.2 โพรงสมองด้านข้าง (Lateral Ventricles)

โพรงสมอง คือ ช่องหรือโพรงที่อยู่ภายในสมอง ซึ่งเป็นที่อยู่ของน้ำหล่อเลี้ยงสมองและไขสันหลัง (Cerebrospinal Fluid) ซึ่งสร้างจากเนื้อเยื่อภายในโพรงสมองที่เรียกว่า คอโรยด์เพล็กซ์ (Choroid Plexuses) ทั้งนี้โพรงสมอง น้ำหล่อเลี้ยงสมอง และไขสันหลัง มีหน้าที่เพื่อหล่อเลี้ยง ปกป้องสมองและไขสันหลัง ให้ความชุ่มชื้น ให้การคงรูปร่าง หล่อลื่นไม่ให้สมองเสียดสีกับกะโหลกและไม่ให้ไขสันหลังเสียดสีกับกระดูกสันหลัง

โพรงสมอง ประกอบด้วยสามส่วน ดังนี้


- 1) โพรงสมองด้านข้าง (Lateral Ventricles) อยู่ในซีรีบรัม (Cerebrum)
- 2) โพรงสมองที่สาม (Third Ventricle) เป็นช่องเดียวที่อยู่กึ่งกลางระหว่างทาลามัส (Thalamus)
- 3) โพรงสมองที่สี่ (Fourth Ventricle) เป็นช่องเดียวที่อยู่ใต้ซีรีเบลลัม (Cerebellum)

โดยภาพที่ 2.2 แสดงตำแหน่งที่ตั้งของโพรงสมองทั้งสามส่วน บนพื้นผิวของสมอง

โพรงสมองด้านข้างเป็นส่วนหนึ่งของระบบโพรงสมอง นับเป็นส่วนหนึ่งของเทเลนเซฟาโลน (Telencephalon) อาจเรียกอีกชื่อหนึ่งว่า ซีรีบรัม (Cerebrum) หรือ สมองใหญ่ โพรงสมองด้านข้างนับเป็นโพรงสมองที่มีขนาดใหญ่ที่สุด เชื่อมต่อกับโพรงสมองที่สามผ่านทางอินเทอร์เวนทริคูลาร์ ฟอรามิน (Interventricular Foramina of Monro) ซึ่งโพรงสมองด้านข้างแบ่งออกเป็นสองข้าง คือ ข้างซ้ายและข้างขวา


### หลักการการทำงานของโพรงสมองด้านข้าง

น้ำไขสันหลังสร้างมาจากคอโรยด์เพล็กซ์ และถูกกรองจากเส้นเลือดในคอโรยด์เพล็กซ์เข้าไปอยู่ในโพรงสมอง (Ventricle) ลักษณะเป็นของเหลวใส ๆ ไหลจากโพรงสมองด้านข้าง (Lateral Ventricles) แต่ละข้างผ่านช่องของมอนโร (Foramen of Monro) เข้าสู่โพรงสมองที่สาม (Third Ventricle) จากนั้นจะผ่านช่องในซีรีบรัม (Cerebral Aqueduct) เข้าสู่โพรงสมองที่สี่ (Fourth Ventricle) แล้วน้ำไขสันหลังจะไหลผ่านออกสู่ช่องว่างระหว่างเยื่อหุ้มสมอง (Subarachnoid Space) ทางช่องของผนังในโพรงสมองสามทาง (Foramina in the Roof หรือ Foramen of Luschka สองข้าง และ Magendie's Foramen) ไปอยู่รอบ ๆ สมองและไขสันหลังในบริเวณเอว ซึ่งจะเป็นบริเวณที่แพทย์นิยมใช้เจาะน้ำไขสันหลัง โดยน้ำไขสันหลังที่ไหลเวียนในช่องว่างนี้จะนำสารอาหารไปให้เนื้อสมองและไขสันหลัง แล้วนำของเสียเข้าสู่ระบบหมุนเวียนของหลอดเลือดดำทางอะแรชนอยด์วิลโล (Arachnoid Villi) ต่อไป นอกจากนี้น้ำไขสันหลังยังช่วยกันกระเทือนให้กับสมองและไขสันหลังด้วย




ภาพที่ 2.2 ตำแหน่งที่ตั้งของโพรงสมองทั้งสามส่วน

โพรงสมองด้านข้างแบ่งออกเป็นสามส่วน คือ ส่วนด้านหน้า (Anterior หรือ Frontal Horn) ส่วนด้านหลัง (Posterior หรือ Occipital Horn) และส่วนด้านล่าง (Inferior หรือ Temporal Horn) ส่วนแกนของโพรงสมองด้านข้างเป็นส่วนตรงกลาง อยู่ด้านหลังส่วนด้านหน้า ส่วน Trigone ของโพรงสมองด้านข้างเป็นบริเวณรูปสามเหลี่ยมที่มีส่วน Temporal Horn อยู่ด้านล่าง ส่วน Occipital Horn อยู่ด้านหลัง และแกนของโพรงสมองด้านข้างอยู่ด้านหน้า โดยภาพที่ 2.3 แสดงส่วนประกอบจากมุมมองด้านบนของโพรงสมอง และภาพที่ 2.4 แสดงส่วนประกอบจากมุมมอง ด้านข้างของโพรงสมอง



ภาพที่ 2.3 มุมมองด้านบนของโพรงสมอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 2.4 มุมมองด้านข้างของโพรงสมอง



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


## 2.3 วิธีการกำหนดค่าขีดแบ่ง (Thresholding)

วิธีการกำหนดค่าขีดแบ่ง (Thresholding) เป็นวิธีที่ง่ายที่สุดในขั้นตอนวิธีการทำการแบ่งส่วนภาพ (Image Segmentation) เพราะว่ามีวิธีการที่ไม่ซับซ้อน และให้ผลลัพธ์ที่ค่อนข้างดี นิยมใช้ในการแบ่งส่วนภาพของภาพแบบ Grayscale โดยหัวข้อนี้จะพูดถึงการกำหนดค่าขีดแบ่งและหลักการทำงานของการกำหนดค่าขีดแบ่ง ซึ่งแสดงในหัวข้อที่ 2.3.1 - 2.3.2 ตามลำดับ

### 2.3.1 การกำหนดค่าขีดแบ่ง

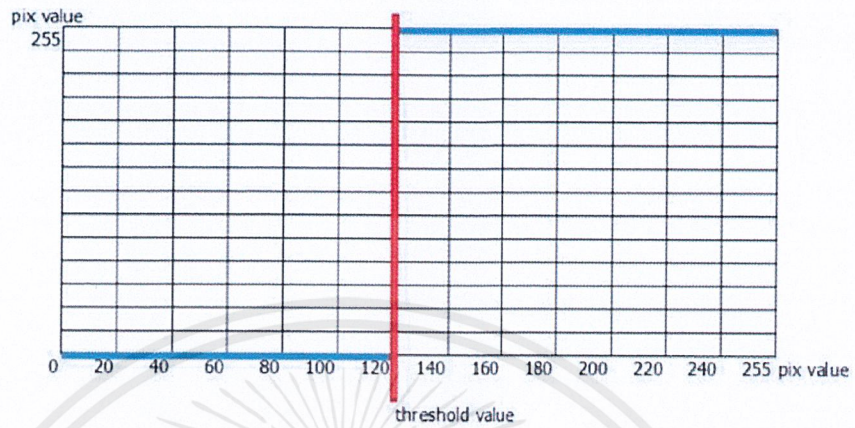
กำหนดค่าขีดแบ่งที่เป็นที่นิยม จะพิจารณาจากค่าเฉลี่ยของค่าพิกเซลที่สูงที่สุด กับค่าพิกเซลที่ต่ำที่สุด

- สมมติค่าพิกเซลต่ำสุดเท่ากับศูนย์ และค่าพิกเซลสูงสุดเท่ากับ 255 จะได้ค่าขีดแบ่งเท่ากับ 128
- ค่าฮิสโตแกรมที่จุดต่ำสุดที่อยู่ระหว่างจุดสูงสุด ดังแสดงในภาพที่ 2.5



ภาพที่ 2.5 ตำแหน่งค่าฮิสโตแกรมที่จุดต่ำสุดที่อยู่ระหว่างจุดสูงสุด

### 2.3.2 หลักการทำงานของ การกำหนดค่าขีดแบ่ง



ภาพที่ 2.6 ค่าขีดแบ่งของภาพแบบ Grayscale ขนาดแปดบิต

จากภาพที่ 2.6 จะเห็นได้ว่า เมื่อกำหนดค่าขีดแบ่งมีค่าเท่ากับ 120 แล้ว ค่าพิกเซลในรูปที่มีค่าน้อยกว่า 120 จะถูกปรับค่าเป็นศูนย์ ในทางกลับกันถ้าค่าในพิกเซล มากกว่า 120 จะถูกปรับเป็น 255

การกำหนดค่าขีดแบ่งจะได้สมการดังนี้

$$f(x, y) = \begin{cases} 1; & \text{if } (x, y) > \text{Threshold} \\ 0; & \text{if } (x, y) < \text{Threshold} \end{cases}$$

เมื่อ  $f(x, y)$  คือ ค่าข้อมูลภาพ ณ ตำแหน่งที่  $x, y$

จากสมการข้างต้นสรุปได้ว่า

- ถ้าค่า Pixel ในรูปมีค่ามากกว่าค่าขีดแบ่ง (Threshold) จะถูกปรับค่าเป็นหนึ่ง
- ถ้าค่า Pixel ในรูปมีค่าน้อยกว่าค่าขีดแบ่ง (Threshold) จะถูกปรับค่าเป็นศูนย์

เมื่อหาค่าขีดแบ่งได้แล้ว จะนำค่าขีดแบ่งที่ได้ไปทำการแบ่งส่วนภาพให้ภาพเป็นสีขาวดำโดยตัวอย่างของภาพเอ็มอาร์ไอของสมองก่อนและหลังการใช้วิธีกำหนดค่าขีดแบ่ง และทำภาพให้เป็น ภาพสีขาวดำได้แล้ว


## 2.4 ฟลัดฟิลล์ (Flood Fill)

เป็นขั้นตอนวิธีที่สามารถทำให้ไปยังจุดต่าง ๆ ในบริเวณที่กำหนด โดยจำลองการทำงานมาจาก Graph Traversal Problem มองพื้นที่เสมือนเมทริกซ์และพิจารณาจุดรอบด้านเป็นจุดที่เชื่อมต่อกับมัน เริ่มต้นต้องกำหนดสิ่งที่เรียกว่า Seed Point ในบริเวณที่ต้องการก่อน โดยตัวอย่างการกำหนด Seed Point , การเชื่อมจ่อแบบ 4 จุดรอบ Seed Point และการเชื่อมต่อบแบบ 8 จุดรอบ Seed Point แสดงดังภาพที่ 2.7-2.9




ภาพที่ 2.7 การกำหนด seed point

ซึ่งวิธีการเลือกไปจุดข้างเคียงมี 4 จุดรอบ Seed Point (4 Connected) และ 8 จุดรอบ Seed Point (8 Connected)



ภาพที่ 2.8 การเชื่อมต่อบแบบ 4 จุดรอบ Seed Point (4 Connected)



ภาพที่ 2.9 การเชื่อมต่อบแบบ 8 จุดรอบ Seed Point (8 Connected)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


## 2.5 แอ็กทีฟคอนทัวร์โมเดล (Active Contour Model)

แอ็กทีฟคอนทัวร์โมเดลรู้จักกันในชื่อ เสนค (Snake) วิธีการนี้ถือว่าเป็นส่วนสำคัญของการตัดส่วนที่สนใจจากภาพเอ็มอาร์ไอมาใช้งาน สามารถระบุได้ว่าสิ่งที่สนใจอยู่ส่วนใดของภาพ วิธีนี้เป็นวิธีที่ทำให้เส้นโค้งพอดีกับเส้นหรือขอบวัตถุบนภาพ ทำงานโดยการค่อย ๆ ลดขนาดลงในช่วงพื้นที่ที่กำหนดจนเจอวัตถุ

เสนค คือเส้นโค้งที่แทนด้วยตัวแปร  $s \in [0, 1]$  เส้นโค้งสามารถเปลี่ยนรูปเป็นรูปแบบต่าง ๆ ได้เกิดขึ้นจากปัจจัย 2 สิ่งคือ แรงภายใน และ แรงภายนอก มีผลทำให้เสนคกระจายตัวไปทั่วบริเวณ ทำให้ภาพเรียบขึ้น สามารถทำให้หาเส้นของขอบได้แรงภายนอกได้มาจากข้อมูลของภาพ ดังนั้นโมเดลของแอ็กทีฟคอนทัวร์จะทำงานอย่างดังฟังก์ชันต่อไปนี้

$$E(X) = \int_0^1 \frac{1}{2} [\alpha |x'(s)|^2 + \beta |X''(s)|^2] + E_{ext}(x(s)) ds$$

เมื่อค่าในวงเล็บ คือ ระดับพลังงานภายในและ  $E_{ext}$  เป็นพลังงานภายนอก  $x'(s)$  และ  $x''(s)$  เป็นพลังงานที่ควบคุมความเรียบ และความยืดหยุ่นของเส้นแอ็กทีฟคอนทัวร์ บนตัวแปร  $\alpha$  และ  $\beta$  ตามลำดับ โดยตัวอย่างการใช้แอ็กทีฟคอนทัวร์โมเดลแสดงดังภาพที่ 2.10




ภาพที่ 2.10 ตัวอย่างการใช้แอ็กทีฟคอนทัวร์โมเดล

(ที่มา: [http://scikit-image.org/docs/dev/auto\\_examples/edges/plot\\_active\\_contours.html](http://scikit-image.org/docs/dev/auto_examples/edges/plot_active_contours.html))

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2.6 การปรับเท่าฮิสโตแกรมแบบปรับตัว (Adaptive Histogram Equalization)

CLAHE คือ วิธีการเพิ่มคุณภาพของภาพ ซึ่งมีการพัฒนามาจาก Histogram Equalization (HE) โดย S.M. Pizer (S. M. Pizer, et. al, 1990) วิธีการนี้จะพิจารณารายละเอียดข้อมูลจาก HE ในแต่ละค่าพิกเซลบนบริเวณพื้นส่วนกลางของภาพต้นฉบับ โดยค่าฮิสโตแกรมที่มีระดับสูงกว่าค่าเฉลี่ย จะถูกนำมากระจายให้กับทุกพิกเซลในภาพ Grayscale ซึ่งแทนด้วยตัวแปร  $N_{clip}$



ภาพที่ 2.11 ภาพแสดงการปรับเท่าฮิสโตแกรมแบบปรับตัว

(ก) ค่าฮิสโตแกรมต้นฉบับ (ข) ค่าฮิสโตแกรมที่ถูกตัด

(ที่มา พิเชษ วัชระสุน, 2556)

ค่าฮิสโตแกรมนี้จะมีความแตกต่างจากค่าฮิสโตแกรมอื่นโดยผู้ใช้งานสามารถกำหนดระดับความหนาแน่นของค่าพิกเซลได้ วิธีการดังกล่าวสามารถแสดงดังสมการ

$$N_{aver} = \frac{N_{CR-X_p} * N_{CR-Y_p}}{N_{gray}}$$

- $N_{aver}$  คือ ค่าเฉลี่ยพิกเซล  
 $N_{gray}$  คือ หมายเลขของค่า Grayscale ในแต่ละพื้นที่  
 $N_{CR-X_p}$  คือ หมายเลขของพิกเซลใน X มิติในแต่ละพื้นที่นั้น ๆ  
 $N_{CR-Y_p}$  คือ หมายเลขใน Y มิติของพื้นที่นั้น ๆ

จากพื้นฐานของสมการที่  $N_{CL}$  สามารถคำนวณจากสมการ

$$N_{CL} = N_{clip} * N_{aver}$$

โดย

$N_{CL}$  คือ ค่าระดับการตัดจริง

$N_{clip}$  คือ ค่าสูงสุดต่าง ๆ ในระดับ Grayscale ของค่าเฉลี่ยพิกเซลในค่าระดับ  $N$  คือค่าสูงสุด

ต่าง ๆ ในระดับ Grayscale ของค่าเฉลี่ยพิกเซลตามลักษณะพื้นที่นั้น ๆ โดยค่าฮิสโตแกรมจากภาพเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ต้นฉบับเมื่อหมายเลขของพิกเซลมีค่ามากกว่า  $N_{clip}$  พิกเซลนั้นจะถูกตัดจากนั้นค่าพิกเซลจะถูกกระจายไปยังทุกพิกเซลในระดับ Gray ดังสมการนี้

$$N_{cap} = \frac{N_{\Sigma clip}}{N_{gray}}$$

โดย  $N_{cap}$  คืออัตราส่วนระหว่างผลรวมของฮิสโตแกรมต่อค่าสีระดับเทาจากพื้นฐานของสมการข้างต้นสามารถคำนวณค่าระดับของฮิสโตแกรมในแต่ละพื้นที่จากกฎดั้งเดิม

*If*  $HCR(i) > N_{CL}$   $HNCR(i) = N_{CL}$ ;  
*Else if*  $HCR(i) + N_{cap} \geq N_{CL}$   $HNCR(i) = N_{CL}$ ;  
*Else*  $HNCR(i) = HCR(i) + N_{cap}$ ;

โดย

$HCR(i)$

คือ หมายเลขของแต่ละพิกเซลในระดับ Gray ของพื้นที่นั้น ๆ

$i$

คือ หมายเลขของค่าในระดับ Gray หลังจากกระจายค่าฮิสโตแกรมใหม่ให้กับทุกพิกเซลในระดับ Gray ดังสมการนี้

$$S = \frac{N_{gray}}{N_{LP}}$$

โดย

$S$

คือ ค่าฮิสโตแกรมใหม่ที่กระจายให้ทุกพิกเซล


$N_{LP}$

คือ ค่าพิกเซลที่ตัดมาเพื่อใช้คำนวณใหม่

## 2.7 โครงข่ายประสาทเทียมแบบคอนโวลูชันนอลเชิงลึก

เป็นการเรียนรู้เชิงลึกประเภทหนึ่ง โดยพัฒนาต่อยอดมาจาก เพอร์เซ็ปตรอนหลายชั้น (Multi-layer Perceptron) การเรียนรู้เชิงลึกมีแนวคิดที่มีการเรียนรู้แบบ End-to-end คือ เรียนรู้ทุกกระบวนการของการทำงาน ตั้งแต่ข้อมูล Input จนถึงการทำนายผลลัพธ์ ซึ่งมีรูปแบบการเรียนรู้แบบลำดับชั้น (Hierarchy) ในปัญหาพิเศษพิเศษนี้ถูกนำมาใช้กับข้อมูลที่เป็นรูปภาพ สิ่งที่ขั้นตอนวิธีนี้ทำได้คือการเรียนรู้ตั้งแต่ระดับ จุดภาพ (Pixel) ลวดลาย (Motif) ส่วน (Part) จนไปถึงวัตถุ (Object) โดยความสามารถที่โครงข่ายประสาทเทียมแบบคอนโวลูชันนอลเชิงลึกได้พัฒนาต่อจากเพอร์เซ็ปตรอนหลายชั้นนั่นก็คือ การเรียนรู้คุณลักษณะ (Feature Learning) และนำคุณลักษณะที่ได้ไปเป็นข้อมูล Input สำหรับโครงข่ายประสาทเทียมเพื่อเข้าสู่กระบวนการจำแนก (Classification) แสดงการทำงานได้ดังภาพที่ 2.12

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




ภาพที่ 2.12 การทำงานของโครงข่ายประสาทแบบคอนโวลูชันนอลเชิงลึก

จากภาพที่ 2.12 จะเห็นได้ว่าการทำงานหลักจะแบ่งเป็น 2 ส่วน คือ การเรียนรู้คุณลักษณะ (Feature Learning) และ การจำแนก (Classification)

ต่อไปจะอธิบายถึงขั้นตอนการเรียนรู้คุณลักษณะ ซึ่งประกอบไปด้วย Convolutional Layer, ReLU (Rectified Linear Unit) Layer, Pooling Layer และ Fully Connected Layer ซึ่งเป็นส่วนประกอบหลักที่สำคัญโดยรายละเอียดของแต่ละส่วนจะถูกอธิบายในหัวข้อ 2.7.1 – 2.7.4

### 2.7.1 Convolutional Layer

เป็นขั้นตอนแรกซึ่งในขั้นนี้จะมีขั้นตอนใน การหาคุณลักษณะ (Feature Extraction) จากรูปภาพโดยใช้สิ่งเรียกว่า Filters ซึ่งจะทำให้การเลื่อนผ่านไปตามข้อมูล Input matrix เพื่อให้ได้คุณลักษณะของข้อมูลออกมา ซึ่งขนาดของ Filters ที่นิยมใช้จะมีขนาด  $n \times n$  ข้างในประกอบไปด้วย Parameters แต่ละช่อง ซึ่งขนาดของ Filters จะต้องน้อยกว่าขนาดของข้อมูล ซึ่งการเลื่อนไปแต่ละครั้งจะมีการทำ Convolution Operation ด้วยการคูณเพื่อนำคุณลักษณะออกมาแสดงดังภาพที่ 2.13

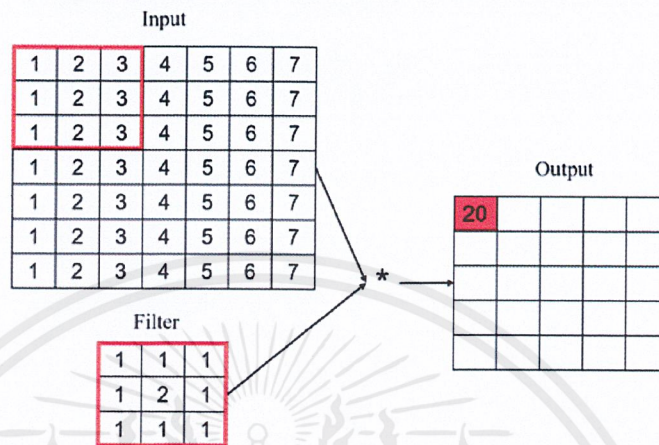


$$z_{ij} = \sum_m \sum_n x_{i+m, j+n} w_{mn}$$

ภาพที่ 2.13 สมการการทำ Convolution Operation ด้วยการคูณ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Parameters แต่ละช่องใน Filters อาจจะมาจากการสุ่มหรือกำหนดค่าขึ้นมาเองก็ได้ ซึ่งแต่ละ Neuron จะมีค่า Parameters ของ Filters ที่แตกต่างกันเพื่อหา Feature



ภาพที่ 2.14 ตัวอย่างการทำ Convolution Operation ด้วยการคูณ Filters จะทำการเลื่อนไปตามภาพเรื่อย ๆ จนครบ Input Matrix แต่ละ Neuron ใน Convolutional Layer จะแสดงคุณลักษณะแต่ละส่วนของภาพแตกต่างกันไป ในขั้นแรก ๆ จะได้ Low-level Features และค่อย ๆ ละเอียดเพิ่มขึ้นตามลำดับชั้น Convolutional Layer ต่อไป

### Zero Padding

จากภาพที่ 2.14 จะเห็นว่า Output ที่ได้จาก Convolutional Layer จะมีขนาดเล็กลง ยิ่งจำนวนชั้นมาก จะยิ่งทำให้เล็กลงเรื่อย ๆ วิธีการ Zero Padding จะทำให้จำนวนของ Input มีขนาดเท่ากับ Output โดยการเพิ่ม 0 ไปใน Input Matrix แสดงดังภาพที่ 2.15

0	0	0	0	0	0	0	0	0
0								0
0								0
0								0
0								0
0								0
0								0
0								0
0								0
0	0	0	0	0	0	0	0	0


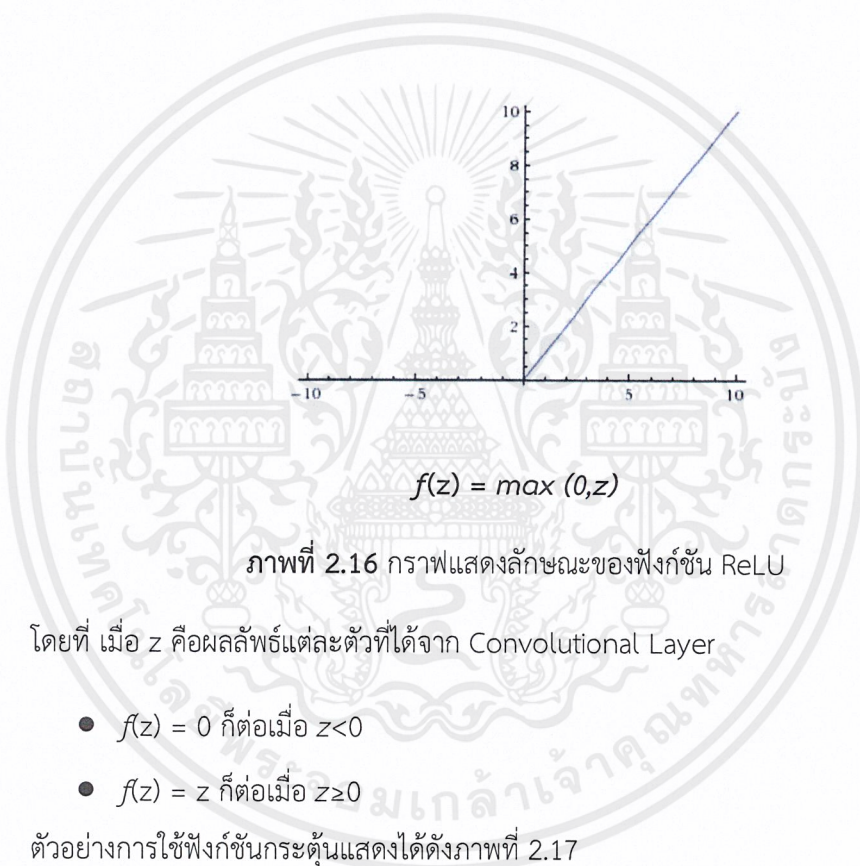
ภาพที่ 2.15 การทำ Zero Padding

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 2.7.2 ReLU (Rectified Linear Unit) Layer

เป็นขั้นตอนที่สองสำหรับการเรียนรู้คุณลักษณะชั้นที่ใช้ฟังก์ชันกระตุ้นซึ่งนิยมใช้สำหรับโครงข่ายประสาทแบบคอนโวลูชันนอลเชิงลึก ซึ่งนำ Output จาก Convolutional Layer มาผ่านฟังก์ชันกระตุ้น โดยกราฟแสดงลักษณะของฟังก์ชัน ReLU แสดงดังภาพที่ 2.16

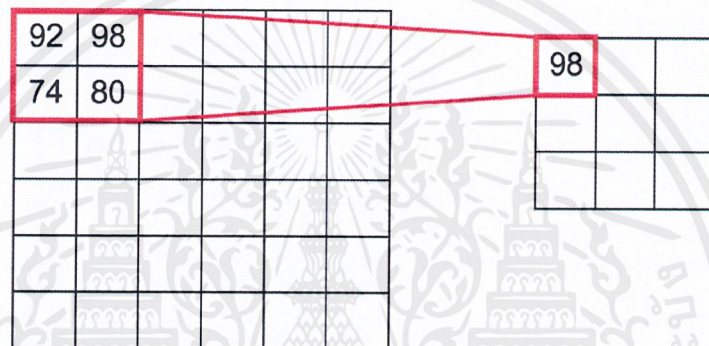
ReLU



ภาพที่ 2.17 ตัวอย่างการปรับค่าด้วยฟังก์ชันกระตุ้น ReLU

### 2.7.3 Pooling Layer

เป็นขั้นตอนที่สามในการเรียนรู้คุณลักษณะ จุดประสงค์ของขั้นตอนนี้มีเพื่อทำการลดขนาดของข้อมูล ที่ได้จาก ReLU Layer โดยการลดจำนวน Parameters ของ Matrix และเพื่อต้องการลดการคำนวณ ให้การทำงานของงานของโครงข่ายประสาทเทียมมีประสิทธิภาพมากขึ้น โดยการนำ Filters เลื่อนผ่านไปตาม Matrix และดำเนินการตามวิธีต่าง ๆ โดยที่นิยมใช้คือ Max Pooling ซึ่งเป็นการเลือกค่าที่มากที่สุดในทุก ๆ ช่องที่ Filters ทำการเลื่อนผ่าน แสดงดังภาพที่ 2.18




ภาพที่ 2.18 การทำ Max Pooling

หลังจากเสร็จขั้นตอนที่สาม จะได้คุณลักษณะของข้อมูลเพื่อนำไปสู่ขั้นตอนที่สี่คือการจำแนกประเภท

### 2.7.4 Fully Connected Layer

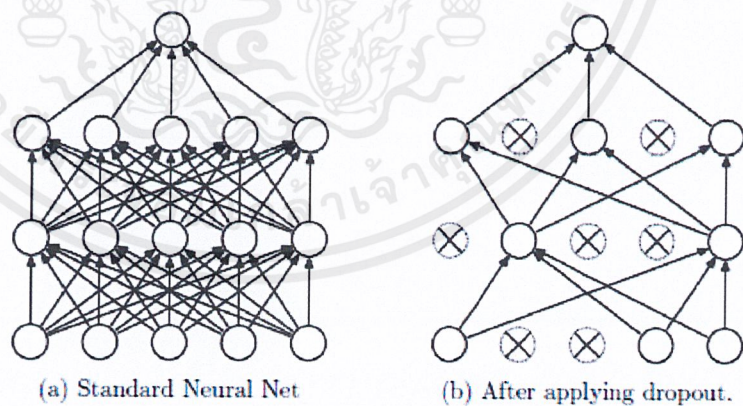
ขั้นนี้จะเป็นขั้นตอนสุดท้ายสำหรับการทำโครงข่ายประสาทแบบคอนโวลูชันนอลเชิงลึก หลังจากที่ได้คุณลักษณะโดยผ่าน Convolutional Layer , ReLU Layer และ Pooling Layer ตามลำดับ Output ที่ได้จะนำไปสู่กระบวนการเรียนรู้เพื่อสร้างโมเดลที่ใช้ในการจำแนกโดยใช้โครงข่ายประสาทเทียมแบบเพอร์เซ็ปตรอนหลายชั้น (Multi-Layer Perceptron) โดย Output ที่ได้เป็นเวกเตอร์ N มิติ โดยที่ N คือจำนวนคลาสของสิ่งที่ต้องการจะทำนาย การทำโครงข่ายประสาทเทียมใน Fully Connected Layer แสดงดังภาพที่ 2.19



ภาพที่ 2.19 การทำโครงข่ายประสาทเทียมใน Fully Connected Layer

### Dropout

เป็นการทำ Regularization เพื่อลดอัตราการเกิดปัญหา Overfitting ซึ่งจะสุ่มตัด Neuron บาง Node ของโครงข่ายประสาทเทียมเพื่อไม่ให้เกิดการเรียนรู้มากเกินไป เพราะการเรียนรู้อาจทำได้ดีถ้าทดสอบด้วยข้อมูลชุดเดียวกัน แต่ตอนทดสอบกับข้อมูลที่ไม่เคยเจอหรือข้อมูลแปลกใหม่อาจจะทำนายไม่แม่นยำ ตัวอย่างโครงข่ายก่อนทำและหลังทำ Dropout แสดงดังภาพที่ 2.20




ภาพที่ 2.20 โครงข่ายก่อนและหลังทำ Dropout

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2.8 โครงข่ายประสาทเทียมแบบคอนโวลูชันอลเชิงลึกสามมิติ

ภาพสแกนสมองแบบ MRI บันทึกลงอยู่ในรูปแบบภาพสองมิติหลาย ๆ ภาพประกอบกัน ส่วนของโพรงสมองด้านข้าง (Lateral Ventricles) ที่แสดงบนภาพ MRI จะอยู่เป็นช่วงของภาพที่แสดงทั้งหมด ดังนั้นเมื่อทำการตัดโพรงสมองด้านข้างออกมา จะได้ภาพส่วนที่ปรากฏโพรงสมองด้านข้างในรูปแบบภาพสองมิติหลาย ๆ ภาพต่อกันเป็นจำนวน  $n$  ภาพต่อรูป ( $n$  แปรผันตามขนาดของโพรงสมองด้านข้าง) ซึ่งถูกเก็บอยู่ในรูปแบบของภาพสามมิติ หรืออาร์เรย์สามมิติ (3-D Arrays) ที่เป็นไบนารี การใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันอลเชิงลึก (หัวข้อ 2.7) ในงานที่เป็นภาพสามมิตินั้นมีสถาปัตยกรรมโดยรวมของโครงข่ายไม่ต่างกับการดำเนินการด้วยภาพสองมิติ แต่จะมีส่วนที่เพิ่มเติมมาคือ การหาคุณลักษณะ (Feature Extraction) สำหรับภาพสามมิตินั้นจะต้องพิจารณาความลึกด้วย สถาปัตยกรรมเน็ตเวิร์ค (Network Architecture) ที่ถูกเลือกใช้สำหรับงานนี้มี 2 ชนิด ได้แก่ 3D CNNs: VoxNet และ 3-D NIN (3-Dimension Network in Network) ซึ่งแสดงในหัวข้อที่ 2.8.1 และ 2.8.2 โดยทั้งหมดที่กล่าวมานี้มีการหาคุณลักษณะ (Feature Extraction) กับข้อมูลในเชิงปริมาตร (Volumetric) ซึ่งข้อมูลจะแสดงอยู่ในรูปแบบของ Voxel ตัวอย่างภาพ Lateral Ventricles แสดงในภาพที่ 2.21




ภาพที่ 2.21 Volumetric Display of Lateral Ventricles

### 2.8.1 3D CNNs: VoxNet

VoxNet เป็นโมเดลหนึ่งที่ใช้กับจัดการกับข้อมูลที่เป็นภาพสามมิติได้ เริ่มต้นถูกนำมาใช้กับข้อมูลที่มีจุดเริ่มต้นเป็น Point Cloud ที่เป็นเชิงปริมาตร (Volumetric Representation) ขั้นตอนต่อไปจะถูกทำให้อยู่ในรูปแบบของคู่อันดับของ Voxel ที่จำกัด

เอกสารนี้เป็นเอกสาร (Discrete Voxel Coordinates) ซึ่งเป็นรูปแบบข้อมูลที่มีความคล้ายกับโพรงสมองด้านข้าง ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ที่ถูกเตรียมไว้สำหรับเป็น Input สำหรับขั้นตอนวิธีอื่นๆ โดยภาพการจำลองสถาปัตยกรรมของ 3D CNNs: VoxNet แสดงดังภาพที่ 2.22



ภาพที่ 2.22 ภาพการจำลองสถาปัตยกรรมของ 3D CNNs: VoxNet

VoxNet มี Input Layer ที่รับ Input ที่มีค่าตายตัวขนาด  $I \times J \times K$  ซึ่งแต่ละค่าของเซลล์กริด (Grid Cell) จะถูกอัปเดตด้วยสมการที่เท่ากับ 1 2 หรือ 3 ลบด้วย 0.5 และคูณด้วย 2 ซึ่งจะทำให้ค่าอยู่ระหว่าง -1 ถึง 1

Convolutional Layers  $C(f, d, s)$  เลเยอร์เหล่านี้รับ Input ที่เป็นสี่มิติ โดยสามมิติแรกเป็นข้อมูลเชิงพื้นที่ และเลเยอร์ที่สี่เป็นส่วนหนึ่งของ Feature Maps เลเยอร์ดังกล่าวจะสร้าง  $f$  Feature Maps โดยการรวมกันของ Input ที่ทำคอนโวลูชัน กับ  $f$  ซึ่งเป็น Filters ที่ได้รับการเรียนรู้ของสัดส่วน  $d \times d \times d \times f'$  โดยที่  $d$  คือมิติเชิงพื้นที่ (Spatial Dimensions) และ  $f'$  คือจำนวนของ Input ของ Feature Maps ส่วนคอนโวลูชันสามารถถูกประยุกต์ที่ Spatial Stride  $s$  ด้วย และ Output ที่ได้จะผ่านฟังก์ชันกระตุ้น Rectified Nonlinear Unit (ReLU)

Pooling Layers  $P(m)$  เลเยอร์เหล่านี้จะลดปริมาณการป้อนข้อมูลลงตามขนาดของ  $m$  พร้อมกับมิติเชิงพื้นที่ (Spatial Dimensions) โดยการแทนที่แต่ละบล็อกที่ไม่ทับซ้อนกันของ Voxel สูงสุด ทั้งหมดขนาด  $m \times m \times m$

Fully Connected Layer  $FC(n)$  สำหรับ Fully Connected Layer มี Output จำนวน  $n$  นิวรอน ซึ่ง Output แต่ละนิวรอนคือการรวมกันเชิงเส้นที่ถูกเรียนรู้ (Learned Linear Combination) ของ Output ทั้งหมดจากเลเยอร์ก่อนหน้าผ่านส่วนที่ไม่เป็นเชิงเส้น (Nonlinearity) ReLU จะถูกใช้สำหรับการบันทึกเลเยอร์สุดท้าย เมื่อจำนวนของ Output

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สอดคล้องกับจำนวนของประเภทที่ใช้ทำนาย (Class Labels) และ Softmax Nonlinearity จะถูกใช้สำหรับการให้ Output ที่น่าจะเป็น

### 2.8.2 3D NIN FC (3-Dimensional Network in Network Full Connected)

3D NIN FC มีพื้นฐานโครงสร้างมาจาก NIN (Network in Network) เป็นโมเดลการเรียนรู้เชิงลึกประเภทหนึ่งที่โครงสร้างของตัวโครงข่ายนั้นถูกพัฒนาต่อยอดมาจากโครงข่ายประสาทเทียมแบบคอนโวลูชันนอลเชิงลึกแบบทั่วไป โมเดลนี้ทำการเพิ่มความสามารถในการจำแนกรูปแบบสำหรับ Local Patches ภายใน Receptive Field โครงข่ายประสาทเทียมแบบคอนโวลูชันนอลเชิงลึกแบบทั่วไปใช้ Filter ที่เป็นเชิงเส้น (Linear Filters) ตามด้วยฟังก์ชันกระตุ้นที่ไม่เป็นเชิงเส้น (Nonlinear Activation Function) เพื่อทำการแสดกน Input แต่ NIN มีโครงข่ายประสาทเทียมขนาดย่อม (Micro Network) ที่มาพร้อมกับโครงสร้างที่ซับซ้อนมากขึ้นเพื่อทำการสรุปข้อมูลใน Receptive Field


โครงข่ายประสาทเทียมแบบคอนโวลูชันนอลเชิงลึกประกอบไปด้วยชั้นคอนโวลูชัน (Convolution Layers) ต่าง ๆ และ Pooling Layers ซึ่งชั้นคอนโวลูชันได้ใช้ส่วนประกอบที่อยู่ภายในของ Linear Filter และเป็นรากฐานของ Receptive Field ที่ตามด้วยฟังก์ชันกระตุ้นที่ไม่เป็นเชิงเส้น (Nonlinear Activation Function) ในทุก ๆ ส่วนในแต่ละส่วนของ Input ซึ่งผลลัพธ์ที่ได้จะถูกเรียกว่า Feature Maps

Convolution Filter ใน CNN คือโมเดลเชิงเส้นทั่วไป (Generalized Linear Model หรือ GLM) สำหรับการเป็นรากฐานของ Data Patch และผู้คิดค้นวิธีนี้ได้ทำการโต้แย้งว่าระดับของสิ่งที่เป็นนามธรรมนั้นต่ำด้วยรูปแบบเชิงเส้นทั่วไป โดยนามธรรมที่ว่านั้นหมายถึงคุณลักษณะ (Feature) นี้ไม่สอดคล้องกับรูปแบบของแนวคิดเดียวกัน ดังนั้นการแทนที่ GLM ด้วยตัวประมาณฟังก์ชันที่ไม่ใช่เชิงเส้นที่มีศักยภาพมากขึ้น (Nonlinear Function Approximator) สามารถเพิ่มความสามารถที่เป็นนามธรรมของแต่ละส่วนของโมเดล GLM สามารถบรรลุขอบเขตของสิ่งที่เป็นนามธรรมได้ดี เมื่อนำตัวอย่างของแนวคิดที่ซ่อนอยู่นี้สามารถแบ่งออกได้ด้วยเส้นตรง (Linearly Separable) ตัวแปรของแนวคิดนี้ทั้งหมดที่อยู่บนด้านใดด้านหนึ่งของระนาบที่แบ่งออก (Separation Plane) โดย GLM ดังนั้น CNN โดยทั่วไปจะสร้างสมมติฐานโดยปริยายว่า แนวคิดที่ซ่อนอยู่นั้นจะถูกแยกออก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากกันโดยเส้นตรง (Linearly Separable) อย่างไรก็ตามข้อมูลสำหรับแนวคิดเดียวกันมักจะอยู่บนสิ่งที่ไม่เป็นเชิงเส้นทั้งหลาย ดังนั้นการแสดงที่รักษาแนวคิดเหล่านี้เอาไว้โดยทั่วไปเป็นหน้าที่ของฟังก์ชันที่ไม่เป็นเชิงเส้นของ Input ใน NIN นี้ GLM จะถูกแทนที่ด้วยโครงสร้างเครือข่ายขนาดย่อม (Micro Network Structure) ซึ่งเป็นตัวประมาณการฟังก์ชันที่ไม่เป็นเชิงเส้นทั่วไป (Nonlinear Function Approximator) ซึ่งในงานนี้ได้เลือกเพอร์เซ็ปตรอนหลายชั้น (Multi-layer perceptron) ที่ใช้กันอย่างแพร่หลายมาเป็นโครงข่ายขนาดย่อมเพื่อเป็นการแสดงตัวอย่าง และโครงข่ายมีการเรียนรู้และปรับค่าน้ำหนักแบบ Back-propagation


ผลลัพธ์ที่ได้จากโครงสร้างที่กล่าวมาข้างต้นนี้ถูกเรียกว่า Mlpconv Layers ซึ่งถูกเปรียบเทียบกับ CNN ในภาพที่ 2.23 ทั้ง Linear Convolutional Layer และ Mlpconv Layer นั้นจะแมป Local Receptive Field ไปสู่ Output Feature Vector และ Mlpconv จะแมป Input Local Patch ไปสู่ Output Feature Vector ด้วยกับเพอร์เซ็ปตรอนหลายชั้นซึ่งในนั้นประกอบไปด้วย Multiple Fully Connected Layers ด้วยกับฟังก์ชันกระตุ้นที่ไม่เป็นเชิงเส้น (Nonlinear Activation Function) เพอร์เซ็ปตรอนหลายชั้นจะถูกแบ่งไปตาม Local Receptive Fields ทั้งหมด ส่วน Feature Map จะได้มาจากเพอร์เซ็ปตรอนหลายชั้น



ภาพที่ 2.23 การเปรียบเทียบระหว่าง Linear Convolution Layer และ Mlpconv Layer

จากภาพที่ 2.23 ส่วนของ Linear Convolution Layer ประกอบไปด้วย Linear Filter แต่ในขณะที่ Mlpconv Layer ประกอบไปด้วยโครงข่ายขนาดย่อมซึ่งในนี้ใช้เพอร์เซ็ปตรอนหลายชั้น

โครงสร้างโดยรวมของ NIN คือการซ้อนกันของ Mlpconv Layers เรียกว่า "Network In Network" (NIN) เนื่องจากเรามีเครือข่ายขนาดเล็ก (เพอร์เซ็ปตรอนหลายชั้น) ซึ่งประกอบไปด้วยองค์ประกอบของเครือข่ายเล็กโดยรวมภายใน Mlpconv Layers โครงสร้างโดยรวมของ NIN แสดงในภาพที่ 2.24



ภาพที่ 2.24 โครงสร้างโดยรวมทั้งหมดของโครงข่าย NIN

## 2.9 งานวิจัยที่เกี่ยวข้อง

หัวข้อนี้จะกล่าวถึงงานวิจัยที่เกี่ยวข้องซึ่งประกอบไปด้วยงานวิจัยเรื่อง 3-D MRI Brain Scan Feature Classification Using an Oct-tree Representation, 3-D Volume of Interest Based Image Classification และ Graph-Based Shape Analysis for MRI Classification ซึ่งแต่ละงานวิจัยจะถูกกล่าวถึงในหัวข้อ 2.9.1 – 2.9.3

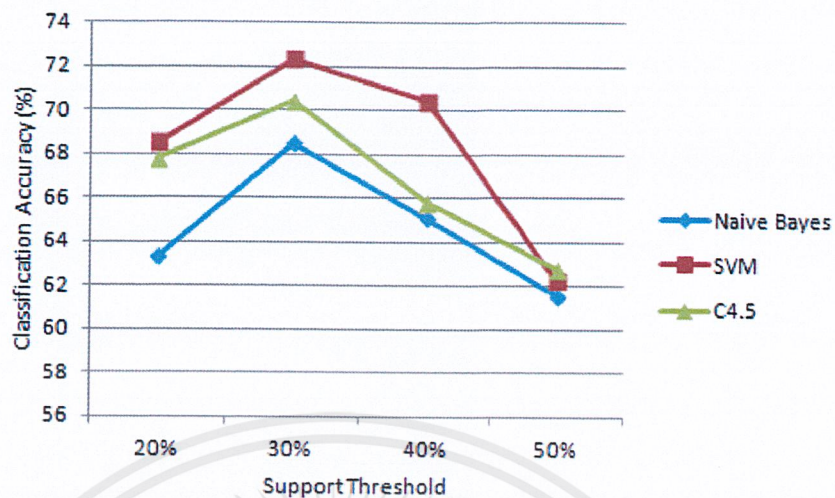
### 2.9.1 3 - D MRI Brain Scan Feature Classification Using an Oct-tree Representation

ในงานวิจัยฉบับนี้ได้ทำการจำแนกตามคุณลักษณะสำหรับภาพสแกนสมองแบบ MRI วิธีการที่ใช้ได้แก่ เทคนิคการแบ่งส่วน Bounding Box เทคนิคการแทนข้อมูล Oct-tree และการใช้ FSM (Frequent Sub-graphs Mining) ด้วยค่า Support Thresholds ที่ 20%, 30%, 40% และ 50% เพื่อระบุคุณสมบัติ ซึ่งผลการทดลองคือเทคนิค Bounding Box และ นำคุณลักษณะ (Feature) ใช้รูปแบบ Oct-tree และ โดยจำนวนภาพโพรงสมองประกอบไปด้วย ภาพโพรงสมองของคนที่มีสุขภาพปกติ 105 ภาพ และคนที่เป็นโรคลมชัก (Epilepsy) 105 ภาพ ใช้วิธีการ Naive Bayes, Support Vector Machine (SVM) และ Decision Trees ได้ผลลัพธ์ตามภาพที่ 2.21

T(%)	Naive Bayes			SVM			Decision Trees		
	Accu.	Sens.	Spec.	Accu.	Sens.	Spec.	Accu.	Sens.	Spec.
20	64.34	67.25	66.80	68.53	70.40	68.23	67.83	70.58	68.67
30	68.53	70.40	69.23	72.34	75.67	70.45	70.45	74.28	73.20
40	65.13	68.57	70.34	70.45	72.34	69.23	65.87	70.47	65.40
50	61.56	65.40	64.15	62.28	66.96	60.67	62.80	67.05	64.15

ตารางที่ 2.2 ตารางแสดงผลลัพธ์ในงานวิจัย 3-D MRI Brain Scan Feature Classification Using an Oct-tree Representation

จากภาพที่ 2.25 แสดงให้เห็นว่าวิธีการที่แม่นยำที่สุดในการจำแนกคือ Support Vector Machine (SVM)



ภาพที่ 2.25 กราฟเปรียบเทียบผลลัพธ์แต่ละวิธีการที่ใช้จำแนกในงานวิจัย 3-D MRI Brain Scan Feature Classification Using an Oct-tree Representation

### 2.9.2 3-D Volume of Interest Based Image Classification

ในงานวิจัยฉบับนี้ได้ทำการจำแนกตามคุณลักษณะสำหรับภาพสแกนสมองแบบ MRI เทคนิคที่ใช้ในการจัดกลุ่มตามลักษณะเฉพาะของโพรงสมองด้านข้างซึ่งใช้ 3 วิธีในการจัดกลุ่ม ได้แก่ Statistical Metric Based, Point Series Based (Disc Based และ Spoke Base) และ Tree-based โดยใช้ชุดข้อมูลผู้ที่เป็นโรคลมชัก (Epilepsy) และนักดนตรี (Musician) จะถูกนำมาวิจัย 2 อย่าง คือ ผู้ป่วยโรคลมชัก (Epilepsy) กับคนสุขภาพดี (Healthy) และนักดนตรี (Musician) กับไม่ใช่ นักดนตรี (Non-musician) ผลลัพธ์ของชุดข้อมูลของผู้ที่เป็นนักดนตรี (Musician) แสดงในตารางที่ 2.3 และผู้ที่เป็นโรคลมชัก (Epilepsy) แสดงในตารางที่ 2.4

Technique	Accu.	Sens.	Spec.
SMB	69.89	71.77	68.00
DB	77.36	81.13	75.47
SB	82.39	<b>88.68</b>	79.25
TB	<b>86.32</b>	87.74	<b>80.19</b>

ตารางที่ 2.3 ตารางแสดงผลลัพธ์การจำแนกสำหรับชุดข้อมูลนักดนตรี (Musician)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Technique	Accu.	Sens.	Spec.
SMB	60.63	63.56	57.16
DB	62.20	67.50	57.14
SB	69.81	71.70	67.92
TB	<b>72.34</b>	<b>75.67</b>	<b>70.45</b>

ตารางที่ 2.4 ตารางแสดงผลลัพธ์การจำแนกสำหรับชุดข้อมูลโรคลมชัก (Epilepsy)

จากตารางที่ 2.3 แสดงให้เห็นว่าวิธี Tree-based ได้ค่า Accuracy และ Specificity มากที่สุด และวิธี Spoke Based ได้ค่า Specificity มากที่สุด

ในส่วนของตารางที่ 2.4 แสดงให้เห็นว่าวิธี Tree-based ได้ค่า Accuracy, Sensitivity และ Specificity มากที่สุด

### 2.9.3 Graph-Based Shape Analysis for MRI Classification

ในงานวิจัยนี้เกี่ยวข้องกับการแบ่งส่วนโพรงสมองด้านข้างร่วมกับโพรงสมองที่สาม โดยใช้วิธีการกำหนดค่าขีดแบ่งแบบพลวัต ซึ่งเป็นการปรับค่าขีดแบ่งที่ละรูป ทำให้ใช้เวลาในการคำนวณค่อนข้างมาก อีกทั้งบทความดังกล่าวยังไม่ได้กล่าวถึงผลการประเมินความถูกต้องของการแบ่งส่วนโพรงสมองด้านข้างและโพรงสมองที่สาม เช่นเดียวกับบทความการประชุมวิชาการอื่น ๆ ในปัจจุบัน ยังไม่เคยมีการนำเสนอวิธีการประเมินผลการแบ่งส่วนของสมองแบบอัตโนมัติ นอกจากการให้แพทย์หรือผู้เชี่ยวชาญเป็นผู้ประเมิน

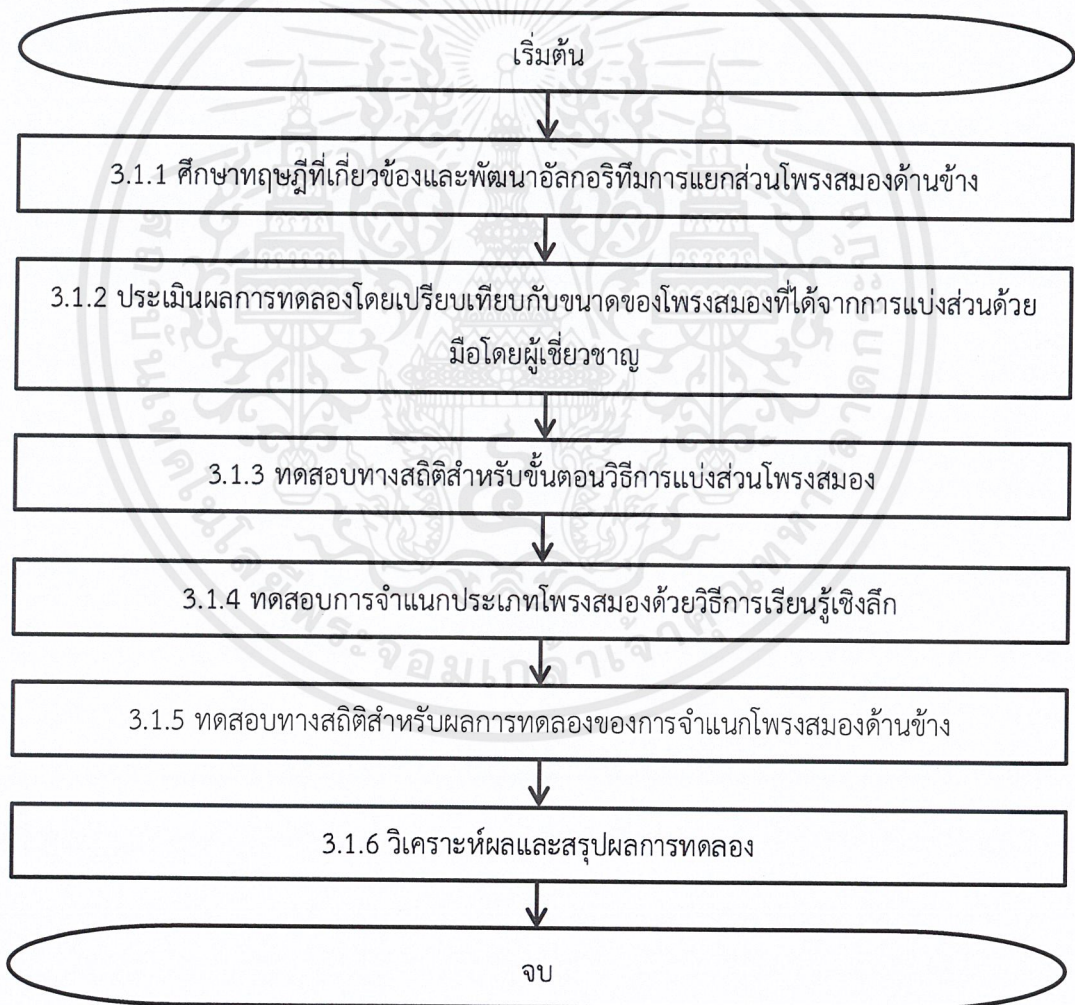
## บทที่ 3

### วิธีการดำเนินงาน

ในบทนี้จะกล่าวถึงวิธีการดำเนินงานซึ่งเป็นขั้นตอนการปฏิบัติงานทั้งหมดตั้งแต่เริ่มโครงการ ประกอบด้วย ระบบวิธีการดำเนินงาน และขั้นตอนการจำแนกโพรงสมองด้านข้าง

#### 3.1 ระเบียบวิธีการดำเนินงาน

ระเบียบการดำเนินงานของการจำแนกประเภทโพรงสมองด้านข้าง มีลำดับการดำเนินงาน แสดงดังภาพที่ 3.1



ภาพที่ 3.1 ระเบียบวิธีการดำเนินงานของการจำแนกประเภทโพรงสมองด้วยวิธีการเรียนรู้เชิงลึก

### 3.1.1 ศึกษาทฤษฎีที่เกี่ยวข้องและพัฒนาขั้นตอนวิธีการแยกส่วนโพรงสมองด้านข้าง

ศึกษาทฤษฎีที่เกี่ยวข้องซึ่งได้แก่ วิธีการปรับค่าความเข้มแสงของภาพ วิธีการกำหนดค่าขีดแบ่ง วิธีฟลัดฟิล วิธีแบ่งส่วนภาพออกเป็นพื้นหน้าและพื้นหลังด้วยวิธีแอกทีฟคอนทัวร์ และ การศึกษาเชิงสัมฐานวิทยา จากนั้นนำความรู้ที่ได้ไปพัฒนาและประยุกต์ใช้ให้ได้มาซึ่ง ขั้นตอนวิธีการแยกส่วนโพรงสมองด้านข้าง

### 3.1.2 ประเมินผลการทดลองโดยเปรียบเทียบกับขนาดของโพรงสมองที่ได้จากการแบ่งส่วนด้วยมือโดยผู้เชี่ยวชาญ

การประเมินผลการทดลองนี้จะใช้วิธีการแบ่งโพรงสมองด้านข้างด้วยมือโดยผู้เชี่ยวชาญเป็นมาตรฐานในการเปรียบเทียบขนาดของโพรงสมองด้านข้างที่ได้จากการทดลอง

### 3.1.3 ทดสอบทางสถิติสำหรับขั้นตอนวิธีการแบ่งส่วนโพรงสมอง

ขั้นตอนนี้จะใช้วิธีการทางสถิติเพื่อทดสอบว่า ขั้นตอนวิธีที่ทำขั้นนี้มีความแตกต่างกับวิธีการแบ่งโพรงสมองด้านข้างด้วยมือโดยผู้เชี่ยวชาญอย่างมีนัยสำคัญหรือไม่

### 3.1.4 ทดสอบการจำแนกประเภทโพรงสมองด้านข้างด้วยวิธีการเรียนรู้เชิงลึก

เตรียมการฝึกฝนด้วยเครือข่ายประสาทศัลยศาสตร์เพื่อสกัดรูปแบบของโพรงสมองด้านข้างสำหรับการนำไปจำแนกประเภทโพรงสมองด้านข้าง

### 3.1.5 ทดสอบทางสถิติสำหรับผลการทดลองของการจำแนกโพรงสมองด้านข้าง

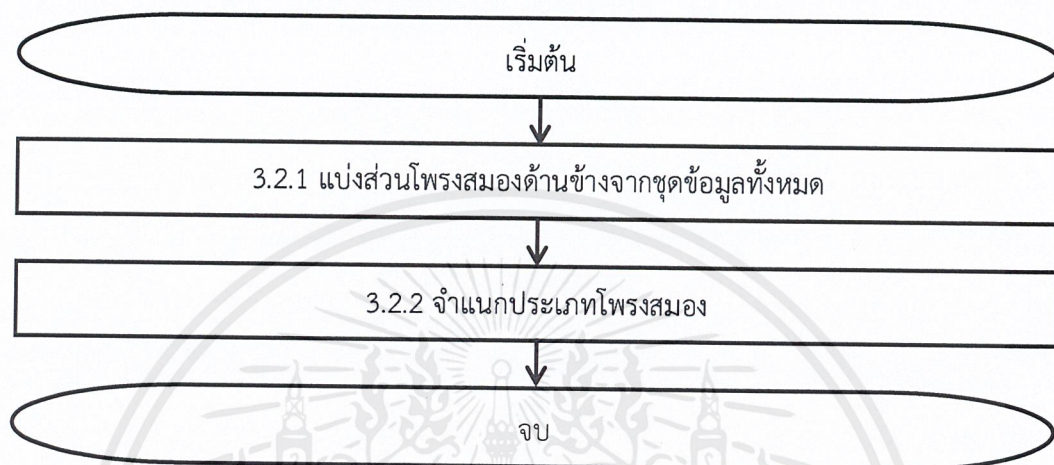
ขั้นตอนนี้จะใช้วิธีการทางสถิติเพื่อทดสอบว่า แต่ละขั้นตอนวิธีที่นำมาใช้สร้างโมเดลการจำแนกวิธีการไหนให้ผลการทดลองที่ดีที่สุดสำหรับข้อมูลชุดนี้ โดยพิจารณาจากผลการทดลองของขั้นตอนวิธีการที่นำมาใช้ในปัญหาพิเศษนี้และผลการทดลองจากงานวิจัยที่เกี่ยวข้อง

### 3.1.6 วิเคราะห์และสรุปผลการทดลอง

นำผลลัพธ์ที่ได้ทั้งหมดจากการดำเนินงานมาวิเคราะห์ และสรุปผล

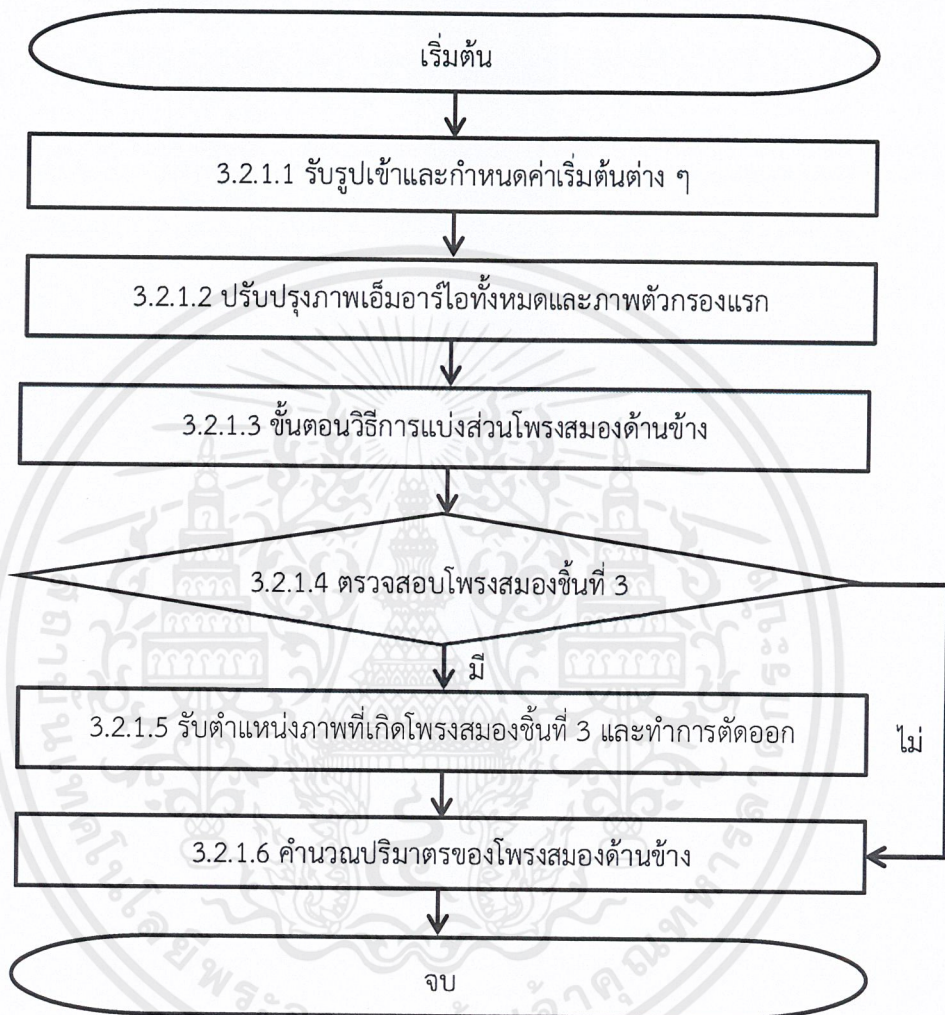
### 3.2 ขั้นตอนวิธีการจำแนกประเภทโครงสมองด้านข้าง

ขั้นตอนวิธีการจำแนกประเภทโครงสมองด้านข้างเริ่มจากการแบ่งส่วนโครงสมองด้านข้างของชุดข้อมูลทั้งหมดก่อนจากนั้นจึงจะทำการจำแนกประเภทโครงสมองด้านข้าง แสดงดังภาพที่ 3.2



ภาพที่ 3.2 ขั้นตอนวิธีการจำแนกประเภทโครงสมองด้านข้างด้วยวิธีการเรียนรู้เชิงลึก


3.2.1 การแบ่งส่วนโพรงสมองด้านข้างจากชุดข้อมูลทั้งหมด  
ขั้นตอนวิธีแบ่งส่วนโพรงสมองด้านข้างมีขั้นตอน แสดงดังภาพที่ 3.3



ภาพที่ 3.3 ขั้นตอนวิธีการแบ่งส่วนโพรงสมองด้านข้าง

### 3.2.1.1 รับค่า Input

ส่วนนี้จะรับค่า Input ซึ่งได้แก่ชื่อไฟล์ (Name) ค่าขีดแบ่ง (Thresholding) ช่วงที่เกิดโพรงสมองด้านข้าง (Start, End) และ ตำแหน่งภาพตัวกรองแรก (First\_Mask) โดยภาพที่ 3.4 แสดงให้เห็นจุดเริ่มของภาพที่เกิดโพรงสมองด้านข้าง จนถึงภาพสุดท้าย



ภาพที่ 3.4 ภาพแสดงลำดับการเกิดโพรงสมองด้านข้าง

(ก) ภาพที่เริ่มเกิดโพรงสมองด้านข้าง


(ข) ภาพสุดท้ายที่เกิดโพรงสมองด้านข้าง

(ค) ภาพตัวกรองตัวแรก

### 3.2.1.2 ปรับปรุงภาพเอ็มอาร์ไอทั้งหมดและภาพตัวกรองแรก

ปรับค่าความเข้มแสงของภาพทั้งหมดด้วยวิธี Contrast-limited Adaptive Histogram Equalization (CLAHE) จากนั้นปรับปรุงภาพตัวกรองแรกโดยภาพที่

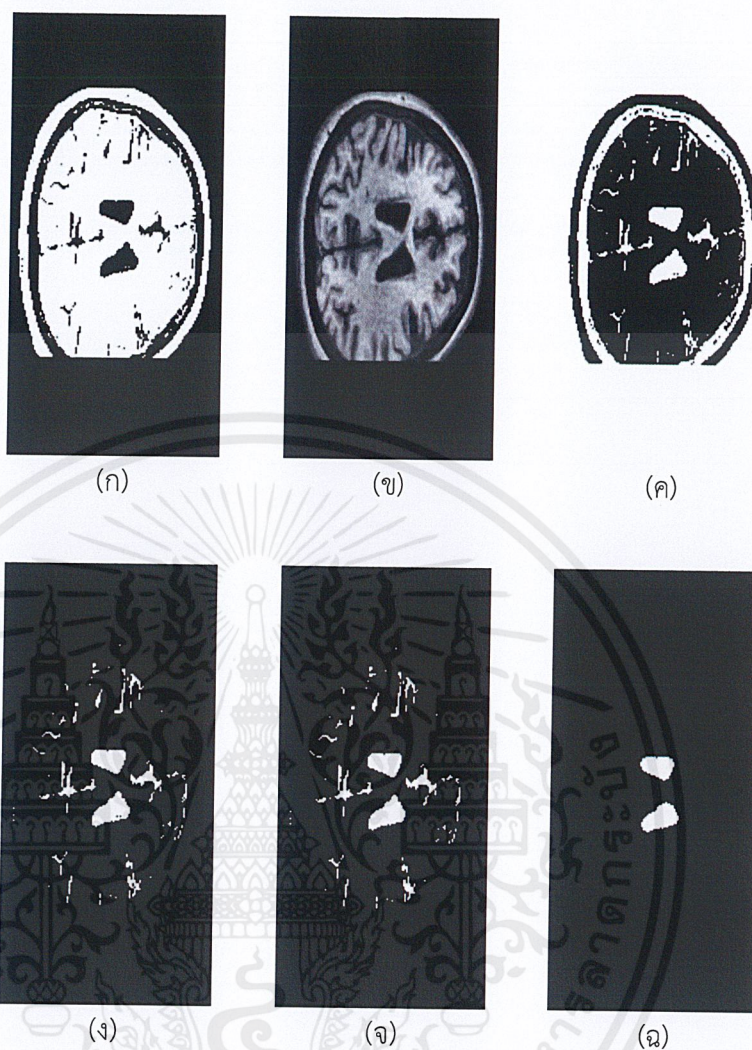
3.5 แสดงผลที่ได้จากการปรับค่าความเข้มแสงด้วยวิธี CLAHE



ภาพที่ 3.5 ภาพก่อนและหลังการปรับค่าความเข้มแสงด้วยวิธี CLAHE

(ก) ก่อนปรับความเข้มแสง (ข) หลังปรับความเข้มแสงด้วย CLAHE

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



- ภาพที่ 3.6 แสดงขั้นตอนการปรับปรุงตัวกรองแรก โดยมีขั้นตอนดังนี้
- (ก) ตัดขอบสมอง เพื่อให้เนื้อสมองที่ติดกับขอบภาพหายไปหลังจากการทำ Clear Border
  - (ข) กำหนดค่าขีดแบ่งที่ 0.25 ทำให้ภาพเป็นภาพขาวและดำ (ภาพไบนารี)
  - (ค) กลับส่วนของภาพ สลับค่าขาวดำทั้งหมด
  - (ง) การทำ Clear Border หรือ การตัดส่วนที่ติดกับขอบภาพซึ่งพิกเซลสีขาวที่เกิดขึ้นในภาพเป็นส่วนที่ไม่ได้ติดกับขอบภาพ
  - (จ) เติมพิกเซลสีขาวลงบนจุดสีดำที่ถูกล้อมรอบด้วยพิกเซลสีขาว
  - (ฉ) Open Mask with Disk Radius 3 หรือ การลบกลุ่มพิกเซลที่มีรัศมีต่ำกว่า 3 ออก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.2.1.3 ขั้นตอนวิธีการแบ่งส่วนโพรงสมองด้านข้าง

หลังจากรับค่า Input และ ผ่านขั้นตอนการปรับปรุงภาพในข้อ 3.2.1.1 และ 3.2.1.2 แล้วจะเข้าสู่ขั้นตอนการแบ่งส่วนโพรงสมองด้านข้างโดยรายละเอียดแสดงเป็นชุดโค้ดดังนี้

Algorithm for Lateral Ventricles Segmentation.

FOR p = End to Start

IF p >= First\_Mask

Threshold Image p

Mask = (p + First\_Mask) - p

Complement Image p

Clear Borders Image p

Fill Holes Image p

I = Active Contour Image p with Mask Image

Save I

ENDIF

IF p < First\_Mask

Threshold Image p

Mask = (p + First\_Mask) - p

Complement Image p

Clear Borders Image p

Fill Holes Image p

I = Active Contour Image p with Mask Image

Save I

Set Mask = I


ENDIF

ENDFOR

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.2.1.4 ตรวจสอบโพรงสมองชั้นที่ 3


พิจารณาจากโพรงสมองที่ได้ว่าพบโพรงชั้นที่ 3 หรือไม่ โดยภาพที่ 3.7 แสดงถึงโพรงสมองชั้นที่ 3 ปรากฏอยู่ (ในกรอบสี่เหลี่ยมสีน้ำเงิน)



ภาพที่ 3.7 โพรงสมองที่ติดส่วนโพรงสมองชั้นที่ 3 ในกรอบสีน้ำเงิน โดยตัวเลขมีหน่วยเป็นพิกเซล

### 3.2.1.5 รับค่าตำแหน่งภาพที่เกิดและการตัดโพรงสมองชั้นที่ 3 และทำการตัดออก

รับตำแหน่งภาพที่เกิดโพรงชั้นที่ 3 เป็นภาพแรกโดยใช้มุมมองจากส่วนบนสมองลงล่าง จากนั้นใช้วิธีฟลัดฟิลล์บนตำแหน่งจุดศูนย์กลางของตำแหน่งสูงสุดและต่ำสุด ซึ่งทำให้ส่วนที่ไม่โดนฟลัดฟิลล์นั้นหายไป โดยภาพ 3.8 แสดงการตัดโพรงสมองส่วนที่ 3 และผลลัพธ์ที่ได้



ภาพที่ 3.8 แสดงขั้นตอนการตัดโพรงสมองชั้นที่ 3

(ก) เป็นภาพแรกที่เกิดโพรงชั้นที่ 3 (ข) แสดงจุดศูนย์กลางบนพื้นที่

(ค) หลังฟลัดฟิลล์ที่จุดสูงสุดและต่ำสุดทำให้จุดที่ไม่ได้ฟลัดฟิลล์นั้นหายไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

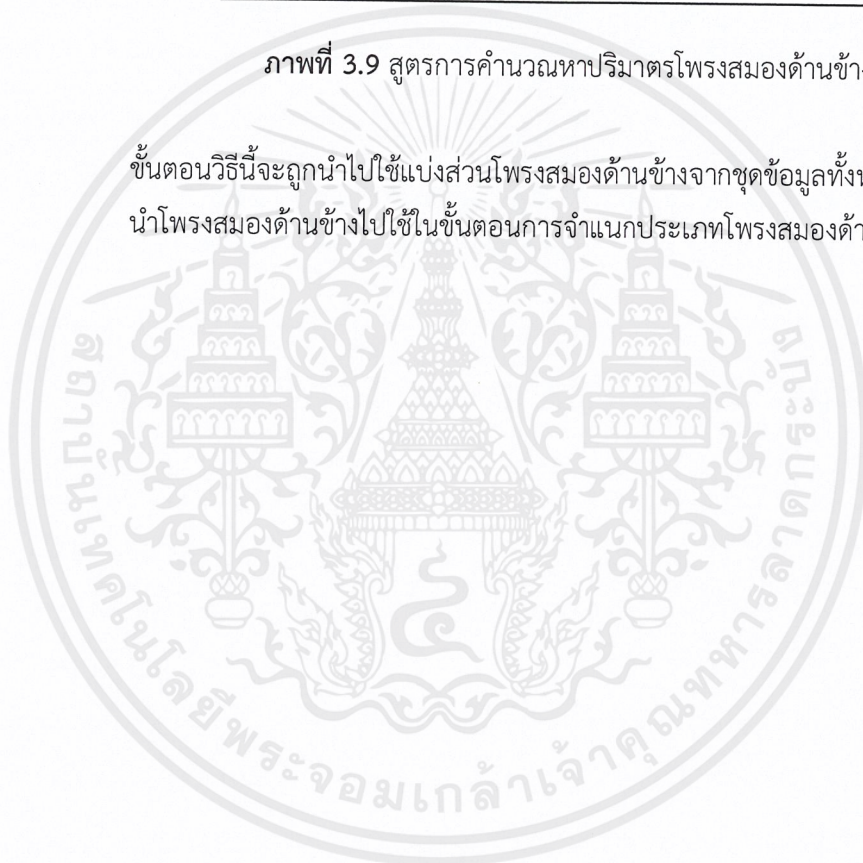
### 3.2.1.6 คำนวณปริมาตรของโพรงสมองด้านข้าง

นับจำนวนพิกเซลส่วนที่เป็น 1 หรือ สีขาว ทั้งหมดที่เกิดขึ้น จากนั้นคูณด้วยค่าคงที่ 1.318359375 ซึ่งเป็นค่าระยะห่างของภาพเอ็มอาร์ไอขนาด 256x256x124 ทำให้ได้ปริมาตรออกมาโดยมีหน่วยเป็นลูกบาศก์เซนติเมตร สูตรการคำนวณปริมาตรโพรงสมองด้านข้าง แสดงได้ดังภาพที่ 3.9

$$\text{ปริมาตรโพรงสมองด้านข้าง (cm}^3\text{)} = \text{จำนวนพิกเซล} \times 1.318359375$$

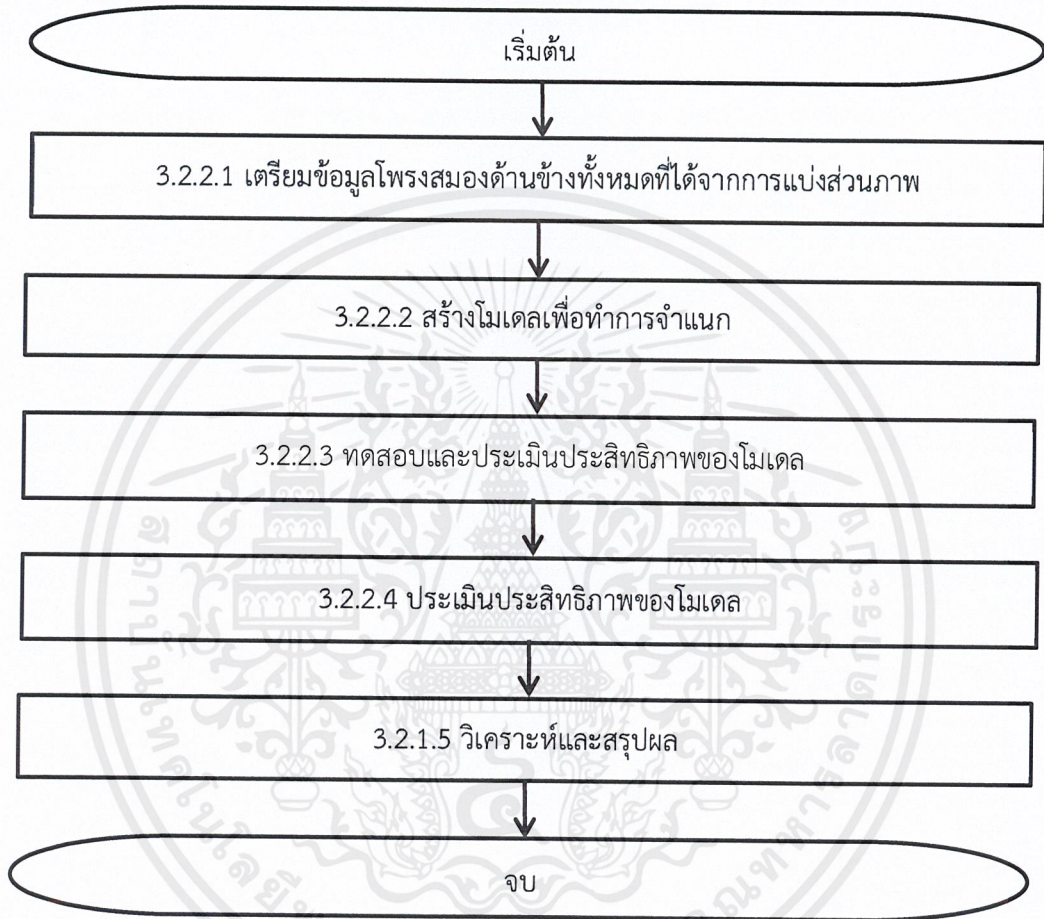
ภาพที่ 3.9 สูตรการคำนวณหาปริมาตรโพรงสมองด้านข้าง

ขั้นตอนวิธีนี้จะถูกนำไปใช้แบ่งส่วนโพรงสมองด้านข้างจากชุดข้อมูลทั้งหมดเพื่อที่จะนำโพรงสมองด้านข้างไปใช้ในขั้นตอนการจำแนกประเภทโพรงสมองด้านข้างต่อไป



### 3.2.2 การจำแนกประเภทโพรงสมองด้านข้าง


ขั้นตอนวิธีสำหรับการจำแนกประเภทโพรงสมองด้านข้างมีลำดับขั้นตอน แสดงดัง  
ภาพที่ 3.10



ภาพที่ 3.10 ขั้นตอนวิธีการจำแนกประเภทโพรงสมองด้านข้าง

### 3.2.2.1 เตรียมข้อมูลโพรงสมองด้านข้างทั้งหมดที่ได้จากการสแกนภาพ

ข้อมูลประกอบด้วยโพรงสมองด้านข้างของผู้ที่ร่างกายปกติ (Healthy) 80 โพรงสมอง ผู้ที่เป็นนักดนตรี (Musician) 40 โพรงสมอง และผู้ที่เป็นโรคลมชัก (Epilepsy) 260 โพรงสมอง การแสดงภาพตัวอย่างของโพรงสมองด้านข้างในรูปแบบของภาพสามมิติแสดงในภาพที่ 3.11 และการแสดงภาพโพรงสมองด้านข้างในรูปแบบของภาพสองมิติแสดงในภาพที่ 3.12

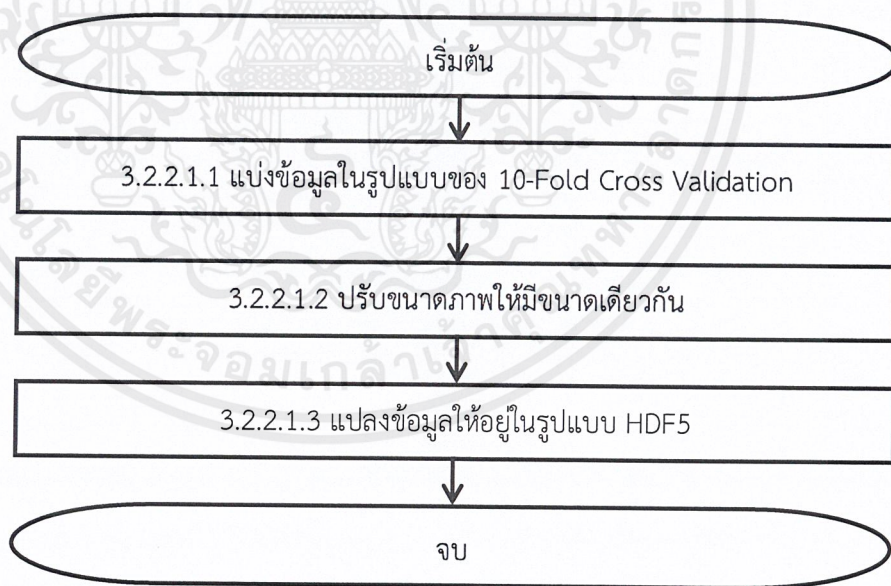


ภาพที่ 3.11 ตัวอย่างโพรงสมองด้านข้างของบุคคลแต่ละประเภท  
 (ก) ภาพตัวอย่างโพรงสมองด้านข้างของผู้ที่มีสุขภาพดี (Healthy)  
 (ข) ภาพตัวอย่างโพรงสมองด้านข้างของผู้ที่เป็นนักดนตรี (Musician)  
 (ค) ภาพตัวอย่างโพรงสมองด้านข้างของผู้ที่เป็นโรคลมชัก (Epilepsy)



ภาพที่ 3.12 ตัวอย่างภาพ 2 มิติของโพรงสมองด้านข้าง (Lateral Ventricles)

ขั้นตอนวิธีการเตรียมข้อมูลสำหรับการสร้างโมเดลเพื่อทำการจำแนกมี  
ดังต่อไปนี้



ภาพที่ 3.13 ขั้นตอนวิธีการเตรียมข้อมูลสำหรับการสร้างโมเดลเพื่อทำการจำแนก

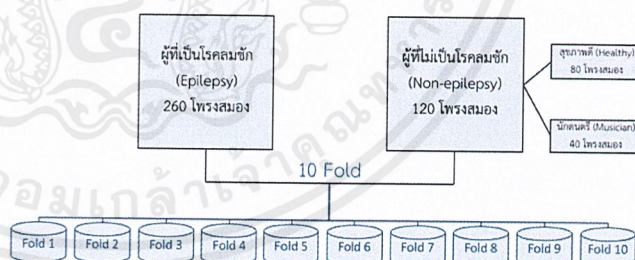
### 3.2.2.1.1 แบ่งข้อมูลในรูปแบบของ 10-Fold Cross Validation

แบ่งข้อมูลตามรูปแบบของวิธีการแบ่งแบบ 10-Fold Cross Validation ข้อมูลที่ถูกแบ่งจะนำมาสร้างโมเดลสำหรับจำแนกผู้ที่มีสุขภาพดี (Healthy) ผู้ที่เป็นนักดนตรี (Musician) และจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy)

ข้อมูลทั้งหมดมี 380 โพรงสมอง ประกอบไปด้วยผู้ที่มีสุขภาพดี (Healthy) 80 โพรงสมอง ผู้ที่เป็นนักดนตรี (Musician) 40 โพรงสมอง และผู้ที่เป็นโรคลมชัก (Epilepsy) 260 โพรงสมอง สำหรับการทดลอง ได้ทำการแบ่งชุดข้อมูลไว้ 7 รูปแบบดังต่อไปนี้

#### 1. Epilepsy: All

สร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) และผู้ที่ไม่เป็นโรคลมชัก (Non-epilepsy) โดยมีข้อมูลผู้ที่เป็นลมชัก (Epilepsy) 260 โพรงสมอง และผู้ที่ไม่เป็นโรคลมชัก (Non-epilepsy) 120 โพรงสมอง (ผู้ที่มีสุขภาพดีและผู้ที่เป็นักดนตรีรวมกัน) สำหรับขั้นตอนการแบ่งข้อมูลแบบ Epilepsy: All แสดงได้ดังภาพที่ 3.14



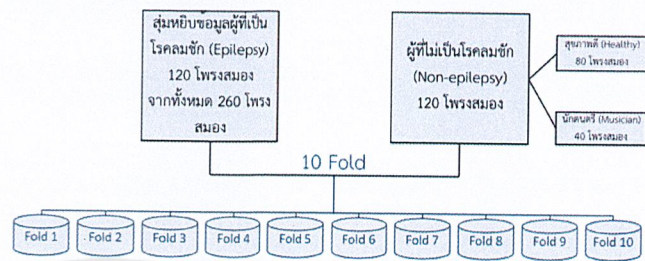
ภาพที่ 3.14 ลำดับขั้นตอนการแบ่งข้อมูลแบบ Epilepsy: All

#### 2. Epilepsy: Split1

สร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยการสุ่มโพรงสมองด้านข้างของผู้ที่เป็นโรคลมชัก (Epilepsy) 120 โพรงสมอง (จากทั้งหมด 260 โพรงสมอง) และผู้ที่ไม่เป็นโรคลมชัก (Non-epilepsy) 120 โพรงสมอง (ผู้ที่มีสุขภาพดีและผู้ที่เป็นัก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

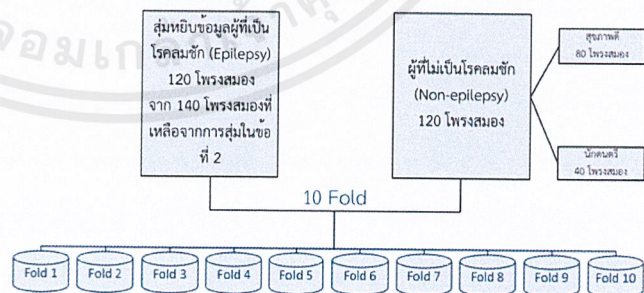
ดนตรีรวมกัน) สำหรับขั้นตอนการแบ่งข้อมูลแบบ Epilepsy: Split1 แสดงดังภาพที่ 3.15



ภาพที่ 3.15 ลำดับขั้นการแบ่งข้อมูลแบบ Epilepsy: Split1

### 3. Epilepsy: Split2

สร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยการสุ่มโพรงสมองด้านข้างของผู้ที่เป็นโรคลมชัก (Epilepsy) 120 โพรงสมอง ที่เหลือจากการสุ่มโพรงสมองด้านข้างของผู้ที่เป็นโรคลมชัก (Epilepsy) จากข้อ 2. (จากที่เหลือทั้งหมด 140 โพรงสมอง) และผู้ที่ไม่เป็นโรคลมชัก (Non-epilepsy) 120 โพรงสมอง (ผู้ที่มีสุขภาพดีและผู้ที่เป็นนักดนตรีรวมกัน) สำหรับขั้นตอนการแบ่งข้อมูลแบบ Epilepsy: Split2 แสดงดังภาพที่ 3.16

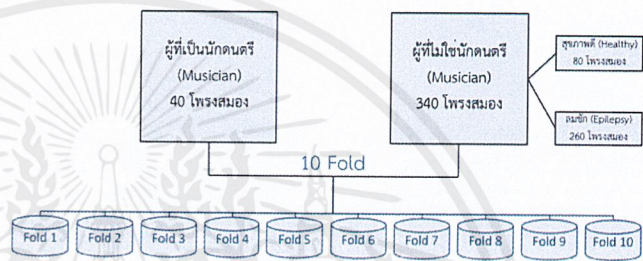


ภาพที่ 3.16 ลำดับขั้นการแบ่งข้อมูลแบบ Epilepsy: Split2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

#### 4. Musician: All

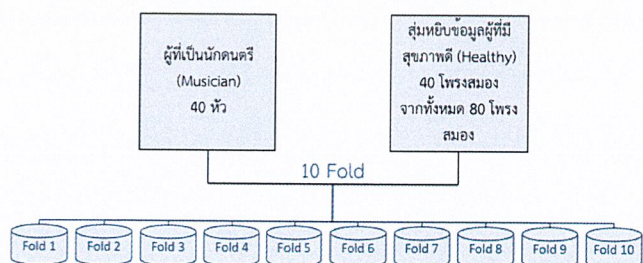
สร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) และผู้ที่ไม่เป็นนักดนตรี (Non-musician) โดยมีข้อมูลผู้ที่เป็นนักดนตรี (Musician) 40 โพรงสมอง และผู้ที่ไม่เป็นโรคนักดนตรี (Non-musician) 340 โพรงสมอง (ผู้ที่มีสุขภาพดีและผู้ที่เป็นโรคลมชัก รวมกัน) สำหรับขั้นตอนการแบ่งข้อมูลแบบ Musician: All แสดงดังภาพที่ 3.17



ภาพที่ 3.17 ลำดับขั้นการแบ่งข้อมูลแบบ Musician: All

#### 5. Musician: Split1

สร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยการสุ่มโพรงสมองด้านข้างของผู้ที่มีสุขภาพดี (Healthy) 40 โพรงสมอง (จากทั้งหมด 80 โพรงสมอง) และผู้ที่เป็นนักดนตรี (Musician) 40 โพรงสมอง สำหรับขั้นตอนการแบ่งข้อมูลแบบ Musician: Split1 แสดงดังภาพที่ 3.18

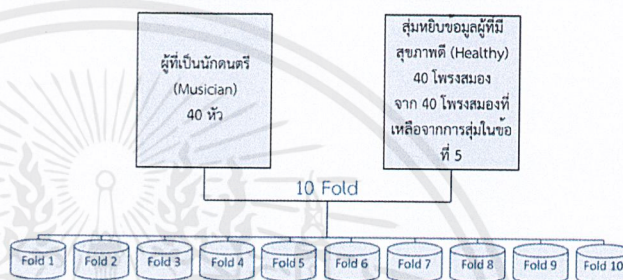


ภาพที่ 3.18 ลำดับขั้นการแบ่งข้อมูลแบบ Musician: Split1

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 6. Musician: Split2


สร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยการสุ่มโพรงสมองด้านข้างของผู้ที่มีสุขภาพดี (Healthy) 40 โพรงสมอง ที่เหลือจากการสุ่มโพรงสมองของผู้ที่มีสุขภาพดี (Healthy) จากข้อ 5. (จากที่เหลือทั้งหมด 40 โพรงสมอง) และผู้ที่เป็นนักดนตรี (Musician) 40 โพรงสมอง สำหรับขั้นตอนการแบ่งข้อมูลแบบ Musician: Split2 แสดงดังภาพที่ 3.19



ภาพที่ 3.19 ลำดับขั้นตอนการแบ่งข้อมูลแบบ Musician: Split2

## 7. Healthy, Musician and Epilepsy: All

สร้างโมเดลจำแนกผู้ที่มีสุขภาพดี (Healthy) ผู้ที่เป็นนักดนตรี (Musician) และผู้ที่เป็นโรคลมชัก (Epilepsy) โดยให้โมเดลจำแนกข้อมูล 3 ประเภทในโมเดลเดียวกัน (3 Classes) สำหรับขั้นตอนการแบ่งข้อมูลแบบ Healthy, Musician and Epilepsy: All แสดงดังภาพที่ 3.20



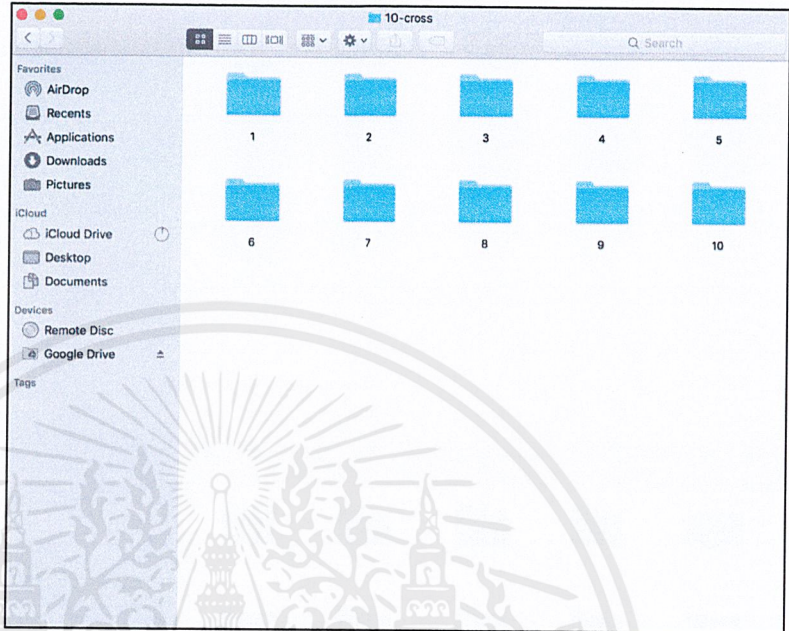
ภาพที่ 3.20 ลำดับขั้นตอนการแบ่งข้อมูลแบบ

Healthy, Musician and Epilepsy: All

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อทำการแบ่งเสร็จแล้วข้อมูลจะถูกแบ่งออกเป็น 10 ส่วนแสดงในภาพที่

### 3.21



ภาพที่ 3.21 ข้อมูลที่ถูกจัดแบ่งด้วยวิธีการ 10-Fold Cross Validation

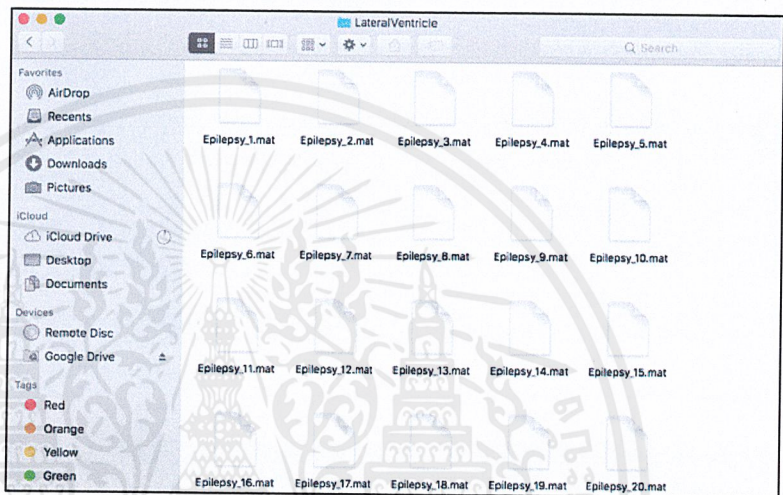
#### 3.2.2.1.2 ปรับขนาดภาพให้มีขนาดเดียวกัน

ภาพต้นฉบับของโพรงสมองด้านข้างมีขนาด  $256 \times 256 \times 124$  Voxels ภาพทั้งหมดจะถูกปรับให้อยู่เป็นขนาด  $100 \times 100 \times 100$  Voxels โดยแบ่งเป็นส่วนของโพรงสมองด้านข้างขนาด  $94 \times 94 \times 94$  Voxel ซึ่งตัวเลขดังกล่าวอ้างอิงจากข้อมูลของโพรงสมองด้านข้างในชุดข้อมูลทั้งหมดที่มีขนาดใหญ่ที่สุดเพื่อรักษาคุณลักษณะ (Feature) ที่เกี่ยวข้องกับขนาด และใช้ทรัพยากรในการคำนวณน้อยที่สุด เพิ่มส่วนพื้นที่ว่างด้านข้าง (Padding) ทุกแถวทุกด้าน 3 Voxels รวมแล้วมีขนาด  $100 \times 100 \times 100$  Voxel คำสั่งการปรับภาพแสดงในภาพที่ 3.22 ซึ่งทำผ่าน MATLAB ผลลัพธ์ที่ได้อยู่ในรูปแบบของไฟล์ .mat ซึ่งแสดงในภาพ 3.23

```
Command Window
>> obj2vox_batch('LateralVentricle.txt',94,3,'LateralVentricle')

```

ภาพที่ 3.22 คำสั่งการปรับภาพโพรงสมองด้านข้างทั้งหมดมีขนาดเดียวกัน



ภาพที่ 3.23 ไฟล์ผลลัพธ์ที่ได้จากการปรับภาพโพรงสมองด้านข้าง

### 3.2.2.1.3 แปลงข้อมูลให้อยู่ในรูปแบบ HDF5

ภาพที่ 3.24 แสดงคำสั่งการแปลงข้อมูลเนื่องจากเฟรมเวิร์ค Torch7 รองรับไฟล์ข้อมูลนำเข้าในรูปแบบ HDF5 เริ่มต้นจะมีคำสั่งอ่านเส้นทางที่เก็บไฟล์ (Path) ที่บรรจุไว้ไฟล์ Text แสดงในภาพที่ 3.25 และเมื่อทำงานเสร็จแล้วจะได้ไฟล์ผลลัพธ์แสดงในภาพที่ 3.26

```

1 from hdf5_util import *
2 output_filename_prefix = 'LateralVentricle'
3
4 def write_tensor_label_hdf5(mat_filelist, volume_size, pad_size):
5     """ We will use constant label (class 0) for the test data """
6     tensor_filenames = [line.rstrip() for line in open(mat_filelist, 'r')]
7     labels = [1 for _ in range(len(tensor_filenames))]
8     N = len(tensor_filenames)
9     assert(N<=500)
10
11     # Specify what data and label to write, CHANGE this according to your needs...
12     vox_size = volume_size + pad_size * 2
13     data_dim = [1, vox_size, vox_size, vox_size]
14     label_dim = [1]
15     data_dtype = 'uint8'
16     label_dtype = 'uint8'
17
18     # use batch buffer
19     h5_batch_size = N
20
21     batch_data_dim = [min(h5_batch_size, N)] + data_dim
22     batch_label_dim = [min(h5_batch_size, N)] + label_dim
23     h5_batch_data = np.zeros(batch_data_dim)
24     h5_batch_label = np.zeros(batch_label_dim)
25
26     for k in range(N):
27         mat = sio.loadmat(tensor_filenames[k])
28         print tensor_filenames[k]
29         if (tensor_filenames[k][81] == 'c'):
30             labels = [2 for _ in range(len(tensor_filenames))]
31         elif (tensor_filenames[k][81] == 'm'):
32             labels = [1 for _ in range(len(tensor_filenames))]
33         else:
34             labels = [0 for _ in range(len(tensor_filenames))]
35         d = mat[mat.keys()[0]]
36         l = labels[k]
37         h5_batch_data[k:h5_batch_size, ...] = d
38         h5_batch_label[k:h5_batch_size, ...] = l
39
40         if (k+1)*h5_batch_size == 0 or k==N-1:
41             print '[%s] %d/%d' % (datetime.datetime.now(), k+1, N)
42             print 'batch data shape: ', h5_batch_data.shape
43             h5_filename = output_filename_prefix+str(k/h5_batch_size)+'.h5'
44             print h5_filename
45             print np.shape(h5_batch_data)
46             print np.shape(h5_batch_label)
47             begidx = 0
48             endidx = min(h5_batch_size, (k+1)*h5_batch_size)
49             print h5_filename, data_dtype, label_dtype
50             save_h5(h5_filename, h5_batch_data[begidx:endidx, :, :, :], h5_batch_label[begidx:endidx, :], data_dtype, label_dtype)
51
52 write_tensor_label_hdf5('lateral_ventricle_path.txt', 94, 3)
53 (d, l) = load_h5(output_filename_prefix+'0.h5')
54 print d.shape

```

ภาพที่ 3.24 คำสั่งการแปลงข้อมูลให้อยู่ในรูปแบบ HDF5

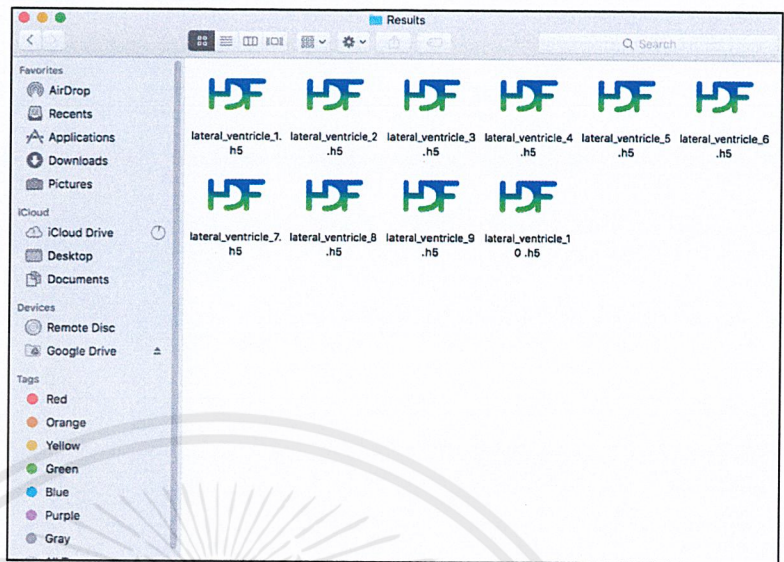
```

lateral_ventricle_path
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/hab_2.mat
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/hach.mat
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/had_4.mat
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/haff.mat
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/ham_6.mat
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/hamh.mat
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/hanr_8.mat
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/hat_9.mat
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/havn.mat
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/hbjb_11.mat
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/hbmo_12.mat
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/hbo_13.mat
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/hcab.mat
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/hccd_15.mat
/Users/pokpakornlinkasen/Documents/mri-brain-project/3dmodel_feature-master/
LateralVentricle/hcjc_16.mat

```

ภาพที่ 3.25 Text File สำหรับเส้นทางที่เก็บโพรงสมองด้านข้าง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 3.26 HDF5 File ที่ได้จากการแปลง

### 3.2.2.2 สร้างโมเดลเพื่อทำการจำแนก

การสร้างโมเดลแต่ละประเภทจะถูกสร้างตามรูปแบบการแบ่งข้อมูลตามข้อที่ 1-7 ในหัวข้อที่ 3.2.2.1.1 ซึ่งจะสร้างโมเดลในรูปแบบของ 10-Fold Cross Validation โดยใช้ 2 ชั้นตอนวิธี (VoxNet และ 3D NIN FC) ซึ่งจะให้ได้โมเดลแต่ละชนิด 10 โมเดล รวม 2 ชั้นตอนวิธีเป็น 20 โมเดล รวมทุกรูปแบบ (ตามข้อที่ 1 – 7 ในหัวข้อที่ 3.2.2.1.1) จะได้ทั้งหมด 140 โมเดล ดำเนินการโดยใช้เฟรมเวิร์กที่ชื่อ Torch7 เป็นเฟรมเวิร์กหนึ่งเป็นที่นิยมสำหรับการทำงานที่เกี่ยวกับเรียนรู้เชิงลึก ซึ่งเขียนขึ้นด้วยภาษา Lua จาก <https://github.com/charlesq34/3dcnn.torch>

การดำเนินการดำเนินการบนระบบปฏิบัติการ Ubuntu 16.04 Server โดยใช้บริการผ่าน AWS (Amazon Web Services) EC2 เลือกใช้บริการ Instance Type: p3.2xlarge ซึ่งประกอบไปด้วยสเปคดังนี้ 23.5 ECUs, 8 vCPUs, 2.7 GHz, Intel Xeon E5-2686 v4, 61 GiB memory, EBS only, 1 GPUs Nvidia Tesla V100 (ประกอบไปด้วย 5,120 CUDA Cores และ 640 Tensor Cores)

Hyperparameters ที่ใช้เป็นค่าเริ่มต้น (Default) มีดังต่อไปนี้

- learningRate (Learning Rate) = 0.01
- learningRateDecay (Learning Rate Decay) = 1e-7
- weightDecay (Weight Decay) = 0.0005
- momentum (Momentum) = 0.9
- epoch\_step (Epoch Step) = 20
- jitter\_step (Jitter Augmentation Step Size) = 2

Hyperparameters ที่กำหนดเอง (Custom Hyperparameters) มีดังต่อไปนี้

- batchSize (Batch Size) = 2 (จากเดิม 64)
- max\_epoch (Maximum Number of Epochs) = 150 (จากเดิม 200)

ตัวอย่างการเรียกใช้คำสั่งสำหรับสร้างโมเดลเพื่อจำแนกข้อมูลแสดงในภาพที่ 3.27 และ 3.28

```
Downloads — ubuntu@ip-172-31-0-119: ~/Documents/3dcnn.torch — ssh -i obey...
ubuntu@ip-172-31-0-119:~/Documents/3dcnn.torch$ th train.lua --train_data data/LT/train_data_1.txt --test_data data/LT/test_data_1.txt --batchSize 2 --max_epoch 150 --model voxnet --save musician_all_VoxNet_1
{
  train_data : "data/LT/train_data_1.txt"
  learningRateDecay : 1e-07
  weightDecay : 0.0005
  learningRate : 0.01
  model : "voxnet"
  batchSize : 2
  epoch_step : 20
  momentum : 0.9
  gpu_index : 0
  test_data : "data/LT/test_data_1.txt"
  save : "musician_all_VoxNet_1"
  jitter_step : 2
  help : false
  max_epoch : 150
}
Found Environment variable CUDNN_PATH = /usr/local/cuda/lib64/libcudnn.so.7
nn.Sequential {
  [input -> (1) -> (2) -> (3) -> (4) -> (5) -> (6) -> (7) -> (8) -> (9) -> (10) -> (11) -> (12) -> output]
  (1): nn.VolumetricConvolution(1 -> 32, 5x5x5, 2,2,2, 1,1,1)
  (2): nn.LeakyReLU(0.1)
```

ภาพที่ 3.27 การใช้คำสั่งสำหรับสร้างโมเดลเพื่อจำแนก

ผู้ที่เป็นนักดนตรี (Musician) กับผู้ที่ไม่ได้เป็นนักดนตรี (Non-musician)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

Downloads — ubuntu@ip-172-31-0-119: ~/Documents/3dcnn.torch — ssh -i obey...
ubuntu@ip-172-31-0-119:~/Documents/3dcnn.torch$ th train.lua --train_data data/LT/t
rain_data_1.txt --test_data data/LT/test_data_1.txt --batchSize 2 --max_epoch 150 -
-model 3dnin_fc --save epilepsy_all_3DNIN_1
{
  train_data : "data/LT/train_data_1.txt"
  learningRateDecay : 1e-07
  weigthDecay : 0.0005
  learningRate : 0.01
  model : "3dnin_fc"
  batchSize : 2
  epoch_step : 20
  momentum : 0.9
  gpu_index : 0
  test_data : "data/LT/test_data_1.txt"
  save : "epilepsy_all_3DNIN_1"
  jitter_step : 2
  help : false
  max_epoch : 150
}
Found Environment variable CUDNN_PATH = /usr/local/cuda/lib64/libcudnn.so.7
nn.Sequential {
  [input -> (1) -> (2) -> (3) -> (4) -> (5) -> (6) -> (7) -> (8) -> (9) -> (10) ->
  (11) -> (12) -> (13) -> (14) -> (15) -> (16) -> (17) -> (18) -> (19) -> (20) -> (21)
  ] -> (22) -> (23) -> (24) -> (25) -> (26) -> (27) -> (28) -> (29) -> (30) -> (31) -
  > (32) -> (33) -> (34) -> (35) -> output]

```

ภาพที่ 3.28 การใช้คำสั่งสำหรับสร้างโมเดลเพื่อจำแนก

ผู้ที่ เป็นโรคลมชัก (Epilepsy) กับผู้ที่ไม่ได้เป็นโรคลมชัก (Non-epilepsy)

### 3.2.2.3 ทดสอบและประเมินประสิทธิภาพของโมเดล

มาตรวัดที่ถูกใช้เพื่อทำการประเมินการสร้างโมเดลในแต่ละโมเดลมีทั้งหมด 3 มาตรวัด ได้แก่ Accuracy, Sensitivity และ Specificity ในการประมวลผลแต่ละครั้งจะประมวลผลจนครบ 150 Epoch โดยผลลัพธ์ทั้งหมดจะถูกเขียนลงในไฟล์ Text ตัวอย่างการแสดงผลค่าของแต่ละมาตรวัดในขณะที่กำลังประมวลผลโมเดลแสดงในภาพที่ 3.29

```

Downloads — ubuntu@ip-172-31-0-119: ~/Documents/3dcnn.torch — ssh -i obey...
Epoch: 1
[===== 18/18 =====>] Tot: 709ms | Step: 41ms
[===== 18/18 =====>] Tot: 479ms | Step: 28ms
[===== 18/18 =====>] Tot: 482ms | Step: 28ms
[===== 18/18 =====>] Tot: 479ms | Step: 28ms
[===== 18/18 =====>] Tot: 458ms | Step: 26ms
[===== 18/18 =====>] Tot: 483ms | Step: 28ms
[===== 18/18 =====>] Tot: 454ms | Step: 26ms
[===== 18/18 =====>] Tot: 477ms | Step: 28ms
[===== 18/18 =====>] Tot: 477ms | Step: 28ms

loss: 2.5054697990417
Train accuracy: 77.16 % time: 7.49 s
True Positive: 189
False Positive: 41
True Negative: 61
False Negative: 32
Sensitivity(1): 85.52036199095
Specificity(0): 59.803921568627

-----
elapsed time: 18.00

```

ภาพที่ 3.29 ตัวอย่างการแสดงผลค่าของแต่ละมาตรวัด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อทำการประมวลผลโมเดลจนครบตามแบบ 10-Fold Cross Validation แล้วจึงทำการหาค่าทั้งหมดของแต่ละมาตรวัด สำหรับผลการทดสอบและประเมินประสิทธิภาพของโมเดลจะแสดงในหัวข้อที่ 4.4 ในบทที่ 4

#### 3.2.2.4 วิเคราะห์และสรุปผล

นำผลลัพธ์ค่าเฉลี่ยของแต่ละมาตรวัดที่ได้ของโมเดลทั้ง 2 ประเภท มาทำการสรุปว่า โพรงสมองด้านข้าง (Lateral Ventricles) มีความสามารถในการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) และสมองผู้ที่เป็นนักดนตรี (Musician) ได้มากน้อยเพียงใด รายละเอียดของผลการทดลองและการสรุปผลจะกล่าวถึงในบทที่ 4




## บทที่ 4

### ผลการดำเนินงานและการอภิปรายผล

ในบทนี้จะกล่าวถึง ผลการดำเนินงานการแบ่งส่วนโพรงสมองด้านข้าง การประเมินผลการดำเนินงานการแบ่งส่วนโพรงสมองด้านข้าง ปัญหาที่พบในการแบ่งส่วนโพรงสมองด้านข้าง ผลการดำเนินงานการจำแนกประเภทโพรงสมองด้านข้าง ผลการทดสอบและประเมินประสิทธิภาพการจำแนกประเภทโพรงสมองด้านข้าง และ ปัญหาที่พบในการจำแนกประเภทโพรงสมองด้านข้าง


#### 4.1 ผลการดำเนินงานการแบ่งส่วนโพรงสมองด้านข้าง

จากวิธีการแบ่งส่วนโพรงสมองด้านข้างที่ได้นำเสนอในบทที่ 3 หัวข้อที่ 3.2 ตัวอย่างโพรงสมองด้านข้างที่ถูกแบ่งส่วนด้วยวิธีการนี้ แสดงในภาพที่ 4.1 – 4.3 โดยภาพที่ 4.1 คือ ภาพสามมิติของโพรงสมองด้านข้างของสมอง sw8nr ภาพที่ 4.2 คือ ภาพสามมิติของโพรงสมองด้านข้างของสมอง mdy และภาพที่ 4.3 คือภาพสามมิติของโพรงสมองด้านข้างของสมอง hjjh ซึ่งภาพดังกล่าวได้ถูกนำเสนอด้วยซอฟต์แวร์ MATLAB




ภาพที่ 4.1 ภาพสามมิติโพรงสมองด้านข้างของสมอง sw8nr

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 4.2 ภาพสามมิติโพรงสมองด้านข้างของสมอง mdy

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 4.3 ภาพสามมิติโพรงสมองด้านข้างของสมอง hjjh

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.2 การประเมินผลการดำเนินงานการแบ่งส่วนโพรงสมองด้านข้าง

จากผลการดำเนินงานแบ่งส่วนโพรงสมองด้านข้าง สามารถนำขนาดของโพรงสมองด้านข้างที่ได้จากวิธีการที่นำเสนอมาเปรียบเทียบกับขนาดโพรงสมองด้านข้างที่ได้จากการแบ่งส่วนด้วยมือโดยผู้เชี่ยวชาญจำนวน 84 สมอง ซึ่งแสดงดังตารางที่ 4.1

ตารางที่ 4.1 การเปรียบเทียบขนาดของโพรงสมองด้านข้างที่ได้จากวิธีการที่นำเสนอ และการแบ่งส่วนด้วยมือโดยผู้เชี่ยวชาญ

ชื่อสมอง	ขนาดของโพรงสมองด้านข้างจากการแบ่งส่วนโดยผู้เชี่ยวชาญ (ลูกบาศก์เซนติเมตร)	ขนาดของโพรงสมองด้านข้างจากวิธีการที่นำเสนอ (ลูกบาศก์เซนติเมตร)	ค่าความแตกต่างระหว่างขนาดโพรงสมองด้านข้างจากการแบ่งส่วนโดยผู้เชี่ยวชาญและวิธีการที่นำเสนอ (ลูกบาศก์เซนติเมตร)	ค่าความคล้อยกันของขนาดโพรงสมองด้านข้างจากการแบ่งส่วนโดยผู้เชี่ยวชาญและวิธีการที่นำเสนอ (ร้อยละ)
JR	5.94	5.80	0.14	97.65
ID	6.15	7.84	-1.69	72.56
SLD	6.20	5.23	0.97	84.42
MD	6.22	6.37	-0.15	97.67
AMH	6.51	6.53	-0.02	99.74
AD	6.59	7.25	-0.66	89.95
PD	6.68	5.54	1.14	82.93
AB	7.16	7.04	0.12	98.27
GPB	7.31	7.81	-0.50	93.20
PJC	7.58	7.05	0.53	92.98
AFF	7.90	7.54	0.36	95.44
TD	8.30	7.62	0.68	91.79
LR	8.51	8.12	0.39	95.37
SAA	8.52	6.90	1.62	81.00
SVC	9.36	9.33	0.03	99.66

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ชื่อ สมอง	ขนาดของโพรง สมองด้านข้าง จากการแบ่งส่วน โดยผู้เชี่ยวชาญ (ลูกบาศก์ เซนติเมตร)	ขนาดของโพรง สมองด้านข้าง จากวิธีการที่ นำเสนอ (ลูกบาศก์ เซนติเมตร)	ค่าความแตกต่าง ระหว่างขนาดโพรง สมองด้านข้างจาก การแบ่งส่วนโดย ผู้เชี่ยวชาญและ วิธีการที่นำเสนอ (ลูกบาศก์เซนติเมตร)	ค่าความคล้ายกัน ของ ขนาดโพรงสมอง ด้านข้างจากการ แบ่งส่วนโดย ผู้เชี่ยวชาญและ วิธีการที่นำเสนอ (ร้อยละ)
PP	9.38	8.91	0.47	95.00
RP	9.45	10.03	-0.58	93.88
MW	9.51	10.60	-1.09	88.58
BM	9.78	9.52	0.26	97.34
PRW	10.16	8.88	1.28	87.37
MCA	11.09	10.41	0.68	93.88
AT	12.36	11.53	0.83	93.31
MBO	12.44	13.05	-0.61	95.09
CAB	12.60	13.88	-1.28	89.84
DMN	13.24	13.54	-0.30	97.71
GB	13.24	14.72	-1.48	88.83
CCD	13.27	13.00	0.27	97.96
NE	13.52	12.05	1.47	89.13
BO	13.53	13.75	-0.22	98.39
GO	13.61	13.27	0.34	97.49
MWJ	13.82	14.29	-0.47	96.58
WB	13.89	13.95	-0.06	99.53
MES	14.60	15.03	-0.43	97.03
MKR	14.94	14.41	0.53	96.44
BMO	15.44	14.66	0.78	94.92
JLH	15.81	16.08	-0.27	98.30
RL	15.82	16.63	-0.81	94.88
TAA	15.94	15.38	0.56	96.47

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ชื่อ สมอง	ขนาดของโพรง สมองด้านข้าง จากการแบ่งส่วน โดยผู้เชี่ยวชาญ (ลูกบาศก์ เซนติเมตร)	ขนาดของโพรง สมองด้านข้าง จากวิธีการที่ นำเสนอ (ลูกบาศก์ เซนติเมตร)	ค่าความแตกต่าง ระหว่างขนาดโพรง สมองด้านข้างจาก การแบ่งส่วนโดย ผู้เชี่ยวชาญและ วิธีการที่นำเสนอ (ลูกบาศก์เซนติเมตร)	ค่าความคล้ายกัน ของ ขนาดโพรงสมอง ด้านข้างจากการ แบ่งส่วนโดย ผู้เชี่ยวชาญและ วิธีการที่นำเสนอ (ร้อยละ)
PAL	15.97	15.86	0.11	99.28
KE	16.28	16.91	-0.63	96.12
AM	16.44	16.42	0.02	99.88
LA	17.28	17.04	0.24	98.63
CAF	17.78	17.22	0.56	96.85
RRA	18.25	18.63	-0.38	97.93
JF	18.30	17.38	0.92	94.96
GM	19.03	20.42	-1.39	92.68
JKF	20.18	22.71	-2.53	87.46
JAS	20.34	23.50	-3.16	84.44
DIJ	20.78	20.82	-0.04	99.81
GH	20.82	26.87	-6.05	70.96
JEB	21.11	20.48	0.63	97.02
PB	21.54	24.69	-3.15	85.39
PM	22.04	23.57	-1.53	93.07
AVN	22.18	23.02	-0.84	96.21
JDG	23.71	24.78	-1.07	95.50
MK	23.81	23.86	-0.05	99.81
PAF	23.97	24.60	-0.63	97.38
CNB	24.13	27.51	-3.38	85.99
DB	24.34	23.07	1.27	94.78
DS	25.16	11.55	13.61	45.91
ML	25.54	24.24	1.30	94.90

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

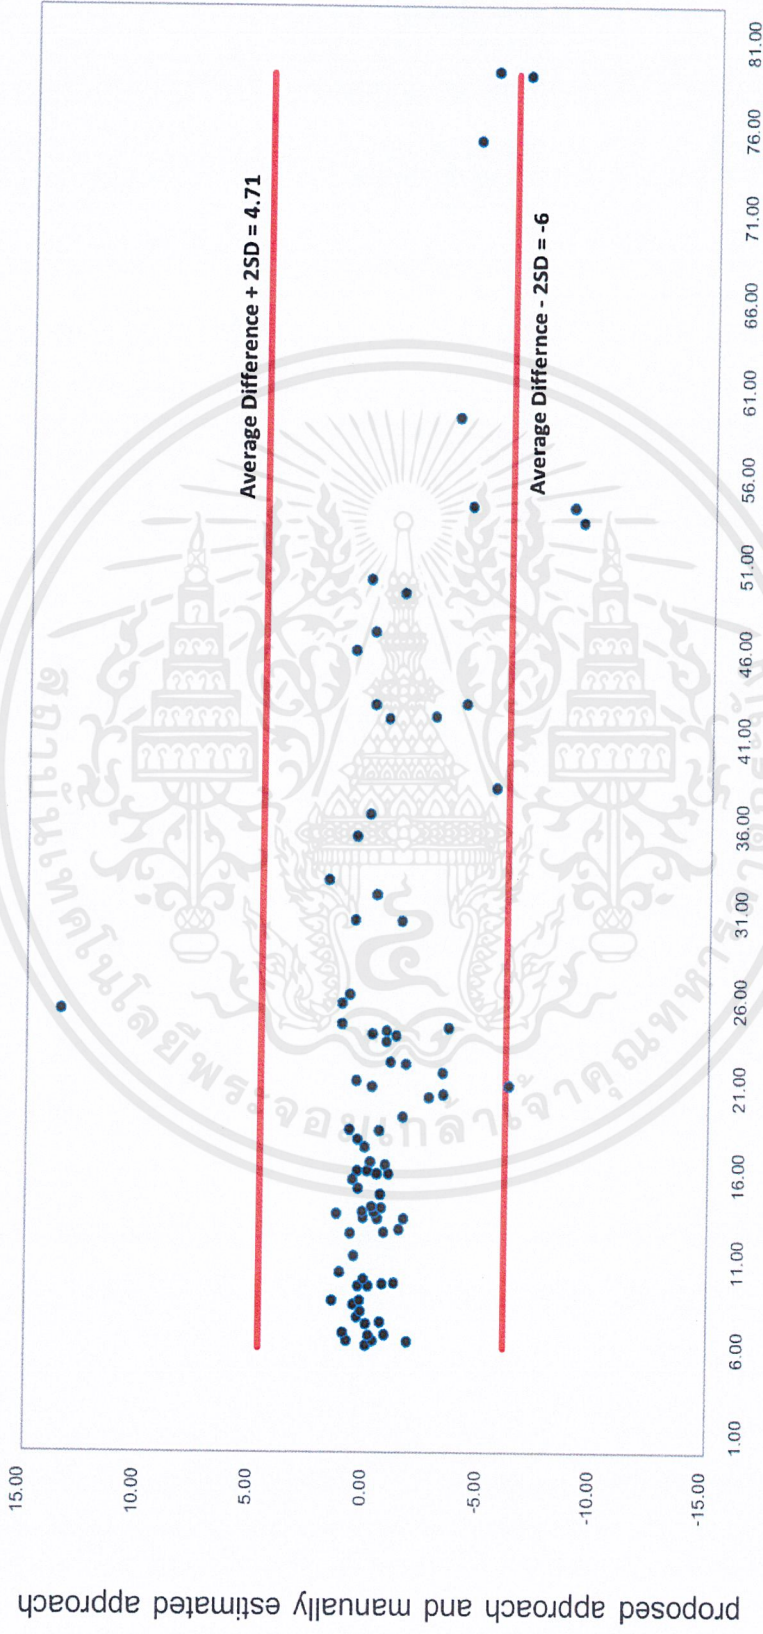
ชื่อ สมอง	ขนาดของโพรง สมองด้านข้าง จากการแบ่งส่วน โดยผู้เชี่ยวชาญ (ลูกบาศก์ เซนติเมตร)	ขนาดของโพรง สมองด้านข้าง จากวิธีการที่ นำเสนอ (ลูกบาศก์ เซนติเมตร)	ค่าความแตกต่าง ระหว่างขนาดโพรง สมองด้านข้างจาก การแบ่งส่วนโดย ผู้เชี่ยวชาญและ วิธีการที่นำเสนอ (ลูกบาศก์เซนติเมตร)	ค่าความคล้อยกัน ของ ขนาดโพรงสมอง ด้านข้างจากการ แบ่งส่วนโดย ผู้เชี่ยวชาญและ วิธีการที่นำเสนอ (ร้อยละ)
OMC	26.05	25.10	0.95	96.34
JDL	30.23	31.50	-1.27	95.79
BJB	30.30	29.53	0.77	97.44
ACH	31.76	31.90	-0.14	99.55
SM	32.56	30.62	1.94	94.03
LDK	35.08	34.36	0.72	97.94
LT	36.37	36.19	0.18	99.51
EMJ	37.90	43.26	-5.36	85.86
MC	41.87	42.49	-0.62	98.53
MI	41.98	44.65	-2.67	93.63
TJG	42.65	42.66	-0.01	99.99
IRR	42.73	46.73	-4.00	90.64
PLD	45.78	44.90	0.88	98.08
ANR	46.82	46.77	0.05	99.89
CJG	49.11	50.34	-1.23	97.49
MDY	49.87	49.63	0.24	99.53
CVS	53.17	62.28	-9.11	82.87
EP	53.99	62.69	-8.70	83.88
TH	54.09	58.22	-4.13	92.37
EHC	59.18	62.71	-3.53	94.04
GJL	75.05	79.36	-4.31	94.26
JJH	78.77	85.22	-6.45	91.81
RMT	79.01	84.04	-5.03	93.63

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ชื่อ สมอง	ขนาดของโพรง สมองด้านข้าง จากการแบ่งส่วน โดยผู้เชี่ยวชาญ (ลูกบาศก์ เซนติเมตร)	ขนาดของโพรง สมองด้านข้าง จากวิธีการที่ นำเสนอ (ลูกบาศก์ เซนติเมตร)	ค่าความแตกต่าง ระหว่างขนาดโพรง สมองด้านข้างจาก การแบ่งส่วนโดย ผู้เชี่ยวชาญและ วิธีการที่นำเสนอ (ลูกบาศก์เซนติเมตร)	ค่าความคล้ายกัน ของ ขนาดโพรงสมอง ด้านข้างจากการ แบ่งส่วนโดย ผู้เชี่ยวชาญและ วิธีการที่นำเสนอ (ร้อยละ)
ค่าเฉลี่ย	23.33	23.97	-0.64	93.25
Lower Bound	-	-	-6.00	-
Upper Bound	-	-	4.71	-
SD	17.14	18.57	2.68	-

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้





The manually estimated size of each lateral ventricles

ภาพที่ 4.5 กราฟค่าความแตกต่างระหว่างขนาดที่ทรงสมองด้านข้างจากการแบ่งส่วนโดยผู้เชี่ยวชาญและวิธีการที่นำเสนอเทียบกับค่าขอบล่าง (Lower Bound) และค่าขอบบน (Upper Bound)

The lateral ventricles size difference between our proposed approach and manually estimated approach


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.1 จะเห็นได้ว่า ปริมาณโพรงสมองด้านข้างที่ได้จากวิธีการที่นำเสนอมีค่าใกล้เคียงกับปริมาณโพรงสมองด้านข้างที่แบ่งด้วยมือโดยผู้เชี่ยวชาญ ซึ่งจากผลการดำเนินงานที่ได้สามารถนำมาทดสอบทางสถิติโดยใช้  $Z - test$  โดยมีสมมติฐานดังนี้

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

โดยที่  $\mu_1$  คือ ค่าเฉลี่ยขนาดของโพรงสมองด้านข้างที่ได้จากการแบ่งส่วนโดยวิธีการที่นำเสนอโดยมีค่าเท่ากับ 23.97 และ  $\mu_2$  คือ ขนาดของโพรงสมองด้านข้างที่ได้จากการแบ่งส่วนด้วยมือโดยผู้เชี่ยวชาญ โดยมีค่าเท่ากับ 23.33 จากการทดสอบ สมมติฐานโดยใช้  $\alpha$  เท่ากับ 0.05 ส่วนเบี่ยงเบนมาตรฐานเท่ากับ 17.14 และ จำนวนโพรงสมองเท่ากับ 84 โพรงสมอง ทำให้ได้บริเวณวิกฤต  $Z$  น้อยกว่า -1.96 และ มากกว่า 1.96 จากนั้นคำนวณค่าสถิติทดสอบ  $Z$  ได้เท่ากับ 0.34 ซึ่งตกอยู่ในบริเวณที่ไม่ปฏิเสธสมมติฐานว่าง นั่นคือไม่มีหลักฐานเพียงพอที่จะปฏิเสธ  $H_0$  แสดงว่า วิธีการที่นำเสนอไม่มีความแตกต่างกันอย่างมีนัยสำคัญกับวิธีแบ่งส่วนโดยผู้เชี่ยวชาญ



ภาพที่ 4.6 กราฟแสดงค่า  $Z$  ของการทดสอบประสิทธิภาพวิธีการแบ่งส่วนด้วย  $Z$ -test ระหว่างวิธีการที่นำเสนอและวิธีแบ่งส่วนโดยผู้เชี่ยวชาญ

#### 4.3 ปัญหาที่พบในการแบ่งส่วนโพรงสมองด้านข้าง

##### 4.3.1 ขนาดที่ไม่เท่ากันของภาพสแกนเอ็มอาร์ไอที่นำมาใช้

ภาพสแกนเอ็มอาร์ไอบางส่วนมีขนาดที่แตกต่างกันโดยปกติกำหนดขนาดของภาพเท่ากับ  $256 \times 256 \times 124$  ซึ่งบางส่วนมีขนาดเท่ากับ  $256 \times 256 \times 256$  จึงต้องมีการปรับขนาดภาพก่อนนำมาใช้ต่อไป

##### 4.3.2 มุมมองของภาพสแกนเอ็มอาร์ไอที่ไม่เหมือนกัน

ภาพสแกนเอ็มอาร์ไอบางส่วนมีมุมมองแตกต่างกันโดยต้องปรับทิศทางโดยการหมุนภาพก่อนนำไปใช้งาน

##### 4.3.3 เส้นขอบโพรงสมองบางส่วนไม่ต่อเนื่องกัน

ความต่อเนื่องของโพรงสมองเป็นสิ่งสำคัญเมื่อมีจุดที่พิกเซลขาดออกจากกันจะทำให้ความสมบูรณ์ของโพรงสมองด้านข้างลดน้อยลงจึงต้องมีการกำหนดค่าขีดแบ่งให้เหมาะสมที่สุด

##### 4.3.4 การประเมินผลของวิธีการแบ่งส่วนโพรงสมองด้านข้างที่นำเสนอไม่สามารถพิจารณาจากรูปร่างของโพรงสมองด้านข้างได้

ผลการประเมินโพรงสมองด้านข้างที่ได้จากการแบ่งส่วนโดยผู้เชี่ยวชาญอยู่ในรูปของปริมาณจึงทำให้ปัญหาพิเศษนี้ ประเมินผลของวิธีการที่นำเสนอได้เพียงเปรียบเทียบขนาดของโพรงสมองด้านข้างที่ได้จากวิธีการที่นำเสนอเท่านั้นไม่สามารถเปรียบเทียบรูปร่างของโพรงสมองด้านข้างได้

#### 4.4 ผลการดำเนินงานการจำแนกประเภทโพรงสมองด้านข้าง

ในหัวข้อนี้จะพูดถึงผลการทดลอง และ การประเมินประสิทธิภาพของโมเดล ซึ่งมาตรวัดที่ใช้ประกอบไปด้วย Accuracy, Sensitivity และ Specificity ของการสร้างโมเดลเพื่อทำการจำแนกโดยใช้วิธีการเรียนรู้เชิงลึก (Deep Learning) โดยใช้สถาปัตยกรรม VoxNet และ 3D NIN (3-Dimensional Network in Network) รายละเอียดของสถาปัตยกรรมทั้งสองอธิบายไว้ในหัวข้อที่ 2.8.1 และ 2.8.2 ตามลำดับ โดยข้อมูลทั้งหมดจะถูกแบ่งออกเป็น 7 แบบ ได้แก่ Epilepsy: All, Epilepsy: Split1, Epilepsy: Split2, Musician: All, Musician: Split1, Musician: Split2 และ Healthy, Musician and Epilepsy Classification Using 3D NIN-FC ในหัวข้อที่ 3.2.2.1.1 ข้อ 1, 2, 3, 4, 5, 6 และ

7 ตามลำดับ และหลังจากนั้นข้อมูลในแต่ละแบบจะถูกแบ่งตามรูปแบบของ 10-Fold Cross Validation ในส่วนของการสร้างโมเดลจากทั้ง 2 สถาปัตยกรรมนั้นใช้ Hyperparameters ที่เหมือนกัน (กล่าวไว้ในหัวข้อที่ 3.2.2.2) ซึ่งผลการทดลองสำหรับ VoxNet , 3D NIN FC (3-Dimensional Network in Network Full Connected) และ การประเมินประสิทธิภาพของโมเดล จะแสดงในหัวข้อที่ 4.4.1 , 4.4.2 และ 4.4.3 ตามลำดับ

#### 4.4.1 ผลการทดลองสำหรับสถาปัตยกรรม VoxNet

ในหัวข้อนี้แสดงผลการทดลองจากการแบ่งข้อมูลทั้ง 7 แบบ (ในหัวข้อที่ 3.2.2.1.1 ข้อ 1, 2, 3, 4, 5 ,6 และ 7) โดยสร้างโมเดลจากสถาปัตยกรรม VoxNet เพื่อทำการจำแนกตามรูปแบบของ 10-Fold Cross Validation โดยผลการทดลองสำหรับการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) สำหรับข้อมูลแบบ Epilepsy: All, Epilepsy: Split1, Epilepsy: Split2 แสดงในตารางที่ 4.2, 4.3 และ 4.4 ตามลำดับ ผลการทดลองสำหรับการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) สำหรับข้อมูลแบบ Musician: All, Musician: Split1, Musician: Split2 แสดงในตาราง 4.5, 4.6 และ 4.7 ในส่วนของผลการทดลองสำหรับการสร้างโมเดลจำแนกผู้ที่มีสุขภาพดี (Healthy) ผู้ที่เป็นนักดนตรี (Musician) และผู้ที่เป็นโรคลมชัก (Epilepsy) เป็นการทำนาย 3 ประเภท (3 Targets) สำหรับข้อมูลแบบ Healthy, Musician and Epilepsy: All แสดงในตาราง 4.8

Epilepsy Classification Using VoxNet						
Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
1	99.38	97.37	96.15	100.00		34
2	99.69	89.47	84.62	100.00		34
3	100.00	97.37	96.15	100.00		34
4	100.00	92.11	92.31	91.67		34
5	99.69	97.37	96.15	100.00		34
6	100.00	89.47	96.15	75.00		34
7	99.69	94.74	96.15	91.67		34
8	99.69	86.84	88.46	83.33		34
9	99.69	94.74	96.15	91.67		34
10	100.00	92.11	96.15	83.33		34
Average	99.78	<b>93.16</b>	<b>93.85</b>	<b>91.67</b>	Total	340

ตารางที่ 4.2 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) ด้วยสถาปัตยกรรม VoxNet สำหรับข้อมูลแบบ Epilepsy: All

Split1: Epilepsy Classification Using VoxNet						
Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
1	100.00	79.17	83.33	75.00		22
2	100.00	91.67	83.33	100.00		22
3	98.99	95.83	100.00	91.67		22
4	100.00	100.00	100.00	100.00		22
5	98.99	91.67	83.33	100.00		22
6	100.00	91.67	91.67	91.67		22
7	100.00	100.00	100.00	100.00		22
8	98.99	91.67	83.33	100.00		22
9	100.00	83.33	83.33	83.33		22

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
10	100.00	100.00	100.00	100.00		22
Average	99.70	<b>92.50</b>	<b>90.83</b>	<b>94.17</b>	Total	<b>220</b>

ตารางที่ 4.3 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy)

ด้วยสถาปัตยกรรม VoxNet สำหรับข้อมูลแบบ Epilepsy: Split1

Split2: Epilepsy Classification Using VoxNet						
Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
1	99.49	79.17	83.33	75.00		22
2	100.00	91.67	91.67	91.67		22
3	100.00	95.83	100.00	91.67		22
4	100.00	95.83	91.67	100.00		22
5	100.00	91.67	83.33	100.00		22
6	100.00	91.67	91.67	91.67		22
7	100.00	100.00	100.00	100.00		22
8	100.00	91.67	83.33	100.00		22
9	99.49	83.33	83.33	83.33		22
10	100.00	100.00	100.00	100.00		22
Average	99.90	<b>92.08</b>	<b>90.83</b>	<b>93.33</b>	Total	<b>220</b>

ตารางที่ 4.4 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy)

ด้วยสถาปัตยกรรม VoxNet สำหรับข้อมูลแบบ Epilepsy: Split2

Musician Classification Using VoxNet						
Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
1	100.00	92.11	50.00	97.06		34
2	100.00	92.11	50.00	97.06		34
3	99.07	89.47	25.00	97.06		34
4	99.69	92.11	50.00	97.06		34
5	100.00	89.47	50.00	94.12		34
6	99.69	92.11	50.00	97.06		34
7	100.00	89.47	50.00	94.12		34
8	99.69	86.84	25.00	94.12		34
9	99.69	89.47	25.00	97.06		34
10	99.07	92.11	50.00	97.06		34
Average	99.69	90.53	42.50	96.18	Total	340

ตารางที่ 4.5 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) ด้วยสถาปัตยกรรม VoxNet สำหรับข้อมูลแบบ Musician: All

Split 1: The Musician Classification Using VoxNet						
Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
1	100.00	50.00	75.00	25.00		7
2	98.15	75.00	75.00	75.00		7
3	94.44	37.50	25.00	50.00		7
4	98.15	62.50	75.00	50.00		7
5	98.15	62.50	75.00	50.00		7
6	98.15	87.50	75.00	100.00		7
7	96.30	87.50	100.00	75.00		7
8	98.15	75.00	50.00	100.00		7

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
9	100.00	75.00	75.00	75.00		7
10	98.15	87.50	75.00	100.00		7
Average	97.96	70.00	70.00	70.00	Total	70

ตารางที่ 4.6 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician)

ด้วยสถาปัตยกรรม VoxNet สำหรับข้อมูลแบบ Musician: Split1

Split2: Musician Classification using VoxNet						
Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
1	100.00	75.00	75.00	75.00		7
2	100.00	75.00	100.00	50.00		7
3	100.00	75.00	75.00	75.00		7
4	100.00	100.00	100.00	100.00		7
5	100.00	25.00	0.00	50.00		7
6	100.00	75.00	75.00	75.00		7
7	100.00	62.50	75.00	50.00		7
8	98.15	50.00	25.00	75.00		7
9	100.00	50.00	75.00	25.00		7
10	98.15	75.00	75.00	75.00		7
Average	99.63	66.25	67.50	65.00	Total	70

ตารางที่ 4.7 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician)

ด้วยสถาปัตยกรรม VoxNet สำหรับข้อมูลแบบ Musician: Split2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Healthy, Musician and Epilepsy Classification Using VoxNet										
Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (Healthy) (%)	Testing Specificity (Healthy) (%)	Testing Sensitivity (Musician) (%)	Testing Specificity (Musician) (%)	Testing Sensitivity (Epilepsy) (%)	Testing Specificity (Epilepsy) (%)	Run Time (mins)	
1	99.07	94.74	100.00	93.33	50.00	100.00	100.00	100.00	34	
2	100.00	84.21	87.50	83.33	50.00	96.15	88.46	100.00	34	
3	99.69	84.21	62.50	90.00	50.00	90.00	96.15	100.00	34	
4	98.46	86.84	75.00	90.00	50.00	96.43	96.15	88.89	34	
5	99.07	84.21	62.50	90.00	50.00	93.10	96.15	87.50	34	
6	99.07	84.21	62.50	96.43	50.00	93.10	96.15	70.00	34	
7	100.00	86.84	87.50	92.86	25.00	92.86	96.15	88.89	34	
8	99.38	81.58	87.50	88.89	25.00	92.31	88.46	80.00	34	
9	99.69	78.95	50.00	86.67	25.00	89.66	96.15	83.33	34	
10	99.07	84.21	37.50	100.00	100.00	85.29	96.15	87.50	34	
Average	99.35	85.00	71.25	91.15	47.50	92.89	95.00	88.61	Total	

ตารางที่ 4.8 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่มีสุขภาพดี (Healthy) ผู้ที่เป็นนักดนตรี (Musician) และผู้ที่เป็นโรคลมชัก (Epilepsy) ด้วยสถาปัตยกรรม VoxNet สำหรับข้อมูลแบบ Healthy, Musician and Epilepsy: All

#### 4.4.2 ผลการทดลองสำหรับสถาปัตยกรรม 3D NIN FC

ในหัวข้อนี้แสดงผลการทดลองจากการแบ่งข้อมูลทั้ง 7 แบบ (ในหัวข้อที่ 3.2.2.1.1 ข้อ 1, 2, 3, 4, 5, 6 และ 7) โดยสร้างโมเดลจากสถาปัตยกรรม 3D NIN FC เพื่อทำการจำแนกตามรูปแบบของ 10-Fold Cross Validation โดยผลการทดลองสำหรับการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) สำหรับชุดข้อมูล Epilepsy: All, Epilepsy: Split1, Epilepsy: Split2 แสดงในตารางที่ 4.9, 4.10 และ 4.11 ตามลำดับ ผลการทดลองสำหรับการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) สำหรับชุดข้อมูล Musician: All, Musician: Split1, Musician: Split2 แสดงในตาราง 4.12, 4.13 และ 4.14 ในส่วนของผลการทดลองสำหรับการสร้างโมเดลจำแนกผู้ที่มีสุขภาพดี (Healthy) ผู้ที่เป็นนักดนตรี (Musician) และผู้ที่เป็นโรคลมชัก (Epilepsy) เป็นการทำนายแบบ 3 แบบ (3 Targets) สำหรับชุดข้อมูลที่ Healthy, Musician and Epilepsy: All แสดงในตาราง 4.15

Epilepsy Classification Using 3D NIN FC					
Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)	Run Time (mins)
1	100.00	100.00	100.00	100.00	94
2	100.00	89.47	84.62	100.00	94
3	99.69	94.74	96.15	91.67	94
4	99.69	97.37	96.15	100.00	94
5	98.46	94.74	96.15	91.67	94
6	100.00	86.84	96.15	66.67	94
7	99.07	92.11	92.31	91.67	94
8	98.46	84.21	84.62	83.33	94
9	99.69	94.74	96.15	91.67	94
10	99.07	94.74	100.00	83.33	94
Average	99.41	92.89	94.23	90.00	Total 940

ตารางที่ 4.9 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy)

ด้วยสถาปัตยกรรม 3D NIN FC สำหรับข้อมูลแบบ Epilepsy: All

Split1: Epilepsy Classification Using 3D NIN FC						
Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
1	99.49	79.17	83.33	75.00		58
2	99.49	91.67	83.33	100.00		58
3	99.49	95.83	100.00	91.67		58
4	100.00	100.00	100.00	100.00		58
5	99.49	87.50	75.00	100.00		58
6	98.99	95.83	91.67	100.00		58
7	100.00	100.00	100.00	100.00		58
8	100.00	91.67	83.33	100.00		58
9	98.99	83.33	83.33	83.33		58
10	100.00	100.00	100.00	100.00		58
Average	99.59	92.50	90.00	95.00	Total	580

ตารางที่ 4.10 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) ด้วยสถาปัตยกรรม 3D NIN FC สำหรับข้อมูลแบบ Epilepsy: Split1

Split2: Epilepsy Classification Using 3D NIN FC						
Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
1	100.00	83.33	91.67	75.00		58
2	100.00	91.67	91.67	91.67		58
3	100.00	91.67	100.00	83.33		58
4	100.00	95.83	91.67	100.00		58
5	100.00	91.67	83.33	100.00		58
6	98.99	95.83	91.67	100.00		58
7	100.00	95.83	100.00	91.67		58
8	100.00	91.67	83.33	100.00		58
9	100.00	87.50	91.67	83.33		58

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้เผยแพร่ไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
10	100.00	100.00	100.00	100.00		58
Average	99.90	<b>92.50</b>	<b>92.50</b>	<b>92.50</b>	Total	<b>580</b>

ตารางที่ 4.11 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy)

ด้วยสถาปัตยกรรม 3D NIN FC สำหรับข้อมูลแบบ Epilepsy: Split2

Musician Classification Using 3D NIN FC						
Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
1	99.69	94.74	50.00	100.00		94
2	100.00	92.11	50.00	97.06		94
3	96.30	94.74	75.00	97.06		94
4	99.38	92.11	50.00	97.06		94
5	99.07	86.84	25.00	94.12		94
6	99.38	92.11	50.00	97.06		94
7	98.77	97.37	75.00	100.00		94
8	100.00	84.21	25.00	91.18		94
9	99.38	84.21	25.00	91.18		94
10	99.38	92.11	75.00	94.12		94
Average	99.14	<b>91.05</b>	<b>50.00</b>	<b>95.88</b>	Total	<b>940</b>

ตารางที่ 4.12 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician)

ด้วยสถาปัตยกรรม 3D NIN FC สำหรับข้อมูลแบบ Musician: All

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Split1: Musician Classification Using 3D NIN FC						
Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
1	94.44	75.00	75.00	75.00		18
2	100.00	50.00	25.00	75.00		18
3	98.15	37.50	50.00	25.00		18
4	100.00	62.50	75.00	50.00		18
5	100.00	62.50	75.00	50.00		18
6	100.00	75.00	50.00	100.00		18
7	100.00	62.50	75.00	50.00		18
8	100.00	62.50	50.00	75.00		18
9	98.15	75.00	75.00	75.00		18
10	98.15	62.50	50.00	75.00		18
Average	98.89	62.50	60.00	65.00	Total	180

ตารางที่ 4.13 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) ด้วยสถาปัตยกรรม 3D NIN FC สำหรับข้อมูลแบบ Musician: Split1

Split2: Musician Classification Using 3D NIN FC						
Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
1	100.00	87.50	75.00	100.00		18
2	88.89	62.50	75.00	50.00		18
3	92.59	87.50	75.00	100.00		18
4	96.30	75.00	75.00	75.00		18
5	100.00	12.50	0.00	25.00		18
6	96.30	75.00	75.00	75.00		18
7	96.30	75.00	75.00	75.00		18
8	100.00	50.00	25.00	75.00		18
9	100.00	37.50	50.00	25.00		18

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (%)	Testing Specificity (%)		Run Time (mins)
10	96.30	50.00	75.00	25.00		18
Average	96.67	61.25	60.00	62.50	Total	180

ตารางที่ 4.14 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician)

ด้วยสถาปัตยกรรม 3D NIN FC สำหรับข้อมูลแบบ Musician: Split2




เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Healthy, Musician and Epilepsy Classification Using 3D NIN FC									
Fold	Training Accuracy (%)	Testing Accuracy (%)	Testing Sensitivity (Healthy) (%)	Testing Specificity (Healthy) (%)	Testing Sensitivity (Musician) (%)	Testing Specificity (Musician) (%)	Testing Sensitivity (Epilepsy) (%)	Testing Specificity (Epilepsy) (%)	Run Time (mins)
1	99.07	92.11	87.50	96.55	50.00	96.55	100.00	90.00	94
2	99.38	81.58	100.00	82.14	25.00	95.83	84.62	90.00	94
3	100.00	84.21	50.00	93.33	75.00	90.32	96.15	87.50	94
4	99.69	86.84	75.00	90.00	50.00	93.10	96.15	100.00	94
5	98.77	78.95	50.00	89.66	25.00	92.86	96.15	62.50	94
6	99.38	84.21	62.50	96.43	50.00	93.10	96.15	70.00	94
7	98.77	89.47	100.00	89.66	50.00	100.00	92.31	90.91	94
8	99.07	81.58	87.50	92.31	25.00	88.89	88.46	80.00	94
9	98.77	81.58	50.00	90.00	50.00	90.00	96.15	85.71	94
10	99.07	84.21	50.00	100.00	100.00	90.32	92.31	72.73	94
Average	99.20	84.47	71.25	92.01	50.00	93.10	93.85	82.94	Total 940


ตารางที่ 4.15 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่มีสุขภาพดี (Healthy) ผู้ที่เป็นนักดนตรี (Musician) และผู้ที่เป็นโรคลมชัก (Epilepsy) ด้วยสถาปัตยกรรม 3D NIN FC สำหรับข้อมูลแบบ Healthy, Musician and Epilepsy: All

#### 4.4.3 การประเมินประสิทธิภาพของโมเดล


ในทุก ๆ 10 Epoch จะทำการบันทึกค่าน้ำหนัก (Weight) ของโมเดลล่าสุดไว้ โดย จะทำการหยุดการประมวลผลก็ต่อเมื่อพิจารณาค่า Training Accuracy ที่โมเดลทดสอบกับ ข้อมูลที่ใช้สำหรับการฝึกสอนก่อน (Training Data) และพิจารณาด้วยกับค่า Testing Accuracy ที่ทดสอบกับข้อมูลที่ใช้ในการทดสอบจริง (Test Data) ว่าค่าทั้งสองนี้ไม่มี แนวโน้มหรือไม่สามารถที่จะเพิ่มขึ้นได้อีก ถ้าค่าทั้งสองไม่เพิ่มขึ้นจากค่าสูงสุดที่เคยได้ ก็ สามารถหยุดการประมวลผล (การสร้างโมเดล) ได้ทันที จากการทดลองกรณีดังกล่าวจะเป็น ดังที่ กล่าวมาข้างต้นภายในจำนวน Epoch ที่ 150 ซึ่งเป็นเหตุผลที่ว่าทำไมค่า Hyperparameter: max\_epoch ถูกตั้งไว้ที่ 150 กราฟแสดงค่า Accuracy ทั้งสองที่ได้จาก การสร้างโมเดลสำหรับการแบ่งข้อมูล แบบ Epilepsy: All, Epilepsy: Split1, Epilepsy: Split2, Musician: All, Musician: Split1, Musician: Split2 และ Healthy, Musician and Epilepsy: All ตามข้อที่ 1, 2, 3, 4, 5, 6 และ 7 ในหัวข้อที่ 3.2.2.1.1 ตามลำดับ ค่าเฉลี่ย Training Accuracy และ Testing Accuracy ของทั้ง 10 Fold ที่ สร้างโมเดลด้วยกับ VoxNet และ 3D NIN FC สำหรับข้อมูลที่ถูกแบ่งไว้แต่ละประเภทแสดงในภาพที่ 4.7 – 4.20



ภาพที่ 4.7 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม VoxNet ด้วยการแบ่งข้อมูลแบบ Epilepsy: All ตั้งแต่ Epoch ที่ 1 ถึง 150




ภาพที่ 4.8 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม 3D NIN FC ด้วยการแบ่งข้อมูลแบบ Epilepsy: All ตั้งแต่ Epoch ที่ 1 ถึง 150




ภาพที่ 4.9 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม VoxNet ด้วยการแบ่งข้อมูลแบบ Epilepsy: Split1 ตั้งแต่ Epoch ที่ 1 ถึง 150

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




ภาพที่ 4.10 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม 3D NIN FC ด้วยการแบ่งข้อมูลแบบ Epilepsy: Split1 ตั้งแต่ Epoch ที่ 1 ถึง 150




ภาพที่ 4.11 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม VoxNet ด้วยการแบ่งข้อมูลแบบ Epilepsy: Split2 ตั้งแต่ Epoch ที่ 1 ถึง 150

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




ภาพที่ 4.12 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม 3D NIN FC ด้วยการแบ่งข้อมูลแบบ Epilepsy: Split2 ตั้งแต่ Epoch ที่ 1 ถึง 150




ภาพที่ 4.13 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยสถาปัตยกรรม VoxNet ด้วยการแบ่งข้อมูลแบบ Musician: All ตั้งแต่ Epoch ที่ 1 ถึง 150

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




ภาพที่ 4.14 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยสถาปัตยกรรม 3D NIN FC ด้วยการแบ่งข้อมูลแบบ Musician: All ตั้งแต่ Epoch ที่ 1 ถึง 150




ภาพที่ 4.15 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยสถาปัตยกรรม VoxNet ด้วยการแบ่งข้อมูลแบบ Musician: Split1 ตั้งแต่ Epoch ที่ 1 ถึง 150

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




ภาพที่ 4.16 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยสถาปัตยกรรม 3D NIN FC ด้วยการแบ่งข้อมูลแบบ Musician: Split1 ตั้งแต่ Epoch ที่ 1 ถึง 150




ภาพที่ 4.17 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยสถาปัตยกรรม VoxNet ด้วยการแบ่งข้อมูลแบบ Musician: Split2 ตั้งแต่ Epoch ที่ 1 ถึง 150

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




ภาพที่ 4.18 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยสถาปัตยกรรม 3D NIN FC ด้วยการแบ่งข้อมูลแบบ Musician: Split2 ตั้งแต่ Epoch ที่ 1 ถึง 150



ภาพที่ 4.19 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่มีสุขภาพดี (Healthy) ผู้ที่เป็นนักดนตรี (Musician) และผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม VoxNet ด้วยการแบ่งข้อมูลแบบ Healthy, Musician and Epilepsy: All ตั้งแต่ Epoch ที่ 1 ถึง 150

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

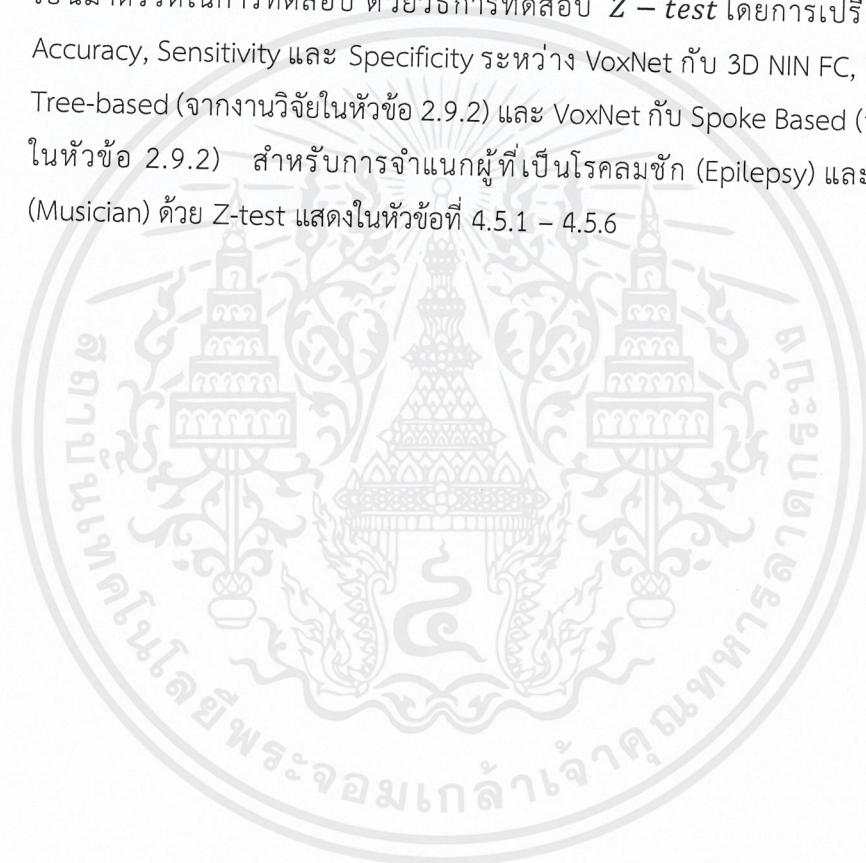


ภาพที่ 4.20 กราฟแสดงค่าเฉลี่ย Training Accuracy และ Testing Accuracy แต่ละ Epoch ทั้ง 10 Fold ของการสร้างโมเดลจำแนกผู้ที่มีสุขภาพดี (Healthy) ผู้ที่เป็นนักดนตรี (Musician) และผู้ที่เป็นโรคลมชัก (Epilepsy) โดยสถาปัตยกรรม 3D NIN FC ด้วยการแบ่งข้อมูลแบบ Healthy, Musician and Epilepsy: All ตั้งแต่ Epoch ที่ 1 ถึง 150

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

#### 4.5 ผลการทดสอบและประเมินประสิทธิภาพการจำแนกประเภทโพรงสมอง ด้านข้าง

หัวข้อนี้จะกล่าวถึงการเปรียบเทียบผลการทดลองที่ได้จากการสร้างโมเดลจำแนกด้วยสถาปัตยกรรม VoxNet และ 3D NIN FC สำหรับชุดข้อมูลทั้ง 7 รูปแบบ แสดงในตารางที่ 4.16 และ การทดสอบทางสถิติทั้ง 2 วิธีระหว่าง VoxNet และ 3D NIN FC โดยตั้งสมมติฐานจากผลการทดลองที่ดีที่สุดระหว่าง Epilepsy: Split1 - Epilepsy: Split2 และ Musician: Split1 - Musician: Split2 โดยใช้ค่า Accuracy, Sensitivity, และ Specificity เป็นมาตรวัดในการทดสอบ ด้วยวิธีการทดสอบ  $Z - test$  โดยการเปรียบเทียบค่า Accuracy, Sensitivity และ Specificity ระหว่าง VoxNet กับ 3D NIN FC, VoxNet กับ Tree-based (จากงานวิจัยในหัวข้อ 2.9.2) และ VoxNet กับ Spoke Based (จากงานวิจัยในหัวข้อ 2.9.2) สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) และ นักดนตรี (Musician) ด้วย Z-test แสดงในหัวข้อที่ 4.5.1 – 4.5.6



Name	Accuracy (%)		Sensitivity (%)		Specificity (%)		Total Run Time (mins)	
	VoxNet	3D NIN FC	VoxNet	3D NIN FC	VoxNet	3D NIN FC	VoxNet	3D NIN FC
Epilepsy: All	93.16	92.89	93.85	94.23	91.67	90.00	340	940
Epilepsy: Split1	92.50	92.50	90.83	90.00	94.17	95.00	220	580
Epilepsy: Split2	92.08	92.50	90.83	92.50	93.33	92.50	220	580
Musician: All	90.53	91.05	42.50	50.00	96.18	95.88	340	940
Musician: Split1	70.00	62.50	70.00	60.00	70.00	65.00	70	180
Musician: Split2	66.25	61.25	67.50	60.00	65.00	62.50	70	180

ตารางที่ 4.16 ตารางเปรียบเทียบผลการทดลองที่ได้จากการสร้างโมเดลจำแนกด้วยสถาปัตยกรรม VoxNet และ 3D NIN FC สำหรับข้อมูลแบบ Epilepsy: All , Epilepsy: Split1 , Epilepsy: Split2, Musician: All , Musician: Split1 , Musician: Split2

Architecture	Testing Accuracy (%)	Testing Sensitivity (Healthy) (%)	Testing Specificity (Healthy) (%)	Testing Sensitivity (Musician) (%)	Testing Specificity (Musician) (%)	Testing Sensitivity (Epilepsy) (%)	Testing Specificity (Epilepsy) (%)	Total Run Time (mins)
VoxNet	85.00	71.25	91.15	47.50	92.89	95.00	88.61	340
3D NIN	84.47	71.25	92.01	50.00	93.10	93.85	82.94	940

ตารางที่ 4.17 ผลการทดลองที่ได้จากการสร้างโมเดลจำแนกผู้ที่มีสุขภาพดี (Healthy) ผู้ที่เป็นนักดนตรี (Musician) และผู้ที่เป็นโรคลมชัก (Epilepsy) ด้วยสถาปัตยกรรม VoxNet และ 3D NIN FC สำหรับข้อมูลแบบ Healthy, Musician and Epilepsy: All

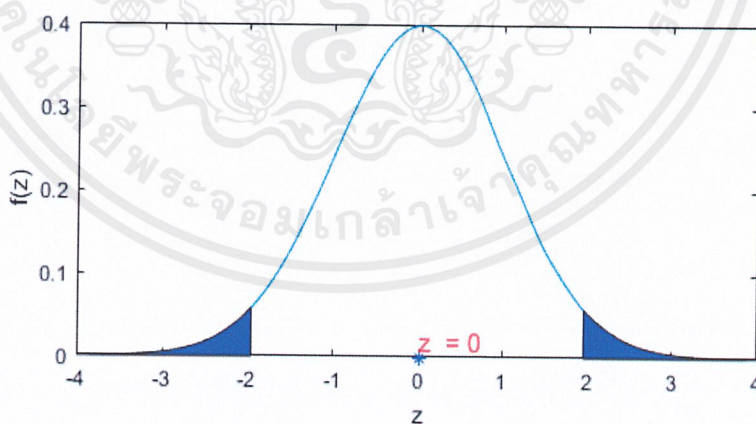
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

#### 4.5.1 การทดสอบประสิทธิภาพระหว่าง VoxNet และ 3D NIN FC ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Accuracy

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

โดยที่  $\mu_1$  คือค่า Accuracy ทั้ง 10 Fold ของชุดข้อมูลที่มีการแบ่งแบบ Epilepsy: Split1 จาก VoxNet ซึ่งมีค่าเท่ากับ 92.50 และ  $\mu_2$  คือค่า Accuracy ทั้ง 10 Fold ของชุดข้อมูลที่มีการแบ่งแบบ Epilepsy: Split1 จาก 3D NIN FC ซึ่งมีค่าเท่ากับ 92.50 จากการทดสอบ สมมติฐานโดยใช้  $\alpha$  เท่ากับ 0.05 ส่วนเบี่ยงเบนมาตรฐาน 10 Fold ของ Epilepsy: Split1 จาก 3D NIN FC มีค่าประมาณ 7.3 และจำนวน Fold เป็น 10 ทำให้ได้บริเวณวิกฤต Z น้อยกว่า -1.96 และ มากกว่า 1.96 จากนั้นคำนวณค่าสถิติทดสอบ Z ได้เท่ากับ 0 ซึ่งตกอยู่ในบริเวณที่ไม่ปฏิเสธสมมติฐานว่าง นั่นคือไม่มีหลักฐานเพียงพอที่จะปฏิเสธ  $H_0$  แสดงว่าไม่มีความแตกต่างกันอย่างมีนัยสำคัญระหว่างสถาปัตยกรรม VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Accuracy กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Accuracy แสดงดังภาพที่ 4.21




ภาพที่ 4.21 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Accuracy

#### 4.5.2 การทดสอบประสิทธิภาพระหว่าง VoxNet และ 3D NIN FC ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Accuracy

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

โดยที่  $\mu_1$  คือค่า Accuracy ทั้ง 10 Fold ของชุดข้อมูลที่มีการแบ่งแบบ Musician: Split1 จาก VoxNet ซึ่งมีค่าเท่ากับ 70 และ  $\mu_2$  คือค่าเฉลี่ย Accuracy ทั้ง 10 Fold ของชุดข้อมูลที่มีการแบ่งแบบ Musician: Split1 จาก 3D NIN FC ซึ่งมีค่าเท่ากับ 62.5 จากการทดสอบ สมมติฐานโดยใช้  $\alpha$  เท่ากับ 0.05 ส่วนเบี่ยงเบนมาตรฐาน 10 Fold ของกลุ่ม Musician: Split1 จาก 3D NIN FC ประมาณ 11.79 และ จำนวน Fold เท่ากับ 10 ทำให้ได้บริเวณวิกฤต Z น้อยกว่า -1.96 และ มากกว่า 1.96 จากนั้นคำนวณค่าสถิติทดสอบ Z ได้เท่ากับ 2.01 ซึ่งตกอยู่ในบริเวณวิกฤต นั่นคือมีหลักฐานเพียงพอที่จะปฏิเสธ  $H_0$  แสดงว่ามีความแตกต่างกันอย่างมีนัยสำคัญระหว่างสถาปัตยกรรม VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Accuracy กราฟแสดงถึงค่าความเชื่อมั่น Z เท่ากับ 2.01 ตกอยู่ในช่วงวิกฤต z ที่ 1.96 และ -1.96 จึงยอมรับ  $H_1 : \mu_1 \neq \mu_2$  แสดงดังภาพที่ 4.22




ภาพที่ 4.22 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Accuracy

#### 4.5.3 การทดสอบประสิทธิภาพระหว่าง VoxNet และ 3D NIN FC ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Sensitivity

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

โดยที่  $\mu_1$  คือ ค่า Sensitivity ทั้ง 10 Fold ของกลุ่ม Epilepsy: Split1 จาก VoxNet โดยมีค่าเท่ากับ 90.83 และ  $\mu_2$  คือ ค่า Sensitivity ทั้ง 10 Fold ของกลุ่ม Epilepsy: Split2 จาก 3D-NIN FC โดยมีค่าเท่ากับ 92.50 จากการทดสอบ สมมติฐานโดยใช้  $\alpha$  เท่ากับ 0.05 ส่วนเบี่ยงเบนมาตรฐาน 10 Fold ของกลุ่ม Epilepsy: Split1 จาก 3D-NIN FC ประมาณ 6.15 และ จำนวน Fold เท่ากับ 10 ทำให้ได้บริเวณวิกฤต Z น้อยกว่า -1.96 และ มากกว่า 1.96 จากนั้นคำนวณค่าสถิติทดสอบ  $Z$  ได้เท่ากับ -0.86 ซึ่งตกอยู่ในบริเวณที่ไม่ปฏิเสธสมมติฐานว่าง นั่นคือไม่มีหลักฐานเพียงพอที่จะปฏิเสธ  $H_0$  แสดงว่าไม่มีความแตกต่างกันอย่างมีนัยสำคัญระหว่างสถาปัตยกรรม VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Sensitivity กราฟแสดงถึงค่าความเชื่อมั่น  $Z$  เท่ากับ -0.86 ไม่ได้ตกอยู่ในช่วงวิกฤต  $z$  ที่ 1.96 และ -1.96 จึงยอมรับ  $H_0 : \mu_1 = \mu_2$  แสดงดังภาพที่ 4.23




ภาพที่ 4.23 กราฟแสดงค่า  $Z$  ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Sensitivity

#### 4.5.4 การทดสอบประสิทธิภาพระหว่าง VoxNet และ 3D NIN FC ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Sensitivity

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

โดยที่  $\mu_1$  คือ ค่า Sensitivity ทั้ง 10 Fold ของกลุ่ม Musician: Split1 จาก VoxNet โดยมีค่าเท่ากับ 70 และ  $\mu_2$  คือ ค่า Sensitivity ทั้ง 10 Fold ของกลุ่ม Musician: Split1 จาก 3D-NIN FC โดยมีค่าเท่ากับ 60 จากการทดสอบ สมมติฐานโดยใช้  $\alpha$  เท่ากับ 0.05 ส่วนเบี่ยงเบนมาตรฐาน 10 Fold ของกลุ่ม Musician: Split1 จาก 3D-NIN FC ประมาณ 17.48 และ จำนวน Fold เท่ากับ 10 ทำให้ได้บริเวณวิกฤต Z น้อยกว่า -1.96 และ มากกว่า 1.96 จากนั้นคำนวณค่าสถิติทดสอบ  $Z$  ได้เท่ากับ 1.81 ซึ่งตกอยู่ในบริเวณที่ไม่ปฏิเสธสมมติฐานว่าง นั่นคือไม่มีหลักฐานเพียงพอที่จะปฏิเสธ  $H_0$  แสดงว่าไม่มีความแตกต่างกันอย่างมีนัยสำคัญระหว่างสถาปัตยกรรม VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Sensitivity กราฟแสดงถึงค่าความเชื่อมั่น  $Z$  เท่ากับ 1.81 ไม่ได้ตกอยู่ในช่วงวิกฤต  $z$  ที่ 1.96 และ -1.96 จึงยอมรับ  $H_0 : \mu_1 = \mu_2$  แสดงดังภาพที่ 4.24




ภาพที่ 4.24 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Sensitivity

#### 4.5.5 การทดสอบประสิทธิภาพระหว่าง VoxNet และ 3D NIN FC ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Specificity

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

โดยที่  $\mu_1$  คือ ค่า Specificity ทั้ง 10 Fold ของกลุ่ม Epilepsy: Split1 จาก VoxNet โดยมีค่าเท่ากับ 94.17 และ  $\mu_2$  คือ ค่า Specificity ทั้ง 10 Fold ของกลุ่ม Epilepsy: Split1 จาก 3D-NIN FC โดยมีค่าเท่ากับ 95 จากการทดสอบ สมมติฐานโดยใช้  $\alpha$  เท่ากับ 0.05 ส่วนเบี่ยงเบนมาตรฐาน 10 Fold ของกลุ่ม Epilepsy: Split1 จาก 3D-NIN FC ประมาณ 8.96 และ จำนวน Fold เท่ากับ 10 ทำให้ได้บริเวณวิกฤต Z น้อยกว่า -1.96 และ มากกว่า 1.96 จากนั้นคำนวณค่าสถิติทดสอบ Z ได้เท่ากับ -0.29 ซึ่งตกอยู่ในบริเวณที่ไม่ปฏิเสธสมมติฐานว่าง นั่นคือไม่มีหลักฐานเพียงพอที่จะปฏิเสธ  $H_0$  แสดงว่าไม่มีความแตกต่างกันอย่างมีนัยสำคัญระหว่างสถาปัตยกรรม VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Specificity กราฟแสดงถึงค่าความเชื่อมั่น Z เท่ากับ -0.29 ไม่ได้ตกอยู่ในช่วงวิกฤต z ที่ 1.96 และ -1.96 จึงยอมรับ  $H_0 : \mu_1 = \mu_2$  แสดงดังภาพที่ 4.25




ภาพที่ 4.25 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Specificity

#### 4.5.6 การทดสอบประสิทธิภาพระหว่าง VoxNet และ 3D NIN FC ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Specificity

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

โดยที่  $\mu_1$  คือ ค่า Specificity ทั้ง 10 Fold ของกลุ่ม Musician: Split1 จาก VoxNet โดยมีค่าเท่ากับ 70 และ  $\mu_2$  คือ ค่า Specificity ทั้ง 10 Fold ของกลุ่ม Musician: Split1 จาก 3D-NIN FC โดยมีค่าเท่ากับ 65 จากการทดสอบ สมมติฐานโดยใช้  $\alpha$  เท่ากับ 0.05 ส่วนเบี่ยงเบนมาตรฐาน 10 Fold ของกลุ่ม Musician: Split1 จาก 3D-NIN FC ประมาณ 21.08 และ จำนวน Fold เท่ากับ 10 ทำให้ได้บริเวณวิกฤต Z น้อยกว่า -1.96 และ มากกว่า 1.96 จากนั้นคำนวณค่าสถิติทดสอบ  $Z$  ได้เท่ากับ 0.75 ซึ่งตกอยู่ในบริเวณที่ไม่ปฏิเสธสมมติฐานว่าง นั่นคือไม่มีหลักฐานเพียงพอที่จะปฏิเสธ  $H_0$  แสดงว่าไม่มีความแตกต่างกันอย่างมีนัยสำคัญระหว่างสถาปัตยกรรม VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Specificity กราฟแสดงถึงค่าความเชื่อมั่น  $Z$  เท่ากับ 0.75 ไม่ได้ตกอยู่ในช่วงวิกฤต  $z$  ที่ 1.96 และ -1.96 จึงยอมรับ  $H_0 : \mu_1 = \mu_2$  แสดงดังภาพที่ 4.26



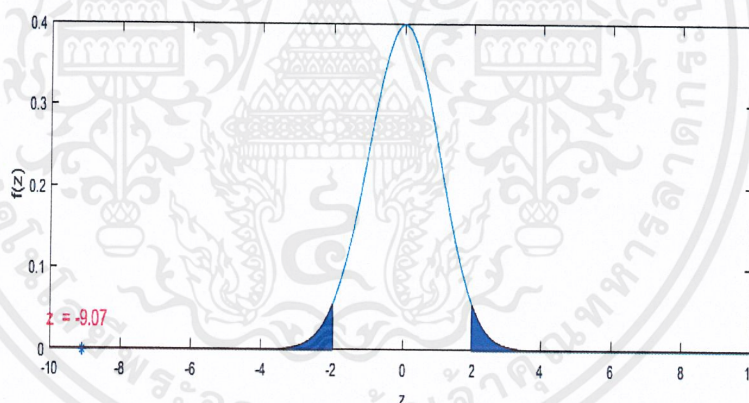
ภาพที่ 4.26 กราฟแสดงค่า  $Z$  ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ 3D NIN FC สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Specificity

#### 4.5.7 การทดสอบประสิทธิภาพระหว่าง VoxNet และ Tree-based ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Accuracy

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

โดยที่  $\mu_1$  คือ ค่าความแม่นยำของ Tree-based โดยมีค่าเท่ากับ 72.34 และ  $\mu_2$  คือ ค่าความแม่นยำ 10 Fold ของกลุ่ม Split1:Epilepsy Classification Using VoxNet โดยมีค่าเท่ากับ 92.5 จากการทดสอบ สมมติฐานโดยใช้  $\alpha$  เท่ากับ 0.05 ส่วนเบี่ยงเบนมาตรฐานของ Split1: Epilepsy Classification Using VoxNet ประมาณ 7.03 และจำนวน Fold เท่ากับ 10 ทำให้ได้บริเวณวิกฤต Z น้อยกว่า -1.96 และ มากกว่า 1.96 จากนั้นคำนวณค่าสถิติทดสอบ Z ได้เท่ากับ -9.07 ซึ่งตกอยู่ในบริเวณวิกฤต นั่นคือมีหลักฐานเพียงพอที่จะปฏิเสธ  $H_0$  แสดงว่า วิธีการ VoxNet มีความแตกต่างกับวิธีการ Tree-based อย่างมีนัยสำคัญที่ระดับความเชื่อมั่น 95 % แสดงดังภาพที่ 4.27




ภาพที่ 4.27 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ Tree-based สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Accuracy

#### 4.5.8 การทดสอบประสิทธิภาพระหว่าง VoxNet และ Tree-based ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Accuracy

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

โดยที่  $\mu_1$  คือ ค่าความแม่นยำของ Tree-based โดยมีค่าเท่ากับ 86.32 และ  $\mu_2$  คือ ความแม่นยำ 10 Fold ของกลุ่ม Split1:Musician Classification Using VoxNet โดยมีค่าเท่ากับ 70 จากการทดสอบ สมมติฐานโดยใช้  $\alpha$  เท่ากับ 0.05 ส่วนเบี่ยงเบนมาตรฐานของ Split1: Musician Classification Using VoxNet ประมาณ 19.72 และ จำนวน Fold เท่ากับ 10 ทำให้ได้บริเวณวิกฤต Z น้อยกว่า -1.96 และ มากกว่า 1.96 จากนั้นคำนวณค่าสถิติทดสอบ  $Z$  ได้เท่ากับ 2.62 ซึ่งตกอยู่ในบริเวณวิกฤต นั่นคือมีหลักฐานเพียงพอที่จะปฏิเสธ  $H_0$  แสดงว่า วิธีการ VoxNet มีความแตกต่างกับวิธีการ Tree-based อย่างมีนัยสำคัญที่ระดับความเชื่อมั่น 95 % แสดงดังภาพที่ 4.28




ภาพที่ 4.28 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ Tree-based สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Accuracy

#### 4.5.9 การทดสอบประสิทธิภาพระหว่าง VoxNet และ Tree-based ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Sensitivity

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

โดยที่  $\mu_1$  คือ ค่า Sensitivity ของ Tree-based โดยมีค่าเท่ากับ 75.64 และ  $\mu_2$  คือ ค่า Sensitivity 10 Fold ของกลุ่ม Split1:Epilepsy Classification Using VoxNet โดยมีค่าเท่ากับ 90.83 จากการทดสอบ สมมติฐานโดยใช้  $\alpha$  เท่ากับ 0.05 ส่วนเบี่ยงเบนมาตรฐานของ Split1: Epilepsy Classification Using VoxNet ประมาณ 8.29 และจำนวน Fold เท่ากับ 10 ทำให้ได้บริเวณวิกฤต Z น้อยกว่า -1.96 และ มากกว่า 1.96 จากนั้นคำนวณค่าสถิติทดสอบ Z ได้เท่ากับ -5.79 ซึ่งตกอยู่ในบริเวณวิกฤต นั่นคือมีหลักฐานเพียงพอที่จะปฏิเสธ  $H_0$  แสดงว่า วิธีการ VoxNet มีความแตกต่างกับวิธีการ Tree-based อย่างมีนัยสำคัญที่ระดับความเชื่อมั่น 95 % แสดงดังภาพที่ 4.29




ภาพที่ 4.29 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ Tree-based สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Sensitivity

#### 4.5.10 การทดสอบประสิทธิภาพระหว่าง VoxNet และ Spoke Based ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Sensitivity

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

โดยที่  $\mu_1$  คือ ค่า Sensitivity ของ Spoke Based โดยมีค่าเท่ากับ 88.68 และ  $\mu_2$  คือ ค่า Sensitivity 10 Fold ของกลุ่ม Split1: Musician Classification Using VoxNet โดยมีค่าเท่ากับ 70 จากการทดสอบ สมมติฐานโดยใช้  $\alpha$  เท่ากับ 0.05 ส่วนเบี่ยงเบนมาตรฐานของ Split1: Musician Classification Using VoxNet ประมาณ 19.72 และจำนวน Fold เท่ากับ 10 ทำให้ได้บริเวณวิกฤต Z น้อยกว่า -1.96 และ มากกว่า 1.96 จากนั้นคำนวณค่าสถิติทดสอบ Z ได้เท่ากับ 2.99 ซึ่งตกอยู่ในบริเวณวิกฤต นั่นคือมีหลักฐานเพียงพอที่จะปฏิเสธ  $H_0$  แสดงว่า วิธีการ VoxNet มีความแตกต่างกับวิธีการ Tree-based อย่างมีนัยสำคัญที่ระดับความเชื่อมั่น 95 % แสดงดังภาพที่ 4.30



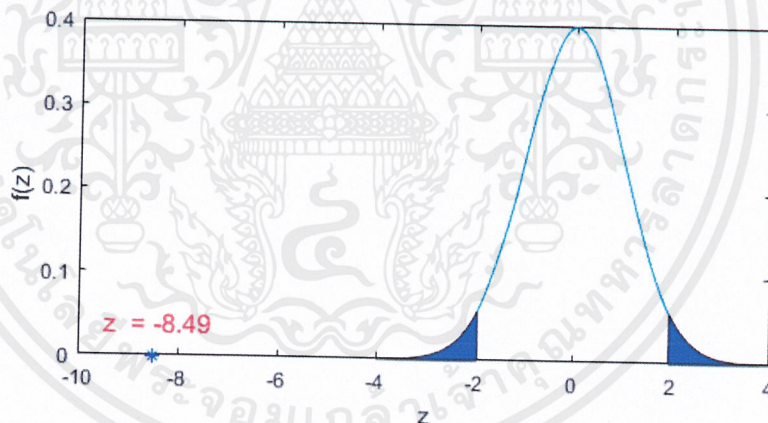
ภาพที่ 4.30 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ Spoke Based สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Sensitivity

#### 4.5.11 การทดสอบประสิทธิภาพระหว่าง VoxNet และ Tree-based ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Specificity

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

โดยที่  $\mu_1$  คือ ค่า Specificity Tree-based โดยมีค่าเท่ากับ 70.45 และ  $\mu_2$  คือ ค่าความจำเพาะ 10 Fold ของกลุ่ม Split1:Epilepsy Classification Using VoxNet โดยมีค่าเท่ากับ 94.17 จากการทดสอบ สมมติฐานโดยใช้  $\alpha$  เท่ากับ 0.05 ส่วนเบี่ยงเบนมาตรฐานของ Split1: Epilepsy Classification Using VoxNet ประมาณ 8.83 และ จำนวน Fold เท่ากับ 10 ทำให้ได้บริเวณวิกฤต Z น้อยกว่า -1.96 และ มากกว่า 1.96 จากนั้นคำนวณค่าสถิติทดสอบ Z ได้เท่ากับ -8.49 ซึ่งตกอยู่ในบริเวณวิกฤต นั่นคือมีหลักฐานเพียงพอที่จะปฏิเสธ  $H_0$  แสดงว่า วิธีการ VoxNet มีความแตกต่างกับวิธีการ Tree-based อย่างมีนัยสำคัญที่ระดับความเชื่อมั่น 95 % แสดงดังภาพที่ 4.31




ภาพที่ 4.31 กราฟแสดงค่า Z ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ Tree-based สำหรับการจำแนกผู้ที่เป็นโรคลมชัก (Epilepsy) โดยใช้มาตรวัด Specificity

#### 4.5.12 การทดสอบประสิทธิภาพระหว่าง VoxNet และ Tree-based ด้วย Z-test สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Specificity

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

โดยที่  $\mu_1$  คือ ค่า Specificity Tree-based โดยมีค่าเท่ากับ 80.19 และ  $\mu_2$  คือ ค่า Specificity 10 Fold ของกลุ่ม Split1: Musician Classification Using VoxNet โดยมีค่าเท่ากับ 70 จากการทดสอบ สมมติฐานโดยใช้  $\alpha$  เท่ากับ 0.05 ส่วนเบี่ยงเบนมาตรฐานของ Split1: Musician Classification Using VoxNet ประมาณ 25.82 และ จำนวน Fold เท่ากับ 10 ทำให้ได้บริเวณวิกฤต  $Z$  น้อยกว่า  $-1.96$  และ มากกว่า  $1.96$  จากนั้นคำนวณค่าสถิติทดสอบ  $Z$  ได้เท่ากับ  $1.25$  ซึ่งตกอยู่ในบริเวณที่ไม่ปฏิเสธสมมติฐานว่าง นั่นคือไม่มีหลักฐานเพียงพอที่จะปฏิเสธ  $H_0$  แสดงว่า วิธีการ VoxNet ไม่มีความแตกต่างกับวิธีการ Tree-based อย่างมีนัยสำคัญที่ระดับความเชื่อมั่น 95 % แสดงดังภาพที่ 4.32



ภาพที่ 4.32 กราฟแสดงค่า  $Z$  ของการทดสอบประสิทธิภาพสถาปัตยกรรมด้วย Z-test ระหว่าง VoxNet และ Tree-based สำหรับการจำแนกผู้ที่เป็นนักดนตรี (Musician) โดยใช้มาตรวัด Specificity

## 4.6 ปัญหาที่พบในการจำแนกประเภทโพรงสมองด้านข้าง


### 4.6.1 ชุดข้อมูลสำหรับคนเป็นนักร้องน้อยเกินไป

ชุดข้อมูลที่น้อยเกินไปมีส่วนที่ทำให้ค่า Training accuracy ไม่คงที่ ส่งผลให้เลือกโมเดลที่ดีที่สุดยากและค่า Testing accuracy ไม่สูงเท่าที่ควร เมื่อเทียบกับชุดข้อมูลของคนที่เป็นลมโรคลมชัก (Epilepsy)

### 4.6.2 การคำนวณภาพสามมิติและการสร้างโมเดลการเรียนรู้เชิงลึก

(Deep Learning) ต้องใช้ทรัพยากรในการคำนวณสูง

คอมพิวเตอร์ที่มีอยู่มีประสิทธิภาพไม่เพียงพอต่อการคำนวณภาพสามมิติ และการสร้างโมเดล เป็นเหตุให้ต้องมีการเช่า GPU Computing จากทาง AWS (Amazon Web Service)



## บทที่ 5

### สรุปผลการดำเนินงานและข้อเสนอแนะ

ในบทนี้จะกล่าวถึงการสรุปผลการดำเนินงานและข้อเสนอแนะ ซึ่งการสรุปผลการดำเนินงาน จะถูกนำเสนอในหัวข้อ 5.1 และข้อเสนอแนะจะถูกนำเสนอในหัวข้อ 5.2

#### 5.1 สรุปผลการดำเนินงาน

ปัญหาพิเศษนี้ได้นำเสนอวิธีการแบ่งส่วนโพรงสมองด้านข้าง และการจำแนกประเภทโพรงสมองด้านข้างด้วยวิธีการเรียนรู้เชิงลึก ซึ่งผลการทดลองการแบ่งส่วนโพรงสมองด้านข้างด้วยวิธีที่นำเสนอไม่มีความแตกต่างอย่างมีนัยสำคัญกับวิธีการแบ่งส่วนโพรงสมองด้านข้างด้วยมือผู้เชี่ยวชาญจากการทดสอบทางสถิติ อย่างไรก็ตามการเปรียบเทียบความคล้ายกันของโพรงสมองจากขนาดไม่สามารถบอกได้ว่ารูปร่างของโพรงสมองที่ได้จากทั้ง 2 วิธี มีความแตกต่างกันหรือไม่ เพราะข้อมูลที่ใช้เปรียบเทียบเป็นขนาดโพรงสมองด้านข้างเท่านั้น

หลังจากจากการแบ่งส่วน โพรงสมองด้านข้างทั้งหมดในชุดข้อมูลถูกนำมาเป็นข้อมูลในการจำแนกประเภทโดยใช้วิธีการเรียนรู้เชิงลึกโดยสถาปัตยกรรมที่ถูกนำมาใช้ได้แก่ สถาปัตยกรรม VoxNet และ 3D-NIN ซึ่งทั้งสองวิธีนี้ไม่มีความแตกต่างกันอย่างมีนัยสำคัญสำหรับมาตรวัด Accuracy, Sensitivity และ Specificity สำหรับชุดข้อมูล Epilepsy และไม่มีความแตกต่างกันอย่างมีนัยสำคัญสำหรับมาตรวัด Sensitivity และ Specificity สำหรับชุดข้อมูล Musician ที่ระดับความเชื่อมั่น 95% ขณะที่มาตรวัด Accuracy ของวิธีการ VoxNet และ 3D-NIN สำหรับชุดข้อมูล Musician แตกต่างกันอย่างมีนัยสำคัญที่ระดับ 0.05

#### 5.2 ข้อเสนอแนะ

วิธีการแบ่งส่วนโพรงสมองด้านข้างสามารถพัฒนาให้แบ่งส่วนข้างซ้ายและข้างขวาแยกออกจากกันได้ และสามารถพัฒนาขั้นตอนวิธีให้ผลมีความแม่นยำมากขึ้นโดยการใช้ Active-Contour แบบย้อนกลับจากวิธีเดิม ทำให้ส่วนพิกเซลที่ขาดเชื่อมต่อกันได้มากขึ้น

ในส่วนของการจำแนกประเภทโพรงสมองด้านข้างสามารถใช้เทคนิคที่เรียกว่า Data Augmentation ซึ่งอาจช่วยเพิ่มประสิทธิภาพของโมเดลให้มีความแม่นยำขึ้นได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บรรณานุกรม

- กฤษณะ ชินสาร, สุวรรณ รัศมีขวัญ, เบญจภรณ์ จันทรวงกุล, ภูสิต กุลเกษม, อังณัฐพันธ์ รอด  
ทุกข์, ชิดชนก เหลือสินทรัพย์ และปิยตระกูล บุญทอง. 2557. “การตรวจหามะเร็งเต้านมโดย  
การตรวจหามวลที่มีรูปร่างแบบ Spiculation สำหรับคอมพิวเตอร์ช่วยการวินิจฉัยใน  
โรงพยาบาล”, รายงานวิจัยฉบับสมบูรณ์ โครงการวิจัยประเภทงบประมาณเงินรายได้ จากเงิน  
อุดหนุนรัฐบาล (งบประมาณแผ่นดิน) ปีงบประมาณ พ.ศ. 2557 มหาวิทยาลัยบูรพา, หน้า 15-  
17.
- ชัยชนะ กุลวรรฐิต, ฐาปนกร ชาวสำอาง และ ณ หทัย อึ้งเจริญสุข. 2559. “การแบ่งส่วนโพรงสมอง  
ด้านข้างจากภาพเอ็มอาร์ไอสามมิติ.” ปริญญาโท วิทยาศาสตรบัณฑิต สาขาวิทยาการ  
คอมพิวเตอร์, สถาบัน เทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง.
- วิไลพร กุลตั้งวัฒนา และกริช สมกันธา. 2558. “การแยกแยะภาพหัวใจห้องล่างซ้ายในภาพคลื่น  
แม่เหล็กไฟฟ้าหัวใจโดยเอกซิมคอนทัวริโมเดล”, *วิศวกรรมสาร มก.*, ฉบับที่ 92 ปีที่ 28, หน้า  
61-70.
- สายชล ใจเย็น. 2560. “Convolutional Neural Networks” เอกสารประกอบการสอนวิชาการ  
เรียนรู้ของเครื่อง, สถาบัน เทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง.
- Kempton, M. J., Underwood, T. S.A., Brunton, S., Stylios, F., Schmechtig, A., Ettinger,  
U., . . . Simmons, A. “A Comprehensive Testing Protocol for MRI  
Neuroanatomical Segmentation Techniques: Evaluation of A Novel Lateral  
Ventricle Segmentation Method”, *Journal of NeuroImage*, Volume 58 Issue 4,  
Pages 1051-1059, Elsevier, 2011.

- Kass, M. Witkin, A. and Terzopoulos, D. “Snakes: Active contour models”,  
*International Journal of Computer Vision*, Pages 321-331, Kluwer Academic  
Publishers, Boston, 1988.
- Lin, M. Chen, Q. Yan, S. “Network in Network”, *arXiv: 1312.4400v3 [cs.NE]*, 2014.
- Long, S. and Holder L. B. “Graph-Based Shape Analysis for MRI Classification”,  
*International Journal of Knowledge Discovery in Bioinformatics*, Pages 19-33,  
2011.
- Maturana, D. and Scherer, S. “VoxNet: A 3D Convolutional Neural Network for Real-  
Time Object Recognition”, in *2015 IEEE/RSJ International Conference on  
Intelligent Robots and Systems (IROS)*, Hamburg: IEEE, 2015.
- Qi, C. R. Su, H. Niessner, M. Dai, A. Yan, M. and Guibas L. J. “Volumetric and Multi-  
View CNNs for Object Classification on 3D Data”, *arXiv: 1604.03265v2 [cs.CV]*,  
2016.
- Shahedi, M. “imshow3D (3D imshow)” [Online].  
[https://www.mathworks.com/matlabcentral/fileexchange/41334-imshow3d--3d-  
imshow-](https://www.mathworks.com/matlabcentral/fileexchange/41334-imshow3d--3d-imshow-), 2018. (1 April 2018).
- “Segment Lungs from 3-D Chest Scan and Calculate Lung Volume” [Online].  
[https://www.mathworks.com/help/images/segment-lungs-from-3-d-chest-mri-  
data.html](https://www.mathworks.com/help/images/segment-lungs-from-3-d-chest-mri-data.html). (1 April 2018).
- spm. “Statistical Parametric Mapping” [Online]. <http://www.fil.ion.ucl.ac.uk/spm/>,  
2018. (1 April 2018).

Udomchaiporn A., Coenen F., García-Fiñana M., Sluming V. “3-D MRI Brain Scan Feature Classification Using an Oct-tree Representation”. In: Motoda H., Wu Z., Cao L., Zaiane O., Yao M., Wang W. (eds) *Advanced Data Mining and Applications. ADMA 2013. Lecture Notes in Computer Science*, vol 8346. Springer, Berlin, Heidelberg, 2013.

Udomchaiporn A., Coenen F., García-Fiñana M., Sluming V. “3-D Volume of Interest Based Image Classification”. In: Booth R., Zhang ML. (eds) *PRICAI 2016: Trends in Artificial Intelligence. PRICAI 2016. Lecture Notes in Computer Science*, vol 9810. Springer, 2016.

Zhang, Y. Brady, M. and Smith, S. “Segmentation of Brain MR Images Through A Hidden Markov Random Field Model and The Expectation-maximization Algorithm”, *IEEE Transactions on Medical Imaging*, Volume 20 Issue 1, Pages 45-57, 2001.