

Received: 23 เม.ย. 2567

Revised: 14 ก.พ. 2568

Accepted: 17 ก.พ. 2568

การพัฒนาตัวแบบคัดกรองโรคที่ออกโซพลาสโมซิสจากภาพถ่ายจอประสาทตาด้วย
เทคนิคเหมืองข้อมูลภาพ

The Development of a Screening Model for Toxoplasmosis from Fundus
Photography using Image Mining Techniques

อนุปงศ์ สุขประเสริฐ^{1*}, พงศกร เทนสันเทียะ¹, ศิวกร มีสนม¹ และ ชีระวัฒน์ ภูทองชัย¹

¹สาขาคอมพิวเตอร์ธุรกิจ คณะการบัญชีและการจัดการ มหาวิทยาลัยมหาสารคาม

Anupong Sukprasert^{1*}, Pongsakorn Tensanthia¹, Siwakorn Meesanome¹ and
Teerawat Phukongchai¹

¹Major of Business Computer, Mahasarakham Business School,
Mahasarakham University, Mahasarakham

*Corresponding author: anupong.s@acc.msu.ac.th

Abstract

This research aimed to develop and evaluate the performance of screening models for toxoplasmosis using fundus photography. Data analysis was conducted following the Cross-Industry Standard Process for Data Mining (CRISP-DM) methodology. Three image classification techniques were utilized: Decision Tree, Support Vector Machine (SVM), and k-Nearest Neighbors (k-NN). The hyperparameters of each technique were tuned to optimize model performance. The models were evaluated using Accuracy, F-measure, Sensitivity, and Specificity. Results revealed that the Decision Tree showed the best performance in image classification, with an Accuracy of 90.74%, F-measure of 83.15%, Sensitivity of 85.55%, and Specificity of 92.45%. Thus, it is suitable for developing a model for screening patients with toxoplasmosis from fundus images. The results of this study can support physicians' decision-making in diagnosing and screening patients with toxoplasmosis more accurately and predicting the risk of disease occurrence or complications.

Keywords: Image Mining; Toxoplasmosis; Decision Tree; Support Vector Machine;
K-Nearest Neighbors

บทคัดย่อ

การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อสร้างตัวแบบและเปรียบเทียบประสิทธิภาพของตัวแบบสำหรับคัดกรองผู้ป่วยโรคท็อกโซพลาสโมซิส โดยใช้ข้อมูลจากภาพถ่ายจอประสาทตา มาวิเคราะห์ตามกระบวนการมาตรฐานในการทำเหมืองข้อมูล (CRISP-DM) โดยใช้เทคนิคการจำแนกประเภทข้อมูลภาพทั้ง 3 เทคนิค ประกอบด้วย เทคนิคต้นไม้ตัดสินใจ (Decision Tree) เทคนิคซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) และเทคนิคเพื่อนบ้านใกล้ที่สุด (k-Nearest Neighbors: k-NN) หลังจากนั้นวัดประสิทธิภาพของตัวแบบโดยใช้ค่าความแม่นยำ (Accuracy) ค่าประสิทธิภาพโดยรวม (F-Measure) ค่าความไว (Sensitivity) และค่าจำเพาะ (Specificity) ผลการวิจัยพบว่า เทคนิคที่ให้ประสิทธิภาพของการจำแนกประเภทข้อมูลภาพที่ดีที่สุด คือ เทคนิคต้นไม้ตัดสินใจ โดยมีค่าความแม่นยำ เท่ากับ 91.10% ค่าประสิทธิภาพโดยรวม เท่ากับ 93.71% ค่าความไว เท่ากับ 91.51% และค่าจำเพาะ เท่ากับ 90.00% จึงเป็นเทคนิคที่มีความเหมาะสมสำหรับนำไปสร้างตัวแบบสำหรับคัดกรองผู้ป่วยโรคท็อกโซพลาสโมซิสจากภาพถ่ายจอประสาทตา ซึ่งผลการวิเคราะห์ข้อมูลจากงานวิจัยนี้สามารถนำไปสนับสนุนการตัดสินใจของแพทย์สำหรับการวินิจฉัยคัดกรองผู้ป่วยโรคท็อกโซพลาสโมซิสที่มีความแม่นยำมากยิ่งขึ้นและยังสามารถคาดการณ์ความเสี่ยงของการเกิดโรคหรือภาวะแทรกซ้อนอื่นๆ

คำสำคัญ: การทำเหมืองข้อมูลภาพ; โรคท็อกโซพลาสโมซิส; เทคนิคต้นไม้ตัดสินใจ; เทคนิคซัพพอร์ตเวกเตอร์แมชชีน; เทคนิคเพื่อนบ้านใกล้ที่สุด

1. บทนำ

โรคท็อกโซพลาสโมซิส (Toxoplasmosis) เป็นการติดเชื้อปรสิตที่เกิดจากเชื้อ *Toxoplasma gondii* ซึ่งสามารถพบได้ในสัตว์เลี้ยงลูกด้วยนมและสัตว์ปีก การติดเชื้อสามารถเกิดขึ้นได้หลายวิธี เช่น การรับประทานอาหารที่ปนเปื้อนไข่ของเชื้อ การสัมผัสกับอุจจาระของสัตว์ที่ติดเชื้อ และการสัมผัสกับน้ำหรือดินที่ปนเปื้อนไข่ของเชื้อโรคท็อกโซพลาสโมซิสสามารถส่งผลกระทบต่อระบบอวัยวะต่างๆ ของร่างกาย โดยอาการที่พบบ่อย ได้แก่ ไข้ ปวดศีรษะ ปวดกล้ามเนื้อ อ่อนเพลีย ตาพร่ามัว และอาจรุนแรงถึงขั้นเสียชีวิตได้ โดยเฉพาะในผู้ป่วยที่ภูมิคุ้มกันบกพร่อง เช่น หญิงตั้งครรภ์ ผู้ป่วยเอดส์ เป็นต้น การตรวจวินิจฉัยโรคท็อกโซพลาสโมซิสสามารถทำได้หลายวิธี เช่น การตรวจเลือด การตรวจน้ำไขสันหลัง การตรวจคัดกรองโรคด้วยถ่ายภาพคลื่นสนามแม่เหล็ก (Magnetic Resonance Imaging: MRI) และการตรวจภาพถ่ายจอประสาทตา เป็นวิธีที่ใช้ในการตรวจวินิจฉัยโรคท็อกโซพลาสโมซิส โดยแพทย์จะตรวจดูร่องรอยโรคที่อาจเกิดจากการติดเชื้อ เช่น รอยโรคสีขาวหรือสีเหลืองที่บริเวณจอประสาทตา จากปัญหาดังกล่าว ผู้วิจัยจึงสนใจพัฒนาตัวแบบสำหรับคัดกรองผู้ป่วยโรคท็อกโซพลาสโม

ซิสจากภาพถ่ายจอประสาทตาโดยใช้เทคนิคเหมือนข้อมูลภาพ ซึ่งเป็นแนวทางที่มีศักยภาพในการเพิ่มประสิทธิภาพการคัดกรองผู้ป่วยและลดค่าใช้จ่ายในการตรวจวินิจฉัยโรค เทคนิคเหมือนข้อมูลภาพนี้ใช้สำหรับจำแนกและแยกแยะข้อมูลภาพออกเป็นกลุ่มต่าง ๆ โดยตัวแบบจะเรียนรู้จากข้อมูลตัวอย่างที่ใช้ในการฝึกสอน ทั้งนี้ ผู้วิจัยได้นำทฤษฎีการประมวลผลภาพมาประยุกต์ใช้เพื่อวิเคราะห์ภาพถ่ายจอประสาทตาในการพัฒนาตัวแบบคัดกรองโรคที่ออกโซพลาสโมซิสให้มีประสิทธิภาพและความแม่นยำยิ่งขึ้น ในงานวิจัยนี้ได้ใช้เทคนิคเหมือนข้อมูลภาพ 3 เทคนิค ได้แก่ เทคนิคต้นไม้ตัดสินใจ (Decision Tree) เทคนิคซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) และเทคนิคเพื่อนบ้านใกล้ที่สุด (k-Nearest Neighbors) จากนั้นได้เปรียบเทียบประสิทธิภาพของตัวแบบที่พัฒนาขึ้นโดยใช้เกณฑ์ 4 ประการ ได้แก่ ค่าความแม่นยำ (Accuracy) ค่าประสิทธิภาพโดยรวม (F-Measure) ค่าความไว (Sensitivity) และค่าจำเพาะ (Specificity) เพื่อเลือกเทคนิคที่เหมาะสมที่สุดสำหรับการพัฒนาตัวแบบคัดกรองผู้ป่วย นอกจากนี้ งานวิจัยยังมุ่งเน้นการต่อยอดสู่การพัฒนาระบบสารสนเทศสำหรับคัดกรองผู้ป่วย โดยผสานข้อมูลจากภาพถ่ายจอประสาทตาและวิธีวินิจฉัยอื่น ๆ เพื่อสนับสนุนวงการแพทย์ให้สามารถวินิจฉัยโรคที่ออกโซพลาสโมซิสได้อย่างรวดเร็วและแม่นยำยิ่งขึ้น

2. วิธีดำเนินการ

การวิจัยเพื่อสร้างตัวแบบสำหรับคัดกรองโรคที่ออกโซพลาสโมซิสด้วยเทคนิคเหมือนข้อมูลภาพได้ดำเนินการโดยอ้างอิงกระบวนการมาตรฐาน (Cross-Industry Standard Process for Data Mining: CRISP-DM) ซึ่งประกอบด้วย 6 ขั้นตอน ดังนี้ (อนุพงศ์ สุขประเสริฐ, 2564)


2.1 การทำความเข้าใจกับธุรกิจ (Business Understanding)

ปัจจุบัน คนไทยนิยมเลี้ยงสัตว์เลี้ยงไว้ในบ้านเป็นจำนวนมาก ข้อมูลจากมหาวิทยาลัยมหิดลระบุว่า ผู้คนในปัจจุบันนิยมเลี้ยงสัตว์มากที่สุด ได้แก่ อันดับ 1 สุนัข คิดเป็น 40.4% อันดับ 2 แมว คิดเป็น 37.1% และอันดับ 3 สัตว์เอ็กโซติก คิดเป็น 22.6% (วรณรัตน์ คัทมาตย์, 2566) โดยสัตว์เหล่านี้อาจเป็นพาหะของเชื้อ *Toxoplasma gondii* ซึ่งเป็นโปรโตซัวในกลุ่ม coccidia และเป็นสาเหตุของโรคที่ออกโซพลาสโมซิส อันเป็นโรคจากสัตว์ที่สามารถแพร่สู่คนได้ ผู้วิจัยได้ศึกษาข้อมูลเกี่ยวกับการเกิดโรคที่ออกโซพลาสโมซิส และพบปัญหาที่เกิดขึ้นจริงว่า คนส่วนใหญ่มักไม่ทราบถึงปัจจัยเสี่ยงของโรคนี้ อีกทั้งมักละเลยการตรวจเช็คสุขภาพ ส่งผลให้โรคถูกตรวจพบในระยะวิกฤต นอกจากนี้ พฤติกรรมการใช้ชีวิตของแต่ละบุคคลยังมีความแตกต่างกัน ส่งผลต่อโอกาสในการติดเชื้อ ปัจจุบัน เทคโนโลยีทางการแพทย์มีการพัฒนาอย่างต่อเนื่อง โดยเฉพาะเทคนิคการตรวจวินิจฉัยโรคผ่านภาพถ่ายจอประสาทตา (fundus images) ซึ่งเป็นวิธีที่มีประสิทธิภาพสูงในการตรวจจับความผิดปกติจากโรคที่ออกโซพลาสโมซิส อย่างไรก็ตาม การวินิจฉัยด้วยตาเปล่าของแพทย์ยังคงมีข้อจำกัด ทั้งในเรื่องของเวลา ความละเอียดของภาพ และความเชี่ยวชาญเฉพาะทาง ส่งผลให้

เกิดความจำเป็นในการพัฒนาเครื่องมือสนับสนุนการวินิจฉัยที่มีความแม่นยำและรวดเร็วยิ่งขึ้น การทำเหมืองข้อมูลภาพ (image data mining) เป็นเทคนิคที่สามารถประมวลผลข้อมูลขนาดใหญ่และซับซ้อน เช่น ภาพถ่ายจอประสาทตา โดยอาศัยกระบวนการวิเคราะห์เชิงลึก (deep learning) ร่วมกับเทคนิคการจำแนกประเภท (classification algorithms) เพื่อค้นหาแบบแผนที่ซับซ้อนของโรคจากภาพถ่าย ด้วยเหตุนี้ ผู้วิจัยจึงให้ความสนใจนำเทคนิคดังกล่าวมาสร้างตัวแบบ เปรียบเทียบประสิทธิภาพของตัวแบบ และพัฒนาตัวแบบให้สามารถจำแนกประเภทโรคที่ออกโซพลาสโมซิสจากภาพถ่ายจอประสาทตาได้อย่างแม่นยำ เพื่อใช้เป็นแนวทางในการวางแผนการรักษาและการป้องกันโรคในอนาคต

2.2 การทำความเข้าใจเกี่ยวกับข้อมูล (Data Understanding)

ผู้วิจัยได้รวบรวมข้อมูลที่เกี่ยวข้องเพื่อใช้ในการสร้างตัวแบบการคัดกรองผู้ป่วยโรคที่ออกโซพลาสโมซิส ด้วยเทคนิคการทำเหมืองข้อมูลภาพ ซึ่งเป็นข้อมูลจริงของภาพถ่ายจอประสาทตา ที่ได้จาก Dataset of fundus images for the diagnosis of ocular toxoplasmosis ชุดข้อมูลนี้สร้างโดย Cardozo, Olivia, et. Al. (2023) ซึ่งถูกรวบรวมไว้ในเว็บไซต์ www.kaggle.com และสามารถเข้าถึงได้อย่างเปิดเผย ชื่อชุดข้อมูล “Ocular Toxoplasmosis” จำนวน 411 ภาพ โดยแบ่งข้อมูลเป็น 2 โฟลเดอร์ ได้แก่ โฟลเดอร์ Diseased ใช้สำหรับการจัดเก็บข้อมูลภาพถ่ายจอประสาทตาของผู้ป่วยเป็นโรคที่ออกโซพลาสโมซิส จำนวน 279 ภาพ และโฟลเดอร์ Healthy สำหรับการจัดเก็บข้อมูลภาพถ่ายจอประสาทตาของคนปกติ จำนวน 132 ภาพ รูปทั้งหมดมีขนาด 2124 x 2056 pixels และขนาด 1536 x 1152 จัดอยู่ในรูปแบบไฟล์ JPG ดังแสดงในภาพที่ 1



ภาพที่ 1 ตัวอย่างภาพถ่ายจอประสาทตาที่นำมาใช้ในการวิเคราะห์

จาก Dataset of fundus images for the diagnosis of ocular toxoplasmosis. (Cardozo, Olivia, et. al., 2023)

2.3 การเตรียมข้อมูล (Data Preparation)

ผู้วิจัยได้ดำเนินการเตรียมข้อมูลก่อนการวิเคราะห์ เพื่อให้เกิดความน่าเชื่อถือและคุณภาพของข้อมูลที่จะนำมาใช้ในการวิเคราะห์ ซึ่งในงานวิจัยนี้ได้แบ่งการเตรียมข้อมูล 2 ขั้นตอน ดังนี้

2.3.1 การคัดเลือกรูปภาพ (Data Selection) โดยผู้วิจัยได้ทำการคัดเลือกรูปภาพที่มีขนาด 2124×2056 pixels เนื่องจากภาพที่มีขนาดใหญ่จะมีผลต่อประสิทธิภาพการจำแนกประเภทข้อมูลภาพ จากนั้นนำเข้าสู่ข้อมูลภาพเพื่อนำมาวิเคราะห์ด้วยโปรแกรม RapidMiner Studio version 10 จำนวนทั้งสิ้น 292 ภาพ โดยแบ่งข้อมูลออกเป็น 2 โฟลเดอร์ย่อย ได้แก่ โฟลเดอร์ Diseased สำหรับการจัดเก็บข้อมูลภาพถ่ายจอประสาทตาของผู้ป่วยเป็นโรคที่อกโซพลาสโมซิส จำนวน 212 ภาพ และโฟลเดอร์ Healthy สำหรับการจัดเก็บข้อมูลภาพถ่ายจอประสาทตาของคนปกติ จำนวน 80 ภาพ

2.3.2 การแปลงข้อมูล (Data Transformation) ให้อยู่ในรูปแบบข้อมูลที่มีโครงสร้าง (Structured Data) สำหรับงานวิจัยนี้ผู้วิจัยได้ใช้การแยกคุณลักษณะโดยธรรมชาติ สำหรับการทำให้เหมือนข้อมูลภาพในระดับสากล (Global Level) เพื่อแยกคุณสมบัติส่วนกลางออกจากรูปภาพ และบ่งบอกถึงความแตกต่างของภาพ ซึ่งเหมาะสำหรับการจำแนกประเภทของภาพและการกำหนดคุณสมบัติของภาพโดยรวม การคำนวณค่าต่างๆ จากรูปภาพแบบโหมดระดับสีเทา (Grayscale) ซึ่งในงานวิจัยนี้จะทำการแยกคุณสมบัติของภาพทั้งหมดโดยใช้ค่าคุณสมบัติทั้ง 8 ค่า ได้แก่ ค่าเฉลี่ย (Mean) ค่ามัธยฐาน (Median) ค่าขั้นต่ำของระดับสีเทา (Minimum Gray Value) ค่าสูงสุดของระดับสีเทา (Maximum Gray Value) ค่ามาตรฐานสำหรับแกน X (Normalized X) ค่ามาตรฐานสำหรับแกน Y (Normalized Y) ค่าส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) และความคมของพิกเซลสีขาว (Edginess Global statistics) โดยมีการนำโปรแกรม RapidMiner Studio มาใช้สำหรับการทำให้เหมือนข้อมูลภาพ การแบ่งชุดข้อมูลนี้ดำเนินการแบบสุ่ม (Random Sampling) เพื่อให้การกระจายของข้อมูลมีความสมดุลในทั้งสองชุด และลดโอกาสที่จะเกิดอคติจากการแบ่งข้อมูล โดยในงานวิจัยนี้ได้ใช้วิธีการประเมินแบบ Cross-Validation จำนวน 10 ส่วน (10-Folds Cross-Validation) เพื่อเพิ่มความน่าเชื่อถือในผลลัพธ์การวิเคราะห์ โดยการแปลงจากข้อมูลรูปภาพให้เป็นข้อมูลที่มีโครงสร้าง ซึ่งใช้ส่วนขยาย Image mining Extension เพื่อทำการแยกคุณลักษณะ ดังตารางที่ 1


ตารางที่ 1 ตัวอย่างข้อมูลภาพจอประสาทตาที่ถูกแปลงให้อยู่ในรูปแบบของข้อมูลที่มีโครงสร้าง (Structured Data)

Row No.	Label	Mean	Median	Minimum	Maximum	Normalized X	Normalized Y	Standard	Edginess
1	Diseased	159.977	161.000	20.000	255.000	0.507	0.506	27.943	0.002
2	Diseased	206.011	208.000	18.000	255.000	0.499	0.501	13.878	0.002
3	Diseased	209.147	213.000	16.000	255.000	0.500	0.500	13.694	0.001
4	Diseased	145.946	147.000	8.000	255.000	0.499	0.501	15.752	0.001
5	Diseased	160.074	161.000	15.000	255.000	0.498	0.500	18.239	0.001
6	Healthy	159.977	161.000	20.000	255.000	0.507	0.506	27.943	0.002
7	Healthy	154.984	157.000	10.000	255.000	0.497	0.501	19.063	0.001
8	Healthy	146.988	148.000	13.000	255.000	0.497	0.501	20.340	0.001
9	Healthy	147.550	149.000	11.000	255.000	0.497	0.501	20.756	0.001
10	Healthy	143.648	144.000	8.000	255.000	0.501	0.500	20.121	0.001

2.4 การสร้างแบบจำลอง (Modeling)

ขั้นตอนนี้ผู้จัดทำวิจัยตัวแบบสำหรับคัดกรองผู้ป่วยเป็นโรคที่อกโซพลาสโมซิสจากภาพจอประสาทตา ด้วยเทคนิคเหมือนข้อมูลภาพ โดยใช้เทคนิคการจำแนกประเภทข้อมูลภาพ 3 เทคนิค ได้แก่ เทคนิคเพื่อนบ้านใกล้ที่สุด เทคนิคซัพพอร์ตเวกเตอร์แมชชีน เทคนิคต้นไม้ตัดสินใจ โดยเทคนิคทั้ง 3 ที่ถูกเลือกนี้เนื่องจากแต่ละเทคนิคมีคุณสมบัติที่เสริมกันและสามารถวิเคราะห์ข้อมูลภาพถ่ายจอประสาทตาในมุมมองที่แตกต่างกัน การเปรียบเทียบประสิทธิภาพของเทคนิคเหล่านี้จะช่วยให้ผู้วิจัยสามารถเลือกเทคนิคที่เหมาะสมที่สุดสำหรับการสร้างตัวแบบคัดกรองโรคที่อกโซพลาสโมซิสได้ ซึ่งจะนำไปสู่การวางแผนการรักษาที่แม่นยำและรวดเร็วมากยิ่งขึ้น ซึ่งรายละเอียดแต่ละวิธีมีดังต่อไปนี้

2.4.1 เทคนิคเพื่อนบ้านใกล้ที่สุด (k-Nearest Neighbors: k-NN) เป็นอัลกอริทึมการเรียนรู้ของเครื่องแบบ Supervised learning ที่ใช้ในการจำแนกประเภทข้อมูล โดยอาศัยแนวคิดที่ว่าข้อมูลที่มีระยะห่างใกล้เคียงกันมักจะมีคลาสเดียวกันในการจำแนกประเภทข้อมูลด้วยเทคนิค k-NN ในทางการแพทย์ โดยมีวัตถุประสงค์เพื่อ เช่น การวินิจฉัยโรค โดยอาศัยข้อมูลประวัติทางการแพทย์ การตรวจร่างกาย และผลการตรวจทางห้องปฏิบัติการของผู้ป่วย มาเปรียบเทียบกับข้อมูลของผู้ป่วยรายอื่นๆ ที่มีประวัติและอาการคล้ายคลึงกัน เพื่อคาดการณ์ว่าผู้ป่วยรายนั้นเป็นโรคใด การคัดกรองโรคแสดงดังภาพที่ 2 (อนุพงศ์ สุขประเสริฐ, 2564).




ภาพที่ 2 เทคนิคเพื่อนบ้านใกล้ที่สุด K-Nearest Neighbors (k-NN)

ที่มา : บุษยารักษ์ ภัคศิริรักษ์ และคณะ (2566)

2.4.2 เทคนิคซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) เป็นหนึ่งในเทคนิคการเรียนรู้ของเครื่อง ที่ใช้สำหรับจำแนกข้อมูล โดยที่การทำงานจะสร้างเส้นแบ่งกลุ่มระหว่างกลุ่มข้อมูลที่เข้าสู่กระบวนการ เพื่อให้ระบบได้รับรู้ ซึ่งจะเน้นไปที่เส้นแบ่งของข้อมูลและยัง


แยกแยะข้อมูลได้ดีที่สุดเป็นแนวคิดการแบ่งกลุ่มออกจากกันโดยที่สร้างเส้นแบ่ง (Hyper plane) เป็นเส้นตรงขึ้นมา แล้วหาว่าเส้นไหนเป็นเส้นที่ดีที่สุด แล้วนำมาแก้ไขปัญหาการจำแนกข้อมูลของทั้งสองกลุ่มแนวคิดในการแบ่งข้อมูล นอกจากนี้ SVM ยังมีประสิทธิภาพสูงเมื่อจำนวนของ Dimensions มากกว่า จำนวนของ Sample เนื่องจากเส้นแบ่ง Hyperplane สามารถจำแนกข้อมูลได้โดยใช้ลักษณะเฉพาะของข้อมูล (Features) แสดงดังภาพที่ 3 (เดชธรรม ศิริ และพยุ่ง มีสัจ, 2554)



ภาพที่ 3 เทคนิคซ์พอร์ตเวกเตอร์แมชชีน (Support Vector Machine : SVM)

ที่มา : อานนท์ เปียงแล และสวรินทร์ ฤกษ์อยู่สุข (2563)

2.4.3 เทคนิคต้นไม้ตัดสินใจ (Decision Tree) เป็นเทคนิคการเรียนรู้ของเครื่องประเภทหนึ่งที่ใช้ในการสร้างแบบจำลองการจำแนกประเภทข้อมูล (Classification) โดยสร้างต้นไม้ที่มีกิ่งก้านสาขา แต่ละกิ่งก้านจะแสดงถึงเงื่อนไขในการจำแนกข้อมูลต้นไม้ตัดสินใจทำงานโดยแบ่งข้อมูลออกเป็นสองกลุ่มย่อยตามเงื่อนไขของตัวแปรหนึ่งๆ อย่างต่อเนื่อง จนกว่าข้อมูลในแต่ละกลุ่มจะมีขนาดเล็กเพียงพอหรือไม่มีตัวแปรใดที่มีความสัมพันธ์กับตัวแปรเป้าหมายอีกต่อไป ตัวแปรที่ใช้ในการแบ่งข้อมูลในแต่ละครั้ง จะถูกเลือกจากตัวแปรที่มีความสัมพันธ์กับตัวแปรเป้าหมายมากที่สุด แสดงดังภาพที่ 4 (เดชธรรม ศิริ และพยุ่ง มีสัจ, 2554)



ภาพที่ 4 เทคนิคการตัดสินใจแบบต้นไม้ (Decision Tree)

ที่มา : สมศักดิ์ ศรีสุวรรณ และสมัย ศรีสวย, 2564

จากนั้น ผู้วิจัยได้ปรับแต่งค่าพารามิเตอร์ของแต่ละเทคนิคให้เหมาะสมที่สุดเพื่อเพิ่มประสิทธิภาพของตัวแบบ โดยในเทคนิคต้นไม้ตัดสินใจ ได้ทำการกำหนดค่าที่เหมาะสมสำหรับพารามิเตอร์ Maximal Depth, Minimal Leaf Size และ Minimal Size for Split ส่วนในเทคนิคซัพพอร์ตเวกเตอร์แมชชีน ได้ปรับค่าพารามิเตอร์ C และ Gamma ให้เหมาะสมที่สุด ในขณะที่เทคนิคเพื่อนบ้านใกล้เคียงที่สุด ได้ปรับค่าพารามิเตอร์ k เพื่อให้เกิดประสิทธิภาพสูงสุด หลังจากการปรับค่าพารามิเตอร์ในแต่ละเทคนิคแล้ว ผู้วิจัยได้นำผลการจำแนกประเภทข้อมูลที่ได้มาทำการเปรียบเทียบประสิทธิภาพระหว่างทั้งสามเทคนิคในขั้นตอนที่ 2.5 ต่อไป

2.5 การประเมินผล (Evaluation)

ผู้วิจัยทำการแบ่งข้อมูลออกเป็น 2 ส่วน ได้แก่ ส่วนที่ใช้สำหรับการสร้างตัวแบบ (Training Set) และส่วนที่ใช้สำหรับการทดสอบประสิทธิภาพของตัวแบบ (Testing Set) ด้วยวิธี 10-fold cross validation โดยแบ่งข้อมูลออกเป็น 10 ส่วนเท่าๆ กัน จากนั้นทำการคำนวณหาประสิทธิภาพการจำแนกประเภทข้อมูลภาพ ทั้งหมด 4 ค่า ได้แก่ ค่าความแม่นยำ ค่าประสิทธิภาพโดยรวม ค่าความไว และค่าจำเพาะ โดยมีรายละเอียดดังแสดงในเมทริกซ์ความสับสน (confusion matrix)

ตารางที่ 2 เมทริกซ์ความสับสน (confusion matrix)

	Predicted Positive (Yes)	Predicted Negative (No)
Actual Positive (Yes)	True Positive (TP)	False Negative (FN)
Actual Negative (No)	False Positive (FP)	True Negative (TN)

โดยที่ True Positive (TP) คือ สิ่งที่ทำนายตรงกับสิ่งที่เกิดขึ้นจริง ในกรณีทำนายว่าจริง และสิ่งที่เกิดขึ้นคือจริง

True Negative (TN) คือ สิ่งที่ทำนายตรงกับสิ่งที่เกิดขึ้นจริง ในกรณีทำนายว่าไม่จริง และสิ่งที่เกิดขึ้นคือไม่จริง

False Positive (FP) คือ สิ่งที่ทำนายไม่ตรงกับสิ่งที่เกิดขึ้นจริง ในกรณีทำนายว่าจริง แต่สิ่งที่เกิดขึ้นคือไม่จริง

False Negative (FN) คือ สิ่งที่ทำนายไม่ตรงกับสิ่งที่เกิดขึ้นจริง ในกรณีทำนายว่าไม่จริง แต่สิ่งที่เกิดขึ้นคือจริง

2.5.1 ค่าความแม่นยำ (Accuracy) คือ ค่าที่ตัวแบบจำลองสามารถพยากรณ์ข้อมูลผู้ป่วยที่เกิดโรคและไม่เกิดโรคได้อย่างถูกต้องต่อข้อมูลทั้งหมด จากสมการที่ 1 ดังนี้

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

2.5.2 ค่าประสิทธิภาพโดยรวม (F-measure) คือ ค่าที่เกิดจากการเปรียบเทียบระหว่าง ค่าความเที่ยง (Precision) และ ค่าการเรียกคืน (Recall) ของแต่ละคลาสเป้าหมาย จากสมการที่ 2 ดังนี้

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

2.5.3 ค่าความไว (Sensitivity) คือ ค่าที่ตัวแบบจำลองสามารถพยากรณ์ข้อมูลผู้ป่วยที่เกิดโรคได้อย่างถูกต้องต่อผู้ป่วยที่เกิดโรคจริง จากสมการที่ 3 ดังนี้

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (3)$$

2.5.4 ค่าจำเพาะ (Specificity) คือ ค่าที่ตัวแบบจำลองสามารถพยากรณ์ข้อมูลผู้ป่วยที่ไม่เกิดโรคได้อย่างถูกต้องต่อผู้ป่วยที่ไม่เกิดโรคจริง จากสมการที่ 4 ดังนี้

$$\text{Specificity} = \frac{TN}{TN + FP} \quad (4)$$

2.6 การนำไปใช้ (Deployment)

หลังจากที่ผู้วิจัยวิเคราะห์ข้อมูลเพื่อหาตัวแบบที่เหมาะสมที่สุด ตัวแบบดังกล่าวสามารถนำไปพัฒนาต่อยอดเป็นระบบสารสนเทศสำหรับคัดกรองผู้ป่วยโรคที่อ็อกโซพลาสโมซิสโดยอาศัยภาพถ่ายจอประสาทตา ร่วมกับวิธีวินิจฉัยอื่น ๆ ซึ่งผลลัพธ์นี้จะช่วยสนับสนุนการตัดสินใจของแพทย์ในการวินิจฉัยโรคได้อย่างแม่นยำและรวดเร็วยิ่งขึ้น นอกจากนี้ ยังสามารถประยุกต์ใช้เพื่อหาวิธีป้องกันการเกิดโรค รวมถึงให้ความรู้แก่กลุ่มเสี่ยงเพื่อลดโอกาสการเกิดโรคในอนาคตได้อีกด้วย

3. ผลการศึกษา

ผลการสร้างตัวแบบสำหรับคัดกรองผู้ป่วยโรคที่อ็อกโซพลาสโมซิสจากภาพถ่ายจอประสาทตา ด้วยเทคนิคเหมือนข้อมูลภาพ โดยใช้เทคนิคจำแนกประเภทข้อมูลภาพ ทั้ง 3 เทคนิค ได้แก่ เทคนิคต้นไม้ตัดสินใจ (Decision Tree) เทคนิคซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) เทคนิคเพื่อนบ้านใกล้ที่สุด (K-Nearest Neighbors: k-NN) โดยผู้วิจัยได้ทำการหาค่าเหมาะสมที่สุดสำหรับพารามิเตอร์ ด้วยวิธี Evolutionary algorithm กับทั้ง 3 เทคนิค จากนั้นได้ทำการวัดค่าประสิทธิภาพของการจำแนกประเภทข้อมูลภาพ ทั้งหมด 4 ค่า ได้แก่ ค่าความแม่นยำ (Accuracy) ค่าประสิทธิภาพโดยรวม (F-Measure) ค่าความไว (Sensitivity) และค่าจำเพาะ (Specificity) ซึ่งผลลัพธ์ได้แสดงในตารางที่ 3 และตารางที่ 4

ตารางที่ 3 การทดสอบประสิทธิภาพการจำแนกประเภทข้อมูลภาพ

Image Classification Techniques	Image Classification Performance			
	Accuracy	F-Measure	Sensitivity	Specificity
K-Neural Network	90.77%	83.04%	82.66%	93.87%
Support Vector Machine	90.80%	83.30%	82.38%	93.81%
Decision Tree*	91.10%	93.71%	91.51%	90.00%

* คือ เทคนิคที่มีความเหมาะสมสำหรับนำมาสร้างตัวแบบการคัดกรองผู้ป่วยโรคที่อ็อกโซพลาสโมซิส

จากตารางที่ 3 แสดงให้เห็นว่าเทคนิคที่มีประสิทธิภาพในการจำแนกประเภทข้อมูลภาพดีที่สุดคือ เทคนิคต้นไม้ตัดสินใจ โดยมีค่าพารามิเตอร์ที่เหมาะสม ได้แก่ Maximal Depth เท่ากับ 54, Minimal Leaf Size เท่ากับ 4 และ Minimal Size for Split เท่ากับ 20 ซึ่งให้ค่าความแม่นยำสูงสุด 91.10% รองลงมาคือ เทคนิคซัพพอร์ตเวกเตอร์แมชชีน ที่มีค่าพารามิเตอร์เหมาะสม ได้แก่ C เท่ากับ 2.714 และ Gamma เท่ากับ 0.001 ซึ่งให้ค่าความแม่นยำ 90.80% ในขณะที่ เทคนิคเพื่อนบ้านใกล้ที่สุด ให้ประสิทธิภาพการจำแนกประเภทข้อมูลภาพน้อยที่สุด โดยค่าพารามิเตอร์ที่เหมาะสมสำหรับ k เท่ากับ 16 ซึ่งให้ค่าความแม่นยำ 90.77%

ตารางที่ 4 เมทริกซ์ความสับสนที่ใช้วัดประสิทธิภาพของตัวแบบการพยากรณ์สำหรับเทคนิคต้นไม้ตัดสินใจ

	true Diseased	true Healthy
pred. Diseased	194	8
pred. Healthy	18	72

จากตารางที่ 4 แสดงผลการพยากรณ์จากเทคนิคต้นไม้ตัดสินใจ โดยมีความถูกต้อง (Accuracy) 91.10% ความไว (Sensitivity) 91.51% และความจำเพาะ (Specificity) 90.00% ทั้งนี้ ค่า F-Measure ของกลุ่มผู้ป่วย (Diseased) อยู่ที่ 93.73% สะท้อนถึงประสิทธิภาพที่ดีในการจำแนกข้อมูลระหว่างผู้ป่วยและคนสุขภาพดี

4. สรุปผล และอภิปรายผล

การวิจัยนี้เป็นการนำเทคโนโลยีการประมวลผลภาพมาใช้ในการสร้างและเปรียบเทียบประสิทธิภาพของตัวแบบสำหรับการคัดกรองผู้ป่วยโรคที่อกโซพลาสโมซิสจากภาพถ่ายของจอประสาทตา โดยใช้เทคนิคการทำเหมืองข้อมูลภาพ โดยใช้เทคนิคการจำแนกประเภทข้อมูลภาพ 3 เทคนิค ได้แก่ เทคนิคต้นไม้ตัดสินใจ เทคนิคซัพพอร์ตเวกเตอร์ และเทคนิคเพื่อนบ้านใกล้ที่สุด จากการทดลองพบว่าเทคนิคที่ให้ค่าความแม่นยำที่สุดคือ เทคนิคต้นไม้ตัดสินใจ ซึ่งมีค่าความแม่นยำเท่ากับ 91.10% อย่างไรก็ตาม ผลลัพธ์ที่ได้ไม่สอดคล้องกับงานวิจัยก่อนหน้าของพิศาล บุญมาวาสนาสง และสุนันทา สดสี (2561) ที่ได้ศึกษาการตรวจจับผู้ดื่มเครื่องดื่มแอลกอฮอล์จากภาพถ่ายโดยใช้เทคนิคการรู้จำสีและความกว้างของดวงตา เทคนิคที่ให้ประสิทธิภาพที่ดีที่สุดในงานนี้คือ เทคนิคโครงข่ายประสาทเทียม ที่มีความถูกต้องสูงที่สุดเท่ากับ 82.326% อีกทั้งผู้วิจัยได้ทำการเปรียบเทียบกับงานวิจัยของ Wang, W.C., (2015) และ Koukiou, G. and Anasassopoulos, V., (2013) โดย Wang, W.C., (2015) ได้ศึกษาการตรวจจับภาพใบหน้าด้วยการใช้ภาพสี พบว่า การใช้เทคนิคซัพพอร์ตเวกเตอร์แมชชีนให้ความแม่นยำสูงสุดที่ 87.9% ในขณะที่ Koukiou, G. and Anasassopoulos, V., (2013) ได้ทำการศึกษาเปรียบเทียบการจำแนกการตรวจสอบสถานะการดื่มสุราและขับรถโดยใช้กล้อง ผลการวิจัยพบว่า เทคนิคโครงข่ายประสาทเทียมมีความแม่นยำอยู่ที่ 77.3% ซึ่งถือเป็นเทคนิคที่มีประสิทธิภาพสูงสุดในการตรวจจับสถานะการดื่มสุราและขับรถโดยใช้กล้อง ทั้งนี้ ผลการวิจัยดังกล่าวได้รับการยอมรับในวงการวิจัยด้านการประมวลผลภาพและการตรวจจับองค์ประกอบในภาพถ่ายในหลายแง่มุม จึงมีความเป็นไปได้ว่างานวิจัยนี้จะได้รับการพิจารณาและยอมรับในวงการอย่างกว้างขวางในอนาคต

เอกสารอ้างอิง

- กฤษฎาณ อินทร์ตัน. (2565). การจำแนกการใช้ประโยชน์ที่ดินในจังหวัดนครนายกด้วยอัลกอริธึมการเรียนรู้เครื่องและภาพถ่ายจากดาวเทียม Sentinel-2. วารสารวิทยาศาสตร์บูรพา. 27(2), 1153-1171
- เดชธรรม ศิริ และพยุ่ง มีสัจ. (2554). การจำแนกข้อมูลด้วยวิธีแบบร่วมกันตัดสินใจจากพื้นฐานของเทคนิคต้นไม้ตัดสินใจ เทคนิคโครงข่ายประสาทเทียม และเทคนิคซัพพอร์ตเวกเตอร์แมชชีน ร่วมกับการเลือกตัวแทนที่เหมาะสมด้วยขั้นตอนวิธีเชิงพันธุกรรม. วารสารวิชาการพระจอมเกล้าพระนครเหนือ, 21(2), 293-303
- บุษยารัตน์ รักดีรักษ์ อนุพงศ์ สุขประเสริฐ และแพรวไพลิน จันทร์โพธิ์ศรี. (2566). การพิจารณาอนุมัติสินเชื่อสำหรับสมาชิกสหกรณ์การเกษตรแห่งหนึ่งด้วยวิธีเทคนิคเหมืองข้อมูล. การประชุมวิชาการระดับนานาชาติ ครั้งที่ 9 ประจำปี พ.ศ.2566, พิษณุโลก : โรงแรมท็อปแลนด์ พลาซ่า. (หน้า 222-232).
- ผู้จัดการออนไลน์. (2566). เจาะเทรนด์ Pet Humanization “สัตว์เลี้ยง” คือสมาชิกในครอบครัว. ค้นเมื่อ 10 มกราคม 2567 ค้นจาก <https://mgronline.com/daily/detail/9660000013428>.
- พิมพ์ลภัส สุวรรณสิงห์, และคณะ. (2566). การเปรียบเทียบการแยกส่วนภาพและไม่แยกส่วนภาพเพื่อจำแนกน้ำหนักรถของปลานิลแดง โดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง. วารสารวิทยาศาสตร์บูรพา. 28(1), 208-222.
- พิศาล บุญมาวาสนาส่ง และสุนันทา สดสี. (2562). การตรวจจับผู้ดื่มเครื่องดื่มแอลกอฮอล์จากภาพถ่ายโดยเทคนิคการรู้จำสีแก้มและความกว้างขนาดดวงตา. วารสารวิทยาศาสตร์และเทคโนโลยี. 27(3), 539-549.
- วรณรัตน์ คัทมาตย์. (2566). หมดยุคคนอยากมีลูก? ผลสำรวจชี้ คนไทยกว่า 49% เลือกเลี้ยง"สัตว์เลี้ยง"แทนลูก. ค้นเมื่อ 10 มกราคม 2567 ค้นจาก <https://www.bangkokbiznews.com/business/business/1048207?>
- สมศักดิ์ ศรีสวการย์ และสมัย ศรีสว. (2563). การวิเคราะห์เหมืองความคิดเห็นโดยใช้เทคนิคการสกัดคำ. วารสารวิชาการการประยุกต์ใช้เทคโนโลยีสารสนเทศ, 6(2), 95-104
- อนุพงศ์ สุขประเสริฐ. (2564). การทำเหมืองข้อมูลด้วยโปรแกรม RapidMiner Studio. มหาสารคาม: คณะการบัญชีและการจัดการมหาวิทยาลัยมหาสารคาม.
- อานนท์ เปียงแล และสวรินทร์ ฤกษ์อยู่สุข. (2563). การศึกษาการจำแนกข้อมูลด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีน กรณีศึกษา พื้นที่เพาะปลูกข้าว อำเภोजุน จังหวัดพะเยา. วารสารวิชาการเพื่อการพัฒนาวัฒนธรรมเชิงพื้นที่, 1(3), 51-62.

- Cardozo, O., Ojeda, V., Parra, R., Mello-Román, J. C., Noguera, J. L. V., García-Torres, M., & Aquino-Brítez, D. (2023). **Dataset of fundus images for the diagnosis of ocular toxoplasmosis**. *Data in Brief*, 48, 109056
- Dubey, J. P., & Beattie, C. P. (1988). **Toxoplasmosis of animals and man**. CABI Database, (pp. 220-pp).
- Koukiou, G., & Anasassopoulos, V. (2013, April). **Face locations suitable drunk persons identification**. In 2013 International Workshop on Biometrics and Forensics (IWBF) (pp. 1-4). IEEE.
- Wang, W. C. (2015). **A face detection method used for color images**. *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 8(2), 257-266.