



การตรวจจับและระบุตำแหน่งของจุดเลือดออกในสมองจากภาพถ่าย

คลื่นแม่เหล็กไฟฟ้าโดยใช้เครือข่ายแบบสังวัตนาการ

Cerebral Microbleed Detection by Extracting Area and Number from
Susceptibility Weighted Imagery using Convolutional Neural Network

สุจิตตรา เสงี่ยม

Sujittra Sa-ngiem

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญา

วิทยาศาสตรมหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ

มหาวิทยาลัยสงขลานครินทร์

A Thesis Submitted in Partial Fulfillment of the Requirements for the

Degree the Master of Science in Information Technology

Prince of Songkla University

2562

ลิขสิทธิ์ของมหาวิทยาลัยสงขลานครินทร์



การตรวจจับและระบุตำแหน่งของจุดเลือดออกในสมองจากภาพถ่าย

คลื่นแม่เหล็กไฟฟ้าโดยใช้เครือข่ายแบบสังวัตนาการ

Cerebral Microbleed Detection by Extracting Area and Number from
Susceptibility Weighted Imagery using Convolutional Neural Network

สุจิตตรา เสงี่ยม

Sujitra Sa-ngiem

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญา

วิทยาศาสตรมหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ

มหาวิทยาลัยสงขลานครินทร์

A Thesis Submitted in Partial Fulfillment of the Requirements for the

Degree the Master of Science in Information Technology

Prince of Songkla University

2562

ลิขสิทธิ์ของมหาวิทยาลัยสงขลานครินทร์

ชื่อวิทยานิพนธ์ การตรวจจับและระบุตำแหน่งของจุดเชื่อมต่อออกในสมองจากภาพถ่ายคลื่นแม่เหล็กไฟฟ้าโดยใช้เครือข่ายแบบสังวัตนาการ

ผู้เขียน นางสุจิตตรา เสี่ยงม

สาขาวิชา เทคโนโลยีสารสนเทศ

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

คณะกรรมการสอบ

.....
(ดร.ขวัญกมล ดิฐกัญจน์)

.....ประธานกรรมการ
(ดร.กรวิทย์ พฤษชัยนิมิต)

.....กรรมการ
(ดร.ขวัญกมล ดิฐกัญจน์)

.....กรรมการ
(ดร.สรรพฤทธิ มฤคทัต)

บัณฑิตวิทยาลัย มหาวิทยาลัยสงขลานครินทร์ อนุมัติให้บัณฑิตวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา ตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ

.....
(ศาสตราจารย์ ดร.ดำรงศักดิ์ ฟ้ารุ่งแสง)
คณบดีบัณฑิตวิทยาลัย

ขอรับรองว่า ผลงานวิจัยนี้มาจากการศึกษาวิจัยของนักศึกษาเอง และได้แสดงความขอบคุณบุคคล
ที่มีส่วนช่วยเหลือแล้ว

ลงชื่อ.....

(ดร.ขวัญกมล ตีรภักดิ์)

อาจารย์ที่ปรึกษาวิทยานิพนธ์

ลงชื่อ.....

(นางสุจิตตรา เสงี่ยม)

นักศึกษา

(4)

ข้าพเจ้าขอรับรองว่า ผลงานวิจัยนี้ไม่เคยเป็นส่วนหนึ่งในการอนุมัติปริญญาในระดับใดมาก่อน และ
ไม่ได้ถูกใช้ในการยื่นขออนุมัติปริญญาในขณะนี้

ลงชื่อ.....

(นางสุจิตตรา เสงี่ยม)

นักศึกษา

ชื่อวิทยานิพนธ์	การตรวจจับและระบุตำแหน่งของจุดเลือดออกในสมองจากภาพถ่ายคลื่นแม่เหล็กไฟฟ้าโดยใช้เครือข่ายแบบสังวัตนาการ
ผู้เขียน	นางสุจิตตรา เสงี่ยม
สาขาวิชา	เทคโนโลยีสารสนเทศ
ปีการศึกษา	2561

บทคัดย่อ

การตรวจจับจุดเลือดออกในสมอง (Cerebral Microbleeding: CMB) เป็นภาวะเลือดออกในสมองเป็นจุดเล็ก ๆ ซึ่งเป็นอาการเริ่มต้นของโรคอัลไซเมอร์ ซึ่งเดิมการวินิจฉัยกระทำโดยแพทย์เฉพาะทางด้านประสาทวิทยาหรือผู้เชี่ยวชาญ อย่างไรก็ตามกระบวนการนี้ใช้เวลานาน และผลลัพธ์ที่ได้ไม่แม่นยำ เนื่องจากขึ้นอยู่กับประสบการณ์ของแพทย์ ซึ่งประสิทธิภาพและความน่าเชื่อถือของการวินิจฉัยเป็นสิ่งจำเป็น งานวิจัยนี้จึงเสนอกรอบแนวคิดของการตรวจจับจุดเลือดออกและตำแหน่งของจุดในสมอง ซึ่งนำภาพถ่ายสมองมาจากโรงพยาบาลในจังหวัดภูเก็ตของผู้ป่วย จำนวน 26 คน แบ่งเป็นภาพที่ใช้ในกระบวนการสร้างตัวจำแนก จำนวน 16 คน และใช้ในกระบวนการทดสอบ จำนวน 10 คน โดยมีการระบุจุดที่สนใจจากภาพถ่ายสมอง รวมถึงระบุตำแหน่งของจุดจากภาพถ่ายคลื่นแม่เหล็กไฟฟ้าแบบ SWI นอกจากนี้มีการนำระบบโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolution Neural Network: CNN) มาสร้างตัวจำแนกเพื่อการทำนาย ซึ่งใช้ในขั้นตอนการตรวจจับจุดเลือดออกในสมอง โดยมีการทดสอบความแม่นยำเพื่อเลือกวิธีการที่ใช้ จาก 4 วิธีการคือ 1) Alexnet 2) Googlenet 3) Resnet50 และ 4) Squeezenet รวมถึงมีการทดสอบจำนวนของข้อมูลที่ใช้ที่ทำให้มีค่าความแม่นยำ โดยทดสอบจากข้อมูลจำนวน 1,000 2,000 3,000 4,000 และ 5,000 ภาพ ส่วนในการระบุตำแหน่งของจุดมีการใช้การจับคู่ภาพที่มีรูปร่างเหมือนกัน (Shape matching) ตำแหน่งที่แสดงในงานวิจัยนี้มี 1) เนื้อสมองส่วนนอก (Cortical) 2) เนื้อสมองส่วนใน (Subcortical) 3) สมองส่วนท้าย (Cerebellum) และ 4) ก้านสมอง (Brainstem) ซึ่งผลลัพธ์ที่ได้จากการตรวจจับจุดเลือดออกในสมอง และการระบุตำแหน่งมีค่าความแม่นยำร้อยละ 95.76 และร้อยละ 100 ตามลำดับ

คำสำคัญ: การตรวจจับจุดเลือดออกในสมอง สังวัตนาการ การเรียนรู้เชิงลึก

Thesis Title	Cerebral Microbleed Detection by Extracting Area and Number from Susceptibility Weighted Imagery using Convolutional Neural Network
Author	Mrs. Sujitra Sa-ngiem
Major Program	Information Technology
Academic Year	2018

ABSTRACT

Cerebral micro-bleeding (CMB) is the condition where small vessels in the brain suffer small chronic hemorrhages. The main cause of CMB is hypertension. CMB does not have any symptoms in the short term but could cause the Alzheimer's disease in the long term. CMB patients generally have difficulties with daily activities such as speaking, walking, and remembering. Currently, CMB is manually diagnosed by the doctor, and there are many limitations (using time and not accurate, up to the doctor experience). The performance and reliability are importance. This thesis presents an automatic micro-bleeding detection and location from susceptibility weighted imaging (SWI) brain scan framework. The data used with respect to this research was collected from 26 patients that obtained from the local hospital in Phuket. A set of images from 16 patients was used as a training set and a set of images from 10 patients was used as test set. The process started with the training set images were segmented thus the region of interests (ROIs) were identified. Once a collection of ROIs has been obtained. The classifier generation process was then commenced. With respect to the work presented in this thesis, there were 4 architectures of Convolutional neural network were carried out: (i) Alexnet (ii) Googlenet (iii) Resnet50 and (iv) Squeezenet. The experiments also evaluated the classification performance using the different number of samples. There were five experiments had been conducted: 1,000 2,000 3,000 4,000 and 5000 samples. There were 4 areas of the brain were extracted using shape matching technique. The areas include: (i) cortical (ii) subcortical (iii) cerebellum and (iv) brainstem. There was 95.76% accuracy was

recorded for CMB detection while 100% accurate was recorded for area (location) identification on the test set.

Keywords: Cerebral microbleed, CMB Detection, Convolutional Neural Network, CMB mining, Image Classification, Deep Learning

กิตติกรรมประกาศ

ขอขอบพระคุณ ดร.ขวัญกมล ตีรภักดิ์ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่คอยให้คำปรึกษา แนะนำเรื่องต่าง ๆ รับฟังปัญหาต่าง ๆ คอยอยู่เคียงข้างตลอดเวลาทั้งเรื่องงานวิจัยและเรื่องส่วนตัว รวมถึงคอยให้กำลังใจและผลักดันในการทำงานวิจัย ข้าพเจ้ารู้สึกซาบซึ้งในความเมตตาและทุก ๆ อย่างที่คอยช่วยเหลือ

ขอขอบพระคุณ คณะกรรมการสอบ และคณะอาจารย์วิทยาลัยการคอมพิวเตอร์ทุกท่านที่คอยแนะนำ ช่วยเหลือ ให้กำลังใจ และถ่ายทอดวิชาแก่ข้าพเจ้า เพื่อจะได้นำมาใช้ในการทำงานวิจัยนี้ และงานอื่น ๆ ต่อไปในอนาคต

ขอขอบคุณแพทย์หญิงกัญญา เต็มเกียรติวิเศษ แพทย์เฉพาะทางด้านประสาทวิทยา โรงพยาบาลกรุงเทพภูเก็ต รวมถึงเจ้าหน้าที่ทุกท่านที่มอบชุดข้อมูลที่ใช้ในงานวิจัยนี้ ซึ่งงานนี้จะสำเร็จ ล่วงไปไม่ได้หากขาดสิ่งนี้

ขอขอบคุณคุณวรรณช ญาณศักดิ์ และคุณฐิติมา วศินพัฒน์วิศิษฐ์ เจ้าหน้าที่วิทยาลัยการคอมพิวเตอร์ที่คอยดูแล และช่วยเหลือด้านเอกสารต่าง ๆ รวมถึงบุคลากรทุกคนที่มีส่วนเกี่ยวข้อง ทั้งนี้ขอขอบคุณบัณฑิตวิทยาลัยและวิทยาลัยการคอมพิวเตอร์ที่ให้โอกาสและทุนการศึกษาแก่ข้าพเจ้า

ขอขอบคุณทุก ๆ กำลังใจจากครอบครัว ที่เข้าใจและคอยช่วยเหลือทุก ๆ ด้าน ระหว่างการศึกษา รวมถึงกัลยาณมิตรทุกคนที่เข้าใจและคอยให้กำลังใจ ในยามที่มีปัญหา รวมถึงคอยรับฟังปัญหาต่าง ๆ ซึ่งสิ่งเหล่านี้เป็นสิ่งที่จำเป็นอย่างยิ่ง และมีส่วนผลักดันให้งานวิจัยนี้สำเร็จ ข้าพเจ้าจึงขอขอบพระคุณมา ณ โอกาสนี้

สุจิตตรา เสงี่ยม

สารบัญ

	หน้า
บทคัดย่อ	(5)
ABSTRACT	(6)
กิตติกรรมประกาศ	(8)
สารบัญ	(9)
รายการตาราง	(12)
รายการภาพประกอบ	(13)
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญของงานวิจัย	1
1.2 คำถามงานวิจัย	4
1.3 วัตถุประสงค์	4
1.4 ระเบียบวิธีวิจัย	5
1.5 ข้อค้นพบ	6
1.6 ขอบเขตของงานวิจัย	7
1.7 การตีพิมพ์	8
1.8 การจัดการวิทยานิพนธ์	8
1.9 สรุป	9
บทที่ 2 การทบทวนวรรณกรรมและทฤษฎีที่เกี่ยวข้อง	10
2.1 บทนำ	10
2.2 การตรวจจับจุดเลือดออกในสมองจากภาพถ่ายทางการแพทย์	11
2.3 โครงข่ายประสาทเทียมแบบสังวัตนาการ	16
2.4 การประมวลผลภาพ (Image Processing)	27
2.5 การวัดและประเมินผล	34

สารบัญ (ต่อ)

	หน้า
2.6 บทสรุป	36
บทที่ 3 ชุดข้อมูลภาพและกระบวนการจับพื้นที่ที่สนใจ	37
3.1 บทนำ	37
3.2 การเก็บรวบรวมข้อมูล	38
3.3 การตรวจจับพื้นที่ที่สนใจ	45
3.4 การตรวจสอบจุดซ้ำ (Overlapping)	51
3.5 ชุดข้อมูลที่ใช้ (Datasets)	53
3.6 สรุป	59
บทที่ 4 กระบวนการสร้างตัวจำแนกสำหรับตรวจจับจุดเลือดออกในสมอง จากภาพที่สร้างด้วยสนามแม่เหล็กไฟฟ้าถ่วงน้ำหนักตามความอ่อนไหว	61
4.1 บทนำ	60
4.2 โครงข่ายประสาทเทียมแบบสังวัตนาการ	62
4.3 การกำหนดการทดลอง	63
4.4 การวัดและการประเมินผล	65
4.5 อภิปรายผล	72
4.6 สรุป	73
บทที่ 5 การระบุตำแหน่งของจุดเลือดออกในสมอง	74
5.1 บทนำ	74
5.2 กระบวนการจับคู่ภาพที่มีรูปร่างเหมือนกัน	76
5.3 การวัดและการประเมินผล	87
5.4 อภิปรายผล	91
5.5 สรุป	92

สารบัญ (ต่อ)

	หน้า
บทที่ 6 สรุปและข้อเสนอแนะ	93
6.1 สรุปผลการทดลอง	93
6.2 ข้อค้นพบหลักและสิ่งที่ค้นพบใหม่	94
6.3 ปัญหาและอุปสรรค	97
6.4 ลักษณะของการนำไปใช้ประโยชน์	98
6.5 งานในอนาคต	98
เอกสารอ้างอิง	99
ภาคผนวก ก	105
ภาคผนวก ข	111
ภาคผนวก ค	119
ประวัติผู้เขียน	125

รายการตาราง

	หน้า
ตารางที่ 2.1 แสดงการเปรียบเทียบงานวิจัยก่อนหน้า	13
ตารางที่ 2.2 แสดงรายละเอียดการทำงานของ Alexnet	19
ตารางที่ 2.3 แสดงรายละเอียดการทำงานของ GoogleNet	22
ตารางที่ 2.4 แสดงรายละเอียดของ Resnet50	24
ตารางที่ 2.5 แสดงรายละเอียดของ Squeezenet	26
ตารางที่ 2.6 Confusion matrix	35
ตารางที่ 4.1 ผลการทดลองการหาข้อมูลพื้นที่ที่สนใจ	66
ตารางที่ 4.2 ผลการทดลองการหาสถาปัตยกรรมของ CNN	68
ตารางที่ 4.3 ผลการทดลองเวลาในการหาสถาปัตยกรรมของ CNN	69
ตารางที่ 4.4 ผลการทดลองการหาข้อมูลพื้นที่ที่สนใจ	71
ตารางที่ 5.1 ผลลัพธ์ที่ได้จากการทดสอบตัวจำแนกเพื่อตรวจจับจุดเลือดออกในสมอง	88
ตารางที่ 5.2 Confusion matrix	89
ตารางที่ 5.3 ผลลัพธ์ที่ได้จากการทดสอบตำแหน่งของจุดเลือดออกในสมอง	90

รายการภาพประกอบ

	หน้า
ภาพที่ 1.1 จุดเลือดออกในสมอง	1
ภาพที่ 1.2 สมองที่ไม่มี CMB	2
ภาพที่ 1.3 โครงสร้างของงานวิจัย	6
ภาพที่ 2.1 ตัวอย่างภาพ T2*-weighted (Chunjing, et al., 2017)	11
ภาพที่ 2.2 ภาพถ่ายสมองแบบ SWI	12
ภาพที่ 2.3 โครงสร้างทั่วไปของโครงข่ายประสาทเทียมแบบสังวัตนาการ	16
ภาพที่ 2.4 ตัวอย่างของแม็กซ์พูลลิง	17
ภาพที่ 2.5 สถาปัตยกรรม Alexnet	18
ภาพที่ 2.6 สถาปัตยกรรมของ Googlenet	20
ภาพที่ 2.7 มอดูล Inception เวอร์ชันนาอีฟ (naive) (Szegedy, et al., 2015)	21
ภาพที่ 2.8 มอดูล Inception เวอร์ชันการลดมิติ (dimensionality reduction)	21
ภาพที่ 2.9 Residual block	23
ภาพที่ 2.10 ตัวอย่างโครงสร้างของ Resnet	23
ภาพที่ 2.11 ตัวกรองของคอนโวลูชันใน Fire module (Iandola, et al., 2017)	25
ภาพที่ 2.12 สถาปัตยกรรมของ Squeezenet	26
ภาพที่ 2.13 เมตริกซ์ของภาพ	27
ภาพที่ 2.14 ภาพก่อนและหลังการปรับปรุงภาพ	28
ภาพที่ 2.15 ภาพที่มีความถี่เชิงพื้นที่เป็นศูนย์ (ก) ความถี่เชิงพื้นที่ต่ำ (ข)	29
ภาพที่ 2.16 ภาพและรูปแบบตั้งต้น	30
ภาพที่ 2.17 ภาพผลลัพธ์ที่ได้หลังการขยายภาพ	30
ภาพที่ 2.18 ตัวอย่างภาพก่อนและหลังการขยายภาพ	31
ภาพที่ 2.19 ตัวอย่างภาพก่อนและหลังการลบหลุม	31
ภาพที่ 2.20 ตัวอย่างภาพทางการแพทย์ที่ผ่านการแยกวัตถุด้วยวิธีการใช้ค่าขีดแบ่ง	32
ภาพที่ 2.21 เปรียบเทียบพิกเซล	33
ภาพที่ 2.22 การเปรียบเทียบภาพโดยใช้ Pixel Tolerance	33
ภาพที่ 2.23 การเปรียบเทียบโดยใช้ภาพต้นแบบ	34

รายการภาพประกอบ (ต่อ)

	หน้า
ภาพที่ 3.1 ตัวอย่างภาพที่ได้จากการระบุจุดเลือดออกในสมองและตำแหน่งจากแพทย์	39
ภาพที่ 3.2 ภาพ SWI ดั้งเดิมที่แสดงผลในรูปแบบของ DICOM	40
ภาพที่ 3.3 ตัวอย่างภาพ SWI ที่ถ่ายจากผู้ป่วยหนึ่งราย	41
ภาพที่ 3.4 กระบวนการตรวจจับพื้นที่ที่สนใจ	45
ภาพที่ 3.5 ผลลัพธ์จากกระบวนการจับพื้นที่ที่สนใจ	46
ภาพที่ 3.6 แสดงรูปที่ผ่านการ Thresholding	47
ภาพที่ 3.7 อัลกอริทึมในการตรวจจับจุดที่สนใจ	49
ภาพที่ 3.8 อัลกอริทึมในการตัดจุดที่สนใจ	51
ภาพที่ 3.9 ตัวอย่างจุดเลือดออกในสมองที่ปรากฏใน 2 ภาพ	52
ภาพที่ 3.10 อัลกอริทึมในการตรวจสอบจุดที่ซ้ำกัน	53
ภาพที่ 3.11 ตัวอย่างพื้นที่ที่สนใจที่เป็นจุดเลือดออกในสมองและไม่ใช่จุดเลือดออกในสมอง	54
ภาพที่ 3.12 ตัวอย่างพื้นที่ที่สนใจที่เป็นจุดเลือดออกในสมองแบบดั้งเดิมที่ตัดได้	55
ภาพที่ 3.13 ตัวอย่างพื้นที่ที่สนใจที่ไม่ใช่จุดเลือดออกในสมองแบบดั้งเดิมที่ตัดได้	55
ภาพที่ 3.14 ตัวอย่างพื้นที่ที่สนใจที่เป็นจุดเลือดออกในสมองแบบที่ปรับพื้นที่รอบข้างให้น้อยลง	56
ภาพที่ 3.15 ตัวอย่างพื้นที่ที่สนใจที่ไม่ใช่จุดเลือดออกในสมองแบบที่ปรับพื้นที่รอบข้างให้น้อยลง	57
ภาพที่ 3.16 ตัวอย่างพื้นที่ที่สนใจที่เป็นจุดเลือดออกในสมองแบบที่ตัดเอาแต่ส่วนจุด	58
ภาพที่ 3.17 ตัวอย่างจุดที่ไม่ใช่จุดเลือดออกในสมองแบบที่ตัดเอาแต่ส่วนจุด	58
ภาพที่ 4.1 กระบวนการสร้างตัวจำแนก	61
ภาพที่ 4.2 กระบวนการทดลอง	64
ภาพที่ 4.3 กราฟแสดงประสิทธิภาพของการจำแนกดังที่แสดงในตารางที่ 4.1	67
ภาพที่ 4.4 กราฟแสดงประสิทธิภาพของการจำแนกดังที่แสดงในตารางที่ 4.2	69
ภาพที่ 4.5 กราฟแสดงเวลาในการสร้างตัวจำแนกดังที่แสดงในตารางที่ 4.3	70
ภาพที่ 4.6 กราฟแสดงประสิทธิภาพของการจำแนกดังที่แสดงในตารางที่ 4.4	71
ภาพที่ 4.7 ผลจากการสร้างตัวจำแนก	72
ภาพที่ 5.1 ขั้นตอนการระบุตำแหน่งจุดเลือดออกในสมอง	75
ภาพที่ 5.2 ตำแหน่งของส่วนของสมองบนภาพ SWI	76

รายการภาพประกอบ(ต่อ)


	หน้า
ภาพที่ 5.3 การหาสเกลของรูป	77
ภาพที่ 5.4 ภาพต้นแบบในการจับขอบของสมอง	78
ภาพที่ 5.5 ภาพต้นแบบในการจับพื้นที่ของสมอง	79
ภาพที่ 5.6 ตัวอย่างผลลัพธ์จากการระบุตำแหน่งของเนื้อสมองส่วนนอก	80
ภาพที่ 5.7 ตัวอย่างผลลัพธ์จากการระบุตำแหน่งของเนื้อสมองส่วนใน	81
ภาพที่ 5.8 ตัวอย่างผลลัพธ์จากการระบุตำแหน่งของสมองส่วนท้าย	82
ภาพที่ 5.9 ตัวอย่างผลลัพธ์จากการระบุตำแหน่งของก้านสมอง	83
ภาพที่ 5.10 ตัวอย่างผลลัพธ์ที่ได้จากการระบุตำแหน่งของจุดเลือดออกในสมอง	84
ภาพที่ 5.11 อัลกอริทึมในการระบุตำแหน่งให้จุดเลือดออกในสมอง	85
ภาพที่ 5.12 กราฟแสดงผลลัพธ์จากตารางที่ 5.1	89

บทที่ 1

บทนำ


1.1 ที่มาและความสำคัญของงานวิจัย

ในยุคที่โรคภัยไข้เจ็บเกิดขึ้นอย่างมากมายในมนุษย์ โดยเฉพาะอย่างยิ่งภาวะที่เกี่ยวข้องกับสมอง สมองเป็นอวัยวะที่ทำหน้าที่ควบคุมระบบต่าง ๆ ของร่างกาย ดังนั้นภาวะที่เกิดขึ้นกับสมองย่อมมีความสำคัญ โรคหนึ่งที่เจอได้บ่อย คือ ภาวะเลือดออกในสมองเป็นจุดเล็ก ๆ ภาษาอังกฤษเรียกว่า Cerebral Microbleed หรือตัวย่อ คือ CMB ซึ่งอาจจะเกิดจากภาวะความดันโลหิตสูง หรือ สมองขาดเลือด (Noorbakhsh-Sabet, et al., 2017) ซึ่งพบในผู้ป่วยที่มีอายุเฉลี่ย 72 ปี (Gregoire, et al., 2010) โดยปกติภาวะนี้หากเป็นในระยะสั้นย่อมไม่ส่งผลอะไรมากนัก แต่ในระยะยาวอาจก่อให้เกิดอัลไซเมอร์ได้ แพทย์เฉพาะทางด้านศัลยกรรมประสาทและสมองทำการวินิจฉัยโรคนี้จากภาพเอกซเรย์คลื่นแม่เหล็กไฟฟ้า (Magnetic Resonance Imaging: MRI) ตัวอย่างของสมองที่มี CMB แสดงดังภาพที่ 1.1 และไม่มี CMB แสดงดังภาพที่ 1.2 กรอบสีแดงแสดงจุดเลือดออกในสมองและกรอบสีเขียวแสดงจุดที่ไม่ใช่จุดเลือดออกในสมอง



ภาพที่ 1.1 จุดเลือดออกในสมอง

โดยจุดต่าง ๆ ที่สามารถพบได้ในสมอง ได้แก่ จุดเลือดออกในสมองขนาดใหญ่ (Macrobleed) จุดแคลเซียม (Calcifications) จุดแร่เหล็ก (Iron deposits) และเม็ดเลือดแดงที่ไม่มีออกซิเจน (Deoxyhemoglobin) โดยจุดเลือดออกในสมองมีลักษณะจุด สีเข้ม และเล็ก ขนาด 2-10 มิลลิเมตร (Gregoire, et al., 2010)



ภาพที่ 1.2 สมองที่ไม่มี CMB

ส่วนจุดเลือดออกในสมองขนาดใหญ่มีขนาดมากกว่า 5-10 มิลลิเมตร (Greenberg, et al., 2009) แคลเซียมและแร่เหล็กในสมองจะมีความเข้มข้นน้อยและมีขนาดเล็กมาก เม็ดเลือดแดงที่ไม่มีออกซิเจนจะแยกจากจุดเลือดออกในสมองด้วยตำแหน่ง โดยจะอยู่ในตำแหน่งที่ติดกับเส้นเลือด ตัวอย่างภาพสมองที่มี CMB และมีจุดที่ไม่ใช่ CMB แสดงดังภาพที่ 1.1 ภาวะเลือดออกในสมองเป็นประเภทหนึ่งของอาการกลุ่มเลือดออกในสมองแบบมีอาการ (Symptomatic Intracerebral Hemorrhage: ICH) ในกลุ่มของผู้ป่วยที่มีอาการเลือดออกในสมอง (Stroke) พบว่ามีจุดเลือดออกในสมอง (CMB) ร้อยละ 19-83 ผู้ป่วยที่มีอาการนี้จะใช้ชีวิตประจำวันได้ลำบาก เช่น การพูด การเดิน และการจดจำ เป็นต้น ปัจจุบันการวินิจฉัยโรคโดยแพทย์ทางด้านศัลยกรรมประสาทและสมอง ซึ่งจะทำกรวินิจฉัยผ่านทางระบบคอมพิวเตอร์ โดยผู้ป่วยต้องทำการ MRI สมองในท่านอน จากนั้นแพทย์จะทำการวินิจฉัยจากภาพถ่าย MRI ผ่านทางคอมพิวเตอร์ ซึ่งมีข้อจำกัด คือ ต้องใช้เวลานานเนื่องจากภาพสมองของผู้ป่วยแต่ละคนจะมีหลายสไลด์ แพทย์ต้องเปิดภาพสลับไปมา และผลลัพธ์ที่ได้จากการวินิจฉัยของแพทย์จะขึ้นอยู่กับประสบการณ์ของแพทย์แต่ละคน

ปัจจุบันปัญญาประดิษฐ์ (Artificial Intelligence: AI) ได้เข้ามามีบทบาทต่อการพัฒนาเทคโนโลยีอย่างมาก โดยเป็นศาสตร์แขนงหนึ่งของวิทยาการคอมพิวเตอร์ ซึ่งสามารถทำให้คอมพิวเตอร์มีพฤติกรรมคล้ายมนุษย์ โดยเฉพาะการทำให้คอมพิวเตอร์สามารถคิด และเรียนรู้ได้เอง ศาสตร์แขนงหนึ่งของปัญญาประดิษฐ์ที่ใช้กันอย่างแพร่หลาย คือ การเรียนรู้ของเครื่อง (Machine Learning) เป็นการสอนให้คอมพิวเตอร์สามารถเรียนรู้ได้ด้วยตัวเอง โดยมีการคิดและตัดสินใจ

ที่ใกล้เคียงกับมนุษย์ ซึ่งรูปแบบหนึ่ง คือ การเรียนรู้เชิงลึก (Deep Learning) เป็นการทำงานของคอมพิวเตอร์ที่เลียนแบบระบบโครงข่ายเซลล์สมองของมนุษย์ ในโครงข่ายประสาทเทียม (Artificial Neural Network) มีเทคนิคที่ใช้กันแพร่หลาย คือ โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional neural network: CNN) ตัวอย่างปัญญาประดิษฐ์ได้ถูกนำมาใช้ทางการแพทย์ ได้แก่ Esteva, et al. (2017) ได้ทำการวิเคราะห์หิมะเรียงผิวหนังจากภาพถ่าย Jiang, et al. (2017) กล่าวถึงแอปพลิเคชันที่ใช้ระบบ AI ในการวินิจฉัยโรคหัวใจจากภาพการเต้นของหัวใจ ตัวอย่างด้านอื่น ๆ ได้แก่ Krizhevsky and Hinton (2012) ได้เสนอการตรวจจับเสียงบนโทรศัพท์มือถือแบบทันที Takano, et al. (2018) ได้เสนอเกมต่อสู้ที่ใช้ AI ในการสร้าง โดยเกมนี้มีประสิทธิภาพและได้รับรางวัลต่าง ๆ มากมาย

จากที่กล่าวมาข้างต้นนั้น งานวิจัยนี้ผู้วิจัยได้เสนอกรอบแนวคิดในการนำการเรียนรู้ของเครื่อง มาใช้ตรวจจับจุดเลือดออกในสมอง และใช้กระบวนการประมวลผลภาพเข้ามาระบุตำแหน่งของจุดเลือดออกในสมอง โดยใช้ภาพต้นแบบจากโรงพยาบาลกรุงเทพภูเก็ต ซึ่งงานวิจัยนี้แบ่งออกเป็น 2 ส่วน คือ 1) กระบวนการสร้างตัวจำแนกเพื่อใช้ทำนายจุดเลือดออกในสมอง และ 2) กระบวนการนำตัวจำแนกที่ได้ไปใช้ในการจับจุดเลือดออกในสมองและการระบุตำแหน่ง ผลลัพธ์ที่ได้จากงานวิจัยนี้ ช่วยให้แพทย์ทางด้านศัลยกรรมประสาทและสมองสามารถทำงานได้รวดเร็วขึ้น โดยผลลัพธ์ที่ได้เสถียรมากขึ้น

หัวข้ออื่น ๆ ที่จะกล่าวถึงในบทนี้ มีดังนี้ หัวข้อ 1.2 คำถามวิจัยที่ใช้เป็นแนวทาง เพื่อหาวิธีในการตรวจจับจุดเลือดออกในสมองและการระบุตำแหน่ง หัวข้อ 1.3 อธิบายวัตถุประสงค์ของงานวิจัยนี้ เพื่อให้ทราบว่าการวิจัยนี้ทำเพื่ออะไร หัวข้อ 1.4 ระเบียบวิธีวิจัย อธิบายโครงสร้างของงานวิจัยนี้ในภาพรวม เพื่อให้เห็นภาพชัดเจนยิ่งขึ้น หัวข้อ 1.5 แสดงประโยชน์ของงานวิจัยนี้ โดยกล่าวถึงทางการแพทย์ ประโยชน์ต่อวงการวิจัย และประโยชน์ต่อผู้วิจัย หัวข้อ 1.6 อธิบายขอบเขต ข้อจำกัดของงานวิจัยนี้ หัวข้อ 1.7 แสดงการตีพิมพ์ เพื่อแสดงให้เห็นว่างานวิจัยนี้ได้เผยแพร่แล้ว หัวข้อ 1.8 หัวข้อต่าง ๆ ในการจัดการวิทยานิพนธ์ หรืออธิบายว่าในวิทยานิพนธ์เล่มนี้ประกอบด้วยหัวข้ออะไรบ้าง และหัวข้อ 1.9 สรุปรายละเอียดของบทนี้

1.2 คำถามงานวิจัย

จากที่มาและความสำคัญของงานวิจัยที่ได้กล่าวไปแล้วนั้น มีเป้าหมายเพื่อศึกษาวิเคราะห์ และออกแบบกระบวนการที่สามารถตรวจจับจุดเลือดออกในสมอง ซึ่งสามารถแสดงเป็นคำถามการวิจัยดังต่อไปนี้

“จุดและตำแหน่งของจุดเลือดออกในสมอง (CMB) สามารถตรวจจับได้จากภาพถ่ายแม่เหล็กไฟฟ้าได้โดยใช้การเรียนรู้ของเครื่องได้หรือไม่”

โดยเพื่อตอบคำถามของงานวิจัยนั้น การวิจัยจะพิจารณาประเด็นต่าง ๆ ดังนี้

- 1) หากกระบวนการประมวลผลภาพที่เหมาะสมในการตรวจจับพื้นที่ที่สนใจ (Region of Interest)
- 2) หากการประมวลผลด้วยเครื่อง โดยการเรียนรู้เชิงลึกที่เหมาะสม ในการสร้างตัวจำแนก เพื่อตรวจจับจุดเลือดออกในสมอง
- 3) หากกระบวนการประมวลผลภาพที่เหมาะสมในการระบุตำแหน่งของจุดเลือดออกในสมอง
- 4) หากกระบวนการที่ใช้ในการจับจุดซ้ำ (Overlapping Problem) เพื่อใช้ในการหาจุดซ้ำจากภาพถ่ายต่างภาพได้ เนื่องจากจุดเลือดออกบางจุดสามารถปรากฏได้ในหลาย ๆ ภาพ เนื่องจากภาพถ่ายของผู้ป่วย 1 สมอง จะประกอบด้วยภาพ 2 มิติ หลาย ๆ ภาพ

1.3 วัตถุประสงค์

จากความเป็นมาของปัญหาและปัญหาที่ได้กล่าวมา และคำถามงานวิจัยที่เกี่ยวข้องกับการศึกษา วิเคราะห์และออกแบบกระบวนการที่สามารถใช้ในการสร้างแบบจำลองเพื่อการตรวจจับจุดเลือดออกในสมอง และระบุตำแหน่งของจุดเลือดออกในสมอง เพื่อให้การดำเนินงานวิจัยดำเนินอย่างถูกต้อง จึงมีวัตถุประสงค์ดังนี้

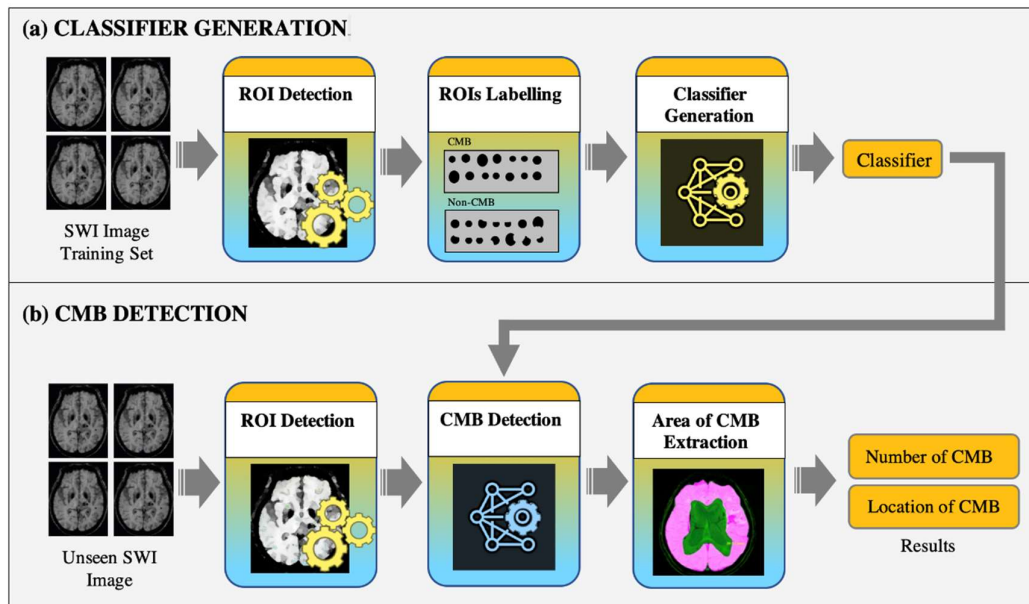
- 1) เพื่อศึกษา คำนวณ ทดลอง และประเมินผล กระบวนการประมวลผลภาพที่เหมาะสมในการตรวจจับพื้นที่ที่สนใจ (Region of Interest)
- 2) เพื่อศึกษา คำนวณ ทดลอง และประเมินผล การประมวลผลด้วยเครื่อง โดยใช้การเรียนรู้เชิงลึกที่เหมาะสม ในการสร้างตัวจำแนกเพื่อตรวจจับจุดเลือดออกในสมอง
- 3) เพื่อศึกษา คำนวณ ทดลอง และประเมินผล กระบวนการประมวลผลภาพที่เหมาะสมในการระบุตำแหน่งของจุดเลือดออกในสมอง
- 4) เพื่อศึกษา คำนวณ ทดลอง และประเมินผล กระบวนการที่ใช้ในการจับจุดซ้ำ (Overlapping Problem) เพื่อใช้ในการหาจุดซ้ำจากภาพถ่ายต่างภาพได้

1.4 ระเบียบวิธีวิจัย

จากคำถามงานวิจัย “จุดและตำแหน่งของจุดเลือดออกในสมอง (CMB) สามารถตรวจจับได้จากภาพถ่ายแม่เหล็กไฟฟ้าได้โดยใช้การเรียนรู้ของเครื่องได้หรือไม่” ผู้วิจัยได้จัดโครงสร้างของงานวิจัยนี้ โดยแสดงดังภาพที่ 1.3 จากภาพแสดงระเบียบวิธีวิจัยเริ่มจากการทำให้มองเห็นภาพได้ชัดเจนยิ่งขึ้น โดยการเพิ่มความคมชัดของภาพเอกซเรย์คลื่นแม่เหล็กไฟฟ้าแบบแนวขวาง (Transverse) ที่ได้มาจากโรงพยาบาลในจังหวัดภูเก็ต โดยใช้กระบวนการทางการประมวลผลภาพ นั่นคือ Spatial filtering smoothing method และ Boost filtering method จากนั้นจึงตรวจจับพื้นที่ที่สนใจ โดยเป็นพื้นที่ที่คาดว่าเป็นจุดเลือดออกในสมอง โดยทำการปรับภาพให้เป็นโทนขาวดำ (Binary image) ก่อน แล้วจึงทำการลบส่วนที่ไม่เกี่ยวข้องออก เหลือแต่ขอบสมอง โดยใช้การดึงคุณลักษณะด้วยวิธี Morphological จากนั้นทำการตัดภาพจริงให้ได้เท่ากับภาพขอบสมองที่ได้ จากนั้นทำการ segmentation โดยใช้ thresholding และตัดเอาเฉพาะพื้นที่ที่สนใจ

จากนั้นนำจุดที่ได้ทั้งหมดมาแบ่งเป็น 2 กลุ่ม คือ จุดเลือดออกในสมอง (CMB) และจุดที่ไม่ใช่จุดเลือดออกในสมอง (Non-CMB) เพื่อเข้าสู่กระบวนการจำแนก (Classification) ด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ ในขั้นตอนนี้มีมีการใช้สถาปัตยกรรม 4 วิธี คือ 1) Alexnet 2) Googlenet 3) Resnet50 และ 4) Squeezenet รวมถึงใช้ชุดข้อมูล 3 ชุด คือ 1) ภาพที่ดั้งเดิมที่ตัดได้ 2) ภาพที่ปรับพื้นที่รอบข้างให้น้อยลง และ 3) ภาพที่ตัดเอาแต่ส่วนจุด เพื่อนำผลลัพธ์ที่ได้มาเปรียบเทียบกัน จากนั้นเลือกวิธีการและชุดข้อมูลที่ให้ค่าความถูกต้องสูงที่สุดมาสร้างตัวจำแนก ซึ่งตัวจำแนกที่ได้ถูกนำไปใช้ในการตรวจจับจุดเลือดออกในสมองอัตโนมัติต่อไป หลังจากกระบวนการ

นี้เสร็จสิ้นแล้วมีการระบุตำแหน่งของจุดเลือดออกในสมองเป็น 4 ตำแหน่ง คือ 1) เนื้อสมองส่วนนอก (Cortical) 2) เนื้อสมองส่วนใน (Sub-Cortical) 3) สมองส่วนท้าย (Cerebellum) และ 4) ก้านสมอง (Brain stem) โดยมีการใช้วิธีจับคู่ภาพที่มีรูปร่างเหมือนกัน (Shape matching) ของกระบวนการประมวลผลภาพ และแสดงผลออกมาบนภาพเอกซเรย์คลื่นแม่เหล็กไฟฟ้า



ภาพที่ 1.3 โครงสร้างของงานวิจัย

1.5 ข้อค้นพบ

ดังที่กล่าวมาแล้วถึงที่มาและความสำคัญของงานวิจัย และวัตถุประสงค์ของงานวิจัย ซึ่งงานวิจัยนี้มีข้อค้นพบดังนี้

1) การตรวจจับจุดที่สนใจจากภาพถ่ายสมอง ทำได้ด้วยกระบวนการประมวลผลภาพ

2) กระบวนการประมวลผลภาพที่เหมาะสมสำหรับการตรวจจับจุดที่สนใจ คือ การใช้ค่าคงที่ (Thresholding) และการดึงคุณลักษณะของวงกลม

- 3) ภาพที่เหมาะสมในการนำมาใช้ในการสร้างตัวจำแนก คือ ภาพที่ได้จากกระบวนการตัดจุดที่น่าสนใจ พร้อมพื้นหลังขนาด 36x36 พิกเซล
- 4) กระบวนการการเรียนรู้เชิงลึกที่เหมาะสมในการสร้างตัวจำแนก คือ สังวัฒนาการโดยใช้สถาปัตยกรรมแบบ Alexnet
- 5) ในการสร้างตัวจำแนก จำนวนรอบในการสร้างตัวจำแนก และจำนวนของข้อมูล มีผลต่อความถูกต้อง
- 6) โครงข่ายประสาทเทียมแบบสังวัฒนาการ สามารถทำการสร้างตัวจำแนกได้โดยไม่ต้องมีการตั้งคุณลักษณะด้วยผู้วิจัย เนื่องจากกระบวนการนี้สามารถทำได้อัตโนมัติ
- 7) การระบุตำแหน่งให้จุดเลือดออกในสมอง สามารถใช้วิธีการจับคู่ภาพที่มีรูปร่างเหมือนกันได้ ซึ่งถือว่าเป็นสิ่งที่ค้นพบใหม่จากงานวิจัยนี้ด้วย
- 8) การตรวจสอบจุดเลือดออกในสมองจุดเดียวกันที่ปรากฏในหลายภาพ สามารถทำได้โดยใช้วิธีการทางประมวลผลภาพ โดยใช้การวัดการเคลื่อนที่ของจุดศูนย์กลาง

1.6 ขอบเขตของงานวิจัย

- 1) ภาพ MRI เป็นภาพถ่ายแบบถ่วงน้ำหนักตามความอ่อนไหว (Susceptibility weighted imaging) ที่มีความหนา 3 มิลลิเมตร และถ่ายจากด้านบนลงมาด้านล่าง (Transverse) เท่านั้น
- 2) จุดเลือดออกในสมองมีขนาด 2-10 มิลลิเมตร เท่านั้น
- 3) ตำแหน่งของจุดเลือดออกในสมองแสดง 3 ตำแหน่ง คือ 1) เนื้อสมองส่วนนอก (Cortical) 2) เนื้อสมองส่วนใน (Sub-Cortical) 3) สมองส่วนท้าย (Cerebellum) และ 4) ก้านสมอง (Brain stem)
- 4) รูปแบบการตรวจจับจุดเลือดออกในสมองที่ถูกสร้างขึ้นในงานวิจัยนี้ ใช้เพื่อช่วยอำนวยความสะดวกให้แพทย์ใช้ประกอบในการวินิจฉัยโรค

1.7 การตีพิมพ์

Sa-ngiem, S., Dittakan, K., Temkiatvises, K., Yaisoongnern, S. and Kespechara, K. (2019) “Cerebral Microbleed Detection by Extracting Area and Number from Susceptibility Weighted Imagery using Convolutional Neural Network”, Proceeding of the 3rd International Conference on Machine Vision and Information Technology (CMVIT 2019), Shanghai, China: 22-24 March, 2019.

งานวิจัยที่ตีพิมพ์นี้เกี่ยวกับการตรวจจับ และการระบุตำแหน่งของจุดเลือดออกในสมอง โดยใช้กระบวนการทางการประมวลผลภาพ และโครงข่ายแบบสังวัตนาการ เพื่อสร้างตัวจำแนก กระบวนการทางการประมวลผลภาพ เพื่อระบุตำแหน่งของจุดเลือดออกในสมอง การตรวจจับจุดเลือดออกในสมอง สามารถตรวจจับได้จากตัวจำแนกที่สร้างมาจากโครงข่ายแบบสังวัตนาการ โดยมีสถาปัตยกรรมแบบ Alexnet จำนวน Epoch เท่ากับ 8 ซึ่งผลลัพธ์ที่ได้ในการตรวจจับจุดเลือดออกในสมองมีความถูกต้องร้อยละ 95.45 ส่วนการระบุตำแหน่งใช้วิธีการจับคู่รูปร่างที่เหมือนกัน (shape matching) โดยแบ่งออกเป็น 3 ตำแหน่ง คือ 1) เนื้อสมอง (Cortical region) 2) สมองส่วนท้าย (Cerebellum) และ 3) ก้านสมอง (Brain stem) ผลลัพธ์ที่ได้จากการระบุตำแหน่งมีความถูกต้องเมื่อเทียบกับผลลัพธ์จากการจำแนกของแพทย์ด้านประสาทวิทยาเท่ากับ ร้อยละ 100

1.8 การจัดการงานวิจัย

การจัดการงานวิจัยมีดังนี้ บทที่ 2 เป็นการศึกษางานวิจัยและทฤษฎีต่าง ๆ ที่เกี่ยวข้องกับงานวิจัยนี้ โดยมีการกล่าวถึงการตรวจจับจุดเลือดออกในสมองที่มีมาก่อนหน้าสถาปัตยกรรมโครงข่ายประสาทเทียมแบบสังวัตนาการ 4 วิธีที่ใช้ ได้แก่ 1) Alexnet 2) Googlenet 3) Resnet50 และ 4) Squeezenet กระบวนการจัดการรูปภาพ คือ การเพิ่มความคมชัดของภาพ การตัดภาพที่สนใจ การลบวัตถุที่ไม่เกี่ยวข้อง กระบวนการในการระบุตำแหน่งให้จุดเลือดออกในสมอง และการประเมินผลในการเลือกตัวจำแนกเพื่อนำมาใช้ต่อไป ถัดมาบทที่ 3 กล่าวถึงชุดข้อมูล

ที่ใช้ในงานวิจัย และกระบวนการทั้งหมดก่อนเข้าสู่การสร้างตัวจำแนก นั่นคือ กระบวนการให้ได้มาซึ่งพื้นที่ที่สนใจ และการเลือกชุดข้อมูลที่ใช้ทั้ง 3 แบบ บทที่ 4 อธิบายเรื่องการจัดกลุ่มของจุดเลือดออกในสมอง และการให้ได้มาซึ่งตัวจำแนกของงานวิจัยนี้ รวมถึงการประเมินผลต่าง ๆ บทที่ 5 อธิบายถึงภาพต้นแบบ วิธีการของการระบุตำแหน่งให้จุดเลือดออกในสมอง และการประเมินผล สุดท้าย คือ บทที่ 6 เป็นการสรุปผลที่ได้จากงานวิจัยทั้งหมด โดยจะกล่าวถึงสิ่งที่เจอจากงานวิจัยนี้ และงานที่เป็นไปได้ในอนาคต

1.9 สรุป

บทนี้กล่าวถึงที่มาและความสำคัญของงานวิจัยนี้ ซึ่งปัจจุบันพบผู้ป่วยที่มีภาวะเลือดออกในสมองเป็นจุดเล็ก ๆ มากขึ้น ดังนั้นงานวิจัยนี้จึงสามารถอำนวยความสะดวกให้แก่แพทย์ในการวินิจฉัยโรคได้ นอกจากนี้ในบทนี้ยังกล่าวถึงรายละเอียดต่าง ๆ ที่เกี่ยวข้องมาสู่งานวิจัย ได้แก่ คำถามงานวิจัย ซึ่งอธิบายทั้งคำถามหลัก และคำถามย่อยที่ได้มาซึ่งคำตอบของคำถามหลัก จากนั้นจึงกล่าวถึงวัตถุประสงค์ของงานวิจัยนี้ ระเบียบวิธีวิจัยที่มีแสดงถึงโครงสร้างของกระบวนการวิจัย ประโยชน์ของการวิจัย รวมถึงขอบเขตของงานวิจัยนี้ นอกจากนี้มี การกล่าวถึงการตีพิมพ์ที่ได้เผยแพร่งานวิจัยนี้ไปแล้ว และการจัดการวิทยานิพนธ์ ซึ่งอธิบายถึงบทต่อ ๆ ไป โดยบทถัดไปจะพูดถึงการทบทวนวรรณกรรม ซึ่งมีการเปรียบเทียบงานวิจัยที่มีมาก่อนหน้า และทฤษฎีที่เกี่ยวข้อง

บทที่ 2


การทบทวนวรรณกรรมและทฤษฎีที่เกี่ยวข้อง

2.1 บทนำ

การทบทวนวรรณกรรมและทฤษฎีที่เกี่ยวข้องที่กล่าวถึงในบทนี้ เป็นเรื่องที่เกี่ยวข้องกับงานวิจัยนี้ ซึ่งหัวข้อต่าง ๆ ประกอบด้วยการตรวจจับจุดเลือดออกในสมองจากภาพถ่ายทางการแพทย์ กล่าวถึงลักษณะของจุดเลือดออกในสมองและอาการ รวมถึงประเภทของภาพที่ใช้ในการตรวจจับจุดเลือดออกในสมอง และแสดงการเปรียบเทียบงานวิจัยก่อนหน้านี้เกี่ยวกับจุดเลือดออกในสมอง โครงข่ายประสาทเทียมแบบสังวัตนาการ โดยกล่าวถึง 4 วิธี คือ 1) Alexnet 2) GoogleNet 3) Resnet50 และ 4) Squeezenet ทั้ง 4 วิธีนี้ผู้วิจัยได้ทำการทดสอบเพื่อหาวิธีที่เหมาะสมที่สุดมาสร้างตัวจำแนก โดยจะกล่าวถึงโครงสร้าง ระบบการทำงาน รวมถึงความแตกต่างของทั้ง 4 วิธี ถัดมากระบวนการประมวลผลภาพ หรือ Image Processing ซึ่งเป็นกระบวนการพื้นฐานที่ใช้ในงานวิจัยนี้ เป็นการกระทำต่าง ๆ กับภาพเพื่อให้มีประสิทธิภาพมากที่สุด ก่อนจะดำเนินการขั้นตอนอื่น ๆ โดยอธิบายถึงการปรับปรุงความคมชัดของภาพ (Image Enhancement) ซึ่งเป็นกระบวนการเพิ่มประสิทธิภาพของภาพในเรื่องความชัด จากนั้นอธิบายถึงกระบวนการเปลี่ยนแปลงลักษณะรูปร่างหรือโครงร่างของภาพ (Morphological) ซึ่งเป็นการกระทำกับภาพในเรื่องของขนาด นอกจากนี้ยังกล่าวถึงการดึงวัตถุพื้นหน้าออกจากพื้นหลัง (Thresholding) ซึ่งเป็นการเลือกส่วนที่ไม่เกี่ยวข้องออกจากภาพ โดยใช้ค่าคงที่ และการจับคู่ภาพ (Shape matching) โดยกระบวนการนี้ใช้งานในขั้นตอนการระบุตำแหน่งของจุดเลือดออกในสมอง และสุดท้ายอธิบายถึงวิธีการวัดและประเมินผลเพื่อหาวิธีที่เหมาะสมที่สุดในการสร้างตัวจำแนก และการวัดผลของผลลัพธ์ที่ได้


2.2 การตรวจจับจุดเลือดออกในสมองจากภาพถ่ายทางการแพทย์

ภาวะเลือดออกในสมอง หรือ Cerebral Microbleeds (CMB) เป็นภาวะที่มีเลือดออกในสมองเป็นจุดเล็ก ๆ กระจายอยู่ในสมอง ซึ่งเกิดจากผนังหลอดเลือดได้รับความเสียหาย (Yates, et al., 2014) โดยจุดเลือดออกในสมองมีความสัมพันธ์กับภาวะเลือดออกในสมอง (Intracerebral hemorrhage) และภาวะสมองเสื่อม (Shams, et al., 2015) ซึ่งพบได้ในผู้ป่วยโรคอัลไซเมอร์และความดันโลหิตสูงเป็นส่วนใหญ่ (Jellinger, 2002) การวินิจฉัยของแพทย์สามารถทำได้โดยใช้ภาพ MRI 2 แบบ คือ 1) T2*-weighted imaging (Ghafaryasl, et al., 2012; Zhang, et al., 2017) และ 2) Susceptibility weighted imaging (SWI) (Chen, et al., 2015; Dou, et al., 2015; Dou, et al., 2016; Fazlollahi, et al., 2013; Fazlollahi, et al., 2014; Wang, et al., 2017) โดยภาพแบบ T2*-weighted เป็นภาพที่เน้นน้ำมากกว่าไขมัน (ปาลนนท์ ศิริวนารังสรรค์, 2559) ซึ่งจะแสดงน้ำออกมาสีโทนขาว ที่สามารถมองเห็นจุดเลือดออกในสมองได้ ดังภาพที่ 2.1



ภาพที่ 2.1 ตัวอย่างภาพ T2*-weighted (Chunjing, et al., 2017)

ส่วน SWI เป็นภาพถ่ายที่สามารถมองเห็นจุดเลือดออกในสมองได้ชัดกว่าและละเอียดกว่า เห็นได้จากจำนวนจุดที่แสดงให้เห็นมากกว่า เนื่องจากเป็นการถ่ายภาพแบบ 3 มิติ ใช้เทคนิคการไล่สี ซึ่งแยกแยะระหว่างเนื้อเยื่อได้ดี และแสดงให้เห็นถึงเส้นเลือดดำได้ดี (Shams, et al., 2015) แสดงดังภาพที่ 2.2



ภาพที่ 2.2 ภาพถ่ายสมองแบบ SWI

จากการทบทวนงานวิจัยก่อนหน้าที่เกี่ยวกับการตรวจจับจุดเลือดออกในสมองพบว่า มีหลายงานวิจัยที่มีวัตถุประสงค์เพื่อตรวจจับจุดเลือดออกในสมองจากภาพ SWI ได้แก่ Hao Chan, et al. (2015) ได้ใช้การเรียนรู้เชิงลึกโดยการแสดงคุณลักษณะ 3 มิติ (deep learning using 3D feature representation) บนพื้นฐานของโครงข่ายประสาทเทียมแบบสังวัตนาการโดยใช้ภาพ SWI เป็นสไลด์ Qi Dou, et al. (2015) เลือกใช้วิธี Independent subspace analysis (ISA) บนพื้นฐานของคุณลักษณะแบบเป็นลำดับชั้น โดยใช้ภาพเป็น 3 มิติทั้งชุด กระบวนการนี้มี 2 ชั้น คือ ชั้นแรก การแบ่งภาพออกเป็นภาพ 3 มิติเล็ก ๆ ส่วนชั้นที่สองเป็นการดึงคุณลักษณะแบบเป็นลำดับชั้นโดยใช้ principal component analysis (PCA) Fazlollahi, et al. (2013) ได้ใช้ภาพถ่าย 3 มิติ มาทำการตรวจจับจุดเลือดออกในสมองโดยใช้วิธี multi-scale Laplacian of Gaussian framework นอกจากนี้ Qi Dou, et al. (2016) ได้ใช้โครงข่ายประสาทเทียมในการตรวจจับจุดเลือดออกในสมอง ซึ่งให้ผลลัพธ์ที่มีประสิทธิภาพสูง และ Shuihua, et al. (2017) ทำการตรวจจับจุดเลือดออกในสมอง โดยใช้โครงข่ายประสาทเทียม พร้อมทั้งเปรียบเทียบประสิทธิภาพโครงสร้างของโครงข่ายประสาทเทียมโดยการปรับลำดับชั้น (layer) เป็น 3 5 และ 9 ชั้น ซึ่งผลลัพธ์ที่ได้ 9 ชั้น ให้ความแม่นยำสูงสุด ถัดมาทำการเปรียบเทียบวิธีการของชั้น pooling คือ Max pooling Average pooling และวิธีการของผู้วิจัยเอง พบว่า max pooling ให้ความแม่นยำสูงสุด นอกจากนี้ยังนำวิธีการของงานนี้เปรียบเทียบกับวิธีการอื่น คือ พบว่าวิธีการนี้ให้ความแม่นยำสูงสุดที่ 5 ชั้น (layer) ซึ่งจากการทบทวนงานวิจัยก่อนหน้า ผู้วิจัยได้ทำการสรุปไว้ดังตารางที่ 2.1

ตารางที่ 2.1 แสดงการเปรียบเทียบงานวิจัยก่อนหน้า

Paper name	Method	MRI type	Subjects	Sensitivity (Percentage)	CMB number	CMB size	CMB location
EFFICIENT MACHINE LEARNING FRAMEWORK FOR COMPUTER-AIDED DETECTION OF CEREBRAL MICROBLEEDS USING THE RADON TRANSFORM (Fazlollahi, et al., 2014)	A novel cascade of random forest classifiers trained on robust Radon-based features	SWI	41	92.04	104	✗	✗
AUTOMATIC CEREBRAL MICROBLEEDS DETECTION FROM MR IMAGES VIA INDEPENDENT SUBSPACE ANALYSIS BASED HIERARCHICAL FEATURES (Dou, et al., 2015)	Independent Subspace Analysis Based Hierarchical Features	SWI	19	89.44	161	✗	✗

ตารางที่ 2.1 แสดงการเปรียบเทียบงานวิจัยก่อนหน้า (ต่อ)

Paper name	Method	MRI type	Subjects	Sensitivity (Percentage)	CMB number	CMB size	CMB location
AUTOMATIC DETECTION OF CEREBRAL MICROBLEEDS VIA DEEP LEARNING BASED 3D FEATURE REPRESENTATION (Chen, et al., 2015)	Deep learning based 3D feature representation	SWI	20	89.13	117	✗	✗
AUTOMATIC DETECTION OF CEREBRAL MICROBLEEDS FROM MR IMAGES VIA 3D CONVOLUTIONAL NEURAL NETWORKS (Dou, et al., 2016)	3D Convolutional Neural Networks	SWI	320	93.16	1149	✗	✗

ตารางที่ 2.1 แสดงการเปรียบเทียบงานวิจัยก่อนหน้า (ต่อ)

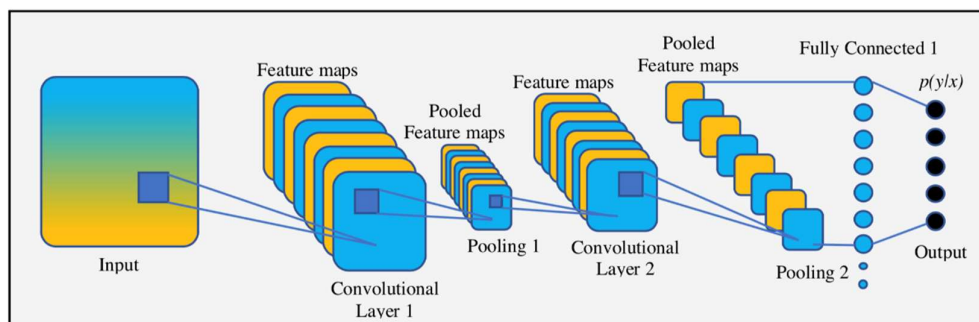
Paper name	Method	MRI type	Subjects	Sensitivity (Percentage)	CMB number	CMB size	CMB location
Cerebral Micro-Bleed Detection Based on the Convolution Neural Network with Rank Based Average Pooling (Wang, et al., 2017)	Convolution Neural Network	SWI	10	96.94	33,632	✗	✗
OUR RESEARCH (Sa-ngiem, 2018)	Convolutional Neural Networks	SWI	26	95.76	✓	✓	✓

“✓” = The related work is work.

“✗” = The related work is not work.

2.3 โครงข่ายประสาทเทียมแบบสังวัตนาการ

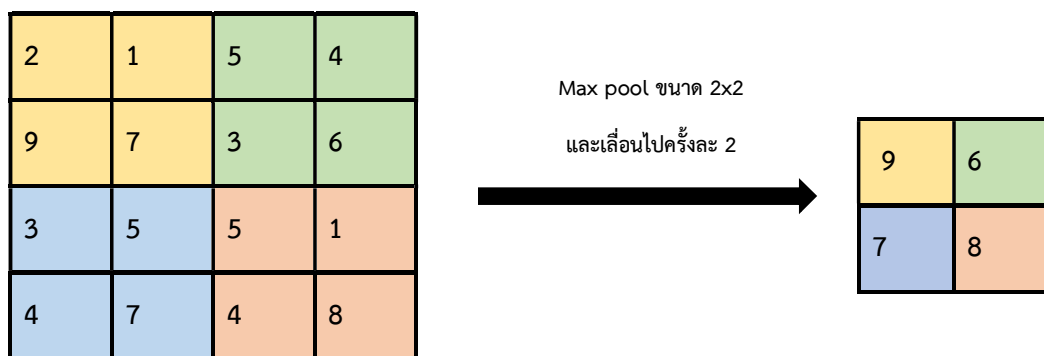
โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolution Neural Network: CNN) เป็นอัลกอริทึมในกลุ่มการเรียนรู้เชิงลึก (Deep learning) ที่ทำขึ้นมาเพื่อการเรียนรู้ของเครื่อง โดยใช้แนวคิดการทำงานของระบบประสาทของมนุษย์ ทำให้มีการเรียนรู้และตัดสินใจคล้ายสมองมนุษย์ ประมวลผลแบบขนาน มีการจำลองวัตถุออกเป็นพื้นที่ย่อย ๆ เพื่อดูคุณลักษณะเด่น (feature) เมื่อกระทำครบทุกส่วนแล้ว จึงทำการรวมพื้นที่ย่อย ๆ เหล่านั้นเข้าด้วยกัน แล้วจึงมาคิดว่าวัตถุนั้นคืออะไร ซึ่งมีชั้นของการเรียนรู้ซ่อนอยู่ (hidden layer) ส่วนของระบบการคำนวณนั้นมีความซับซ้อน จึงต้องมีคณิตศาสตร์มารองรับ และใช้หลักการเดียวกับคอนโวลูชันเชิงพื้นที่ (Spatial convolution) โครงข่ายประสาทเทียมนี้เป็นสาขาหนึ่งของ Machine Learning ที่มีลักษณะเช่นเดียวกับโครงข่ายประสาทเทียมแบบ Artificial Neuron Networks หรือ ANN แต่ต่างกันว่าโครงข่ายประสาทเทียมแบบสังวัตนาการมีลำดับชั้นที่ซ่อนอยู่มากกว่า โครงข่ายประสาทเทียมแบบสังวัตนาการเป็นอัลกอริทึมหนึ่งที่ใช้กันอย่างแพร่หลายในการทำงานที่เกี่ยวกับการวิเคราะห์รูปภาพ เช่น การวิเคราะห์ใบหน้าคน การตรวจจับป้ายทะเบียนรถ การแยกวัตถุที่แตกต่างออก เป็นต้น ซึ่งอัลกอริทึมกลุ่มการเรียนรู้เชิงลึกนี้ทำให้ซอฟต์แวร์สามารถจำภาพและเสียงของวัตถุได้ รวมถึงทำให้จำแนก จัดจำ แยกแยะสิ่งที่เจอได้ (บริษัทกลุ่มแอดวานซ์ รีเสิร์ช จำกัด, 2560) โครงสร้างของโครงข่ายประสาทเทียมแบบสังวัตนาการแสดงดังภาพที่ 2.3



ภาพที่ 2.3 โครงสร้างทั่วไปของโครงข่ายประสาทเทียมแบบสังวัตนาการ

โครงสร้างโดยทั่วไปของโครงข่ายประสาทเทียมแบบสังวัตนาการประกอบด้วย 3 ชั้นตอน คือ 1) ชั้นคอนโวลูชัน (Convolutional) 2) ชั้นพูลลิง (Pooling) และ 3) ชั้นพูลลีคอนเนค

(Fully Connected) ซึ่งชั้นคอนโวลูชันเป็นชั้นที่มีการแบ่งภาพอินพุตเป็นพื้นที่เล็ก ๆ เท่า ๆ กัน จากนั้นทำการดึงคุณลักษณะเด่นจากพื้นที่เล็ก ๆ แต่ละส่วน ด้วยเคอร์เนลฟีเจอร์ (kernel feature) โดยแต่ละพื้นที่จะมีคุณลักษณะเด่นที่แตกต่างกัน เมื่อเสร็จขั้นตอนนี้จึงได้คุณลักษณะต่าง ๆ ออกมามากมาย ซึ่งมีจำนวนเท่ากับเคอร์เนลฟีเจอร์ จากนั้นจึงนำมาทำเป็นผังคุณลักษณะ (feature map) หลังจากที่ได้แผนผังคุณลักษณะแล้วจึงเข้าสู่กระบวนการพูลลิง ซึ่งเป็นขั้นตอนที่ลดขนาดของคุณลักษณะ โดยการลดขนาดนี้ทำเพื่อลดเวลาการทำงานของระบบ โดยทั่วไปมี 2 แบบ คือ แมกซ์พูลลิง (Max pooling) และ มินพูลลิง (Average pooling) ซึ่ง Max pooling เป็นวิธีที่ได้รับความนิยม โดยกระบวนการทำงานจะดึงค่าที่มากที่สุดของบริเวณนั้นออกมา หลักการเหมือนกับชั้นคอนโวลูชัน คือ ใช้ตัวกรองเลื่อนไปตามจำนวน stride แต่ในขั้นนี้จะเรียกขนาดของตัวกรองว่า พูลไซต์ (pool size) ตัวอย่างของแมกซ์พูลลิง แสดงดังภาพที่ 2.4




ภาพที่ 2.4 ตัวอย่างของแมกซ์พูลลิง

กระบวนการพูลลิงแบบถัดมา คือ มินพูลลิง เป็นการกรองแบบหาค่าเฉลี่ย หลักการเช่นเดียวกับ Max pooling แต่ค่าที่ได้นั้นเป็นค่าเฉลี่ยจากพื้นที่ย่อยทั้งหมดในช่วงนั้น ๆ วิธีการนี้ผลลัพธ์ที่ได้อาจจะดีกว่าวิธีแรก เนื่องจากเป็นการหาค่าเฉลี่ย นอกจากนี้ Shuisua, et al. (2017) ได้ทดลองใช้วิธี Rank-based average pooling เปรียบเทียบกับ 2 วิธีที่กล่าวมาข้างต้น งานวิจัยนี้ผลลัพธ์ที่ได้มีความแม่นยำสูงกว่า 2 วิธีแรก ซึ่งวิธีนี้สามารถแก้ปัญหาข้อมูลหายที่เกิดขึ้นได้ โดยแมกซ์พูลลิงดึงค่าที่สูงที่สุด และทิ้งข้อมูลที่เหลือ มินพูลลิงดึงค่าเฉลี่ยก็ทำให้ค่าที่ดีหายไป โดยใช้ค่าที่อยู่ระหว่างแมกซ์พูลลิงและมินพูลลิง ส่วนขั้นสุดท้ายเป็นชั้นที่เชื่อมคุณลักษณะต่าง ๆ ที่ได้เข้าด้วยกันเป็นภาพเดียว หรือการทำโครงข่ายประสาทเทียมแบบสังวัตนาการ (CNN) โดยดูว่าโปรแกรมทำนายว่าภาพนั้นเป็นวัตถุชนิดใดสูงที่สุด โดยจะมีการคำนวณน้ำหนัก (weight) เข้ามาเกี่ยวข้องด้วย (Wang, et al., 2017)

งานวิจัยทางการแพทย์ก่อนหน้านี้ที่ใช้โครงข่ายประสาทเทียมแบบนี้ในการแยกแยะ เช่น การแยกแยะโรคจากภาพถ่ายรังสีที่ทรวงอก (Bar, et al., 2015) การจำแนกผิวอัตโนมัติ เพื่อแยกแยะมะเร็งผิวหนัง (Esteva, et al., 2017) การตรวจหาตำแหน่งของเนื้องอกจากภาพถ่าย สนามแม่เหล็กไฟฟ้า (Shin, et al., 2013) ในหัวข้อนี้กล่าวถึงโครงข่ายประสาทเทียม 4 แบบ คือ 1) Alexnet ซึ่งเป็นโครงข่ายประสาทเทียมที่ได้รับความนิยมอย่างแพร่หลาย 2) Googlenet ที่พัฒนา โดยนักวิจัยของกูเกิล 3) Resnet50 และ 4) Squeezenet

2.3.1 Alexnet

Alexnet เป็นคอนโวลูชันที่มีรูปแบบเรียบง่าย แต่ทำงานได้อย่างมีประสิทธิภาพ คิดค้นโดย Krizhevsky and Hinton, 2012 ในปี ค.ศ. 2012 Alexnet เป็นที่รู้จักจากการแข่งขัน รายการ ImageNet Large Scale Visual Recognition Challenge ซึ่งติดอันดับสูงสุด 5 อันดับ โดยมีอัตราความผิดพลาด (error) ร้อยละ 15.3 ซึ่งประมวลผลบนหน่วยประมวลผลกราฟิก 3 มิติ (GPU) แสดงให้เห็นถึงประสิทธิภาพของสถาปัตยกรรมนี้ โครงสร้างของประกอบด้วยคอนโวลูชัน 5 ชั้น โดยบางชั้นมีพูลลิ่งด้วย และสุดท้าย 3 พูลลิ่งคอนเน็ก (Deshpande, 2016; Krizhevsky and Hinton, 2012) ดังภาพที่ 2.5 ส่วนรายละเอียดแสดงดังตารางที่ 2.2



ภาพที่ 2.5 สถาปัตยกรรม Alexnet

ตารางที่ 2.2 แสดงรายละเอียดการทำงานของ Alexnet

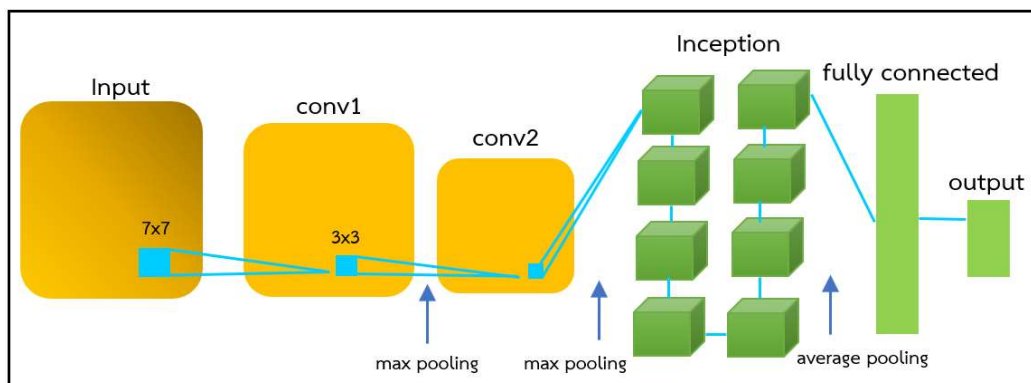
Layer	Type	Description
conv1	Convolution	96 11x11x3 convolutions with stride [4 4] and padding [0 0 0 0]
relu1	ReLU	ReLU
norm1	Cross Channel Normalization	Cross Channel Normalization with 5 channels per element
pool1	Max Pooling	3x3 max pooling with stride [2 2] and padding [0 0 0 0]
conv2	Convolution	256 5x5x48 convolutions with stride [1 1] and padding [2 2 2 2]
relu2	ReLU	ReLU
norm2	Cross Channel Normalization	Cross Channel Normalization with 5 channels per element
pool2	Max Pooling	3x3 max pooling with stride [2 2] and padding [0 0 0 0]
conv3	Convolution	384 3x3x256 convolutions with stride [1 1] and padding [1 1 1 1]
relu3	ReLU	ReLU
conv4	Convolution	384 3x3x192 convolutions with stride [1 1] and padding [1 1 1 1]
relu4	ReLU	ReLU
conv5	Convolution	256 3x3x192 convolutions with stride [1 1] and padding [1 1 1 1]
relu5	ReLU	ReLU
pool5	Max Pooling	3x3 max pooling with stride [2 2] and padding [0 0 0 0]
fc6	Fully Connected	4096 fully connected layer
relu6	ReLU	ReLU
drop6	Dropout	50% dropout
fc7	Fully Connected	4096 fully connected layer
relu7	ReLU	ReLU

ตารางที่ 2.2 แสดงรายละเอียดการทำงานของ Alexnet (ต่อ)

Layer	Type	Description
drop7	Dropout	50% dropout
fc8	Fully Connected	1000 fully connected layer
prob	Softmax	Softmax

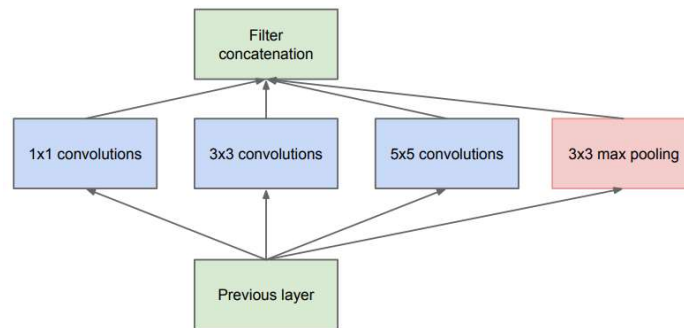
2.3.2 Googlenet

Googlenet เป็นคอนโวลูชันที่พัฒนาโดยทีมของกูเกิล ซึ่งชนะการแข่งขันในรายการ Large Scale Visual Recognition Challenge 2014 ชื่อย่อ คือ ILSVRC2014 ของ Imagenet ในปี ค.ศ. 2014 (Imagenet, 2014) โดยผลการแข่งขันมีอัตราความผิดพลาด (error) ร้อยละ 6.66 (GitHub) โดยเป็นคอนโวลูชันที่ลึก 22 ชั้น และมีชั้นที่เรียกว่า “Inception” เพิ่มขึ้นมา สถาปัตยกรรมของ Googlenet แสดงดังภาพที่ 2.6

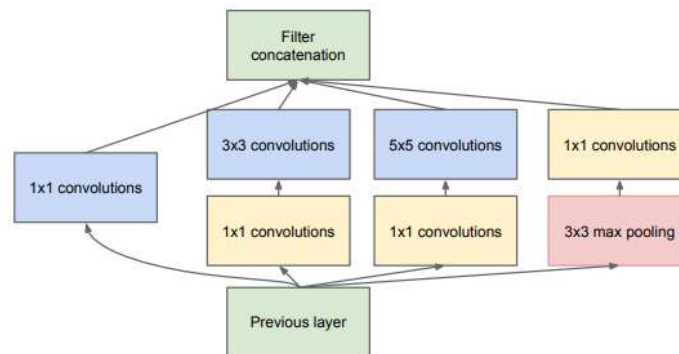


ภาพที่ 2.6 สถาปัตยกรรมของ Googlenet

ชั้น Inception ของ Googlenet มีแนวคิด คือ การใช้พื้นที่ขนาดใหญ่ โดยไม่ทำให้ความละเอียดของภาพนั้นหายไป แม้ว่าขนาดของภาพจะเล็กลง ซึ่งตัวกรองมี 3 ตัว และมีขนาดต่างกัน คือ 1x1 3x3 และ 5x5 ดังภาพที่ 2.7 และ 2.8 แสดงมอดูล Inception ทั้ง 2 เวอร์ชัน นอกจากนี้สถาปัตยกรรมของ Googlenet มีชั้น Inception ถึง 9 เลเยอร์ เพื่อให้การเรียนรู้เป็นไปอย่างมีประสิทธิภาพ แต่ข้อจำกัดของวิธีนี้ คือ อาจจะเกิดปัญหาคอขวดระหว่างการประมวลผลข้อมูลได้ (Al-Qizwini, et al., 2017; Szegedy, et al., 2015; Zucconi, 2015) รายละเอียดของแต่ละชั้นแสดงดังตารางที่ 2.3



ภาพที่ 2.7 มอดูล Inception เวอร์ชันนาอิว (naive) (Szegedy, et al., 2015)



ภาพที่ 2.8 มอดูล Inception เวอร์ชันการลดมิติ (dimensionality reduction) (Szegedy, et al., 2015)


จากภาพที่ 2.7 และ 2.8 กล่องสี่เหลี่ยมสีเขียวล่างสุด (Previous layer) คือ อินพุต และกล่องสี่เหลี่ยมบนสุด คือ ผลลัพธ์ที่ได้ (output)

ตารางที่ 2.3 แสดงรายละเอียดการทำงานของ GoogleNet

Layer	Type	Description
conv1	Convolution	64 7x7x3 convolutions with stride [2 2] padding [3 3 3 3]
pool1	Max pooling	3x3 max pooling with stride [2 2] and padding [0 1 0 1]
conv2	Convolution	192 3x3x64 convolutions with stride [1 1] padding [1 1 1 1]
pool2	Max pooling	3x3 max pooling with stride [2 2] and padding [0 1 0 1]
inception 3a	Inception (3a)	
inception 3b	Inception (3b)	
pool3	Max pooling	3x3 max pooling with stride [2 2] and padding [0 1 0 1]
inception 4a	Inception (4a)	
inception 4b	Inception (4b)	
inception 4c	Inception (4d)	
inception 4d	Inception (4e)	
pool4	Max pooling	3x3 max pooling with stride [2 2] and padding [0 1 0 1]
inception 5a	Inception (5a)	
inception 5b	Inception (5b)	
pool5	Average pooling	7x7 average pooling with stride [1 1] and padding [0 0 0 0]
prob	Softmax	softmax

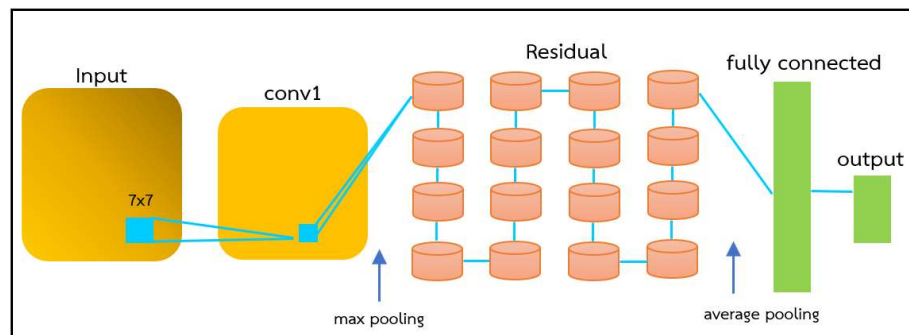
2.3.3 Resnet50

Resnet หรือ Residual Network เป็นสถาปัตยกรรมที่พัฒนาโดยไมโครซอฟท์ (Microsoft) ในปลายปี ค.ศ. 2015 โดยมี 152 เลเยอร์ ที่สร้างข้อมูลในการจำแนก (Classification) ตรวจจับ (Detection) และระบุตำแหน่ง (Localization) นอกจากนี้ยังได้รับรางวัล ILSVRC 2015 ด้วยอัตราข้อผิดพลาดแค่ร้อยละ 3.6 จากปกติร้อยละ 5-10 ซึ่งถือว่ามีข้อผิดพลาดน้อยมาก สิ่งที่เพิ่มเข้ามาของ Resnet คือ Residual module ที่นำมาต่อกัน ส่วนของอินพุต (Input) จะถูกแบ่งเป็นแพทช์ (patch) เล็ก ๆ ก่อนการเทรน เพื่อแก้ปัญหา diminishing gradients (He, et al., 2016; Mahadeokar and Pesavento, 2016) โดย Residual block แสดงดังภาพที่ 2.9 และตัวอย่างโครงสร้างของ Resnet แสดงดังภาพที่ 2.10 ส่วน Resnet50 ก็คือ Resnet ที่มี 50 ชั้น รายละเอียดแสดงดังตารางที่ 2.4



ภาพที่ 2.9 Residual block

จากภาพที่ 2.9 $F(x)$ คือ ผลลัพธ์ที่ได้มาจากชั้น Convolution-ReLu-Convolution ส่วน x คือ ผลลัพธ์ที่ได้จากชั้นก่อนหน้า ดังนั้นผลลัพธ์ที่ได้จาก Residual block คือ $F(x) + x$



ภาพที่ 2.10 ตัวอย่างโครงสร้างของ Resnet


ตารางที่ 2.4 แสดงรายละเอียดของ Resnet50

Layer	Type	Description
conv1	Convolution	64 7x7x3 convolutions with stride [2 2] padding [3 3 3 3]
relu1	ReLU	ReLU
pool1	Max pooling	3x3 max pooling with stride [2 2] and padding [0 1 0 1]
residual1	Residual	
residual2	Residual	
residual3	Residual	
residual4	Residual	
residual5	Residual	
residual6	Residual	
residual7	Residual	
residual8	Residual	
residual9	Residual	
residual10	Residual	
residual11	Residual	
residual12	Residual	
residual13	Residual	
residual14	Residual	
residual15	Residual	
residual16	Residual	
avg_pool	Average pooling	7x7 average pooling with stride [1 1] and padding [0 0 0 0]
fc1000_softmax	Softmax	softmax

2.3.4 Squeezenet

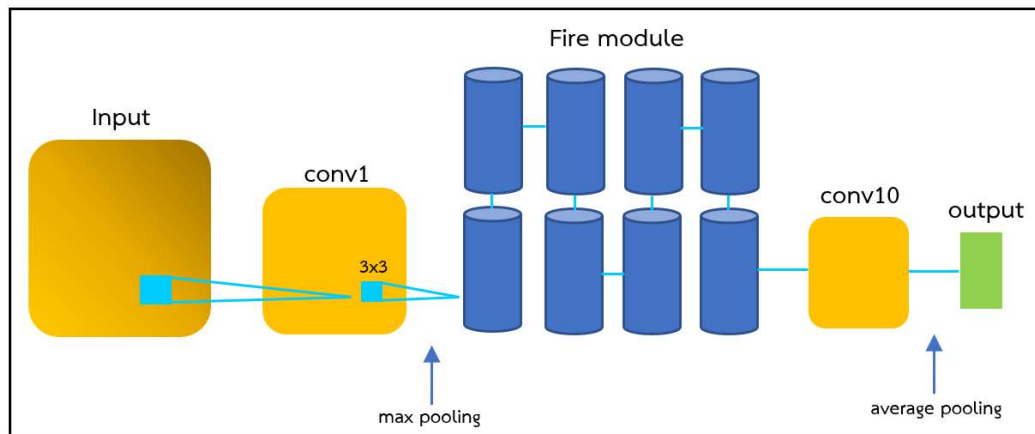
Squeezenet เป็นสถาปัตยกรรมที่ปรับปรุงมาจาก Alexnet โดยมี Fire module เพิ่มขึ้นมา เพื่อลดจำนวนของพารามิเตอร์ที่ใช้ทำให้ทำงานได้เร็วขึ้นและมีความแม่นยำมาก เช่นเดียวกับ Alexnet แต่ใช้เมมโมรี่ (Memory) น้อยกว่า (Mahadeokar and Pesavento, 2016) จากงานวิจัยของ Landola, et al. (2017) พบว่าข้อดีของ Squeezenet มี 3 ข้อ ดังนี้ 1) เป็นคอนโวลูชันที่เล็ก ซึ่งใช้การสื่อสารระหว่างเซิร์ฟเวอร์ระหว่างการเทรนน้อย 2) ใช้แบนด์วิธ (bandwidth) ในการสร้างตัวจำแนกได้อย่างอิสระ และ 3) สามารถนำไปใช้กับอุปกรณ์ (Hardware) ที่มีข้อจำกัดได้ ซึ่งในงานวิจัยนี้ได้บอกด้วยว่า Squeezenet ใช้พารามิเตอร์น้อยกว่า Alexnet ถึง 50 เท่า

Fire module ประกอบด้วยชั้นคอนโวลูชันที่มีตัวกรองขนาด 1×1 ใส่เข้าไปในชั้นที่เพิ่มขึ้นมาซึ่งมีการผสมระหว่างตัวกรอง 1×1 และ 3×3 ดังภาพที่ 2.11



ภาพที่ 2.11 ตัวกรองของคอนโวลูชันใน Fire module (landola, et al., 2017)

Fire module มีจุดแข็ง คือ 1) มีการแทนที่ตัวกรอง 3×3 ด้วยตัวกรอง 1×1 เพราะตัวกรอง 1×1 มีค่าพารามิเตอร์น้อยกว่าตัวกรอง 3×3 ถึง 9 เท่า 2) ลดจำนวนของช่องข้อมูลที่ใส่เป็นตัวกรอง 3×3 เนื่องจากการใช้พารามิเตอร์แบบเดิมมีจำนวนมาก ดังนั้นจึงมีการใช้ตัวกรอง 1×1 และลดจำนวนของช่องข้อมูล (input channels) และ 3) ลดพารามิเตอร์ลงในงบประมาณที่จำกัด โดยสถาปัตยกรรมของ Squeezenet แสดงดังภาพที่ 2.12 และรายละเอียดแสดงดังตารางที่ 2.5



ภาพที่ 2.12 สถาปัตยกรรมของ Squeezenet

ตารางที่ 2.5 แสดงรายละเอียดของ Squeezenet

Layer	Type	Description
conv1	Convolution	64 3x3x3 convolutions with stride [2 2] padding [0 0 0 0]
pool1	Max pooling	3x3 max pooling with stride [2 2] and padding [0 1 0 1]
fire2	Fire module	
fire3	Fire module	
pool3	Max pooling	3x3 max pooling with stride [2 2] and Padding [0 1 0 1]
fire4	Fire module	
fire5	Fire module	
pool5	Max pooling	3x3 max pooling with stride [2 2] and padding [0 1 0 1]
fire6	Fire module	
fire7	Fire module	
fire8	Fire module	
fire9	Fire module	
conv10	Convolution	1000 1x1x512 convolutions with stride [1 1] and padding [0 0 0 0]

ตารางที่ 2.5 แสดงรายละเอียดของ Squeezenet (ต่อ)

Layer	Type	Description
pool10	Average pooling	14x14 average pooling with stride [1 1] and padding [0 0 0 0]

2.4 การประมวลผลภาพ (Image Processing)

หัวข้อนี้อธิบายถึงแนวคิดของการประมวลผลภาพ ซึ่งการประมวลผลภาพเป็นการใช้คอมพิวเตอร์มาคำนวณหรือประมวลผลภาพ โดยเริ่มจากการนำภาพเข้าสู่ระบบคอมพิวเตอร์แล้วจึงประมวลผล จากนั้นจึงแสดงผลออกมา โดยปกติแล้วภาพ (image) คือ พิกัดแกน x และ y บนระนาบ แสดงได้ดั่งฟังก์ชัน 2 มิติ $f(x,y)$ ซึ่ง f คือ ค่าของสีเทา (gray level) หรือความเข้มแสง (intensity) ส่วนภาพดิจิทัล คือ การที่ค่าตัวแปรทั้ง 3 มีค่าแน่นอนและเป็นจำนวนเต็ม เมตริกซ์ของภาพแสดงดังภาพที่ 2.13

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & f(0,2) & \dots & f(0,N-1) \\ f(1,0) & f(1,1) & f(1,2) & \dots & f(1,N-1) \\ \vdots & \vdots & \vdots & \dots & \vdots \\ f(M-1,0) & f(M-1,1) & f(M-1,2) & \dots & f(M-1,N-1) \end{bmatrix}$$

ภาพที่ 2.13 เมตริกซ์ของภาพ

วัตถุประสงค์ของการประมวลผลภาพมีดังนี้

- 1) เพื่อให้มีการวิเคราะห์รูปภาพได้อัตโนมัติ
- 2) เพื่อปรับปรุงภาพ ทำให้มนุษย์สามารถตีความได้ง่ายขึ้น
- 3) เพื่อจัดการการเก็บและส่งข้อมูลภาพ
- 4) เพื่อให้คอมพิวเตอร์สามารถมองเห็นภาพได้

นอกจากนี้ภาพสามารถแบ่งออกเป็น 4 ประเภท คือ 1) ภาพไบนารี (Binary image) หรือเรียกอีกอย่างว่า โมโนโครม (Monochrome) เป็นภาพที่มีค่าของพิกเซลแค่ 2 ค่า คือ 0 แทน


สีดำ และ 1 แทน สีขาว 2) ภาพขาวดำ เป็นภาพที่มีแต่สีขาวและดำเท่านั้น 3) ภาพสี 8 บิต หรือ เกรสเกล (Grayscale) คือ ภาพที่มี 256 เฉดสี โดย 0 คือ สีดำ 255 คือ สีขาว และ 127 คือ สีเทา 4) ภาพสี 16 บิต หรือ High Color Format ซึ่งเป็นภาพที่มีเฉดสีถึง 65,536 สี (Baxes, 1994; Frédéric, 2003; Ian, et al., 2007; Lim, 1990)

การประมวลผลภาพมีการใช้งานกันอย่างแพร่หลาย โดยเฉพาะกับภาพถ่ายทางการแพทย์ที่เรียกว่า การประมวลผลภาพทางการแพทย์ (Medical Image Processing)

กระบวนการทางการแพทย์ประมวลผลภาพมีมากมาย ในงานวิจัยนี้ได้กล่าวถึงดังนี้ กระบวนการในการปรับปรุงภาพ (Image Enhancement) การเปลี่ยนแปลงลักษณะรูปร่างของภาพ (Morphological) การเลือกส่วนของภาพที่สนใจ (Thresholding) และการจับคู่ภาพ (Shape Matching) ซึ่งมีการใช้งานในส่วนของการระบุตำแหน่งของจุดเลือดออกในสมอง

2.4.1 การปรับปรุงภาพ (Image Enhancement)

การปรับปรุงภาพเป็นเทคนิคที่ใช้ในการปรับปรุงคุณภาพของภาพ เพื่อให้สามารถมองเห็นภาพได้ชัดเจนขึ้น โดยเป็นการเปลี่ยนแปลงภาพ เพื่อให้เน้นรายละเอียดที่ต้องการ โทนแสงของภาพ ภาพที่ได้หลังจากผ่านกระบวนการนี้จึงเป็นภาพที่สามารถมองเห็นรายละเอียดได้ชัดขึ้น สามารถนำไปใช้งานต่อได้ง่ายขึ้น ดังตัวอย่างในภาพที่ 2.14 เทคนิคโดยทั่วไปที่ใช้ในการปรับปรุงภาพ คือ เชนพื้นที่ (Spatial domain) และ เชนความถี่ (Frequency domain)



(ก) ภาพดั้งเดิม (ข) ภาพที่ผ่านการปรับความคมชัดแล้ว

ภาพที่ 2.14 ภาพก่อนและหลังการปรับปรุงภาพ

การปรับปรุงภาพเชิงพื้นที่ (Spatial domain enhancement) คือ การปรับความสว่างจากจุดที่อยู่ใกล้ เป็นความแตกต่างของจุดที่อยู่ติดกันที่นำมาคำนวณดำเนินงานกับฟังก์ชัน โดยตรงอาศัยค่าสูงสุดและต่ำสุดเกี่ยวกับความถี่เชิงพื้นที่ (spatial frequency) หากเป็นภาพเรียบ ๆ ที่ค่าของแต่ละจุดเท่ากันหมดจะได้ความถี่เชิงพื้นที่เป็นศูนย์ แต่หากภาพนั้นมีความแตกต่างของโทนสี


เป็นความถี่เชิงพื้นที่ต่ำ ส่วนภาพที่มีความแตกต่างระหว่างสีดำกับสีขาว เรียกว่า ความถี่เชิงพื้นที่สูง (ทรงกต ทศานนท์, 2550; Asha and Gupta, 2016; Imagine, 2002; Hong Kong University, n.d.) ดังแสดงในภาพที่ 2.15 และสมการที่ใช้แสดงดังสมการที่ 2.1

$$g(x,y) = f(x,y)*h(x,y) \quad (2.1)$$

เมื่อ g คือ ผลลัพธ์ที่ได้

f คือ ภาพที่ป้อนเข้าไป

T คือ การดำเนินการเกี่ยวกับ f ที่กำหนดเหนือพื้นที่ใกล้เคียงของ (x,y)



ภาพที่ 2.15 ภาพที่มีความถี่เชิงพื้นที่เป็นศูนย์ (ก) ความถี่เชิงพื้นที่ต่ำ (ข) และความถี่เชิงพื้นที่สูง (ค) (Imagine, 2002)

การปรับปรุงภาพเชิงความถี่ (Frequency domain enhancement) คือ การปรับปรุงคุณภาพของภาพเพื่อเพิ่มความคมชัดโดยใช้การลดสัญญาณรบกวน ซึ่งสามารถกำหนดช่วงของความถี่ได้ และใช้เทคนิคการกรองสัญญาณความถี่สูง และเทคนิค inverse filter ด้วย โดยสมการที่ใช้ (Hong Kong University, n.d.) คือ

$$G(w_1,w_2) = F(w_1,w_2)H(w_1,w_2) \quad (2.2)$$

2.4.2 การเปลี่ยนแปลงลักษณะรูปร่างหรือโครงร่างของภาพ (Morphological)

การเปลี่ยนแปลงลักษณะรูปร่างหรือโครงร่างของภาพเป็นการดำเนินการกับภาพที่ไม่ใช่เชิงเส้น (non-linear operation) และคุณสมบัติของภาพ ซึ่งเน้นรูปแบบ (Form) และโครงสร้าง (Structure) ในที่นี้ประกอบด้วย การขยายภาพ (Dilation) และการลบหลุม (Closing) ซึ่งมีรายละเอียดดังนี้


การขยายภาพ (Dilation) เป็นการขยายโดยกำหนดรูปแบบ (Template) แล้วนำรูปแบบที่กำหนดไปวางบนภาพตั้งต้นที่ต้องการขยาย แล้วค่อย ๆ เลื่อนไป เมื่อจุดเริ่มต้นบนรูปแบบตรงกับภาพตั้งต้น จะได้จุดตรงนั้นมีค่าเท่ากับ 1 แล้วจึงทำการรวม (Union) รูปแบบเข้ากับภาพตั้งต้น โดยจะทำงานภาพขาวดำ ดังภาพที่ 2.16-2.18 (พนมขวัญ ธิยะมงคล, ม.ป.ป.; Dougherty and Lotufo, 2003; Fisher, n.d.; Sicuranza, 2000)

* * * * * 1 * * 1 *	
* * * * * 1 * * * 1	
* * * * * 1 1 * 1 1 *	1 *
* * * * 1 1 1 1 1 1 1	1 1
* * * * 1 1 1 1 1 * 1	
* * * * 1 1 1 1 1 1 1	
* * * * 1 1 1 1 1 1 1	
ข้อมูลภาพ	รูปแบบ

ภาพที่ 2.16 ภาพและรูปแบบตั้งต้น


* * * * * 1 * * 1 * *
* * * * * 1 1 * 1 1 *
* * * * * 1 1 1 1 1 1 1
* * * * 1 1 1 1 1 1 1
* * * * 1 1 1 1 1 1 1
* * * * 1 1 1 1 1 1 1
* * * * 1 1 1 1 1 1 1
* * * * 1 1 1 1 1 1 1

ภาพที่ 2.17 ภาพผลลัพธ์ที่ได้หลังการขยายภาพ



ภาพที่ 2.18 ตัวอย่างภาพก่อนและหลังการขยายภาพ

การลบหลุม (Closing) คือ การย่อและขยายภาพโดยใช้รูปแบบเดียวกัน เป็นการทำให้เพื่อลบหลุมเล็ก ๆ ที่เป็นช่องว่างอยู่ระหว่างพิกเซล ถือเป็นการกระทำ (operation) หนึ่งของการเปลี่ยนแปลงลักษณะรูปร่างหรือโครงร่างของภาพ (Dougherty and Lotufo, 2003; Fisher, n.d.; Sicuranza, 2000) ตัวอย่างภาพก่อนและหลังการลบหลุมแสดงดังภาพที่ 2.19



ภาพที่ 2.19 ตัวอย่างภาพก่อนและหลังการลบหลุม

2.4.3 Thresholding

การทำขีดแบ่ง (Thresholding) เป็นวิธีการหนึ่งในการแยกวัตถุที่ต้องการออกจากพื้นหลัง (Segmentation) โดยมีการกำหนดค่าความเข้ม (Intensity) ที่ต้องการ แล้วนำมาเปรียบเทียบกับพิกเซลของภาพที่ต้องการ เรียกว่า เทคนิคในการทำขีดแบ่ง (Thresholding Techniques) ซึ่งผลลัพธ์ของการพิจารณาแบ่งเป็นจุดขาวและจุดดำ หากพิกเซลนั้นมีค่าน้อยกว่าค่าความเข้มที่กำหนด จุดนั้นจะถูกปรับให้เป็นสีดำซึ่งเป็นส่วนของวัตถุ ส่วนพิกเซลที่มีค่ามากกว่าค่าความเข้มที่กำหนด จุดนั้นจะถูกปรับให้เป็นส่วนของพื้นหลังซึ่งปรับเป็นสีขาว สามารถเขียนเป็นสมการได้ดังสมการที่ 2.3 วิธีนี้มีข้อดี คือ สามารถทำงานได้รวดเร็ว ง่าย ส่วนข้อเสีย คือ ต้องใช้กับ

ภาพที่ไม่มีสัญญาณรบกวนมาก (Ibungomacha, et al., 2017; Jaiswal and Sarode, 2018; Kang, et al., 2009)


$$g(i,j) = \begin{cases} 0 & \text{if } p_{i,j} < T \\ 1 & \text{if } p_{i,j} \geq T \end{cases} \quad (2.3)$$

โดย $g(i,j)$ คือ ผลลัพธ์ที่ได้

$p_{i,j}$ คือ พิกเซลของภาพที่ต้องการปรับ

T คือ ค่าความเข้มที่กำหนด

เทคนิคในการทำขีดแบ่งที่กล่าวถึงในที่นี้มี 2 แบบ คือ 1) ค่าขีดแบ่งส่วนกลาง (global threshold) คือ การใช้ค่าเดียวกันทั้งภาพ และ 2) ค่าขีดแบ่งเฉพาะที่ (local threshold) คือ การแบ่งภาพออกเป็นภาพย่อยแล้วกำหนดค่าให้แต่ละภาพ (Kang, et al., 2009) ตัวอย่างภาพถ่ายทางการแพทย์ที่ผ่านการแยกวัตถุด้วยวิธีการใช้ค่าขีดแบ่งแสดงดังภาพที่ 2.20 (Jaiswal and Sarode, 2018)



(ก)

(ข)

(ค)

(ง)


ภาพที่ 2.20 ตัวอย่างภาพทางการแพทย์ที่ผ่านการแยกวัตถุด้วยวิธีการใช้ค่าขีดแบ่ง

(ก) ภาพดั้งต้น (Original image) (ข) ภาพโทนขาวดำ (Binary image)

(ค) ภาพที่ได้จากการแบ่งส่วน (Extracted image) (ง) ผลลัพธ์ที่ได้ (Final image)


2.4.4 การจับคู่จากรูปร่าง (Shape Matching)

การจับคู่ภาพจากรูปร่างที่เหมือนกัน เป็นวิธีการที่สามารถใช้ในการระบุตำแหน่งของจุดเลือดออกในสมองของงานวิจัยนี้ ซึ่งวิธีการที่สามารถใช้ในการจับคู่จากรูปร่างได้ คือ เปรียบเทียบภาพโดยพิกเซลต่อพิกเซล (pixel-by-pixel comparison) หากสีของแต่ละพิกเซลของทั้ง 2 ภาพ เป็นสีตรงกัน ก็ถือว่าภาพทั้ง 2 เหมือนกัน ตัวอย่างการเปรียบเทียบพิกเซลแสดงดังภาพที่ 2.21




ภาพที่ 2.21 เปรียบเทียบพิกเซล

การเปรียบเทียบพิกเซลมีหลายเทคนิค Pixel Tolerance และ Color Tolerance เป็นการกำหนดค่าขึ้นมาว่าจะยอมรับให้มีพิกเซลต่างกันแค่ไหน จากนั้นเมื่อผลลัพธ์ที่ได้จากการเปรียบเทียบภาพมีจุดที่ต่างกันเท่ากับหรือน้อยกว่าค่าที่กำหนดไว้ ก็ถือว่าภาพทั้ง 2 นั้นเหมือนกันดังภาพที่ 2.22 ภาพทั้ง 2 ภาพมีจุดที่ต่างกันอยู่ 2 พิกเซล และมีการกำหนดค่า Pixel Tolerance เป็น 2 นั่นคือ 2 ภาพนี้เหมือนกัน ส่วน Color Tolerance เป็นการใช้ความแตกต่างของสีในการเปรียบเทียบ โดยความแตกต่างของสีแสดงเป็นจำนวนเต็มระหว่าง 0-255 ซึ่งต้องกำหนดค่าขึ้นมาเช่นเดียวกับวิธีแรก โดยค่าสีที่ใช้ คือ แดง เขียว และน้ำเงิน พิกเซลที่เปรียบเทียบกัน หากมีค่าสีแตกต่างกันระหว่างค่า Color Tolerance ที่กำหนดถือว่าไม่แตกต่างกัน



ภาพที่ 2.22 การเปรียบเทียบภาพโดยใช้ Pixel Tolerance

นอกจากนี้ยังมีวิธีอื่น ๆ ได้แก่ การเปรียบเทียบพิกเซลตามตำแหน่งของเมาส์ (Include Mouse Pointer) การใช้ความโปร่งของสี (“Transparent” Color) เป็นการเปรียบเทียบเฉพาะส่วนที่ไม่โปร่ง โดยสีของพิกเซลที่อยู่ซ้ายมือบนสุดถือว่าเป็นสีโปร่ง ถัดมาเป็นการเปรียบเทียบโดยใช้ภาพต้นแบบ (Comparison mask) ซึ่งภาพต้นแบบจะมีสีขาวดำ โดยโปรแกรมจะทำการเปรียบเทียบเฉพาะส่วนที่เป็นสีขาวเท่านั้น ดังตัวอย่างในภาพที่ 2.23



ภาพที่ 2.23 การเปรียบเทียบโดยใช้ภาพต้นแบบ

สุดท้ายวิธีการที่ใช้พารามิเตอร์เปรียบเทียบ เนื่องจากในภาพชนิด BMP PNG และ TIFF มีข้อมูลที่แสดงถึงความโปร่งของพิกเซล ที่เรียกว่า ช่องอัลฟา (Alphe channel) ซึ่งการพิจารณาจะกระทำเฉพาะพิกเซลที่ไม่โปร่งแสงเท่านั้น (Smartbear software, 2562)

2.5 การวัดและประเมินผล

การวัดและประเมินผลเป็นขั้นตอนหนึ่งที่สำคัญ เพื่อที่ผู้วิจัยจะได้ทราบว่างานวิจัยนั้น มีประสิทธิภาพมากเพียงใด ในที่นี้กล่าวถึงวิธีวัดและประเมินผล 6 วิธี คือ การประเมินผลลัพธ์ของการทำนายจาก confusion matrix รวมถึงการแสดงถึงที่มาของค่าความแม่นยำ (accuracy) อัตราของผลบวกจริง (sensitivity หรือ true positive rate: TPR) อัตราของผลลบจริง (specificity: SPC หรือ true negative rate) อัตราความผิดพลาดชนิดที่ 1 (fall-out หรือ false positive rate: FPR) และอัตราความผิดพลาดชนิดที่ 2 (false negative rate: FNR)

การประเมินผลลัพธ์ของการทำนายจาก confusion matrix

Confusion matrix เป็นตารางขนาด 2x2 ที่ใช้เพื่อบันทึกประสิทธิภาพการทำงานของโปรแกรม โดยเป็นการไขว้ความสัมพันธ์ของค่าจากการทำนาย (prediction values) และค่าจริง (observed values) (เอกสิทธิ์ พัทธวงศ์ศักดิ์, 2558; Sripaoraya and Sinsomboonthong, 2017) ซึ่งประกอบด้วยค่าต่าง ๆ จำนวน 4 ค่า ดังตารางที่ 2.6

ตารางที่ 2.6 Confusion matrix

		Actual class	
		True	False
Predict class	True	TP	FP
	False	FN	TN

จากตาราง 2.6 อธิบายค่าต่าง ๆ ได้ดังนี้

Actual class คือ ค่าที่ได้จากความเป็นจริง

Predict class คือ ค่าที่ได้จากการทำนาย

True positive: TP (ผลบวกจริง) คือ ค่าที่โปรแกรมทำนายว่าจริง และคนบอกว่าจริง

True negative: NP (ผลลบจริง) คือ ค่าที่โปรแกรมทำนายว่าไม่จริง และคนบอกว่าไม่จริง

False positive: FP (ความผิดพลาดชนิดที่ 1) คือ ค่าที่โปรแกรมทำนายว่าจริง แต่คนบอกว่าไม่จริง

False negative: FN (ความผิดพลาดชนิดที่ 2) คือ ค่าที่โปรแกรมทำนายว่าไม่จริง แต่คนบอกว่าจริง

จากค่าที่แสดงในตารางที่ 2.6 สามารถนำมาคำนวณค่าต่าง ๆ เพื่อทดสอบประสิทธิภาพของตัวจำแนกได้ดังนี้

Accuracy คือ ค่าความแม่นยำของโปรแกรม ที่สามารถบ่งชี้คุณภาพของตัวจำแนก ซึ่งสามารถแสดงผลได้ง่าย และเข้าใจง่ายที่สุด คำนวณได้จากสมการที่ 2.4

$$Accuracy = \frac{TP+T}{TP+TN+FN+FP} = \frac{TP+}{P+N} \quad (2.4)$$

Precision คือ ค่าที่แสดงถึงความถูกต้องของโปรแกรมที่ทำนายว่าจริง หาได้จากสมการที่ 2.5

$$Precision = \frac{TP}{TP+FP} \quad (2.5)$$

Recall / Sensitivity (True Positive Rate) คือ ค่าที่แสดงอัตราส่วนระหว่างค่าที่โปรแกรมทำนายถูกต้องว่าจริง ต่อค่าจริงทั้งหมด แสดงค่าได้ดังสมการที่ 2.6

$$Recall/Sensitivity = \frac{TP}{TP+FN} = \frac{TP}{P} \quad (2.6)$$

Specificity (True Negative Rate) คือ ค่าที่แสดงอัตราส่วนระหว่างค่าที่โปรแกรมทำนายถูกต้องว่าไม่จริง ต่อค่าจริงทั้งหมด ดังสมการที่ 2.7

$$Specitifity = \frac{TN}{TN+F} = \frac{TN}{N} \quad (2.7)$$

2.6 บทสรุป

บทนี้เป็นการทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้องกับงานวิจัยนี้ ซึ่งประกอบด้วยหัวข้อต่าง ๆ คือ การตรวจจับจุดเลือดออกในสมองจากภาพถ่ายทางการแพทย์ โดยเป็นการศึกษางานวิจัยก่อนหน้าเพื่อทบทวนวิธีการต่าง ๆ และประสิทธิภาพที่ได้ รวมถึงขั้นตอนในการทำงาน นอกจากนี้มีการเปรียบเทียบผลลัพธ์ที่ได้จากงานวิจัยนั้น ๆ ด้วย ถัดมาระบบโครงข่ายประสาทเทียมแบบสังวัตนาการ ในที่นี้ศึกษา 4 วิธีการ ซึ่งเป็นวิธีการที่มีความแม่นยำค่อนข้างสูง และเป็นที่ยอมรับ ส่วนกระบวนการจัดการรูปภาพ เป็นทั้งกระบวนการที่ใช้ก่อนการตัดจุดเลือดออกในสมองและการตัดจุด สุกการวัดและประเมินผล ซึ่งรายละเอียดต่าง ๆ มีการใช้งานตามที่กล่าวต่อไป

บทที่ 3

ชุดข้อมูลภาพและกระบวนการจับพื้นที่ที่สนใจ

3.1 บทนำ

บทนี้เป็นารอธิบายถึงชุดข้อมูลภาพที่ใช้ในการวิจัยการตรวจจับจุดเลือดออกในสมองและการระบุตำแหน่งของจุดเลือดออกในสมอง และกระบวนการจับพื้นที่ที่สนใจ ซึ่งจะอธิบายถึงการเก็บรวบรวมข้อมูลที่ใช้ในงานวิจัยนี้ ประกอบไปด้วย แหล่งที่มาของข้อมูล อธิบายถึงการได้มาซึ่งข้อมูลที่ใช้ในการตรวจจับจุดเลือดออกในสมอง และการระบุตำแหน่งของจุดเลือดออกในสมอง จำนวนและสถิติต่าง ๆ เป็นการอธิบายถึงจำนวนของข้อมูลที่นำมาใช้ในงานวิจัยนี้ ซึ่งแบ่งออกเป็นข้อมูลชุดที่ใช้ในการสร้างตัวจำแนก (Testing data) และข้อมูลชุดที่ใช้ในการทดสอบ (Training data) อธิบายถึงการถ่ายภาพที่ใช้ในงานวิจัยนี้ ประกอบไปด้วยประเภทของเครื่องถ่ายภาพ ทำทางในการถ่ายภาพ ความหนาของภาพ นามสกุลของภาพ และตัวอย่างของข้อมูลภาพ การตรวจจับพื้นที่ที่สนใจ จะเป็นการอธิบายกระบวนการในการตรวจจับพื้นที่ที่สนใจ รวมถึงมีการกล่าวถึงคุณสมบัติต่าง ๆ ที่ใช้ในการตรวจจับพื้นที่ที่สนใจ คือ 1) ขนาดของพื้นที่ที่สนใจ 2) จุดเยื้องศูนย์กลาง (Eccentricity) และ 3) ค่าความกลม (Roundness) ซึ่งผลลัพธ์ที่ได้จะถูกนำไปใช้ในการสร้างตัวจำแนก โดยจะอธิบายถึงการตรวจสอบจุดซ้ำ หรือ Overlapping และมีการแสดงชุดข้อมูลที่ใช้ในการสร้างตัวจำแนก ซึ่งมี 3 ชุดข้อมูล คือ 1) ภาพดั้งเดิมที่ตัดได้ (ภาพชุดที่ 1) 2) ภาพที่ปรับพื้นที่รอบข้างให้น้อยลง (ภาพชุดที่ 2) และ 3) ภาพที่ตัดส่วนพื้นที่ที่สนใจจากภาพดั้งเดิม (ภาพชุดที่ 3) พร้อมทั้งแสดงตัวอย่างของชุดข้อมูลดังกล่าว และสุดท้ายเป็นบทสรุปทั้งหมดของบทนี้


3.2 การเก็บรวบรวมข้อมูล

หัวข้อนี้เป็นการอธิบายถึงการเก็บรวบรวมข้อมูลที่ใช้ในงานวิจัยนี้ ข้อมูลทั้งหมดที่ใช้ในงานวิจัยนี้มีจำนวน 1,338 ภาพ ซึ่งแบ่งออกเป็น 2 ชุด คือ 1) ภาพชุดที่ใช้ในการสร้างตัวจำแนก (training dataset) จำนวน 818 ภาพ จากผู้ป่วยจำนวน 16 คน และ 2) ภาพชุดที่ใช้ในการทดสอบตัวจำแนก (testing dataset) จำนวน 520 ภาพ จากผู้ป่วยจำนวน 10 คน ทั้งเพศชายและเพศหญิง โดยได้มาจากโรงพยาบาลกรุงเทพภูเก็ต ซึ่งแพทย์ทางด้านประสาทวิทยา เป็นผู้ระบุให้ว่าจุดใดเป็น และจุดใดที่ไม่เป็นจุดเลือดออกในสมอง โดยทำการระบุจุดเลือดออก ในสมองในภาพ SWI ทีละภาพจนครบทุกสไลด์ ในผู้ป่วยแต่ละราย ตัวอย่างภาพที่มีการระบุจุดจากแพทย์แสดงดังภาพที่ 3.1


โดยสมองส่วนต่าง ๆ ที่แพทย์ทำการระบุว่าจุดไหนบ้างที่เป็นจุดเลือดออกในสมอง รวมถึงการระบุตำแหน่งของจุดนั้นแสดงด้วยปากกาสีแดงและสีน้ำเงิน โดยแพทย์ทำการวาดวงกลมล้อมส่วนต่าง ๆ ของสมอง แล้วเขียนตำแหน่งเป็นตัวเลข ดังนี้

- 1.1 คือ เนื้อสมองส่วนนอก
- 1.2 คือ เนื้อสมองส่วนใน
- 2 คือ สมองส่วนท้าย
- 3 คือ ก้านสมอง


ส่วนตัวเลขสีน้ำเงินก็มีความหมายเช่นเดียวกัน โดยภาพที่ 3.1(ก)–3.1(จ) แสดงให้เห็นว่า สามารถมองเห็นส่วนของสมองได้หลายส่วน และจุดเลือดออกในสมองก็สามารถเกิดได้หลายส่วน โดยรายละเอียดของการระบุตำแหน่งของจุดเลือดออกในสมอง จะอธิบายในบทที่ 5 นอกจากนี้ในภาพที่ 3.1(ฉ) แสดงให้เห็นว่า สามารถมองเห็นสิ่งผิดปกติอื่นที่ไม่ใช่จุดเลือดออกในสมอง โดยแพทย์เขียนไว้ให้ว่าเป็นแคลเซียม (Calcification) รวมถึงส่วนของจุดเลือดออกในสมองที่แตกแล้ว (Bleeding) และจากภาพที่ 3.1(ข) และ 3.1(ญ) สามารถมองเห็นร่องในสมอง หรือ Ventricle ซึ่งภายในประกอบด้วยน้ำ ในส่วนนี้จะไม่สามารถเกิดจุดเลือดออกในสมองได้ สุดท้ายภาพที่ 3.1(ฎ) แสดงจุดเลือดออกในสมองในเนื้อสมองส่วนนอกเพียงตำแหน่งเดียว



(ก) สมองส่วนก้านสมองและส่วนท้าย (ข) สมองส่วนก้านสมองและส่วนท้าย (ค) เนื้อสมองส่วนนอก ก้านสมองและสมองส่วนท้าย




(ง) เนื้อสมองส่วนนอก ก้านสมองและสมองส่วนท้าย (จ) เนื้อสมองส่วนนอก ก้านสมองและสมองส่วนท้าย (ฉ) เนื้อสมองส่วนนอก



(ช) เนื้อสมองส่วนนอก (ฅ) เนื้อสมองส่วนนอก และเนื้อสมองส่วนใน (ฎ) เนื้อสมองส่วนนอก


ภาพที่ 3.1 ตัวอย่างภาพที่ได้จากการระบุจุดเลือดออกในสมองและตำแหน่งจากแพทย์

ซึ่งชนิดของภาพที่ผู้วิจัยได้มานั้นเป็นภาพถ่ายเฉพาะที่ใช้ในโรงพยาบาล นั่นคือ Digital Image and Communication on Medicine (DICOM) ภาพได้มาจากการเอกซเรย์คลื่นแม่เหล็กไฟฟ้า (Magnetic Resonance Imaging: MRI) แบบการถ่ายภาพแบบถ่วงน้ำหนักตามความอ่อนไหว (Susceptibility Weighted Imaging: SWI) ปกติภาพ MRI สามารถถ่ายได้ 3 แบบ คือ 1) แนวขวาง (transverse) 2) แนวยาว (coronal) และ 3) แนวเฉียง (sagittal) ในงานวิจัยนี้ใช้การถ่ายภาพตามแนวขวางเท่านั้น ตัวอย่างของภาพถ่าย SWI ตามแนวขวางแสดงดังภาพที่ 3.2




ภาพที่ 3.2 ภาพ SWI ดั้งเดิมที่แสดงผลในรูปแบบของ DICOM


ภาพถ่าย SWI ของสมองจากผู้ป่วยแต่ละคนจะมีจำนวนภาพไม่เท่ากัน ขึ้นอยู่กับขนาดของสมอง โดยจำนวนภาพอยู่ระหว่าง 40-60 ภาพ แต่ละภาพมีความหนา 3 มิลลิเมตร เท่ากัน ซึ่งถ่ายจากเครื่อง Siemens MAGNETOM Aera 1.5T scanner with 20 channel head&neck coil ปริมาตร $0.9 \times 0.9 \times 3.0$ ลูกบาศก์มิลลิเมตร (mm^3) โดยผู้ป่วยจะต้องนอนหงาย ซึ่งใช้ในการทำซ้ำ (Time of Repetition: TR) ที่ 49 มิลลิวินาที ส่วนเวลาในการเอคโค (Time of Echo: TE) ที่ 40 มิลลิวินาที โปรแกรมที่ใช้ในการ MRI คือ E11 ตัวอย่างของภาพถ่าย SWI แสดงได้ดังภาพที่ 3.3 โดยพบว่าแต่ละภาพจะไม่เหมือนกัน เนื่องจากการถ่ายเลื่อนจากล่างขึ้นบนทั้งหัว การถ่ายภาพจะใช้สไลด์ที่มีความหนา 3 มิลลิเมตร เท่ากันทุกภาพ ดังนั้นจุดเลือดออกในสมองอาจจะพบได้ในภาพ SWI จำนวน 1-3 ภาพ เนื่องจากขอบเขตของงานวิจัยนี้ตามที่ระบุไว้ว่าจะทำการตรวจจับจุดเลือดออกในสมองที่มีขนาดเส้นผ่านศูนย์กลาง 2-10 มิลลิเมตร




ภาพที่ 3.3 ตัวอย่างภาพ SWI ที่ถ่ายจากผู้ป่วยหนึ่งราย




ภาพที่ 3.3 ตัวอย่างภาพ SWI ที่ถ่ายจากผู้ป่วยหนึ่งราย (ต่อ)



ภาพที่ 3.3 ตัวอย่างภาพ SWI ที่ถ่ายจากผู้ป่วยหนึ่งราย (ต่อ)



ภาพที่ 3.3 ตัวอย่างภาพ SWI ที่ถ่ายจากผู้ป่วยหนึ่งราย (ต่อ)




ภาพที่ 3.3 ตัวอย่างภาพ SWI ที่ถ่ายจากผู้ป่วยหนึ่งราย (ต่อ)

3.3 การตรวจจับพื้นที่ที่สนใจ

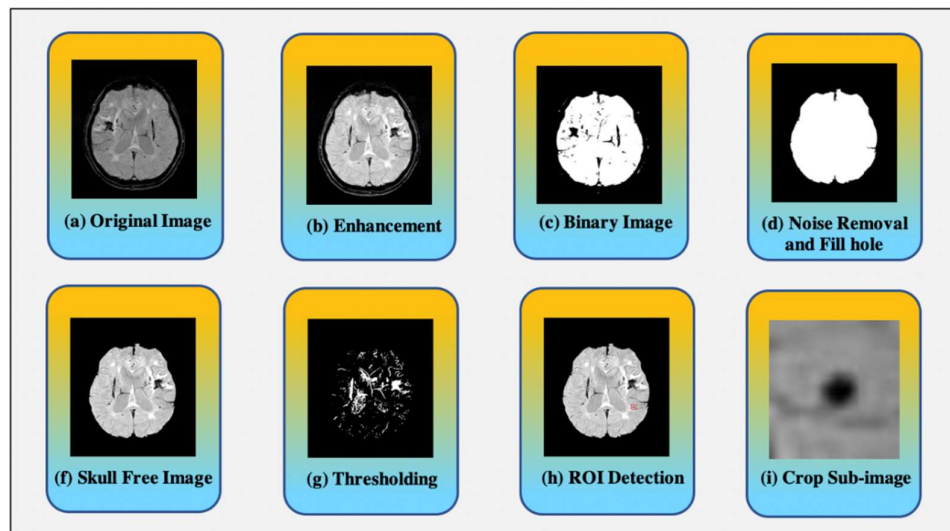
ดังที่กล่าวมาแล้วในข้อ 3.2 ถึงการเก็บรวบรวมข้อมูล ข้อมูลที่ใช้ในงานวิจัยนี้ได้มาจากโรงพยาบาลกรุงเทพภูเก็ต มีทั้งหมดจำนวน 1,338 ภาพ ข้อมูลทั้งหมดจะถูกแบ่งออกเป็นชุดข้อมูลสำหรับการสร้างตัวจำแนกจำนวน 818 ภาพ และชุดข้อมูลสำหรับทดสอบตัวจำแนกจำนวน 520 ภาพ กระบวนการในการสร้างตัวจำแนกเพื่อตรวจจับจุดเลือดออกในสมอง ต้องอาศัยกระบวนการประมวลผลภาพ เพื่อได้มาซึ่งชุดของภาพพื้นที่ที่สนใจ (Region of interest: ROI)

รายละเอียดของกระบวนการตรวจจับพื้นที่ที่สนใจจะนำเสนอในหัวข้อนี้มีวัตถุประสงค์ของกระบวนการเพื่อระบุพื้นที่ (จุด) ที่คาดว่าจะเป็จุดเลือดออก (CMB) จากภาพถ่ายสมอง โดยผลลัพธ์ที่ได้จากกระบวนการนี้คือ ชุดของพื้นที่ที่คาดว่าจะเป็ CMB ซึ่งอาจจะประกอบไปด้วยจุดเลือดออก และจุดที่ไม่ใช่จุดเลือดออก กระบวนการตรวจจับพื้นที่ที่สนใจแสดงได้ดังภาพที่ 3.4



ภาพที่ 3.4 กระบวนการตรวจจับพื้นที่ที่สนใจ


จากภาพที่ 3.4 กระบวนการตรวจจับพื้นที่ที่สนใจเริ่มจากการนำเข้าภาพ SWI ที่ละภาพ แล้วทำการปรับปรุงคุณภาพของภาพโดยการปรับความคมชัด เพื่อให้สามารถมองเห็นพื้นที่ที่สนใจได้ชัดขึ้น ซึ่งขั้นตอนนี้ใช้วิธี spatial filtering smoothing method and boost filtering method โดยกระบวนการนี้ให้แสดงให้เห็นถึงพื้นที่ที่สนใจได้ชัดเจนที่สุด ดังแสดงในภาพที่ 3.5(b) เมื่อได้รูปที่ปรับความคมชัดแล้วรูปที่ได้จะถูกปรับจากรูปโทนสีเทา (greyscale image) เป็นรูปโทนขาวดำ (binary image) ซึ่งทำให้แยกโทนสีของรูปได้ และทำกระบวนการจัดการรูปภาพได้ง่ายขึ้น ผลลัพธ์จากขั้นตอนนี้แสดงดังภาพที่ 3.5(c) อย่างไรก็ตามผลลัพธ์ที่ได้ี้จะมีส่วนที่ไม่เกี่ยวข้อง (noise) และส่วนที่เป็นหลุม (holes) ซึ่งมีสีขาวและเป็นบริเวณกว้าง ๆ แสดงอยู่ ดังนั้นต้องมีการลบส่วนที่ไม่เกี่ยวข้อง และเพิ่มส่วนที่เป็นสีขาวบริเวณกว้างโดยใช้วิธีการ morphological ผลลัพธ์ที่ได้แสดงดังภาพที่ 3.5(d) เห็นได้ว่าผลลัพธ์ออกมาชัดยิ่งขึ้น จากนั้นนำภาพที่ได้มาเป็นภาพต้นแบบ (Phototype) เพื่อนำไปเทียบกับรูปดั้งเดิม (Original Image) แล้วตัดเอาเฉพาะรูปส่วนที่มีขอบเขตเช่นเดียวกับภาพต้นแบบ ผลลัพธ์ที่ได้แสดงดังภาพที่ 3.5(f) จากนั้นทำการตรวจจับพื้นที่ที่สนใจด้วยวิธีการ Thresholding ตัวอย่างแสดงดังภาพที่ 3.5(g) ส่วนตัวอย่างของผลลัพธ์ที่ได้ของกระบวนการนี้แสดงในรูปที่ 3.5(h) และ 3.6(i) ตามลำดับ



ภาพที่ 3.5 ผลลัพธ์จากกระบวนการจับพื้นที่ที่สนใจ

ในกระบวนการตรวจจับพื้นที่ที่สนใจ มีการดึงวัตถุพื้นหน้าออกจากพื้นหลังโดยใช้ค่าคงที่ (Thresholding: T) จำนวน 3 ค่า เนื่องจากจุดแต่ละจุดมีความเข้มที่ต่างกัน ในงานวิจัยนี้จึงใช้ค่าดังนี้ 1) T = 90 2) T = 140 3) T = 180 โดยภาพที่ 3.6(a) แสดงผลลัพธ์ที่ได้จากการใช้

ค่า $T = 90$ แล้วจึงใช้ค่า $T = 140$ ผลลัพธ์ที่ได้จากการใช้ค่า $T = 90$ และ $T = 140$ แสดงดังภาพที่ 3.6(b) จากนั้นจึงใช้ค่า $T = 180$ ซึ่งผลลัพธ์ที่ได้จากการใช้ค่า T ทั้ง 3 ค่า แสดงดังภาพที่ 3.6(c)



ภาพที่ 3.6 แสดงรูปที่ผ่านการ Thresholding

นอกจากนี้มีตัวแปรที่เกี่ยวข้องอีก 3 ตัว ที่ใช้ในการเลือกพื้นที่ที่สนใจนั้นคือ 1) ขนาดของจุด (Size) 2) จุดเยื้องศูนย์กลาง (Eccentricity) และ 3) ค่าความกลม (Roundness) ขนาดของพื้นที่ที่สนใจอยู่ระหว่าง 2-10 มิลลิเมตร (7-35 พิกเซล) ส่วนพื้นที่อื่น ๆ จะถูกลบออก ในส่วนจุดเยื้องศูนย์กลางนั้น หากพบว่าค่าของจุดเยื้องศูนย์กลางที่ตรวจพบเป็นวงรีก็จะถูกลบออก โดยจุดเยื้องศูนย์กลางจะวัดจากจุดศูนย์กลางไปยังขอบของจุด ซึ่งสามารถวัดค่าได้ดังสมการที่ 3.1 ผลลัพธ์ที่ได้จากสมการที่ 3.1 จะเป็นค่าระหว่าง 0-1 ถ้าจุดเป็นวงรี จะได้ค่าจุดเยื้องศูนย์กลางเท่ากับ 1 ในส่วนงานวิจัยนี้หากพบว่าพื้นที่ที่ได้มีค่าจุดเยื้องศูนย์กลางน้อยกว่า 0.75 จุดเหล่านั้นจะถูกเก็บไว้ และเช่นเดียวกับเงื่อนไขของขนาดพื้นที่ที่มีค่าจุดเยื้องศูนย์กลางมากกว่าหรือเท่ากับ 0.75 จะถูกลบออก

$$\text{Eccentricity} = \frac{c}{a} \quad (3.1)$$

เมื่อ c คือ ระยะห่างระหว่างจุดศูนย์กลางและขอบของจุด

a คือ ระยะห่างระหว่างจุดในวงรีและจุดบนเส้นขอบของวงรี

หลังจากการคำนวณค่าจุดเยื้องศูนย์กลางแล้ว ก็มีการคำนวณค่าความกลมของพื้นที่ที่จับได้ โดยค่าความกลมใช้วัดว่าพื้นที่นั้น ๆ มีความกลมมากแค่ไหน และพื้นที่นั้น ๆ กลมหรือไม่ ซึ่งค่าความกลมสามารถคำนวณได้จากสมการที่ 3.2 ผลลัพธ์ที่ได้จากสมการนี้อยู่ระหว่าง 0-1 หากค่าความกลมมีค่าเท่ากับ 1 แสดงว่าจุดนั้นมีรูปร่างกลม ส่วนค่าความกลมที่เท่ากับ 0 แสดงให้เห็นว่าพื้นที่นั้นมีรูปร่างเป็นวงรี ซึ่งในงานวิจัยนี้เลือกพื้นที่ที่มีค่าความกลมมากกว่าหรือเท่ากับ 0.8

$$\text{Roundness} = \frac{4\pi * \text{Area}}{\text{Perimeter}^2} \quad (3.2)$$

เมื่อ Area	คือ ค่าที่คำนวณมาจาก πR^2
R	คือ รัศมีของจุดที่จับได้
π	เท่ากับ 3.14
Perimeter	คือ เส้นรอบรูปของจุด

หลังจากที่ทำกระบวนการเหล่านี้ครบทุกขั้นตอน ก็พบพื้นที่ที่สนใจที่มีลักษณะใกล้เคียงกับจุดเลือดออกในสมอง และท้ายที่สุดพื้นที่ที่น่าสนใจจะถูกตัดออกมาอยู่ที่ขนาด 36x36 พิกเซล โดยการตัดพื้นที่วัดจากจุดศูนย์กลางตามแนวแกน x ไปลบ 18 และวัดจากจุดศูนย์กลางตามแนวแกน y ไปลบ 18 เช่นกัน จากนั้นกำหนดขนาดที่ต้องการเป็น 36x36 พิกเซล ซึ่งอัลกอริทึมในการระบุตำแหน่งของจุดเลือดออกในสมองแสดงดังภาพที่ 3.7 และอัลกอริทึมในการตัดจุดแสดงดังภาพที่ 3.8 ทั้งนี้มีจุดเลือดออกในสมองที่ระบุโดยแพทย์ แต่กระบวนการตัดพื้นที่ที่สนใจไม่สามารถตรวจจับได้จำนวน 16 จุด

สำหรับกระบวนการตรวจจับพื้นที่ที่สนใจที่แสดงไว้ในภาพที่ 3.7 เริ่มจากการกำหนดค่าเริ่มต้นเพื่อใช้เป็นเกณฑ์ในการแยกจุดที่น่าสนใจออกมา โดยมีค่า Threshold 3 ค่า ดังบรรทัดที่ 2-4 จากนั้นบรรทัดที่ 6 กำหนดให้ตัวแปร iPic เก็บค่ารูปสไลด์สมองทั้งหัวที่กำลังดำเนินการอยู่ ซึ่งในกระบวนการนี้กระทำภายใต้ขั้นตอนการทำซ้ำของจำนวนสไลด์ของ 2 หัวนั้น ๆ ทั้งหมด จากนั้นกำหนดให้สไลด์ปัจจุบันอยู่ในตัวแปร Origimg แล้วทำการปรับขนาดของสไลด์ให้ใหญ่ขึ้นเพื่อให้สามารถดำเนินการต่อได้ แล้วจึงเปลี่ยนประเภทของภาพจาก DICOM เป็น JPG จากนั้นเพิ่มความคมชัดของภาพ แล้วจึงปรับภาพเป็นโทนขาวดำ (binary image) ถัดมาจึงทำการเพิ่มสีขาวลงไป ในภาพเพื่อให้ส่วนที่เป็นสมองเป็นสีขาวทึบ แล้วจึงนำรูปที่ได้จากขั้นตอนก่อนหน้ามาทาบลงบนภาพสมองสไลด์นั้น ๆ แล้วตัดออกมา ขั้นตอนที่กำลังกล่าวมาทั้งหมดนี้แสดงดังบรรทัด 8-15

จากนั้นทำการกำหนดค่าให้ Tclearborder ดังบรรทัดที่ 16-25 ซึ่งค่านี้นำไปใช้ในการตัดส่วนที่ไม่ต้องการออกในบรรทัดที่ 26 ขั้นตอนถัดมาในบรรทัดที่ 27 และ 28 ทำการกำหนดค่าตั้งต้นว่าจะเลือกเอาแต่จุดที่มีพื้นที่เท่าไร แล้วจึงทำการเลือกเฉพาะจุดที่ต้องการจากพื้นที่ดังบรรทัดที่ 29-30 จากนั้นทำการปรับภาพที่ได้เป็นภาพโทนขาวดำในบรรทัดที่ 31-33 แล้วจึงจับพื้นที่ที่ได้ออกมา ในบรรทัดที่ 34

ถัดมาเป็นการนำพื้นที่ที่ได้จากบรรทัดที่ 34 มาใช้เพื่อหาพื้นที่ที่มีคุณสมบัติต่าง ๆ ตรงกับจุดเลือดออกในสมองที่ต้องการ ในที่นี้ใช้คำสั่ง regionprops ดังแสดงในบรรทัดที่ 35-57 แล้วจึงนำพื้นที่ที่ได้ทั้งหมดเข้าสู่อัลกอริทึมต่อไป ดังแสดงในภาพที่ 3.8

อัลกอริทึม 3.1 ROI Detection

```

1: Start:
2: Threshold      = 150
3: TRoundness     = 0.8
4: TEccentricity  = 0.75
5: Input:
6: iPic = A collection of cerebral images
7: for i = 1 to i = |iPic| do
8:   OrigImg       = iPic(i)
9:   resizeImg     = Resize(OrigImg)
10:  JPGImg        = Convert format of image from DICOM to JPG (resizeImg)
11:  ContrastImg   = Adjust the contrast (JPGImg)
12:  binaryImg     = ContrastImg > Threshold
13:  binaryImg     = Fill background pixel(binaryImg)
14:  skullFreeImg  = ContrastImg;
15:  skullFreeImg(not_binaryImg) = 0
16:  for iclear_border = 1 to 3 do
17:    if iclear_border = 1 then
18:      Tclearborder = 90
19:    end if
20:    if iclear_border = 2 then
21:      Tclearborder = 140
22:    end if
23:    if iclear_border = 3 then
24:      Tclearborder = 180
25:    end if

```

ภาพที่ 3.7 อัลกอริทึมในการตรวจจับจุดที่สนใจ

```

26:     binaryImg2{iPic,iclear_border} = (skullFreelmg < Tclearborder)
27:     Areamin = 28.26
28:     Areamax = 961
29:     binaryImg2{iPic,iclear_border} =
30:         Extract objects(binaryImg2{iPic,iclear_border},[areamin areamax]);
31:     mat_gray = converts the binaryImg2 to an intensity image
32:         (binaryImg2{iPic,iclear_border})
33:     img_bi = creates a binary image (mat_gray)
34:     [boundary_bi,con_area_bi] = Trace region boundaries(image_bi,'noholes')
35:     for k = 1 to length(boundary_bi) do
36:         boundary = boundary_bi{k};
37:         stats = regionprops(con_area_bi,'Area','Centroid',
38:             'Eccentricity','PixelIdxList','EquivDiameter')
39:         delta_sq = diff(boundary).^2
40:         perimeter = sum(sqrt(sum(delta_sq,2)))
41:         radius = stats(k).EquivDiameter/2
51:         area = stats(k).Area
52:         eccentricity = stats(k).Eccentricity
53:         roundness = 4*pi*area/perimeter^2
54:         centroid = stats(k).Centroid
55:         if roundness >= TRoundness and eccentricity < TEccentricity then
56:             Pic_cnn_incrop = Crop(image_std{iPic},
57:                 [(centroid(1) - 18) (centroid(2) - 18) (36) (36)]);
58:         end if
59:     end for
60: end for

```

ภาพที่ 3.7 อัลกอริทึมในการตรวจจับจุดที่สนใจ (ต่อ)

หลังจากเสร็จสิ้นกระบวนการจับพื้นที่ที่สนใจแล้ว จะเป็นการตัดพื้นที่ที่จับได้ โดยตัวแปร `image_std` คือ ชุดของภาพสมองที่กำลังดำเนินการตรวจจับจุดเลือดออกในสมองอยู่ จากนั้นนำภาพทั้งหมดเข้าสู่ขั้นตอนการทำซ้ำเพื่อการตัดจุด ภายในการทำซ้ำนี้ขั้นตอนแรก คือ การตัดพื้นที่ที่โปรแกรมจับได้ว่าเป็นพื้นที่ที่สนใจ จากนั้นทำการปรับขนาดภาพของพื้นที่ที่ตัดออกมาแล้วเป็น 227×227 พิกเซล เพื่อให้นำไปใช้ในกระบวนการสร้างตัวจำแนกด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการได้ แล้วจึงทำการเชื่อมภาพทั้งหมดเข้าด้วยกัน ทั้ง 3 ขั้นตอนนี้แสดงดังบรรทัดที่ 4-6 แล้วจึงนำเข้าสู่กระบวนการคอนโวลูชันต่อไป อัลกอริทึมในการตัดจุดที่สนใจแสดงดังภาพที่ 3.8

อัลกอริทึม 3.2 Crop ROI

```


1: image_std = A collection of cerebral images
2: for iPic = 1 to All image do
3:   Pic_cnn_imcrop = CutImage(image_std{iPic})
4:   Pic_cnn_imcrop = Resize Pic_cnn_imcrop to 227x227
5:   rgbImage      = Concatenate arrays(Pic_cnn_imcrop)
6: end for

```

ภาพที่ 3.8 อัลกอริทึมในการตัดจุดที่สนใจ

3.4 การตรวจสอบจุดซ้ำ (Overlapping)

หลังจากทำการตรวจจับพื้นที่ที่สนใจ ดังที่กล่าวมาแล้ว จากนั้นมีการนำภาพพื้นที่ที่ได้ทั้งหมดเข้าสู่กระบวนการสร้างตัวจำแนก แล้วจึงนำตัวจำแนกที่ได้มาใช้ในการตรวจจับจุดเลือดออกในสมอง เมื่อได้จุดเลือดออกในสมองแล้วสิ่งหนึ่งที่ต้องให้ความสำคัญ คือ การจัดการจุดเดียวกันที่พบในสไลด์อื่น ๆ (Overlapping) เนื่องจากงานวิจัยนี้ตรวจจับจุดเลือดออกในสมองที่มีขนาด 2-10 มิลลิเมตร ส่วนสไลด์หนา 3 มิลลิเมตร ดังนั้นจึงเป็นไปได้ว่าจุดเลือดออกในสมองจะแสดงใน 1-3 สไลด์ ดังแสดงในรูปที่ 3.9 กรอบสีเขียว



ภาพที่ 3.9 ตัวอย่างจุดเลือดออกในสมองที่ปรากฏใน 2 ภาพ

การจัดการเรื่องจุดที่พบในหลายสไลด์ งานวิจัยนี้ใช้วิธีการวัดจุดศูนย์กลางของจุดที่ตรวจจับได้ โดยหากจุดที่ตรวจจับได้ในสไลด์ถัดไป มีจุดศูนย์กลางเลื่อนจากจุดเดิมไป 2 พิกเซล หรือ 0.57 เซนติเมตร ถือว่าเป็นจุดเดียวกัน การแสดงผลจะแสดงผลที่จุดในภาพแรกที่พบ กระบวนการตรวจสอบจุดซ้ำแสดงได้ดังภาพที่ 3.10

เริ่มจากการตั้งสไลด์ของสมองนั้น ๆ ขึ้นมาทีละภาพ แล้วกำหนดค่าให้ตัวแปร pointStatus จากนั้นทำการตั้งจุดที่จับได้ทั้งหมดบนสไลด์นั้น ๆ มาตรวจสอบว่าบนสไลด์นั้น ๆ มีจุดที่จับได้หรือไม่ ถ้ามีทำการตรวจสอบต่อว่าจุดที่จับได้นั้น มีจุดศูนย์กลางตรงกับจุดที่เก็บไว้ก่อนหน้าหรือไม่ โดยตรวจสอบกับจุดศูนย์กลางของจุดที่เคลื่อนไปอย่างละ 2 พิกเซลด้วย เนื่องจากบางครั้งการถ่ายภาพสมองอาจจะได้จุดออกมาเอียง ถ้าจุดนั้นไม่ได้มีการเก็บไว้แล้ว ก็ตั้งค่าตัวแปร pointStatus ให้เป็น true ดังบรรทัดที่ 3-9 ถัดมาเป็นการตั้งค่าเช่นเดิม แต่ทำการตรวจสอบย้อนหลังไป 3 สไลด์ ดังบรรทัดที่ 10-14 ดังขอบเขตที่ระบุไว้ว่า จุดเลือดออกในสมองในงานวิจัยนี้มีขนาด 2-10 มิลลิเมตร ส่วนสไลด์รูปสมองหนา 3 มิลลิเมตร ดังนั้นจะสามารถเจอจุดเลือดออกในสมองได้ สูงสุดถึง 4 สไลด์

อัลกอริทึม 3.3 Overlapping

```

1: for iPic = 1 to All image do
2:   pointStatus = false;
3:   for count_point = 1 to All_point_in_slide do
4:     if slide has point then
5:       if centerOfPointOnAxisX and centerOfPointOnAxisY +- 2
6:         are not exist then
7:           pointStatus = true;
8:         end if
9:       end if
10:    end for
11:   for iSlide = 1 to 3 then
12:     if centerOfPointOnAxisX and centerOfPointOnAxisY +- 2 are not exist
13:       then
14:         pointStatus = true;
15:       end if
16:     end for
17:   end for


```

ภาพที่ 3.10 อัลกอริทึมในการตรวจสอบจุดที่ซ้ำกัน

3.5 ชุดข้อมูลที่ใช้ (Datasets)

ส่วนนี้เป็นการอธิบายถึงชุดข้อมูลที่ใช้ในงานวิจัยนี้ ดังที่กล่าวมาแล้วถึงการเก็บข้อมูลในหัวข้อที่ 3.2 แล้วนำมาเข้ากระบวนการจับพื้นที่ที่สนใจ (ROI Detection) โดยใช้กระบวนการประมวลผลภาพ เมื่อได้พื้นที่ที่สนใจทั้งหมดแล้ว จะนำมาแบ่งเป็น 2 กลุ่ม คือ กลุ่มของจุดที่แพทย์ระบุว่าจุดเลือดออกในสมอง (CMB) มีจำนวน 688 จุด และกลุ่มของจุดที่แพทย์ระบุว่าไม่ใช่จุดเลือดออกในสมอง (non-CMB) มีจำนวน 13,325 จุด จากนั้นจัดทำภาพทั้ง 2 กลุ่ม เป็น 3 แบบ คือ 1) ภาพดั้งเดิมที่ตัดได้ (ภาพชุดที่ 1) 2) ภาพที่ตัดพื้นที่รอบข้างให้เหลือน้อยลง (ภาพชุดที่ 2) และ

3) ภาพที่ตัดส่วนพื้นที่ที่สนใจจากภาพดั้งเดิม (ภาพชุดที่ 3) โดยข้อมูลที่ใช้มีจำนวนรูปที่เท่ากัน จัดเก็บมาจากที่เดียวกัน คือ โรงพยาบาลกรุงเทพภูเก็ต โดยตัวอย่างจุดเลือดออกในสมองและจุดที่ไม่ใช่แสดงได้ดังภาพ 3.11 ซึ่งได้มีการอธิบายถึงภาพดั้งเดิมที่ตัดได้ โดยมีบริเวณรอบข้างอยู่ ซึ่งเป็นการอธิบายภาพที่ปรับพื้นที่รอบข้างให้น้อยลง และเป็นการอธิบายภาพที่ตัดส่วนพื้นที่ที่สนใจจากภาพดั้งเดิม




ภาพที่ 3.11 ตัวอย่างพื้นที่ที่สนใจที่เป็นจุดเลือดออกในสมองและไม่ใชจุดเลือดออกในสมอง

จากภาพที่ 3.11 ข้ามมือ คือ ภาพจุดเลือดออกในสมองทั้ง 3 แบบ (ลูกศรสีเขียว) พบว่าลักษณะของจุดเลือดออกในสมองจะมีลักษณะกลม สีดำเข้ม ส่วนขาวมือ คือ จุดที่ไม่ใช่จุดเลือดออกในสมอง (ลูกศรสีแดง) แม้จะมองเห็นเป็นสีดำเข้มเช่นกัน แต่พื้นที่รอบข้างจะมีเส้นสีดำจาง ๆ เส้นนั้น คือ เส้นเลือดในสมอง ส่วนในกรอบสีแดงเป็นส่วนที่มีเลือดออกในสมองแต่ไม่ได้มีลักษณะเป็นจุดกลมจึงไม่ใช่จุดเลือดออกในสมอง

3.5.1 ภาพดั้งเดิมที่ตัดได้

ภาพดั้งเดิมที่ตัดได้เป็นภาพที่ได้จากกระบวนการตัดพื้นที่ที่สนใจ ขนาด 36x36 พิกเซล ไม่มีการปรับแต่งใด ๆ ภาพชุดนี้จะเรียกว่า “ภาพชุดที่ 1” ตัวอย่างพื้นที่ที่สนใจที่เป็นจุดเลือดออกในสมองดังแสดงในรูปที่ 3.12 โดยพื้นที่ที่เป็นจุดเลือดออกในสมองที่ตัดได้จากกระบวนการตรวจจับพื้นที่ที่สนใจมีลักษณะค่อนข้างกลม และจุดมีสีดำอย่างชัดเจน บางจุดมีช่องว่างตรงกลาง แต่ขอบยังคงกลมเช่นจุดอื่น ๆ นอกจากนี้ยังมีบริเวณรอบข้างของจุดเหล่านี้อีกด้วย



ภาพที่ 3.12 ตัวอย่างพื้นที่ที่สนใจที่เป็นจุดเลือดออกในสมองแบบดั้งเดิมที่ตัดได้


พื้นที่ที่สนใจที่ไม่ใช่จุดเลือดออกในสมองแบบดั้งเดิมที่ตัดได้ แสดงดังภาพที่ 3.13 ซึ่งพบว่าพื้นที่ที่ไม่ใช่จุดเลือดออกในสมองที่ตัดได้จากกระบวนการตรวจจับพื้นที่ที่สนใจมีลักษณะไม่ชัดเจน บางจุดกลม แต่มีเส้นเลือดอยู่ติดกัน บางจุดรูปร่างไม่กลม นอกจากนี้ยังมีบางจุดที่กลมแต่มีสีจางมาก มองเห็นไม่ชัดเจน ภาพชุดนี้มีบริเวณรอบข้างของจุดเหล่านี้ด้วย



ภาพที่ 3.13 ตัวอย่างพื้นที่ที่สนใจที่ไม่ใช่จุดเลือดออกในสมองแบบดั้งเดิมที่ตัดได้


3.5.2 ภาพที่ปรับพื้นที่รอบข้างให้น้อยลง

ภาพที่ปรับพื้นที่รอบข้างให้น้อยลงเป็นการนำภาพที่ได้จากกระบวนการตัดพื้นที่ที่สนใจ ขนาด 36x36 พิกเซล มาปรับพื้นที่รอบข้างให้น้อยลง เป็น 28x28 พิกเซล โดยภาพชุดนี้ใช้ชื่อว่า “ภาพชุดที่ 2” ตัวอย่างพื้นที่ที่เป็นจุดเลือดออกในสมองดังแสดงในรูปที่ 3.14 พบว่าพื้นที่ที่เป็นจุดเลือดออกในสมองที่ตัดได้จากกระบวนการตรวจจับพื้นที่ที่สนใจมีลักษณะไปทางกลม และมีจุดดำอย่างชัดเจน บางจุดมีช่องว่างตรงกลาง แต่ขอบยังคงกลมเช่นจุดอื่น ๆ



ภาพที่ 3.14 ตัวอย่างพื้นที่ที่สนใจที่เป็นจุดเลือดออกในสมองแบบที่ปรับพื้นที่รอบข้างให้น้อยลง


พื้นที่ที่ที่น่าสนใจที่ไม่ใช่จุดเลือดออกในสมองแบบที่ปรับพื้นที่รอบข้างให้น้อยลง แสดงดังรูปที่ 3.15 โดยพบว่าพื้นที่ที่ไม่ใช่จุดเลือดออกในสมองที่ตัดได้จากกระบวนการตรวจจับพื้นที่ที่สนใจมีลักษณะไม่กลม และไม่ได้เป็นจุดดำอย่างชัดเจน บางจุดมีสีจางมาก และมีการปรับขนาดเป็น 28x28 พิกเซล



ภาพที่ 3.15 ตัวอย่างพื้นที่ที่สนใจที่ไม่ใช่จุดเลือดออกในสมองแบบที่ปรับพื้นที่รอบข้างให้น้อยลง


3.5.3 ภาพที่ตัดเอาแต่พื้นที่ที่สนใจ

ภาพที่ตัดเอาแต่ส่วนพื้นที่ที่สนใจเป็นการนำภาพดั้งเดิมที่ตัดได้ มาตัดเอาแต่ละส่วนของพื้นที่ที่สนใจ โดยภาพชุดนี้ใช้ชื่อว่า “ภาพชุดที่ 3” ตัวอย่างพื้นที่ที่สนใจที่เป็นจุดเลือดออกในสมอง ดังแสดงในรูปที่ 3.16 ซึ่งพบว่าพื้นที่ที่เป็นจุดเลือดออกในสมองที่ตัดได้จากกระบวนการตรวจจับพื้นที่ที่สนใจยังคงมีลักษณะไปทางกลม และมีจุดดำอย่างชัดเจน บางจุดมีช่องว่างตรงกลาง แต่ขอบยังคงกลมเช่นจุดอื่น ๆ แต่ต่างจากภาพที่ตัดพื้นที่รอบข้างให้น้อยลง คือ ภาพชุดนี้จะปรับขนาดของพื้นที่ที่สนใจโดยตรง สังเกตได้ว่าขนาดของพื้นที่ที่สนใจที่เป็นจุดเลือดออกในสมองจะมีขนาดใหญ่ขึ้น



ภาพที่ 3.16 ตัวอย่างพื้นที่ที่สนใจที่เป็นจุดเลือดออกในสมองแบบที่ตัดเอาแต่ส่วนจุด

พื้นที่ที่สนใจที่ไม่ใช่จุดเลือดออกในสมองแบบที่ตัดเอาแต่ส่วนจุด แสดงดังรูปที่ 3.17 ซึ่งพบว่าพื้นที่ที่ไม่ใช่จุดเลือดออกในสมองที่ตัดได้จากกระบวนการตรวจจับพื้นที่ที่สนใจ ไม่สามารถเห็นรูปร่างได้ และไม่ได้เป็นจุดดำอย่างชัดเจน บางจุดมีสีจางมาก อย่างไรก็ตามสังเกตได้ว่าพื้นที่สนใจจะมีขนาดใหญ่ขึ้น



ภาพที่ 3.17 ตัวอย่างจุดที่ไม่ใช่จุดเลือดออกในสมองแบบที่ตัดเอาแต่ส่วนจุด

3.6 สรุป

บทที่ 3 เป็นการอธิบายถึงชุดข้อมูลภาพและกระบวนการในการจับพื้นที่ที่สนใจ ซึ่งใช้ในงานวิจัยนี้ โดยมีการอธิบายถึงรายละเอียดของการเก็บรวบรวมข้อมูล กระบวนการพื้นที่ที่สนใจ ซึ่งเป็นกระบวนการเบื้องต้นที่มีความสำคัญ เนื่องจากต้องนำข้อมูลทั้ง 3 ชุดที่ได้จากกระบวนการนี้ไปทำงานในกระบวนการสร้างตัวจำแนกต่อไป ซึ่งได้อธิบายต่อไปในบทที่ 4

บทที่ 4

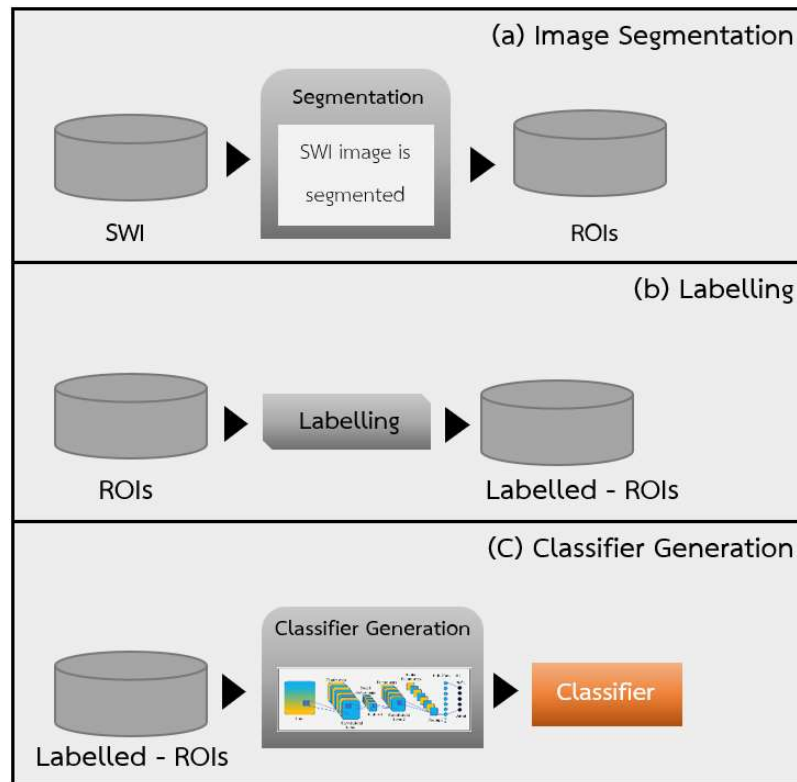
กระบวนการสร้างตัวจำแนกสำหรับตรวจจับจุดเลือดออกในสมองจากภาพที่สร้างด้วยสนามแม่เหล็กไฟฟ้าถ่วงน้ำหนักตามความอ่อนไหว

4.1 บทนำ

ดังที่กล่าวมาแล้วในบทก่อนหน้า งานวิจัยนี้ใช้ชุดข้อมูลภาพที่สร้างด้วยสนามแม่เหล็กไฟฟ้าถ่วงน้ำหนักตามความอ่อนไหว (Susceptibility Weighted Imaging: SWI) ตามแนวขวาง จากโรงพยาบาลในจังหวัดภูเก็ต โดยใช้ 1,338 ภาพ แบ่งออกเป็น 2 กลุ่ม คือ ภาพชุดที่ใช้ในการสร้างตัวจำแนก (training dataset) และภาพชุดที่ใช้ในการทดสอบตัวจำแนก (test dataset) ในบทนี้อธิบายถึงกระบวนการสร้างตัวจำแนก (Classifier) สำหรับการตรวจจับจุดเลือดออกในสมอง โดยใช้ภาพชุดที่ได้มาดังกล่าว

ในการตรวจจับจุดเลือดออกในสมองมีวัตถุประสงค์เพื่อจำแนกจุดที่สนใจออกเป็นจุดเลือดออกในสมอง (CMB) และจุดที่ไม่ใช่จุดเลือดออกในสมอง (Non-CMB) ซึ่งใช้ภาพพื้นที่ที่สนใจ (Region of Interests: ROIs) 3 ชุดข้อมูล คือ 1) ภาพดั้งเดิมที่ตัดได้ (ภาพชุดที่ 1) 2) ภาพที่ปรับพื้นที่รอบข้างให้น้อยลง (ภาพชุดที่ 2) และ 3) ภาพที่ตัดส่วนพื้นที่ที่สนใจจากภาพดั้งเดิม (ภาพชุดที่ 3) โดยใช้สถาปัตยกรรมโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network: CNN) 4 แบบ คือ 1) Alexnet 2) Googlenet 3) Resnet50 และ 4) Squeezenet เพื่อใช้ในการหาวิธีการ และข้อมูลที่เหมาะสมในการสร้างตัวจำแนก

ในกระบวนการสร้างตัวจำแนกได้ใช้ภาพ SWI ที่ได้มาจากโรงพยาบาล โดยนำมาผ่านกระบวนการจัดการเพื่อหาพื้นที่ที่สนใจโดยใช้การประมวลผล โดยใช้การเพิ่มความคมชัดของภาพเพื่อให้สามารถมองเห็นพื้นที่ที่สนใจได้ชัด และเลือกพื้นที่ที่สนใจจากค่าคงที่ (Threshold) ที่เหมาะสม แพทย์เฉพาะทางด้านประสาทวิทยาทำการระบุว่าจุดไหนเป็นจุดเลือดออก และจุดไหนที่ไม่ใช่จุดเลือดออกในสมอง จากนั้นนำจุดที่สนใจทั้งหมดเข้าสู่กระบวนการของโครงข่ายประสาทเทียมแบบสังวัตนาการ แล้วจึงได้ตัวจำแนกออกมา โดยกระบวนการสร้างตัวจำแนก แสดงดังภาพที่ 4.1



ภาพที่ 4.1 กระบวนการสร้างตัวจำแนก

บทนี้เป็นการอธิบายถึงกระบวนการสร้างตัวจำแนกสำหรับตรวจจับจุดเลือดออกในสมองจากภาพที่สร้างด้วยสนามแม่เหล็กไฟฟ้าถ่วงน้ำหนักตามความอ่อนไหว โดยกล่าวถึงสถาปัตยกรรมของโครงข่ายประสาทเทียมแบบสังวัตนาการ ทั้ง 4 แบบ คือ 1) Alexnet 2) Googlenet 3) Resnet50 และ 4) Squeezenet ซึ่งมีโครงสร้างแตกต่างกัน จากนั้นจึงกำหนดการทดลองเพื่อเลือกสถาปัตยกรรมที่เหมาะสมที่สุดมาสร้างตัวจำแนก นอกจากนี้มีการอธิบายถึงการวัดและการประเมินผลการทดลอง เพื่อให้ได้มาซึ่งตัวจำแนก รวมถึงการอภิปรายผลในการสร้างตัวจำแนก

4.2 โครงข่ายประสาทเทียมแบบสังวัตนาการ

โครงข่ายประสาทเทียมแบบสังวัตนาการ หรือ CNN เป็นการจำลองรูปแบบเพื่อการเรียนรู้เชิงลึก ที่นำมาเพื่อใช้ในการเรียนรู้ของเครื่อง โดยเลียนแบบแนวความคิดการทำงานของระบบประสาทของมนุษย์ การสร้างตัวจำแนกสำหรับตรวจจับจุดเลือดออกในสมองจากภาพที่สร้างด้วยสนามแม่เหล็กไฟฟ้าถ่วงน้ำหนักตามความอ่อนไหวด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ ในหัวข้อนี้กล่าวถึงโครงข่ายประสาทเทียมแบบสังวัตนาการทั้ง 4 รูปแบบที่มีโครงสร้างต่างกัน คือ 1) Alexnet 2) Googlenet 3) Resnet50 และ 4) Squeezenet ที่นำมาทดสอบความถูกต้องและความเร็ว เพื่อสร้างตัวจำแนกที่มีประสิทธิภาพมากที่สุด โดยมีการกำหนดค่าให้โครงสร้างของโครงข่ายประสาทเทียมทั้ง 4 แบบ คือ Freeze weight ในชั้นที่ 1-10 และจำนวนคลาสของงานวิจัยนี้มี 2 คลาส คือ CMB และ non-CMB โดยมีการกำหนดค่าที่ตัวแปร augmentedImageDatastore นอกจากนี้มีการกำหนดค่า weightLearnRateFactor เท่ากับ 10

4.2.1 Alexnet

Alexnet เป็นโครงข่ายประสาทเทียมแบบเรียบง่าย ทำงานได้อย่างมีประสิทธิภาพ และใช้กันอย่างแพร่หลาย (Krizhevsky and Hinton, 2012) โครงสร้างประกอบด้วยชั้นคอนโวลูชันที่ทำหน้าที่ดึงคุณลักษณะจำนวน 5 ชั้น นอกจากนี้มีชั้นพูลลิงที่ทำหน้าที่ลดขนาดของคุณลักษณะจำนวน 3 ชั้น ชั้นดรอปเอาต์จำนวน 2 ชั้น และชั้นเชื่อมต่อหรือพูลลีคอนเน็กจำนวน 3 ชั้น

4.2.2 Googlenet

Googlenet พัฒนาโดยนักวิจัยของกูเกิล สถาปัตยกรรมนี้มีชั้น Inception เข้ามาแทนที่ชั้นพูลลีคอนเน็ก ซึ่งสามารถทำงานได้ดีและเร็ว โดยสถาปัตยกรรมประกอบด้วย 2 คอนโวลูชัน 3 พูลลิง และ 9 อินเซพชัน

4.2.3 Resnet50

Resnet50 เป็นโครงข่ายประสาทเทียมแบบสังวัตนาการลึก 50 ชั้นที่มีชั้น Residual เพิ่มเข้ามา และเทรนข้อมูลด้วย Stochastic Gradient Descent (SGD) สถาปัตยกรรมของ Resnet50 ประกอบด้วย 47 คอนโวลูชัน รวมถึงชั้นพูลลิง และพูลลีคอนเน็ก

4.2.4 Squeezenet

Squeezenet เป็นสถาปัตยกรรมที่ใช้แบนด์วิดท์ต่ำ (low bandwidth) ใช้พื้นที่เพียง 4.9 เมกะไบร์ท รวมถึงมีชั้นที่เรียกว่าไฟร์เอมอดูล (fire module) เพิ่มขึ้นมา ประกอบด้วย 2 คอนโวลูชัน 5 พูลลิง และ 8 ไฟร์เอมอดูล

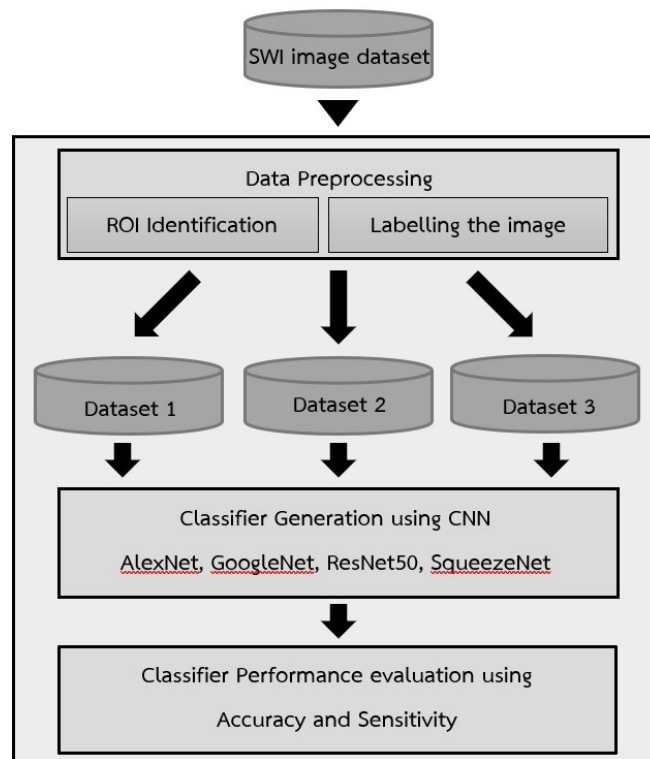
ดังที่กล่าวมาแล้วถึงสถาปัตยกรรมของโครงข่ายประสาทเทียมแบบสังวัตนาการทั้ง 4 แบบที่ใช้ในการสร้างตัวจำแนก ซึ่งมีโครงสร้างที่แตกต่างกัน แต่แต่ละแบบมีชั้นคอนโวลูชันเหมือนกันแต่จำนวนไม่เท่ากัน นอกจากนี้บางแบบมีมอดูลเฉพาะเพิ่มขึ้นมา ในหัวข้อถัดไปกล่าวถึงการกำหนดการทดลองในการสร้างตัวจำแนก

4.3 การกำหนดการทดลอง

ดังที่ได้กล่าวมาแล้วถึงสถาปัตยกรรมโครงข่ายประสาทเทียมแบบสังวัตนาการที่ใช้ในงานวิจัยนี้ทั้ง 4 แบบ ได้แก่ 1) Alexnet 2) Googlenet 3) Resnet50 และ 4) Squeezenet ในหัวข้อนี้อธิบายถึงการกำหนดการทดลองที่ใช้ในการสร้างตัวจำแนกสำหรับจุดเลือดออกในสมอง โดยกระบวนการทดลองทั้งหมด แสดงดังภาพที่ 4.2

เมื่อได้ภาพชุดภาพ SWI จากโรงพยาบาลในจังหวัดภูเก็ตแล้ว จะถูกนำเข้าสู่กระบวนการเตรียมข้อมูล โดยประกอบด้วยการระบุพื้นที่ที่สนใจ (ROI Identification) และการระบุว่าพื้นที่ไหนเป็นจุดเลือดออกและพื้นที่ไหนไม่ใช่จุดเลือดออกโดยแพทย์เฉพาะทางประสาทวิทยา (Labelling the image) กระบวนการนี้ใช้การประมวลผลภาพโดยมีการเพิ่มความคมชัดของภาพเพื่อให้เห็นรายละเอียดของภาพได้ชัดเจนขึ้น จากนั้นใช้ค่าคงที่ (Thresholding) ดึงพื้นที่ที่สนใจขึ้นมา

ซึ่งอาศัยคุณสมบัติเรื่องขนาด ค่าความกลม และจุดเยื้องศูนย์เข้ามาพิจารณาด้วย เมื่อแพทย์ทำการระบุว่าจุดไหนเป็นจุดเลือดออกในสมองและจุดไหนที่ไม่ใช่จุดเลือดออกในสมองแล้ว พื้นที่ที่สนใจทั้งหมดถูกนำเข้าสู่กระบวนการของโครงข่ายประสาทเทียมแบบสังวัตนาการทั้งหมด 4 สถาปัตยกรรม คือ 1) Alexnet 2) Googlenet 3) Resnet50 และ 4) Squeezenet ซึ่งมีการทดสอบประสิทธิภาพด้านความถูกต้อง ความเร็ว และจำนวนรอบของการเทรนข้อมูล นอกจากนี้มีการทดสอบเพื่อเลือกชุดข้อมูลที่เหมาะสมที่สุด เพื่อนำมาสร้างตัวจำแนก จากข้อมูล 3 ชุด คือ 1) ชุดข้อมูลที่มีพื้นที่ที่สนใจและพื้นที่รอบข้าง 2) ชุดข้อมูลที่มีพื้นที่ที่สนใจปรับพื้นที่รอบข้างให้เล็กลง และ 3) ชุดข้อมูลที่มีเฉพาะพื้นที่ที่สนใจ จากนั้นทำการประเมินประสิทธิภาพของตัวจำแนกโดยใช้ค่าความถูกต้อง (accuracy) ที่ได้จาก confusion matrix ซึ่งผลลัพธ์ที่ได้แสดงไว้แล้วในหัวข้อถัดไป



ภาพที่ 4.2 กระบวนการทดลอง

4.4 การวัดและการประเมินผล

เพื่อวัดและประเมินกระบวนการจับจุดเลือดออกในสมองที่ได้นำเสนอในงานวิจัยนี้ จากข้อมูลทั้งหมดที่ใช้ในงานวิจัยนี้จำนวน 1,338 ภาพ แบ่งออกเป็น 2 ชุด คือ 1) ภาพชุดที่ใช้ในการสร้างตัวจำแนก (training dataset) จำนวน 818 ภาพ จากผู้ป่วยจำนวน 16 คน และ 2) ภาพชุดที่ใช้ในการทดสอบตัวจำแนก (testing dataset) จำนวน 520 ภาพ จากผู้ป่วยจำนวน 10 คน ในหัวข้อนี้ ใช้ข้อมูลภาพสำหรับเรียนรู้ (Training Set) จำนวน 818 ภาพ ซึ่งถ่ายจากผู้ป่วยจำนวน 16 ราย ภาพแต่ละภาพจะถูกประมวลผลด้วยกระบวนการตรวจจับพื้นที่ที่สนใจ เพื่อหาจุดที่คาดว่าจะเป็จุดเลือดออกในสมอง ซึ่งแต่ละพื้นที่ที่สนใจจะมีการจำแนกว่าเป็นจุดเลือดออก (CMB) หรือไม่ใช่จุดเลือดออก (Non-CMB) โดยแพทย์เฉพาะทางด้านประสาทวิทยา หรือเรียกว่า ประสาทแพทย์ โดยชุดข้อมูลพื้นที่ที่สนใจจะมีการประมวลผลภาพออกเป็น 3 ชุดข้อมูล ได้แก่ ข้อมูลชุดที่ 1 พื้นที่สนใจและพื้นที่รอบข้าง ข้อมูลชุดที่ 2 พื้นที่ที่สนใจปรับขนาดให้มีขนาดพื้นที่รอบข้างน้อยลง และข้อมูลชุดที่ 3 เฉพาะพื้นที่ที่สนใจ ทั้งนี้เพื่อศึกษาว่าลักษณะของพื้นที่ที่สนใจแบบใดที่เหมาะสมต่อการจับจุดเลือดออกในสมอง เมื่อชุดข้อมูลได้ถูกเตรียมเรียบร้อยแล้ว แต่ละชุดของข้อมูลถูกใช้เป็นข้อมูลชุดเรียนรู้ (Training Set) ในกระบวนการสร้างตัวจำแนกต่อไป

วัตถุประสงค์ของการวัดและการประเมินผล เพื่อหาหลักฐาน หรือสนับสนุนว่าจุดเลือดออกในสมองสามารถตรวจจับได้ โดยใช้กระบวนการทางการประมวลผลภาพ และโครงข่ายประสาทเทียมแบบสังวัตนาการ โดยมี 3 ชุดการทดลอง ดังนี้

1) ชุดข้อมูลภาพพื้นที่ที่สนใจ ชุดของการทดลองเมื่อวิเคราะห์หาชุดข้อมูลภาพทั้ง 3 วิธี ได้แก่ ชุดข้อมูลชุดที่ 1 พื้นที่สนใจและพื้นที่รอบข้าง ชุดข้อมูลชุดที่ 2 พื้นที่ที่สนใจปรับขนาดของพื้นที่รอบข้างให้เล็กลง และชุดข้อมูลชุดที่ 3 เฉพาะพื้นที่ที่สนใจ โดยภาพทั้ง 3 ชุด มีจำนวน 688 ภาพที่เป็นจุดเลือดออกในสมอง และจำนวน 13,325 ภาพที่ไม่ใช่จุดเลือดออกในสมอง

2) สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบสังวัตนาการ (CNN Architecture) ชุดของการทดลองเพื่อหาสถาปัตยกรรมของ CNN ที่เหมาะสมที่สุดระหว่าง Alexnet Googlenet Resnet50 และ Squeezenet โดยมีการกำหนดค่า WeightLearnRateFactor เท่ากับ 10 ในส่วนของโครงสร้างนั้นไม่มีการเปลี่ยนแปลงในขั้นตอนการทดลองเพื่อหาสถาปัตยกรรมที่เหมาะสม แต่ในขั้นตอนของการสร้างตัวจำแนกนั้น ใช้จำนวนรอบเท่ากับ 8 รวมถึงมีการ Freeze weight ในชั้นที่ 1-10 และสุดท้ายจำนวนคลาสของงานวิจัยนี้มี 2 คลาส คือ CMB และ non-CMB มีการกำหนดค่าที่ตัวแปร augmentedImageDatastore

3) จำนวน Epoch ที่เหมาะสมในสถาปัตยกรรมของ CNN ชุดของการทดลอง เพื่อวิเคราะห์ผลของจำนวน Epoch ในสถาปัตยกรรม CNN โดยจำนวน Epoch 5 ตัวอย่าง คือ 2 4 6 8 และ 10 ได้ถูกนำมาใช้ทดลองเพื่อหา Epoch ที่เหมาะสมที่สุด

การทดลองทั้งหมดนั้นมีการดำเนินการโดยใช้ MatLab (Matrix Laboratory) เวอร์ชัน R2018b โดยประสิทธิภาพของการสร้างตัวจำแนกจะบันทึกเป็นค่า Accuracy และ Sensitivity โดยใช้ข้อมูลร้อยละ 80 ของข้อมูลเป็นชุดสร้างตัวจำแนก และร้อยละ 20 เป็นตัวทดสอบ รวมถึงมีการเลือกข้อมูลแบบสุ่ม

4.4.1 ชุดข้อมูลพื้นที่ที่สนใจ

เพื่อวิเคราะห์หาประสิทธิภาพของการจำแนกที่มีการใช้ชุดข้อมูลของพื้นที่ที่สนใจแตกต่างกัน ได้แก่ 1) ชุดข้อมูลที่ 1 พื้นที่ที่สนใจและพื้นที่รอบข้าง 2) ชุดข้อมูลชุดที่ 2 พื้นที่ที่สนใจปรับขนาดของพื้นที่รอบข้างให้เล็กลง และ 3) ชุดข้อมูลชุดที่ 3 เฉพาะพื้นที่ที่สนใจ ทั้งนี้วัตถุประสงค์เพื่อหาว่า ชุดข้อมูลที่ประมวลผลแบบใดเหมาะสมที่สุด ในการจำแนกจุดเลือดออกในสมองและจุดที่ไม่ใช่จุดเลือดออกในสมอง สำหรับการทดลองชุดนี้ จะใช้สถาปัตยกรรมของ Alexnet เนื่องจากพิจารณาประสิทธิภาพที่เหมาะสมที่สุดในการสร้างตัวจำแนก และจะมีการใช้จำนวน 8 Epoch เนื่องจากการทดลองพบว่า การสร้างตัวจำแนกด้วย 8 Epoch มีประสิทธิภาพมากที่สุด โดยมีการกำหนดค่าต่าง ๆ (parameter) คือ dropout ร้อยละ 50 stride เริ่มต้นที่ 4x4 padding เริ่มต้นที่ 0 ประมวลผลด้วย MATLAB R2018b ผลการทดลองสามารถแสดงได้ดังตารางที่ 4.1


ตารางที่ 4.1 ผลการทดลองการหาข้อมูลพื้นที่ที่สนใจ

พื้นที่ที่สนใจ	Classification Performance (Accuracy)				
	1,000	2,000	3,000	4,000	5,000
ชุดที่ 1	91.62	93.35	94.59	93.93	96.27
ชุดที่ 2	85.34	92.07	92.55	94.56	95.66
ชุดที่ 3	81.68	87.72	89.68	93.30	94.25

จากตารางที่ 4.1 แสดงให้เห็นว่าประสิทธิภาพของการจำแนกเมื่อพิจารณาค่าความถูกต้อง พบว่าข้อมูลชุดที่ 1 ให้ประสิทธิภาพสูงสุดที่ร้อยละ 96.27 ในขณะที่ข้อมูลชุดที่ 3 ให้

ประสิทธิภาพต่ำสุดที่ความถูกต้องร้อยละ 94.25 และเมื่อข้อมูลมากขึ้นยิ่งทำให้มีประสิทธิภาพดียิ่งขึ้น จากผลการทดลองสามารถสรุปได้ดังนี้ 1) ชุดข้อมูลภาพชุดที่ 1 ซึ่งเป็นพื้นที่ที่สนใจและมีพื้นที่รอบข้างนั้นให้ประสิทธิภาพสูงสุด แสดงให้เห็นว่าการพิจารณาลักษณะของ CMB นั้นจะพิจารณาจากทั้งจุดสนใจและพื้นที่รอบข้าง เนื่องจากจะให้ข้อมูลอันมีความจำเป็นได้ดีกว่ามีเฉพาะภาพพื้นที่ที่สนใจเท่านั้น 2) จำนวนข้อมูลยังมีจำนวนมากจะช่วยให้ตัวจำแนกมีการเรียนรู้ และรู้จักถึงข้อมูล และมีตัวอย่างข้อมูลให้เรียนรู้ได้มากขึ้น ทำให้มีประสิทธิภาพของการจำแนกนั้นดีขึ้น

ประสิทธิภาพของการจำแนกจากตารางที่ 4.1 สามารถแสดงเป็นกราฟเส้น ดังภาพที่ 4.3 โดยแกน x คือ จำนวนข้อมูลที่ใช้ในขั้นตอนการสร้างตัวจำแนก และแกน y คือ ประสิทธิภาพที่ได้ คือ ความถูกต้อง (Accuracy) จากกราฟแสดงให้เห็นว่า ชุดข้อมูลชุดที่ 1 ให้ประสิทธิภาพสูงที่สุด



ภาพที่ 4.3 กราฟแสดงประสิทธิภาพของการจำแนกดังที่แสดงในตารางที่ 4.1

4.4.2 สถาปัตยกรรมของ CNN

เพื่อวิเคราะห์หาประสิทธิภาพของการจำแนกที่มีสถาปัตยกรรมของ CNN ที่แตกต่างกัน ได้แก่ 1) Alexnet 2) Googlenet 3) Resnet50 และ 4) Squeezenet ทั้งนี้มีวัตถุประสงค์เพื่อหาว่า สถาปัตยกรรมของ CNN แบบใดเหมาะสมที่สุดในการจำแนกจุดเลือดออกและจุดที่ไม่ใช่จุดเลือดออก สำหรับการทดลองชุดนี้ จะใช้ทดลองกับข้อมูลจำนวน 1,000 2,000 3,000 4,000 และ 5,000 ภาพ จากข้อมูลชุดที่ 1 พื้นที่ที่สนใจและพื้นที่รอบข้าง เนื่องจากการทดสอบพบว่าข้อมูลชุดนี้มีความเหมาะสมมากที่สุดในการสร้างตัวจำแนก และจะมีการใช้จำนวน 8 Epoch เนื่องจากการทดลองพบว่า การสร้างตัวจำแนกด้วย 8 Epoch มีประสิทธิภาพมากที่สุด ผลการทดลองแสดงได้

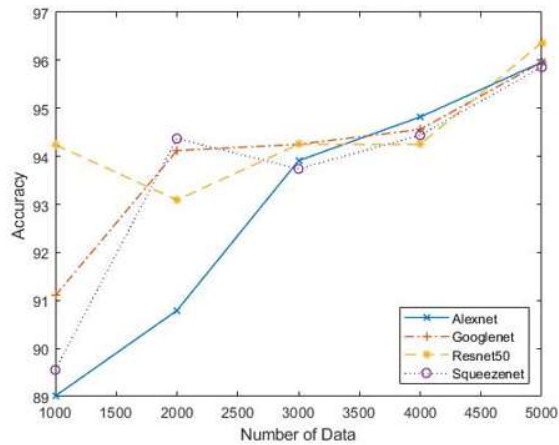
ดังตารางที่ 4.2 นอกจากนี้ยังพิจารณาถึงเวลาที่ใช้ในการทดลองด้วย ผลการทดลองแสดงได้ดังตารางที่ 4.3

ตารางที่ 4.2 ผลการทดลองการหาสถาปัตยกรรมของ CNN

สถาปัตยกรรม ของ CNN	Classification Performance (Accuracy)				
	1,000	2,000	3,000	4,000	5,000
Alexnet	89.01	90.79	93.91	94.82	95.96
Googlenet	91.10	94.12	94.25	94.56	95.96
Resnet50	94.24	93.09	94.25	94.56	96.37
Squeezenet	89.53	94.37	93.74	94.44	95.86

จากตารางที่ 4.2 แสดงถึงประสิทธิภาพของการจำแนกเมื่อพิจารณาจากความถูกต้องพบว่าสถาปัตยกรรม Resnet50 ให้ประสิทธิภาพสูงสุดที่ร้อยละ 96.37 ในขณะที่สถาปัตยกรรม Alexnet และ Googlenet ให้ประสิทธิภาพรองลงมาที่ความถูกต้องร้อยละ 95.96 ที่ชุดข้อมูล 5,000 ภาพ จากผลการทดลองสามารถสรุปได้ คือ 1) สถาปัตยกรรม Resnet50 ให้ประสิทธิภาพสูงสุด 2) จำนวนข้อมูลยิ่งมีจำนวนมากจะช่วยให้ตัวจำแนกมีการเรียนรู้ และรู้จักถึงข้อมูล และมีตัวอย่างข้อมูลให้เรียนรู้ได้มากขึ้น ทำให้มีประสิทธิภาพของการจำแนกนั้นดีขึ้น

จากประสิทธิภาพของการจำแนกในตารางที่ 4.2 สามารถแสดงในรูปของกราฟเส้นดังภาพที่ 4.4 โดยแกน x คือ จำนวนข้อมูลที่ใช้ในขั้นตอนการสร้างตัวจำแนก และแกน y คือ ประสิทธิภาพที่ได้ คือ ความถูกต้อง (Accuracy) จากกราฟแสดงให้เห็นว่า สถาปัตยกรรม Resnet50 ให้ประสิทธิภาพสูงสุด

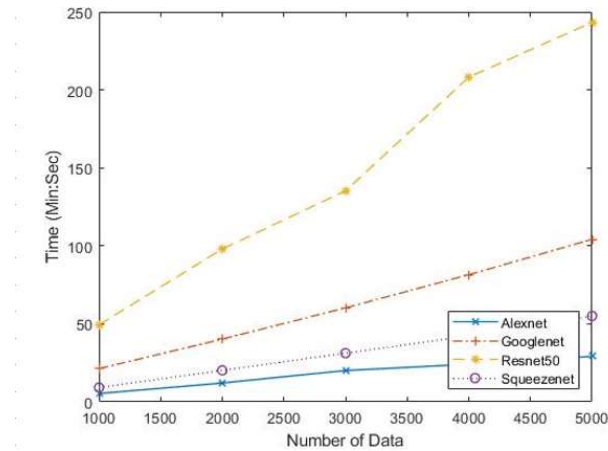


ภาพที่ 4.4 กราฟแสดงประสิทธิภาพของการจำแนกดังที่แสดงในตารางที่ 4.2

ตารางที่ 4.3 ผลการทดลองเวลาในการหาสถาปัตยกรรมของ CNN

สถาปัตยกรรม ของ CNN	Processing Time (min:sec)				
	1,000	2,000	3,000	4,000	5,000
Alexnet	5:35	12:09	20:11	24:11	29:19
Googlenet	21:30	40:24	60:25	81:51	104:17
Resnet50	49:35	98:02	135:27	208:16	243:24
Squeezenet	9:18	20:20	31:22	42:35	55:05

จากตารางที่ 4.3 แสดงให้เห็นระยะเวลาของการสร้างตัวจำแนก เมื่อพิจารณาเวลาพบว่าสถาปัตยกรรม Alexnet ที่ให้ประสิทธิภาพเป็นอันดับที่ 2 ใช้เวลาไป 29 นาที 19 วินาที ในขณะที่สถาปัตยกรรม Resnet50 ที่ให้ประสิทธิภาพสูงสุดที่ความถูกต้องร้อยละ 96.37 ได้ใช้เวลาไปสูงสุดถึง 243 นาที 24 วินาที โดยผลลัพธ์ที่ได้จากตารางที่ 4.3 แสดงเป็นกราฟเส้นได้ดังภาพที่ 4.5 โดยแกน x คือ จำนวนข้อมูลที่ใช้ในขั้นตอนการสร้างตัวจำแนก และแกน y คือ เวลา



ภาพที่ 4.5 กราฟแสดงเวลาในการสร้างตัวจำแนกดังที่แสดงในตารางที่ 4.3

จากผลการทดลองหาสถาปัตยกรรมของ CNN สามารถสรุปได้ คือ 1) สถาปัตยกรรม Alexnet ให้ประสิทธิภาพดี และใช้เวลาในการสร้างตัวจำแนกเหมาะสมที่สุด 2) จำนวนข้อมูลยิ่งมีจำนวนมากจะช่วยให้ตัวจำแนกมีการเรียนรู้ และรู้จักถึงข้อมูล และมีตัวอย่างข้อมูลให้เรียนรู้ได้มากขึ้น ทำให้มีประสิทธิภาพของการจำแนกนั้นดีขึ้น

4.4.3 จำนวน Epoch

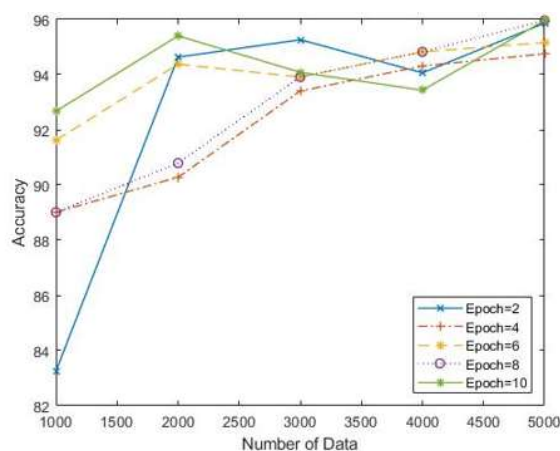
จากการวิเคราะห์หาประสิทธิภาพของการจำแนกที่มีสถาปัตยกรรมของ CNN แตกต่างกันนั้น พบว่าสถาปัตยกรรม Alexnet มีประสิทธิภาพสูงสุด และใช้เวลาในการสร้างตัวจำแนกเหมาะสม เพื่อให้วิเคราะห์หาประสิทธิภาพของการจำแนกให้มีความถูกต้องมากยิ่งขึ้น จึงได้มีการพิจารณา Epoch ที่จะใช้ในการสร้างตัวจำแนก โดยพิจารณา Epoch จำนวน 2 4 6 8 และ 10 ทั้งนี้วัตถุประสงค์เพื่อหาว่า จำนวน Epoch เท่าไรมีความเหมาะสมที่สุดในการจำแนกจุดเลือดออก และจุดที่ไม่ใช่จุดเลือดออก สำหรับการทดลองชุดนี้ได้ใช้ชุดข้อมูลที่เหมาะสมที่สุด คือ ข้อมูลชุดที่ 1 พื้นที่ที่สนใจและพื้นที่รอบข้าง และจะใช้จำนวนข้อมูล คือ 1,000 2,000 3,000 4,000 และ 5,000 ภาพ ผลการทดลองแสดงได้ดังตารางที่ 4.4

ตารางที่ 4.4 ผลการทดลองการหาข้อมูลพื้นที่ที่สนใจ

จำนวน Epoch	Classification Performance (Accuracy)				
	1000	2000	3000	4000	5000
2	83.25	94.63	95.26	94.06	95.86
4	89.01	90.28	93.40	94.31	94.75
6	91.62	94.37	93.91	94.82	95.16
8	89.01	90.79	93.91	94.82	95.96
10	92.67	95.40	94.08	93.43	95.96

จากตารางที่ 4.4 แสดงให้เห็นว่าประสิทธิภาพของการจำแนกเมื่อพิจารณา ค่า Epoch พบว่าสถาปัตยกรรม Alexnet ให้ประสิทธิภาพสูงสุด ซึ่งจากการทดสอบจำนวน Epoch พบว่าค่าความถูกต้องสูงสุดอยู่ที่ร้อยละ 95.96 โดยอยู่ที่จำนวน Epoch = 8 และ Epoch = 10 ที่ข้อมูล 5,000 ภาพ และให้ค่าความถูกต้องต่ำสุดที่ Epoch = 2 คือ ร้อยละ 83.25 จากผลการทดลองสามารถสรุปได้ คือ Epoch ที่เหมาะสมที่สุดในการสร้างตัวจำแนกด้วยสถาปัตยกรรม Alexnet และชุดข้อมูลที่ 1 คือ Epoch = 8 เนื่องจากจำนวนรอบที่น้อยกว่าย่อมใช้เวลาในการทำงานที่น้อยกว่า ซึ่งช่วยให้ประหยัดเวลาในการสร้างตัวจำแนกได้

ซึ่งภาพที่ 4.6 แสดงถึงประสิทธิภาพของการจำแนกดังที่แสดงในตารางที่ 4.4 ในรูปของกราฟเส้น โดยแกน x คือ จำนวนข้อมูลที่ใช้ในขั้นตอนการสร้างตัวจำแนก และแกน y คือ ประสิทธิภาพที่ได้ คือ ความถูกต้อง (Accuracy) จากกราฟแสดงให้เห็นว่า จำนวน Epoch = 8 และ Epoch = 10 ให้ประสิทธิภาพสูงที่สุด ดังนั้นงานวิจัยนี้เลือก Epoch = 8 ด้วยเหตุผลที่กล่าวมาแล้ว



ภาพที่ 4.6 กราฟแสดงประสิทธิภาพของการจำแนกดังที่แสดงในตารางที่ 4.4

4.5 อภิปรายผล

จากผลการทดลองที่กล่าวมาทั้งหมด สรุปได้ว่า 1) ชุดข้อมูลที่มีประสิทธิภาพมากที่สุดในการสร้างตัวจำแนก คือ ข้อมูลชุดที่ 1 พื้นที่ที่สนใจและบริเวณรอบข้าง 2) Alexnet คือ สถาปัตยกรรมของ CNN ที่ให้ความถูกต้องสูงสุด และใช้เวลาเหมาะสมที่สุด 3) จำนวน Epoch ที่เหมาะสม คือ 8 เมื่อทำการสร้างตัวจำแนกตามผลการทดลองที่กล่าวมานั้น พบว่าตัวจำแนกให้ค่าความถูกต้องถึงร้อยละ 97.86 แสดงดังภาพที่ 4.7



ภาพที่ 4.7 ผลจากการสร้างตัวจำแนก

4.6 สรุป

บทที่ 4 นี้เป็นการอธิบายถึงกระบวนการสร้างตัวจำแนกสำหรับตรวจจับจุดเลือดออกในสมอง โดยอธิบายถึง CNN ซึ่งเป็นวิธีการที่ใช้ในการสร้างตัวจำแนก นอกจากนี้มีการแสดงการกำหนดการทดลองในรูปแบบรูปภาพ เพื่อให้สามารถมองเห็นภาพการทดลองได้ชัดเจนยิ่งขึ้น ตลอดจนการวัดและการประเมินผล ซึ่งงานวิจัยนี้มีการทดลองเพื่อหาวิธีการที่ให้ได้มาซึ่งตัวจำแนกที่แม่นยำที่สุด โดยพิจารณาถึงลักษณะของชุดข้อมูลที่ใช้ สถาปัตยกรรม CNN ที่เหมาะสมที่สุด โดยพิจารณาถึงค่าความถูกต้องและระยะเวลาในการสร้างตัวจำแนก นอกจากนี้ยังพิจารณาจำนวน Epoch ที่ให้ความถูกต้องสูงที่สุดเช่นกัน และท้ายที่สุดเมื่อนำผลลัพธ์ที่ได้มาสร้างตัวจำแนกที่มีความถูกต้องถึงร้อยละ 97.86 หลังจากที่ได้ตัวจำแนกออกมาแล้วก็นำไปใช้งานต่อไป จากนั้นเป็นการระบุตำแหน่งของจุดเลือดออกในสมอง ซึ่งจะนำเสนอในบทถัดไป

บทที่ 5


การระบุตำแหน่งของจุดเลือดออกในสมอง

5.1 บทนำ

ดังที่ได้อธิบายกระบวนการในการสร้างตัวจำแนกแล้วในบทที่ 4 งานวิจัยนี้ได้ตัวจำแนกจากชุดข้อมูลที่ 1 พื้นที่ที่สนใจและบริเวณรอบข้าง ซึ่งภาพ SWI ที่ใช้ในงานวิจัยนี้ได้มาจากโรงพยาบาลในจังหวัดภูเก็ต จำนวน 1,338 ภาพ แบ่งออกเป็นภาพชุดที่ใช้ในการสร้างตัวจำแนก และภาพชุดที่ใช้ในการทดสอบตัวจำแนก โดยใช้สถาปัตยกรรม CNN แบบ Alexnet และ Epoch = 8 ตัวจำแนกที่ได้มีค่าความถูกต้องร้อยละ 97.86 จากนั้นจึงนำตัวจำแนกที่ได้มาทำการตรวจจับจุดเลือดออกในสมองจากภาพ SWI จำนวน 512 ภาพ ในบทนี้อธิบายถึงผลลัพธ์ที่ได้จากการใช้ตัวจำแนกที่สร้างขึ้นเพื่อตรวจจับจุดเลือดออกในสมอง

นอกจากนี้งานวิจัยเรื่องการตรวจจับจุดเลือดออกในสมองมีการระบุตำแหน่งของจุดเลือดออกในสมองเป็นกระบวนการที่สำคัญอีกกระบวนการหนึ่ง เนื่องจากการวินิจฉัยโรคจากจุดเลือดออกในสมองมีความสัมพันธ์กับตำแหน่ง ซึ่งทำหลังจากการระบุจุดเลือดออกในสมอง งานวิจัยนี้แบ่งตำแหน่งของจุดเลือดออกในสมองเป็น 4 ส่วน คือ 1) เนื้อสมองส่วนนอก (cortical) 2) เนื้อสมองส่วนใน (subcortical) 3) สมองส่วนท้าย (cerebellum) และ 4) ก้านสมอง (brainstem) โดยกระบวนการสร้างตัวจำแนกสำหรับการตรวจจับจุดเลือดออกในสมองได้กล่าวไว้แล้วในบทที่ 4 ส่วนบทนี้กล่าวถึงกระบวนการระบุตำแหน่งของจุดเลือดออกในสมอง โดยมีการใช้วิธีการจับคู่ภาพที่มีรูปร่างเหมือนกัน (shape matching) ซึ่งเป็นวิธีหนึ่งในกระบวนการประมวลผลภาพ (image processing) การจับคู่ภาพที่มีรูปร่างเหมือนกัน เป็นการเปรียบเทียบรูปภาพโดยใช้พิกเซลต่อพิกเซล หากสีของพิกเซลนั้น ๆ ของทั้ง 2 ภาพใกล้เคียงกันหรือตรงกัน ถือว่าภาพทั้ง 2 เหมือนกัน จากการจับคู่จากรูปร่าง สำหรับกระบวนการในการระบุตำแหน่งของจุดเลือดออกในสมองแสดงดังภาพที่ 5.1

โดยขั้นตอนในการระบุตำแหน่งของจุดเลือดออกในสมองประกอบด้วย 3 ขั้นตอน คือ 1) การปรับขนาดของภาพทั้งหมด (Resize) โดยขนาดจะเลือกจากภาพที่มีพื้นที่ส่วนสมองใหญ่ที่สุด แล้วจึงปรับขนาดของสมองในภาพอื่น ๆ ให้มีขนาดเท่ากันทั้งชุดข้อมูลนั้น ๆ 2) การจับคู่ขอบของสมอง (Border Matching) เพื่อตรวจสอบว่าภาพสมองนั้น ๆ เป็นขอบสมองของส่วนไหน 3) การจับคู่ของพื้นที่ (Area Matching) เป็นการตรวจสอบเพื่อหาว่าจุด CMB ที่จับได้นั้นอยู่ในส่วนไหนของสมอง โดยการจับคู่ทั้งหมดนี้จะต้องมีภาพต้นแบบ (Prototype) เพื่อใช้ในการจับคู่




ภาพที่ 5.1 ขั้นตอนการระบุตำแหน่งจุดเลือดออกในสมอง

ซึ่งบทนี้อธิบายถึงการระบุตำแหน่งของจุดเลือดออกในสมองที่จับโดยตัวต้นแบบที่สร้างขึ้น โดยกล่าวถึงกระบวนการในการจับคู่ภาพที่มีรูปร่างเหมือนกัน ซึ่งแบ่งตำแหน่งของจุดเลือดออกในสมองเป็น 4 ส่วน คือ 1) เนื้อสมองส่วนนอก (cortical) 2) เนื้อสมองส่วนใน (subcortical) 3) สมองส่วนท้าย (cerebellum) และ 4) ก้านสมอง (brainstem) นอกจากนี้มีการอธิบายถึงวิธีการปรับขนาดของภาพ ซึ่งจะต้องปรับทุก ๆ ภาพ จากนั้นเป็นการประเมินผลในการตรวจจับจุดเลือดออกในสมองด้วยตัวจำแนกที่สร้างได้ และการประเมินผลการระบุตำแหน่งของจุดเลือดออกในสมอง ซึ่งการประเมินผลการตรวจจับจุดเลือดออกในสมองใช้ค่า Accuracy และ Sensitivity ซึ่งคำนวณได้จาก Confusion Matrix ส่วนการประเมินผลการระบุตำแหน่งของจุดเลือดออกในสมองใช้การเปรียบเทียบผลลัพธ์ที่ได้กับการ label จากแพทย์ด้านประสาทวิทยา จากนั้นเป็นการอธิบายผลลัพธ์ที่ได้จากการตรวจจับจุดเลือดออกในสมอง และการระบุตำแหน่ง


5.2 กระบวนการจับคู่ภาพที่มีรูปร่างเหมือนกัน

ดังที่กล่าวมาแล้วข้างต้นถึงกระบวนการจับคู่ภาพที่มีรูปร่างเหมือนกัน (Shape Matching) เป็นกระบวนการที่ทำหลังจากใช้ตัวจำแนกที่สร้างขึ้น โดยเมื่อมีการจับจุดเลือดออกในสมองโดยใช้ตัวจำแนกที่สร้างขึ้นมาแล้วจากชุดข้อมูลที่ 1 พื้นที่ที่สนใจและบริเวณรอบข้าง และใช้สถาปัตยกรรม CNN แบบ Alexnet และ Epoch = 8 กระบวนการถัดมา คือ การระบุตำแหน่งของจุดเลือดออกในสมอง ซึ่งมีการแบ่งตำแหน่งของจุดเลือดออกในสมองเป็น 4 ส่วน คือ 1) เนื้อสมองส่วนนอก (cortical) 2) เนื้อสมองส่วนใน (subcortical) 3) สมองส่วนท้าย (cerebellum) และ 4) ก้านสมอง (brainstem) ส่วนต่าง ๆ ของสมองแสดงดังภาพที่ 5.2 โดยสีน้ำเงิน คือ เนื้อสมองส่วนนอก สีเขียว คือ เนื้อสมองส่วนใน สีเหลือง คือ สมองส่วนท้าย และสีแดง คือ ก้านสมอง



ภาพที่ 5.2 ตำแหน่งของส่วนของสมองบนภาพ SWI

โดยกระบวนการนี้เริ่มจากการใช้กระบวนการจับคู่ภาพที่มีรูปร่างเหมือนกัน โดยภาพ SWI จะเข้าสู่กระบวนการนี้โดยมีการปรับขนาด (resize) ของภาพทั้งหมดก่อน โดยมีการหาสเกลของรูปก่อนว่า 1 เซนติเมตรเท่ากับกี่พิกเซล ตัวอย่างแสดงดังภาพที่ 5.3 ซึ่งการปรับขนาดจะทำตามภาพที่มีขนาดของสมองใหญ่ที่สุดในภาพชุดนั้น ๆ เช่น ชุดรูปสมองของนาย ก มีจำนวน 55 รูป เมื่อโปรแกรมทำการวัดความกว้างของรูปทั้งหมดแล้ว พบว่ารูปที่ 40 กว้างมากที่สุด โปรแกรมก็จะทำการปรับขนาดให้รูปอื่นๆ กว้างเท่ากับรูปที่ 40 เป็นต้น ในที่นี้ต้องปรับขนาดภาพต้นแบบด้วย ขั้นตอนนี้ทำบนภาพขาวดำ (binary image)



ภาพที่ 5.3 การหาสเกลของรูป

จากภาพที่ 5.3 กำหนดให้รูปตัวอย่างมีขนาดจริง กว้าง (O_x) 20 เซนติเมตร สูง (O_y) 22 เซนติเมตร และขนาดของรูปเป็นกว้าง (R_x) 696 พิกเซล สูง (R_y) 768 พิกเซล ดังนั้น

$$\begin{aligned} \text{ความกว้าง 1 เซนติเมตร} &= R_x / O_x \\ &= 696/20 \\ &= 34.8 \text{ พิกเซล} \end{aligned}$$

$$\begin{aligned} \text{ความสูง 1 เซนติเมตร} &= R_y / O_y \\ &= 768/22 \\ &= 34.9 \text{ พิกเซล} \end{aligned}$$

จึงได้ 1 เซนติเมตรประมาณ 34.85 พิกเซล

จากการคำนวณข้างต้นจึงสามารถนำมาใช้ในการหาขนาดเส้นผ่านศูนย์กลางของจุดตามที่ต้องการได้ โดยงานวิจัยนี้ทำการตรวจจับจุดเลือดออกในสมองที่มีขนาดเส้นผ่านศูนย์กลาง 2-10 มิลลิเมตร ดังนั้นจะได้


$$\begin{aligned} \text{รัศมี 1 มิลลิเมตร} &= \text{ขนาด 1 พิกเซลในหน่วยเซนติเมตร}/10 \\ &= 34.85/10 \\ &= 3.485 \text{ พิกเซล} \end{aligned}$$

$$\begin{aligned} \text{รัศมี 5 มิลลิเมตร} &= 3.485 * 5 \\ &= 17.425 \text{ พิกเซล} \end{aligned}$$

จึงสรุปได้ว่าในงานวิจัยนี้ทำการจับจุดเลือดออกในสมองที่มีรัศมี 3.5–17.5 พิกเซล

เมื่อปรับขนาดของสมองแล้ว ขั้นตอนถัดไป คือ การตรวจสอบว่าขอบตรงกับภาพต้นแบบขอบสมองภาพใดมากที่สุด (Border Matching) โดยใช้ภาพต้นแบบแสดงดังภาพที่ 5.4 โดยวัตถุประสงค์ของการตรวจสอบขอบของสมองนั้น ๆ จะตรวจสอบพื้นที่ของสมอง เพื่อดูว่าจะใช้ภาพต้นแบบส่วนของสมองส่วนใด

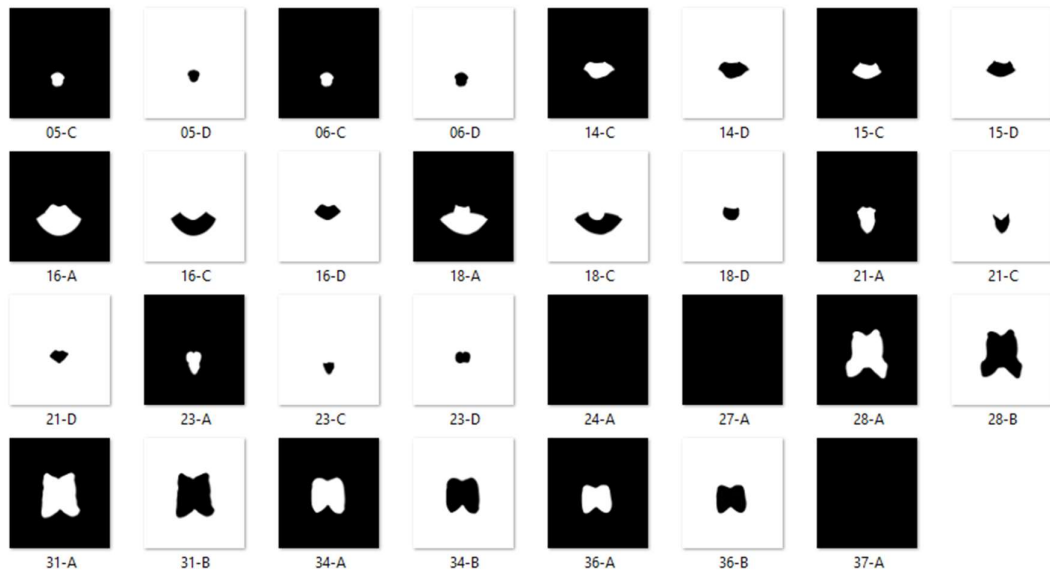
ส่วนต่าง ๆ ของสมองแสดงดังภาพที่ 5.4 โดยส่วนของก้านสมองแสดงดังภาพ 05 06 14 15 และ 23 ส่วนของสมองส่วนท้าย แสดงดังภาพ 16 18 21 และ 23 นอกจากนี้ภาพ 24 27 28 31 34 36 และ 37 เป็นภาพต้นแบบของการจับขอบสมองส่วนเนื้อสมองส่วนในและส่วนนอก



ภาพที่ 5.4 ภาพต้นแบบในการจับขอบของสมอง

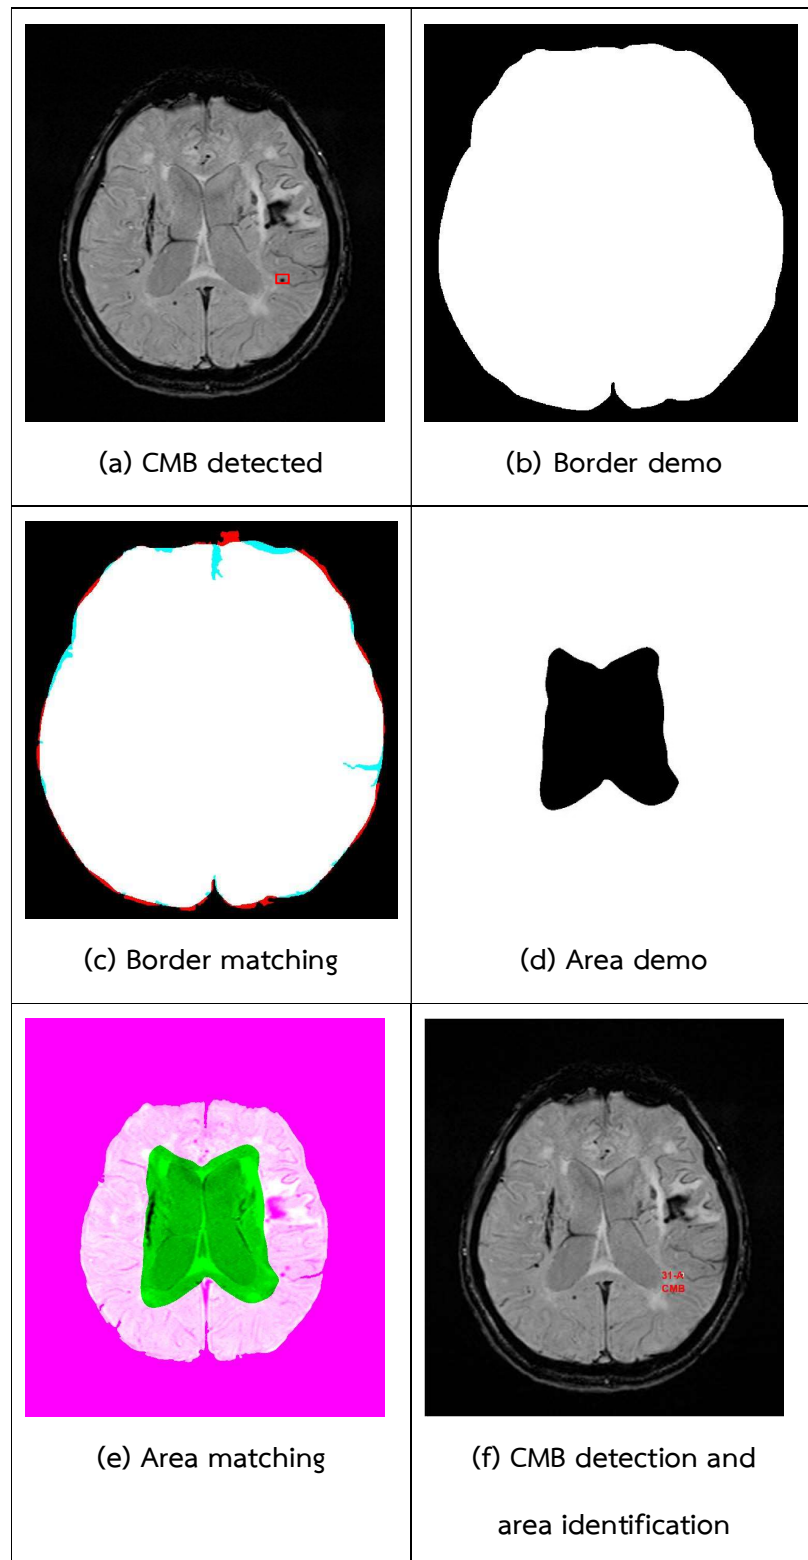
เมื่อตรวจสอบขอบของสมองแล้ว ระบบจะทำการตรวจสอบพื้นที่ของสมองโดยใช้ภาพต้นแบบชุดที่ 2 (Area Matching) โดยใช้ภาพต้นแบบจำนวน 31 ภาพ ดังภาพต้นแบบในภาพที่ 5.5 โดยมีวัตถุประสงค์เพื่อหาพื้นที่ของสมอง เมื่อหาพื้นที่ของสมองได้เรียบร้อยแล้ว หลังจากนั้น จะทำการตรวจจับว่าจุด CMB ที่ตรวจจับได้นั้นอยู่ในพื้นที่ใดของสมอง โดยใช้ Area Extraction และสุดท้ายจุด CMB และพื้นที่ของ CMB นั้น จะนำมาตรวจสอบว่าเป็นจุดเดียวกันหรือไม่

จากภาพต้นแบบในการจับพื้นที่ของสมอง ชื่อของภาพส่วนที่เป็นตัวเลขจะสัมพันธ์กับภาพต้นแบบในการจับขอบของสมอง ส่วนตัวอักษรนั้น จะแสดงตำแหน่งของจุดเลือดออกในสมอง โดย A คือ เนื้อสมองส่วนนอก B คือ เนื้อสมองส่วนใน C คือ สมองส่วนท้าย และ D คือ ก้านสมอง

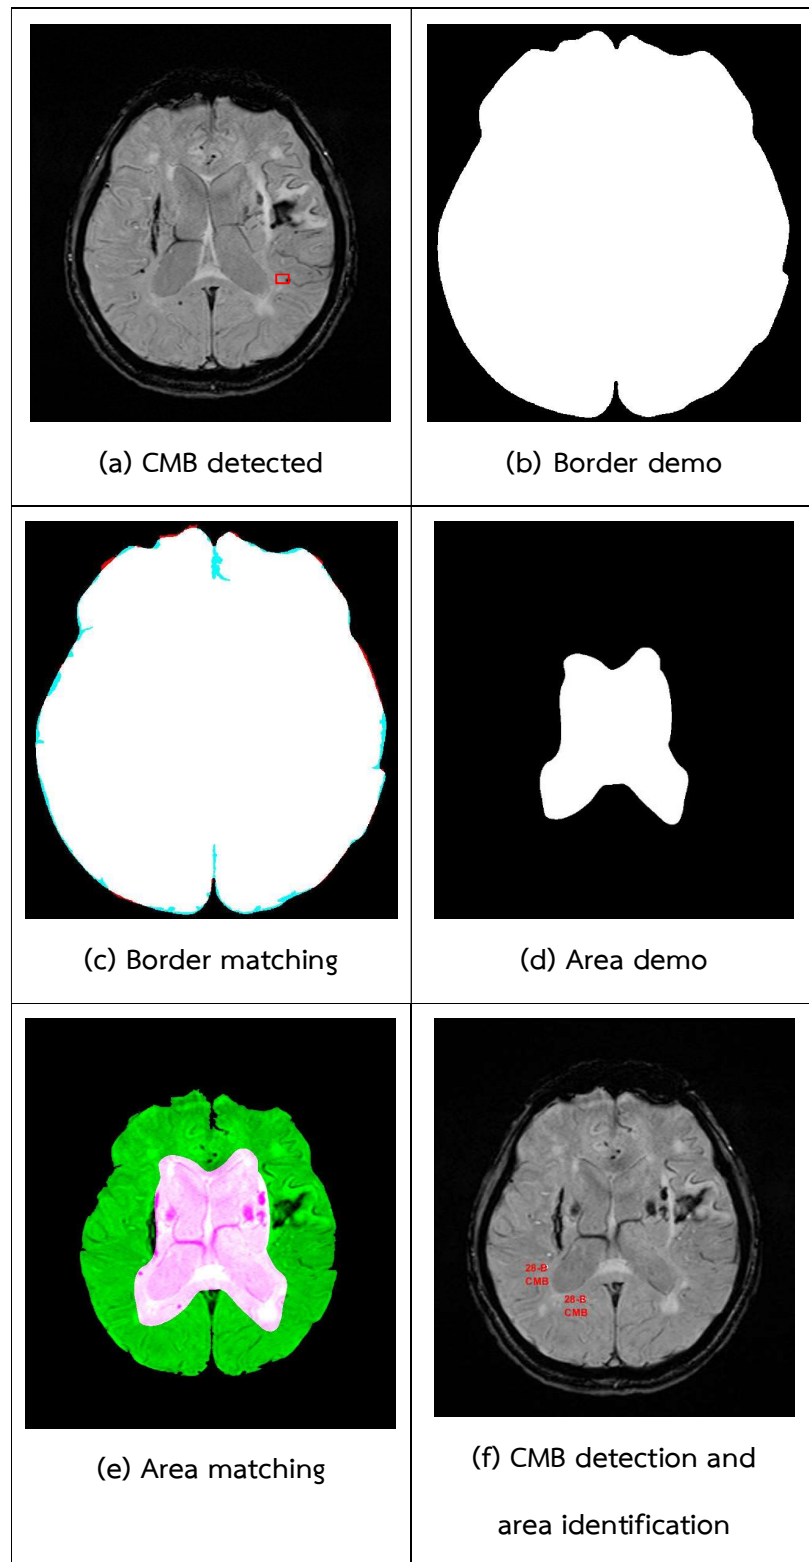


ภาพที่ 5.5 ภาพต้นแบบในการจับพื้นที่ของสมอง

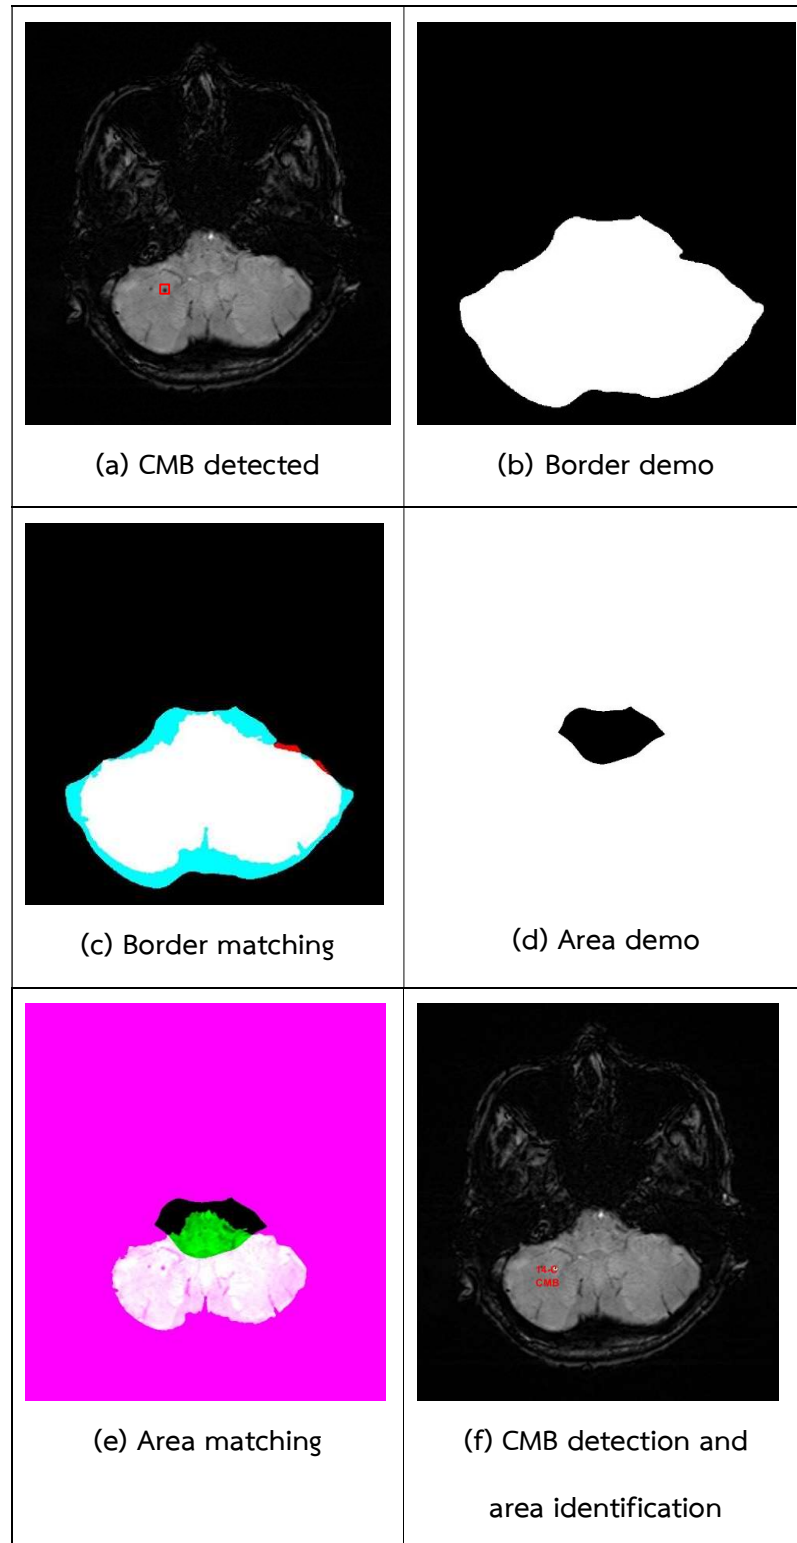
ตัวอย่างของการทำ shape matching ส่วนต่าง ๆ ของสมองแสดงดังภาพที่ 5.6-5.9 โดยแสดงตัวอย่างผลลัพธ์จากการระบุตำแหน่งในเนื้อสมองส่วนนอก เนื้อสมองส่วนใน สมองส่วนท้าย และก้านสมอง ตามลำดับ ซึ่งมีการระบุจุดเลือดออกในสมองด้วยตัวจำแนกที่สร้างขึ้น จากงานวิจัยนี้ แสดงดังภาพที่ 5.6(a) 5.7(a) 5.8(a) และ 5.9(a) จากนั้นจึงมีการปรับขนาดของสมอง แล้วทำการจับคู่ขอบของสมองด้วยภาพต้นแบบที่แสดงไว้ในภาพที่ 5.6(b) 5.7(b) 5.8(b) และ 5.9(b) เมื่อได้ภาพสมองที่จับคู่ได้กับภาพต้นแบบขอบของสมองส่วนใด ผลลัพธ์จะแสดงดังภาพที่ 5.6(c) 5.7(c) 5.8(c) และ 5.9(c) หลังจากนั้นจึงทำการจับคู่ส่วนของสมอง โดยภาพต้นแบบแสดงดังภาพที่ 5.6(d) 5.7(d) 5.8(d) และ 5.9(d) ผลลัพธ์จากการจับคู่แสดงดังภาพที่ 5.6(e) 5.7(e) 5.8(e) และ 5.9(e) ซึ่งภาพผลลัพธ์จะแสดงเป็นสีชมพู เมื่อทำการจับคู่ครบแล้ว จึงแสดงผลออกมา ดังภาพที่ 5.6(f) 5.7(f) 5.8(f) และ 5.9(f) ซึ่งตัวอักษรด้านหลังจะบอกตำแหน่งของจุดเลือดออกในสมอง



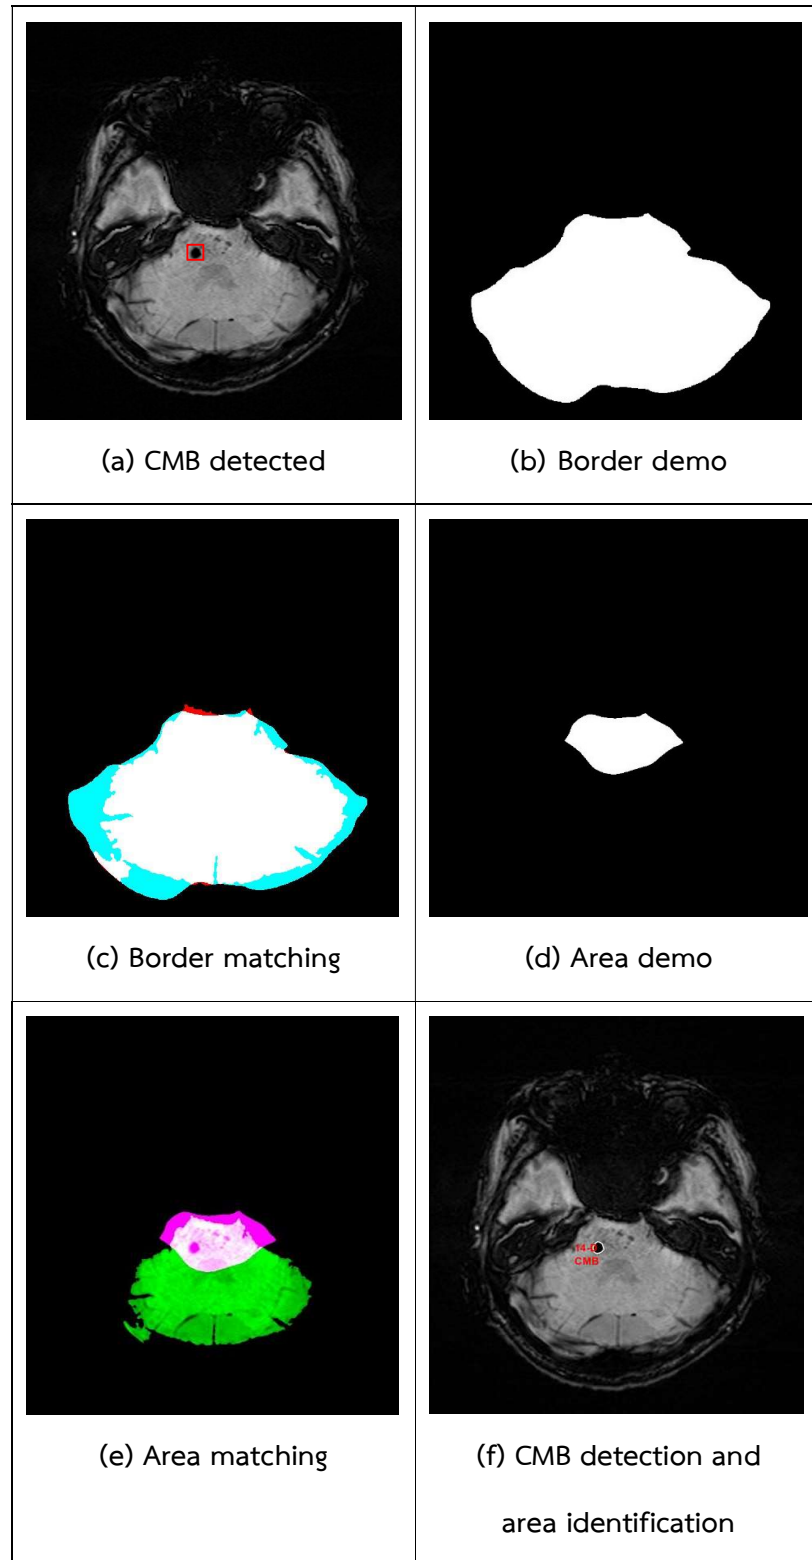
ภาพที่ 5.6 ตัวอย่างผลลัพธ์จากการระบุตำแหน่งของเนื้อสมองส่วนนอก



ภาพที่ 5.7 ตัวอย่างผลลัพธ์จากการระบุตำแหน่งของเนื้อสมองส่วนใน




ภาพที่ 5.8 ตัวอย่างผลลัพธ์จากการระบุตำแหน่งของสมองส่วนท้าย



ภาพที่ 5.9 ตัวอย่างผลลัพธ์จากการระบุตำแหน่งของก้อนสมอง

นอกจากนี้บางภาพมีจุดเลือดออกในสมองอยู่หลายตำแหน่ง ดังตัวอย่างในภาพที่ 5.10 โดยมี 2 จุดที่อยู่ในเนื้อสมองส่วนใน และ 1 จุดอยู่ในเนื้อสมองส่วนนอก



ภาพที่ 5.10 ตัวอย่างผลลัพธ์ที่ได้จากการระบุตำแหน่งของจุดเลือดออกในสมอง

จากกระบวนการทั้งหมดที่กล่าวมาแล้ว การระบุตำแหน่งของจุดเลือดออกในสมอง ด้วยกระบวนการ shape matching แสดงได้ดังภาพที่ 5.11 โดยกระบวนการในการระบุตำแหน่งของจุดเลือดออกในสมอง แบ่งเป็น 2 กระบวนการใหญ่ ๆ คือ 1) กระบวนการในการจับคู่กับสไลด์ต้นแบบ และ 2) กระบวนการในการจับโซนต้นแบบ บรรทัดที่ 1-5 เป็นการกำหนดค่าให้ตัวแปรที่เกี่ยวข้องกับภาพต้นแบบ และปรับขนาดของภาพให้มีขนาดเท่ากับภาพสมองที่มีการปรับขนาดมาก่อนแล้ว ซึ่งเป็นขนาดของสไลด์ที่แสดงสมองใหญ่ที่สุด จากนั้นทำการเรียกภาพต้นแบบของโซนต่าง ๆ บนสมองมาเก็บไว้ในตัวแปร image_demo_zone ดังบรรทัดที่ 6-9

จากนั้นเข้าสู่กระบวนการที่ 1 คือ การจับคู่กับสไลด์ต้นแบบ ดังบรรทัดที่ 10-28 เริ่มจากการดึงจำนวนของภาพต้นแบบทั้งหมด จากนั้นการตรวจสอบจำนวนพิกเซลบนแกน X และ

แกน Y โดยทำการเช็คค่าพิกเซล ณ ตำแหน่งเดียวกับของทั้ง 2 ภาพมีค่าเท่ากันหรือไม่ ถ้าเท่ากันก็ถือว่าจับคู่กันได้ โดยเก็บจำนวนของพิกเซลไว้ในตัวแปร matched_data ถ้าหากจับคู่กันไม่ได้จะเก็บไว้ในตัวแปร notmatched_data จากนั้นบรรทัดที่ 22 จึงนำจำนวนพิกเซลที่จับคู่กันได้มาคิดเป็นจำนวนร้อยละ ส่วนบรรทัดที่ 24-27 เป็นการเก็บค่าร้อยละที่มากที่สุดไว้ในตัวแปร percentMax และเก็บค่ารูปแบบที่จับคู่กันไว้ในตัวแปร imageMatch โดยไปใช้ต่อในกระบวนการที่ 2

กระบวนการที่ 2 เป็นการจับคู่ระหว่างสไลด์สมอง ณ ปัจจุบันกับภาพต้นแบบของโซนต่าง ๆ บนสมองโดยตรวจสอบว่าพิกเซล 2 ตัวแรกที่ชื่อภาพต้นแบบนี้เหมือนกับพิกเซล 2 ตัวของรูปสมองหรือไม่ ถ้าใช่ก็ทำการตรวจสอบต่อว่าจุดศูนย์กลางของโซนที่มีจุดเลือดออกในสมองบนภาพต้นแบบเป็นสีดำหรือไม่ ถ้าใช่จึงถือว่าภาพทั้งคู่สามารถจับคู่กันได้ ซึ่งโซนของสมองจะดูจากชื่อของไฟล์ที่จับคู่ได้

อัลกอริทึม 5.1 Identification the location with shape matching

```

1:  for mPic = 1 to numberOfDemo do
2:      imagename      = The folder of brain demo
3:      image_demo     = Image name of brain demo
4:      image_demo     = Resize image to the biggest size of each head
5:  end for
6:  for mzPic = 1 to numberOfDemoZone do
7:      imagename = The folder of brain demo zone
8:      image_demo_zone = Image name of brain demo zone
9:  end for
10: for iPic = 1 to All image do
11:  for mPic = 1 to numberOfDemo do
12:      for a = 1 to numberOfPixelOnAxisX do
13:          for b = 1 to numberOfPixelOnAxisY do
14:              if current_Pixel_Point_Of_Demo =
15:                  current_Pixel_Point_Of_Binary_Image then
16:                  matched_data = matched_data + 1
17:              else
18:                  notmatched_data = notmatched_data + 1

```

ภาพที่ 5.11 อัลกอริทึมในการระบุตำแหน่งให้จุดเลือดออกในสมอง

```

19:             end if
20:         end for
21:     end for
22:     currentShapeMatch = ((matched_data /
23:         (matched_data + notmatched_data) ) * 100)
24:     if percentMax < currentShapeMatch then
25:         percentMax = currentShapeMatch
26:         imageMatch = mPic
27:     end if
28: end for
29: for mzPic = 1 to numberOfDemoZone do
30:     if firstTwoCharacterOf_image_demo_zone =
31:         firstTwoCharacterOf_imageMatch
32: then
33:     if centerOf_image_demo_zone = black then
34:     match_zone = theFirstToForthCharacterOf_image_demo_zone
35:     end if
36: end if
37: end for
38: end for

```

ภาพที่ 5.11 อัลกอริทึมในการระบุตำแหน่งให้จุดเลือดออกในสมอง (ต่อ)

หลังจากเสร็จสิ้นกระบวนการระบุตำแหน่งแล้ว จำเป็นต้องมีการนำโปรแกรมที่ได้มาทำการทดสอบความถูกต้องและค่าต่าง ๆ จาก Confusion Matrix โดยมีการประเมินผลลัพธ์ที่ได้จากการระบุตำแหน่งของจุดเลือดออกในสมอง ซึ่งจะอธิบายในการวัดและการประเมินผลต่อไป

5.3 การวัดและการประเมินผล

ดังที่กล่าวมาแล้วในบทที่ 4 ถึงกระบวนการสร้างตัวจำแนกสำหรับตรวจจับจุดเลือดออกในสมอง จากภาพจำนวน 1,338 ภาพ แบ่งออกเป็นภาพชุดที่ใช้ในการสร้างตัวจำแนก และภาพชุดที่ใช้ในการทดสอบตัวจำแนก โดยใช้ข้อมูลชุดที่ 1 พื้นที่ที่สนใจและบริเวณรอบข้าง ด้วยสถาปัตยกรรม CNN แบบ Alexnet และ Epoch = 8 ตัวจำแนกที่ได้มีค่าความถูกต้องร้อยละ 97.86 บทนี้กล่าวถึงกระบวนการจับคู่ภาพที่มีรูปร่างเหมือนกัน ซึ่ง 2 กระบวนการนี้ทำต่อเนื่องกัน โดยทำการตรวจจับจุดเลือดออกในสมองจากตัวจำแนกที่สร้างได้ก่อน แล้วจึงทำการระบุตำแหน่งของจุดเลือดออกในสมองที่จับได้ โดยมีการแบ่งตำแหน่งของจุดเลือดออกในสมองเป็น 4 ส่วน คือ 1) เนื้อสมองส่วนนอก (cortical) 2) เนื้อสมองส่วนใน (subcortical) 3) สมองส่วนท้าย (cerebellum) และ 4) ก้านสมอง (brainstem)

วัตถุประสงค์ของการวัดและประเมินผลการระบุตำแหน่งของจุดเลือดออกในสมองในงานวิจัยนี้ เพื่อเปรียบเทียบผลลัพธ์ที่ได้จากกระบวนการจับคู่ภาพที่มีรูปร่างเหมือนกันและการ label ของแพทย์ด้านประสาทวิทยา

ในข้อนี้ได้อธิบายถึงการวัดและการประเมินผลของการตรวจจับจุดเลือดออกในสมองจากตัวจำแนกที่สร้างได้ และประเมินการระบุตำแหน่งของจุดเลือดออกในสมองที่จับได้ โดยมีการประเมินประสิทธิภาพของตัวจำแนกได้อธิบายถึงผลที่ได้จากการสร้างตัวจำแนก และการทดสอบตัวจำแนกด้วย Confusion Matrix นอกจากนี้มีการประเมินผลการระบุตำแหน่งของจุดเลือดออกในสมองเป็นการกล่าวถึงผลลัพธ์ของการระบุตำแหน่งด้วยการเปรียบเทียบกับ label ของแพทย์ด้านประสาทวิทยา

5.3.1 ผลจากการตรวจจับจุดเลือดออกในสมองด้วยตัวจำแนก

จากสร้างตัวจำแนกสำหรับตรวจจับจุดเลือดออกในสมอง โดยใช้ข้อมูลชุดที่ 1 พื้นที่ที่สนใจและบริเวณรอบข้าง ด้วยสถาปัตยกรรม CNN แบบ Alexnet และ Epoch = 8 ซึ่งให้ค่าความถูกต้องและใช้เวลาที่เหมาะสม ผลลัพธ์ที่ได้จากการตรวจจับจุดเลือดออกในสมองที่จับด้วยตัวจำแนกนี้ ใช้ภาพในการทดสอบจำนวน 520 ภาพ จากโรงพยาบาลในจังหวัดภูเก็ต แสดงผลดังตารางที่ 5.1 โดยภาพชุดที่ 1-5 เป็นสมองที่มีจุดเลือดออกในสมอง และภาพชุดที่ 6-10 เป็นสมองที่ไม่มีจุดเลือดออกในสมอง

ตารางที่ 5.1 ผลลัพธ์ที่ได้จากการทดสอบตัวจำแนกเพื่อตรวจจับจุดเลือดออกในสมอง

ภาพชุดที่	จำนวนภาพ	TP	FP	FN	TN
1	47	2	2	0	34
2	55	2	4	0	20
3	55	3	0	0	19
4	47	5	0	0	29
5	47	3	1	1	18
6	52	0	0	0	12
7	52	0	1	0	18
8	55	0	0	0	14
9	55	0	1	0	22
10	55	0	0	0	25

โดยช่อง Slide คือ จำนวนภาพทั้งหมดของสมองหัวนั้น ๆ

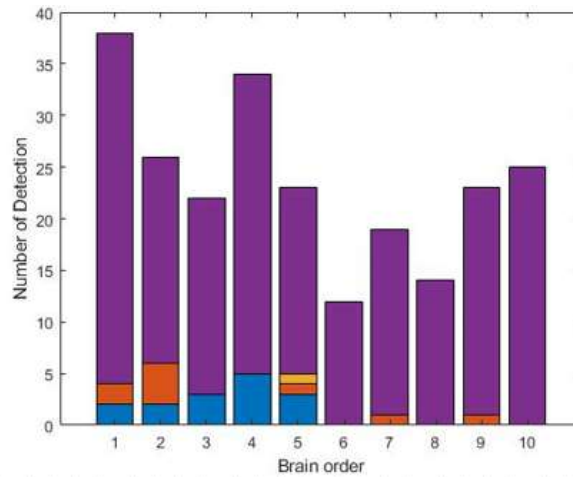
TP (True Positive) คือ จุดที่แพทย์ระบุว่าเป็นจุดเลือดออกในสมอง และตัวจำแนกจับว่าเป็นจุดเลือดออกในสมองเช่นกัน

FP (False Positive) คือ จุดที่แพทย์ระบุว่าจะไม่ใช่จุดเลือดออกในสมอง แต่ตัวจำแนกจับได้ว่าเป็นจุดเลือดออกในสมอง

FN (False Negative) คือ จุดที่แพทย์ระบุว่าเป็นจุดเลือดออกในสมอง แต่ตัวจำแนกจับว่าไม่ใช่จุดเลือดออกในสมอง

TN (True Negative) คือ จุดที่แพทย์ระบุว่าจะไม่ใช่จุดเลือดออกในสมองและตัวจำแนกทำนายว่าไม่ใช่จุดเลือดออกในสมองเช่นกัน

จากตารางที่ 5.1 ภาพชุดที่ 1-5 เป็นภาพที่มีจุดเลือดออกในสมอง ผลลัพธ์ที่ได้ก็พบจุดเลือดออกในสมอง ส่วนภาพชุดที่ 6-10 เป็นภาพที่ไม่มีจุดเลือดออกในสมอง และโปรแกรมก็ไม่สามารถจับได้ โดยผลลัพธ์ที่ได้สามารถแสดงเป็นกราฟ ดังภาพที่ 5.12



ภาพที่ 5.12 กราฟแสดงผลลัพธ์จากตารางที่ 5.1

จากภาพที่ 5.12 แกน x แสดงจำนวนของสมองที่นำมาทดสอบ แกน y คือ จำนวนของจุดที่จับได้ โดยแถบสีฟ้า คือ ค่า TP สีส้ม คือ FP สีเหลือง คือ FN และสีม่วง คือ TN เมื่อพิจารณาภาพพบว่าสมองหัวที่ 1- 5 พบจุดเลือดออกในสมอง และสมองหัวที่ 6-10 ไม่พบจุดเลือดออกในสมอง นอกจากนี้มีเพียงสมองหัวที่ 5 ที่พบค่า FN ซึ่งเป็นค่าที่หมอระบุว่าเป็นจุดเลือดออกในสมอง แต่ตัวจำแนกจับว่าไม่ใช่จุดเลือดออกในสมอง โดยค่า TP FP FN และ TN เป็นค่าที่ใช้ใน Confusion matrix ผู้วิจัยจึงแสดงค่าออกมาในรูปแบบ Confusion matrix ดังตารางที่ 5.2

ตารางที่ 5.2 Confusion matrix

		Actual class	
		CMB	Non-CMB
Predict class	CMB	15	9
	Non-CMB	1	211

จากตารางที่ 5.2 พบว่าจากจำนวนจุดทั้งหมดที่ตัวจำแนกทำนายว่าเป็นจุดเลือดออกในสมองจำนวน 24 จุด เป็นจุดเลือดออกในสมองจำนวน 15 จุด และจุดที่ไม่ใช่จุดเลือดออกในสมองจำนวน 9 จุด ส่วนจุดที่เป็นจุดเลือดออกในสมอง แต่ตัวจำแนกไม่สามารถจับได้มีจำนวน 1 จุด สุดท้ายจุดที่ไม่ใช่จุดเลือดออกในสมองและตัวจำแนกไม่ได้จับมีจำนวนถึง 211 จุด

จากตารางที่ 5.3 เป็นการแสดงผลการระบุตำแหน่งของจุดทั้งหมดที่ตัวจำแนกจับได้ โดยแยกเป็น TP และ FP ซึ่งตำแหน่งต่าง ๆ บนสมองแทนค่าดังนี้

- A คือ เนื้อสมองส่วนนอก (cortical)
- B คือ เนื้อสมองส่วนใน (subcortical)
- C คือ สมองส่วนท้าย (cerebellum)
- D คือ ก้านสมอง (brainstem)

งานวิจัยนี้พบว่าจุดเลือดออกในสมองส่วนใหญ่อยู่ในเนื้อสมองส่วนนอก ซึ่งมีจำนวน 17 จุด รองลงมา คือ ก้านสมองจำนวน 5 จุด เนื้อสมองส่วนในและสมองส่วนท้ายมีอย่างละ 1 จุด ซึ่งผลที่ได้ทั้งหมดนี้มีค่าความถูกต้องเมื่อเปรียบเทียบกับการ Label ของแพทย์ด้านประสาทวิทยา เท่ากับร้อยละ 100

5.4 อภิปรายผล

การสร้างตัวจำแนกสำหรับตรวจจับจุดเลือดออกในสมอง โดยใช้ข้อมูลชุดที่ 1 พื้นที่ที่สนใจและบริเวณรอบข้าง ด้วยสถาปัตยกรรม CNN แบบ Alexnet และ Epoch = 8 และนำตัวจำแนกมาจับจุดเลือดออกในสมอง รวมถึงการระบุจุดเลือดออกในสมอง ซึ่งแสดงให้เห็นว่าการตรวจจับจุดเลือดออกในสมองมีค่าความถูกต้องค่อนข้างสูง คือ เท่ากับร้อยละ 95.76 รวมถึงค่า sensitivity เช่นกัน แสดงให้เห็นว่าตัวจำแนกที่ได้จากงานวิจัยนี้มีประสิทธิภาพในการตรวจจับจุดเลือดออกในสมอง นอกจากนี้ในการระบุตำแหน่งของจุดเลือดออกในสมองโดยใช้กระบวนการจับคู่ภาพที่มีรูปร่างเหมือนกัน วิธีการที่ใช้ คือ การตรวจสอบพิกเซลต่อพิกเซล ผลลัพธ์ที่ได้พบว่าวิธีการตรวจสอบพิกเซลต่อพิกเซลมีประสิทธิภาพในการระบุตำแหน่งของจุดเลือดออกในสมอง เห็นได้จากค่าความถูกต้องที่มีถึงร้อยละ 100 อย่างไรก็ตามงานวิจัยนี้ทดสอบกับสมองจำนวน 10 หัว ดังนั้นในอนาคตจึงจำเป็นต้องหาภาพสมองมาทดสอบเพิ่มเติม เพื่อเป็นการยืนยันว่าวิธีการที่ใช้ในงานวิจัยนี้สามารถใช้งานได้จริงและถูกต้อง

5.5 สรุป

บทนี้เป็นการอธิบายถึงการระบุตำแหน่งของจุดเลือดออกในสมอง โดยใช้กระบวนการจับคู่ภาพที่มีรูปร่างเหมือนกัน วิธีการที่ใช้ คือ การตรวจสอบพิกเซลต่อพิกเซล นอกจากนี้มีการอธิบายการประเมินผลของการตรวจจับจุดเลือดออกในสมอง โดยใช้ Confusion Matrix และการระบุตำแหน่งของจุดเลือดออกในสมอง ซึ่งการเปรียบเทียบกับผลการ Label ของแพทย์ด้านประสาทวิทยา ส่วนผลลัพธ์ที่ได้ของทั้ง 2 กระบวนการมีค่าความถูกต้องมากกว่าร้อยละ 95 แสดงให้เห็นว่าตัวจำแนกที่ได้จากงานวิจัยนี้มีประสิทธิภาพในการตรวจจับจุดเลือดออกในสมอง และวิธีการตรวจสอบพิกเซลต่อพิกเซลมีประสิทธิภาพในการระบุตำแหน่งของจุดเลือดออกในสมอง

บทที่ 6

สรุปและข้อเสนอแนะ

บทสรุปของงานวิจัยการตรวจจับและระบุตำแหน่งของจุดเลือดออกในสมอง จากภาพเอกซเรย์คลื่นแม่เหล็กไฟฟ้าแบบการถ่ายภาพแบบถ่วงน้ำหนักตามความอ่อนไหว โดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ ได้อธิบายไว้แล้วในบทนี้ โดยมีหัวข้อดังนี้ 6.1 เป็นการสรุปผลการทดลองที่ได้ 6.2 อธิบายถึงข้อค้นพบหลักและสิ่งที่ค้นพบใหม่ในงานวิจัย ส่วนข้อ 6.3 กล่าวถึงปัญหาและอุปสรรค ข้อ 6.4 ลักษณะของการนำไปใช้ประโยชน์ และสุดท้ายงานในอนาคตได้กล่าวไว้ในข้อ 6.5

6.1 สรุปผลการทดลอง

งานวิจัยนี้แบ่งออกเป็น 2 กระบวนการใหญ่ ๆ คือ การตรวจจับจุดเลือดออกในสมอง และการระบุตำแหน่งของจุดเลือดออกในสมอง ซึ่งในกระบวนการตรวจจับจุดเลือดออกในสมองได้มีการสร้างตัวจำแนกจากโครงข่ายประสาทเทียมแบบสังวัตนาการ โดยมีการเปรียบเทียบ 4 วิธีการ คือ 1) Alexnet 2) Googlenet 3) Resnet50 และ 4) Squeezenet กับ 3 ชุดข้อมูล คือ 1) รูปดั้งเดิมที่ตัดได้ 2) รูปที่ปรับขนาดพื้นที่รอบข้างให้เล็กลง และ 3) รูปที่ตัดเอาแต่ส่วนจุด ส่วนการประเมินผลของทั้ง 2 กระบวนการมีการใช้ค่าจาก confusion matrix มาคำนวณ ได้แก่ ค่า accuracy และ ค่า sensitivity นอกจากนี้ยังมีการวิเคราะห์จากกราฟเพื่อดูประสิทธิภาพของตัวจำแนก โดยมีการเปรียบเทียบทั้งจำนวนของข้อมูล และจำนวนรอบในการประมวลผล CNN โดยสรุปผลการทดลองแบ่งได้เป็น 2 กระบวนการ คือ 1) การตรวจจับจุดเลือดออกในสมอง และ 2) การระบุตำแหน่งของจุดเลือดออกในสมอง

สำหรับกระบวนการแรก คือ การตรวจจับจุดเลือดออกในสมอง โดยใช้กระบวนการทางโครงข่ายประสาทเทียมแบบสังวัตนาการ อันดับแรกทำการตัดภาพจุดที่น่าสนใจ (ROI) จากภาพ

สมองที่ได้ จากนั้นทำการนำจุดที่ได้ทั้งหมดมาแยกเป็น 2 กลุ่ม คือ จุดที่เป็นจุดเลือดออกในสมอง (CMB) และจุดที่ไม่ใช่จุดเลือดออกในสมอง (Non-CMB) โดยเปรียบเทียบกับจุดทั้งหมดที่แพทย์ทางด้านประสาทวิทยาเป็นผู้ระบุ จุดทั้งหมดที่แยกแล้วทางผู้วิจัยได้นำไปใช้ในการสร้างตัวจำแนก (training data) โดยเลือกใช้วิธีการ Alexnet ซึ่งเป็นวิธีการที่ให้ความแม่นยำสูงที่สุดจากทั้ง 4 วิธี จากนั้นจึงนำตัวจำแนกที่ได้ไปใช้ในการตรวจจับจุดเลือดออกในสมอง จากนั้นเมื่อได้จุดเลือดออกในสมองก็นำจุดที่ได้มาตรวจสอบว่าจุดที่จับได้ในแต่ละสไลด์นั้นเป็นจุดเดียวกันหรือไม่ (Overlapping) โดยใช้วิธีวัดค่าของจุดศูนย์กลาง (Centroid) เมื่อเสร็จสิ้นกระบวนการนี้ ได้มีการประเมินผลประสิทธิภาพของตัวจำแนก โดยได้ค่า accuracy และ sensitivity ค่อนข้างสูง แล้วจึงนำจุดที่จับได้ทั้งหมดไปเข้าสู่กระบวนการระบุตำแหน่ง

ในกระบวนการระบุตำแหน่ง ผู้วิจัยได้แบ่งตำแหน่งของจุดเลือดออกในสมองเป็น 4 ส่วนตามแพทย์เฉพาะทางทางด้านศัลยกรรมประสาทและสมอง ได้แก่ 1) เนื้อสมองส่วนนอก (cortical) 2) เนื้อสมองส่วนใน (subcortical) 3) สมองส่วนท้าย (cerebellum) และ 4) ก้านสมอง (brainstem) โดยการระบุตำแหน่งนี้มีความสัมพันธ์กับโรค กล่าวคือหากมีจุดเลือดออกในสมองจำนวนมากอยู่ในตำแหน่งเนื้อสมองส่วนนอก แสดงว่าผู้ป่วยมีภาวะอัลไซเมอร์ได้ ส่วนหากมีมากในเนื้อสมองส่วนใน แสดงว่าผู้ป่วยเป็นความดันโลหิตสูงได้ ในกระบวนการนี้ใช้กระบวนการการจับคู่ภาพ (Shape matching) โดยใช้การเทียบพิกเซลต่อพิกเซล ซึ่งผลลัพธ์ที่ได้จากการทดสอบกับภาพสมองจากผู้ป่วย 10 คน พบว่ามีความแม่นยำถึงร้อยละ 100

6.2 ข้อค้นพบหลักและสิ่งที่ค้นพบใหม่

หัวข้อนี้เป็นการอธิบายถึงสิ่งที่พบหลักและสิ่งที่ค้นพบจากงานวิจัยนี้ ซึ่งงานวิจัยนี้ได้ อธิบายถึงคำตอบที่ได้จากการทดลอง เพื่อตอบคำถามงานวิจัย ดังที่ระบุไว้ในบทที่ 1

“จุดและตำแหน่งของจุดเลือดออกในสมอง (CMB) สามารถตรวจจับได้จากภาพถ่ายแม่เหล็กไฟฟ้าได้โดยใช้การเรียนรู้ของเครื่องได้หรือไม่”

จากคำถามงานวิจัยข้างต้นจำเป็นต้องมีคำถามย่อยเพื่อใช้ในการหาคำตอบ ในหัวข้อนี้ผู้วิจัยได้อธิบายถึงคำตอบของคำถามย่อยทั้ง 4 ข้อ ดังคำถามที่ระบุไว้ในบทที่ 1

1) การหากระบวนการประมวลผลภาพที่เหมาะสมในการตรวจจับพื้นที่ที่สนใจ (Region of Interest)

การตรวจจับพื้นที่ที่สนใจเป็นกระบวนการที่ทำเพื่อจับจุดที่คาดว่าจะจุดเลือดออกในสมองทั้งหมด จากนั้นนำจุดที่ได้มาแยกกลุ่มเป็นกลุ่มของจุดเลือดออกในสมอง และจุดที่ไม่ใช่จุดเลือดออกในสมอง จากนั้นจึงนำจุดทั้งหมดเข้าสู่กระบวนการคอนโวลูชัน เพื่อสร้างตัวจำแนก ดังนั้นกระบวนการตรวจจับจุดที่น่าสนใจจึงเป็นกระบวนการที่มีความสำคัญ โดยภาพที่นำมาใช้ในงานวิจัยนี้มาจากโรงพยาบาลในจังหวัดภูเก็ต วิธีการทำงานวิจัยนี้ใช้ คือ การใช้ค่าคงที่ หรือ Thresholding ซึ่งเป็นกระบวนการทาง image processing ที่ใช้ถึง 3 ค่า ดังที่กล่าวไว้แล้วในบทที่ 3 นอกจากนี้มีการใช้คุณสมบัติต่าง ๆ ของวงกลม เช่น รัศมี ค่าความกลม จุดเยื้องศูนย์ เป็นต้น เพื่อนำมาคัดจุดที่มีคุณสมบัติไม่เข้าเกณฑ์ออกไป จุดที่ได้ทั้งหมดจะได้มีคุณสมบัติใกล้เคียงจุดเลือดออกในสมองมากที่สุด ซึ่งรายละเอียดทั้งหมดกล่าวไว้แล้วในบทที่ 3

2) การหาการประมวลผลด้วยเครื่อง โดยใช้การเรียนรู้เชิงลึกที่เหมาะสม ในการสร้างตัวจำแนก เพื่อตรวจจับจุดเลือดออกในสมอง

หลังจากเสร็จสิ้นการตรวจจับพื้นที่ที่สนใจแล้ว ดังที่กล่าวไว้ในข้อที่ 1 จุดทั้งหมดถูกนำเข้าสู่กระบวนการสร้างตัวจำแนก ซึ่งการสร้างตัวจำแนกนี้นักวิจัยต้องหาวิธีในคอนโวลูชันที่สามารถสร้างตัวจำแนกได้แม่นยำที่สุด ในงานวิจัยนี้ใช้ 4 วิธี คือ 1) Alexnet 2) GoogleNet 3) Resnet50 และ 4) Squeezenet ซึ่งนักวิจัยได้ทำการเปรียบเทียบทั้งจำนวนรอบที่ทดสอบ ซึ่งทดลอง 2 4 6 8 และ 10 รอบ และจำนวนข้อมูลที่ใช้ในการทดสอบ ทั้ง 1,000 2,000 3,000 4,000 และ 5,000 ภาพ ผลการทดลองที่ได้แสดงให้เห็นว่าการประมวลผลข้อมูล (Training) 8 รอบให้ผลลัพธ์ออกมาแม่นยำที่สุด ส่วนข้อมูลที่ใช้ใช้นั้นยิ่งมากยิ่งขึ้น ผู้วิจัยจึงเลือกใช้ข้อมูลที่มีทั้งหมดมาสร้างตัวจำแนก ส่วนวิธีการที่ใช้นั้น Alexnet ให้ผลลัพธ์ออกมาแม่นยำ และใช้เวลาในการสร้างตัวจำแนกเหมาะสมที่สุด ซึ่งรายละเอียดทั้งหมดกล่าวไว้แล้วในบทที่ 4

3) การหากระบวนการประมวลผลภาพที่เหมาะสมในการระบุตำแหน่งของจุดเลือดออกในสมอง

การระบุตำแหน่งของจุดเลือดออกในสมองเป็นกระบวนการที่ทำหลังจากมีการตรวจจับจุดเลือดออกในสมองด้วยตัวจำแนกที่สร้างได้แล้ว เนื่องจากตำแหน่งของการเกิดจุดเลือดออกในสมองสัมพันธ์กับอาการของโรค สำหรับวิธีการที่ใช้ในการระบุตำแหน่ง คือ การจับคู่พิกเซลของรูป (Shape Matching) โดยทำการจับคู่ทีละพิกเซลแล้วตรวจสอบว่าพิกเซลที่จับคู่กันนั้นเหมือนหรือใกล้เคียงกันเพียงใด จากนั้นก็เลื่อนไปที่ละพิกเซล การจับคู่รูปนี้ทำการจับรูปใหญ่

เพื่อดูก่อนว่าขอบของสมองรูปนั้นสามารถจับคู่ได้กับรูปต้นแบบรูปไหน แล้วจึงจับคู่ภาพต้นแบบชุดของรายละเอียด เพื่อดูตำแหน่ง ซึ่งรายละเอียดทั้งหมดกล่าวไว้แล้วในบทที่ 5 ผลลัพธ์ที่ได้จากงานวิจัยนี้มีความแม่นยำสูง

4) การหากระบวนการที่ใช้ในการจับจุดซ้ำ (Overlapping Problem) เพื่อใช้ในการหาจุดซ้ำจากภาพถ่ายต่างภาพได้ เนื่องจากจุดเลือดออกบางจุดสามารถปรากฏได้ในหลาย ๆ ภาพ เนื่องจากภาพถ่ายของผู้ป่วยหนึ่งสมอง จะประกอบด้วยภาพ 2 มิติหลาย ๆ ภาพ

การตรวจสอบการจับจุดซ้ำสามารถทำได้โดยใช้การวัดการคลาดเคลื่อนของจุดศูนย์กลาง โดยวัดทั้ง 4 ด้าน คือ 1) ด้านบน 2) ด้านล่าง 3) ด้านซ้าย และ 4) ด้านขวา ของจุดศูนย์กลางนั้นๆ หากจุดที่อยู่ในภาพถัดไปมีจุดศูนย์กลางคลาดเคลื่อนไม่เกิน 2 พิกเซล หรือ 0.57 เซนติเมตร ถือว่าจุดเลือดออกในสมองจุดนั้นเป็นจุดเดียวกัน

จากคำถามหลักของงานวิจัยนี้ และคำตอบที่ได้จากงานวิจัยนี้สรุปได้ว่า การตรวจจับจุดเลือดออกในสมองและการระบุตำแหน่งสามารถใช้กระบวนการทางการประมวลผลภาพได้ ทั้งนี้การสร้างตัวจำแนกได้มีการนำกระบวนการของโครงข่ายประสาทเทียมแบบสังวัตนาการเข้ามาใช้วิธีการที่เหมาะสมที่สุด คือ Alexnet นอกจากนี้ข้อมูลที่มีจำนวนมากทำให้ผลลัพธ์ออกมาแม่นยำ รวมถึงจำนวนรอบในการเทรนข้อมูลที่ให้ผลลัพธ์แม่นยำที่สุด คือ 8 รอบ ทั้งนี้เมื่อนำตัวจำแนกที่ได้มาทดสอบกับรูปสมองชุดสำหรับทดสอบ จากผู้ป่วยจำนวน 10 คน พบว่าให้ความแม่นยำถึงร้อยละ 95.76 รวมถึงการทดสอบวิธีการ Shape Matching ที่ใช้ในการระบุตำแหน่งของจุดเลือดออกในสมองด้วยภาพชุดเดียวกัน ให้ความแม่นยำร้อยละ 100 สำหรับสิ่งที่ค้นพบจากงานวิจัยแยกเป็นข้อๆ ได้ดังนี้

1) การตรวจจับจุดที่น่าสนใจจากภาพถ่ายสมอง ทำได้ด้วยกระบวนการประมวลผลภาพ คือ segmentation โดยเป็นกระบวนการที่มีความเหมาะสมกับงานวิจัยนี้

2) กระบวนการตรวจจับจุดที่น่าสนใจจากภาพถ่ายสมอง ทำได้ด้วยกระบวนการประมวลผลภาพด้วยวิธี Thresholding และการดึงคุณลักษณะของวงกลม โดย Thresholding สามารถดึงส่วนที่สนใจออกมาได้ แต่ในงานวิจัยนี้ต้องใช้ 3 ค่า จึงจะได้จุดที่สนใจออกมามากที่สุด

3) การประมวลผลภาพเพื่อหาภาพที่เหมาะสมในการจำแนก ภาพที่ได้ คือ ภาพจากกระบวนการตัดจุดที่น่าสนใจ โดยมีพื้นที่รอบข้างด้วย โดยมีขนาด 36x36 พิกเซล แสดงให้เห็นว่าพื้นที่รอบข้างของจุดที่สนใจมีผลต่อการจำแนกกว่าเป็นจุดเลือดออกในสมองหรือไม่

4) กระบวนการการเรียนรู้เชิงลึกที่เหมาะสมในการสร้างตัวจำแนก คือ การเรียนรู้แบบเครือข่ายประสาทสังวัตนาการ โดยใช้สถาปัตยกรรมแบบ Alexnet โดยสถาปัตยกรรมนี้ใช้เวลาในการประมวลผลน้อย และให้ความถูกต้องสูง

5) ในกระบวนการสร้างตัวจำแนก จำนวนรอบในการเทรนข้อมูล และจำนวนของข้อมูลมีผลต่อความถูกต้องในการประเมินประสิทธิภาพของการจำแนก

6) โครงข่ายประสาทเทียมแบบสังวัตนาการ สามารถทำการสร้างตัวจำแนกได้โดยไม่ต้องมีการดึงคุณลักษณะด้วยผู้วิจัย เนื่องจากกระบวนการนี้สามารถทำได้อัตโนมัติ ทำให้ลดเวลาในการทำงานวิจัยได้มากขึ้น

7) กระบวนการระบุตำแหน่งให้จุดเลือดออกในสมอง ที่นำเสนอในงานวิจัยนี้ ใช้วิธีการจับคู่ภาพที่มีรูปร่างเหมือนกัน (Shape Matching) ที่ให้ผลลัพธ์ออกมามีความถูกต้องสูง ซึ่งเป็นข้อค้นพบใหม่ในงานวิจัยนี้

8) กระบวนการตรวจสอบจุดเลือดออกในสมองจุดเดียวกันที่ปรากฏในหลายภาพ (Overlapping Problem) สามารถทำได้โดยใช้วิธีการทางการประมวลผลภาพ โดยใช้การวัดการเคลื่อนที่ของจุดศูนย์กลาง วิธีนี้สามารถตรวจสอบจุดซ้ำได้ แต่ในบางจุดยังมีข้อผิดพลาด คือ จุดที่พบมากกว่า 2 ภาพ อาจจะเจอซ้ำในภาพที่ 3 ได้

6.3 ปัญหาและอุปสรรค

จากการดำเนินงานวิจัยนี้ พบว่ามีปัญหาและอุปสรรคที่มีผลกระทบต่อการทำงานวิจัยดังนี้

1) การที่จะได้มาซึ่งภาพที่ใช้ในการทดลองต้องใช้เวลาาน เนื่องจากมีขั้นตอนต่าง ๆ เช่น การคัดเลือกรูป การไม่มีรูป เป็นต้น ซึ่งทำให้ระยะเวลาในการทำงานวิจัยยาวนานขึ้น แต่ทั้งนี้ทางแพทย์และเจ้าหน้าที่จากโรงพยาบาลก็ให้ความร่วมมืออย่างเต็มที่ งานวิจัยนี้สำเร็จลุล่วงไปด้วยดี

2) การระบุว่าจุดไหนเป็นจุดเลือดออกในสมอง และจุดนั้นอยู่ตำแหน่งไหน จะต้องรอแพทย์ผู้เชี่ยวชาญเป็นคนระบุ ดังนั้นจึงเกิดปัญหาเช่นเดียวกับการที่จะได้มาซึ่งรูป แต่เจ้าหน้าที่ทุกคนก็ให้ความร่วมมืออย่างดีเช่นกัน

6.4 ลักษณะของการนำไปใช้ประโยชน์

งานวิจัยนี้สามารถนำไปใช้ประโยชน์ได้จริงทางการแพทย์ ช่วยให้แพทย์สามารถวินิจฉัยโรคได้เร็ว และเสถียรขึ้น ทั้งนี้การที่ระบบจะทำงานได้สมบูรณ์ต้องมีการทำแอปพลิเคชันขึ้นมา เพื่อให้แพทย์สามารถใช้งานได้ง่ายยิ่งขึ้น

6.5 งานในอนาคต

งานวิจัยนี้สามารถนำไปต่อยอดได้ในอนาคต รวมถึงสามารถพัฒนาให้มีความแม่นยำมากขึ้นได้ ดังนี้

- 1) การนำงานวิจัยนี้ไปใช้งานจริง ต้องมีการทำแอปพลิเคชันขึ้นมา เพื่อให้แพทย์สามารถใช้งานได้ง่ายขึ้น
- 2) งานวิจัยนี้สามารถพัฒนาให้แม่นยำมากขึ้นโดยการใช้ภาพสมองจำนวนมากขึ้น
- 3) กระบวนการในการสร้างตัวจำแนก สามารถทดลองกับวิธีอื่น ๆ ของโครงข่ายประสาทเทียมแบบสังวัตนาการได้
- 4) การทำ Shape matching เป็นวิธีการเบื้องต้นที่ใช้ในการระบุตำแหน่งของจุดเลือดออกในสมองในอนาคต ผู้วิจัยสามารถศึกษาวิธีการอื่น ๆ เพื่อเปรียบเทียบผลลัพธ์ที่ได้ และหาวิธีที่ดีที่สุด
- 5) งานวิจัยนี้สามารถสร้างตัวจำแนกได้โดยการกำหนดค่าของข้อมูลแต่ละชั้นเอง

เอกสารอ้างอิง

- ทรงกต ทศานนท์. (2550). “การวิเคราะห์และแปลภาพเชิงตัวเลข (Digital Image Analysis and Interpretation)” (ออนไลน์) เข้าถึงได้ที่ http://www.tobthong.rbru.ac.th/wp-content/uploads/2015/09/RS1_15_บทที่-4-ข้อมูลภาพจากดาวเทียมและการประมวลผลเชิงเลข.pdf. (สืบค้นเมื่อวันที่ 6 มีนาคม 2562)
- บริษัทกลุ่มแอดวานซ์ รีเสิร์ช จำกัด. (2560) “การเรียนรู้เชิงลึก (Deep Learning) เป็นส่วนหนึ่งของ AI” (ออนไลน์) เข้าถึงได้ที่ https://www.ar.co.th/news_content/th/686 (สืบค้นเมื่อวันที่ 27 กุมภาพันธ์ 2562)
- पालันท์ ศิริวนารังสรรค์. (2559) “ความเข้าใจเบื้องต้นของการตรวจคลื่นแม่เหล็กไฟฟ้า ของระบบกระดูกและข้อ” (ออนไลน์) เข้าถึงได้ที่ [http://www.si.mahidol.ac.th/th/department/radiology/sr/document/6/08-p.%20132-141F2%20\(1\).pdf](http://www.si.mahidol.ac.th/th/department/radiology/sr/document/6/08-p.%20132-141F2%20(1).pdf) (สืบค้นเมื่อวันที่ 26 กุมภาพันธ์ 2562).
- พนมขวัญ ธิยะมงคล. ม.ป.ป. “Digital Image Processing” (ออนไลน์) เข้าถึงได้ที่ <http://www.ecpe.nu.ac.th/panomkhawn/imagepro/pdf/ch09.pdf> (สืบค้นเมื่อวันที่ 7 มีนาคม 2562).
- เอกสิทธิ์ พัทธวงศ์ศักดิ์. (2015) “ตัววัดประสิทธิภาพของโมเดล Classification” (ออนไลน์) เข้าถึงได้ที่ http://dataminingtrend.com/2014/classifier_evaluation_metrics/ (สืบค้นเมื่อวันที่ 8 มีนาคม 2562).
- Adit Deshpande. (2016) “The 9 Deep Learning Papers You Need To Know About (Understanding CNNs Part 3)” (Online) Available on <https://adeshpande3.github.io/The-9-Deep-Learning-Papers-You-Need-To-Know-About.html> (accessed March 2, 2019).
- Al-Qizwini, M., Barjasteh, I., Al-Qassab, H., & Radha, H. (2017). “Deep learning algorithm for autonomous driving using GoogLeNet.”, *Proceedings of IEEE Intelligent Vehicles Symposium (IV)*, Los Angeles, USA: 11-14 June, 2017.
- Alan Zucconi. (2015) “googlenet-arch” (Online) Available on <https://www.alanzucconi.com/2015/07/06/live-your-deepdream-how-to-recreate-the-inceptionism-effect/googlenet-arch/> (accessed March 3, 2019).
- Amir Fazlollahi, Fabrice Meriaudeau, Victor L. Villemagne, Christopher C. Rowe, Paul

- Yates, O. S. (2014). "Efficient Machine Learning Framework for Computer-Aided Detection of Cerebral Microbleeds Using the Radon Transform", 113–116.
- Asha, M., & Gupta, K. (2016). "A Basic Approach to Enhance a Gray Scale Image", (7), 126–129.
- Arden Dertat. (2017) "Applied Deep Learning - Part 4: Convolutional Neural Networks" (Online) Available on <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2> (accessed March 2, 2562).
- Bar, Y., Diamant, I., Wolf, L., Lieberman, S., Konen, E., & Greenspan, H. (2015). "Chest pathology detection using deep learning with non-medical training.", *Proceedings of International Symposium on Biomedical Imaging*, New York, USA, July 2015.
- Baxes, G. A. (1994). *Digital image processing: principles and applications*, (pp. I-XVIII). New York: Wiley.
- Chen, H., Yu, L., Dou, Q., Shi, L., Mok, V. C. T., & Heng, P. A. (2015). "Automatic detection of cerebral microbleeds via deep learning based 3D feature representation." *2015 IEEE 12th International Symposium on Biomedical Imaging (ISBI)*, 764–767.
- Chunjing, Y., Yueyao, Z., Yaxuan, Z., & Liu, H. (2017). "Application of convolutional neural network in classification of high resolution agricultural remote sensing images." *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 42(2W7), 989–992.
- Dou, Q., Chen, H., Yu, L., Zhao, L., Qin, J., Wang, D., ... Heng, P. A. (2016). "Automatic Detection of Cerebral Microbleeds from MR Images via 3D Convolutional Neural Networks." *IEEE Transactions on Medical Imaging*, 35(5), 1182–1195.
- Dou, Q., Chen, H., Yu, L., Shi, L., Wang, D., Mok, V. C., & Heng, P. A. (2015). "Automatic cerebral microbleeds detection from MR images via Independent Subspace Analysis based hierarchical features.", *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, Milan, Italy: November 2015.
- Dougherty, E. R., & Lotufo, R. A. (2003). *Hands-on morphological image processing* (Vol. 59), SPIE press.
- ERDAS Imagine. (2002). *ERDAS Field Guid*, Atlanta, Georgia.

- Esteva, A., Thrun, S., Swetter, S. M., Novoa, R. A., Blau, H. M., Kuprel, B., & Ko, J. (2017). "Dermatologist-level classification of skin cancer with deep neural networks." *Nature*, 542(7639), 115–118.
- Fazlollahi, A., Meriaudeau, F., Villemagne, V. L., Rowe, C. C., Desmond, P. M., Yates, P. A., ... Bourgeat, P. (2013). "Automatic detection of small spherical lesions using multiscale approach in 3D medical images." *2013 IEEE International Conference on Image Processing*, Melbourne, Australia: 15-18 September, 2013.
- GitHub. "GoogleNet" (Online) Available on <https://leonardoraujosantos.gitbooks.io/artificial-intelligence/content/googlenet.html> (สืบค้นเมื่อวันที่ 3 มีนาคม 2562).
- Ghafaryasl, B., Van Der Lijn, F., Poels, M., Vrooman, H., Ikram, M. A., Niessen, W. J., ... De Bruijne, M. (2012). "A computer aided detection system for cerebral microbleeds in brain MRI.", *Proceedings of 2012 9th International Symposium on Biomedical Imaging (ISBI)*, Barcelona, Spain: 2-5 May, 2012.
- Greenberg, S. M., Vernooij, M. W., Cordonnier, C., Viswanathan, A., Al-Shahi Salman, R., Warach, S., ... Breteler, M. M. (2009). "Cerebral microbleeds: a guide to detection and interpretation." *The Lancet Neurology*, 8(2), 165–174.
- Gregoire, S. M., Werring, D. J., Chaudhary, U. J., Thornton, J. S., Brown, M. M., Yousry, T. A., & Jäger, H. R. (2010). "Choice of echo time on GRE T2*-weighted MRI influences the classification of brain microbleeds." *Clinical Radiology*, 65(5), 391–394.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). "Deep residual learning for image recognition.", *Proceedings of the 2016 IEEE conference on computer vision and pattern recognition (CVPR)*, Las Vegas, USA: 27-30 June, 2016.
- Hong Kong University. n.d. "Image Enhancement" (Online) Available on <http://www.eie.polyu.edu.hk/~enyhchan/imagee.pdf> (accessed March 7, 2019).
- Ian T. Young, Jan J. Gerbrands, Lucas J. van Vliet. (2007) "Fundamentals of Image Processing" (Online) Available on http://www.imageprocessingplace.com/downloads_V3/root_downloads/tutorials/Image%20Processing%20FundamentalsAn%20Overview.pdf (accessed March 6, 2019)
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., & Keutzer, K. (2017). "SQUEEZENET: ALEXNET-LEVEL ACCURACY WITH 50X FEWER PARAMETERS AND <0.5MB MODEL SIZE", *Proceeding of the 5th International Conference on Learning*

- Representations (ICLR 2017)*, Toulon, France; 24-26 April, 2017.
- Ibngomacha Singh, T. H., Laishram, R., & Roy, S. (2017). "Image segmentation using spatial fuzzy C means clustering and grey Wolf optimizer.", *Proceeding of the 2016 IEEE International Conference on Computational Intelligence and Computing Research (ICIC 2016)*, Tamil Nadu, India; 15-17 December, 2016.
- Imagenet. (2014) "Large Scale Visual Recognition Challenge 2014 (ILSVRC2014)" (Online) Available on <http://www.image-net.org/challenges/LSVRC/2014/> (accessed March 3, 2019)
- Jaiswal, R., & Sarode, M. (2018). "Comparative study of different segmentation techniques applied to medical imaging.", *Proceedings of the 2018 3rd IEEE International Conference on Research in Intelligent and Computing in Engineering (RICE 2018)*, Soyapango, El Salvador: 22-24 August, 2018.
- Jay Mahadeokar and Gerry Pesavento. (2016) "Open Sourcing a Deep Learning Solution for Detecting NSFW Images" (Online) Available on <https://yahoocs.tumblr.com/> (accessed March 4, 2019)
- Jellinger, K. A. (2002). "Alzheimer disease and cerebrovascular pathology: An update." *Journal of Neural Transmission*, 109(5–6), 813–836.
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., ... Wang, Y. (2017). "Artificial intelligence in healthcare: Past, present and future." *Stroke and Vascular Neurology*, 2(4), 230–243.
- Kang, W. X., Yang, Q. Q., & Liang, R. P. (2009). "The comparative research on image segmentation algorithms.", *Proceedings of the 1st International Workshop on Education Technology and Computer Science (ETCS 2009)*, Hubei, China; 7-8 March, 2009.
- Krizhevsky, A., & Hinton, G. E. (n.d.). "ImageNet Classification with Deep Convolutional Neural Networks." *Neural Information Processing Systems*, 25, 1–9.
- Lim, J. S. (1990). "Two-dimensional signal and image processing. Englewood Cliffs." NJ, Prentice Hall, 710.
- Maini, R., & Aggarwal, H. (2010). "A comprehensive review of image enhancement techniques." *Journal Of Computing*, 2(3), 8–13.
- Nishant Kumar. "Digital Image Processing Basics" (Online) Available on <https://www.>

- geeksforgeeks.org/digital-image-processing-basics/ (accessed March 6, 2019)
- Noorbakhsh-Sabet, N., Pulakanti, V. C., & Zand, R. (2017). "Uncommon Causes of Cerebral Microbleeds." *Journal of Stroke and Cerebrovascular Diseases*, 26(10), 2043–2049.
- Pawara, P., Okafor, E., Surinta, O., Schomaker, L., & Wiering, M. (2017). "Comparing Local Descriptors and Bags of Visual Words to Deep Convolutional Neural Networks for Plant Recognition", *Proceedings of the 6th International Conference on Pattern Recognition Applications and Methods - Volume 1: ICPR AM*, Porto, Portugal: 24-26 February, 2017.
- Robert, Fisher. n.d. "Closing" (Online) Available on <http://homepages.inf.ed.ac.uk/rbf/HIPR2/dilate.htm> (accessed March 7, 2019).
- Robert, Fisher. n.d. "Dilation" (Online) Available on <http://homepages.inf.ed.ac.uk/rbf/HIPR2/dilate.htm> (accessed March 7, 2019).
- Robert, Fisher. n.d. "Morphological Image Processing" (Online) Available on <https://www.cs.auckland.ac.nz/courses/compsci773s1c/lectures/ImageProcessing-html/topic4.htm> (accessed March 7, 2019).
- Smartbear software. (2019) "How Image Comparison Works" (Online) Available on <https://support.smartbear.com/testcomplete/docs/testing-with/checkpoints/regions/how-image-comparison-works.html> (accessed March 8, 2019).
- Sripaoraya, S., & Sinsomboonthong, S. (2017). "กรณีศึกษาโรงพยาบาลแห่งหนึ่งในประเทศไทย อินเดีย Efficiency Comparison of Data Mining Classification Methods for Chronic Kidney Disease : A Case Study of a Hospital in India." *Thai Science and Technology Journal*, 25(5), 839-853.
- Shams, S., Martola, J., Cavallin, L., Granberg, T., Shams, M., Aspelin, P., ... Kristoffersen-Wiberg, M. (2015). "SWI or T2*: Which MRI sequence to use in the detection of cerebral microbleeds? The Karolinska Imaging Dementia Study." *American journal of Neuroradiology*, 36(6), 1089–1095.
- Shin, H. C., Orton, M. R., Collins, D. J., Doran, S. J., & Leach, M. O. (2013). "Stacked autoencoders for unsupervised feature learning and multiple organ detection in a pilot study using 4D patient data." *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1930–1943.

- Sicuranza, G. (2000). *Nonlinear image processing*. Elsevier.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... Rabinovich, A. (2015). "Going deeper with convolutions.", *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPRW)*, Boston, USA, 7-12 June, 2015.
- Takano, Y., Ouyang, W., Ito, S., Harada, T., & Thawonmas, R. (2018). "Applying Hybrid Reward Architecture to a Fighting Game AI." *IEEE Conference on Computational Intelligence and Games (CIG)*, Maastricht, Netherlands, 14-17 August, 2018.
- Veltkamp, R. C. (2001). "Shape Matching: Similarity Measures and Algorithms." *Proceedings of the International Conference on Shape Modeling and Applications*, Geneva, Italy, 7-11 May, 2001.
- Wang, S., Jiang, Y., Hou, X., Cheng, H., & Du, S. (2017). "Cerebral Micro-Bleed Detection Based on the Convolution Neural Network with Rank Based Average Pooling." *IEEE Access*, 5, 16576–16583.
- Yates, P. A., Villemagne, V. L., Ellis, K. A., Desmond, P. M., Masters, C. L., & Rowe, C. C. (2014). "Cerebral microbleeds: A review of clinical, genetic, and neuroimaging associations." *Frontiers in Neurology*, 1–13.
- Zhang, Y. D., Hou, X. X., Lv, Y. D., Chen, H., Zhang, Y., & Wang, S. H. (2017). "Sparse autoencoder based deep neural network for voxelwise detection of cerebral microbleed." *Proceedings of the International Conference on Parallel and Distributed Systems (ICPADS)*, Shenzhen, China: 15-17 December, 2017.

ภาคผนวก ก

ซอร์สโค้ดอื่น ๆ ในการทำงานวิจัย

ภาคผนวก ก

ซอร์ซโค้ดอื่น ๆ ในการทำงานวิจัย

ผู้วิจัยได้ทำการรวบรวมซอร์ซโค้ดอื่นๆ ที่ใช้ในงานวิจัยนี้นอกจากที่แสดงไว้แล้ว ในบทต่าง ๆ โดยแสดงไว้แล้วดังภาพที่ ก.1-ก.6 ซึ่งภาพ ก.1-ก.3 แสดงซอร์ซโค้ดในการตัดภาพจุดในกรณีต่าง ๆ ทั้ง 3 กรณี คือ 1) ภาพดั้งเดิมที่ตัดได้ (ภาพชุดที่ 1) 2) ภาพที่ปรับพื้นที่รอบข้างให้น้อยลง (ภาพชุดที่ 2) และ 3) ภาพที่ตัดส่วนพื้นที่ที่สนใจจากภาพดั้งเดิม (ภาพชุดที่ 3) นอกจากนี้ผู้วิจัยได้แสดงซอร์ซโค้ดในการปรับขนาดของภาพก่อนที่จะเข้าสู่กระบวนการสร้างตัวจำแนก ซึ่งแสดงดังภาพที่ ก.4 สุดท้ายซอร์ซโค้ดแสดงการสร้างตัวจำแนกแสดงดังภาพที่ ก.5-ก.6

```

folderName = ['D:\MSIT\THESIS\MATLAB\SWI\CNN1\M' num2str(icnn) '\' num2str(iPic - 1) '\'];

if ~exist(folderName, 'dir')
    mkdir(folderName);
end

textXpic      = [folderName num2str(count) '.jpg'];
Pic_cnn_imcrop = imcrop(image_std{iPic}, [(centroid(1) - 18) (centroid(2) - 18) (36) (36)]);
imwrite(Pic_cnn_imcrop, textXpic, 'jpg');

textX          = [num2str(count)];
plot(boundary(:,2), boundary(:,1), 'w', 'LineWidth', 1)
pcount        = pcount + 1;
count         = count + 1;
text(boundary(1,2)-35, boundary(1,1)+13, textX, 'Color', 'r', ...
     'FontSize', 10, 'FontWeight', 'bold');

```

ภาพที่ ก.1 ซอร์ซโค้ดการตัดภาพจุดในกรณีที่ 1

จากภาพที่ ก.1 เป็นการแสดงซอร์ซโค้ดที่ใช้ในการตัดภาพจุดที่สนใจในกรณีที่ 1 คือ ตัดภาพให้มีขนาด 36x36 พิกเซล ซึ่งในงานวิจัยนี้เรียกภาพชุดนี้ว่า “ภาพชุดที่ 1”

```

folderName = ['D:\MSIT\THESIS\MATLAB\SWI\CNN2\M' num2str(icnn) '\ ' num2str(iPic - 1) '\'];

if ~exist(folderName, 'dir')
    mkdir(folderName);
end

textXpic      = [folderName num2str(count) '.jpg'];
Pic_cnn_imcrop = imcrop(image_std(iPic),[(centroid(1) - 14) (centroid(2) - 14) (28) (28)]);
imwrite(Pic_cnn_imcrop,textXpic, 'jpg');

textX = [num2str(count)];
plot(boundary(:,2), boundary(:,1), 'w', 'LineWidth', 1)
pcount      = pcount + 1;
count       = count + 1;
text(boundary(1,2)-35,boundary(1,1)+13,textX,'Color','r',...
     'FontSize',10,'FontWeight','bold');

```

ภาพที่ ก.2 ซอร์ซโค้ดการตัดภาพจุดในกรณีที่ 2

จากภาพที่ ก.2 เป็นการแสดงซอร์ซโค้ดที่ใช้ในการตัดภาพจุดที่สนใจในกรณีที่ 2 คือ ภาพที่ปรับพื้นที่รอบข้างให้น้อยลง โดยตัดภาพให้มีขนาด 28x28 พิกเซล ซึ่งในงานวิจัยนี้เรียกภาพชุดนี้ว่า “ภาพชุดที่ 2”

```

Pic_cnn_imcrop = imcrop(image_std(iPic),[stats(k).BoundingBox(1) stats(k).BoundingBox(2) (cnn_size) (cnn_size)]);

[x,y]=size(Pic_cnn_imcrop);

Pic_cnn_imcrop = imresize(Pic_cnn_imcrop, (36 / x));

imwrite(Pic_cnn_imcrop,textXpic, 'jpg');

textX = [num2str(count)];
plot(boundary(:,2), boundary(:,1), 'w', 'LineWidth', 1)
pcount      = pcount + 1;
count       = count + 1;
text(boundary(1,2)-35,boundary(1,1)+13,textX,'Color','r',...
     'FontSize',10,'FontWeight','bold');

```

ภาพที่ ก.3 ซอร์ซโค้ดการตัดภาพจุดในกรณีที่ 3

จากภาพที่ ก.3 เป็นการแสดงซอร์ซโค้ดที่ใช้ในการตัดภาพจุดที่สนใจในกรณีที่ 3 คือ ภาพที่ตัดส่วนพื้นที่ที่สนใจจากภาพดั้งเดิม โดยตัดเอาเฉพาะส่วนที่เป็นจุดที่สนใจเท่านั้น ซึ่งในงานวิจัยนี้เรียกภาพชุดนี้ว่า “ภาพชุดที่ 3”

เมื่อได้ภาพที่จะนำเข้าสู่กระบวนการสร้างตัวจำแนก จำต้องนำภาพที่ได้ทั้งหมด มาปรับขนาดให้มีขนาดเท่ากับ 227x227 พิกเซลก่อน ซึ่งเป็นเงื่อนไขของการใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ ซอร์ซโค้ดแสดงดังภาพที่ ก.4

```

imagefiles = dir('*.png');
nfiles = length(imagefiles);

for ii=1:nfiles

    currentfilename = imagefiles(ii).name;
    currentimage = imread(currentfilename);
    qa{ii} = currentimage;
    final{ii}=imresize(currentimage, [227 227]);
    imwrite(final{ii}, ['!' num2str(ii) '.jpg'])

end

```

ภาพที่ ก.4 ซอร์ซโค้ดการปรับขนาดของรูปก่อนสร้างตัวจำแนก

จากภาพที่ ก.4 แสดงซอร์ซโค้ดในการปรับขนาดของภาพจุดที่สนใจทั้ง 3 ชุด ก่อนที่จะนำเข้าสู่กระบวนการสร้างตัวจำแนก โดยปรับให้มีขนาด 227x227 พิกเซลเท่ากันทั้งหมด โดยขั้นตอนี้มีความจำเป็นที่จะต้องทำ เพื่อป้องกัน error ที่จะเกิดขึ้น จากนั้นจึงนำชุดข้อมูลที่ได้ทั้งหมดเข้าสู่กระบวนการสร้างตัวจำแนกต่อไป ซึ่งซอร์ซโค้ดแสดงดังภาพที่ ก.5 และ ก.6

```

imds = imageDatastore('TrainingDataAll', ...
    'IncludeSubfolders',true, ...
    'LabelSource','foldernames');

[imdsTrain,imdsValidation] = splitEachLabel(imds,0.8);

net = alexnet;

analyzeNetwork(net)

net.Layers(1)

inputSize = net.Layers(1).InputSize;

if isa(net,'SeriesNetwork')
    lgraph = layerGraph(net.Layers);
else
    lgraph = layerGraph(net);
end

[learnableLayer,classLayer] = findLayersToReplace(lgraph);
[learnableLayer,classLayer]

numClasses = numel(categories(imdsTrain.Labels));

if isa(learnableLayer,'nnet.cnn.layer.FullyConnectedLayer')
    newLearnableLayer = fullyConnectedLayer(numClasses, ...
        'Name','new_fc', ...
        'WeightLearnRateFactor',10, ...
        'BiasLearnRateFactor',10);

elseif isa(learnableLayer,'nnet.cnn.layer.Convolution2DLayer')
    newLearnableLayer = convolution2dLayer(1,numClasses, ...
        'Name','new_conv', ...
        'WeightLearnRateFactor',10, ...
        'BiasLearnRateFactor',10);
end

lgraph = replaceLayer(lgraph,learnableLayer.Name,newLearnableLayer);

```

ภาพที่ ก.5 ซอร์ซโค้ดการสร้างตัวจำแนก

```

newClassLayer = classificationLayer('Name','new_classoutput');
lgraph = replaceLayer(lgraph,classLayer.Name,newClassLayer);

layers = lgraph.Layers;
connections = lgraph.Connections;

layers(1:10) = freezeWeights(layers(1:10));
lgraph = createLgraphUsingConnections(layers,connections);

pixelRange = [-30 30];
scaleRange = [0.9 1.1];
imageAugmenter = imageDataAugmenter( ...
    'RandXReflection',true, ...
    'RandXTranslation',pixelRange, ...
    'RandYTranslation',pixelRange, ...
    'RandXScale',scaleRange, ...
    'RandYScale',scaleRange);
augimdsTrain = augmentedImageDatastore(inputSize(1:2),imdsTrain, ...
    'DataAugmentation',imageAugmenter);

augimdsValidation = augmentedImageDatastore(inputSize(1:2),imdsValidation);

options = trainingOptions('sgdm', ...
    'MiniBatchSize',10, ...
    'MaxEpochs',8, ...
    'InitialLearnRate',3e-4, ...
    'Shuffle','every-epoch', ...
    'ValidationData',augimdsValidation, ...
    'ValidationFrequency',10, ...
    'Verbose',false, ...
    'Plots','training-progress');

net = trainNetwork(augimdsTrain,lgraph,options);
[YPred,probs] = classify(net,augimdsValidation);
accuracy = mean(YPred == imdsValidation.Labels);

modelalexnetAll_e8 = net;
save modelalexnetAll_e8;

```

ภาพที่ ก.6 ซอร์ซโค้ดการสร้างตัวจำแนก (ต่อ)

ภาพที่ ก.5 และ ก.6 แสดงซอร์ซโค้ดในการสร้างตัวจำแนก ซึ่งเป็นซอร์ซโค้ดมาตรฐานในโปรแกรม MATLAB โดยผู้วิจัยได้ทำการเปลี่ยนชื่อสถาปัตยกรรมของโครงข่ายประสาทเทียมแบบสังวัตนาการที่ต้องการที่บรรทัด net = alexnet;

ภาคผนวก ข

ผลลัพธ์จากการทดลองวิธีการต่าง ๆ

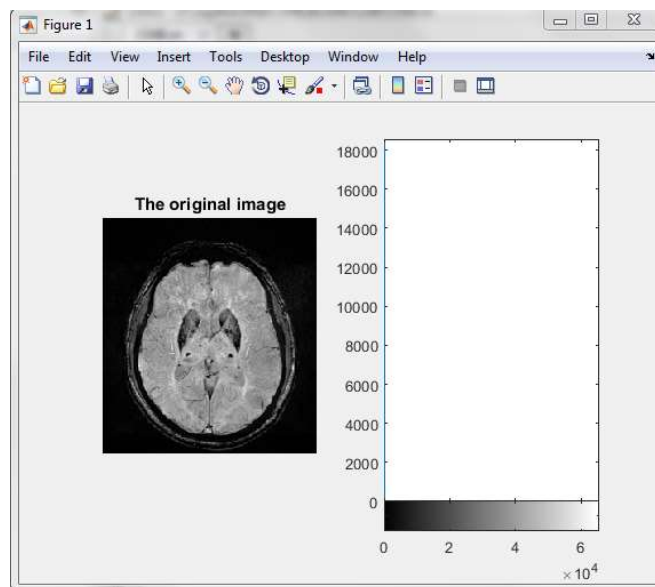
ภาคผนวก ข

ผลลัพธ์จากการทดลองวิธีการต่าง ๆ

ในภาพผนวก ข นี้ทางผู้วิจัยได้ทำการรวบรวมผลลัพธ์ที่ได้จากการปรับความคมชัดของภาพ (Image enhancement) ซึ่งได้ทดสอบทั้งหมด 7 วิธี และผลลัพธ์ที่ได้จากการตรวจจับเส้นขอบ (Edge detection) ซึ่งทำการทดสอบ 7 วิธีเช่นกัน

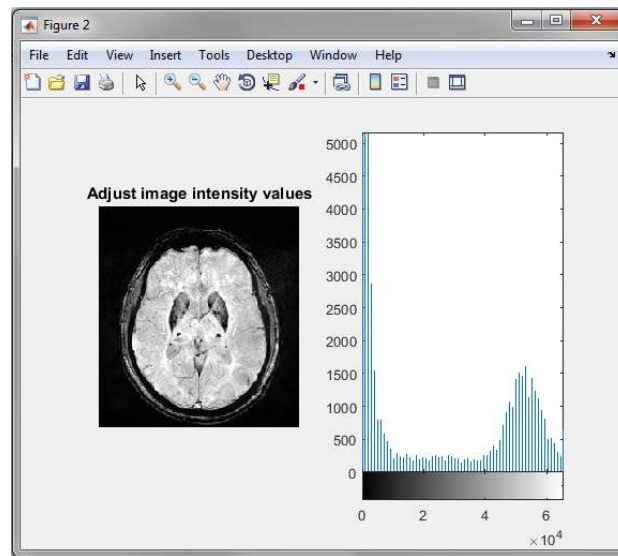
1) การปรับความคมชัดของภาพ (Image enhancement)

ขั้นตอนแรกของการทำงานวิจัยนี้จำเป็นต้องมีการเพิ่มประสิทธิภาพของภาพ เพื่อให้สามารถมองเห็นรายละเอียดของภาพ และสามารถตรวจจับจุดเลือดออกในสมองได้ง่ายขึ้น ดังนั้นจึงมีการปรับความคมชัดของรูป เพื่อให้สามารถมองเห็นจุดได้ชัดที่สุด และตรวจจับได้มากที่สุด ผลลัพธ์ที่ได้จากการทดลองปรับความคมชัดของรูปด้วยวิธีต่าง ๆ แสดงดังภาพที่ ข.1-ข.7

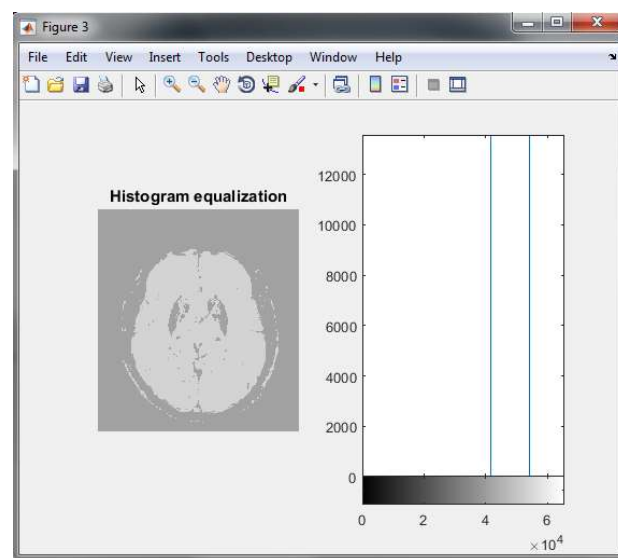


ภาพที่ ข.1 ภาพเดิมก่อนการปรับความคมชัด

จากภาพที่ ข.1 ที่แสดงภาพดั้งเดิมก่อนการปรับความคมชัด ผู้วิจัยได้ทำการทดสอบปรับความคมชัดของภาพสมองด้วยวิธีต่าง ๆ คือ การปรับความเข้ม (Adjust image intensity values) ซึ่งผลลัพธ์แสดงดังภาพที่ ข.2 พบว่าวิธีนี้สามารถทำให้เห็นรายละเอียดของสมองได้ชัดขึ้นกว่าภาพเดิม ส่วนการปรับความเข้มด้วย Histogram equalization แสดงดังภาพที่ ข.3 ซึ่งผลลัพธ์ที่ได้แสดงให้เห็นว่าไม่เหมาะสมกับภาพสมอง

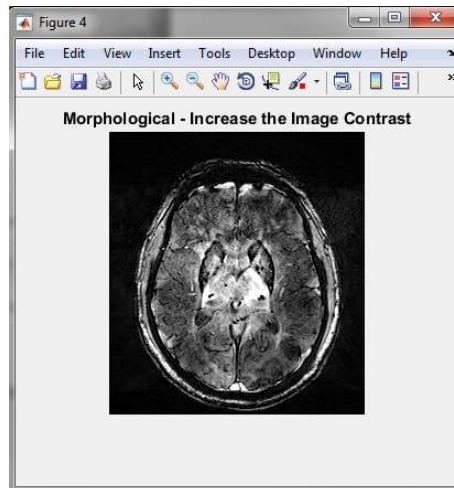


ภาพที่ ข.2 ภาพหลังปรับความคมชัดด้วยการปรับความเข้ม

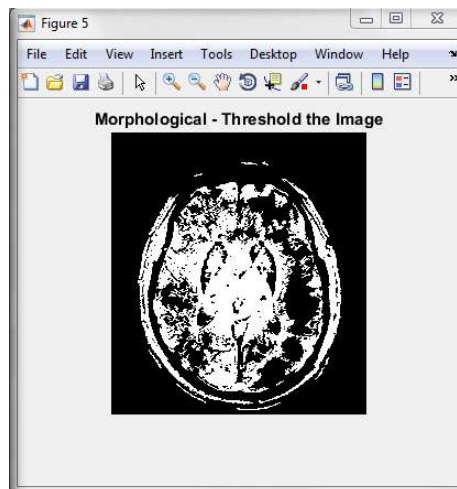


ภาพที่ ข.3 ภาพหลังปรับความคมชัดด้วย Histogram equalization

นอกจากนี้ยังมีการทดสอบปรับความคมชัดด้วย Morphological โดยผลลัพธ์ที่ได้จากการ Increases the Image Contrast แสดงดังภาพที่ ข.4 และผลลัพธ์ที่ได้จากการ Threshold the Image แสดงดังภาพที่ ข.5 และผลลัพธ์ที่ได้จากการใช้วิธีการ Otsu แสดงดังภาพที่ ข.6 ซึ่งทั้ง 3 วิธีให้ผลลัพธ์ออกมาไม่เหมาะสมกับงานวิจัยนี้



ภาพที่ ข.4 ภาพหลังปรับความคมชัดด้วย Morphological – Increases the Image Contrast




ภาพที่ ข.5 ภาพหลังปรับความคมชัดด้วย Morphological – Threshold the Image



ภาพที่ ข.6 ภาพหลังปรับความคมชัดด้วย Otsu


วิธีการสุดท้ายที่ใช้ในการทดสอบการปรับความคมชัดของภาพสมอง ซึ่งเป็นวิธีที่เหมาะสมที่สุด และถูกนำมาใช้ในงานวิจัยนี้ คือ วิธีการ Smoothing Weighted High Boost Filtering ผลลัพธ์แสดงดังภาพที่ ข.7




ภาพที่ ข.7 ภาพหลังปรับความคมชัดด้วย Smoothing Weighted High Boost Filtering

2) การดึงส่วนที่สนใจด้วยเส้นขอบ (Edge detection)


ในช่วงแรกของการทำงานวิจัยนี้ ผู้วิจัยได้ทำการศึกษาวิธีการต่าง ๆ เพื่อหาวิธีการตรวจจับจุดเลือดออกในสมอง ดังนั้นจึงมีการทดลองด้วยวิธีต่าง ๆ ซึ่งผลลัพธ์ที่ได้แสดงดังรูป ข.8-ข.14 โดยภาพทางซ้ายเป็นภาพสมองที่ผ่านการเพิ่มความคมชัดแล้ว และผลลัพธ์แสดงทางขวามือ โดยภาพที่ ข.8 แสดงผลลัพธ์จากการจับวัตถุด้วยวิธีการ Canny โดยไม่มีการกำหนด Threshold ส่วนภาพที่ ข.9 ภาพการจับวัตถุด้วยวิธีการ Canny โดยมีการกำหนด Threshold ภาพที่ ข.10 แสดงภาพการจับวัตถุด้วยวิธีการ Prewitt ภาพที่ ข.11 แสดงภาพการจับวัตถุด้วยวิธีการ Roberts ภาพที่ ข.12 ภาพแสดงผลลัพธ์การจับวัตถุด้วย ภาพการจับวัตถุด้วยวิธีการ Sobel ภาพที่ ข.13 ภาพแสดงผลลัพธ์การจับวัตถุด้วยวิธีการ Gaussian และภาพที่ ข.14 ภาพแสดงผลลัพธ์การจับวัตถุด้วยวิธีการ Laplacian




ภาพที่ ข.8 ภาพการจับวัตถุด้วยวิธีการ Canny (ไม่กำหนด Threshold)




ภาพที่ ข.9 ภาพการจับวัตถุด้วย ภาพการจับวัตถุด้วยวิธีการ Canny (กำหนด Threshold)



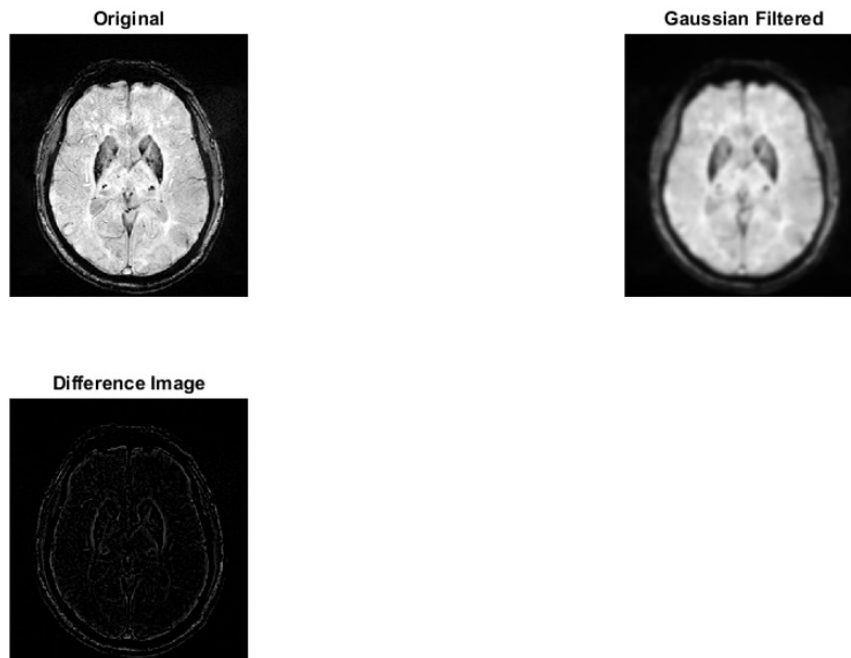
ภาพที่ ข.10 ภาพการจับวัตถุด้วย ภาพการจับวัตถุด้วยวิธีการ Prewitt




ภาพที่ ข.11 ภาพการจับวัตถุด้วย ภาพการจับวัตถุด้วยวิธีการ Roberts



ภาพที่ ข.12 ภาพการจับวัตถุด้วย ภาพการจับวัตถุด้วยวิธีการ Sobel



ภาพที่ ข.13 ภาพการจับวัตถุด้วย ภาพการจับวัตถุด้วยวิธีการ Gaussian



ภาพที่ ข.14 ภาพการจับวัตถุด้วย ภาพการจับวัตถุด้วยวิธีการ Laplacian

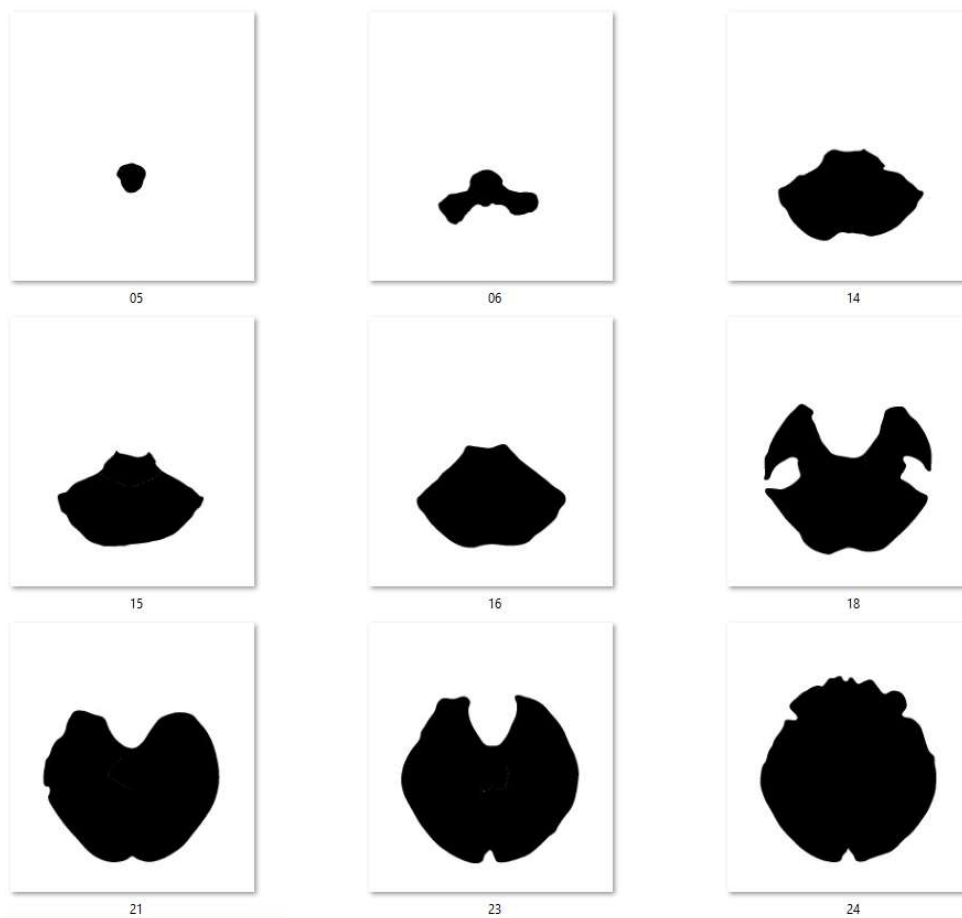
ภาคผนวก ค

ภาพต้นแบบในการจับคู่ภาพที่มีรูปร่างเหมือนกัน


ภาคผนวก ค

ภาพต้นแบบในการจับคู่ภาพที่มีรูปร่างเหมือนกัน

ในกระบวนการระบุตำแหน่งของจุดเลือดออกในสมองจำเป็นต้องมีภาพต้นแบบเพื่อใช้ในการจับคู่ภาพที่มีรูปร่างเหมือนกัน ในภาคผนวก ค แสดงภาพต้นแบบทั้งหมด โดยภาพที่ ค.1-ค.2 แสดงภาพต้นแบบที่ใช้ในการจับคู่ขอบสมอง และภาพที่ ค.3-ค.5 แสดงภาพต้นแบบที่ใช้ในการจับคู่ส่วนของสมอง




ภาพที่ ค.1 ภาพต้นแบบในการจับคู่ขอบสมอง



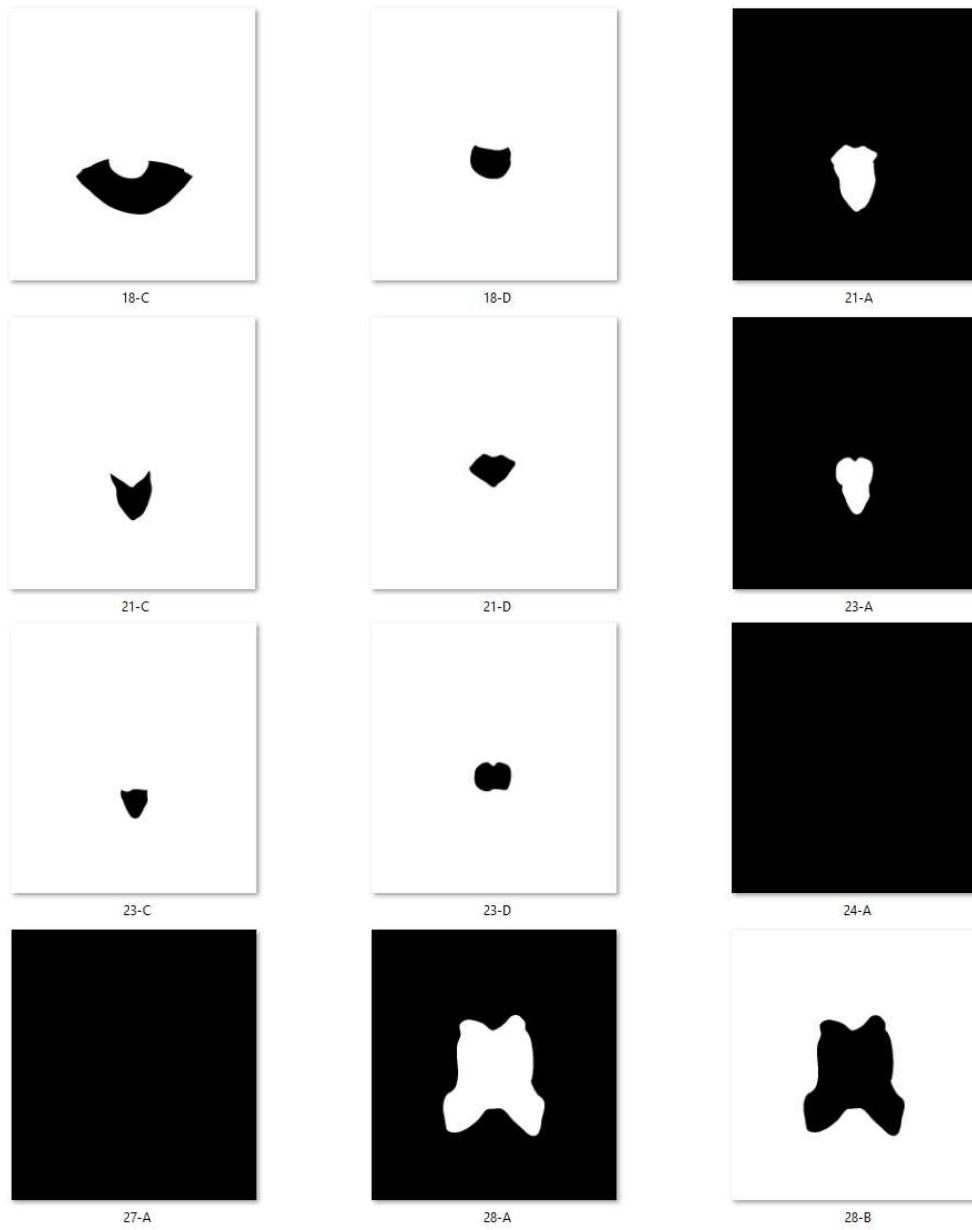
ภาพที่ ค.1 ภาพต้นแบบในการจับคู่ขอบสมอง (ต่อ)

เมื่อมีภาพต้นแบบในการจับคู่ขอบของสมองแล้ว ต้องมีภาพต้นแบบเพื่อจับคู่ ส่วนของสมองซึ่งแสดงดังภาพ ค.3-ค.5 โดยตัวเลขที่ชื่อของภาพ คือ ส่วนของสมองที่จับคู่ได้ จากภาพต้นแบบ ค1-ค.2 และตัวอักษร A-D คือ ส่วนต่าง ๆ ของสมองดังนี้

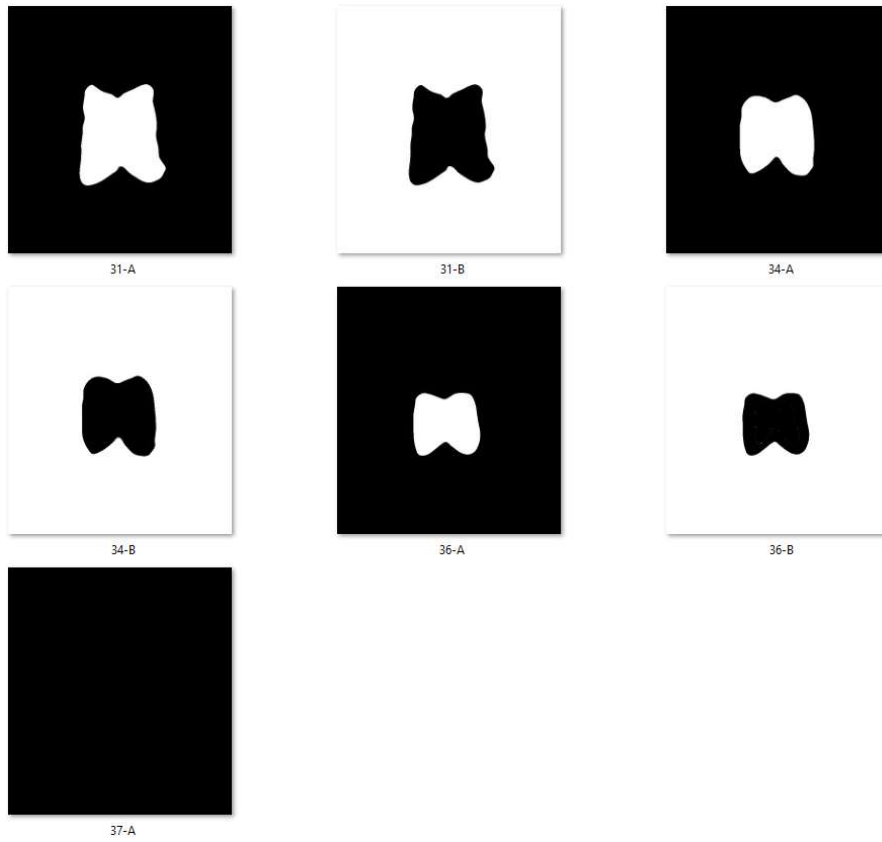
- A คือ เนื้อสมองส่วนนอก
- B คือ เนื้อสมองส่วนใน
- C คือ สมองน้อย
- D คือ ก้านสมอง



ภาพที่ ค.2 ภาพต้นแบบในการจับคู่ส่วนของสมอง



ภาพที่ ค.2 ภาพต้นแบบในการจับคู่ส่วนของสมอง (ต่อ)



ภาพที่ ค.2 ภาพต้นแบบในการจับคู่ส่วนของสมอง (ต่อ)

ประวัติผู้เขียน

ชื่อ สกุล นางสุจิตตรา เสงี่ยม

รหัสประจำตัวนักศึกษา 6030223002

วุฒิการศึกษา

วุฒิ	ชื่อสถาบัน	ปีที่สำเร็จการศึกษา
วิทยาศาสตรบัณฑิต (เทคโนโลยีสารสนเทศ)	มหาวิทยาลัยสงขลานครินทร์ วิทยาเขตภูเก็ต	2552

ทุนการศึกษา

ทุนอุดหนุนการวิจัยจากกองทุนวิจัยวิทยาลัยการคอมพิวเตอร์

การตีพิมพ์เผยแพร่ผลงาน

Sa-ngiem, S., Dittakan, K., Temkiatvises, K., Yaisoongnern, S. and Kespechara, K. (2019) "Cerebral Microbleed Detection by Extracting Area and Number from Susceptibility Weighted Imagery using Convolutional Neural Network", Proceeding of the 3rd International Conference on Machine Vision and Information Technology (CMVIT 2019), Shanghai, China: 22-24 March, 2019.