

การประยุกต์ใช้ YOLOv5 และ ReLU ในการพยากรณ์สภาพอากาศ สำหรับบริการอุตุนิยมวิทยาการบิน Application of YOLOv5 and ReLU for Weather Forecasting in Aeronautical Meteorological Services

ณัฐพงษ์ จันทรแดง

สถาบันนวัตกรรมมหานครคณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีมหานคร

Email: jnattapo@mut.ac.th

Manuscript Received December 15, 2024

Revised December 21, 2024

Accepted December 23, 2024

บทคัดย่อ

บทความนี้เปรียบเทียบการเรียนรู้เชิงลึก YOLOv5 และ ReLU เพื่อสร้างระบบทำนายสำหรับบริการอุตุนิยมวิทยาสำหรับการนำทางทางอากาศ โดยมีผลการพยากรณ์ทั้งหมด 5 ประเภท: BKN, CAVOK, FEW, OVER และ SCT ข้อมูลแสดงสำหรับการประเมินภาพคือการสังเกตลักษณะของเมฆที่จัดกลุ่มกันและเปรียบเทียบกับปริมาณในท้องฟ้าโดยใช้หน่วยวัด "โอกตา" ซึ่งแบ่งภาพออกเป็น 8 ส่วน ดังนั้นลักษณะการใช้การเรียนรู้เชิงลึกในบทความนี้คือการสอนการเรียนรู้เชิงลึกให้รู้จักลักษณะภาพต่างๆ ทั้งในเวลากลางวันและกลางคืนเพื่อใช้ผลการพยากรณ์ในการแจ้งเตือนสภาพอากาศในท้องฟ้า กระบวนการในบทความนี้ประกอบด้วย 3 ขั้นตอน: ขั้นตอนแรกคือการฝึกข้อมูลด้วยภาพที่มีลักษณะต่างๆ จาก 5 ประเภทข้อมูล ขั้นตอนต่อไปคือการทดสอบความแม่นยำของน้ำหนักที่สร้างจากการฝึกและขั้นตอนการฝึกขั้นตอนสุดท้ายคือการใช้ค่าน้ำหนักในการสร้างระบบตัดสินใจสำหรับผู้ใช้ จากการทดลอง ชุดข้อมูลส่วนตัวในบทความนี้ใช้ภาพมากกว่า 10,000 ภาพเข้าร่วมในการทดลอง ผลการทดลองพบว่าค่าเฉลี่ยของความแม่นยำจากอัลกอริทึม YOLOv5 และ ReLU สามารถวัดความแม่นยำเฉลี่ยได้ที่ 80.88% และ 76.82% ตามลำดับ

คำสำคัญ: YOLO, อุตุนิยมวิทยา, การเรียนรู้เชิงลึก

ABSTRACT

This paper compares the use of deep learning with YOLOv5 and ReLU to create a prediction system for Aeronautical Meteorological Services. The system forecasts five types of weather conditions: BKN, CAVOK, FEW, OVER, and SCT. The evaluative information for the images is based on observing the characteristics of grouped clouds and comparing them with quantities in the sky using the "okta" unit of measurement, which divides each image into eight parts. Thus, the deep learning aspect of this paper involves teaching the model to recognize various image characteristics both during the day and at night to use the forecast results to inform sky conditions. The process described in this article involves three steps: The first step is to train the data with images that have varying characteristics from the five data types. The next step is to test the accuracy of the weights generated from the training and training steps. The final step is to use the weights to create a decision-making system for users. From the experiment, a private dataset in this article used more than 10,000 images in the testing. The experimental results found that the average accuracy results for the YOLOv5 and ReLU algorithms could be measured at 80.88% and 76.82%, respectively.

Keywords: YOLO, Meteorological, Deep Learning

1. บทนำ

การประมวลผลภาพคือการรวบรวมและการวิเคราะห์ข้อมูลภาพอย่างเป็นระบบ ได้ถูกใช้เป็นวิธีการวิจัยตั้งแต่อดีตจนถึงปัจจุบัน และยังคงเป็นหัวข้อที่ได้รับความนิยมกันอย่างแพร่หลาย การวิจัยด้านการประมวลผลภาพนี้ช่วยให้นักวิจัยสามารถสรุปข้อมูลที่มีค่าจากข้อมูลภาพที่สามารถสังเกตได้ง่าย สาเหตุหนึ่งที่ทำให้การประมวลผลด้วยข้อมูลภาพนั้นโดดเด่นคือ ข้อมูลจากภาพที่ใช้ในการวิเคราะห์มักจะต้องอาศัยสมมติฐานในการหาหรือประเมินผลการแก้ปัญหา โดยอิงตามแนวทางที่จัดตั้งขึ้นจากลักษณะของข้อมูลที่มองเห็นซึ่งสามารถตรวจจับได้ด้วยตามนุษย์ การวิเคราะห์ต่าง ๆ เหล่านี้รวมถึงการประเมินภาพด้วยสี ขนาด และความสัมพันธ์เชิงพื้นที่ระหว่างวัตถุในภาพ เป้าหมายแรกๆของการวิเคราะห์ภาพที่ถูกพิจารณาด้วยวิธีการคำนวณต่าง ๆ นั้นถูกออกแบบมาเพื่อเลียนแบบความสามารถทางการวิเคราะห์ของมนุษย์ [1] – [2] ต่อมาอัลกอริทึมจำนวนมากเกิดขึ้น โดยมีจุดมุ่งเน้นที่งานที่แตกต่างกันไป เช่นการจำแนกประเภทภาพ การตรวจจับวัตถุ และการรู้จำรูปแบบ เป็นต้น

นอกจากนี้ อัลกอริทึมเหล่านี้ในปัจจุบันได้ถูกรวมเข้ากับเทคโนโลยีสมัยใหม่เพิ่มขึ้นเรื่อย ๆ เนื่องจากฮาร์ดแวร์ปัจจุบันสามารถจัดการกับงานที่ซับซ้อนได้มากขึ้น เช่น การผสมผสานเทคนิคการประมวลผลภาพกับเทคโนโลยี AI [3] การรวมกันนี้นำไปสู่นวัตกรรมที่หลากหลายมากขึ้น อีกทั้งยังช่วยเร่งการวิจัยได้อย่างมากเนื่องจาก AI สามารถทดแทนวิธีการทำงานด้วยตนเองด้วยการใช้พลังการคำนวณของการประมวลผลภาพ AI อีกทั้งยังช่วยค้นพบวิธีแก้ปัญหาแบบใหม่ ได้หลายวิธี ตัวอย่างเช่น การศึกษาเช่นการลดเวลาการคำนวณของวิธี trace-transform โดยใช้ AI [4] ขณะที่ [5] ได้ใช้ AI เพื่อกำหนดทิศทางการหมุนของวัตถุ นอกจากนี้ยังมีการพัฒนาอัลกอริทึมเพื่อเสริมความสามารถของการเรียนรู้ลึกทำให้สามารถใช้แบบจำลองที่ถูกฝึกสอนไว้ล่วงหน้าเพื่อการวิเคราะห์ข้อมูลที่แม่นยำยิ่งขึ้น เป็นต้น

การอุตุนิยมวิทยาการบิน ซึ่งเป็นสาขาหนึ่งของการอุตุนิยมวิทยาภายใต้องค์การอุตุนิยมวิทยาโลก (WMO) มุ่งเน้นไปที่ความสัมพันธ์ระหว่างสภาพอากาศและการนำทางทางอากาศ การเปลี่ยนแปลงของสภาพอากาศไม่ว่าจะเป็นบวกรหรือลบ สามารถส่งผลโดยตรงต่อการดำเนินการบินได้ แต่ละเที่ยวบินถูกแบ่งออกเป็นสามขั้นตอนหลัก: การขึ้น การบิน และการลง ระหว่างขั้นตอนเหล่านี้ นักบินและนำทางต้องเตรียมตัวอย่างรอบคอบสำหรับการขึ้นและการลง โดย


ข้อมูลอุตุนิยมวิทยามีบทบาทสำคัญในการตัดสินใจเหล่านี้ ผลลัพธ์คือ การพยากรณ์อากาศซึ่งได้จากชุดข้อมูลต่างๆ ได้กลายเป็นเครื่องมือที่สำคัญ โดยเฉพาะเมื่อรวมกับ AI ในการทำนายผลลัพธ์ ตัวอย่างเช่น ข้อมูลอุตุนิยมวิทยาได้ถูกนำไปใช้ในหลายด้าน รวมถึง [6] การจัดการบนแพลตฟอร์มข้อมูลขนาดใหญ่ [7] – [8] การพยากรณ์สภาพอากาศ และ [9] – [11] การทำนายสภาพอากาศผ่านการผสานข้อมูลจากเมฆและภาพถ่ายดาวเทียมโดยใช้ข้อมูลหลายโมด

ระบบนี้ช่วยเสริมสภาพแวดล้อมของอากาศยานที่สนามบินโดยให้ข้อมูลสภาพอากาศที่สำคัญแก่สถานีภาคพื้นและเครื่องบิน โดยการใช้อัลกอริทึม YOLO [12] ในการวิเคราะห์ภาพท้องฟ้าและเมฆเพื่อสร้างการทำนายที่แม่นยำอย่างอิสระ YOLO ประมวลผลภาพเหล่านี้โดยจัดหมวดหมู่ข้อมูลผ่านชั้นที่ซ่อนอยู่ หนึ่งในเป้าหมายหลักคือการรับประกันความแม่นยำในขณะที่รักษาประสิทธิภาพของระบบ ทำให้สามารถเข้าถึงได้บนอุปกรณ์คอมพิวเตอร์มาตรฐาน

2. แนวคิดและทฤษฎี

2.1 การแบ่งประเภทของเมฆ

เมฆ (Cloud) เป็นสิ่งที่เกิดขึ้นจากการยกตัวของไอน้ำในบรรยากาศตามแนวดิ่ง จนเกิดการกลั่นตัวเป็นหยดน้ำขนาดเล็กและรวมตัวอยู่เป็นกลุ่มก้อน อาจมีสภาพเป็นอนุภาคเล็กๆของน้ำหรือน้ำแข็ง หรือทั้งสองอย่างปนกันลอยอยู่ในอากาศ สามารถมองเห็นได้ดังรูปที่ 1



รูปที่ 1 การเกิดเมฆ

ทางอุตุนิยมวิทยาจะทำการตรวจวัด ชนิด จำนวน และความสูงของฐานเมฆเราอาจจัดแบ่งออกเป็นประเภทใหญ่ ๆ สองประเภท คือ ประเภทเมฆก้อน (Cumuliform Clouds) คือประเภทของเมฆ

ที่มีลักษณะเป็นก้อน ๆ หรือคล้ายกับก้อนสำลีขนาดใหญ่ ซึ่งมักมีการเติบโตในแนวดิ่ง ลักษณะที่โดดเด่นของเมฆประเภทนี้คือมีโครงสร้างที่หนาและมีความชัดเจนที่ด้านบน ได้แก่เมฆจำพวกที่มีการก่อตัวในทางตั้งอาจเป็นอาการ Convention หรือการที่อากาศไหลขึ้นไปตามลาดเขา หรือตามแนวปะทะอากาศ เป็นต้น โดยเมฆก้อนมักเกิดจากการพลัดกันของอากาศชั้นล่างที่อุ่นชื้นและชั้นสูงชั้นบรรยากาศที่สูงขึ้น ซึ่งทำให้อากาศเย็นลงและกลายเป็นหยดน้ำหรือผลึกน้ำแข็ง โดยเมฆชนิดนี้จะเห็นได้บ่อยในวันที่อากาศแจ่มใสหรือมีลมพัดอ่อนๆ แต่เมฆก้อนบางชนิด เช่น Cumulonimbus ก็สามารถนำมาซึ่งฝนฟ้าคะนองและสภาพอากาศเลวร้ายได้ เมฆก้อนเป็นตัวบ่งชี้ถึงการเปลี่ยนแปลงของอากาศในระดับท้องถิ่น และเป็นหนึ่งในเมฆที่น่าสนใจที่สุดในการสังเกตการณ์สำหรับผู้สนใจด้านอุตุนิยมวิทยา

ประเภทเมฆแผ่น (Stratiform Clouds) เป็นชนิดของเมฆที่มีลักษณะเป็นแผ่นหรือชั้นคล้ายผ้าปูที่เรียบและกว้าง แผ่ขยายไปทั่วท้องฟ้า โดยทั่วไปเมฆแผ่นมีความหนาแน่นต่ำและมักปกคลุมท้องฟ้าในพื้นที่กว้างโดยไม่มีลักษณะที่ชัดเจนเหมือนก้อนหรือยอดเขา ได้แก่เมฆจำพวกที่มีการถ่ายเทอากาศในทางนอน เมฆจึงมีการแผ่ตัวออกไปในทางแนวนอน ทำให้จับตัวอยู่เป็นแผ่น เมฆประเภทนี้มักเกิดจากการเคลื่อนตัวช้าๆ ของอากาศชั้นที่แผ่กระจายอย่างสม่ำเสมอในแนวนอน มักพบในสภาวะที่อากาศมีความชื้นสูงและมีการรวมตัวของอากาศเย็นชนิดหนึ่ง ไม่ใช้การขึ้นสู่ชั้นบรรยากาศอย่างรวดเร็วเหมือนกับเมฆก้อน โดยเมฆแผ่นมักนำมาซึ่งสภาพอากาศที่มีดึกครึ้มและหม่นหมอง แต่ไม่จำเป็นต้องมีฝนตกเสมอไป พวกมันบ่งบอกถึงสภาวะอากาศที่มีความชื้นสูงและอาจนำไปสู่การตกของน้ำฝนหรือหิมะในบางกรณี

2.2การตรวจจำนวนเมฆ

เมื่อได้ทำการตรวจชนิดของเมฆแล้ว จำเป็นต้องทราบจำนวนของเมฆที่มีอยู่ในท้องฟ้าด้วยตามรหัสอุตุนิยมวิทยาสากลได้กำหนดให้แบ่งท้องฟ้าออกเป็น 8 ส่วน หน่วยการวัดเรียกว่า “Okta” หมายถึงจำนวนเมฆที่ส่วนใน 8 ส่วนของท้องฟ้า ดังรูปที่ 2

ถ้าท้องฟ้ามีเมฆเพียงเล็กน้อย อาจใช้เลขรหัสหมายเลข 1 หมายความว่าเมฆเพียงเล็กน้อยขึ้นไปจนถึง 1/8 ส่วน ไม่ใช่ถึง 3/16 ส่วน และถ้าท้องฟ้าครึ้มฝน แต่ยังมีช่องว่างพอมองเห็นท้องฟ้าอยู่ ให้ใช้เลขรหัสหมายเลข 7 หมายความว่าเมฆจำนวนมากลงไปถึง 7/8 ส่วน (ไม่ใช่ลดน้อยลงไปถึง 13/16 ส่วน)

สัญลักษณ์	เลขรหัส	จำนวนเมฆท้องฟ้า
○	0 0	0
◐	1 1	อีกด้านหรือต่ำกว่า แต่ไม่ถึง 0
◑	2 2	อีกด้าน
◒	3 3	อีกด้าน
◓	4 4	อีกด้าน
◔	5 5	อีกด้าน
◕	6 6	อีกด้าน
◖	7 7	อีกด้านหรือมากกว่า แต่ไม่ถึง 8 อีกด้าน
◗	8 8	อีกด้าน
⊗	9	ท้องฟ้ามืดครึ้ม หรือไม่สามารถกะประมาณจำนวนเมฆได้
⊘	/	ไม่ได้ทำการตรวจ

รูปที่ 2 การแบ่งจำนวนเมฆ

อนึ่งการตรวจจำนวนเมฆนั้น ให้แยกตรวจเป็นประเภทเมฆชั้นต่ำ ชั้นกลาง และชั้นสูง ออกเป็นพวก ๆ เสียก่อน จำนวนเมฆเป็นชั้น ๆ นั้นเมื่อรวมกันแล้ว อาจมากกว่าจำนวนเมฆรวมทั้งท้องฟ้าเมื่อตรวจเห็นว่าเมฆนั้นซ้อนกันอยู่

การรายงานจำนวนเมฆ (จากจำนวน 8 ส่วน)

- จำนวนเมฆ 1-2 ส่วน ใช้อักษรย่อ FEW
- จำนวนเมฆ 3-4 ส่วน ใช้อักษรย่อ SCT
- จำนวนเมฆ 5-7 ส่วน ใช้อักษรย่อ BKN
- จำนวนเมฆ 8 ส่วนหรือเต็มท้องฟ้า ใช้อักษรย่อ OVC

2.3 Convolutional Neural Network (CNN)

เป็นแบบจำลองปัญญาประดิษฐ์ที่มีความเชื่อมโยงกับ Neural Network แต่ใช้เทคนิคการประมวลผลภาพเพิ่มเติม เพื่อให้การทำงานมีประสิทธิภาพและความแม่นยำสูงขึ้น CNN มีโครงสร้างเป็นชั้น (layer) โดยแต่ละชั้นจะประกอบด้วยชั้นการประมวลผลต่าง ๆ เช่น ชั้น


ก. Convolutional Layer, Pooling Layer และ Fully Connected Layer ที่ทำหน้าที่ในการประมวลผลภาพเพื่อให้สามารถแยกแยะภาพของจำนวนเมฆได้

ข. Convolutional Layer เป็นชั้นที่ทำหน้าที่ในการหา Feature ของภาพเพื่อนำมาใช้ในการจำแนกภาพ โดยใช้ Filter หรือ Kernel ในการสกัด Feature และนำไปคำนวณเพื่อสร้าง Feature Map ตามลักษณะของฟีเจอร์ที่ต้องการจำแนก ซึ่งจะช่วยลดขนาดของภาพเพื่อเป็นการลดความซับซ้อนในการคำนวณ

ค. Pooling Layer เป็นชั้นที่ใช้ในการลดขนาดของ Feature

Map ที่ได้จากConvolutional Layer โดยมีวิธีการหลายแบบ เช่น Max Pooling หรือ Average Pooling เพื่อให้การคำนวณเร็วขึ้น และลดความซับซ้อนในการคำนวณ

ง. Fully Connected Layer เป็นขั้นที่ใช้ในการจำแนกภาพ โดยมีโครงสร้างไปยังขั้นตอนการเรียนรู้และวิเคราะห์ข้อมูลจาก Feature Map ที่ได้จาก Convolutional Layer และ Pooling Layer โดยใช้ Fully Connected Layer ในการจำแนกภาพเป็นภาพเมฆตามคลาสที่กำหนดไว้ โดย Fully Connected Layer จะรวม Feature ที่ได้จากการสกัดเอาไว้ในแต่ละ Layer แล้วนำมาคำนวณด้วย Neural Network ที่มีความซับซ้อนเพื่อให้ได้ผลลัพธ์ว่าเป็นเมฆตามคลาสที่กำหนดไว้ อีกทั้งการใช้ Convolutional Neural Network ในการวิเคราะห์ภาพเมฆมีข้อดีหลายอย่าง เช่น มีความแม่นยำสูงในการวิเคราะห์ โดยการใช้ Convolutional Layer และ Pooling Layer ในการสกัด Feature ของภาพทำให้สามารถแยกคลาสของเมฆได้อย่างแม่นยำ




รูปที่ 3 โครงสร้างแบบจำลอง CNN

2.4 YOLO

YOLO (You Only Look Once) เป็นหนึ่งในระบบการตรวจจับวัตถุ (Object Detection System) ที่มีความสามารถในการทำนายตำแหน่งและหมวดหมู่ของวัตถุในภาพเพียงครั้งเดียวจากการสแกนภาพ ซึ่งแตกต่างจากระบบอื่น ๆ ที่อาจต้องทำการสแกนหลายครั้ง ลักษณะการทำงานของ YOLO ทำการวิเคราะห์ภาพโดยแบ่งภาพออกเป็นตารางเซลล์ ๆ และทำนายบาวดิงบ็อกซ์ (Bounding Boxes) และความน่าจะเป็นสำหรับแต่ละคลาสหรือหมวดหมู่ของวัตถุที่อาจปรากฏอยู่ในเซลล์นั้น ๆ ต่างจากระบบตรวจจับวัตถุแบบเดิมที่จะมองหาพื้นที่ที่น่าสนใจในภาพก่อนแล้วจึงทำการทำนายว่าพื้นที่นั้นมีวัตถุประเภทใดบ้าง YOLO ทำการทำนายทั้งพื้นที่และหมวดหมู่ของวัตถุในขั้นตอนเดียวกัน ลดเวลาที่ต้องใช้และทำให้การตรวจจับวัตถุมีความเร็วมากขึ้น

มีหลายรุ่นของ YOLO ตั้งแต่ YOLOv1 จนถึงปัจจุบันคือ YOLOv11 ซึ่งสำหรับเวอร์ชัน v11 นี้จะยังไม่ได้ถูกกล่าวถึงภายในบทความ แต่ละรุ่นมีการปรับปรุงในด้านของความแม่นยำและความเร็วในการทำนาย รวมถึงโครงสร้างของแบบจำลองรุ่นใหม่ มักจะมีการปรับใช้เทคนิคต่าง ๆ เช่น Batch Normalization, Skip Connections, หรือ Multi-Scale Predictions เพื่อปรับปรุงประสิทธิภาพ ดังรูปที่ 4




รูปที่ 4 ประสิทธิภาพของ YOLO ในแต่ละรุ่น

โครงสร้างของ YOLO มักจะเป็น Convolutional Neural Network (CNN) ที่ประกอบด้วยชั้นต่าง ๆ เช่น Convolutional Layer, Batch Normalization Layer, Activation Layer และ Layer สุดท้ายที่ทำการทำนายอ็อบเจกต์

2.5 YOLOv5


YOLOv5 เป็นอัลกอริธึมสำหรับการตรวจจับวัตถุ ซึ่งได้รับการออกแบบโดยใช้ข้อมูลที่เกี่ยวข้องกับคุณสมบัติจากรูปภาพอินพุต โดยคุณสมบัติจากรูปภาพเหล่านี้จะถูกป้อนเข้าสู่ระบบเพื่อนำไปสู่การทำนายเพื่อและทำการวาดกรอบรอบวัตถุเพื่อทำนายคลาสดังรูปที่ 5



รูปที่ 5 การค้นหวัตถุของ YOLO

• แบบจำลอง YOLO เป็นเครื่องมือสำหรับตรวจจับวัตถุที่เชื่อมต่อขั้นตอนการทำนายผลลัพธ์จากกรอบข้อมูลที่มีการกำหนดขอบเขตด้วยป้ายกำกับคลาสในเครือข่ายที่สามารถหาอนุพันธ์ได้ตั้งแต่ต้นจนจบ โดยเครือข่าย YOLO ประกอบด้วย 3 ส่วนหลักดังรูปที่ 6 โดยประกอบไปด้วย

- Backbone : โครงข่ายประสาทเทียมที่รวบรวมและสร้างฟีเจอร์รูปภาพในรายละเอียดที่แตกต่างกัน
- Neck : ชุดของชั้นสำหรับผสมและรวมคุณลักษณะของรูปภาพเพื่อส่งต่อข้อมูลที่ถูกรองสำหรับนำไปฝึกสอนหรือทำนาย
- Head: เป็นส่วนของการใช้คุณสมบัติจากส่วน Neck และทำตามขั้นตอนการทำนายข้อมูลภายในกรอบออกมาตามคลาสที่กำหนดไว้



รูปที่ 6 โครงสร้างการค้นหาวัตถุของ YOYO

การทำงานของ YOLOv5 มีการใช้วิธีการพยากรณ์คำตอบโดยวิธีการ “Anchor-Based Prediction” ซึ่งจะใช้ anchor boxes ในการคาดคะเนตำแหน่งของวัตถุที่จะถูกตีกรอบเพื่อกำหนดขนาดและอัตราส่วนล่วงหน้าเพื่อช่วยในการทำนายกลุ่มข้อมูลที่เหมาะสม โดยจะเขียนได้ดังสมการที่ 1


$$Loss_{object} = \sum_{i=1}^N (1 - IOU) + \sum_{j=1}^N (\text{Confidence Loss}) \quad (1)$$

$$IOU = \frac{\text{Area of Overlap}}{\text{Area of Union}} \quad (2)$$

เมื่อ IOU อยู่ในช่วง [0,1] โดยหาก IOU สูง (ใกล้ 1) หมายถึงการคาดการณ์ bounding box แม่นยำ และ Loss ต่ำ และหาก IOU ต่ำ (ใกล้ 0) หมายถึงการคาดการณ์คลาดเคลื่อนมาก และ Loss สูง และสามารถคำนวณ Confidence Loss (C) ได้จากสมการที่ 3

$$C = P(\text{object}) \times IOU_{pred,truth} \quad (3)$$

เมื่อ $P(\text{object})$ เป็นความน่าจะเป็นที่มีวัตถุ และคือ $IOU_{pred,truth}$ ค่า IOU ระหว่าง predicted box และ ground truth box ดังนั้นจะสามารถแสดงค่าการตรวจสอบ IOU จากสมการได้ดังรูปที่ 7



รูปที่ 7 ขั้นตอนการทำงาน IOU

2.6 CSP Backbone

CSP (Cross Stage Partial Network) ใน YOLOv5 ถูกนำมาใช้เพื่อเพิ่มประสิทธิภาพของโครงข่ายเชิงลึก (Deep Neural Network) โดยเฉพาะในส่วน Backbone ของ YOLOv5 ซึ่ง CSPNet ถูกนำมาใช้เพื่อลดปริมาณการคำนวณ ลดความต้องการหน่วยความจำ และยังเพิ่มความสามารถในการเรียนรู้ของแบบจำลอง CSPNet ใช้แนวคิดในการแบ่ง feature map ออกเป็นสองส่วน แล้วรวมเฉพาะบางส่วนของข้อมูลเข้าไปใน layer ลึก ๆ ของเครือข่าย ซึ่งประกอบไปด้วยขั้นตอนหลักดังนี้

2.6.1. การแบ่ง Feature Map

Feature map ที่ได้จาก layer ก่อนหน้าจะถูกแบ่งออกเป็นสองส่วน คือ F_a และ F_b โดย F_a จะถูกส่งไปยังเส้นทางหลักของแบบจำลอง และจะถูกผ่าน layer ในชั้นลึกของเครือข่ายและ F_b จะถูกส่งไปยังเส้นทางที่แยกออกมาซึ่งไม่ต้องการการประมวลผลที่ซับซ้อน โดยเส้นทางนี้จะถูกเก็บไว้และรวมกับ F_a ในภายหลัง


2.6.2. การเชื่อมต่อ

แทนที่จะใช้การเชื่อมต่อข้อมูลในลักษณะทั่วไปซึ่งเชื่อมข้อมูลจากชั้นต้นทางกับชั้นปลายทางแบบเต็ม แต่รูปแบบของ CSP จะใช้วิธีการ การเชื่อมต่อแบบบางส่วน (Partial Residual Connections) เพื่อทำให้การคำนวณนั้นไม่ซ้ำซ้อนโดยจะช่วยให้ข้อมูลที่ส่งผ่านไปมีความหลากหลายมากขึ้น และช่วยให้การไหลของข้อมูลมีประสิทธิภาพ

2.6.3. การรวมข้อมูล

หลังจากที่ F_b ถูกส่งผ่านชั้นลึกแล้ว ข้อมูลจาก F_b จะถูกรวมเข้ากับ F_b เพื่อให้ได้ Feature map ที่มีข้อมูลเชิงลึกและหลากหลายมากขึ้น การรวมข้อมูลนี้ทำให้ข้อมูลที่อยู่ใน feature map มีการแสดงผลที่ครอบคลุมและครบถ้วนมากขึ้น โดยข้อมูลที่ถูกประมวลผลกับข้อมูลที่ไม่ได้ประมวลผลจะถูกเชื่อมต่อกันเพื่อให้เกิดการสรุปที่แม่นยำยิ่งขึ้น

โดยประโยชน์และความสำคัญของ CSPNet ใน YOLOv5 คือ CSPNet จะช่วยลดการคำนวณที่ซ้ำซ้อนโดยการแยกการประมวลผลบางส่วนออกจาก feature map ออก ซึ่งทำให้ไม่จำเป็นต้องผ่านชั้นลึกของแบบจำลองทั้งหมด ซึ่งช่วยลดทั้งเวลาและหน่วยความจำในการคำนวณ อีกทั้งการแบ่ง และรวมข้อมูลช่วยให้ CSPNet สามารถสกัดข้อมูลได้ดีขึ้น เพราะมีการประมวลผลแบบคู่ขนานระหว่างส่วนที่ผ่านชั้นลึกและส่วนที่เก็บข้อมูลดั้งเดิม ทำให้แบบจำลองสามารถเรียนรู้ feature ที่หลากหลายได้มากขึ้น ซึ่งช่วยเพิ่มความแม่นยำของการตรวจจับ และอีกทั้ง CSPNet ช่วยลดปริมาณการคำนวณ ทำให้ YOLOv5 สามารถตรวจจับวัตถุได้เร็วขึ้นและยังคงความแม่นยำไว้ได้ดีเพราะจำนวนพารามิเตอร์ลดลง ซึ่งส่งผลให้ latency ของแบบจำลองต่ำลง โดยจะสามารถแสดงการทำงานของ CSP ร่วมกับ YOLO ได้ดังรูปที่ 8




รูปที่ 8 CSP (Cross Stage Partial Network)

2.7 ภาพรวมของระบบ

การทำงานของระบบมี การเก็บข้อมูลภาพจากสถานีตรวจอากาศ โดยกล้องจะถ่ายภาพท้องฟ้า (Fisheye View) เพื่อเก็บข้อมูลลักษณะของเมฆและสภาพอากาศในปัจจุบัน เพื่อส่งข้อมูลภาพ

เข้าสู่ระบบ AI แบบจำลองนี้ได้รับการฝึกด้วยข้อมูลภาพที่ถูกแยกประเภทตามลักษณะของเมฆ (เช่น CAVOK, FEW, SCT, BKN, OVC) เพื่อให้สามารถจำแนกประเภทของท้องฟ้าได้ การประมวลผลด้วยแบบจำลอง AI มีกระบวนการ Weight แบบจำลองใช้ค่าพารามิเตอร์ที่ได้รับการฝึกมาเพื่อวิเคราะห์ข้อมูลภาพ และส่งค่าพยากรณ์ของแบบจำลองจะประมวลผลภาพและสร้างผลลัพธ์ออกมาเป็นค่าความน่าจะเป็นของแต่ละคลาสดังรูปที่ 9



รูปที่ 9 System Overview

2.7.1 Input/Output Specification

Input/Output Specification ในรายงานสภาพอากาศจากภาพถ่ายด้วยปัญญาประดิษฐ์นั้น สามารถกำหนดได้ตามลักษณะของข้อมูลที่ระบบต้องการรับเข้ามาและส่งออกได้ โดยสามารถระบุ Input/Output Specification ได้ดังนี้

Input Specification

- รูปภาพของเมฆ รูปแบบไฟล์ภาพที่รองรับ JPG,PNG
- ขนาดของภาพ ที่มีความละเอียดอย่างน้อย 320 x 320 พิกเซล และมีขนาดไฟล์ไม่เกิน 5 MB
- รูปแบบไฟล์ควรเป็นไฟล์ดิจิทัลแบบสมบูรณ์ ไม่ควรมีการตัดขาดหรือสแกนบางส่วน

Output Specification


- ผลลัพธ์การวิเคราะห์เมฆ

2.7.2 Input/Output Specification

โดยภาพรวมการทำงานส่วนของการฝึกสอนและการนำแบบจำลองไปใช้งานจะแสดงได้ดังรูปที่ 10 ซึ่งเป็นการพยากรณ์สภาพอากาศจากภาพถ่ายด้วยปัญญาประดิษฐ์ สามารถเขียนสรุป

เป็นขั้นตอนของการทำงานได้ดังนี้

- การรับภาพเมฆ ระบบจะทำการดึงภาพถ่ายเมฆ ณ ปัจจุบันจาก server ที่ สนามบินอุตะเกา และส่งผ่านเข้าสู่ระบบการพยากรณ์คำตอบโดยผ่านการหน้าต่าง UX/UI สำหรับติดต่อกับผู้ใช้งาน



รูปที่ 10 ขั้นตอนการทำงานของระบบ

- การวิเคราะห์ ระบบจะใช้แบบจำลองปัญญาประดิษฐ์ อย่างเช่น Convolutional Neural Network (CNN) หรือ YOLOv5 เป็นต้น ในการวิเคราะห์จำนวนเมฆบนท้องฟ้า

- การแสดงผลลัพธ์ ระบบจะแสดงผลลัพธ์ของการพยากรณ์คำตอบที่ส่วนของหลังบ้านของระบบ และทำการส่งผ่านข้อมูลผลลัพธ์จากการพยากรณ์กลับไปสู่การแสดงผลที่หน้า UX/UI สำหรับติดต่อกับผู้ใช้งาน

- การจัดการข้อมูล ระบบจะจัดการข้อมูลภาพเมฆที่รับเข้ามา และผลลัพธ์จากการวิเคราะห์ เพื่อให้ผู้ใช้งานสามารถดูประวัติการวิเคราะห์ได้

- การเข้าถึงข้อมูล ระบบจะมีการตรวจสอบสิทธิ์การเข้าถึงข้อมูล เพื่อป้องกันการเข้าถึงข้อมูลโดยไม่ได้รับอนุญาต

3. การทดลอง

3.1 การเตรียมข้อมูล

ข้อมูลที่ใช้ประกอบด้วยภาพถ่ายท้องฟ้า จำนวน 10,000 ภาพ โดยถูกแบ่งออกเป็นห้าคลาสดังนี้


- Class FEW คือการแทนค่าจำนวนเมฆ 1-2 ส่วน จาก 8 ส่วน
- Class SCT คือการแทนค่าจำนวนเมฆ 3-4 ส่วน จาก 8 ส่วน

- Class BKN คือการแทนค่าจำนวนเมฆ 5-7 ส่วน จาก 8 ส่วน
- Class OVC คือการแทนค่าจำนวนเมฆ ปกคลุมเต็มท้องฟ้า
- Class CAVOK คือการแทนค่าที่ฟ้าโปร่งใส ไม่มีก้อนเมฆ

ข้อมูลทั้งหมดได้รวบรวมทุกสภาพอากาศ ทั้ง 3 ฤดู ณ สนามบินอุตะเกา และได้รับการแนะนำแบ่ง Class จากเจ้าหน้าที่ตรวจอากาศการบิน และนักพยากรณ์อากาศ เพื่อให้แบบจำลองสามารถเรียนรู้ได้ดีขึ้น

3.2 การฝึกสอนและการทดสอบ

ภายในการทดลองจากบทความฉบับนี้ได้มีการเตรียมรูปภาพท้องฟ้าจำนวน 10,000 รูป โดยแบ่งเป็น 5 คลาส ขั้นตอนในการแบ่งคลาสจะถูกกำหนดขอบเขตของการฝึกสอน ดังรูปที่ 11 กำหนดขอบเขตของภาพเพื่อป้องกันการวิเคราะห์ภาพในส่วนที่ไม่ต้องการ และลดขนาดของกรอบการวิเคราะห์ภาพให้การวิเคราะห์ผลลัพธ์ได้ไวขึ้น การแยกคลาสจะได้รับการชี้แนะจากผู้ตรวจอากาศการบินที่มีประสบการณ์




รูปที่ 11 การกำหนดขอบเขตในการฝึกสอน

แบบจำลองได้รับการฝึกสอนโดยใช้ชุดข้อมูลที่ทำการแยกคลาสเตรียมไว้ การฝึกสอนได้รับการดำเนินการตั้งค่ามากกว่า 100 รอบ (Epochs) เพื่อให้แบบจำลองสามารถปรับเปลี่ยนค่าน้ำหนักและการเรียนรู้ลักษณะเฉพาะของภาพท้องฟ้า โดยภายใต้การทดลองนี้ได้ทำการฝึกสอนแบบจำลองไว้ 2 แบบคือ YOLOv5 และ ReLU โดยใช้ข้อมูลชุดเดียวกัน

สำหรับแบบจำลอง YOLOv5 จะมีข้อมูลภาพและป้ายกำกับ (label) ที่ประกอบด้วยคลาสของวัตถุและตำแหน่ง bounding

boxes จะถูกเตรียมในรูปแบบที่ YOLO รองรับ ข้อมูลจะถูกแบ่งเป็นชุดข้อมูลสำหรับการเทรนและการทดสอบ YOLOv5 ใช้สถาปัตยกรรม CNN ซึ่งประกอบด้วยหลายชั้นที่ถูกปรับให้เหมาะสมกับการทำนาย bounding boxes และคลาสวัตถุ YOLO จะแบ่งภาพออกเป็นกริด 80×80 ซึ่งเหมาะสำหรับการตรวจจับวัตถุขนาดเล็ก โดยแต่ละเซลล์ในกริดนี้จะทำนาย bounding boxes และความน่าจะเป็นของคลาสต่าง ๆ ดังรูปที่ 12



รูปที่ 12 การแบ่งกริดภาพ YOLO

กระบวนการ Loss Function และการ Backpropagation ในขั้นตอนการเทรน YOLOv5 จะใช้ฟังก์ชันการสูญเสีย (loss function) สามส่วนคือ

- Localization Loss วัดความผิดพลาดระหว่าง bounding box ที่ทำนายกับ bounding box ที่เป็นจริง
- Confidence Loss ประเมินความมั่นใจในวัตถุที่ตรวจจับได้
- Class Prediction Loss วัดความผิดพลาดในการทำนายคลาสของวัตถุ

การปรับค่าพารามิเตอร์เกิดขึ้นผ่านการทำ Backpropagation และการปรับค่าน้ำหนักของชั้นในแบบจำลอง โดยใช้เทคนิค Optimization เช่น Stochastic Gradient Descent (SGD) หรือ Adam

ไฟล์แบบจำลองที่เทรนเสร็จจะมีนามสกุลเป็น .pt ซึ่งเป็นไฟล์บันทึกของ PyTorch ประกอบด้วย

- ค่า State Dictionary เก็บค่าน้ำหนัก (weights) และออฟเซต (bias) ของแต่ละชั้นในแบบจำลอง
- โครงสร้างแบบจำลองหรือโครงสร้างของแต่ละชั้นและการเชื่อมต่อภายในแบบจำลอง โดยข้อมูลนี้จะช่วยให้สามารถเรียกคืนแบบจำลองที่บันทึกไว้ได้อย่างแม่นยำในครั้งต่อไป
- ค่า Hyperparameters เก็บข้อมูลพารามิเตอร์ที่ใช้ในการเทรน เช่น learning rate, momentum และค่าอื่นๆ ที่เกี่ยวข้องกับการเรียนรู้

กระบวนการคัดกรอง bounding boxes ของ YOLOv5 หลังการทำนายภาพ (Post-processing) ประกอบด้วย 2 ขั้นตอนหลัก คือ การเปรียบเทียบค่า confidence threshold และการใช้ Non-Maximum Suppression (NMS) เพื่อตัด bounding boxes ที่ซ้อนทับกันมากเกินไป โดยมีขั้นตอนดังนี้

1. เปรียบเทียบกับ Confidence Threshold หลังจากทำ YOLOv5 ทำการทำนาย bounding boxes และ class prediction สำหรับวัตถุในภาพ แต่ละ bounding box จะมีคะแนนความมั่นใจ (confidence score) ที่บอกว่าแบบจำลองมั่นใจว่ามีวัตถุอยู่ใน bounding box นั้นๆ มากน้อยแค่ไหน โดยมีขั้นตอนดังต่อไปนี้

- กำหนดค่า Confidence Threshold: ค่า threshold นี้มักจะกำหนดไว้ระหว่าง 0 ถึง 1 เช่น 0.5 หรือ 0.25 ขึ้นอยู่กับความต้องการของผู้ใช้
- คัดกรอง bounding boxes: ลบ bounding boxes ที่มีค่า confidence ต่ำกว่าค่า threshold ออก เนื่องจากแบบจำลองไม่มั่นใจมากพอที่จะบอกว่ามีวัตถุอยู่ในตำแหน่งนั้น



```
{
  "inference_id": "1a4a13ec-0608-92f3-fa84399a5f5d",
  "time": 0.1042724670005548,
  "image": {
    "width": 1500,
    "height": 1409
  },
  "predictions": [
    {
      "x": 762.5,
      "y": 759,
      "width": 1809,
      "height": 1809,
      "confidence": 0.9253670321838379,
      "class": "plane",
      "loss_id": "2",
      "detection_id": "F82FF5de-1499-437a-ad32-837f9b6738a"
    }
  ]
}
```

รูปที่ 13 ผลการวิเคราะห์ภาพ

หลังจากผ่านขั้นตอน NMS จะได้ bounding boxes ที่มีค่าความมั่นใจสูงสุดและไม่มีการซ้อนทับกันมากเกินไปในแต่ละบริเวณ จึงพร้อมสำหรับนำไปแสดงผลเป็นการตรวจจับวัตถุในภาพดังแสดงในรูปที่ 13

สำหรับแบบจำลอง ReLU ซึ่งใช้ชุดข้อมูลที่แบ่งแยกคลาสชุดเดียวกันกับ Yolo โดยจะมีการสร้างแบบจำลองประสาทเทียม (neural network) โดยใช้ PyTorch แบบจำลอง ReLU นี้มีการทำงานหลักๆ คือรับข้อมูลภาพ (input image) เข้ามาและส่งผ่านชั้นต่าง ๆ ที่ใช้ฟังก์ชัน ReLU (Rectified Linear Unit) เพื่อสร้างคุณสมบัติที่เป็นเชิงเส้นและทำการจำแนกข้อมูลเป็น 5 คลาส และมีข้อกำหนดในการทดลองดังนี้


- สร้างชั้น fully connected จะรับอินพุตที่มีขนาด 640×640 พิกเซล
- สร้างชั้นการทำงานของฟังก์ชัน ReLU ซึ่งจะทำงานหลังจากผ่านการแปลงภาพ เพื่อสร้างคุณสมบัติที่เป็นเชิงเส้น โดย ReLU จะทำการแทนค่าทั้งหมดที่น้อยกว่า 0 ให้เป็น 0
- สร้างชั้น fully connected ที่สอง ซึ่งรับอินพุตขนาด 128 จากชั้นก่อนหน้า และแปลงเป็น 64 พิกเซล
- สร้างชั้น ReLU ลำดับที่สองที่ทำงานเหมือนกับลำดับที่หนึ่ง คือแทนค่าที่น้อยกว่า 0 ให้เป็น 0
- สร้างชั้น fully connected สุดท้าย ซึ่งรับอินพุตขนาด 64 จากชั้นก่อนหน้าและแปลงไปเป็น 5 คลาส

3.3 ผลการทดสอบและการวิเคราะห์

ผลลัพธ์แบบจำลอง YOLOv5 จากการทดสอบแสดงให้เห็นว่า YOLOv5 มีประสิทธิภาพที่ดีในการวิเคราะห์เมฆ YOLOv5 มีความแม่นยำ (Accuracy) สูง ความเฉพาะเจาะจง (Specificity) สูง และความไว (Sensitivity) ที่ดี นอกจากนี้ ยังต้องการทรัพยากรการคำนวณน้อย ทำให้เหมาะสมกับการประมวลผลภาพเมฆในเวลาจริง ได้ดีแสดงได้ดังรูปที่ 14 โดยผลการฝึกสอนจากแบบจำลอง YOLOv5 สามารถวัดค่า mAP ได้ที่ 99.5% Precision 99.7% Recall 100.0% และ Box Loss 12.8%

จากตารางที่ 1 แสดงผลการทดสอบของแบบจำลอง YOLOv5 ซึ่งถูกใช้ในการวิเคราะห์ภาพเมฆสำหรับการบริการอุตุนิยมวิทยาการบิน โดยระบุผลลัพธ์สำหรับประเภทเมฆทั้งห้า: FEW, SCT, BKN, OVC, และ CAVOK ผ่านการวัดค่า Precision, Recall, และ F1-score สำหรับแต่ละประเภท โดยวัดเฉลี่ยสำหรับแบบจำลองอยู่ที่

80.88%, 83.48% และ 80.84% ตามลำดับ



รูปที่ 14 ผลการทดสอบความสูญเสีย (loss) ของแบบจำลอง YOLOv5

ตารางที่ 1 ผลการทดสอบของทุกคลาสจาก YOLOv5

	Precision (%)	Recall (%)	F1-score (%)
Average	80.88	83.48	80.84
FEW	83.7	71.4	77.2
SCT	84.5	86.7	80.3
BKN	70.6	88.5	77.5
OVC	95.5	93.7	92.3
CAVOK	70.1	77.1	76.9

ตารางที่ 2 นำเสนอผลการทดสอบของแบบจำลอง ReLU ในการวิเคราะห์ภาพเมฆสำหรับการบริการอุตุนิยมวิทยาการบิน แสดงตัวชี้วัดสำคัญ ได้แก่ Precision, Recall, และ F1-score สำหรับแต่ละคลาสเมฆ: FEW, SCT, BKN, OVC, และ CAVOK. คลาส OVC แสดงความแม่นยำสูงที่สุดด้วย Precision 89.7%, Recall 90.1%, และ F1-score 90.5%, ขณะที่คลาส BKN และ CAVOK มีความแม่นยำต่ำสุด ซึ่งสะท้อนถึงความท้าทายในการจำแนกเมฆที่มีลักษณะไม่ชัดเจนหรือหลากหลาย. ผลการทดสอบเหล่านี้เน้นย้ำถึงความสามารถของแบบจำลอง ReLU ในการจัดการกับงานการวิเคราะห์ลักษณะเฉพาะของเมฆ แม้ว่าจะมีข้อจำกัดบางประการในคลาสที่มีความซับซ้อนสูง

ตารางที่ 2 ผลการทดสอบของทุกคลาสจาก ReLU

	Precision (%)	Recall (%)	F1-score (%)
Average	76.82	73.4	74.8
FEW	81.4	73.4	74.8
SCT	81.3	72.7	73.1
BKN	66.1	78.3	78.1
OVC	89.7	90.1	90.5
CAVOK	65.6	70.2	73.2

4. สรุป

บทความวิจัยนี้ศึกษาเกี่ยวกับการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) โดยเฉพาะการใช้ YOLOv5 และ ReLU เพื่อพัฒนาระบบพยากรณ์สำหรับบริการอุตุนิยมวิทยาการบิน โดยเน้นการพยากรณ์เมฆ 5 ประเภท ได้แก่ BKN, CAVOK, FEW, OVC และ SCT โดยใช้หน่วย "okta" ซึ่งแบ่งท้องฟ้าออกเป็น 8 ส่วนเพื่อวัดปริมาณการปกคลุมของเมฆ การศึกษาเน้นความสำคัญของการเรียนรู้เชิงลึกในการช่วยวิเคราะห์ลักษณะของเมฆทั้งในเวลากลางวันและกลางคืน ซึ่งช่วยให้การพยากรณ์สภาพอากาศมีความแม่นยำมากขึ้น

กระบวนการวิจัยประกอบด้วย 3 ขั้นตอนหลัก ได้แก่ การฝึกสอนแบบจำลองด้วยภาพเมฆที่หลากหลายตามประเภทที่กำหนด การทดสอบความแม่นยำของแบบจำลอง และการนำแบบจำลองไปใช้งานเพื่อช่วยในการตัดสินใจของผู้ใช้ จากการทดลองโดยใช้ข้อมูลภาพมากกว่า 10,000 ภาพ ซึ่งจากการพิจารณาผลลัพธ์จากแบบจำลองทั้งสองชนิดอาจจะวิเคราะห์ได้ว่ารูปแบบของฟังก์ชันกระตุ้นจาก ReLU สำหรับใช้ในการฝึกสอน และการตัดสินใจเพื่อการจัดกลุ่มของคลาสผลลัพธ์นั้นมีความเหมาะสมกับข้อมูลภาพท้องฟ้าที่นำมาพิจารณาน้อยกว่า YOLOv5 โดยจากการผลการทดลองพบว่าแบบจำลอง YOLOv5 และ ReLU ให้ความแม่นยำเฉลี่ยที่ 80.88% และ 76.82% ตามลำดับ

บทความนี้แสดงให้เห็นถึงควมมีประสิทธิภาพของอัลกอริธึมการเรียนรู้เชิงลึกในการพัฒนาการพยากรณ์อุตุนิยมวิทยา ซึ่งช่วยเพิ่มความปลอดภัยและประสิทธิภาพในการดำเนินงานด้านการบินได้อย่างมีนัยสำคัญ

เอกสารอ้างอิง

- [1] G. Kim, J. G. Choi, M. Ku, H. Cho and S. Lim, "A Multimodal Deep Learning-Based Fault Detection Model for a Plastic Injection Molding Process," in IEEE Access, vol. 9, pp. 132455-132467, 2021.
- [2] M. Gwak, K. S. Kim and P. Park, "Explainable AI Framework with Multi-Source Data-Driven Anomaly Detection for Injection Molding Machines," 2024 14th Asian Control Conference (ASCC), Dalian, China, 2024, pp. 1-5.
- [3] Q. Huang, "Design and Implementation of Image Recognition System Based on AI Intelligent Video Technology," 2023 2nd International Conference on Data Analytics, Computing and Artificial Intelligence (ICDACA), Zakopane, Poland, 2023, pp. 687-691, doi: 10.1109/ICDACA59742.2023.00137.
- [4] N. Jundang and S. Sitjongsatoporn, "Coordinated-axis Weight for Real-Time Trace Transform," 2023 International Electrical Engineering Congress (iEECON), Krabi, Thailand, pp. 184-187, 2023.
- [5] N. Jundang, "Development of Trace Transform using Machine Learning for reducing the tracing line calculation," 2022 International Electrical Engineering Congress (iEECON), pp. 1-4, 2022.
- [6] X. Ai, "The Construction of an Online Education Platform Under the Background of Big Data and Intelligent Data Interaction: The Realization of Interaction Based on C#," 2022 Second International Conference on Artificial Intelligence and Smart Energy (ICAIS), Coimbatore, India, 2022, pp. 545-548.
- [7] Z. Li, N. Ye and Y. He, "Meteorological Data Transmission Management System Based on Multi-source Satellite Data," 2023 IEEE 2nd International Conference on Electrical Engineering, Big Data and Algorithms (EEBDA), Changchun, China, 2023, pp. 1343-1346.
- [8] Y. Luo, "Storm Streaming Technology Applied to Intelligent Analysis of Meteorological Data in the Era of Big Data," 2023 International Conference on Networking, Informatics and Computing (ICNETIC), Palermo, Italy, 2023, pp. 793-796.
- [9] W. Shan, H. Zhang, Y. Luan, H. Li and J. Zhu, "Research on Meteorological Data Quality Control Based on Association Rule Algorithm," 2024 7th International Conference on Advanced Algorithms and Control Engineering (ICAACE), Shanghai, China, 2024, pp. 766-770.
- [10] Y. Chen, K. Hayawi, J. He, H. Song and J. Wang, "Impact and Challenges of Intelligent IoT in Meteorological Science," in IEEE Internet of Things Magazine, vol. 6, no. 2, pp. 58-63, June 2023.
- [11] Raut, Bhupendra A., Muradyan, Paytsar, Sankaran, Rajesh, Jackson, Robert C., Park, Seongha, Shahkarami, Sean A., Dematties, Dario, Kim, Yongho, Swantek, Joseph, Conrad, Neal, Gerlach, Wolfgang, Shemyakin, Sergey, Beckman, Pete, Ferrier, Nicola J., and Collis, Scott M. Optimizing cloud motion estimation on the edge with phase correlation and optical flow. United States: N. p., 2023.
- [12] Jocher, G.; Chaurasia, A.; Qiu, J. YOLO by Ultralytics. 2023. Available online: <https://github.com/ultralytics/ultralytics>



ผู้ช่วยศาสตราจารย์ ดร.ณัฐพงษ์ จันทรแดง
จบการศึกษาวิศวกรรมศาสตรบัณฑิต
(วิศวกรรมคอมพิวเตอร์) วิศวกรรมศาสตร
มหาบัณฑิต(วิศวกรรมไฟฟ้าสาขาย่อย
คอมพิวเตอร์) และวิศวกรรมศาสตรดุษฎี
บัณฑิต (วิศวกรรมไฟฟ้าสาขาย่อย
คอมพิวเตอร์) มหาวิทยาลัยเทคโนโลยีมหา
นคร ปัจจุบันเป็นอาจารย์ประจำภาควิชา

วิศวกรรมคอมพิวเตอร์และปัญญาประดิษฐ์สถาบันนวัตกรรมมหานครโดยดำรง
ตำแหน่งเป็นหัวหน้าภาควิชา มีหัวข้องานวิจัยที่สนใจได้แก่การประมวลผล
สัญญาณและภาพดิจิทัล (Signal and Image Processing) การรู้จำแบบ
(Pattern Recognition) การรู้จำภาพ (Image Recognition) และ
ปัญญาประดิษฐ์ (Artificial Intelligence)