

การจำแนกภาพ MRI สำหรับการคัดกรองผู้ป่วยเนื้องอกในสมอง Classification of MRI Images for Brain Tumor Patient Screening

กมลชนก สีพาทิง¹, นนทวัฒน์ เปรณาม¹, วีระศักดิ์ สว่างโลก¹, อนุปงศ์ สุขประเสริฐ^{1,*}
Kamonchanok Siphating¹, Nonthawat Peranam¹, Weerasak Sawangloke¹,
Anupong Sukprasert^{1,*}

¹ คณะการบัญชีและการจัดการ มหาวิทยาลัยมหาสารคาม มหาสารคาม 44150 ประเทศไทย

¹ Maharakham Business School, Maharakham University, Maharakham 44150, Thailand

* Corresponding Author: Anupong Sukprasert, anupong.s@acc.msu.ac.th

Received:

5 March 2023

Revised:

8 April 2023

Accepted:

29 May 2023

คำสำคัญ:

การเปรียบเทียบประสิทธิภาพ,
การจำแนกประเภทข้อมูลภาพ,
เนื้องอกในสมอง, เหมืองข้อมูลภาพ

Keywords:

Performance Comparison,
Image Classification, Brain
Tumor, Image Mining

บทคัดย่อ: งานวิจัยนี้มีวัตถุประสงค์เพื่อสร้างแบบจำลองสำหรับการคัดกรองผู้ป่วยเนื้องอกในสมองด้วยภาพ MRI โดยใช้ข้อมูลจากเว็บไซต์ www.kaggle.com ซึ่งได้ถูกรวบรวมโดย Chakrabarty (2021) จำนวนข้อมูลทั้งหมด 253 ภาพ และนำมาวิเคราะห์ตามกระบวนการทำเหมืองข้อมูล จากนั้นเปรียบเทียบประสิทธิภาพแบบจำลอง ผลการวิจัยพบว่า เทคนิคต้นไม้ป่าสุ่ม เป็นเทคนิคที่มีความเหมาะสมในการสร้างแบบจำลองการพยากรณ์โอกาสเป็นโรคเนื้องอกในสมอง โดยให้ค่าความแม่นยำสูงที่สุดถึง 76.31% ค่าประสิทธิภาพโดยรวมเท่ากับ 73.48% ค่าความไวเท่ากับ 70.14% และค่าจำเพาะเท่ากับ 82.69% ซึ่งผลการวิเคราะห์ข้อมูลในครั้งนี้สามารถนำไปสร้างเป็นระบบสารสนเทศเพื่อใช้สำหรับการคัดกรองผู้ป่วยเนื้องอกในสมองในอนาคต

Abstract: This research aims to create a model for screening brain tumor patients using MRI imaging data from www.kaggle.com. The data was gathered by Chakrabarty (2021) with a total of 253 images. The data was analyzed using the cross-industry standard process for data mining, then the performances of the classification models were compared. The results showed that random forest technique gave the best result for predicting the likelihood of brain tumors, with an accuracy of 76.31%. The f-measure was 73.48% with a sensitivity of 70.14% and a specificity of 82.69%. The data analysis results could be utilized to develop an information system for future patient screenings for brain tumors.

1. บทนำ

เนื้องอกในสมองเป็นโรคที่พบได้ทุกเพศทุกวัย ที่มีความรุนแรง เนื่องจากทำให้สมองทำงานผิดปกติ อีกทั้งยังทำให้ผู้ป่วยเกิดความพิการและมีความเสี่ยงต่อการเสียชีวิต (Bunevicius *et al.*, 2013; Siegel, Miller & Jemal, 2018) การผ่าตัดเปิดกะโหลกศีรษะเพื่อเอาเนื้องอกออก เป็นการรักษาที่นิยมใช้กับผู้ป่วยเนื้องอกสมอง เพื่อเพิ่มคุณภาพชีวิตและลดภาวะแทรกซ้อนแก่ผู้ป่วย ช่วงระยะ 2 - 4 สัปดาห์แรกของการพักฟื้นร่างกาย อาจต้องเผชิญกับปัญหาและความทุกข์ทรมานด้านร่างกาย เช่น อาการอ่อนล้า นอนไม่หลับ และอาการปวด ด้านจิตใจ เช่น เครียด, ซึมเศร้า และวิตกกังวล (Tankumpuan *et al.*, 2015; Armstrong, *et al.*, 2016) ตลอดจนปัญหาความบกพร่องด้านการรู้คิดที่พบได้น้อยกว่าร้อยละ 30 ในผู้ป่วยเนื้องอกในสมองภายหลังการผ่าตัด โดยมีสาเหตุมาจากการผ่าตัดได้มีการทำลายเนื้อสมองบางส่วน รวมถึงเกิดการบวมของสมองบริเวณโดยรอบตำแหน่งที่ผ่าตัด (Johnson *et al.*, 2012) ซึ่งความบกพร่องด้านระบบประสาทการรู้คิดทำให้สูญเสียความตัดสินใจและการปฏิบัติกิจวัตรประจำวัน ความบกพร่องที่เกิดจากด้านร่างกาย ผลของการประสพภาวะดังกล่าวทำให้คุณภาพชีวิตไม่ดีในระยะสั้นหรืออาจจะเป็นระยะยาว (Bunevicius *et al.*, 2014; Back *et al.*, 2014) แต่ในปัจจุบันเทคโนโลยีทางการแพทย์มีส่วนสำคัญในระบบบริการสุขภาพเนื่องจากเทคโนโลยีทางการแพทย์มีการเปลี่ยนแปลงและก้าวหน้าอย่างรวดเร็ว โดยมีประสิทธิผลในการรักษาสูงขึ้น ลดความเสี่ยงของภาวะแทรกซ้อนที่เกิดจากการรักษา ลดระยะเวลาการพักฟื้น โดยเฉพาะกลุ่มผู้ป่วยที่มีโรคทางสมอง อาทิ กลุ่มที่เกิดภาวะความผิดปกติของเส้นเลือดในสมอง กลุ่มโรคเนื้องอกในสมอง กลุ่มโรคกระตุกที่กระจายจากที่อื่นมาสู่สมอง และกลุ่มอาการเกิดการทำงานที่ผิดปกติของสมอง ผู้ป่วยกลุ่มโรคทางสมองจากการมีเนื้องอกในสมองและเส้นเลือดผิดปกติในสมองเหล่านี้ โดยทั่วไปปรับ

การรักษาด้วยวิธีการผ่าตัด ผลหลังการผ่าตัดอาจเกิดอาการข้างเคียงตามมา ได้แก่ มีการทำลายเนื้อเยื่อในส่วนข้างเคียงที่เกิดผลในพื้นที่และเกิดภายหลัง ทั้งแบบชั่วคราวและถาวร ลักษณะทางพยาธิวิทยาพบได้ตั้งแต่มีการบวมของเซลล์ไปจนถึงการตายของเนื้อเยื่อ ส่งผลให้เกิดอาการได้หลายรูปแบบตั้งแต่อาการปวดศีรษะชั่วคราวไปจนถึงอาการทางประสาทวิทยา (Srisubat, A. *et al.*, 2017) จากปัญหาดังกล่าวผู้วิจัยจึงมีความสนใจในการนำทฤษฎีการจำแนกประเภทข้อมูลภาพมาคัดกรองผู้ป่วยเนื้องอกในสมองด้วยภาพ MRI ในประเทศไทย เพื่อศึกษาโอกาสการเป็นโรคเนื้องอกในสมอง และช่วยให้ทีมแพทย์ได้ทำการวางแผนการรักษาจากแพทย์ผู้เชี่ยวชาญระบบประสาทและสมอง นอกจากนี้ยังสามารถนำผลการวิเคราะห์ที่ได้ไปพัฒนาเป็นระบบสารสนเทศสำหรับการคัดกรองผู้ป่วยเนื้องอกในสมองเบื้องต้นก่อนถึงมือแพทย์เพื่อลดภาระของแพทย์ในการวินิจฉัยโรคต่อไป

2. วัตถุประสงค์

1. เพื่อสร้างแบบจำลองสำหรับการคัดกรองผู้ป่วยเนื้องอกในสมองด้วยภาพ MRI
2. เพื่อเปรียบเทียบประสิทธิภาพแบบจำลองที่ใช้สำหรับการคัดกรองผู้ป่วยเนื้องอกในสมองด้วยภาพถ่าย MRI

3. ขอบเขตงานวิจัย

งานวิจัยนี้มีการกำหนดขอบเขตและข้อตกลงเพื่อสร้างความเข้าใจเบื้องต้น ดังนี้

3.1 ข้อมูลที่ใช้ในการวิจัย

ผู้วิจัยได้ใช้ข้อมูลภาพ MRI สำหรับนำมาสร้างแบบจำลองสำหรับการคัดกรองผู้ป่วยเนื้องอกในสมองจำนวนทั้งหมด 253 ภาพ ซึ่งดาวน์โหลดได้จากเว็บไซต์ www.kaggle.com ได้ข้อมูลถูกรวบรวมโดย Chakraborty (2021) ซึ่งถูกจัดเก็บในรูปแบบไฟล์ภาพ

นามสกุล .jpg โดยแบ่งข้อมูลออกเป็น 2 โฟลเดอร์ คือ โฟลเดอร์ No จัดเก็บข้อมูลภาพ MRI ของผู้ที่ไม่เป็นโรคเนื้องอกในสมอง จำนวน 98 ภาพ และโฟลเดอร์ Yes จัดเก็บข้อมูลภาพ MRI ของผู้ป่วยที่เป็นโรคเนื้องอกในสมอง จำนวน 155 ภาพ ซึ่งชุดข้อมูลนี้ Silva (2021) ได้นำข้อมูลภาพ MRI มาศึกษาการตรวจจำการเป็นเนื้องอกในสมองของผู้ป่วย โดยทำนายความน่าจะเป็นของภาพที่ระบุว่ามีโอกาสเป็นเนื้องอกในสมองหรือไม่ เทคนิคนี้เรียกว่าการเรียนรู้แบบถ่ายโอน

3.2 เทคนิคที่ใช้ในงานวิจัย

ในงานวิจัยนี้ผู้วิจัยได้เทคนิคการทำเหมืองข้อมูลภาพ (Image Mining) เพื่อทำการสร้างตัวแบบสำหรับการสร้างแบบจำลองการ คัดกรองผู้ป่วยเนื้องอกในสมอง โดยใช้เทคนิคการจำแนกประเภทข้อมูลภาพ 3 เทคนิค ประกอบด้วย ต้นไม้ป่าสุ่ม (Random Forest) โครงข่ายประสาทเทียม (Neural Network) และการเรียนรู้เชิงลึก (Deep Learning) โดยการทดสอบประสิทธิภาพของการจำแนกประเภทข้อมูลภาพ MRI ใช้ ค่าความแม่นยำ (Accuracy) ค่าประสิทธิภาพโดยรวม (F-measure) ค่าความไว (Sensitivity) และค่าจำเพาะ (Specificity)

3.3 โปรแกรมที่ใช้สำหรับงานวิจัย

ผู้วิจัยใช้โปรแกรม RapidMiner Studio Version 10 เพื่อใช้สำหรับการเตรียมข้อมูลในการวิเคราะห์และการสร้างแบบจำลองสำหรับการคัดกรองผู้ป่วยที่มีโอกาสเป็นโรคเนื้องอกในสมอง รวมไปถึงการเปรียบเทียบแบบจำลองที่ใช้สำหรับการคัดกรองผู้ป่วยเนื้องอกในสมองในครั้งนี้

4. แนวคิดและทฤษฎีที่เกี่ยวข้อง

4.1 เนื้องอกในสมอง (Brain Tumor)

เนื้องอกในสมองเป็นเนื้อเยื่อที่เจริญเติบโตแบบผิดปกติในเซลล์สมอง จนไปกระทบการทำงาน

ของสมองและระบบประสาท เนื้องอกในสมองสามารถแบ่งออกได้เป็นเนื้องอกแบบธรรมดาและเนื้องอกแบบเนื้อร้าย โดยส่วนใหญ่แล้วจะไม่ทราบสาเหตุที่แน่ชัดของการกำเนิดเนื้องอก ผู้ป่วยบางรายอาจพบว่ามีปัจจัยเสี่ยงหรือสาเหตุที่พบในกรรมพันธุ์ อาการเตือนของเนื้องอกในสมอง ได้แก่ อาการที่เกิดจากเนื้องอกที่ลุกลามไปยังพื้นที่บริเวณสมองส่งผลทำให้ระดับความดันของสมองสูงมากขึ้น ผู้ป่วยจะมีอาการปวดบริเวณศีรษะอย่างมาก ตาพร่า อาเจียน เห็นภาพซ้อนและอาการที่เกิดจากเนื้องอกไปกดทับบริเวณเส้นประสาทในบางจุด อาทิ เนื้องอกเกิดในบริเวณใกล้เส้นประสาทที่ทำงานควบคุมแขนขา จะทำให้ผู้ป่วยเกิดอาการแขนขาอ่อนแรง ใบหน้าเบี้ยวขา มีความผิดปกติของการมองเห็น สืบเนื่องมาจากถูกเนื้องอกมากกดทับบริเวณเส้นประสาทของตา เทคนิคการตรวจวินิจฉัยในการหาความผิดปกติของเนื้องอกในสมอง สามารถทำได้โดยการตรวจด้วยคลื่นแม่เหล็กไฟฟ้า หรือเรียกว่า MRI ซึ่งเป็นเทคนิคที่ทำให้การตรวจวินิจฉัยมีความแม่นยำ และวางแผนการรักษาผู้ก่อนที่จะมีลุกลามของเนื้องอก (Sikarin, 2022) เช่นเดียวกับงานวิจัยของ Raza (2021) ที่มีการศึกษาการประมวลผลผลการวินิจฉัยล่วงหน้าโดยการจำแนกภาพ MRI สำหรับการคัดกรองผู้ป่วยเนื้องอก

4.2 การจำแนกประเภทข้อมูลภาพ (Image Classification)


การจำแนกประเภทข้อมูลภาพเป็นการประมวลผลในทางสถิติ เพื่อแยกข้อมูลจุดภาพทั้งหมดที่ประกอบเป็นพื้นที่ศึกษาออกเป็นกลุ่มย่อย โดยใช้ลักษณะทางสถิติเป็นตัวกำหนดความแตกต่างระหว่างกลุ่มจุดภาพ โดยจุดภาพที่ถูกจัดให้อยู่กลุ่มเดียวกันจะมีลักษณะทางสถิติเฉพาะกลุ่มเป็นไปในทิศทางเดียวกัน แต่ละกลุ่มจุดภาพที่จำแนกได้นั้นจะแสดงถึงสิ่งปกคลุมพื้นดินประเภทใดประเภทหนึ่งแตกต่างกันไป โดยมีวัตถุประสงค์เพื่อหาคำตอบว่าภาพนั้นคืออะไร ซึ่งการจำแนกประเภทข้อมูลภาพนี้มีหลายแบบ ซึ่งทำได้ด้วยการสร้างโมเดลขึ้นมา โดยใช้

ข้อมูลภาพที่มีการจำแนกประเภทแล้ว เช่น ภาพของ สัตว์ ภาพของพืช หรือภาพของอวกาศ การจำแนกประเภทข้อมูลภาพนี้มักใช้ในการประมวลผลภาพอัตโนมัติ เช่น การค้นหาภาพ การจัดเก็บภาพ หรือ การแสดงผลภาพอัตโนมัติ การจำแนกประเภทข้อมูลภาพนั้นมีการจำแนกประเภทข้อมูลภาพที่มีการใช้งานอย่างแพร่หลาย เช่น การค้นหาภาพจากกล้องถ่ายรูปของโทรศัพท์มือถือ การจัดเก็บภาพอัตโนมัติในคลังภาพ หรือการแสดงผลภาพอัตโนมัติในหน้าเว็บไซต์ นอกจากนี้ยังมีการใช้งานการจำแนกประเภทข้อมูลภาพในงานวิจัยด้านปัญญาประดิษฐ์ เช่น การจำแนกประเภทของภาพของผู้ใช้งานในเว็บไซต์ หรือการจำแนกประเภทของภาพประกอบบทความในหนังสือพิมพ์ เป็นต้น ซึ่งเทคนิคการจำแนกประเภทข้อมูลภาพที่นิยมใช้ ประกอบด้วย 1) เทคนิค Random Forest เช่นเดียวกันกับของ Yang *et al.* (2017) ได้ทำการวิจัยการจำแนกภาพ MRI ที่ใช้ในการรักษาผู้ป่วยโรคมะเร็งด้วยรังสีโดยใช้เทคนิคต้นไม้ป่าสุ่มเพื่อหาคุณลักษณะทางกายวิภาคเฉพาะของผู้ป่วยและนำมาใช้เป็นลายเซ็นสำหรับแต่ละ voxel คุณสมบัติที่มีประสิทธิภาพและให้ข้อมูลมากที่สุดจะถูกระบุ


โดยใช้การเลือกคุณสมบัติ เพื่อประเมินผลการรักษาของผู้ป่วยรายใหม่ โดยใช้เทคนิคต้นไม้ป่าสุ่มในการจำแนกประเภทรูปภาพเช่นกัน 2) เทคนิค Deep Learning โดยมี Cai, Gao, & Zhao (2020) ได้ทำการวิจัยการจำแนกและการแบ่งภาพทางการแพทย์โดยข้อมูลทางการแพทย์ส่วนใหญ่ประกอบด้วยข้อมูลเวชระเบียนอิเล็กทรอนิกส์ ข้อมูลภาพทางการแพทย์ ข้อมูลยีน ฯลฯ โดยใช้เทคนิค Deep Learning ในการจำแนกประเภทรูปภาพเช่นกัน 3) เทคนิค Neural Network ซึ่งงานของ Mehdy *et al.*, (2017) ได้ทำการวิจัยการจำแนกรูปภาพเพื่อตรวจหาภาระเริ่มต้นในระยะเริ่มต้น โดยใช้เทคนิค Neural Network ในการจำแนกประเภทรูปภาพเช่นกัน

5. วิธีดำเนินงานวิจัย

งานวิจัยสำหรับการสร้างแบบจำลองและการเปรียบเทียบประสิทธิภาพของแบบจำลองสำหรับการคัดกรองผู้ป่วยเนื้องอกในสมองด้วยภาพ MRI ใช้เทคนิคจำแนกประเภทข้อมูลภาพโดยการทำเหมืองข้อมูล โดยมีขั้นตอนการดำเนินงานดังภาพประกอบ 1



ภาพประกอบ 1 แสดงวิธีดำเนินงานวิจัย



ภาพประกอบ 2 แสดงขั้นตอนการทำเหมืองข้อมูล (CRISP-DM)


ผู้วิจัยได้นำข้อมูลมาวิเคราะห์ตามขั้นตอนการจำแนกข้อมูลภาพ (Cross-Industry Standard Process for Data Mining: CRISP-DM) ดังแสดงในภาพประกอบ 2 เช่นเดียวกับงานวิจัยพยากรณ์การเกิดโรคหลอดเลือดในสมอง สำหรับการแบ่งกลุ่มผู้ป่วยโรคหลอดเลือดในสมองโดยอ้างอิงตามกระบวนการมาตรฐานในการทำเหมืองข้อมูล (CRISP-DM) เช่นกัน (Kumjit *et al.*, 2022) ในการสร้างแบบจำลองเพื่อคัดกรองผู้ป่วยที่มีโอกาสการเป็นเนื้องอกในสมองและทำการทดสอบประสิทธิภาพของแบบจำลองโดยมีขั้นตอนการวิเคราะห์ข้อมูลทั้ง 6 ขั้นตอนดังนี้

5.1 ขั้นตอนการทำความเข้าใจปัญหา (Business Understanding)

ผู้วิจัยจัดทำงานวิจัยนี้ขึ้นมาเพื่อศึกษาการคัดกรองผู้ป่วยเนื้องอกในสมองจากภาพ MRI โดยการเปรียบเทียบประสิทธิภาพของเทคนิคเหมืองข้อมูลสำหรับการจำแนกประเภทข้อมูลภาพ โดยพิจารณาว่าเทคนิคใดที่มีความเหมาะสมในการสร้างแบบจำลองในการคัดกรองผู้ป่วยที่จะเกิดโอกาสการเป็นโรคเนื้องอกในสมอง

5.2 การทำความเข้าใจเกี่ยวกับข้อมูล (Data Understanding)

ผู้วิจัยได้ศึกษาและพบว่า มีพบผู้ป่วยโรคเนื้องอกในสมองจำนวนมาก ส่งผลให้แพทย์ไม่เพียงพอต่อการรักษาผู้ป่วยโรคเนื้องอกในสมอง ผู้วิจัยต้องการพัฒนาซอฟต์แวร์ที่เป็นทางเลือกให้กับแพทย์ในการคัดกรองผู้ป่วยเนื้องอกในสมองเบื้องต้น ด้วยการพิจารณาจากภาพ MRI สำหรับการคัดกรองผู้ป่วยโรคเนื้องอกในสมอง แหล่งข้อมูลผู้วิจัยได้เก็บรวบรวมข้อมูลจากเว็บไซต์ www.kaggle.com ซึ่งข้อมูลถูกเผยแพร่โดย Chakrabarty (2021) ซึ่งเป็นชุดข้อมูลจริงของผู้ป่วยเนื้องอกในสมอง ทั้งหมด 253 ภาพ โดยจัดแบ่งเป็น 2 กลุ่ม ได้แก่ กลุ่มที่ป่วยเป็นโรคเนื้องอกในสมองจำนวน 98 ภาพ และกลุ่มของผู้ที่ไม่ได้เป็นเนื้องอกในสมอง จำนวน 155 ภาพ ซึ่งขนาดภาพ MRI มีขนาด 630x630 พิกเซล โดยมีความละเอียดภาพอยู่ที่ 97 dpi และถูกจัดเก็บในรูปแบบไฟล์ภาพนามสกุล .jpg และนำไปใช้สำหรับการวิเคราะห์ข้อมูลต่อไป



ภาพประกอบ 3 ตัวอย่างข้อมูลภาพ MRI ที่นำมาใช้ในการวิเคราะห์ โดยเป็นภาพ MRI ของผู้ป่วย
(a) ที่มีเนื้องอกในสมอง และ (b) ไม่มีเนื้องอกในสมอง

5.3 การเตรียมข้อมูล (Data Preparation)

ผู้วิจัยได้นำเข้าข้อมูลภาพ MRI มาทำการเตรียมข้อมูลให้อยู่ในรูปแบบข้อมูลที่มีโครงสร้างก่อนการวิเคราะห์ด้วยโปรแกรม RapidMiner Studio และทำการสร้างแบบจำลองสำหรับคัดกรองผู้ป่วยเนื้องอกในสมองด้วยเทคนิคการทำเหมืองข้อมูลภาพ โดยผู้วิจัยทำการเก็บภาพไว้ในโฟลเดอร์ No เพื่อจัดเก็บข้อมูลภาพ MRI ของผู้ที่ไม่เป็นโรคเนื้องอกในสมอง จำนวน 98 ภาพ และโฟลเดอร์ Yes เพื่อจัดเก็บข้อมูลภาพ MRI ของผู้ป่วยที่เป็นโรคเนื้องอกในสมอง จำนวน 155 ภาพ โดยภาพ MRI ทุกภาพจะมีขนาดรูปภาพ 630x630 พิกเซล และมีความละเอียดภาพอยู่ที่ 97 dpi ทั้ง 2 โฟลเดอร์ โดยไม่มีการปรับขนาดของภาพในการจำลองโมเดล ตัวอย่างภาพ MRI แสดงดังภาพประกอบ 3

จากนั้นแปลงข้อมูลอยู่ในรูปแบบข้อมูลโครงสร้าง (Structured Data) สำหรับงานวิจัยนี้ ผู้วิจัยได้ใช้การแยกคุณลักษณะโดยธรรมชาติ สำหรับการทำให้เหมือนรูปภาพในระดับสากล (Global Level) เพื่อแยกคุณสมบัติส่วนกลางออกจากรูปภาพ และบ่งบอกถึงความแตกต่างของภาพ ซึ่งเหมาะสำหรับการจำแนกประเภทของภาพและการกำหนดคุณสมบัติของภาพโดยรวม การคำนวณค่าต่างๆ

5.3.1 กำหนดค่าสถิติของรูปภาพ

ใน Global statistics ที่นำไปใช้สำหรับการจำแนกประเภทข้อมูลภาพ โดยใช้ 8 ค่า ได้แก่ ค่าเฉลี่ย (Mean) ค่ามัธยฐาน (Median) ค่าความโด่ง (Kurtosis) ค่าจุดสูงสุด (Peak) ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ค่าความเบ้ (Skewness) ค่าสีเทาขั้นต่ำ (Min Gray Value) และค่าสีเทาสูงสุด (Max Gray Value) แสดงดังตาราง 1


ตาราง 1 ตัวอย่างข้อมูลรูปภาพ MRI ที่ถูกแปลงให้อยู่ในรูปแบบของข้อมูลที่มีโครงสร้าง (Structured Data)

Row No.	Label	KURTOSIS	Max Gray Value	Mean	Median	Minimum Gray	Peak Relative count	Peak	Skewness	Standard Deviation
1	yes	-0.801	255	75.786	79	0	0.083	3	0.507	69.476
2	yes	-0.692	255	109.886	121	11	0.127	27	0.272	64.421
3	yes	3.124	255	51.240	54	0	0.158	2	1.560	57.128
4	yes	0.011	255	74.948	84	0	0.043	12	0.498	53.143
5	yes	-0.382	255	108.255	115	3	0.020	21	0.433	66.249
6	no	4.190	255	26.370	3	0	0.191	0	1.689	35.174
7	no	2.107	255	35.414	32	0	0.314	0	1.245	38.074
8	no	3.237	255	43.916	44	0	0.121	3	1.494	42.579
9	no	-1.425	139	46.699	47	0	0.259	0	0.160	40.330
10	no	-0.504	255	47.028	30	0	0.399	1	0.601	48.261


5.4 การสร้างแบบจำลอง (Modeling)

ขั้นตอนการสร้างแบบจำลองในเปรียบเทียบประสิทธิภาพของเทคนิคการจำแนกประเภทข้อมูลภาพ 3 เทคนิคเพื่อสร้างแบบจำลองสำหรับการคัดกรองผู้ป่วยเนื้องอกในสมองด้วยภาพ MRI โดยใช้โปรแกรม RapidMiner Version 10 (Sukprasert, 2021) ประกอบด้วย 1) เทคนิค Random Forest โดยกำหนดพารามิเตอร์ของเทคนิค Random Forest

เท่ากับ 100 ต้น Maximal depth เท่ากับ 10 เทคนิค 2) Deep Learning กำหนดค่า Hidden layer sizes เท่ากับ 50 ค่า Epsilon เท่ากับ 1.0E-8 และค่า Rho เท่ากับ 0.99 และ 3) เทคนิค Neural Network กำหนดค่า Hidden เท่ากับ 4 ค่า Training cycles เท่ากับ 200 ค่า Learning rate เท่ากับ 0.01 และค่า Momentum เท่ากับ 0.9 ตัวอย่างการกำหนดค่าในโปรแกรม RapidMiner แสดงดังภาพประกอบ 4



ภาพประกอบ 4 การสร้างแบบจำลองและเปรียบเทียบประสิทธิภาพของแบบจำลอง โดยใช้โปรแกรม RapidMiner Studio




ภาพประกอบ 5 การทำงานของเทคนิคต้นไม้ป่าสุ่ม

5.4.1 เทคนิคต้นไม้ป่าสุ่ม (Random Forest)


เทคนิคต้นไม้ป่าสุ่ม เป็นเทคนิคประเภทหนึ่งของเทคนิคต้นไม้ตัดสินใจที่มีลักษณะแบบ Unpruned หรือ Regression Trees ซึ่งถูกสร้างจากการนำข้อมูลไปสุ่มเลือกตัวอย่างข้อมูล หลักการของเทคนิค Random Forest คือ สร้างแบบจำลองจากเทคนิคต้นไม้ตัดสินใจหลายๆ แบบจำลอง (ตั้งแต่ 10 แบบจำลอง ถึง มากกว่า 1,000 แบบจำลอง) โดยแต่ละแบบจำลองจะได้รับชุดข้อมูลไม่เหมือนกัน ซึ่งเป็นข้อมูลย่อยของชุดข้อมูลทั้งหมด เทคนิคต้นไม้ตัดสินใจทำการพยากรณ์และคำนวณผลการพยากรณ์ด้วยการ Vote output ที่ถูกเลือกเทคนิคต้นไม้ตัดสินใจมากที่สุด หรือหาค่า Mean จากผลของแต่ละเทคนิคต้นไม้ตัดสินใจ แบบจำลองใน Random Forest ถือว่าเป็นตัวแบบที่เป็นเทคนิคของการเรียนรู้โดยใช้ข้อมูลจำนวนมากของแบบจำลองที่ไม่สมบูรณ์ แต่ถ้าหากนำเทคนิคต้นไม้ตัดสินใจทำการพยากรณ์ร่วมกันจะได้แบบจำลองรวมที่มีความสมบูรณ์มากขึ้น และมีความแม่นยำกว่าเทคนิคต้นไม้ตัดสินใจที่ทำการพยากรณ์แบบเดี่ยว (Sukprasert, 2021) ภาพการทำงานของเทคนิค Random Forest แสดงดังภาพประกอบ 5

5.4.2 เทคนิคโครงข่ายประสาทเทียม (Artificial Neural Network)

โครงข่ายประสาทเทียม เป็นโมเดลทางคณิตศาสตร์ ที่ประมวลผลสารสนเทศด้วยการคำนวณเพื่อจำลองการทำงานของเครือข่ายประสาทในสมองมนุษย์ ด้วยวัตถุประสงค์ที่จะสร้างเครื่องมือซึ่งมีความสามารถในการเรียนรู้ การจดจำแบบรูป และการทำนายอนาคต แนวคิดเริ่มต้นของเทคนิคนี้ได้มาจากการศึกษาข่ายงานไฟฟ้าในสมองชีวภาพ (Bioelectric Network) จะประกอบด้วยเซลล์ประสาทหรือ “นิวรอน” (Neurons) และจุดประสานประสาท (Synapses) แต่ละเซลล์ประสาทประกอบด้วยปลายในการรับกระแสประสาท เรียกว่า “เดนไดรต์” (Dendrite) ซึ่งเป็น Input และปลายในการส่งกระแสประสาทเรียกว่า “แอกซอน” (Axon) เป็นเหมือน Output ของเซลล์ เซลล์เหล่านี้ทำงานด้วยปฏิกิริยาไฟฟ้าเคมี (Sukprasert, 2021) ภาพการทำงานของเทคนิคโครงข่ายประสาทเทียมแสดงดังภาพประกอบ 6



ภาพประกอบ 6 การทำงานของเทคนิคโครงข่ายประสาทเทียม (Artificial Neural Network)



ภาพประกอบ 7 การทำงานของเทคนิคการเรียนรู้เชิงลึก

5.4.3 เทคนิคการเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้เชิงลึก คือการพัฒนาเทคโนโลยีคอมพิวเตอร์ให้สามารถเลียนแบบการทำงานของมนุษย์ ซึ่ง Deep Learning จะมีกระบวนการคิดคำนวณ คล้ายกับระบบเซลล์ประสาท (Neurons) ของสมองมนุษย์ เรียกว่าโครงข่ายประสาท (Neural Network: NN) (Saisangchan, Chamchong, & Suwannasa, 2022) ข้อดีของ Deep Learning คือมีชั้นโครงข่ายประสาทหลายชั้นเรียกว่า Hidden Layer แสดงดังภาพประกอบ 7 ทำให้โครงข่ายสามารถเรียนรู้ข้อมูลที่ถูกป้อนเข้ามาในเครือข่ายได้ดีขึ้น ซึ่งคำว่า Deep Learning ก็มาจากการใช้โครงข่ายประสาทที่มีจำนวนชั้น Hidden Layer จำนวนมาก

5.5 การประเมินผล (Evaluation)

เมื่อสร้างแบบจำลองเสร็จนำแบบจำลองมาทดสอบประเมินประสิทธิภาพ โดยการแบ่งข้อมูลออกเป็น 2 ส่วน คือวิธีการ Cross validation โดยการแบ่งข้อมูลออกเป็น 10 กลุ่มเท่าๆ กัน (10-fold cross validation) แบ่งเป็นชุดข้อมูลในการสร้างแบบจำลอง (Training Set) และชุดข้อมูลที่ใช้สำหรับทดสอบประสิทธิภาพของแบบจำลอง (Testing Set) โดยการรันโมเดล 30 รอบ ซึ่งค่าที่ใช้วัดประสิทธิภาพในการจำแนกประเภทข้อมูลประกอบด้วย ค่าความแม่นยำ (Accuracy) ค่าประสิทธิภาพโดยรวม (F-measure) ค่าความไว (Sensitivity) และค่าจำเพาะ (Specificity) ดังสมการที่ 1-5 (Lapthanachai *et al.*, 2023)

5.5.1 ค่าความแม่นยำ (Accuracy)

ค่าที่แบบจำลองสามารถพยากรณ์ข้อมูลผู้ป่วยที่เป็นโรคและไม่เป็นโรคได้อย่างถูกต้องต่อข้อมูลทั้งหมด ดังสมการที่ 1

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

5.5.2 ค่าประสิทธิภาพโดยรวม (F-measure)

ค่าที่เกิดจากการเปรียบเทียบระหว่าง ค่า Precision และ ค่า Recall ของแต่ละคลาสเป้าหมาย ดังสมการที่ 2 และ 3

$$\text{F-measure คลาสเป้าหมาย YES} = \frac{(2 * \text{Precision(YES)} * \text{Recall(YES)})}{(\text{Precision(YES)} + \text{Recall(YES)})} \quad (2)$$

$$\text{F-measure คลาสเป้าหมาย NO} = \frac{(2 * \text{Precision(NO)} * \text{Recall(NO)})}{(\text{Precision(NO)} + \text{Recall(NO)})} \quad (3)$$

5.5.3 ค่าความไว (Sensitivity)

ค่าที่แบบจำลองสามารถพยากรณ์ข้อมูลผู้ป่วยที่เป็นโรคได้อย่างถูกต้องต่อผู้ป่วยที่เป็นโรคจริง ดังสมการที่ 4

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (4)$$

5.5.4 ค่าจำเพาะ (Specificity)

ค่าที่แบบจำลองสามารถพยากรณ์ข้อมูลผู้ป่วยที่ไม่เป็นโรคได้อย่างถูกต้องต่อผู้ป่วยที่พยากรณ์ว่าเป็นโรค ดังสมการที่ 5

$$\text{Specificity} = \frac{TN}{TN + FP} \quad (5)$$

โดยที่

True Positive (TP) คือ สิ่งที่พยากรณ์ตรงกับสิ่งที่เกิดขึ้นจริง ในกรณีพยากรณ์ว่า จริง และสิ่งที่เกิดขึ้น คือจริง

True Negative (TN) คือ สิ่งที่พยากรณ์ตรงกับสิ่งที่เกิดขึ้นจริง ในกรณีพยากรณ์ว่า ไม่จริง และสิ่งที่เกิดขึ้น คือ ไม่จริง

False Positive (FP) คือ สิ่งที่พยากรณ์ไม่ตรงกับสิ่งที่เกิดขึ้นจริง คือพยากรณ์ว่า จริง แต่สิ่งที่เกิดขึ้น คือ ไม่จริง

False Negative (FN) คือ สิ่งที่พยากรณ์ไม่ตรงกับสิ่งที่เกิดขึ้นจริงคือพยากรณ์ว่า ไม่จริง แต่สิ่งที่เกิดขึ้น คือ จริง

6. การนำไปใช้งาน (Deployment)

เมื่อทำการวิเคราะห์ข้อมูลโดยใช้เทคนิคการจำแนกข้อมูลภาพ MRI พบว่าเทคนิค Random Forest เป็นเทคนิคที่เหมาะสมในการสร้างแบบจำลองการคัดกรองผู้ป่วยที่มีโอกาสการเป็นโรคเนื้องอกในสมองจากภาพ MRI เพื่อช่วยคัดกรองผู้ป่วยเนื้องอกในสมอง และช่วยวางแผนการรักษาจากแพทย์ผู้เชี่ยวชาญระบบประสาทและสมอง อีกทั้งยังสามารถนำผลการวิเคราะห์ที่ได้ไปพัฒนาเป็นระบบสารสนเทศสำหรับการคัดกรองผู้ป่วยที่มีโอกาสพบเป็นโรคเนื้องอกในสมองเบื้องต้นก่อนถึงมือแพทย์ และลดภาระให้กับแพทย์ ในการวินิจฉัยโรคเนื้องอกในสมองต่อไป

7. ผลการวิเคราะห์

ผู้วิจัยได้นำข้อมูลภาพ MRI เพื่อนำมาสร้างแบบจำลองและเปรียบเทียบประสิทธิภาพของแบบจำลองสำหรับการคัดกรองผู้ป่วยเนื้องอกในสมอง จำนวนข้อมูลทั้งหมด 253 ภาพ โดยใช้ข้อมูลจากเว็บไซต์ www.kaggle.com ซึ่งถูกรวบรวมโดย

Chakrabarty (2021) มาทำการศึกษาตามกระบวนการมาตรฐานการทำเหมืองข้อมูล (CRISP-DM) เพื่อสร้างแบบจำลองการคัดกรองผู้ป่วยโอกาสการเป็นโรคเนื้องอกในสมอง โดยทำการแบ่งข้อมูลออกเป็น 2 ส่วน ด้วยเทคนิคการแบ่งข้อมูลแบบ Cross Validation ซึ่งข้อมูลจะถูกแบ่งออกเป็น 10 ส่วนเท่าๆ กัน (10-Fold Cross Validation) (Klaythong & Srisawat, 2023) เพื่อใช้สำหรับเป็นชุดข้อมูลสอน (Training Set) และชุดข้อมูลทดสอบ (Test Set) โดยใช้เทคนิคการทำเหมืองข้อมูลภาพ 3 เทคนิค ประกอบด้วย เทคนิค Random Forest เทคนิค Deep Learning และเทคนิค Neural Network ทำการรันแบบจำลองจำนวนทั้งสิ้น 30 รอบ ซึ่งอ้างอิงจากทฤษฎีแนวโน้มนำเข้าสู่ศูนย์กลาง (Central Limit Theorem) โดยทฤษฎีกล่าวไว้ว่า ค่าเฉลี่ยของกลุ่มตัวอย่างที่ได้จากการสุ่มมาจากรประชากรที่มีการแจกแจงแบบปกติ จะทำให้กลุ่มตัวอย่าง

มีการแจกแจงแบบปกติตามไปด้วย ถึงแม้ว่าจะมีขนาดเล็กก็ตาม ซึ่งถ้า มีค่าเท่ากับ 30 ก็มากพอที่จะช่วยให้การแจกแจงเป็นปกติได้ (Songhmokholongtun, 2018) จากนั้นทำการคำนวณค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของประสิทธิภาพการจำแนกประเภทข้อมูลภาพทั้ง 3 เทคนิค ดังแสดงในตารางที่ 2 เพื่อเปรียบเทียบประสิทธิภาพของการจำแนกประเภทข้อมูลภาพ MRI สำหรับการคัดกรองผู้ป่วยเนื้องอกในสมอง ด้วยค่าความแม่นยำ ค่าประสิทธิภาพโดยรวม ค่าความไว และค่าจำเพาะ โดยใช้โปรแกรม RapidMiner Studio Version 10 ในการวิเคราะห์ข้อมูลและเปรียบเทียบประสิทธิภาพของแบบจำลอง ซึ่งผลลัพธ์ของประสิทธิภาพการจำแนกประเภทข้อมูลภาพของทั้ง 3 แบบจำลองได้แสดงในตาราง 3 และภาพประกอบ 8

ตาราง 2 แสดงค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของประสิทธิภาพการจำแนกประเภทข้อมูลภาพทั้ง 3 เทคนิค

Classification Performance	Image Classification Techniques					
	Deep Learning		Random Forest		Neural Network	
	$\bar{X}$	S.D.	$\bar{X}$	S.D.	$\bar{X}$	S.D.
Accuracy	73.5810	2.0220	78.5900	1.4500	71.1800	2.8900
F-measure	74.4353	1.8680	76.8200	1.4500	70.5000	0.0000
Sensitivity	79.2513	2.6228	72.0800	2.8900	69.7200	1.4500
Specificity	68.3736	3.6464	85.1900	4.4300	72.4200	2.8900

ตาราง 3 การเปรียบเทียบค่าทดสอบประสิทธิภาพของการจำแนกประเภทข้อมูลภาพ MRI สำหรับการคัดกรองผู้ป่วยเนื้องอกในสมอง


Image Classification Techniques	Classification Performance			
	Accuracy	F-measure	Sensitivity	Specificity
Deep Learning	69.35%	68.77%	73.33%	65.17%
Random Forest*	76.31%	73.48%	70.14%	82.69%
Neural Network	72.81%	70.36%	70.69%	74.61%

* คือ เทคนิคที่มีความเหมาะสมสำหรับนำมาสร้างตัวแบบการพยากรณ์โอกาสการเป็นโรคเนื้องอกในสมองด้วยภาพ MRI
หมายเหตุ - เทคนิค Random Forest ค่า Maximal Depth ที่ทำให้ประสิทธิภาพสูงสุดเท่ากับ 8

จากตาราง 2 พบว่าเทคนิคที่ให้ค่าเฉลี่ยความแม่นยำสูงสุดคือ เทคนิค Random Forest ซึ่งมีค่าเท่ากับ 78.59% รองลงมาคือเทคนิค Deep Learning มีค่าเท่ากับ 73.58% เทคนิคที่ให้ค่าเฉลี่ยความแม่นยำที่สุดคือ เทคนิค Neural Network ซึ่งมีค่าเท่ากับ 71.18% เทคนิคที่ให้ค่าเฉลี่ยประสิทธิภาพโดยรวมสูงสุดคือ เทคนิค Random Forest ซึ่งมีค่าเท่ากับ 76.82% รองลงมาคือเทคนิค Deep Learning มีค่าเท่ากับ 74.43% และเทคนิคที่ให้ค่าเฉลี่ยประสิทธิภาพโดยรวมต่ำที่สุดคือ เทคนิค Neural Network ซึ่งมีค่าเท่ากับ 70.50% เทคนิคที่ให้ค่าเฉลี่ยความไวสูงสุดคือ เทคนิค Deep Learning ซึ่งมีค่าเท่ากับ 79.25% รองลงมาคือ เทคนิค Neural Network มีค่าเท่ากับ 72.08% และเทคนิคที่ให้ค่าเฉลี่ยความไวน้อยที่สุดคือ เทคนิค Neural Network ซึ่งมีค่าเท่ากับ 69.72% และเทคนิคที่ให้ค่าเฉลี่ยจำเพาะสูงสุดคือ เทคนิค Random Forest ซึ่งมีค่าเท่ากับ 85.19% รองลงมา

คือ เทคนิค Neural Network มีค่าเท่ากับ 72.42% และเทคนิคที่ให้ค่าเฉลี่ยจำเพาะน้อยที่สุดคือ เทคนิค Deep Learning ซึ่งมีค่าเท่ากับ 68.37% ตามลำดับ

จากตาราง 3 พบว่าเทคนิค Random Forest สร้างแบบจำลองที่มีค่าในการพยากรณ์สูงที่สุด โดยให้ค่าความแม่นยำ เท่ากับ 76.31% ค่าประสิทธิภาพโดยรวม เท่ากับ 73.48% ค่าความไว เท่ากับ 70.14% และค่าจำเพาะ เท่ากับ 82.69% รองลงมา เทคนิค Neural Network โดยให้ค่าค่าความแม่นยำ เท่ากับ 72.81% ค่าประสิทธิภาพโดยรวม เท่ากับ 70.36% ค่าความไว เท่ากับ 70.69% และค่าจำเพาะ เท่ากับ 74.61% และน้อยที่สุดในเทคนิค Deep Learning โดยให้ค่าค่าความแม่นยำ เท่ากับ 69.35% ค่าประสิทธิภาพโดยรวม เท่ากับ 68.77% ค่าความไว เท่ากับ 73.33% และค่าจำเพาะ เท่ากับ 65.17% และกราฟเปรียบเทียบประสิทธิภาพของแบบจำลองแสดงดังภาพประกอบ 8



ภาพประกอบ 8 การเปรียบเทียบประสิทธิภาพของแบบจำลอง

8. อภิปรายผลการทำวิจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาสร้างแบบจำลองและเปรียบเทียบประสิทธิภาพของแบบจำลองเพื่อใช้สำหรับการคัดกรองผู้ป่วยโอกาสการเป็นโรคเนื้องอกในสมองด้วยภาพ MRI ผู้วิจัยได้นำข้อมูลภาพ MRI ทั้งหมด 253 ภาพ มาวิเคราะห์ตามกระบวนการทำเหมืองข้อมูล และนำเทคนิคการจำแนกประเภทข้อมูลภาพทั้ง 3 เทคนิค ได้แก่ เทคนิค Random Forest เทคนิค Deep Learning และเทคนิค Neural Network จากนั้นผู้วิจัยได้ทำการเพิ่มประสิทธิภาพของการจำแนกประเภทข้อมูลด้วยเทคนิค Optimize Parameters สำหรับการหาค่าที่ดีที่สุด (Level of Random Forest Maximal Depth) หาจำนวนต้นไม้ที่เหมาะสมที่สุดสำหรับเทคนิค Random Forest และทดสอบประสิทธิภาพของการจำแนกประเภทข้อมูลภาพของแบบจำลองโดยใช้ค่าความแม่นยำ ค่าประสิทธิภาพโดยรวม ค่าความไว และค่าจำเพาะ เพื่อหาแบบจำลองที่เหมาะสมที่สุดสำหรับการนำไปสร้างตัวแบบในการพยากรณ์ ผลการวิจัยพบว่าเทคนิค Random Forest ให้ค่าความแม่นยำสูงที่สุดถึง 76.31% ค่าประสิทธิภาพโดยรวมเท่ากับ 73.48% ค่าความไวเท่ากับ 70.14% และค่าจำเพาะเท่ากับ 82.69% ซึ่งสอดคล้องกับงานวิจัยของ Yang, Islam & Khaled (2019) ที่ได้ศึกษาการจำแนกประเภทการถ่ายภาพด้วยคลื่นสนามแม่เหล็กของการเชื่อมต่อการทำงานสำหรับความผิดปกติของสเปกตรัมออทิสติก โดยใช้ชุดข้อมูล Multisite ABIDE Dataset โดยได้ทำการจำแนกผู้ป่วยโรคออทิสติกสเปกตรัม (ASD) และผู้เข้าร่วมการพัฒนาโดยทั่วไป (TD) โดยใช้ข้อมูล MRI (rs-fMRI) ด้วยเทคนิค Random Forest ซึ่งผลการวิเคราะห์ของงานวิจัยดังกล่าวได้ค่าความแม่นยำที่ดีที่สุด คือ 71.98% อีกทั้งยังสอดคล้องกับงานวิจัยของ Mehdy *et al.* (2017) ซึ่งใช้เทคนิค Neural Network เพื่อประมวลผลภาพเพื่อตรวจหาภาวะเรื้อรังเต้านมในระยะเริ่มต้น ได้ค่าการลงมาคือ 72.64 และ

ผลงานวิจัยของ Cai, Gao, & Zhao (2020) ทำการวิจัยโดยใช้เทคนิค Deep Learning ในการจำแนกและแบ่งภาพทางการแพทย์ ได้ค่าน้อยที่สุด คือ 70.20% ดังนั้นเทคนิค Random Forest จึงเป็นเทคนิคที่มีความเหมาะสมที่สุดในการนำมาสร้างแบบจำลองการคัดกรองผู้ป่วยโอกาสการเป็นโรคเนื้องอกในสมองในครั้งนี้ เพื่อช่วยให้แพทย์สามารถคัดกรองผู้ป่วยที่อาจจะเป็นโรคเนื้องอกในสมองได้แม่นยำยิ่งขึ้น รวมทั้งหาแนวทางการวางแผนการรักษาจากแพทย์ผู้เชี่ยวชาญระบบประสาทและสมองได้อย่างถูกต้อง

กิตติกรรมประกาศ

งานวิจัยฉบับนี้สำเร็จลุล่วงไปด้วยดีโดยได้รับความอนุเคราะห์ข้อมูลของ Mr.Navoneel Chakrabarty ที่ได้เก็บรวมไว้ในเว็บไซต์ www.kaggle.com และขอขอบพระคุณคณะกรรมการบัญชีและการจัดการ มหาวิทยาลัยมหาสารคาม ที่ให้การสนับสนุนในการทำวิจัยครั้งนี้

เอกสารอ้างอิง

- Armstrong, T. S., *et al.* (2016). The symptom burden of primary brain tumors: evidence for a core set of tumor- and treatment-related symptoms. *Neuro-Oncology*, 18(2), 252-260. <https://doi.org/10.1093/neuonc/nov166>
- Back, M., Back, E., Kastelan, M., & Wheeler, H. (2014). Cognitive deficits in primary brain tumours: A framework for management and rehabilitation. *Journal of Cancer Therapy*, 5(1), 74-81. <http://dx.doi.org/10.4236/jct.2014.51010>

- Bunevicius, A., Deltuva, V., Tamasauskas, S., Tamasauskas, A., Laws, E.R., Jr, & Bunevicius, R. (2013). Low triiodothyronine syndrome as a predictor of poor outcomes in patients undergoing brain tumor surgery: A pilot study. *Journal of Neurosurgery*, 118(6), 1279-1287. <https://doi.org/10.3171/2013.1.JNS121696>
- Bunevicius, A., Tamasauskas, S., Deltuva, V., Tamasauskas, A., Radziunas, A., & Bunevicius, R. (2014). Predictors of health-related quality of life in neurosurgical brain tumor patients: focus on patient-centered perspective. *Acta Neurochirurgica*, 156, 367-374. <https://doi.org/10.1007/s00701-013-1930-7>
- Cai, L., Gao, J., & Zhao, D. (2020). A review of the application of deep learning in medical image classification and segmentation. *Annals of Translational Medicine*. 8(11), 713. <https://doi.org/10.21037/atm.2020.02.44>
- Chakrabarty, N. (2021). *Brain MRI images for brain tumor detection*. Retrieved 8 December 2022. Retrieved from <https://www.kaggle.com/datasets/navoneel/brain-mri-images-for-brain-tumor-detection>
- Johnson, D.R., Sawyer, A.M., Meyers, C.A., O'Neill, B.P., & Wefel, J.S. (2012). Early measures of cognitive function predict survival in patients with newly diagnosed glioblastoma. *Neuro-Oncology*, 14(6), 808-816. <https://doi.org/10.1093/neuonc/nos082>
- Klaythong, T. & Srisawat, C. (2023). Forecasting dropout of undergraduates Pibulsongkram Rajabhat University with data mining technique. *Journal of Applied Informatics and Technology*, 5(1), 1-17. <https://doi.org/10.14456/jait.2023.1> [In Thai]
- Kumjit, K., Jaikoomkao, D., Phumirang, W., Sattanako, A., & Sukpraser, A. (2022). The efficiency of data mining technique for the prognosis of cerebrovascular disease. *Journal of Applied Informatics and Technology*, 4(2), 87-98. <https://doi.org/10.14456/jait.2022.7> [In Thai]
- Lapthanachai, N., Chomthong, A., Waijanya, S., & Promrit, N. (2023). Classification of nail abnormalities using convolutional neural network. *Journal of Applied Informatics and Technology*, 5(1), 18-35. <https://doi.org/10.14456/jait.2023.2> [In Thai]

- Mehdy, M.M., Ng, P.Y., Shair, E. F., Md Saleh, N.I., & Gomes, C. (2017). Artificial neural networks in image processing for early detection of breast cancer. *Computational and Mathematical Methods in Medicine*, 2017, 1-15. <https://doi.org/10.1155/2017/2610628>
- Raza, S. (2021). *Brain tumor detector*. Retrieved 8 December 2022. Retrieved from <https://www.kaggle.com/code/saharraza/preprocessing/notebook>.
- Saisangchan, U., Chamchong, R., & Suwannasa, A. (2022). Analysis of lime leaf disease using deep learning. *Journal of Applied Informatics and Technology*, 4(1), 71-86. <https://doi.org/10.14456/jait.2022.6> [In Thai]
- Siegel, R.L., Miller, K.D., & Jemal, A. (2018). Cancer statistics, 2018. *CA: A Cancer Journal for Clinicians*. 68(1), 7-30. <https://doi.org/10.3322/caac.21442>
- Sikarin. (2022). *ปวดหัวบ่อย เห็นภาพซ้อน สัญญาณเตือนเสี่ยงเนื้องอกในสมอง [Frequent headaches, double vision, warning signs of brain tumor]*. Retrieved 8 December 2022. Retrieved from <https://www.sikarin.com/health/เนื้องอกในสมอง-brain-tumor> [In Thai]
- Silva, D. (2021). *Brain tumor detector*. Retrieved 9 December 2022. Retrieved from <https://www.kaggle.com/code/diegossilvadefrana/brain-tumor-detector/notebook>.
- Songhmokholongtun. (2018). *Central Limit Theorem (CLT) สำหรับนักลงทุน [Central Limit Theorem (CLT) for investors]*. Retrieved from 25 November 2022. Retrieved from <https://songhmokholongtun.com>. [In Thai]
- Srisubat, A. et al. (2017). Effectiveness of gamma knife for patients with brain tumor: A systematic review. *Journal of the Department of Medical Services*. 42(4), 64-69. <http://www.imrta.dms.moph.go.th/imrta/images/65-70%20From4.pdf> [In Thai]
- Sukprasert, A. (2021). *คู่มือการทำเหมืองข้อมูลด้วยโปรแกรม RapidMiner Studio [Guide to mining with RapidMiner Studio]*. Mahasakham: Mahasarakham Business School, Mahasarakham University. [In Thai]
- Tankumpuan, T., Utriyaprasit, K., Chayaput, P., & Itthimathin, P. (2015). Predictors of physical functioning in postoperative brain tumor patients. *The Journal of Neuroscience Nursing*, 47(1), E11-E21. <https://doi.org/10.1097/JNN.0000000000000113>
- Yang, X. et al. (2017). Pseudo CT estimation from MRI using patch-based random forest. *Proceedings of SPIE—the International Society for Optical Engineering*, 10133, 101332Q. <https://doi.org/10.1117/12.2253936>

Yang, X., Islam, M.S., & Khaled, A.M. (2019). Functional connectivity magnetic resonance imaging classification of autism spectrum disorder using the multisite ABIDE dataset, *IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, Chicago, IL, USA, 2019, pp. 1-4. <https://doi.org/10.1109/BHI.2019.8834653>