

Received: 17 ก.พ. 2568

Revised: 16 มิ.ย. 2568

Accepted: 18 มิ.ย. 2568

ระบบจำแนกสภาพอากาศโดยใช้เทคโนโลยีการเรียนรู้เชิงลึกสำหรับกล้องถ่ายภาพทั่วท้องฟ้า
ของสถาบันวิจัยดาราศาสตร์แห่งชาติ (องค์การมหาชน)

Weather Classification System using Deep Learning Technology
for National Astronomical Research Institute of Thailand SkyCamera

กณิศนันท์ ทองสกุล¹, กฤษฎา ปาลี³, พยุงศักดิ์ เกษมสำราญ¹, ปวีณ เชื้อนแก้ว¹,

สมชาย อารยพิทยา² และ ภาณุวัฒน์ เมฆะ^{1*}

¹สาขาวิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยแม่โจ้ 50290 ประเทศไทย

²กองเทคโนโลยีดิจิทัล สำนักงานมหาวิทยาลัย มหาวิทยาลัยแม่โจ้ 50290 ประเทศไทย

³ห้องปฏิบัติการหอดูดาว สถาบันวิจัยดาราศาสตร์แห่งชาติ (องค์การมหาชน) 50180 ประเทศไทย

Kanitnan Thongsakul¹, Krisada Palee³, Payungsak Kasemsumran¹, Paween Khoenkaw¹,

Somchai Arayapitaya² and Panuwat Mekha^{1*}

¹Department of Computer Science, Faculty of Science, Maejo University, Chiangmai,
Thailand, 50290

²Technology Digital Division, Office of University, Maejo University, 50290 Thailand

³Observatory Laboratory, National Astronomical Research Institute of Thailand (Public
Organization), 50180, Thailand

*Corresponding author: panuwat_m@mju.ac.th

Abstract

The Weather Classification System Using Deep Learning Technology for Sky Cameras of the National Astronomical Research Institute (Public Organization) The objective is to use continuous sky photo data stored in a database to train and develop an artificial intelligence system for weather classification. This aims to increase the accuracy in displaying sky statuses, including clear sky, cloudy, overcast, and rainy conditions. By using deep learning algorithms, the system achieves an accuracy rate of 96.67% through image classification with convolutional neural networks. These networks are based on artificial neural networks that can effectively learn and analyze complex data. The system can process and classify sky conditions in real-time based on specified locations and times. Additionally, it can store data to display through

graphs, allowing users to know the sky conditions at different times. The system also provides the capability to retrieve historical data by date, time, and location as needed by the users. This is highly beneficial for studying and analyzing weather conditions and astronomical phenomena.

Keywords: Sky image; SkyCamera; Weather Classification; Deep Learning

บทคัดย่อ

ระบบจำแนกสภาพอากาศโดยใช้เทคโนโลยีการเรียนรู้เชิงลึกสำหรับกล้องถ่ายภาพทั่วท้องฟ้าของสถาบันวิจัยดาราศาสตร์แห่งชาติ (องค์การมหาชน) มีวัตถุประสงค์เพื่อนำข้อมูลของรูปถ่ายทางท้องฟ้าที่ถูกเก็บอยู่ในฐานข้อมูลอย่างต่อเนื่อง มาฝึกสอนเพื่อสร้างระบบปัญญาประดิษฐ์ในการจำแนกสภาพอากาศ เพื่อเพิ่มความแม่นยำในการแสดงสถานะของท้องฟ้า ได้แก่ ท้องฟ้าแจ่มใส มีเมฆ มีดครีမ် และฝนตก โดยการใช้อัลกอริทึมแบบการเรียนรู้เชิงลึก โดยให้ค่าความถูกต้องร้อยละ 96.67 ด้วยวิธีการจำแนกภาพด้วยโครงข่ายประสาทแบบคอนโวลูชัน ซึ่งมีพื้นฐานมาจากการใช้โครงข่ายประสาทเทียมที่สามารถเรียนรู้และวิเคราะห์ข้อมูลที่ซับซ้อนได้อย่างมีประสิทธิภาพ โดยระบบสามารถประมวลผลและจำแนกสถานะของท้องฟ้าได้แบบเรียลไทม์ตามสถานที่และเวลาที่กำหนด รวมทั้งสามารถเก็บข้อมูลเพื่อนำไปแสดงผ่านกราฟเพื่อให้ผู้ใช้งานสามารถทราบข้อมูลเกี่ยวกับสถานะท้องฟ้าที่เกิดขึ้นในแต่ละช่วงเวลา อีกทั้งระบบสามารถดูข้อมูลย้อนหลังตามวันที่ เวลา สถานที่ ที่ผู้ใช้งานต้องการทราบได้ อีกทั้งเป็นประโยชน์อย่างยิ่งในการศึกษาและวิเคราะห์สภาพอากาศ รวมถึงปรากฏการณ์ทางดาราศาสตร์ต่างๆ ต่อไป

คำสำคัญ: ภาพถ่ายท้องฟ้า; กล้องถ่ายภาพทั่วท้องฟ้า; การจำแนกสภาพอากาศ; การเรียนรู้เชิงลึก

1. บทนำ

หนึ่งในปัจจัยสำคัญที่ส่งผลต่อการใช้งานกล้องโทรทรรศน์เชิงดาราศาสตร์คือสภาพท้องฟ้า ซึ่งมีผลกระทบโดยตรงต่อคุณภาพของการสังเกตการณ์ ปัจจุบันสถาบันวิจัยดาราศาสตร์แห่งชาติ (องค์การมหาชน) มีระบบ SkyCamera ที่สามารถบันทึกภาพถ่ายของท้องฟ้าแบบเรียลไทม์และเก็บไว้ในฐานข้อมูล และข้อมูลภาพถ่ายจำนวนมากที่ถูกบันทึกไว้ยังไม่ได้ถูกนำไปใช้ให้เกิดประโยชน์ โดยเฉพาะในการตัดสินใจเกี่ยวกับการเปิด-ปิดโดมของกล้องโทรทรรศน์ ซึ่งยังต้องอาศัยการตรวจสอบของเจ้าหน้าที่เป็นหลัก ส่งผลให้เกิดความล่าช้าในการบริหารจัดการระบบ เพื่อแก้ไขปัญหาดังกล่าว งานวิจัยนี้มีเป้าหมายในการพัฒนาโมเดลต้นแบบที่สามารถจำแนกสถานะของท้องฟ้าโดยใช้การเรียนรู้

เชิงลึก (Deep Learning) ซึ่งอาศัยโครงข่ายประสาทเทียม (Neural Networks) ในการเรียนรู้รูปแบบ และลักษณะเฉพาะของภาพท้องฟ้า โดยนำข้อมูลจากระบบ SkyCamera มาใช้ในการฝึกโมเดลเพื่อให้สามารถจำแนกสภาพท้องฟ้าแบบเรียลไทม์ได้อย่างแม่นยำ

ดังนั้นงานวิจัยนี้คาดว่าจะช่วยให้การบริหารจัดการหอดูดาวเป็นไปอย่างมีประสิทธิภาพมากขึ้น ลดภาระงานของเจ้าหน้าที่ และเพิ่มความแม่นยำในการคัดกรองสถานะท้องฟ้าก่อนการใช้งาน กล้องโทรทรรศน์ นอกจากนี้ โครงการนี้ยังส่งเสริมการพัฒนาเทคโนโลยีปัญญาประดิษฐ์ (AI) เพื่อการประยุกต์ใช้ในดาราศาสตร์ และเพิ่มขีดความสามารถในการใช้ข้อมูลที่มีอยู่ให้เกิดประโยชน์สูงสุด

2. วัตถุประสงค์

1. เพื่อพัฒนาโปรแกรมที่สามารถจำแนกสถานะจากภาพท้องฟ้าแบบเรียลไทม์
2. เพื่อพัฒนาไลบรารีที่สามารถนำไปต่อยอดกับโปรแกรม SkyCamera ขององค์กร
3. เพื่อพัฒนาโมเดลด้านปัญญาประดิษฐ์ที่สามารถจำแนกสถานะของภาพถ่ายท้องฟ้าได้

3. งานวิจัยที่เกี่ยวข้อง


จากการวิจัยและพัฒนาระบบจำแนกสภาพอากาศโดยใช้เทคโนโลยีการเรียนรู้เชิงลึกสำหรับ กล้องถ่ายภาพทั่วท้องฟ้าของสถาบันวิจัยดาราศาสตร์แห่งชาติ (องค์การมหาชน) จึงได้มีการนำ งานวิจัยที่เกี่ยวข้องกับการทำระบบเพื่อเป็นแนวทางในการวิจัย ดังนี้

ในยุคปัจจุบันที่เทคโนโลยีมีความก้าวหน้าอย่างรวดเร็ว การนำเทคโนโลยีสมัยใหม่เข้ามา ประยุกต์ใช้ร่วมกับระบบสังเกตการณ์ทางดาราศาสตร์ได้กลายเป็นแนวทางสำคัญในการเพิ่ม ประสิทธิภาพของการทำงาน โดยเฉพาะการประมวลผลภาพถ่ายท้องฟ้าแบบเรียลไทม์ ซึ่งถือเป็น ปัจจัยสำคัญที่มีผลโดยตรงต่อการใช้งานกล้องโทรทรรศน์ เนื่องจากสภาพท้องฟ้าที่ไม่เหมาะสม เช่น เมฆมากหรือฝนตกด้วยเหตุนี้ เทคโนโลยีด้านปัญญาประดิษฐ์ (Artificial Intelligence: AI) โดยเฉพาะ การเรียนรู้เชิงลึก (Deep Learning) จึงได้รับความสนใจอย่างมากในการนำมาประยุกต์ใช้เพื่อช่วย วิเคราะห์และจำแนกสถานะของท้องฟ้าโดยอัตโนมัติ จากการศึกษาวิจัยของ Panuwat Mekha, Nutnicha Teeyasuksaet (2019) เทคโนโลยีนี้อาศัยโครงข่ายประสาทเทียม (Neural Networks) ในการเรียนรู้ลักษณะและรูปแบบของข้อมูลภาพถ่าย เพื่อให้ระบบสามารถตัดสินใจหรือประเมิน สภาพท้องฟ้าได้อย่างแม่นยำและทันต่อเวลา โดยมีการศึกษาโครงข่ายแบบต่างๆจากงานวิจัยของ Neha Sharma , Vibhor Jain , Anju Mishra (2018) เพื่อนำมาประยุกต์ใช้การฝึกและประเมินผล โมเดลในงานนี้อ้างอิงการออกแบบกระบวนการจากงานวิจัยของ Chen, JiaCong (2019) โดยมีการ แบ่งชุดข้อมูลเป็นชุดฝึก 70%, ชุดประเมิน 15% และชุดทดสอบ 15% ตามแนวทางของ Panuwat Mekha, Nutnicha Teeyasuksaet และ Khukrit Osathanunkul (2024) และเพื่อให้เหมาะสมกับ

ข้อมูลภาพถ่ายจริง จึงมีการปรับขนาดของข้อมูลที่ใช้ฝึกให้เหมาะสมก่อนนำเข้าโมเดล ในการเปรียบเทียบประสิทธิภาพของโมเดล พบว่าเครือข่าย GoogleNet และ ResNet-50 เป็นโมเดลที่ให้ผลลัพธ์ที่มีความแม่นยำสูงและมีความเสถียรที่สุด สอดคล้องกับผลการศึกษาโดย Sharma, Jain และ Mishra (2018) ซึ่งเปรียบเทียบความสามารถของโมเดล CNN (Convolutional Neural Network) ยอดนิยมหลายรูปแบบ ระบบที่พัฒนาขึ้นสามารถตรวจจับสถานะท้องฟ้าได้ 4 ประเภท ได้แก่ ท้องฟ้าแจ่มใส, มีเมฆ, มีดครึ้ม และฝนตก โดยสามารถอัปเดตผลแบบเรียลไทม์ทุก 1 นาทีเมื่อมีภาพใหม่เข้ามา อ้างอิงจากแนวทางของ Li-Wei Kang, Ke-Lin Chou และ Ru-Hong Fu (2018) ที่เสนอการนำ Deep Learning มาประยุกต์กับภาพถ่ายท้องฟ้าอย่างมีประสิทธิภาพ นอกจากนี้ ระบบยังเปิดโอกาสให้ผู้ใช้งานเลือกโมเดลที่ต้องการใช้งานในระบบได้ตามความเหมาะสม และสามารถเรียกดูข้อมูลท้องฟ้าในอดีตผ่านระบบ Historical Data พร้อมแสดงผลในรูปแบบกราฟ โดยระบบทั้งหมดถูกพัฒนาด้วยภาษา C# สำหรับการทำงานส่วนหน้า และ MATLAB สำหรับกระบวนการเรียนรู้ของโมเดลเบื้องหลัง

4. วิธีการดำเนินการ

จากการวิจัยเกี่ยวกับระบบจำแนกสภาพอากาศโดยใช้เทคโนโลยีการเรียนรู้เชิงลึกสำหรับกล้องถ่ายภาพท้องฟ้าของสถาบันวิจัยดาราศาสตร์แห่งชาติ (องค์การมหาชน) แสดงให้เห็นถึงกระบวนการพัฒนาระบบ โดยมีรายละเอียด ดังนี้




รูปที่ 1 ผังงานขั้นตอนการเตรียมข้อมูลก่อนนำไปใช้ฝึกโมเดล

จากรูปที่ 1 แสดงกระบวนการเตรียมข้อมูลก่อนฝึกโมเดลเริ่มจากนำเข้าชุดข้อมูลภาพถ่ายท้องฟ้าจำนวน 4,800 ภาพที่ยังไม่ถูกจัดประเภท ซึ่งจะถูกแบ่งเป็น 4 กลุ่ม กลุ่มละ 1,200 ภาพ ได้แก่ ท้องฟ้าแจ่มใส มีเมฆ มีดครึ้ม และฝนตก โดยใช้เทคนิค CNN (Convolutional Neural Network) เพื่อดึงคุณลักษณะสำคัญของภาพ จากนั้นใช้ PCA (Principal Component Analysis) เพื่อลดมิติของข้อมูลเพื่อคงเฉพาะข้อมูลที่สำคัญ ก่อนจัดกลุ่มภาพด้วย K-means (K-means Clustering) เพื่อ


แยกประเภทของท้องฟ้าและนำแต่ละประเภทไปฝึกโมเดลให้เหมาะสมกับลักษณะของภาพทั้ง 4 ประเภท ดังนี้

1. ท้องฟ้าแจ่มใส (Clear) หมายถึง สภาพท้องฟ้าที่ปราศจากเมฆหรือมีเมฆน้อยมากจนไม่สามารถเห็นได้ด้วยตาเปล่า ท้องฟ้าจะเป็นสีฟ้าใส ไม่ถูกบดบังด้วยเมฆ ดังรูปที่ 2




รูปที่ 2 ภาพถ่ายท้องฟ้าแจ่มใส

2. มีเมฆ (Cloudy) หมายถึง สภาพท้องฟ้าที่มีเมฆปรากฏประมาณ 50-70% แต่ยังมีบางส่วนของท้องฟ้าที่ปราศจากเมฆ ดังรูปที่ 3




รูปที่ 3 ภาพถ่ายท้องฟ้ามีเมฆ

3. มีดครึ้ม (Overcast) หมายถึง สภาพท้องฟ้าที่มีเมฆมืดและทึบ จนไม่สามารถมองเห็นท้องฟ้าสีฟ้าได้เลย ดังรูปที่ 4




รูปที่ 4 ภาพถ่ายท้องฟ้ามีดครึ้ม

4. ฝนตก (Rainy) หมายถึง สภาพอากาศที่มีหยดน้ำขนาดใหญ่ ดังรูปที่ 5




รูปที่ 5 ภาพถ่ายท้องฟ้าฝนตก



รูปที่ 6 ผังงานขั้นตอนการทำงานของกระบวนการตั้งค่าการฝึกโมเดล

จากรูปที่ 6 แสดงผังงานกระบวนการฝึก ทดสอบ และประเมินผลโมเดล หลังจากที่มีประเภทของท้องฟ้าทั้ง 4 ประเภทจะมีการตั้งค่าการฝึกของข้อมูล โดยมีการแบ่งข้อมูลที่ฝึกเป็น ชุดฝึก 70% ชุดทดสอบ 15% และชุดการตรวจสอบความถูกต้องระหว่างการฝึก 15% โดยจะมีการประเมินผลโมเดลโดยค่า Accuracy, Precision, Recall และ F1-score ในโมเดลแบบต่างๆเพื่อเปรียบเทียบประสิทธิภาพ




รูปที่ 7 ผังงานขั้นตอนการทำงานของระบบ

จากรูปที่ 7 แสดงถึงแสดงถึงการทำงานของระบบที่ออกแบบเครื่องมือและโปรแกรม การทดสอบจะใช้ ภาษา C# ในการเขียนโค้ด โดยจะทำการเรียกใช้โมเดลที่มีการแปลงไฟล์เพื่อนำมาใช้งานและเขียนฟังก์ชันเพื่อทดสอบการทำงานของโมเดลก่อนที่จะนำมาใช้งานกับระบบและโปรแกรม SkyCamera ขององค์กรในการวัดประสิทธิภาพของแต่ละโครงสร้างข้อมูล ผลการทดสอบจะถูกบันทึกไว้รูปแบบไฟล์ CSV โดยใช้โมเดล Deep Learning ที่พัฒนา เพื่อให้ทำนายสถานะของท้องฟ้าจากข้อมูลภาพถ่ายท้องฟ้า โดยสามารถนำข้อมูลในอดีตมาใช้ในการทำนาย และข้อมูลแบบเรียลไทม์พร้อมแสดงผลออกมาในรูปแบบกราฟและข้อความที่แสดงถึงสถานะและความน่าจะเป็นที่จะเกิดขึ้นของภาพถ่ายท้องฟ้าอื่นๆ

5. ผลการศึกษา


จากการวิจัยเกี่ยวกับระบบจำแนกสภาพอากาศโดยใช้เทคโนโลยีการเรียนรู้เชิงลึกสำหรับกล้องถ่ายภาพทั่วท้องฟ้าของสถาบันวิจัยดาราศาสตร์แห่งชาติ (องค์การมหาชน) ได้ดำเนินการเตรียมข้อมูลในการฝึกโดยใช้เทคนิคและกระบวนการเพื่อฝึกโมเดลในแบบต่างๆเพื่อหาโมเดลที่มีประสิทธิภาพมากที่สุด

5.1 โมเดลที่มีโมเดลที่ตั้งค่าเอง (custom model) คือโมเดลนี้ประกอบด้วยเลเยอร์สำคัญคือ convolutional layers สำหรับดึงฟีเจอร์จากภาพ, batch normalization และ ReLU เพื่อเพิ่มประสิทธิภาพการเรียนรู้, pooling และ dropout สำหรับลด overfitting, และ fully connected layers สำหรับตัดสินผลลัพธ์ก่อนส่งเข้า softmax เพื่อจำแนก 4 ประเภท ใช้ global average pooling เพื่อลดพารามิเตอร์และเพิ่มความเร็วในการเรียนรู้



รูปที่ 8 กราฟแสดงค่าความแม่นยำและค่าความสูญเสียในการฝึกโมเดลที่ตั้งค่าเอง

จากรูปที่ 8 แสดงกราฟโดยมีการแบ่งข้อมูลที่ฝึกเป็นชุดฝึก 70% ชุดทดสอบ 15% และชุดการตรวจสอบความถูกต้องระหว่างการฝึก 15% จากกราฟค่าความแม่นยำที่ค่อยๆ สูงขึ้น บ่งบอกถึงการพัฒนาของโมเดลในการฝึก ซึ่งมีการเปลี่ยนแปลงอยู่ตลอดเวลา และกราฟค่าความสูญเสียที่ด้านล่าง ค่าความสูญเสียอยู่ในระดับสูง เนื่องจากกราฟไม่ใกล้ชิดกับเส้นฐานล่าง ซึ่งหมายถึงยังมีความสูญเสียในการฝึกโมเดลยังสูงและยังไม่มีประสิทธิภาพในการทำงาน



รูปที่ 9 Confusion Matrix การประเมินการทำงานของ Training Data, Validation Data และ Test Data


จากรูปที่ 9 แสดง Confusion Matrix ด้านซ้ายใช้ประเมินการทำงานของโมเดลสำหรับการบอกสถานะท้องฟ้าของชุด Training Data 3,360 ภาพ โดยแบ่งเป็นประเภทละ 840 ภาพ ได้แก่ Clear, Cloudy, Overcast และ Rainy การประเมินโมเดลสามารถจำแนกได้อย่างถูกต้องทั้งหมด 2,861 ครั้ง (True Positives) มีจำนวน 499 ครั้ง ที่โมเดลทำนายว่าเป็นคลาสหนึ่ง ทั้งที่จริง ๆ แล้วเป็นอีกคลาสหนึ่ง (False Positives) และอีก 499 ครั้ง ที่ระบบทำนายผิดว่าไม่ใช่คลาสนั้น ๆ ทั้งที่จริง ๆ แล้วเป็นคลาสนั้น (False Negatives)

Confusion Matrix ตรงกลางใช้ประเมินการทำงานของโมเดลสำหรับการบอกสถานะท้องฟ้าของชุด Validation Data ทั้งหมด 720 ภาพ โดยแบ่งเป็นประเภทละ 180 ภาพ ได้แก่ Clear, Cloudy, Overcast และ Rainy จากการประเมิน โมเดลสามารถจำแนกภาพได้อย่างถูกต้องทั้งหมด 646 ครั้ง (True Positives) มีจำนวน 74 ครั้ง ที่ระบบจำแนกผิดว่าเป็นคลาสหนึ่ง ทั้งที่จริง ๆ แล้วเป็นอีกคลาสหนึ่ง (False Positives) และอีก 66 ครั้ง ที่ระบบทำนายผิดว่าไม่ใช่คลาสนั้น ทั้งที่จริง ๆ แล้วเป็นคลาสนั้น (False Negatives)

Confusion Matrix ด้านขวาใช้ประเมินการทำงานของโมเดลสำหรับการบอกสถานะท้องฟ้าของชุด Test Data ทั้งหมด 720 ภาพ โดยแบ่งเป็นประเภทละ 180 ภาพ ได้แก่ Clear, Cloudy,


Overcast และ Rainy จากการประเมิน โมเดลสามารถจำแนกภาพได้อย่างถูกต้องทั้งหมด 620 ครั้ง (True Positives) มีจำนวน 100 ครั้ง ที่ระบบจำแนกผิดว่าเป็นคลาสหนึ่ง ทั้งที่จริง ๆ แล้วเป็นอีกคลาสหนึ่ง (False Positives) และอีก 91 ครั้ง ที่ระบบทำนายผิดว่าไม่ใช่คลาสนั้น ทั้งที่จริง ๆ แล้วเป็นคลาสนั้น (False Negatives)

5.2 โมเดล GoogleNet ที่มีการ Transfer Learning คือโมเดลผ่านการฝึกและนำปรับค่าพารามิเตอร์ของโมเดลให้มีความเหมาะสมกับงานและมีเลเยอร์ที่สำคัญคือ Inception ที่สามารถวิเคราะห์ข้อมูลจากหลายขนาด receptive field ได้พร้อมกัน ช่วยให้เข้าใจลักษณะของภาพได้อย่างมีประสิทธิภาพโดยไม่เพิ่มจำนวนพารามิเตอร์มากเกินไป เลเยอร์สำคัญ ได้แก่ Inception module, 1x1 convolution สำหรับลดมิติ, Global average pooling เพื่อลด overfitting และ Fully connected layer สำหรับจำแนกคลาส โมเดลนี้จึงให้ความแม่นยำสูง ใช้ทรัพยากรน้อย และเหมาะสมสำหรับงานจริง



รูปที่ 10 กราฟแสดงค่าความแม่นยำและค่าความสูญเสียในการฝึก Transfer Learning โมเดล

จากรูปที่ 10 แสดงกราฟโดยมีการแบ่งข้อมูลที่ฝึกเป็นชุดฝึก 70% ชุดทดสอบ 15% และชุดการตรวจสอบความถูกต้องระหว่างการฝึก 15% จากกราฟแสดงให้เห็นว่าค่าความแม่นยำค่อยเพิ่มขึ้นอย่างสม่ำเสมอ และกราฟมีความคงที่ กราฟค่าความสูญเสียที่ด้านล่างแสดงให้เห็นว่าค่าความสูญเสียลดลง และมีค่าคงที่ ซึ่งหมายความว่าโมเดลมีการปรับปรุงและทำงานได้ดีขึ้น




รูปที่ 11 Confusion Matrix การประเมินการทำงานของ Training Data, Validation Data และ Test Data

จากรูปภาพที่ 11 แสดง Confusion Matrix ด้านซ้ายใช้ประเมินการทำงานของโมเดลสำหรับการบอกสถานะท้องฟ้าของชุด Training Data ทั้งหมด 3,360 ภาพ โดยแบ่งเป็นประเภทละ 840 ภาพ ได้แก่ Clear, Cloudy, Overcast และ Rainy จากการประเมิน โมเดลสามารถจำแนกภาพได้อย่างถูกต้องทั้งหมด 3,360 ครั้ง

Confusion Matrix ตรงกลางใช้ประเมินการทำงานของโมเดลสำหรับการบอกสถานะท้องฟ้าของชุด Validation Data ทั้งหมด 720 ภาพ โดยแบ่งเป็นประเภทละ 180 ภาพ ได้แก่ Clear, Cloudy, Overcast และ Rainy จากการประเมิน โมเดลสามารถจำแนกภาพได้อย่างถูกต้องทั้งหมด 720 ครั้ง (True Positives)

Confusion Matrix ด้านขวาใช้ประเมินการทำงานของโมเดลสำหรับการบอกสถานะท้องฟ้าของชุด Test Data ทั้งหมด 720 ภาพ โดยแบ่งเป็นประเภทละ 180 ภาพ ได้แก่ Clear, Cloudy, Overcast และ Rainy จากการประเมิน โมเดลสามารถจำแนกภาพได้อย่างถูกต้องทั้งหมด 719 ครั้ง (True Positives) มีจำนวน 1 ครั้ง ที่ระบบจำแนกผิดว่าเป็นคลาสหนึ่ง ทั้งที่จริง ๆ แล้วเป็นอีกคลาสหนึ่ง (False Positives) และอีก 1 ครั้ง ที่ระบบทำนายผิดว่าไม่ใช่คลาสนั้น ทั้งที่จริง ๆ แล้วเป็นคลาสนั้น (False Negatives)

5.3 โมเดลที่สร้างจากการกระบวนการ HOG เพื่อดึงคุณลักษณะเด่นของภาพ เช่น ขอบและรูปร่าง ก่อนส่งเข้าโครงข่ายประสาทเทียมที่ออกแบบด้วยเลเยอร์ต่าง ๆ โดย convolution2dLayer ทำหน้าที่เรียนรู้ฟีเจอร์เชิงพื้นที่ batchNormalizationLayer และ reluLayer ช่วยให้การฝึกเสถียรและไม่เชิงเส้น maxPooling2dLayer ช่วยลดขนาดและเน้นข้อมูลสำคัญ ขณะที่ fullyConnectedLayer, softmaxLayer, และ classificationLayer ทำหน้าที่จำแนกประเภทภาพได้อย่างแม่นยำ ทำให้โมเดลมีประสิทธิภาพ



รูปที่ 12 กราฟแสดงค่าความแม่นยำและค่าความสูญเสียในการฝึกโมเดล HOG และการ custom model

จากรูปที่ 12 แสดงกราฟโดยมีการแบ่งข้อมูลที่ฝึกเป็นชุดฝึก 70% ชุดทดสอบ 15% และชุดการตรวจสอบความถูกต้องระหว่างการฝึก 15% จากกราฟค่าความแม่นยำที่ค่อยๆ สูงขึ้น ซึ่งบ่งบอกถึงการพัฒนาของโมเดลในการฝึก โมเดลเริ่มเรียนรู้และปรับตัวให้ทำนายได้ถูกต้องมากขึ้นแต่ก็ยังไม่คงที่ ในส่วนของกราฟค่าความสูญเสียที่ด้านล่าง จะเห็นได้ว่าค่าความสูญเสียยังคงอยู่ในระดับสูงมาก

Confusion Matrix for Train Data				
True Class	Clear	Cloudy	Overcast	Rainy
	837	3		
	12	828		
		5	537	298
			8	832
Confusion Matrix for Validation Data				
True Class	Clear	Cloudy	Overcast	Rainy
	180			
	1	179		
			109	71
			1	179
Confusion Matrix for Test Data				
True Class	Clear	Cloudy	Overcast	Rainy
	180			
	3	177		
		1	120	59
				180


รูปที่ 13 Confusion Matrix การประเมินการทำงานของ Training Data, Validation Data และ Test Data

จากรูปที่ 13 แสดง Confusion Matrix ด้านซ้ายใช้ประเมินการทำงานของโมเดลสำหรับการบอกสถานะท้องฟ้าของชุด Training Data ทั้งหมด 3,360 ภาพ โดยแบ่งเป็นประเภทละ 840 ภาพ ได้แก่ Clear, Cloudy, Overcast และ Rainy จากการประเมิน โมเดลสามารถจำแนกภาพได้อย่างถูกต้องทั้งหมด 3,034 ครั้ง (True Positives) มีจำนวน 28 ครั้ง ที่โมเดลทำนายผิดว่าเป็นคลาสหนึ่ง ทั้งที่จริง ๆ แล้วเป็นอีกคลาสหนึ่ง (False Positives) และอีก 326 ครั้ง ที่ระบบทำนายผิดว่าไม่ใช่คลาสนั้น ๆ ทั้งที่จริง ๆ แล้วเป็นคลาสนั้น (False Negatives)

Confusion Matrix ตรงกลางใช้ประเมินการทำงานของโมเดลสำหรับการบอกสถานะท้องฟ้าของชุด Validation Data ทั้งหมด 720 ภาพ โดยแบ่งเป็นประเภทละ 180 ภาพ ได้แก่ Clear, Cloudy, Overcast และ Rainy จากการประเมิน โมเดลสามารถจำแนกภาพได้อย่างถูกต้องทั้งหมด 688 ครั้ง (True Positives) มีจำนวน 2 ครั้ง ที่โมเดลทำนายผิดว่าเป็นคลาสอื่น (False Positives) และอีก 72 ครั้ง ที่ระบบทำนายผิดว่าไม่ใช่คลาสนั้น ทั้งที่จริง ๆ แล้วเป็นคลาสนั้น (False Negatives)


Confusion Matrix ด้านขวาใช้ประเมินการทำงานของโมเดลสำหรับการบอกสถานะท้องฟ้าของชุด Test Data ทั้งหมด 720 ภาพ โดยแบ่งเป็นประเภทละ 180 ภาพ ได้แก่ Clear, Cloudy, Overcast และ Rainy จากการประเมิน โมเดลสามารถจำแนกภาพได้อย่างถูกต้องทั้งหมด 656 ครั้ง (True Positives) มีจำนวน 4 ครั้ง ที่ระบบจำแนกผิดว่าเป็นคลาสหนึ่ง ทั้งที่จริง ๆ แล้วเป็นอีกคลาสหนึ่ง (False Positives) และอีก 64 ครั้ง ที่ระบบทำนายผิดว่าไม่ใช่คลาสนั้น ทั้งที่จริง ๆ แล้วเป็นคลาสนั้น (False Negatives)

5.4 โมเดล ResNet-50 เลเยอร์สำคัญ ได้แก่ Input Layer สำหรับปรับขนาดภาพ, Convolutional Layers สำหรับดึงคุณลักษณะจากภาพ, Fully Connected Layer และ Classification Layer ที่ปรับให้เหมาะสมกับจำนวนคลาสใหม่ โดยการ Transfer Learning คือ โมเดลที่ฝึกแล้วจากงานอื่น มาปรับใช้กับงานใหม่ ลดเวลาและทรัพยากรที่ต้องใช้ในการฝึกโมเดลใหม่



รูปที่ 14 กราฟแสดงค่าความแม่นยำและค่าความสูญเสียในการฝึกโมเดล RestNet-50

จากรูปที่ 14 แสดงกราฟโดยมีการแบ่งข้อมูลที่ฝึกเป็นชุดฝึก 70% ชุดทดสอบ 15% และชุดการตรวจสอบความถูกต้องระหว่างการฝึก 15% จากกราฟค่าความแม่นยำที่มีค่าไม่แน่นอนในช่วงแรก ซึ่งบ่งบอกถึงการพัฒนาของโมเดลในการฝึกที่ยังไม่มีความคงที่ และค่าความแม่นยำในการฝึกเพิ่มขึ้นอย่างรวดเร็วในภายหลัง หมายความว่าโมเดลเริ่มเรียนรู้และปรับตัวให้ทำนายได้ถูกต้องมากขึ้น ในส่วนของกราฟค่าความสูญเสียที่ด้านล่าง จะเห็นได้ว่าค่าความสูญเสียยังคงอยู่ในระดับสูงมาก เนื่องจากกราฟไม่ใกล้ชิดกับเส้นฐานลดลงอย่างรวดเร็ว แสดงว่าโมเดลเริ่มเรียนรู้และปรับตัวดีขึ้น ทำให้มีข้อผิดพลาดน้อยลง



รูปที่ 15 Confusion Matrix การประเมินการทำงานของ Training Data และ Validation Data

จากรูปที่ 15 แสดง Confusion Matrix ด้านซ้ายใช้ประเมินการทำงานของโมเดลสำหรับการบอกสถานะท้องฟ้าของชุด Training Data ทั้งหมด 3,360 ภาพ โดยแบ่งเป็นประเภทละ 840 ภาพ ได้แก่ Clear, Cloudy, Overcast และ Rainy จากการประเมิน โมเดลสามารถจำแนกภาพได้อย่างถูกต้องทั้งหมด 3,360 ครั้ง (True Positives) ไม่มี จำนวนครั้งที่โมเดลทำนายผิดว่าเป็นคลาสหนึ่ง ทั้งที่จริง ๆ แล้วเป็นอีกคลาสหนึ่ง (False Positives) และไม่มี จำนวนครั้งที่โมเดลทำนายผิดว่าไม่ใช่คลาสนั้น ๆ ทั้งที่จริง ๆ แล้วเป็นคลาสนั้น (False Negatives)

แสดง Confusion Matrix ตรงกลางใช้ประเมินการทำงานของโมเดลสำหรับการบอกสถานะท้องฟ้าของชุด Validation Data ทั้งหมด 720 ภาพ โดยแบ่งเป็นประเภทละ 180 ภาพ ได้แก่ Clear, Cloudy, Overcast และ Rainy จากการประเมิน โมเดลสามารถจำแนกภาพได้อย่างถูกต้องทั้งหมด 720 ครั้ง (True Positives) ไม่มี การทำนายที่ผิดพลาด (ทั้ง False Positives และ False Negatives)

Confusion Matrix ด้านขวาใช้ประเมินการทำงานของโมเดลสำหรับการบอกสถานะท้องฟ้าของชุด Test Data ทั้งหมด 720 ภาพ โดยแบ่งเป็นประเภทละ 180 ภาพ ได้แก่ Clear, Cloudy, Overcast และ Rainy จากการประเมิน โมเดลสามารถจำแนกภาพได้อย่างถูกต้องทั้งหมด 720 ครั้ง (True Positives) ไม่มี การทำนายที่ผิดพลาด (ทั้ง False Positives และ False Negatives)

6. อภิปรายผล

ในการศึกษาครั้งนี้ ได้ทำการเปรียบเทียบประสิทธิภาพระหว่างโมเดลแบบต่างๆ โดยทำการทดสอบจากค่า Accuracy, Precision , Recall และ F1-score โดยแบ่งเป็นสามชุดคือ Training data, Validation data และ Test data เพื่อเปรียบเทียบค่าต่างๆ ดังนี้ โดย TP, TN, FP, FN ในตารางจะแทนด้วยค่าความถี่ในรูปแบบค่าต่างๆได้หลายค่า ได้แก่

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

$$\text{ค่าความแม่นยำ (Precision)} = \frac{TP}{(TP + FP)} \quad (2)$$

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

$$F1\text{-Score} = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (4)$$

จากตารางที่ 1 แสดงถึงการเปรียบเทียบประสิทธิภาพโมเดลจากค่าต่างๆ โดย GoogleNet และ ResNet-50 มีประสิทธิภาพสูงสุด (Accuracy, Precision, Recall, F1-score = 100%) แต่ GoogleNet ประมวลผลเร็วกว่ามาก (7 นาที) เทียบกับ ResNet-50 (65 นาที) HOG + Layer มีประสิทธิภาพรองลงมา (ประมาณ 90%) ด้วยความเร็วใกล้เคียง GoogleNet (6 นาที) Custom Model มีประสิทธิภาพต่ำสุด (ประมาณ 85%) และใช้เวลาประมวลผลนานกว่า HOG + Layer และ GoogleNet (21 นาที) โมเดลนี้ให้ความแม่นยำสูงกว่า แต่ต้องพิจารณาเรื่องเวลาประมวลผลด้วย โดยผลลัพธ์ GoogleNet และ ResNet-50 ทำได้ถึง 100% มาจากการใช้ Transfer Learning ซึ่งนำโมเดลที่เคยผ่านการฝึกมาแล้วจากชุดข้อมูลขนาดใหญ่มาใช้งานต่อ พร้อมปรับ ค่า Training Options ให้เหมาะกับข้อมูลใหม่ เพื่อช่วยให้โมเดลเรียนรู้ได้แม่นยำและลดปัญหา Overfitting ได้อย่างมีประสิทธิภาพ ซึ่งความแม่นยำที่สูงของ ResNet-50 มาจากโครงสร้างโมเดลที่ลึกและซับซ้อน จึงใช้เวลาประมวลผลมากกว่า GoogleNet ซึ่งมีโครงสร้างที่น้อยกว่าแต่ยังให้ผลลัพธ์ใกล้เคียงกัน

ตารางที่ 1 แสดงผลการเปรียบเทียบประสิทธิภาพของโมเดลจากชุด Training Data

Model	Accuracy	Precision	Recall	F1-score	time
custom model	85.14%	85.14%	88.56%	84.38%	21 min 23 sec
GoogleNet	100%	100%	100%	100%	7 min 43 sec
HOG+Layer	90.27%	90.29%	92.44%	89.98%	6 min 40 sec
RestNet-50	100%	100%	100%	100%	65 min 55 sec

ตารางที่ 2 แสดงผลการเปรียบเทียบประสิทธิภาพของโมเดลจากชุด Validation Data

Model	Accuracy	Precision	Recall	F1-score	time
custom model	86.11%	86.11%	88.98%	85.03%	21 min 23 sec
GoogleNet	100%	100%	100%	100%	7 min 43 sec
HOG+Layer	89.86%	89.86%	92.53%	89.46%	6 min 40 sec
RestNet-50	100%	100%	100%	100%	65 min 55 sec


จากตารางที่ 2 แสดงถึงการเปรียบเทียบประสิทธิภาพโมเดลจากค่าต่างๆ โดย ResNet-50 แม่นยำสูงสุด (100%) แต่ช้าสุด (65 นาที) GoogleNet แม่นยำเกือบเท่ากัน (99.86%) และเร็วกว่ามาก (7 นาที) HOG+Layer เร็วสุด (6 นาที) แต่แม่นยำลดลง (ประมาณ 91%) Custom Model แม่นยำน้อยสุด (ประมาณ 89%) และช้ากว่า HOG+Layer กับ GoogleNet (21 นาที) โดยของ ResNet-50 มาจากโครงสร้างโมเดลที่ลึกและซับซ้อน จึงใช้เวลาประมวลผลมากกว่า GoogleNet ซึ่งมีโครงสร้างที่น้อยกว่าแต่ยังให้ผลลัพธ์ใกล้เคียงกัน

ตารางที่ 3 แสดงผลการเปรียบเทียบประสิทธิภาพของโมเดลจากชุด Test Data

Model	Accuracy	Precision	Recall	F1-score	time
custom model	89.72%	89.72%	90.91%	89.28%	21 min 23 sec
GoogleNet	99.86%	99.86%	99.86%	99.86%	7 min 43 sec
HOG+Layer	91.25%	91.25%	93.27%	90.99%	6 min 40 sec
ResNet-50	100%	100%	100%	100%	65 min 55 sec

จากตารางที่ 3 แสดงถึงการเปรียบเทียบประสิทธิภาพโมเดลจากค่าต่างๆ โดย GoogleNet และ ResNet-50 แม่นยำสูงสุด (100%) โดยได้ค่าความถูกต้อง (Accuracy), ความแม่นยำ (Precision), ความไว (Recall) และ F1-score บน Test Data แต่ ResNet-50 ช้ากว่ามาก (65 นาที vs 7 นาที) HOG+Layer เร็วสุด (6 นาที) แต่แม่นยำลดลง (ประมาณ 90%) Custom Model แม่นยำน้อยสุด (ประมาณ 86%) และช้ากว่า GoogleNet กับ HOG+Layer (21 นาที) เลือกโมเดลโดยพิจารณาทั้งความแม่นยำและเวลาประมวลผล โดยผลลัพธ์ GoogleNet และ ResNet-50 ทำได้ถึง 100%

6.1 หน้าจอบรรบบเมื่อทดสอบกับโปรแกรม SkyCamera ขององค์กร



รูปที่ 16 การทดสอบระบบเพื่อใช้งานร่วมกับโปรแกรมขององค์กร

จากรูปที่ 16 แสดงให้เห็นถึงระบบที่มีการนำไปทดสอบร่วมกับโปรแกรม SkyCamera เพื่อหาสถานะท้องฟ้า โดยผลลัพธ์ของการทำงานหน้า Real-Time Data Display ที่แสดงภาพถ่ายท้องฟ้า สถานะท้องฟ้า ความน่าจะเป็น ที่เกิดขึ้นแบบเรียลไทม์ และกราฟ Sky Status over time แสดงผลลัพธ์ของสถานะท้องฟ้าที่เกิดขึ้นก่อนหน้า 10 ภาพ โดยมีวิศวกรวิจัยที่เปิดใช้งานเป็นเวลา 1-2 สัปดาห์เพื่อทดสอบระบบว่าสามารถทำงานร่วมกับโปรแกรมได้หรือไม่ และมีการทดสอบเพื่อนำมาปรับปรุงให้สามารถหาสถานะท้องฟ้าได้โดยมีการบันทึกข้อมูลระยะเวลาที่ถูกใช้งานไว้เป็นไฟล์ CSV

7. สรุปผลการวิจัย

จากการศึกษาการฝึก ทดสอบและประเมินผลโมเดลแบบต่างๆโดยใช้ MATLAB Deep Learning Toolbox ของ Chen, JiaCong (2019) เพื่อนำมาประยุกต์ใช้ในงานโดยมีการแบ่งชุดฝึก 70% ประเมิน15% และทดสอบ15% อ้างอิงจาก Panuwat Mekha, Nutnicha Teeyasuksaet, Khukrit Osathanunkul (2024) โดยปรับปรุงขนาดของชุดต่างๆให้เหมาะสมกับข้อมูลจะเห็นได้ว่า โมเดลที่มีประสิทธิภาพการทำงานที่ดีและสเถียรจากกราฟการฝึกจะเป็น GoogleNet และ ResNet-50 ซึ่งเป็นเครือข่ายออกนิยมจากงานวิจัยของ Neha Sharma , Vibhor Jain , Anju Mishra (2018) โดยที่ค่าความแม่นยำจะมีประสิทธิภาพสูงที่สุดแตกต่างกันเพียงระยะเวลาที่ใช้ในการฝึก ซึ่งมีความห่างกันคือ 7 นาที 43 วินาที และ 65 นาที 55 วินาที ตามลำดับ กรณีของ GoogleNet โมเดลนี้สามารถฝึกได้รวดเร็วกว่า ResNet-50 แต่ยังคงให้ผลลัพธ์ที่มีความแม่นยำสูงและมีความสามารถในการเรียนรู้จากข้อมูลที่มีลักษณะซับซ้อนได้ดี นอกจากนี้ GoogleNet ยังสามารถปรับขนาดของโมเดล

ได้ง่ายและมีการใช้พลังงานที่ค่อนข้างต่ำ ทำให้เป็นตัวเลือกที่ดีเมื่อมีข้อจำกัดในเรื่องของเวลาในการฝึก ในทางตรงกันข้าม ResNet-50 แม้จะมีการฝึกที่ช้ากว่า แต่สามารถให้ผลลัพธ์ที่มีความแม่นยำสูง และมีการจัดการกับปัญหาของการหายไปของกราเดียนต์ได้ดี ซึ่งเป็นข้อดีในการฝึกโมเดลลึกๆ ที่มีจำนวนเลเยอร์มาก การเลือกใช้ ResNet-50 จึงอาจจะเหมาะสมในกรณีที่ต้องการโมเดลที่มีความซับซ้อนสูงและต้องการประสิทธิภาพสูงสุดในแง่ของการจัดการกับข้อมูลที่มีลักษณะหลากหลายในกรณีของงานวิจัยนี้ หากจำนวนข้อมูลที่ใช้ในการฝึกมีแนวโน้มที่จะเพิ่มขึ้นอย่างมากในอนาคตและมีข้อจำกัดในเรื่องของเวลาการฝึก GoogleNet จึงเป็นตัวเลือกที่ดีที่สุด เนื่องจากมีความรวดเร็วในการฝึกและยังคงให้ความแม่นยำที่สูงเหมาะสมกับงานที่ต้องการผลลัพธ์อย่างรวดเร็ว

การทำงานของระบบในส่วน Real-time Display Data คือ การตรวจสอบสถานะห้องฟ้าทั้ง 4 ประเภท ได้แก่ ห้องฟ้าแจ่มใส มีเมฆ มีดคริมและฝนตกแบบเรียลไทม์โดยใช้เทคโนโลยีการเรียนรู้เชิงลึกจากงานวิจัยของ Li-Wei Kang, Ke-Lin Chou, Ru-Hong Fu (2018) โดยระบบสามารถอัปเดตสถานะทุก ๆ นาทีเมื่อมีภาพถ่ายใหม่เข้ามา นอกจากนี้ ผู้ใช้งานยังสามารถเลือกโมเดลที่ต้องการใช้ในระบบได้ตามความเหมาะสม ส่วนใน Historical Data ผู้ใช้งานสามารถเลือกวัน เดือน และปี เพื่อตรวจสอบสถานะห้องฟ้าในอดีต พร้อมทั้งเลือกโมเดลที่ต้องการใช้งานร่วมกับการระบุช่วงเวลาเพื่อแสดงกราฟของสถานะห้องฟ้าในเวลานั้น ๆ ในส่วนของการพัฒนาระบบ ใช้ภาษา C# ในรูปแบบเว็บแอปพลิเคชัน และใช้ MATLAB ในการพัฒนาโมเดลสำหรับการประมวลผลภายในระบบ

8. กิตติกรรมประกาศ

การพัฒนาโครงงาน เรื่อง ระบบจำแนกสถานะห้องฟ้าโดยใช้เทคโนโลยีการเรียนรู้เชิงลึกสำหรับกล้องถ่ายภาพทั่วห้องฟ้าของสถาบันวิจัยดาราศาสตร์แห่งชาติ (องค์การมหาชน) สำเร็จลุล่วงไปด้วยดีด้วยความกรุณาจากคณาจารย์และเจ้าหน้าที่ของสาขาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยแม่โจ้ ที่ รวมถึงสถาบันวิจัยดาราศาสตร์แห่งชาติ (องค์การมหาชน) ที่ช่วยเหลือให้คำปรึกษาและช่วยแก้ปัญหาที่เกิดขึ้นระหว่างการดำเนินโครงงานนี้

9. เอกสารอ้างอิง

ภานุวัฒน์ เมฆะ, พงศิพงศ์ มุสิกอง, ณัฐภาส ผลากอง, พาสณ์ ปราโมกษ์ชน และ พยุงศักดิ์ เกษม

สำราญ. (2566). การเปรียบเทียบประสิทธิภาพของโมเดลจำแนกภาพสำหรับโรคใบ

ข้าวโพด. วารสารแม่โจ้เทคโนโลยีสารสนเทศและนวัตกรรม, 9(2), 1-16.

ภานุวัฒน์ เมฆะ, ณัฐนิชา ตียะสุขเศรษฐ์, ศักดิ์สิทธิ์ โอสถานนัตกุล (2567). การเปรียบเทียบ

ประสิทธิภาพด้วยเครือข่ายประสาทเทียมจากการกำหนดค่าการเรียนรู้แบบต่าง ๆ

- สำหรับจำแนกภาพประเภทโรคอัลไซเมอร์ในมนุษย์. วารสารแม่โจ้เทคโนโลยีสารสนเทศและนวัตกรรม, 10(4), 1-18.
- ภาณุวัฒน์ เมฆะ, ญัฐนิชา ตียะสุขเศรษฐ์ (2567). การเปรียบเทียบประสิทธิภาพของอัลกอริทึมจำแนกภาพสำหรับโรคตาในมนุษย์. วารสารแม่โจ้เทคโนโลยีสารสนเทศและนวัตกรรม, 10(3), 1-16.
- Chen, J. (2019). **Deep learning for handwritten digits recognition using MATLAB toolbox** [Master's thesis, University of Victoria]. UVicSpace.
<http://hdl.handle.net/1828/11353>
- Ichim, L., & Popescu, D. (2017). **Retinal image segmentation based on weighted local detectors and confusion matrix**. *IEEE Transactions on Signal Processing*, 65(15), 4053-4064.
<https://doi.org/10.1109/TSP.2017.8076068>
- Hugo, Vega-Huerta., Kevin, Renzo, Pantoja-Pimentel., Sebastian, Yimmy, Quintanilla Jaimes., Gisella, Luisa, Elena, Maquen-Niño., Percy, De-La-Cruz-VdV., Luis, Guerra-Grados. (2024). **Classification of Alzheimer's Disease Based on Deep Learning Using Medical Images**. *International Journal of Online Engineering (ijoe)*, doi: 10.3991/ijoe.v20i10.49089
- L. -W. Kang, K. -L. Chou and R. -H. Fu, **Deep Learning-Based Weather Image Recognition**. 2018 International Symposium on Computer, Consumer and Control (IS3C), Taichung, Taiwan, 2018, pp. 384-387,
doi: 10.1109/IS3C.2018.00103.
- MathWorks. (n.d.). **Deep Learning Toolbox**. MathWorks. ค้นจาก
<https://ch.mathworks.com/products/deep-learning.html>
- MathWorks. (n.d.). **Train Deep Learning Model in MATLAB**. MathWorks. ค้นจาก
<https://ch.mathworks.com/help/deeplearning/ug/training-deep-learning-models-in-matlab.html>
- P. Mekha and N. Teeyasuksaet, **Image Classification of Rice Leaf Diseases Using Random Forest Algorithm**. 2021 Joint International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical,

Electronics, Computer and Telecommunication Engineering, Cha-am, Thailand, 2021, pp. 165-169, doi: 10.1109/ECTIDAMTNCON51128.2021.9425696.

Mekha, P., & Teeyasuksaet, N. (2019, January). **Deep learning algorithms for predicting breast cancer based on tumor cells.** In *2019 Joint International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunications Engineering (ECTIDAMT-NCON)* (pp. 343-346). IEEE.

Mekha, P., Teeyasuksaet, N., Sompowloy, T., & Osathanunkul, K. (2022). **Honey bee sound classification using spectrogram image features.** In *2022 Joint International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunications Engineering (ECTI DAMT & NCON)* (pp. 205–209). IEEE.