

การพัฒนาระบบปรับปรุงภาพเมฆเชิงอัตโนมัติตามสภาพกลางวันและกลางคืนสำหรับการอุตุนิยมวิทยาการบิน Automatic Day-Night Adaptive Cloud Image Enhancement for Meteorological Services

ณัฐพงษ์ จันทรแดง¹ ธันวา ศรีประโม่ง² สุรัชย์ องกิตติกุล³ คงนัฐ รัตนรังสรรค์⁴ กนกสม ชุตติโสวรรณ⁵ และ จิราวุธ สุวัชรกุลธรร⁶

^{1,2,3,4,5,6}สถาบันวิศวกรรมมหานคร คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีมหานคร [jnattapo, thanwa, surachai, kongnat, kanoksom, jirawut]@mut.ac.th

บทคัดย่อ

บทความนี้มุ่งเน้นการพัฒนาระบบบริการอุตุนิยมวิทยาสำหรับการนำร่องทางอากาศ โดยทำการจำแนกกลุ่มเมฆออกเป็น 5 ประเภท ได้แก่ BKN, CAVOK, FEW, OVER และ SCT. การจำแนกประเภทนี้อ้างอิงจากลักษณะของเมฆที่ปรากฏในภาพ โดยตีความเป็นค่าการปกคลุมท้องฟ้าที่วัดในหน่วย Oka ซึ่งแบ่งแต่ละภาพออกเป็น 8 ส่วน จุดเด่นหลักของวิธีการที่นำเสนออยู่ที่การปรับปรุงภาพเพื่อเสริมให้คุณสมบัติเด่นภายในภาพอย่างลักษณะของก้อนเมฆมีความชัดเจนมากขึ้นด้วยการคำนวณเมตริก การเลือกอัลกอริทึมเสริมภาพด้วยอัลกอริทึมทั้ง 4 ที่จะทำการเลือกแบบอัตโนมัติสำหรับการปรับปรุงภาพในช่วงเวลาที่ท้องฟ้าสว่างและมีแดด และฝึกสอนและพยากรณ์คำตอบด้วยการเรียนรู้เชิงลึก โดยผลทดสอบกับคำนำหน้าที่ได้จากการฝึกสอน ในบทความมีการใช้ภาพถ่ายมากกว่า 10,000 ภาพในการทดลอง และได้ค่าเฉลี่ย precision recall mAP@50 และ mAP@50-95 เท่ากับ 90.6% 92.7% 97.1% และ 97.1% ตามลำดับ

คำสำคัญ: การเรียนรู้เชิงลึก การพยากรณ์อากาศ การวิเคราะห์ภาพ

Abstract

This paper presents the development of a meteorological service system that classifies cloud formations into five categories—BKN, CAVOK, FEW, OVER, and SCT. The classification process interprets sky coverage in Oktas by dividing each image into eight segments. A key innovation of the proposed approach is its image enhancement strategy, which refines prominent cloud features through metric-based calculations combined with four distinct enhancement algorithms. The system automatically selects the most suitable algorithm according to lighting conditions, distinguishing between bright and dark skies. Deep learning techniques are employed for both training and prediction, with model performance assessed using weights generated during training. The experimental evaluation utilized a dataset of over 10,000 cloud images, resulting in strong performance metrics, including average precision, recall, mAP@50, and mAP@50–95 scores of 90.6%, 92.7%, 97.1%, and 97.1%, respectively.

Keywords: Deep learning, weather forecasting, image analysis

1. บทนำ

การประมวลผลภาพคือกระบวนการรวบรวมและวิเคราะห์ข้อมูลจากภาพอย่างเป็นระบบ เพื่อสกัดข้อมูลที่มีคุณค่า ซึ่งสามารถสังเกตได้โดยตรงโดยอาศัยเกณฑ์หรือสมมติฐานจากลักษณะข้อมูลที่มีมองเห็นได้ด้วยสายตามนุษย์ การวิเคราะห์ครอบคลุมทั้งสี ขนาด และความสัมพันธ์เชิงพื้นที่ของวัตถุในภาพ เดิมที การประมวลผลภาพถูกออกแบบมาเพื่อจำลองการตีความของมนุษย์ [1] ต่อมาจึงได้มีการพัฒนาอัลกอริทึมให้รองรับงานที่หลากหลายมากขึ้น เช่น การจำแนกภาพ, การตรวจจับวัตถุ และการรู้จำรูปแบบ

ปัจจุบัน อัลกอริทึมประมวลผลภาพได้รับการผสานเข้ากับเทคโนโลยีสมัยใหม่อย่างต่อเนื่อง ด้วยความก้าวหน้าของฮาร์ดแวร์ที่รองรับงานซับซ้อนได้มีประสิทธิภาพ หนึ่งในตัวอย่างสำคัญคือการรวมเทคนิคประมวลผลภาพกับปัญญาประดิษฐ์ (AI) [2] ซึ่งช่วยสร้างนวัตกรรมและเร่งการวิจัย โดยลดการพึ่งพาการทำงานด้วยมือ เช่น การใช้ AI ลดเวลาในวิธี trace-transform [3] หรือการกำหนดทิศทางการหมุนของวัตถุ [4] และ [5] อีกทั้งยังมีการพัฒนาอัลกอริทึมเพื่อเพิ่มศักยภาพการเรียนรู้เชิงลึก ให้ใช้แบบจำลองที่ผ่านการฝึกสอนล่วงหน้าได้แม่นยำยิ่งขึ้น

การอุตุนิยมวิทยาการบิน ซึ่งอยู่ภายใต้การกำกับดูแลขององค์การอุตุนิยมวิทยาโลก (WMO) เป็นแขนงหนึ่งของวิชาอุตุนิยมวิทยาที่มุ่งศึกษาความเชื่อมโยงระหว่างสภาพอากาศกับการนำร่องทางอากาศ การเปลี่ยนแปลงของสภาพอากาศ ไม่ว่าจะเป็นทิศทางที่เอื้ออำนวยหรือเป็นอุปสรรค สามารถส่งผลกระทบต่อการบินโดยตรงต่อการปฏิบัติการบิน แต่ละเที่ยวบินจำแนกออกได้เป็นสามช่วงหลัก ได้แก่ การขึ้นบิน, ระยะการบิน และการลงจอด ในระหว่างขั้นตอนเหล่านี้ นักบินและเจ้าหน้าที่นำร่องจำเป็นต้องเตรียมการอย่างรอบคอบ โดยเฉพาะอย่างยิ่งในขั้นตอนการขึ้นและลงจอดที่ต้องอาศัยข้อมูลอุตุนิยมวิทยาเป็นอย่างมาก ข้อมูลเหล่านี้เมื่อนำมาวิเคราะห์และสังเคราะห์จะก่อให้เกิดการพยากรณ์อากาศ ซึ่งถือเป็นเครื่องมือสำคัญต่อการตัดสินใจ โดยเฉพาะอย่างยิ่งเมื่อผสานกับเทคโนโลยีปัญญาประดิษฐ์ เพื่อเพิ่มความแม่นยำในการคาดการณ์ ตัวอย่างการประยุกต์ใช้ ได้แก่ [6] การจัดการข้อมูลบนแพลตฟอร์มข้อมูลขนาดใหญ่ และ [7] การทำนายสภาพอากาศโดยบูรณาการข้อมูลจากเมฆและภาพถ่ายดาวเทียมหลายโหมด

ระบบที่นำเสนอมีส่วนช่วยเสริมคุณสมบัติของก้อนเมฆภายในภาพให้มีความโดดเด่นมากขึ้นโดยการนำอัลกอริทึมเสริมภาพหลากหลายวิธีที่จะ

ถูกนำเสนอในบทถัดไป และนำไปเรียนรู้ภาพผ่านการเรียนรู้เชิงลึก YOLO [8] เพื่อเรียนรู้และแยกแยะภาพท้องฟ้าและเมฆ

2. แนวคิดและทฤษฎี

2.1 การตรวจวัดจำนวนเมฆ

การประเมินระดับการปกคลุมของเมฆบนท้องฟ้าเป็นขั้นตอนสำคัญในการวิเคราะห์สภาพภูมิอากาศ. หน่วยวัดมาตรฐานที่ใช้ในอุตุนิยมวิทยาสากลเรียกว่า “Okta” ซึ่งเป็นมาตราส่วนที่แบ่งพื้นที่ท้องฟ้าออกเป็น 8 ส่วน เพื่อระบุจำนวนส่วนที่ถูกปกคลุมด้วยเมฆทั้งหมด ทั้งนี้ การจำแนกลักษณะของเมฆสามารถอ้างอิงได้ตามรายละเอียดในตารางที่ 1

ตารางที่ 1 การแบ่งประเภทปริมาณเมฆตามเกณฑ์มาตรฐาน

ค่า Okta	ระดับการปกคลุมของเมฆ
0	ท้องฟ้าโปร่งใส ไม่มีเมฆเลย
1	มีเมฆปกคลุมน้อยมาก (1/8 ของท้องฟ้า)
2	มีเมฆเล็กน้อย (2/8 ของท้องฟ้า)
3	มีเมฆบางส่วน (3/8 ของท้องฟ้า)
4	เมฆปกคลุมปานกลาง (4/8 ของท้องฟ้า)
5	มีเมฆมากกว่าครึ่ง (5/8 ของท้องฟ้า)
6	มีเมฆหนาแน่น (6/8 ของท้องฟ้า)
7	มีเมฆเกือบเต็มท้องฟ้า (7/8 ของท้องฟ้า)
8	ท้องฟ้าปิดสนิท มีเมฆปกคลุมทั้งหมด (8/8 ของท้องฟ้า)

การใช้หน่วย Okta ในการวัดปริมาณเมฆมีความสำคัญต่อหลายสาขา เช่น ในงานอุตุนิยมวิทยาการบิน หน่วยวัดนี้สามารถใช้เป็นตัวชี้วัดแนวโน้มของสภาพอากาศได้ ตัวอย่างเช่น ท้องฟ้าโปร่งที่มีค่าระหว่าง 0–2 Okta มักสอดคล้องกับสภาพอากาศที่แจ่มใส ขณะที่ท้องฟ้าปกคลุมเต็มที่ (8 Okta) อาจเป็นสัญญาณของฝนตกหนักหรือพายุ ซึ่งข้อมูลนี้ช่วยให้นักบินสามารถประเมินสภาพอากาศทั้งก่อนและระหว่างการบินได้อย่างเหมาะสม นอกจากนี้ ยังมีประโยชน์ต่อการศึกษาการเปลี่ยนแปลงสภาพภูมิอากาศ รวมถึงการวิเคราะห์ความสัมพันธ์ระหว่างปริมาณเมฆ อุณหภูมิ และปริมาณน้ำฝน ดังนั้น การประเมินปริมาณเมฆด้วย Okta จึงเป็นองค์ประกอบสำคัญในกระบวนการตรวจวัดด้านอุตุนิยมวิทยาที่ช่วยเพิ่มความแม่นยำในการพยากรณ์อากาศ

ตารางที่ 2 หน่วยวัดเชิงมาตรฐานสากลในทางอุตุนิยมวิทยา

จำนวนเมฆ (Okta)	อักษรย่อ	ความหมาย
1 – 2 ส่วน (1/8 – 2/8)	FEW	มีเมฆเล็กน้อย
3 – 4 ส่วน (3/8 – 4/8)	SCT	มีเมฆกระจายตัว
5 – 7 ส่วน (5/8 – 7/8)	BKN	มีเมฆมาก
8 ส่วน (8/8)	OVC	ท้องฟ้าปิดสนิท
อื่นๆ	CAVOK	ไม่ต้องรายงาน

ในกระบวนการรายงานปริมาณเมฆของระบบอุตุนิยมวิทยา จะประเมินจากพื้นที่ของท้องฟ้าที่ถูกปกคลุมด้วยเมฆ และบันทึกผลโดยใช้อักษรย่อแทนระดับปริมาณเมฆตามมาตรฐานสากล (ตารางที่ 2) การตรวจวัดนี้ใช้หน่วย Okta ร่วมกับรหัสย่อมาตรฐาน ได้แก่ FEW, SCT, BKN, OVC และ CAVOK เพื่อกำหนดระดับการปกคลุมของเมฆอย่างชัดเจน

มาตรฐานนี้ช่วยให้การสื่อสารข้อมูลสภาพอากาศมีความแม่นยำ เชื่อถือได้ และสามารถถ่ายทอดข้อมูลระหว่างหน่วยงานหรือผู้ปฏิบัติงานด้านอุตุนิยมวิทยาได้อย่างมีประสิทธิภาพ ดังตารางที่ 2

2.2 การปรับปรุงภาพ

การวิเคราะห์และจำแนกลักษณะของก้อนเมฆจากภาพถ่ายท้องฟ้าเป็นกระบวนการที่มีความสำคัญอย่างยิ่งในหลายสาขา เช่น การพยากรณ์อากาศ การติดตามสภาพภูมิอากาศ การประเมินปริมาณรังสีดวงอาทิตย์ และการศึกษาสภาพมลภาวะในชั้นบรรยากาศ อย่างไรก็ตาม ภาพถ่ายท้องฟ้ามักมีปัญหาด้านคุณภาพที่ส่งผลต่อความแม่นยำของการประมวลผล เช่น ความสว่างที่ไม่สม่ำเสมอ (illumination variation) ความแตกต่างของสภาพแสงในช่วงกลางวันและกลางคืน การบดบังของเงาวัตถุ หรือความชัดจางของสีเมฆในสภาวะแสงแรง ซึ่งอาจทำให้ขั้นตอนการตรวจจับและแยกก้อนเมฆทำได้ยาก ด้วยเหตุนี้ การปรับปรุงคุณภาพภาพ (image enhancement) ให้เหมาะสมกับสภาพแสงและเวลาถ่ายภาพจึงเป็นขั้นตอนสำคัญ เพื่อให้ภาพมีรายละเอียดของก้อนเมฆชัดเจนมากขึ้นและสามารถนำไปสู่การวิเคราะห์ที่แม่นยำยิ่งขึ้น การเลือกวิธีการปรับปรุงภาพเพียงแบบเดียวอาจไม่เพียงพอ เนื่องจากสภาพท้องฟ้ามีความหลากหลายและเปลี่ยนแปลงตลอดเวลา ดังนั้น จึงมีความจำเป็นต้องพัฒนาวิธีการปรับปรุงภาพที่สามารถเลือกเทคนิคการประมวลผลให้เหมาะสมกับเงื่อนไขของภาพแต่ละประเภทโดยมีลำดับการทำงานตามลำดับต่อไปนี้

- การจัดประเภทเวลาและความสว่าง คือ การแบ่งภาพออกตามช่วงเวลา (เช่น กลางวัน/กลางคืน) และระดับความสว่าง (เช่น สว่าง/มืด) โดยอ้างอิงจากค่าที่วัดได้จากภาพ เพื่อเลือกวิธีประมวลผลที่เหมาะสม โดยหาได้ดังสมการ

$$p_{time} = \begin{cases} day, & \text{if } meanV > T_{day} \wedge blue_{ratio} > R_{blue_min} \\ night, & \text{otherwise} \end{cases} \quad (1)$$

$$p_{time} = \begin{cases} bright, & \text{if } frac_{high} > R_{bright} \\ dim, & \text{otherwise} \end{cases} \quad (2)$$

$$meanV = \frac{1}{w \cdot h} \sum_{x=1}^w \sum_{y=1}^h V(x, y) \quad (3)$$

$$stdV = \sqrt{\frac{1}{w \cdot h} \sum_{x=1}^w \sum_{y=1}^h (V(x, y) - meanV)^2} \quad (4)$$

$$frac_{white} = \frac{\sum_{x=1}^w \sum_{y=1}^h [V(x, y) > T_{white}]}{w \cdot h} \quad (5)$$

$$frac_{high} = \frac{\sum_{x=1}^w \sum_{y=1}^h [V(x, y) > T_{high}]}{w \cdot h} \quad (6)$$

$$blue_ratio = \frac{\sum_{(x,y) \in \Omega_{sky}} [H_c(x, y) \in R_{blue}]}{|\Omega_{sky}|} \quad (7)$$

เมื่อ T_{day} คือเกณฑ์ความสว่างเฉลี่ย R_{blue_min} คือเกณฑ์สัดส่วนสีน้ำเงิน R_{bright} คือเกณฑ์สัดส่วน pixel สว่างสูง w และ h คือขนาดภาพ $V(x, y)$ และ $H(x, y)$ คือค่า Value และ Hue ใน HSV T_{white} คือเกณฑ์ pixel ขาว T_{high} คือเกณฑ์ pixel สว่างสูง Ω_{sky} คือพื้นที่ท้องฟ้า และ R_{blue} คือช่วงค่าสีน้ำเงินท้องฟ้า

- การปรับปรุงภาพก่อนนำไปฝึกสอน : การเลือกใช้อัลกอริทึมปรับปรุงภาพ (Enhance) ให้เหมาะสมกับลักษณะของภาพเป็นขั้นตอนสำคัญ เพื่อให้ผลลัพธ์การเน้นรายละเอียดของก้อนเมฆมีความชัดเจนและ


ถูกต้อง ภาพท้องฟ้าในช่วงเวลาที่แตกต่างกัน เช่น กลางวันหรือกลางคืน รวมถึงระดับความสว่างที่หลากหลาย เช่น สว่างหรือมืด จะมีลักษณะการกระจายแสง สี และคอนทราสต์ไม่เหมือนกัน หากใช้วิธีการปรับภาพแบบเดียวกันกับทุกสภาพแสง อาจทำให้เกิดการขาดรายละเอียดหรือเกิดการการปรับปรุงภาพมากเกินไป (over-enhance) ดังนั้นจึงจำเป็นต้องมีการกำหนดเงื่อนไขเลือกอัลกอริทึมให้เหมาะกับประเภทเวลาและความสว่างของภาพ เพื่อให้การประมวลผลมีความยืดหยุ่นปรับตัวได้ตามสภาพจริง และรักษาความถูกต้องของข้อมูลภาพสำหรับการนำไปใช้ในขั้นตอนดั่งสมการต่อไปนี้

$$E_{method}(T, L) = \begin{cases} E_{LAB}, T = \text{day} \wedge L = \text{bright} \\ E_{Ret}, T = \text{day} \wedge L = \text{dim} \\ E_{Top}, T = \text{night} \wedge L = \text{bright} \\ E_{Homo}, \text{otherwise} \end{cases} \quad (8)$$

เมื่อ T คือประเภทของเวลามีค่าเป็น {day, night} L คือประเภทความสว่างมีค่าเป็น {bright, dim} และมีอัลกอริทึมสำหรับปรับปรุงภาพตามลำดับต่อไปนี้คือ E_{LAB} E_{Ret} E_{Top} และ E_{Homo} ซึ่งจะประกอบด้วยอัลกอริทึมเพิ่มความเด่นของก้อนเมฆด้วย LAB (LAB Cloudness Boost), อัลกอริทึมเรตินเน็กซ์จำลองการมองเห็นของจอตา (Retinex), อัลกอริทึมที่อปแอดสำหรับเน้นวัตถุสว่างขนาดเล็ก (Top-hat), และ อัลกอริทึมกรองเชิงโฮโมมอร์ฟิกเพื่อเพิ่มคอนทราสต์และแก้ไขแสง (Homomorphic Filtering) ตามลำดับ

ซึ่งเมื่อผ่านการคัดเลือกภาพเพื่อนำเข้าสู่สมการของการปรับปรุงภาพแล้ว จะสามารถผลลัพธ์จากการปรับปรุงเข้าสู่กระบวนการฝึกสอนด้วยการเรียนรู้เชิงลึกในหัวข้อถัดไป

2.3 YOLOv8




รูปที่ 1 สถาปัตยกรรมของ YOLOv8

YOLOv8 เป็นอัลกอริทึมสำหรับการตรวจจับวัตถุ (Object Detection) ที่พัฒนาขึ้นเพื่อเพิ่มทั้งความแม่นยำและความรวดเร็ว โดยใช้ข้อมูลคุณลักษณะ (feature) ที่สกัดจากภาพอินพุต (Input Image) เพื่อระบุตำแหน่งและจำแนกประเภทของวัตถุ กระบวนการเริ่มจากการดึง

คุณลักษณะด้วยโครงข่ายประสาทเทียม (Neural Network) ในส่วน Backbone เพื่อเก็บรายละเอียดเชิงลึกของวัตถุ เช่น เส้นขอบ รูปร่าง พื้นผิว และโครงสร้างภายในภาพ จากนั้นข้อมูลเหล่านี้จะถูกประมวลผลในส่วน Head เพื่อผสานคุณลักษณะจากหลายระดับความละเอียด แล้วนำไปทำนายตำแหน่งวัตถุในรูปกรอบสี่เหลี่ยม (Bounding Boxes) พร้อมระบุคลาสของวัตถุ (Object Classes) ตามที่ตรวจพบ โครงสร้างของ YOLOv8 ดังแสดงในรูปที่ 1 ประกอบด้วยส่วน Backbone สำหรับดึงคุณลักษณะจากภาพ ส่วน Head สำหรับผสานข้อมูลหลายขนาด และส่วนเอาต์พุตที่ใช้สำหรับการตรวจจับและจำแนกวัตถุอย่างแม่นยำ

3. ผลการทดลอง

บทความนี้ได้ทำการทดลองโดยใช้ภาษา Python เวอร์ชัน 3.7 บนคอมพิวเตอร์ระบบปฏิบัติการ Windows 10 แบบ 64 บิต พร้อมหน่วยประมวลผลกลาง (CPU) Intel Core i7-6500U ความถี่ 2.50 GHz และหน่วยความจำ (RAM) ขนาด 16 GB การทดลองทั้งหมดดำเนินการบนฐานข้อมูลภาพท้องฟ้าจำนวนมากกว่า 10,00 ภาพที่ถูกถ่ายโดยกล้องเลนส์มุมมองแบบฟิชอาย โดยแบ่งคำตอบการพยากรณ์ออกเป็น 5 ประเภท ได้แก่ BKN, CAVOK, FEW, OVER และ SCT ที่ขนาดภาพ 640x640 พิกเซล โดยใช้โมเดล YOLOv8s




รูปที่ 2 (ซ้าย) ภาพต้นฉบับ (ขวา) ภาพที่ผ่านกระบวนการปรับปรุง

รูปที่ 2 แสดงให้เห็นความแตกต่างของภาพต้นฉบับ (ซ้าย) โดยแสดงลักษณะท้องฟ้าที่มีความสว่างและคอนทราสต์ต่ำ ทำให้รายละเอียดของก้อนเมฆและโครงสร้างท้องฟ้าถูกบดบังด้วยหมอกหรือแสงรบกวน และรูปที่ 2 ที่ผ่านการปรับปรุง (ขวา) ถูกนำเข้าสู่กระบวนการปรับปรุงภาพเพื่อเพิ่มความแตกต่างระหว่างบริเวณก้อนเมฆและท้องฟ้า ส่งผลให้ลักษณะของก้อนเมฆปรากฏเด่นชัดขึ้น โครงสร้างท้องฟ้ามีรายละเอียดมากขึ้น และค่าความอิ่มสี (saturation) ถูกปรับให้อยู่ในระดับที่ช่วยให้การมองเห็นและแยกประเภทสภาพอากาศทำได้ง่ายขึ้น

เมื่อนำมาเข้าสู่กระบวนการฝึกสอนด้วยการเรียนรู้เชิงลึก จะสามารถแสดงผลการฝึกสอนได้ดังรูปที่ 3 ซึ่งผลการประเมินจากกราฟโดยเป็นแกนค่าความผิดพลาด และค่าความแม่นยำเปรียบเทียบกับแต่ละรอบของการฝึกสอน แสดงให้เห็นว่าโมเดล YOLOv8s มีประสิทธิภาพการเรียนรู้ที่ดี โดยค่าความสูญเสียทั้ง box loss และ cls loss ลดลงอย่างต่อเนื่อง แสดงถึงความแม่นยำที่เพิ่มขึ้นทั้งด้านการระบุตำแหน่งและการจำแนกประเภทวัตถุ ขณะที่ค่าความแม่นยำ (Precision) และค่า mAP50 มีแนวโน้มเพิ่ม

สูงขึ้นจนเกิน 0.9 ในช่วงปลายการฝึกสอน สะท้อนถึงความสามารถของโมเดลในการตรวจจับและจำแนกประเภทเมฆจากภาพท้องฟ้าได้อย่างแม่นยำและมีประสิทธิภาพสูง



รูปที่ 3 ผลการประเมินค่าระหว่างกระบวนการฝึกสอนโมเดล

ตารางที่ 3 ผลการทดลองเปรียบเทียบกับอัลกอริทึมต่างๆ

อัลกอริทึม	Precision(%)	Recall(%)	mAP50(%)	mAP95(%)
จากบทความที่นำเสนอ	90.6	92.7	97.1	97.1
จากบทความ [9]	84.7	92.1	95.7	95.3
จากบทความ [10]	77.5	86.8	84.5	83.7

จากผลการทดลองในตาราง พบว่าอัลกอริทึมที่นำเสนอในบทความนี้มีประสิทธิภาพสูงกว่างานวิจัยที่ไม่ได้ผ่านการประยุกต์ใช้อัลกอริทึมการปรับปรุงภาพในบทความ [9] และ [10] ทุกตัวชี้วัด โดยมีค่า Precision เท่ากับ 90.6% ซึ่งสูงกว่าบทความ [9] (84.7%) และ [10] (77.5%) แสดงถึงความสามารถในการจำแนกข้อมูลอย่างถูกต้องได้มากกว่า ขณะที่ค่า Recall อยู่ที่ 92.7% ใกล้เคียงกับ [9] (92.1%) และสูงกว่า [10] (86.8%) บ่งบอกถึงความสามารถในการตรวจจับข้อมูลที่เกี่ยวข้องได้อย่างครบถ้วน นอกจากนี้ ค่าดัชนี mAP@50 และ mAP@95 ของวิธีที่นำเสนออยู่ที่ 97.1% ทั้งสองค่า ซึ่งสูงกว่าทั้ง [9] (mAP@50 = 95.7%, mAP@95 = 95.3%) และ [10] (mAP@50 = 84.5%, mAP@95 = 83.7%) แสดงให้เห็นว่าวิธีการนี้มีความแม่นยำโดยรวมสูงและสามารถรักษาความสม่ำเสมอของผลลัพธ์ได้ดีกว่างานที่มีอยู่ก่อนหน้านี้

4. สรุป

การปรับปรุงคุณภาพภาพถ่ายท้องฟ้า (Enhance) ที่พัฒนาขึ้นช่วยเพิ่มความคมชัดและการเน้นรายละเอียดเมฆ ส่งผลให้โมเดลตรวจจับได้แม่นยำและครอบคลุมขึ้น โดยได้ค่า Precision 90.6%, Recall 92.7%, mAP@50 97.1% และ mAP@95 97.1% ซึ่งสูงกว่างาน [9] และ [10] อย่างชัดเจน แสดงถึงประสิทธิภาพของวิธีที่เสนอ แต่ยังมีข้อจำกัดเรื่องเวลาในการประมวลผลและการขยายสัญญาณรบกวนในบางภาพ ซึ่งควรปรับปรุงต่อไป

เอกสารอ้างอิง

[1] G. S. A, M. M. B and R. S. O., "Medical Image Fusion Enhancement through Curvelet Transform," 2025

International Conference on Emerging Smart Computing and Informatics (ESCI), Pune, India, 2025, pp. 1-5.

- [2] J. Harika, P. Baleeshwar, K. Navya and H. Shanmugasundaram, "A Review on Artificial Intelligence with Deep Human Reasoning," 2022 International Conference on Applied Artificial Intelligence and Computing (ICAIC), Salem, India, 2022, pp. 81-84.
- [3] N. Jundang, "Development of Trace Transform using Machine Learning for reducing the tracing line calculation," 2022 International Electrical Engineering Congress (iEECON), Khon Kaen, Thailand, 2022, pp. 1-4.
- [4] J. Jundang, and S. Sitjongsataporn, "Discriminant Feature Trace Transform for Predictive Object Rotation," International Journal of Intelligent Engineering and Systems, Vol.16, No.1, 2023.
- [5] N. Jundang and S. Sitjongsataporn, "Coordinated-axis Weight for Real-Time Trace Transform," 2023 International Electrical Engineering Congress (iEECON), Krabi, Thailand, 2023, pp. 184-187.
- [6] C. Hui and Y. Cao, "Research on the Design of Core Data Management System for Large-scale Scientific Research Projects in Enterprises Based on Cloud Computing," 2024 International Conference on Industrial IoT, Big Data and Supply Chain (IIoTBDSC), Wuhan, China, 2024, pp. 414-418.
- [7] K. -k. Hon, "Towards Global Simulated Satellite Imagery based on Next-Generation Numerical Weather Prediction Model," 2022 International Conference on Computer Technologies (ICCTech), Melaka, Malaysia, 2022, pp. 7-10.
- [8] I. Hassan and Z. Xinyou, "Performance Evolution of Yolo Models in Remote Sensing Images," 2024 21st International Computer Conference on Wavelet Active Media Technology and Information Processing (ICCWAMTIP), Chengdu, China, 2024, pp. 1-4.
- [9] S. Ongkittikul, N. Jundang, K. Chutisowan, K. Ratnarangsank, J. Suwatcharakulthorn and P. Phophongviwat, "Revolutionizing Meteorological Forecasting with Cloud Image Analysis Using Edge Flow and YOLO," 2024 8th International Conference on Information Technology (InCIT), Chonburi, Thailand, 2024, pp. 820-823.
- [10] S. Ongkittikul, N. Jundang and T. Panyokaew, "Meteorological Prediction Using Cloud's Images," 2024 12th International Electrical Engineering Congress (iEECON), Pattaya, Thailand, 2024, pp. 1-4.