

DTAJ

วารสารวิชาการเทคโนโลยีป้องกันประเทศ
Defence Technology Academic Journal
Volume 6 Issue 13 / January - June 2024



Google Teachable Machine



รายชื่อผู้จัดทำวารสารวิชาการเทคโนโลยีป้องกันประเทศ

คณะที่ปรึกษา

นาวาอากาศเอก คมสันต์ ประพันธ์กาญจน์
พันเอก จิรศักดิ์ จิวไม้แดง
พลตรี พีรพงศ์ โพธิ์เหมือน
นาวาอากาศโท ดร.เพิ่มศักดิ์ ศิริพละ

บรรณาธิการ

นาวาอากาศเอก ดร.ชำนาญ ชุมทรัพย์

กองบรรณาธิการ

ศาสตราจารย์ ดร.สุจินต์ บุรีรัตน์
ศาสตราจารย์ ดร.เจษฎา ธารีบุญ
รองศาสตราจารย์ ดร.สมชาติ จิรวิภากร
รองศาสตราจารย์ ดร.ธีรพงศ์ เหล่าสุวรรณ
ผู้ช่วยศาสตราจารย์ ดร.ทวีศักดิ์ กฤษเจริญ

มหาวิทยาลัยขอนแก่น
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
มหาวิทยาลัยมหาสารคาม
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี

ฝ่ายจัดการ

นางสาวอินทิรา จุลชาติ
นางสาวสวิตรี ระงับพิช
นางสาวนุกุลรัตน์ ลวงลายทอง

นางสาวบุญญาภรณ์ วาณิชชาติ
นางสาวลัญญ์ณัฐ ภาคะนันท์
ว่าที่ร้อยตรีหญิง ดร.ลำยอง แสนทวี

สารบัญ

วารสารวิชาการเทคโนโลยีป้องกันประเทศ ปีที่ 6 ฉบับที่ 13 มกราคม – มิถุนายน 2567

บทความวิชาการ (Academic Articles)

- การจำแนกประเภทอาวุธโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน
ที่มีการปรับรูปแบบให้เหมาะสมสำหรับอุปกรณ์พกพา
เอกราช นินทรา, สุรพันธุ์ เอื้อไพบุลย์ และ สมชาติ จิรวิภากร 4
- โปรแกรมสำหรับเรียนรู้แบบโต้ตอบโดยใช้ฐานข้อมูลแบบ MySQL
เพื่อเก็บข้อมูลของรถฐานยิงจรวดหลายลำกล้องอเนกประสงค์
กันต์ธร นาทอง, เจษฎา ไกรขาว, รัชชิตา ชันทอง, ปิยะรส มาลีเจริญ,
สิรภพ สันติรัตนรงค์ และ นริศ จันทร์น้ำ 16

บทความวิเคราะห์เทคโนโลยีป้องกันประเทศ (Defence Analysis Article)

- ปัญญาประดิษฐ์แบบรู้สร้างกับการประยุกต์ใช้ทางการทหาร
กนก บุนนาค 28

บทความวิจัย (Research Articles)

- Comparison between Equilibrium Optimization and Systune
on Aircraft Blank Angle Control 42
Yodsadej Kanokmedhakul and Nantiwat Pholdee
- การวิเคราะห์แบ่งส่วนพื้นที่ภาพถ่ายทางอากาศด้วย Generative Adversarial Networks 52
กิตติกร วิริยะศาสตร์, วรากร เลื่องลือวุฒิ, วิชัย แผ้วเกษม, พันธุ์เทพ แก้วมงคล,
สัญญา มิตรเอม และ พันศักดิ์ เทียนวิบูลย์
- การประยุกต์ใช้ Google's Teachable Machine ในการตรวจจับใบหน้าผู้ก่อการร้าย 62
ธรรมราช อาษาสุวรรณ, ชนัชฎาภรณ์ ใจแน่น และ ภาณุระวี โสภณพิเชฐ
- การทดสอบและพัฒนาความแข็งแรงของโครงสร้างปีกอากาศยานไร้คนขับ 74
เจษฎา ชมดารา และ ณัฐธิเบศ จารุเพ็ง
- การเปรียบเทียบโมเดลตรวจจับวัตถุด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน
ในงานภาพถ่ายทางอากาศจากอากาศยานไร้คนขับ 90
กิตติกร วิริยะศาสตร์, วรากร เลื่องลือวุฒิ, ปิยะรส มาลีเจริญ, สิรภพ สันติรัตนรงค์,
วิชัย แผ้วเกษม, พันธุ์เทพ แก้วมงคล, สัญญา มิตรเอม และ พันศักดิ์ เทียนวิบูลย์
- การหาค่าเหมาะสมที่สุดของการออกแบบตามแนวคิดของกามิกาเซ่ไดรอนปีกรูปตัวเอ็กซ์ 108
ขับเคลื่อนด้วยระบบไฟฟ้าด้วยเมต้าฮิวริสติกส์
ภาคิน จำปาศักดิ์

บทบรรณาธิการ

ในวารสารวิชาการเทคโนโลยีป้องกันประเทศฉบับที่ 13 นี้ ผลงานส่วนใหญ่ของนักวิเคราะห์ นักวิจัย และนักวิชาการ ยังคงมีคุณภาพและตรงตามมาตรฐานของงานเขียนที่ดี แต่สิ่งที่น่าสนใจอีกประการหนึ่ง คือ ผลงานเกือบจะทั้งหมดเป็นผลจากการวิเคราะห์ การวิจัย และการศึกษาค้นคว้าด้านซอฟต์แวร์ ทั้งนี้ อาจสอดคล้องกับสภาพทางเศรษฐกิจ ทุนอุดหนุนทางการวิจัยและพัฒนาที่ลดลง และการจัดลำดับความสำคัญของภาครัฐในการรับมือกับสถานการณ์ไวรัสโควิด-19 อย่างไรก็ดี ตาม คู่มือการในเชิงวิชาการและผลกระทบต่ออุตสาหกรรมการป้องกันประเทศ ซึ่งเป็นอุตสาหกรรมเป้าหมายของประเทศ ด้วยการพัฒนาขีดความสามารถด้านซอฟต์แวร์ให้ทันสมัย ตามวัตถุประสงค์ การเพิ่มประสิทธิภาพของกิจกรรมทางทหารของไทย โดยให้ความสำคัญกับการวิจัยและพัฒนา และการยกระดับประสิทธิภาพให้ก้าวทันเทคโนโลยี จึงยังคงสะท้อนออกมาให้เห็นในผลงานคุณภาพเหล่านี้

การเพิ่มความเข้มแข็งของกองทัพผ่านเทคโนโลยีที่ทันสมัย หากเน้นไปที่ฮาร์ดแวร์หรือระบบอาวุธ แต่เพียงอย่างเดียว อาจไม่เพียงพอหรือแทบจะไม่มีโอกาสประสบความสำเร็จได้ เนื่องจากในตลาดอุตสาหกรรมป้องกันประเทศของโลกมีประเทศผู้กุมอำนาจและเป็นเจ้าของเทคโนโลยีรายใหญ่มาก อีกทั้งประเทศไทยยังคงต้องการความพร้อมในระบบนิเวศของอุตสาหกรรมป้องกันประเทศมากกว่านี้ และถึงแม้ EEC จะให้สิทธิประโยชน์สำหรับการลงทุนในอุตสาหกรรมการป้องกันประเทศ ประกอบไปด้วย การได้รับการยกเว้นภาษีสำหรับกิจการที่อยู่ในอุตสาหกรรมฐานความรู้ กิจกรรมโครงสร้างพื้นฐานเพื่อพัฒนาประเทศ และกิจการที่ใช้เทคโนโลยีขั้นสูงซึ่งมีความสำคัญต่อการพัฒนาประเทศ แต่นั่นบอกถึงนโยบายการลงทุนโดยบริษัทข้ามชาติเจ้าของเทคโนโลยีในประเทศไทย การร่วมค้ากับบริษัทภายในประเทศโดยเปิดโอกาสให้สร้างเนื้อหาหรือสาระสำคัญภายในประเทศด้วยซอฟต์แวร์ ลิขสิทธิ์ต่างประเทศ

เมื่อพิจารณาประเภทกิจการที่ได้รับการส่งเสริมนั้น ประเภทกิจการที่เกี่ยวข้องกับอุตสาหกรรมป้องกันประเทศได้จัดอยู่ในหมวด A ประกอบด้วย รถถัง ชุดเกราะ ยานพาหนะ โดรน อากาศยานไร้คนขับ ทุนยนต์ทางการทหาร ระบบการสื่อสาร และอาวุธ อาจนำไปสู่ประเด็นที่ถกเถียงไว้ในตอนต้นว่าประเทศไทยยังคงไม่ได้เป็นเจ้าของเทคโนโลยีแบบเบ็ดเสร็จในระยะเวลาอันใกล้ ดังนั้น ขีดความสามารถทางด้านซอฟต์แวร์จึงยังคงเป็นกุญแจสำคัญในการนำไปสู่ฐานความรู้อุตสาหกรรมการป้องกันประเทศในหมวด A ดังกล่าว ซอฟต์แวร์ประยุกต์หรือการเขียนโค้ดยังคงเป็นส่วนสำคัญของโครงสร้างพื้นฐานในการพัฒนาประเทศ อีกทั้งกิจการที่ใช้เทคโนโลยีขั้นสูง ซึ่งมีความสำคัญต่อการพัฒนาประเทศ ยังคงต้องอาศัยขีดความสามารถในการศึกษา ค้นคว้า วิเคราะห์ วิจัย และพัฒนา โดยนักพัฒนา โปรแกรมม่อือีกมาก ดังจะเห็นได้จากเทคโนโลยีปัญญาประดิษฐ์ ซึ่งสามารถแทรกซึมเข้าไปอยู่ได้ในทุกๆ กิจกรรมของอุตสาหกรรมการป้องกันประเทศหมวด A

นาวาอากาศเอก ดร.ชำนาญ ชุมทรัพย์
บรรณาธิการวารสารวิชาการเทคโนโลยีป้องกันประเทศ

การจำแนกประเภทอาวุธโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันที่มีการปรับรูปแบบให้เหมาะสมสำหรับอุปกรณ์พกพา

เอกราช นินทรา^{1*} สุรพันธุ์ เอื้อไพบูลย์² และ สมชาติ จิรวิภากร³

วันที่รับ 31 ตุลาคม 2566 วันที่แก้ไข 19 มกราคม 2567 วันที่ตอบรับ 27 มีนาคม 2567

บทคัดย่อ

บทความนี้มีวัตถุประสงค์เพื่อศึกษาขั้นตอนการพัฒนากระบวนการสำหรับการจำแนกอาวุธจากข้อมูลภาพ จำนวน 8 ชนิด โดยการประยุกต์ใช้โมเดลการเรียนรู้เชิงลึก ด้วยการนำเทคโนโลยีคอมพิวเตอร์วิชันมาใช้ในการรับรู้ภาพแบบอัตโนมัติและจำแนกภาพอาวุธ เพื่อแก้ปัญหาความผิดพลาดในการวิเคราะห์ข้อมูลภาพที่มีจำนวนมากด้วยสายตามนุษย์ได้อย่างถูกต้องและมีประสิทธิภาพ การลดขนาดของข้อมูลให้สามารถใช้งานบนอุปกรณ์พกพาขนาดเล็ก พร้อมทั้งได้พัฒนาโมเดลในการจำแนกย่อยเฉพาะในคลาสเครื่องบินที่สามารถติดยุทธโธปกรณ์ทางการรบและเครื่องบินทั่วไป ซึ่งมีความยากและซับซ้อนในการจำแนกเนื่องจากมีลักษณะทางกายภาพที่ใกล้เคียงกัน เช่น สี ขนาด และ รูปร่าง ดังนั้น การศึกษานี้จึงใช้ TensorFlow และ Keras ซึ่งเป็นไลบรารีสำหรับพัฒนาการเรียนรู้ของเครื่องด้วยอัลกอริทึมโครงข่ายประสาทเทียมแบบคอนโวลูชัน อีกทั้งยังเพิ่มประสิทธิภาพของโมเดลการเรียนรู้เชิงลึก พร้อมทั้งเปรียบเทียบโมเดลพร้อมใช้งานที่ได้รับการฝึกฝนมาก่อน 8 แบบ ผลลัพธ์ที่ได้จากการศึกษานี้แสดงให้เห็นว่าโมเดล EfficientNet-B0 มีค่าความถูกต้องในการจำแนกอาวุธจากข้อมูลภาพ เท่ากับ 94.01% นอกจากนี้ยังใช้คุณสมบัติของไลบรารี TensorFlow Lite แปลงค่าพารามิเตอร์ นำโมเดลเข้าสู่กระบวนการคำนวณระบบเลขจำนวนเต็มด้วยหลักการทำ Quantization ในการลดขนาดของข้อมูลเพื่อปรับใช้งานและการเพิ่มประสิทธิภาพของระบบการเรียนรู้ของเครื่อง รวมถึงแสดงการเปรียบเทียบคุณสมบัติ ขนาดข้อมูล เวลาแฝง และความแม่นยำ ให้เหมาะสมกับอุปกรณ์สามารถนำไปใช้บนอุปกรณ์พกพาได้ ซึ่งผลการทดลองของโมเดลแบบ int8 มีขนาดเล็กที่สุดได้ค่าความแม่นยำ 88.64%

คำสำคัญ : โมเดลการเรียนรู้เชิงลึก, โครงข่ายประสาทเทียมแบบคอนโวลูชัน, โมเดลพร้อมใช้งานที่ได้รับการฝึกฝนมาก่อน

¹ ภาควิชาวิศวกรรมป้องกันประเทศ, คณะวิศวกรรมศาสตร์, สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

² ภาควิชาอิเล็กทรอนิกส์, คณะวิศวกรรมศาสตร์, สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

³ ภาควิชาวิศวกรรมไฟฟ้า, คณะวิศวกรรมศาสตร์, สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

* ผู้แต่ง, อีเมล: 59601154@kmitl.ac.th

Classification of Weapons using Convolution Neural Networks Suitable for Portable Devices

Eakarach Nintra ^{1*} Surapan Airphaiboon ² and Somchat Jiriwibhakorn ³

Received 31 October 2023, Revised 19 January 2024, Accepted 27 March 2024

Abstract

This article aims to study the process of developing a process for classifying 8 types of weapons from image data using deep learning models, which contribute to the process of using computer vision technology to recognize images and describe weapons accurately and efficiently automatically. This process eliminates errors in analyzing large amounts of image data with human error and reduces the data size for use on portable devices. In this article, there are also models developed to distinguish specific subclasses of aircraft that can be equipped with combat equipment and general aircraft. These aircraft are difficult to classify due to similar physical characteristics, such as color, size, and shape. Therefore, this paper uses TensorFlow and Keras, a library for developing machine learning with artificial convolutional neural network algorithms. In this work, the convolutional neural network is used for the model. The performance of the deep learning model is also improved along with a comparison of 8 pre-trained models. According to the results of this study, the EfficientNet-B0 model has a weapon classification accuracy from image data of 94.01%. Additionally, this work uses features of the TensorFlow Lite library to convert parameters into models. The model is processed using integer-based computation to use quantization principles to reduce the size of the parameters to compare the features, size, latency, and accuracy with parameters. The final model is mobile-compatible and is suitable for use on portable devices. The experimental results of the int8 model are the smallest, with an accuracy of 88.64%.

Keywords : Deep learning models, Convolutional neural networks, Pre-trained model

¹ Defence Engineering, School of Engineering, King Mongkut's Institute of Technology Ladkrabang

² Electronics Engineering, School of Engineering, King Mongkut's Institute of Technology Ladkrabang

³ Electrical Power Engineering, School of Engineering, King Mongkut's Institute of Technology Ladkrabang

* Corresponding author, E-mail: 59601154@kmitl.ac.th

1. บทนำ

การจำแนกภาพเป็นหัวข้อสำคัญที่ได้รับความสนใจอย่างมากในช่วงทศวรรษที่ผ่านมา เริ่มต้นจากการประมวลผลภาพเพื่อให้ได้ข้อมูลภาพที่ละเอียดคมชัดหรือข้อมูลที่อยู่ในภาพสามารถนำมาใช้งานในเรื่องอื่น ๆ ได้ การตัดสินใจที่ต้องอาศัยมนุษย์ในการวิเคราะห์เพื่อจำแนกภาพในบางครั้งไม่สามารถระบุข้อมูลภาพให้ถูกต้องได้อย่างมีประสิทธิภาพ อาจเกิดจากประสบการณ์แต่ละบุคคล ความเหนื่อยล้าหรือข้อจำกัดทางด้านร่างกายอื่น ๆ เป็นปัจจัยที่ทำให้เกิดความผิดพลาดด้านการวิเคราะห์ตัดสินใจ เนื่องจากภาพที่มีลักษณะซับซ้อนและมีจำนวนข้อมูลภาพที่มากขึ้น จึงมีการประมวลผลภาพโดยการแปลงสัญญาณข้อมูลภาพสู่ข้อมูลภาพดิจิทัลแปลงเป็นรหัสทางคณิตศาสตร์ สามารถนำมาใช้กับเทคโนโลยีปัจจุบันที่มีการพัฒนาอุปกรณ์ให้มีขนาดเล็กลง ซึ่งงานวิจัยของ P. Cheewaparakobkit [1] กล่าวถึงการจำแนกภาพ เป็นหนึ่งในความท้าทายสำหรับมนุษย์และคอมพิวเตอร์ เนื่องจากเป็นกระบวนการที่ต้องอาศัยการวิเคราะห์ที่มีประสิทธิภาพและความถูกต้องแม่นยำที่พัฒนาให้สูงขึ้น โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) ได้ถูกนำมาใช้ในงานวิจัยของ K. Chauhan และ S. Ram [2] เพื่อแก้ปัญหาการจัดหมวดหมู่ (Classification) และจำแนกภาพที่มีประสิทธิภาพมากกว่าการวิเคราะห์ด้วยมนุษย์

บทความนี้ใช้เทคนิคในการประมวลผลภาพโดยใช้หลักการของโครงข่ายประสาทเทียมมาวิเคราะห์ประเภทและลักษณะของอาวุธจากข้อมูลภาพถ่าย 8 ชนิด คือ รถถัง เครื่องบินรบ เรือรบ อาวุธปืน ซิปนาอาวุธเครื่องยิงจรวด มืด และเฮลิคอปเตอร์ พร้อมกันนี้ได้นำไปปรับใช้กับโมเดลการเรียนรู้ใน

การจำแนกวัตถุ สามารถแยกความแตกต่างระหว่างเครื่องบินทางทหารที่ใช้ในการรบ สามารถติดอาวุธหรือยุทธโธปกรณ์ในการรบกับเครื่องบินพลเรือนที่ใช้ในการขนส่งโดยสาร และเครื่องบินขนาดเล็กส่วนบุคคลได้ โดยใช้ตัวอย่างข้อมูลภาพเครื่องบิน 10 แบบแตกต่างกันเป็นข้อมูลในการทดสอบและเรียนรู้ พร้อมทั้งนำเสนอวิธีการแปลงค่าพารามิเตอร์ เพื่อปรับรูปแบบให้เหมาะสมกับอุปกรณ์พกพาด้วยระบบเลขจำนวนเต็ม โดยใช้ API ของ TFLiteConverter ดำเนินการแปลงโมเดลที่ผ่านการฝึกอบรมจาก TensorFlow นำไปลดขนาดโมเดลในขั้นตอนการแปลงข้อมูลของ TensorFlow Lite พร้อมกับทางเลือกหลากหลายรูปแบบในการทำ Quantization เพื่อปรับรูปแบบให้เหมาะสมและลดขนาดของโมเดลเพื่อนำไปใช้กับอุปกรณ์พกพาได้

2. ขอบเขตการศึกษาและงานวิจัยที่เกี่ยวข้อง

2.1 ขอบเขตการศึกษา

บทความนี้ศึกษาประสิทธิภาพของโมเดลการเรียนรู้เชิงลึก พร้อมทั้งเปรียบเทียบโมเดลพร้อมใช้งานที่ได้รับการฝึกฝนมาก่อน 8 แบบ วิเคราะห์โมเดลการเรียนรู้เชิงลึกที่มีผลต่อการจำแนกภาพอาวุธเพื่อนำไปปรับใช้กับอุปกรณ์พกพาขนาดเล็ก ซึ่งข้อมูลที่ใช้ในการศึกษาเป็นภาพถ่ายจากฐานข้อมูลออนไลน์ Google LLC Kaggle [3] ซึ่งเป็นแหล่งรวม Datasets สำหรับชุดข้อมูลฝึกสอน Machine Learning จำนวน 32,000 ภาพ โดยนำภาพมาตัดครอบคลุมอาวุธทั้งภาพบนสมมติฐานว่ามีอาวุธเพียงประเภทเดียวในหนึ่งภาพ จากข้อมูลภาพถ่ายอาวุธ 8 ชนิด และข้อมูลภาพเครื่องบิน 10 แบบ ใช้วิธีการทำ Regularization [4] ปรับแต่งโมเดลให้มีประสิทธิภาพในการทำนายที่แม่นยำสูงขึ้นด้วย 3 เทคนิคที่สำคัญคือ Batch Normalization [5],

Augmentation [6] และ Dropout [7] เปรียบเทียบประสิทธิภาพความแม่นยำและเวลาในการฝึกฝน สู่การปรับขนาดโมเดลโดยใช้ TensorFlow Lite [8] แปลงโมเดลให้มีขนาดเล็กลงเพื่อความเหมาะสมสำหรับการเรียนรู้ของเครื่องบนอุปกรณ์พกพา

2.2 วรรณกรรมหรืองานวิจัยที่เกี่ยวข้อง

บทความนี้ได้นำเสนอทฤษฎีและงานวิจัยที่เกี่ยวข้องเกี่ยวกับการประมวลผลภาพเพื่อใช้ในการจำแนกข้อมูลรูปภาพ (Image Classification) การนำเทคโนโลยีไปใช้ในการพัฒนาเทคโนโลยีอุตสาหกรรมป้องกันประเทศ [9] เป้าหมายเพื่อยกระดับไปสู่อุตสาหกรรมที่ใช้เทคโนโลยี ให้มีขีดความสามารถในการผลิตอาวุธยุทโธปกรณ์ เพื่อต่อต้านก่อการร้ายและสงครามนอกแบบ ด้วยเครื่องมือตรวจจับ อุปกรณ์สนับสนุนทางยุทธวิธี อาวุธพิเศษ และการใช้ประโยชน์จากเทคโนโลยีอื่น ๆ เป็นต้น

N. Dwivedi และคณะ [10] กล่าวถึงการใช้เทคโนโลยีโครงข่ายประสาทเทียมในการเรียนรู้เชิงลึกเพื่อการจำแนกอาวุธในการก่ออาชญากรรม ช่วยในการระบุความเป็นไปได้ของการเกิดอาชญากรรม โดยใช้สถาปัตยกรรม VGGNet ซึ่งเป็นโมเดลพร้อมใช้งานที่ได้รับการฝึกฝนมาก่อนและเป็นที่ยอมรับในการแข่งขัน ImageNet 2014 การทดลองใช้ภาพ 3 คลาส คือ มิตร ปืน และไม่มีอาวุธ ผลการทดลองมีระดับความแม่นยำ 98.41% ข้อดี คือ ง่ายต่อการจำแนก เนื่องจากการกำหนดคุณลักษณะจำนวนคลาสไม่มากแต่มีจุดอ่อน คือ ถ้าคุณลักษณะของภาพมีความซับซ้อนและหลากหลายจะยากต่อการจำแนกซึ่งอาจส่งผลให้ประสิทธิภาพและความแม่นยำลดลง

การใช้เทคโนโลยีโครงข่ายประสาทเทียมร่วมกับการจดจำใบหน้าและการตรวจจับอาวุธจากภาพที่มีความละเอียดต่ำมาก โดยงานวิจัยของ M. J. N. V. S. K.

Asrith และ คณะ [11] ใช้อัลกอริทึม Haar Cascades ในการตรวจจับวัตถุ เพื่อแยกความแตกต่างระหว่างใบหน้าและอาวุธ โดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันในการเรียนรู้ ซึ่งการประมวลผลภาพให้ผลลัพธ์ที่ดีกว่าเมื่อเปรียบเทียบกับอัลกอริทึมการจำแนกรูปภาพแบบอื่น สามารถทำงานได้แบบเรียลไทม์และใช้กับภาพที่มีความละเอียดต่ำได้ผลดีของงานวิจัยนี้คือ ความเร็วและความถูกต้องในการตรวจจับใบหน้าสูงจากการใช้งานร่วมกับโครงข่ายประสาทเทียมเมื่อเปรียบเทียบกับเทคนิคการตรวจจับใบหน้าแบบดั้งเดิม

การพัฒนาในการเรียนรู้ของเครื่องทำให้เกิดอัลกอริทึมจำนวนมากที่ออกแบบมาเพื่อแก้ปัญหาที่ซับซ้อนด้วยสถาปัตยกรรมเรียนรู้เชิงลึก แบบ Transfer Learning งานวิจัยของ L. Zhu และ P. Spachos [12] กล่าวถึงการทดลองการเรียนรู้เชิงลึกแบบถ่ายทอดวิธีการเรียนรู้ เพื่อเปรียบเทียบคุณลักษณะการฝึกและทดสอบกับชุดข้อมูลมีเสียง หาวีธีกำหนดรูปแบบที่เหมาะสมที่สุดในการปรับใช้คุณสมบัติของโมเดลให้สามารถตรวจจับประเภทของมีเสียงด้วยการถ่ายภาพมีเสียงแบบเรียลไทม์หรือเลือกหนึ่งภาพได้ โดยใช้วิธีการ Transfer Learning กับโมเดลพร้อมใช้งานที่ได้รับการฝึกฝนมาก่อนหน้า ซึ่ง VGG19 ให้ค่าความถูกต้อง 98.4% การทดลองนี้ชี้ให้เห็นว่าข้อได้เปรียบของการทำ Transfer Learning คือ ช่วยลดเวลาการเรียนรู้ของโมเดลในขั้นของ Deep Learning ด้วยการนำบางส่วนของโมเดลที่เรียนรู้มาก่อนหน้าปรับใช้กับงานที่ใกล้เคียงกันและนำมาเป็นส่วนหนึ่งของโมเดลที่ใช้ในการศึกษาครั้งนี้

การศึกษาการจำแนกรูปภาพตามการเรียนรู้เชิงลึกในงานวิจัยของ M. A. Abu และคณะ [13] ใช้ไลบรารี TensorFlow ในการจำแนกข้อมูลนำเข้า

คลาสตอกไม้ 5 ประเภท ขนาด 224x224 พิกเซล จำนวน 3,670 ภาพ ใช้โครงข่ายประสาทเทียมในการเรียนรู้ด้วยวิธีการ Transfer Learning จาก MobileNet ซึ่งเป็นโมเดลพร้อมใช้งานที่ได้รับการฝึกฝนมาก่อนหน้า ผลลัพธ์ที่ได้ คือ ความถูกต้องของการจำแนกภาพทุกหลายได้ 90.585% และชนิดของดอกไม้ที่เหมือนกัน ผลเฉลี่ยความถูกต้องสูงถึง 90%

ในขณะที่เดียวกันไลบรารี Keras ถูกนำมาใช้ร่วมกับ TensorFlow เพื่อให้สามารถเรียกใช้งานเป็นไลบรารีโอเพนซอร์สของภาษาไพทอนสำหรับการพัฒนาโครงข่ายประสาทเทียมให้สามารถทำงานบน TensorFlow ได้ ซึ่งงานวิจัยของ N. Lamsamut และ S. Valuvanathorn [14] แสดงการจำแนกภาพเอกซเรย์คอมพิวเตอร์โรคหลอดเลือดสมองด้วยวิธีโครงข่ายประสาทเทียมแบบคอนโวลูชัน รูปที่ผ่านการวินิจฉัยของแพทย์ แบ่งเป็น 3 กลุ่ม ข้อมูลภาพขนาด 512x512 พิกเซล จำนวน 450 ภาพ ใช้วิธีการปรับปรุงข้อมูลโดยการประมวลผลภาพ ก่อนทำการเรียนรู้และทดลองด้วยวิธีการโครงข่ายประสาทเทียมแบบคอนโวลูชัน ร่วมกับ TensorFlow และ Keras เรียนรู้จำนวน Epochs 500 รอบ พบว่า มีความแม่นยำในการเรียนรู้ Train 99.96% และ Test 92.60% แต่มีจุดอ่อน คือ หากมีการเพิ่มขึ้นของจำนวนคลาสและคุณลักษณะของภาพมีความซับซ้อนมากขึ้นจะยากต่อการกำหนดคุณลักษณะ ทำให้ประสิทธิภาพของผลลัพธ์อาจส่งผลให้ความแม่นยำลดลง ทั้งนี้ ประสิทธิภาพในการทำนายของโครงข่ายประสาทเทียมยังขึ้นอยู่กับจำนวนและลักษณะของภาพที่ใช้ในการฝึกสอนให้คอมพิวเตอร์เรียนรู้ ซึ่งจำเป็นต้องใช้ภาพจำนวนมากในการฝึกสอน ดังนั้นการกำหนดจำนวนภาพและลักษณะของภาพจึงเป็นสิ่งสำคัญ แต่โครงข่ายประสาทเทียมยังมีข้อจำกัดในด้านการใช้ทรัพยากรและเวลาในการประมวลผลมาก

โครงข่ายประสาทเทียมยังใช้เป็นโมเดลหลักในการพัฒนา โดยในงานวิจัยของ C. Chousangsunthorn และคณะ [15] ได้นำเสนอระบบการเรียนรู้เชิงลึกเพื่อการจดจำและการกู้คืนหมายเลขซีเรียลแถบบนเลื่อนที่ปนเปื้อนในฮาร์ดดิสก์ ซึ่งยากต่อการอ่านและแปลความตัวอักษร ในงานวิจัยนี้ทำการเก็บภาพหมายเลขซีเรียลที่ไม่สามารถอ่านได้ด้วยกระบวนการคอมพิวเตอร์วิทัศน์ ซึ่งถ่ายด้วยกล้องดิจิทัล เปรียบเทียบประสิทธิภาพการจำแนกอักขระระหว่างโครงข่าย DarkNet-19, EfficientNet-B0, ResNet-50 และ DenseNet-201 กระบวนการทดสอบประสิทธิภาพด้วย EfficientNet-B0 แสดงให้เห็นประสิทธิภาพการจัดหมวดหมู่ที่เหนือกว่าการอ่านของมนุษย์การทดลองกับภาพถ่าย 15,000 ภาพ ให้ความแม่นยำมากกว่า 99% งานวิจัยนี้ชี้ให้เห็นถึงข้อดีและประสิทธิภาพของผลลัพธ์จากการทดลองในงานวิจัยนี้ EfficientNet-B0 มีความความแม่นยำสูงจึงเหมาะสมในการนำไปประยุกต์ใช้งาน

3. วิธีดำเนินการวิจัย

3.1 การเตรียมชุดข้อมูล

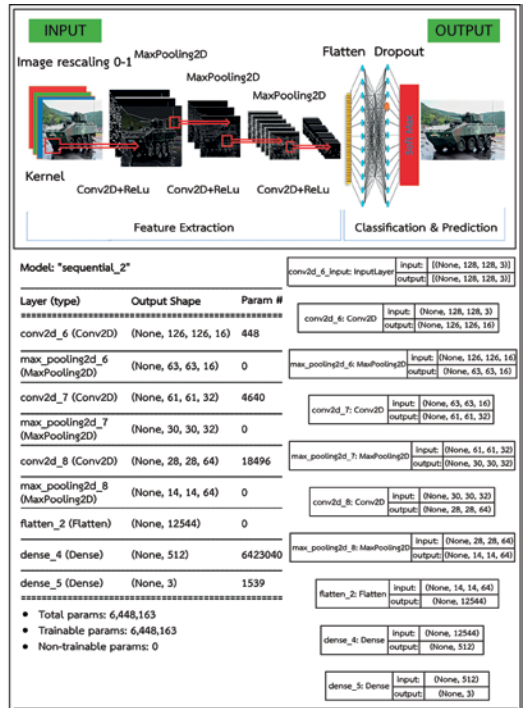
นำข้อมูลรูปภาพอาวุธขนาดไม่เกิน 640x480 พิกเซลต่อหนึ่งภาพ มาทำการแบ่งชุดข้อมูลสำหรับฝึกฝนโมเดล จากกลุ่มที่ 1 จำนวน 10,789 ภาพ ชุดข้อมูลรูปภาพอาวุธ รถถัง (Tank) เครื่องบินรบ (Military Aircraft) อาวุธปืน (Gun) เรือรบ (Military Ship) ขีปนาวุธ (Missile Rocket) เครื่องยิงจรวด (Missile Launcher) มีด (Knife) และเฮลิคอปเตอร์ (Helicopter) กลุ่มที่ 2 จำนวน 21,211 ภาพ ชุดข้อมูลรูปภาพเครื่องบิน 10 แบบ เครื่องบินทางทหารที่สามารถติดยุทโธปกรณ์ (B-1, C-130, E-2, EM B-120, F-35, Tornado) เครื่องบินพลเรือนขนส่งโดยสาร

(A300, Boeing 757) และเครื่องบินพลเรือนขนาดเล็ก ใช้ส่วนบุคคล (DH-82, DR-400)

ในบทความนี้แบ่งข้อมูลออกเป็น 3 ส่วน คือ Train 70%, Validation 15% และ Test 15% ใช้สำหรับการฝึกฝนข้อมูล การปรับพารามิเตอร์ และการทดสอบโมเดล เพื่อจำแนกข้อมูลชุดภาพ ทำการทดลองโดยนำข้อมูลเข้าสู่โมเดลมาตรฐาน เพื่อทำการเรียนรู้ใช้ชุดข้อมูลตามรูปที่ 1 ตัวอย่างชุดข้อมูลรูปภาพอาวุธ 8 ชนิด ขนาด 128x128 พิกเซล จำนวน 10,789 ภาพ ใช้ในการเรียนรู้ 8,651 ภาพ ใช้สำหรับตรวจสอบ 1,069 ภาพ และใช้สำหรับทดสอบ 1,069 ภาพ ทำการเรียนรู้ Epochs 100 รอบ เพื่อทดสอบในข้อมูลพื้นฐานแบบเดียวกัน



รูปที่ 1 ตัวอย่างชุดข้อมูลภาพอาวุธ 8 ชนิด



รูปที่ 2 แบบจำลองโมเดลมาตรฐาน

3.2 โมเดลที่ใช้ในการจำแนกรูปภาพ

ในการศึกษานี้เลือกทดลองใช้โมเดล จำนวน 9 โมเดล แบ่งเป็นโมเดลมาตรฐาน 1 โมเดล ตามรูปที่ 2 และโมเดลพร้อมใช้งานที่ได้รับการฝึกฝนมาก่อนแล้วล่วงหน้า 8 โมเดล ที่ถูกรวมไว้ใน Keras API ตามตารางที่ 1 ได้แก่ VGG19, ResNet50V2, MobileNetV2, EfficientNet-B0, B1, B2, B5 และ B7 โดยนำเข้าชุดข้อมูลรูปภาพจำนวนเท่ากันในแต่ละชุดการทดลอง

จากการทดสอบ Keras Applications [16] โมเดลพร้อมใช้งานที่ได้รับการฝึกฝนมาก่อนแล้วล่วงหน้า 8 แบบ ตามตารางที่ 1 รายละเอียดของการเปรียบเทียบโมเดล ได้ทำการเทียบประสิทธิภาพของโมเดลระหว่าง Accuracy กับ Parameters ดังแสดงจากตัวอย่างของโมเดล EfficientNet-B0 ใช้ตัวแปร

ที่ถูกค่ากำหนดเชิงตัวเลขในการคำนวณ จำนวน 5.3 ล้านพารามิเตอร์ แต่มีความถูกต้องแม่นยำสูง ใน Top-1 Accuracy ถึง 77.10% และ Top-5 Accuracy ถึง 93.30% ซึ่งถือว่าสูงเมื่อเทียบกับ VGG19, ResNet50V2, และ MobileNetV2 เป็นต้น

ตารางที่ 1 รายละเอียดของการเปรียบเทียบโมเดล

Model	Size (MB)	Top-1 Accuracy	Top-5 Accuracy	Parameters	Depth
VGG19	549	71.30%	90.00%	143.7M	19
ResNet50V2	98	76.00%	93.00%	25.6M	103
MobileNetV2	14	71.30%	90.10%	3.5M	105
EfficientNetB0	29	77.10%	93.30%	5.3M	132
EfficientNetB1	31	79.10%	94.40%	7.9M	186
EfficientNetB2	36	80.10%	94.90%	9.2M	186
EfficientNetB5	118	83.60%	96.70%	30.6M	312
EfficientNetB7	256	84.30%	97.00%	66.7M	438

3.3 เครื่องมือที่ใช้ในการวิจัย

การเตรียมอุปกรณ์และสภาพแวดล้อมการทำการศึกษานี้ใช้เครื่องมือที่มีการพัฒนารองรับมาตรฐานเพื่อสร้างสภาพแวดล้อมในการทำงานบน Anaconda พร้อมติดตั้งไลบรารีรุ่นที่เหมาะสม อุปกรณ์ที่ใช้ในการพัฒนาระบบ CPU AMD Ryzen7 2.3GHz, RAM 24576MB, GPU NVIDIA GeForce GTX 1660 Ti

3.4 วัดประสิทธิภาพโมเดลด้วย Confusion Matrix

การศึกษานี้ประเมินประสิทธิภาพของตัวโมเดลด้วย Confusion Matrix [17] ซึ่งเป็นเครื่องมือสำคัญในการประเมินผลลัพธ์ของการทำนาย (Prediction) นำมาใช้ประเมินแบบจำลอง 4 วิธีโดยพิจารณาจากค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความถูกต้องระลึกพิจารณาแยกทีละกลุ่ม (Recall) และค่าเอฟสกอร์ (F1-Score) ดังสมการที่ 1, 2, 3 และ 4

ตารางที่ 2 วัดประสิทธิภาพด้วย Confusion Matrix

Confusion Matrix	Actual Positive	Actual Negative
Predicted Positive	TP	FP
Predicted Negative	FN	TN

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

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

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

$$F1 = 2 * [(precision * recall) / (precision + recall)] \quad (4)$$

3.5 การแปลงค่า Convert ไปเป็น TFLite Model

อุปกรณ์พกพาหรือไมโครคอนโทรลเลอร์ใช้ระบบตัวเลขในการประมวลผลแบบจำนวนเต็ม ดังนั้นโมเดลที่สร้างขึ้นแบบอื่นจึงไม่สามารถใช้งานร่วมกับฮาร์ดแวร์ที่เป็นจำนวนเต็มได้ ในการดำเนินการโมเดลบนฮาร์ดแวร์ที่เป็นจำนวนเต็ม จำเป็นต้องดำเนินการแปลงโมเดล TensorFlow ที่ผ่านการฝึกอบรมเป็นรูปแบบ TensorFlow Lite โดยใช้ API ของ TFLite Converter พร้อมกับการทำ Quantization โดยการหาปริมาณแบบไม่ใช้วิธีการ Quantization, Float16, Dynamic Range, Integer เพื่อเปรียบเทียบรูปแบบที่เหมาะสมกับแต่ละอุปกรณ์นั้น ๆ พร้อมกับการปรับให้สอดคล้องกับการใช้งานเพื่อให้โมเดลมีขนาดเล็กและเพิ่มความเร็วในการอนุมาน ซึ่งการใช้แต่ละโมเดลเหมาะสมที่สุดในการปรับใช้งานบนอุปกรณ์ที่มีความจำเป็นต้องการใช้พลังงานต่ำ

4. ผลการดำเนินงาน

ในบทความนี้จะแสดงให้เห็นถึงแนวทางในการพัฒนาโมเดล พร้อมกับเปรียบเทียบผลลัพธ์ในแต่ละขั้นตอนของการศึกษานี้ ซึ่งการออกแบบระบบให้สามารถทำงานได้ตามวัตถุประสงค์นั้น การเลือกใช้งาน Pre-trained Models ที่มีรูปแบบการทำงานเป็น CNN Architecture ที่สามารถจัดการข้อมูลประเภทรูปภาพได้อย่างมีประสิทธิภาพทำการฝึกสอนโมเดลให้สามารถเรียนรู้ข้อมูลภาพและการปรับปรุงค่าพารามิเตอร์ที่เหมาะสมในการจำแนก

ข้อมูลภาพ เป็นปัจจัยที่มีผลต่อประสิทธิภาพในการจำแนกอวุธในการศึกษาวิจัยครั้งนี้





4.1 เปรียบเทียบผลลัพธ์การทดสอบโมเดล

การจำแนกภาพด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันโดยกำหนดให้โมเดลเรียนรู้จำนวน 100 รอบ และเปรียบเทียบค่าความแม่นยำในการจำแนกภาพก่อนและหลังการใช้เทคนิคการเพิ่มภาพ ภาพอาวุธที่นำเข้าไปในระบบถูกแปลงเป็นตัวเลข และปรับค่าด้วยเทคนิค Batch Normalization เพื่อทำการปรับค่าข้อมูลให้อยู่ในช่วง 0-1 ก่อนนำเข้าไปเรียนรู้ เมื่อพิจารณากราฟในรูปที่ 3(A) การทดลองพบว่า ค่า Accuracy มีแนวโน้มเพิ่มขึ้น แต่ยังมีช่วงห่างระหว่าง Training Accuracy กับ Validation Accuracy สูง ซึ่งแสดงว่ามีข้อมูลภาพในการเรียนรู้ไม่เพียงพอในการ Train Model รวมทั้งกราฟในรูปที่ 3(B) พิจารณาจากค่า Loss เป็นหลัก พบว่า ยังมี การ Train มากขึ้น ค่า Training Loss กลับลดลงอย่างต่อเนื่อง ขณะที่ Validation Loss ลดลงถึงจุดหนึ่งแล้วหลังจากนั้นก็กลับมีการเพิ่มค่าขึ้นเรื่อยๆ จนเกิดการ Overfitting ผลลัพธ์ที่ได้จากตารางที่ 3 โมเดลมาตรฐาน มีค่าความแม่นยำเพียง 59.40%

ทำการทดลองซ้ำโดยเพิ่มประสิทธิภาพด้วยการใช้เทคนิคในการปรับมุมมองภาพก่อนนำเข้าสู่การโมเดล Data Augmentation และการใช้ Dropout กำหนดค่าเท่ากับ 0.2 ปิดการทำงานไป 20% เพื่อลด Overfitting ใน Deep Neural Network จากรูปที่ 3(C) เปรียบเทียบประสิทธิภาพโมเดลมาตรฐานพบว่า ค่า Accuracy มีแนวโน้มเพิ่มขึ้นและรูปที่ 3(D) ซึ่งพิจารณาจาก ค่า Loss พบว่า มีแนวโน้มต่ำลงจากเดิมจากตารางที่ 3 ผลลัพธ์ที่ได้ค่าความแม่นยำเพิ่มขึ้นเป็น 66.79%

ตารางที่ 3 ผลการประเมินโมเดลมาตรฐาน

Standard	Accuracy (%)	Loss	Weighted avg.		
			Precision	Recall	F1-score
Normal	59.40	3.31	0.61	0.59	0.60
Aug&Drop	66.79	0.94	0.67	0.67	0.67



รูปที่ 3 เปรียบเทียบประสิทธิภาพโมเดลมาตรฐาน

การทดลองต่อไปในโมเดลพร้อมใช้งานที่ได้รับการฝึกฝนมาก่อน (Pre-Trained) โดยการนำ Transfer Learning เพิ่มประสิทธิภาพการเรียนรู้ของโมเดล พร้อมกับการเปรียบเทียบโมเดลพร้อมใช้งานที่ได้รับการฝึกฝนมาก่อน 8 โมเดล เป็นตัวแยกคุณลักษณะคงที่ Fixed Feature Extractor ซึ่งสามารถนำมาลบส่วนของ Dense Layer สุดท้ายออกไป ในขั้นตอนนี้จะได้โครงสร้างของ Feature Extractor ที่สามารถสร้างส่วนหัว Custom Head Layer ตามความเหมาะสมกับการศึกษาด้วยการทำ Fine-Tuning ปิดการเรียนรู้บางส่วน (Freeze Model) และเปิดการเรียนรู้เพียงบางส่วน (Unfreeze Model) เพื่อไม่ให้มีการอัปเดตค่าของ Weight จากนั้น Train เฉพาะส่วนหัว (Custom Head Layer) เพื่อปรับ Weight ตามความเหมาะสม

การทดลองด้วยการ Transfer Learning โดยการปิดตัวแยกคุณลักษณะ (Freeze Model) ทุกโมเดล การทดลองตามรูปที่ 4(A) พบว่า ค่า Accuracy มีแนวโน้มเพิ่มขึ้น และตามรูปที่ 4(B) ค่า Loss มีแนวโน้มลดลง แต่ยังมีความห่างระหว่าง Training กับ Validation สูง จากตารางที่ 4 ผลการประเมินโมเดล Transfer Learning นี้ พบว่า EfficientNet-B0 ให้ผลลัพธ์ความแม่นยำมากที่สุด เท่ากับ 92.33%

ตารางที่ 4 ผลการประเมินโมเดลจากการ Transfer Learning





Pre-Trained	Accuracy (%)	Loss	Weighted avg.		
			Precision	Recall	F1-Score
VGG19	85.22	1.576	0.86	0.85	0.85
ResNet50V2	58.75	1.241	0.69	0.59	0.62
MobileNetV2	88.59	1.277	0.89	0.89	0.89
EfficientNet-B0	92.33	0.2361	0.92	0.92	0.92
EfficientNet-B1	89.52	0.2880	0.90	0.89	0.89
EfficientNet-B2	90.36	0.2787	0.91	0.90	0.90
EfficientNet-B5	86.81	0.3711	0.87	0.87	0.87
EfficientNet-B7	88.96	0.3156	0.89	0.89	0.89

การทดลองขั้นสุดท้ายด้วยการทำ Fine-Tuning ใน EfficientNet-B0 ที่มีจำนวนชั้นแยกคุณลักษณะแบบคอนโวลูชัน จำนวน 238 Layers ขั้นตอนนี้มีการเพิ่มจำนวนภาพด้วยเทคนิค Data Augmentation เพื่อปรับมุมมองภาพก่อนนำเข้าข้อมูล ซึ่งการทดลองในขั้นตอนนี้กำหนดให้เปิดการเรียนรู้แบ่งเป็น 50, 100 และ 200 Layers ตามลำดับ ใช้รูปภาพในการทดสอบโมเดล 1,069 ภาพ จากตารางที่ 5 ผลการประเมินโมเดลจากการ Fine-Tuning การเปิดการเรียนรู้ 100 Layers มีความแม่นยำมากที่สุด ตามรูปที่ 4(C) พบว่า ค่า Accuracy มีแนวโน้มเพิ่มขึ้น และตามรูปที่ 4(D) ค่า Loss มีแนวโน้มลดลง กราฟเป็นแบบ Good Fitting ซึ่งผลลัพธ์ของการทดลองนี้เพิ่มขึ้นเป็น 94.01% ผลการประเมิน Precision 0.94, Recall 0.94, F1-score 0.94 แสดงให้เห็นว่าเป็นโมเดลที่มีการเรียนรู้ที่ดี สามารถนำไป Predict ข้อมูลที่ไม่เคยพบเห็นมาก่อนได้อย่างแม่นยำ

การประยุกต์ใช้งานของโมเดลด้วยการนำไปทดสอบกับชุดข้อมูลรูปภาพเครื่องบิน เพื่อทดสอบความสามารถของโมเดลในการจำแนกรูปที่มีความซับซ้อนมากขึ้น จากตารางที่ 5 ผลการประเมินโมเดลจากการ Fine-Tuning เครื่องบินจำนวน 10 แบบ ผลลัพธ์ความแม่นยำอยู่ในเกณฑ์ที่สูงถึง 93.67% แสดงให้เห็นว่าโมเดลมีความยืดหยุ่นและทำงานได้อย่างมีประสิทธิภาพและแสดงให้เห็นลักษณะของผลการทำนายได้อย่างถูกต้อง ตามรูปที่ 5 Confusion Matrix ของรูปอาวุธ 8 ชนิด ซึ่งใช้ในการแสดงค่าความถูกต้องของการทำนายผลของโมเดล

ตารางที่ 5 ผลการประเมินโมเดลจากการ Fine-Tuning

EfficientNet-B0 Fine-Tuning	Accuracy (%)	Loss	Weighted avg.		
			Precision	Recall	F1-Score
Unfreeze 50 Layer	91.67	0.2361	0.92	0.92	0.92
Unfreeze 100 Layer	94.01	0.2880	0.94	0.94	0.94
Unfreeze 200 Layer	93.45	0.2787	0.94	0.93	0.93
10 type of Aircraft	93.67	0.2787	0.94	0.94	0.94



รูปที่ 4 เปรียบเทียบประสิทธิภาพโมเดล Pre-Trained

	Tank	AirCrafft	Gun	ship	rocket	launcher	knife	Helicopter	
Tank	197	1	0	1	0	0	0	0	250
AirCrafft	0	241	3	5	1	1	0	10	200
Gun	1	1	162	0	1	1	1	2	175
ship	3	2	3	89	1	1	0	0	140
rocket	0	0	1	3	86	0	1	3	105
launcher	1	0	1	0	2	77	0	0	70
Knife	0	0	1	0	2	0	38	0	35
Helicopter	0	4	2	2	2	0	0	115	0
	Tank	AirCrafft	Gun	ship	rocket	launcher	knife	Helicopter	

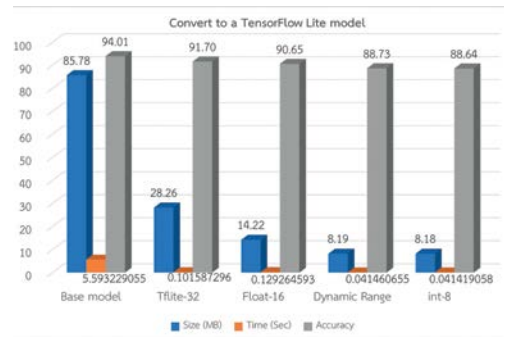
รูปที่ 5 Confusion Matrix ของการจำแนกอาวุธ 8 ชนิด

4.2 ผลการ Convert ไปเป็น TFLite Model

จากตารางที่ 6 ผลการประเมินโมเดลจากการ TensorFlow Lite ลดขนาดแบบจำลองลงมาได้ถึง 25% และรูปที่ 6 ผลการ Convert ไปเป็น TFLite Model แสดงผลการเปรียบเทียบนำโมเดลเข้าสู่กระบวนการคำนวณระบบเลขจำนวนเต็มด้วยหลักการทำ Quantization

ตารางที่ 6 ผลการประเมินโมเดลจาก TensorFlow Lite

No.	Model	Size (MB)	Time (Sec.)	Accuracy	TYPE
1	Base model	85.78	5.5932291	94.01	.h5
2	Tflite-32	28.26	0.1015873	91.70	.TFLITE
3	Float-16	14.22	0.1292646	90.65	.TFLITE
4	Dynamic Range	8.19	0.0414607	88.73	.TFLITE
5	int-8	8.18	0.0414191	88.64	.TFLITE



รูปที่ 6 ผลการ Convert ไปเป็น TFLite Model

5. บทสรุป

5.1 การอภิปรายและสรุปผลการศึกษา

5.1.1 จากการเปรียบเทียบแนวคิดงานวิจัยของ N. Dwivedi และคณะ [10] ใช้เทคโนโลยีโครงข่ายประสาทเทียมในการเรียนรู้เชิงลึกเพื่อการจำแนกอาวุธในการก่ออาชญากรรม โดยใช้สถาปัตยกรรม VGGNet การทดลองใช้ภาพ 3 คลาส คือ มีด ปืน และไม่มีอาวุธ ผลการทดลองมีระดับความแม่นยำ 98.41% มีความสอดคล้องไปตามผลลัพธ์การ

ทดลอง ตารางที่ 4 การทดลองโดยนำข้อมูล 8 คลาส เข้าสู่โมเดล ResNet50V2 ค่าความแม่นยำในการทดสอบ 58.75% ซึ่งมีค่าความแม่นยำที่ต่ำกว่า และ VGG19, MobileNetV2 ค่าความแม่นยำในการทดสอบ 85.22% และ 88.59% มีค่าความแม่นยำในระดับที่ใกล้เคียงกัน

5.1.2 การศึกษาพบว่า การเพิ่มประสิทธิภาพของโมเดลด้วยวิธีการทำ Regularization โดยใช้เทคนิค Augmentation, Batch Normalization และ Dropout มีการเพิ่มขึ้นของค่าความแม่นยำในการทดสอบผลลัพธ์การทดลอง ตารางที่ 4 การทดลองโดยนำข้อมูลภาพเครื่องบิน 10 คลาส เพิ่ม Image augmentation เข้าสู่โมเดล VGG19 ได้ค่าความแม่นยำในการทดสอบเพียง 85.22% เท่านั้น แต่ใน EfficientNet-B0, EfficientNet-B1, EfficientNet-B2 ค่าความแม่นยำในการทดสอบเพิ่มขึ้นเป็น 92.33%, 89.52%, 90.36% ตามลำดับ

5.1.3 ผลการศึกษาครั้งนี้สอดคล้องกับงานวิจัยของ C. Chousangsunthorn และคณะ [15] ระบบการเรียนรู้เชิงลึกเพื่อการจดจำและการรู้จำคุณลักษณะซีเรียลแอมป์บนเครื่องที่ปนเปื้อนในฮาร์ดดิสก์ กระบวนการทดสอบประสิทธิภาพด้วย EfficientNet-B0 ให้ความแม่นยำมากกว่า 99% แสดงให้เห็นประสิทธิภาพการจัดหมวดหมู่ที่เหนือกว่าการอ่านของมนุษย์ แต่ในการศึกษาครั้งนี้ให้ความแม่นยำน้อยกว่า เนื่องจากการศึกษานี้เป็นการจำแนกรูปภาพของวัตถุที่มีลักษณะทางกายภาพที่ใกล้เคียงกัน คุณลักษณะของภาพมีความซับซ้อนและหลากหลายซึ่งยากต่อการจำแนก ผลการศึกษาพบว่าผลลัพธ์จากการทดลองนี้ EfficientNet-B0 มีความเหมาะสมในการนำไปใช้งาน สามารถทำงานได้อย่างถูกต้องแม่นยำสูงสุด 94.01%

5.1.4 จากรูปที่ 6 ผลการ Convert ไปเป็น TFLite Model แสดงการเปรียบเทียบคุณสมบัติของโมเดลในการลดขนาด ลดการใช้เวลาแฝงในการโต้ตอบกับระบบประมวลผลภาพ และความแม่นยำลดลงจากเดิมเมื่อเทียบกับ

โมเดลหลัก ซึ่งผลการแปลงค่าพารามิเตอร์ในตารางที่ 6 ผลการประเมินโมเดลจากการ TensorFlow Lite การทดลองของโมเดลแบบ Float-16 ค่าความแม่นยำ 90.65%, แบบ Dynamic Range ค่าความแม่นยำ 88.73%, ในขณะที่ Int8 มีขนาดเล็กที่สุดได้ค่าความแม่นยำ 88.64% แต่ยังคงอยู่ในเกณฑ์ที่เหมาะสมสามารถนำไปใช้งานกับอุปกรณ์พกพาได้

5.2 ข้อเสนอแนะเพิ่มเติม

จากผลการศึกษาชี้ให้เห็นว่าการจำแนกกลุ่มของข้อมูลภาพมีข้อจำกัดในการนำไปใช้งานดังนี้

5.2.1 กรณีที่มีอาวุธหลายชนิดในภาพเดียวกัน หรือเป็นภาพที่ได้จากวิดีโอ หรือจากการบันทึกเฟรมภาพจากกล้องวิดีโอ การทำนายผลอาจคลาดเคลื่อนได้ เนื่องจากไม่มีฟังก์ชันในการตรวจจับวัตถุ

5.2.2 การจำแนกระหว่างอาวุธที่ใช้งานจริงกับอาวุธที่ทำปลอมขึ้นมา หรือสร้างขึ้นเพื่อเทียบเคียง หรือสิ่งเทียมอาวุธ ยังไม่สามารถจำแนกและระบุได้อย่างถูกต้อง

5.2.3 การทดลองโมเดลที่ผ่านการลดขนาดข้อมูลด้วย TensorFlow Lite การนำไปใช้งานเป็นเพียงทางเลือกตามความต้องการของผู้ใช้งาน ซึ่งค่าความแม่นยำแปรผันตรงกับขนาดโมเดลที่เล็กลงไปด้วย

6. กิตติกรรมประกาศ

ขอขอบคุณสถาบันเทคโนโลยีป้องกันประเทศ กระทรวงกลาโหม ผู้สนับสนุนการทำวิจัยในครั้งนี้จนสำเร็จลุล่วง บทความนี้เป็นส่วนหนึ่งของงานวิจัยที่ได้รับทุนสัญญาเลขที่ 590404 ทุนอุดหนุนการศึกษาระดับปริญญาโท หลักสูตรวิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมป้องกันประเทศ โครงการหลักสูตรร่วมระหว่างสถาบันเทคโนโลยีป้องกันประเทศกับสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

7. เอกสารอ้างอิง

[1] P. Cheewaprabkhit, "Improving the Performance

- of an Image Classification with Convolutional Neural Network Model by Using Image Augmentations Technique,” *TNI J. Eng. Technol.*, vol. 7, no. 1, pp. 59 - 64, Jan. - Jun. 2019.
- [2] K. Chauhan and S. Ram, “Image Classification with Deep Learning and Comparison between Different Convolutional Neural Network Structures Using Tensorflow and Keras,” *Int. J. Adv. Eng. Res. Dev. (IJAEIRD)*. vol. 5, no. 2, pp. 533 - 538, 2018.
- [3] Google LLC Kaggle. (2024). Datasets Explore. [Online]. Available: <https://www.kaggle.com/datasets>
- [4] J. Kukačka, V. Golkov, and D. Cremers, “Regularization for Deep Learning: A Taxonomy,” 2017, arXiv:1710.10686.
- [5] S. Ioffe and C. Szegedy, “Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift,” 2015, arXiv: 1502.03167.
- [6] A. Budhiman, S. Suyanto, and A. Arifianto, “Melanoma Cancer Classification Using ResNet with Data Augmentation,” in *2019 Int. Seminar Res. Inf. Technol. Intell. Syst. (ISRITI)*, Yogyakarta, Indonesia, 2019, pp. 17 - 20, doi: 10.1109/ISRITI48646.2019.9034624.
- [7] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, “Dropout: A Simple Way to Prevent Neural Networks from Overfitting,” *J. Mach. Learn. Res.*, vol. 15, no. 56, pp. 1929 - 1958, 2014.
- [8] *Tensorflow for Mobile & Edge* (2024). Datasets Explore. [Online]. Available: https://www.tensorflow.org/lite/examples/image_classification/overview
- [9] สถาบันเทคโนโลยีป้องกันประเทศ (องค์การมหาชน) กระทรวงกลาโหม. “แผนพื้หน้าทางเทคโนโลยีป้องกันประเทศ พ.ศ. 2553 - 2567.” DTI.or.th <https://www.dti.or.th/download/file/e7dd8350.pdf> (วันที่เข้าถึง ก.พ. 28, 2565).
- [10] N. Dwivedi, D. K. Singh, and D. S. Kushwaha, “Weapon Classification Using Deep Convolutional Neural Network,” in *2019 IEEE Conf. Inf. Commun. Technol.*, Allahabad, India, 2019, pp. 1 - 5, doi: 10.1109/CICT48419.2019.9066227.
- [11] M. J. N. V. S. K. Asrith, K. P. Reddy, and Sujihelen. “Face Recognition and Weapon Detection from Very Low Resolution Image,” in *2018 Int. Conf. Emerg. Trends Innov. Eng. Technol. Res. (ICETIETR)*, Ernakulam, India, 2018, pp. 1 - 5, doi: 10.1109/ICETIETR.2018.8529108.
- [12] L. Zhu and P. Spachos, “Towards Image Classification with Machine Learning Methodologies for Smartphones,” *Mach. Learn. Knowl. Extr.*, vol. 1, no. 4, pp. 1039 - 1057, Oct. 2019, doi: 10.3390/make1040059.
- [13] M. A. Abu, N. H. Indra, A. H. A. Rahman, N. A. Sapiee, and I. Ahmad, “A Study on Image Classification based on Deep Learning and TensorFlow,” *Int. J. Eng. Res. Technol.*, vol. 12, no. 4, pp. 563 - 569, 2019.
- [14] N. Lamsamut and S. Valuvanathorn, “Stroke Disease Classification on Computerized Tomography Scan Images Using Convolutional Neural Network” in *17th Nat. Conf. Comput. Inf. Technol. (NCCIT2021)*, Bangkok, Thailand, 2021, pp. 43 - 48.
- [15] C. Chousangsunton, T. Tongloy, S. Chu wongin, and S. Boonsang, “A Deep Learning System for Recognizing and Recovering Contaminated Slider Serial Numbers in Hard Disk Manufacturing Processes,” *Sensors*, vol. 21, no. 18, p. 6261, Sep. 2021, doi: 10.3390/s21186261.
- [16] *Keras Applications*. (2024). Datasets Explore. [Online]. Available: <https://keras.io/api/applications/>
- [17] A. Géron, “Confusion Matrix,” in *Hands-on Machine Learning with Scikit-Learn, Keras & TensorFlow : Concepts, Tools, and Techniques to Build Intelligent Systems*, N. Tache, Ed., California, CA, USA: O’Reilly Media, 2019, pp. 92 - 106.

โปรแกรมสำหรับเรียนรู้แบบโต้ตอบ โดยใช้ฐานข้อมูลแบบ MySQL เพื่อเก็บข้อมูล ของรถฐานยิงจรวดหลายลำกล้องอเนกประสงค์

กันต์ธร นาทอง¹ เจษฎา ไกรขาว² รัชชิตา ชันทอง²
ปิยะรส มาลีเจริญ^{2*} สิริภาพ สันติรัตนรงค์³ และ นริศ จันทร์น้ำ²

วันที่รับ 22 มีนาคม 2567 วันที่แก้ไข 29 เมษายน 2567 วันตอบรับ 9 พฤษภาคม 2567

บทคัดย่อ

โปรแกรมสำหรับการเรียนรู้แบบโต้ตอบสามารถปรับเนื้อหาการเรียนใช้ได้ตามความต้องการของผู้เรียน ช่วยให้ผู้เรียนเกิดความเข้าใจและจดจำเนื้อหาการเรียนรู้อย่างมีประสิทธิภาพ โปรแกรม D11A-Computer Based Training หรือ D11A-CBT จึงได้ถูกวิจัยพัฒนาขึ้นตามแนวคิดดังกล่าว เพื่อเก็บข้อมูลของรถฐานยิงจรวดหลายลำกล้องอเนกประสงค์ (Multiple Launch Rocket System: MLRS) โดยใช้โปรแกรม Unity เชื่อมต่อกับระบบจัดการฐานข้อมูล (DBMS) แบบ MySQL ซึ่งมีการจัดการข้อมูลผ่าน phpMyAdmin ทำให้สามารถจัดการข้อมูลจำนวนมากให้เป็นระเบียบ สามารถลบ เพิ่มเติม และเรียกใช้งานข้อมูลได้ง่าย โดยการจัดการข้อมูลจะไม่กระทบกับตัวโปรแกรมหลักและข้อมูลที่สามารถจัดเก็บได้จะมีทั้งข้อความ ภาพ และวิดีโอ เป็นต้น โดยแบ่งการใช้งานฐานข้อมูลเป็น 3 ส่วน คือ การแบ่งประเภทผู้ใช้งาน รายละเอียดชิ้นส่วนต่าง ๆ ของตัวรถ และระบบลงทะเบียนเก็บข้อมูลส่วนตัวของผู้ใช้งาน โดยผู้ใช้งานจะถูกแบ่งเป็น 3 ประเภท ได้แก่ บุคคลทั่วไป พลประจำรถและครูฝึก ในแต่ละประเภทจะมีการเข้าถึงข้อมูลได้ต่างกันตามความจำเป็นในการใช้งานข้อมูล ทั้งนี้ การเรียนรู้แบบโต้ตอบยังช่วยให้การศึกษาและจดจำข้อมูลของผู้เรียนเป็นไปอย่างมีประสิทธิภาพ และตัวโปรแกรมยังสามารถใช้งานได้หลายแพลตฟอร์ม ผู้เรียนจึงสามารถเรียนรู้ได้ตลอดเวลา ไม่ว่าจะเป็น คอมพิวเตอร์ แท็บเล็ต หรือสมาร์ตโฟน เป็นต้น โดยผลจากการพัฒนา พบว่า การใช้ระบบฐานข้อมูลภายนอกสามารถทำงานร่วมกับโปรแกรมและเรียกใช้ข้อมูลแบบ Real-time ได้ตามที่ออกแบบ

คำสำคัญ : ฐานข้อมูล, การเรียนรู้แบบโต้ตอบ, เกมเอนจิน

¹ ส่วนทดสอบและประเมินผล, ฝ่ายมาตรฐานและความปลอดภัย, กลุ่มบริหารงานวิจัย, สถาบันเทคโนโลยีป้องกันประเทศ

² ส่วนงานระบบเครื่องช่วยฝึกเสมือนจริง, ฝ่ายวิจัยและพัฒนา, กลุ่มวิจัย, สถาบันเทคโนโลยีป้องกันประเทศ

³ ส่วนงานวิศวกรรมอากาศยาน, ฝ่ายวิจัยและพัฒนา, กลุ่มวิจัย, สถาบันเทคโนโลยีป้องกันประเทศ

* ผู้แต่ง, อีเมล: piyarose.m@dti.or.th

Multiple Launch Rocket System (MLRS) Interactive Learning Program Integration with MySQL Database Integration for Data Storage

Gunthorn Nathong¹ Jedsada Kraikhow² Ranchida Khantong²
Piyarose Maleecharoen^{2*} Siraphob Santironnarong³ and Naris Channum²

Received 22 March 2024, Revised 29 April 2024, Accepted 9 May 2024

Abstract

One of Interactive learning method essential feature is to allow a customization in learning contents that best suited trainee thus maximizing the training effectiveness. Multiple Launch Rocket System (MLRS) interactive learning tool called D11A-Computer Based Training (D11A-CBT) was created on this principle. This program uses Unity to create an interface that allows communication of data between the program and DBMS. Thus, a large quantity of data, such as text, image, and video, can be organized, altered, and requested conveniently with no repercussion on the program. These data consist of the user account type, detailed description of MLRS components and logbook of the user. Users can select an appropriate account type such as visitor, trainer or trainee. Each account type will have different access to corresponding data that is deemed suitable. In addition, this interactive learning program can be installed on various platforms. This feature allows trainees to access training resources at any place and time thus improving their training performance. Furthermore, D11A-CBT program demonstrates the ability to modify and display updated data to the user in real time.

Keywords : Database, Interactive learning, Game engine

¹ Test and Evaluation Division, Standard and Safety Department, Research Management Group, Defence Technology Institute

² Virtual Simulation Division, Research & Development Department, Research Group, Defence Technology Institute

³ Aeronautical Engineering Division, Research & Development Department, Research Group, Defence Technology Institute

* Corresponding author, E-mail: piyarose.m@dti.or.th

1. บทนำ

รถฐานยิงจรวดหลายลำกล้องอเนกประสงค์ (Multiple Launch Rocket System: MLRS) ตามรูปที่ 1 มีการทำงานในแต่ละส่วนที่ซับซ้อนและเป็นขั้นตอน โดยคู่มือของบริษัท เอลบิต ซิสเต็มส์ (Elbit Systems Ltd.) [1] ได้ระบุว่า ภายในรถมีระบบควบคุมการยิงแบบอัตโนมัติสำหรับช่วยในการตั้งมุมยิง โดยระบบเครื่องยิง (Turret) จะสามารถทำระยะมุมยกได้สูงสุด 60 องศา และมุมสายสูงสุด +/- 110 องศา การใช้งานรถมีความยืดหยุ่นตามวัตถุประสงค์ของภารกิจ โดยสามารถเปลี่ยนชุดพ่อยิง (Pod) ได้ 3 แบบสามารถรองรับจรวดได้ทั้งนำวิถีและไม่นำวิถี ระยะยิงไกล 40 กิโลเมตร 150 กิโลเมตร และ 300 กิโลเมตร โดยสามารถทำการยิงจรวดได้ภายในเวลาอันรวดเร็ว หลังจากเริ่มขั้นตอนการยิงจะเห็นได้ว่าตัวรถมีเทคโนโลยีขั้นสูงที่สามารถรองรับการทำภารกิจได้หลากหลายรูปแบบ ผู้ใช้งานจำเป็นต้องมีความรู้ ความชำนาญ และความคุ้นเคยกับระบบการทำงานจึงจะสามารถใช้งานแต่ละระบบได้อย่างถูกต้องแม่นยำในขณะปฏิบัติภารกิจ

ดังนั้น เพื่อให้การเรียนรู้วิธีการใช้งานรถฐานยิงจรวดหลายลำกล้องอเนกประสงค์เป็นไปอย่างมีประสิทธิภาพ จึงได้มีการริเริ่มจัดทำโปรแกรมเพื่อการเรียนรู้แบบโต้ตอบ (Interactive Learning) ซึ่งผู้เรียนจะสามารถเรียนรู้ผ่านอุปกรณ์ต่าง ๆ ได้ง่ายและสะดวกสบาย เช่น คอมพิวเตอร์ (Computer) สมาร์ทโฟน (Smart phone) แท็บเล็ต (Tablet) เป็นต้น โดยสื่อการเรียนรู้แบบโต้ตอบได้ ที่มีการตอบสนองเนื้อหาการเรียนตามความสนใจของผู้เรียนจะเป็นการช่วยผู้เรียนให้สามารถเข้าถึงการเรียนรู้ในการใช้งานรถฐานยิงจรวดหลายลำกล้องอเนกประสงค์ได้โดยสามารถทวนซ้ำข้อมูลสำคัญหรือศึกษารายละเอียด

ปลีกย่อยของตัวรถได้ทุกครั้งทุกเวลาตามต้องการ ซึ่งจากงานวิจัยของ K. Yang และ J. Jie [2] และ A. Nasser และคณะ [3] ได้กล่าวว่าการเรียนรู้แบบโต้ตอบนั้นเป็นการเสริมสร้างพฤติกรรมการเรียนรู้ และเพิ่มประสิทธิภาพให้กับการจดจำของผู้เรียนได้เป็นอย่างดี นอกจากนี้ ในงานวิจัยของ A.-n. N. S. I. Septiani และ คณะ [4], X. Tulkunovna และ X. Mansur [5] และ J.-C. Chen และคณะ [6] ยังระบุว่า สื่อการเรียนการสอนแบบโต้ตอบนั้น สามารถยืดหยุ่นได้ตามลักษณะความสนใจและความถนัดของผู้เรียน ทำให้เกิดประสิทธิผลที่ดีจากการเรียนรู้มากกว่าการเรียนที่ผู้เรียนเป็นฝ่ายรับข้อมูลทางเดียว



รูปที่ 1 รถฐานยิงจรวดหลายลำกล้องอเนกประสงค์

เนื่องจากการการเรียนรู้แบบโต้ตอบนั้นต้องมีการจัดเตรียมการแสดงผลเนื้อหาที่ดึงดูดความสนใจของผู้เรียน ในงานวิจัยของ M. Foxman [7] ได้มีการใช้โปรแกรม Unity ในการพัฒนาโปรแกรมสำหรับแสดงผลสภาพแวดล้อมเสมือนจริงสำหรับการเรียนรู้ เนื่องจากตัวโปรแกรมมีเครื่องมือ (Tools) ที่หลากหลาย ช่วยเพิ่มความสะดวกในการพัฒนาและการเชื่อมต่อกับฐานข้อมูลภายนอก และในงานวิจัยของ K.-S. Hsu และคณะ [8] ยังแสดงให้เห็นว่าการใช้โปรแกรม Unity ยังทำให้การแบ่งส่วนเพื่อพัฒนาโปรแกรมเป็นทีม

เป็นไปได้อย่างมีประสิทธิภาพและรวดเร็วขึ้น ซึ่งส่วนใหญ่ข้อมูลประกอบสำหรับการเรียนรู้จะเป็นข้อมูลที่มีขนาดใหญ่ ทำให้ในบางครั้งข้อมูลทั้งหมดจะถูกย้ายไปจัดเก็บในฐานข้อมูล (Database) ที่ต้องการเชื่อมต่อกับโปรแกรมหลัก ซึ่งการจัดการในรูปแบบนี้ R. C. Mat และ M. H. Mahayudin [9] พบว่า จะทำให้แก้ไขหรือเพิ่มเติมโปรแกรมหลักที่ไม่ใช่ส่วนของข้อมูลได้สะดวกง่ายดายขึ้น

เนื่องจากข้อมูลที่ถูกนำมาใช้ในการจัดทำสื่อการสอนแบบโต้ตอบนั้น ส่วนใหญ่จะเป็นทั้งข้อมูลเนื้อหา รูปภาพ เสียง หรือคลิปวิดีโอ งานวิจัยของ B. Christudas [10] จึงได้มีการใช้ฐานข้อมูลแบบ MySQL ที่สามารถจัดการข้อมูลได้เป็นระเบียบและมีความรวดเร็ว โดยมีการใช้งานร่วมกับ MAMP ที่เป็นโปรแกรมสำเร็จรูปทางคอมพิวเตอร์ (Software) สำหรับจำลองเครื่องแม่ข่ายเว็บบนเครื่องคอมพิวเตอร์ ซึ่งบทความใน Websiterating.com [11] และงานวิจัยของ B. Rawat และคณะ [12] ได้มีการกล่าวว่า MySQL เป็นโอเพนซอร์สที่มีการให้บริการแบบไม่เสียค่าใช้จ่าย และมีความน่าเชื่อถือสำหรับการใช้งานในแอปพลิเคชัน โดย MySQL มีคุณสมบัติที่สำคัญของฐานข้อมูล คือ ACID (Atomicity, Consistency, Isolation, Durability) เพื่อให้สามารถใช้งานในการจัดเก็บข้อมูลหลายชนิด ซึ่งช่วยให้นักพัฒนาสามารถสร้างแอปพลิเคชันฐานข้อมูลบนเว็บที่มีขนาดใหญ่อย่างง่ายดาย โดยใช้ตัวประสาน (Interface) SQL ที่ง่ายต่อการใช้งาน ทำให้ผู้ใช้งานไม่จำเป็นต้องมีความรู้เกี่ยวกับสถาปัตยกรรมของระบบหรือเครื่องมือการจัดเก็บข้อมูล

ดังนั้น ด้วยวัตถุประสงค์เพื่อให้การเรียนรู้วิธีการใช้งานฐานข้อมูลหลายล้ากล้องอเนกประสงค์เป็นไปอย่างมีประสิทธิภาพ บทความนี้จึงได้มีการเริ่มจัดทำโปรแกรมสำหรับช่วยในการฝึกสอนการใช้งานตามหลักการที่ได้กล่าวมาข้างต้น ชื่อว่าโปรแกรม

D11A-CBT (D11A-Computer Based Training) โดยมีลักษณะเด่น คือ เป็นสื่อการสอนที่มีการตอบสนองตามความสนใจของผู้เรียน มีความดึงดูดให้ผู้เรียนเกิดความรู้สึกอยากเรียนรู้ กระตุ้นการจดจำได้มากขึ้น และสามารถเรียนรู้ได้สะดวกผ่านอุปกรณ์ช่วยแสดงผลต่าง ๆ ได้ตลอดเวลา ตัวโปรแกรมถูกออกแบบให้มีการประยุกต์ใช้ MySQL ที่เป็นระบบจัดการฐานข้อมูล (Database Management System: DBMS) แบบข้อมูลเชิงสัมพันธ์ (Relational Database Management System: RDBMS) ร่วมกับโปรแกรมที่สร้างจาก Unity เพื่อเก็บข้อมูลของรถฐานยิงจรวดหลายล้ากล้องอเนกประสงค์ โดยจะเรียกโปรแกรมนี้ว่า D11A-Computer Based Training หรือ D11A-CBT สำหรับการพัฒนาโปรแกรมจะประกอบด้วย 3 ส่วนหลักคือ โมเดลรถฐานยิงจรวดหลายล้ากล้องอเนกประสงค์ที่ถูกสร้างจากโปรแกรม Blender โปรแกรมที่ถูกพัฒนาด้วย Unity และส่วนฐานข้อมูลที่มีการใช้ MySQL ช่วยในการเก็บข้อมูล ซึ่งทั้ง 3 ส่วนจะถูกพัฒนาร่วมกันให้สามารถใช้งานได้ตรงตามความต้องการของผู้ใช้ ในระยะแรกของการวิจัยและพัฒนาโปรแกรมจะถูกกำหนดขอบเขตของการแสดงผลให้มีเฉพาะส่วนของบุคคลภายนอก ซึ่งการแสดงข้อมูลจะประกอบไปด้วยข้อมูลทั่วไปและชิ้นส่วนสำคัญของรถฐานยิงจรวดหลายล้ากล้องอเนกประสงค์ โดยผู้ใช้งานสามารถทำการเลือกคลิกชิ้นส่วนต่าง ๆ ที่ปรากฏบนโปรแกรม เพื่อให้โปรแกรมแสดงผลข้อมูลที่เกี่ยวข้องได้

2. การทบทวนวรรณกรรมที่เกี่ยวข้อง

ระบบฐานข้อมูลที่สามารถนำมาประยุกต์ใช้ร่วมกับโปรแกรม Unity นั้น มีหลายรูปแบบ โดยฐานข้อมูลจะถูกนำมาใช้เก็บข้อมูลของ Object เช่น ข้อมูลของรถฐานยิงจรวดหลายล้ากล้องอเนกประสงค์

ที่ประกอบไปด้วยขนาดและรูปแบบของชิ้นส่วนต่าง ๆ สีและคุณลักษณะเฉพาะของแต่ละอุปกรณ์ ซึ่งการมีฐานข้อมูลจะช่วยให้การพัฒนาโปรแกรมเป็นไปได้ง่ายและสะดวกต่อการปรับปรุงแก้ไขต่อไปในอนาคต

เนื่องจากข้อมูลฐานยังจรวดหลายล้าล้องอเนกประสงค์มีทั้งในรูปแบบภาพ เสียง และวิดีโอ ในการออกแบบโปรแกรมจึงได้มีการเลือกประยุกต์ใช้ฐานข้อมูล (Database) แบบ MySQL ซึ่งจัดอยู่ในกลุ่มระบบจัดการฐานข้อมูลเชิงสัมพันธ์แบบโอเพนซอร์ส (Open Source) ที่สามารถใช้งานได้ง่าย มีความรวดเร็วและเชื่อถือได้โดยมีการจัดเก็บและเรียกข้อมูลด้วยภาษาควิรีที่มีโครงสร้าง (Structured Query Language: SQL) และเป็นโซลูชันจัดเก็บข้อมูลเชิงสัมพันธ์หลักสำหรับเว็บไซต์และแอปพลิเคชัน สามารถติดตั้งได้ทั้งโปรแกรม PHP และ MySQL

2.1 การเรียนรู้แบบตอบโต้ (Interactive Learning)

การเรียนรู้แบบตอบโต้จะมีลักษณะสำคัญที่เด่นชัด คือ การทำให้ผู้เรียนมีส่วนร่วมกับเนื้อหาจนกระทั่งนำไปสู่แรงจูงใจในการเรียนรู้ ซึ่งผู้จัดทำสื่อการเรียนรู้สามารถปรับแต่งเนื้อหาการสอนได้ตามความสนใจของแต่ละบุคคล ทำให้สามารถกระตุ้นการจดจำของผู้เรียนได้ดีขึ้น นอกจากนี้ ยังช่วยประหยัดต้นทุนและพื้นที่สำหรับการเรียนการสอนได้ดี

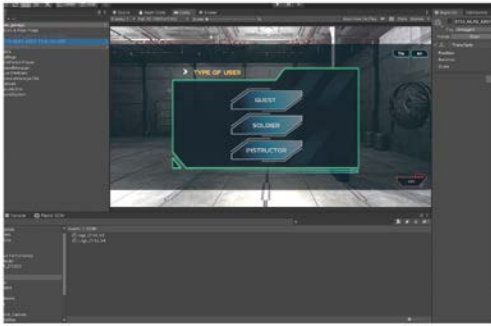
2.2 โปรแกรมยูนิตี (Unity)

โปรแกรม Unity 3D ผลิตขึ้นจากบริษัท Unity Technologies [13] เป็นโปรแกรมเกมเอนจิน (Game Engine) แบบข้ามแพลตฟอร์ม (Cross-platform) ที่ใช้สำหรับพัฒนาเกมได้ทั้งแบบ 2 มิติ และ 3 มิติ ซึ่งใช้อย่างแพร่หลายในกลุ่มนักพัฒนาเกม เพื่อสร้าง

การจำลองแบบตอบโต้ (Interactive) ทั้งบนเครื่องมือสื่อสารแบบพกพา บนเว็บไซต์ รวมถึงสามารถใช้ในการพัฒนาโลกเสมือนจริงแบบความเป็นจริงเสมือน (Virtual Reality: VR) และแบบความเป็นจริงแต่งเติม (Augmented Reality: AR) โดยมีความสามารถในการรองรับฟอร์ตบนแพลตฟอร์มอื่น ๆ ที่หลากหลาย ภาษาคอมพิวเตอร์หลักที่มีการใช้งานคือ C#, Unity, Javascript และ Boo โดยในบทความนี้จะมีการใช้ภาษา C# ในการพัฒนาโปรแกรม และแม้ว่าโปรแกรม Unity จะเป็นเกมเอนจิน แต่ในปัจจุบันได้รับการยอมรับและถูกใช้อย่างแพร่หลายในงานแขนงอื่น ๆ ที่ไม่เกี่ยวข้องกับเกม ไม่ว่าจะเป็นการแสดงข้อมูล การทำกราฟิก หรือการนำเสนอแนวคิดในรูปแบบ 2 มิติ และ 3 มิติ ที่สามารถใช้งานได้ทั้งแบบมีและไม่มีค่าใช้จ่าย [14] - [15] นอกจากนี้ การสร้างโปรแกรมด้วย Unity ยังสามารถประยุกต์ใช้กับ MySQL Database ได้อย่างง่ายดายทำให้การเก็บข้อมูล การแก้ไขข้อมูลในอนาคตและการพัฒนาโปรแกรมร่วมกันเป็นทีมเป็นไปได้ไปอย่างสะดวกสบายมากยิ่งขึ้น

ในส่วนอินเทอร์เฟซของผู้ใช้งาน (User Interface) ของโปรแกรม Unity ตามรูปที่ 2 นั้น จะประกอบไปด้วยส่วนหลัก ๆ คือ

1. การแสดงผลฉากโดยรวม (Scene View) สำหรับแสดงภาพรวมสถานการณ์ตามที่ได้มีการออกแบบ
 2. ส่วนจัดการไฟล์ต่าง ๆ (Assets) สำหรับเก็บไฟล์ที่เกี่ยวข้องกับโปรเจกต์ (Project)
 3. ส่วนแสดงลำดับชั้นของข้อมูลและส่วนแสดงรายละเอียดของข้อมูล (Hierarchy) สำหรับเพิ่มเติมแก้ไข หรือติดตามข้อมูลต่าง ๆ ของในฉากโดยรวม
- โดยทุกครั้งที่มีการสร้างโปรแกรมใหม่ ข้อมูลทั้งหมดจะถูกแบ่งตามประเภทและเก็บไว้ใน Unity Project [16] และสามารถเรียกใช้ข้อมูลได้โดยไม่ต้องแก้ไข



รูปที่ 2 อินเทอร์เฟซของผู้ใช้งาน (User Interface) ในโปรแกรม Unity

2.3 ฐานข้อมูลแบบ MySQL

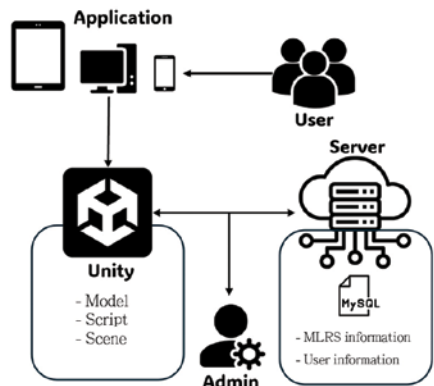
MySQL เป็นระบบจัดการฐานข้อมูลที่พัฒนาโดยใช้ภาษาเอสคิวแอล (SQL) ในการเขียน โดยภาษาเอสคิวแอลจะเป็นภาษาที่ใช้ในการสอบถามข้อมูลหรือภาษาจัดการข้อมูลอย่างมีโครงสร้าง มีการพัฒนาภาษาคอมพิวเตอร์ และโปรแกรมฐานข้อมูลที่รองรับมากมาย [17] ใช้งานได้ทั้งใน Linux และ Windows และเนื่องจาก MySQL เป็นระบบจัดการฐานข้อมูลเชิงสัมพันธ์ (Relational Database) ซึ่งจะมีการเก็บข้อมูลทั้งหมดในรูปแบบของตารางแทนการเก็บข้อมูลทั้งหมดลงในไฟล์เพียงไฟล์เดียว ทำให้สามารถทำงานได้รวดเร็วและมีความยืดหยุ่นสูง นอกจากนี้แต่ละตารางที่มีการเก็บข้อมูลจะสามารถเชื่อมโยงเข้าหากัน ทำให้การรวมกลุ่มหรือจัดกลุ่มข้อมูลเป็นไปได้ง่ายโดยมีการอาศัยภาษาเอสคิวแอลที่เป็นส่วนหนึ่งของโปรแกรม MySQL เป็นภาษามาตรฐานในการเข้าถึงฐานข้อมูล

โปรแกรม D11A-CBT นั้น ได้มีการใช้ phpMyAdmin ซึ่งเป็นเครื่องมือที่มีความสามารถในการจัดการข้อมูลจาก MySQL ได้โดยผ่านทางเบราว์เซอร์ (Browser) นอกจากนี้ phpMyAdmin ยังสามารถรองรับการดำเนินการต่าง ๆ ใน MySQL เช่น

การประมวลผลฐานข้อมูลผู้ใช้งาน และอื่น ๆ โดยมีการออกแบบให้ใช้งานได้ง่าย

3. วิธีดำเนินการวิจัย

โปรแกรม D11A-CBT นั้น ได้มีการออกแบบและพัฒนาด้วยโปรแกรม Unity ร่วมกับ Server ที่มีการติดตั้งระบบจัดการฐานข้อมูลแบบ MySQL และใช้ phpMyAdmin เป็นตัวช่วยในการจัดการ การเชื่อมต่อ Unity กับระบบฐานข้อมูลดังรูปที่ 3 จากนั้นจะแสดงผลไปยังผู้ใช้งานผ่านอุปกรณ์ต่าง ๆ เช่น คอมพิวเตอร์หรือแท็บเล็ต โดยการพัฒนาด้วยโปรแกรม Unity นั้น จะมีเชื่อมต่อระหว่างโปรแกรมด้วยการเขียนสคริปต์ (Scripts) ซึ่งในสคริปต์จะประกอบไปด้วยข้อมูลต่าง ๆ เช่น Server IP, Port, User และ Password และการตรวจสอบสถานะการเชื่อมต่อ เป็นต้น เพื่อทำการเชื่อมต่อกับฐานข้อมูลดังแสดงรายละเอียดใน ER-diagram ตามรูปที่ 4 การเรียกใช้ Code ในสคริปต์จะประกอบไปด้วย ฟังก์ชันประเภทผู้ใช้งาน ฟังก์ชันการเชื่อมต่อ ฟังก์ชันสถานะการเชื่อมต่อ ฟังก์ชันการเข้าสู่ระบบ ฟังก์ชันระบบลงทะเบียน และฟังก์ชันการตรวจสอบชื่อของชิ้นส่วน เมื่อผู้ใช้งานทำการกดปุ่มคลิกที่ชิ้นส่วนนั้น ๆ



รูปที่ 3 ภาพรวมการทำงานและการแสดงผลของโปรแกรม D11A-CBT



รูปที่ 6 หน้าลงทะเบียน

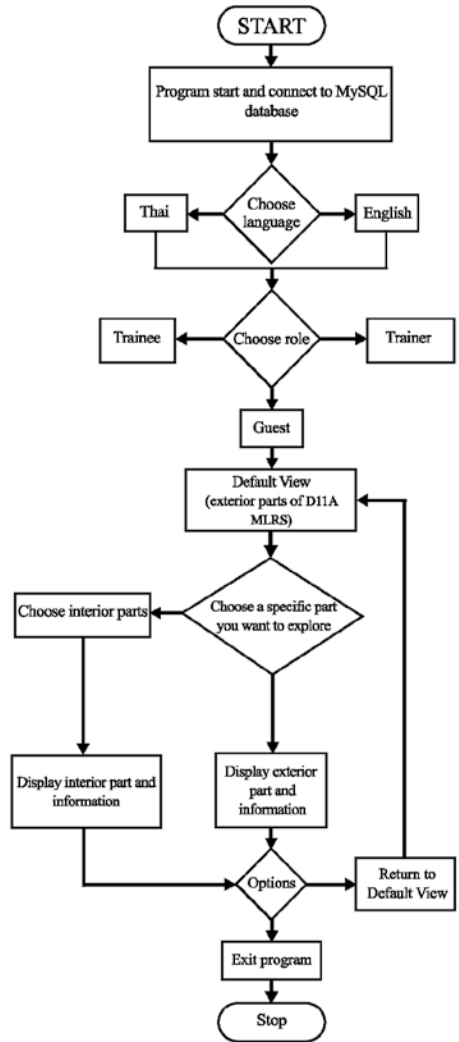


รูปที่ 7 ชั้นส่วนภายนอกตัวรถ



รูปที่ 8 ชั้นส่วนภายในตัวรถ


ในส่วนของการแสดงผลของชั้นส่วนต่าง ๆ ของรถฐานยิงจรวดหลายลำกล้องอเนกประสงค์จะมีการเขียนสคริปต์ในโปรแกรม Unity โดยการใช้การจับคู่ (Matching) กันระหว่างป้ายชื่อ (Tag) ของวัตถุ (Object) กับชื่อชั้นส่วน (part_id) ที่แสดงในตารางของฐานข้อมูล เช่น ในรูปที่ 11 แสดงให้เห็นว่าเมื่อ Object ในโปรแกรม Unity ถูกตั้งชื่อเป็น cabin ชื่อ part_id ในตารางฐานข้อมูลก็ต้องเป็น cabin เช่นเดียวกัน เป็นต้น



รูปที่ 9 Flow Chart แสดงการทำงานของโปรแกรม D11A-CBT

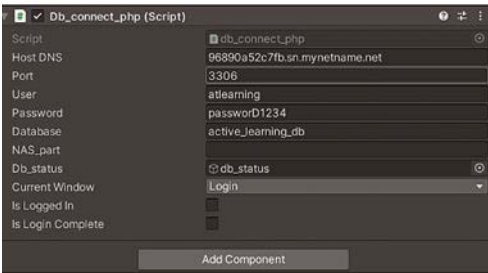


รูปที่ 10 หน้าแรกของโปรแกรม D11A-CBT



รูปที่ 11 การกำหนด Tag ของ object เป็น cabin

การนำสคริปต์มาใช้ร่วมกับ Object ต่าง ๆ ใน Unity นั้น จะใช้วิธีการเพิ่มสคริปต์เข้าไปใน Object ดังรูปที่ 12 โดยจะมีการกำหนดรายละเอียดการตั้งค่าต่าง ๆ ไว้ ซึ่งหากต้องการเปลี่ยนแปลงการตั้งค่าต้องเปลี่ยนในสคริปต์เท่านั้น



รูปที่ 12 การเพิ่มสคริปต์ชื่อ Db_connect_php ใน Object

การแสดงผลสถานะการเชื่อมต่อกับฐานข้อมูล จะมีสถานะบอกอยู่ในฉากภายในตัวรถ (Interior) และภายนอกตัวรถ (Exterior) โดยจะแสดงอยู่ด้านบนขวาของจอแสดงผล ดังรูปที่ 13 และรูปที่ 14 เพื่อตรวจสอบสถานะการเชื่อมต่อระหว่างโปรแกรมและฐานข้อมูล ในระหว่างการใช้งาน โดยออกแบบสคริปต์ดังรูปที่ 15 ให้แสดงข้อความ “Disconnected” เมื่อฐานข้อมูลไม่สามารถเชื่อมต่อได้ และ “Connected” เมื่อทำการเชื่อมต่อฐานข้อมูลสำเร็จ

4. ผลการวิจัย

เมื่อเสร็จสิ้นขั้นตอนการสร้างโปรแกรม และ Build โปรแกรมให้เป็นไฟล์ในรูปแบบ .exe สำหรับนำไปใช้งานในคอมพิวเตอร์พบว่า เมื่อทำการเปิดโปรแกรมและมีการใช้งานโปรแกรม สถานะการ



รูปที่ 13 สถานะการเชื่อมต่อเมื่อมีการใช้งานโปรแกรมในฉากภายในตัวรถ (Interior)



รูปที่ 14 แสดงสถานะการเชื่อมต่อเมื่อมีการใช้งานโปรแกรมในฉากภายนอกตัวรถ (Exterior)


```
void UpdateInterval()
{
    Text newText = _db_status.GetComponentInChildren<Text>();
    //use this as the secondary update.
    if (!connectToDB())
    {
        print("MySQL - Reconnecting");
        newText.text = "Disconnected";
        db_connected = false;
    }
    else if (!db_connected)
    {
        print("MySQL - Connected");
        newText.text = "Connected";
        db_connected = true;
    }
}
```

รูปที่ 15 Code สำหรับตรวจสอบการเชื่อมต่อฐานข้อมูล

เชื่อมต่อระหว่างโปรแกรม D11A-CBT จะแสดงเป็น “Connected” ตลอดเวลา ทั้งการใช้งานเลือกฉากภายในตัวรถ (Interior) และภายนอกตัวรถ (Exterior) เป็นการแสดงว่าสามารถเชื่อมต่อฐานข้อมูลได้สำเร็จ



รูปที่ 16 ผลการเรียกข้อมูลภาษาไทย
ของชิ้นส่วนรถเมื่อทำการคลิกเลือก



รูปที่ 17 ผลการเรียกข้อมูลภาษาอังกฤษ
ของชิ้นส่วนรถเมื่อทำการคลิกเลือก

ตารางที่ 1 เวลาเฉลี่ยของการตอบสนองของฐานข้อมูลเมื่อทำการเรียกใช้การแสดงผลข้อมูลชิ้นส่วนต่าง ๆ

ลำดับที่	ชื่อชิ้นส่วน	Latency (ms)	Data Size (Byte)	Data Transfer Rate (Mbps)
1	ชุดหัวแก๊ง	0.27	2344	68.36
2	ชุดป้องกันกระจก	0.22	974	27.84
3	แชสชิส	0.30	478	12.62
4	คุณลักษณะเครื่องยนต์	0.31	302	7.84
5	ล้อ	0.29	74	2.07
6	ถังน้ำมัน	0.39	72	1.49
7	โครงสร้างย่อย	0.30	1358	36.45
8	ชุดโครงสร้าง	0.29	1158	32.45
9	เท้าข้าง	0.30	1984	52.94
10	ห้องสำหรับอุปกรณ์	0.28	932	26.31
11	ชุดเครื่องยิงและชุดแคร่	0.30	5476	146.86
12	ระบบไฮดรอลิก	0.29	2230	62.40
13	คอมพิวเตอร์ควบคุมการยิง	0.29	3578	97.83
14	ชุดควบคุมการยิง	0.29	2656	72.15
15	ระบบกำหนดตำแหน่ง	0.28	1632	46.04
16	สวิตช์ฉุกเฉิน	0.29	116	3.20

สำหรับการแสดงผลข้อมูลของ
ชิ้นส่วนของรถทั้งภาษาไทยและภาษาอังกฤษ
ดังตัวอย่างในรูปที่ 16 และรูปที่ 17 จะพบว่า
เมื่อทำการเลือกชิ้นส่วนที่ได้มีการทำสคริปต์

เชื่อมโยงกับฐานข้อมูลไว้ตามชื่อ tag ก็
สามารถเรียกข้อมูลของชิ้นส่วนนั้น ๆ มาแสดง
ได้ทั้งภาษาไทยและภาษาอังกฤษตามที่ได้
ทำการออกแบบไว้

การตอบสนองของข้อมูลเมื่อทำการใช้ฐานข้อมูลบนเซิร์ฟเวอร์ที่แยกส่วนกับโปรแกรมหลักมีความถูกต้องรวดเร็วและแม่นยำ โดยมีระยะเวลาการตอบสนองเพื่อแสดงผลของข้อมูลเมื่อทำการเรียกใช้ฐานข้อมูลดังตารางที่ 1

5. สรุปและวิเคราะห์ผลการวิจัย

จากการออกแบบการประยุกต์ใช้งานระบบฐานข้อมูลร่วมกับโปรแกรมที่สร้างจาก Unity พบว่า ระบบฐานข้อมูลสามารถใช้งานได้อย่างมีประสิทธิภาพ และมีความสะดวกในการแก้ไข ช่วยลดความซับซ้อนในการเพิ่มเติมปรับปรุงข้อมูลได้มากกว่าการนำข้อมูลทั้งหมดไปใช้ในโปรแกรมโดยไม่มีระบบฐานข้อมูล นอกจากนี้ การเชื่อมต่อยังมีความเสถียร สามารถเรียกใช้งานได้ทันทีที่โปรแกรม D11A-CBT เริ่มทำงาน โดยจากผลการทดสอบพบว่าสามารถแสดงผลภายในระยะเวลาไม่เกิน 4 ms โดยนอกจากการใช้งานร่วมกับ Windows Application แล้วยังสามารถรองรับการนำไปใช้งานกับ Platform อื่น ๆ ได้ เช่น iOS, iPadOS และ Android เป็นต้น โดยสามารถดึงข้อมูลในระบบฐานข้อมูลออกมาใช้ได้ไม่จำเป็นต้องแก้ไขหรือปรับแต่งระบบฐานข้อมูลเพิ่มเติมใด ๆ ซึ่งผลการพัฒนาเบื้องต้นเป็นประโยชน์อย่างมากในการพัฒนา Application ในยุคปัจจุบันที่มีการใช้งานอุปกรณ์ที่หลากหลาย และยังช่วยลดระยะเวลาในการพัฒนาในอนาคตได้อีกด้วย

ทั้งนี้ ในส่วนของแผนการพัฒนาในอนาคตจะมุ่งเน้นไปที่การออกแบบรายละเอียดของการแสดงผลข้อมูลและการจัดทำฐานข้อมูลในส่วนของผู้ฝึกและครูฝึก ซึ่งในส่วนนี้จะมีการประเมินผลการเรียนและแสดงผลในรูปแบบสถิติเพื่อวัดผลต่อไป

6. กิตติกรรมประกาศ

งานวิจัยฉบับนี้ได้รับการสนับสนุนข้อมูลของรศฐานยิงจรวดหลายลำกล้องอนุกรมประสงค์ อุปกรณ์ที่ใช้ในการวิจัยและพื้นที่ในการทำวิจัยรวมถึงการอำนวยความสะดวกในด้านต่าง ๆ จากโครงการวิจัยและพัฒนาจรวดหลายลำกล้องนำวิถี (D11A) และส่วนงานเครื่องช่วยฝึกเสมือนจริง สถาบันเทคโนโลยีป้องกันประเทศ ซึ่งได้สนับสนุนและส่งเสริมการทำวิจัยจนสามารถสำเร็จลุล่วงได้ด้วยดีตามเป้าหมาย

7. เอกสารอ้างอิง

- [1] Elbit Systems Ltd. "Precise and Universal Launching System." ELBITSYSTEMS.com. <https://elbitsystems.com/product/puls/> (accessed Jan. 4, 2024).
- [2] K. Yang and J. Jie, "The Designing of Training Simulation System Based on Unity 3D," in *2011 4th Int. Conf. Intell. Comput. Technol. Automat.*, Shenzhen, China, 2011, pp. 976 - 978, doi: 10.1109/ICICTA.2011.245.
- [3] A. Nasser, T. Zhou, V. Ha, J. Zhu, D. T. Wu, and H. Ohyama, "Students' Perceptions of Virtual Interactive Clinical Case-based Learning: A Comparative Study with Three Different Cohorts," *J. Dent. Sci.*, pp. 1 - 9, Dec. 2023, doi: 10.1016/j.jds.2023.12.018.
- [4] A. - n. N. S. I. Septiani, T. Rejekiningsih, Triyanto, and Rusnaini, "Development of Interactive Multimedia Learning Courseware to Strengthen Students' Character," *Eur. J. Educ. Res.*, vol. 9, no. 3, pp. 1267 - 1280, 2020.
- [5] X. N. Tulkunovna and X. Mansur, "Improving the Effectiveness of Learning Military Concepts Through Interactive Methods," *Int.*

- J. Integr. Eng.*, vol. 3, no. 10, pp. 158 - 162, 2020, doi: 10.31149/ijie.v3i10.709.
- [6] J.-C. Chen, C.-T. Hsu, M.-H. Chiang, and Y.-J. Jiang, "Unity3D Game-based Learning System," in *2nd Int. Conf. Innov., Commun. Eng.*, Qingdao, China, 2013, p. 235.
- [7] M. Foxman, "United We Stand: Platforms, Tools and Innovation With the Unity Game Engine," *Soc. Media Soc.*, vol. 5, no. 4, p. 205630511988017, 2019, doi: 10.1177/2056305119880177.
- [8] K.-S. Hsu, P.-Y. Lai, J.-F. Jiang, H.-Y. Wei, Y.-J. Chen, and T.-H. Lee, "A Feasibility Study of Unity 3D Interactive Engine Development," in *Innov., Commun. Eng.*, T. H. Meen, S. D. Prior, and A. D. K.-T. Lam, Eds. 2014, pp. 191 - 194.
- [9] R. C. Mat and M. H. Mahayudin, "Using Game Engine for Online 3D Terrain Visualization with Oil Palm Tree Data," *J. Telecommun. Electron. Comput. Eng.*, vol. 10, no. 1 - 10, pp. 93 - 97, Feb. 2018.
- [10] B. Christudas, "MySQL," in *Practical Microservices Architectural Patterns: Event-Based Java Microservices with Spring Boot and Spring Cloud*, Berkeley, CA: Apress, 2019, pp. 877 - 884.
- [11] Website Rating. "MYSQL คืออะไร?." WEBSITERATING.com. <https://www.website-rating.com/th/web-hosting/glossary/what-is-mysql/> (accessed Jun. 12, 2023).
- [12] B. Rawat, S. Purnama, and Mulyati, "MySQL Database Management System (DBMS) on FTP Site LAPAN Bandung," *Int. J. Cyber IT Sevice*, vol. 1, no. 2, pp. 173 - 179, 2021.
- [13] A. Jungherr and D. B. Schlarb, "The Extended Reach of Game Engine Companies: How Companies Like Epic Games and Unity Technologies Provide Platforms for Extended Reality Applications and the Metaverse," *Soc. Media Soc.*, vol. 8, no. 2, p. 20563051221107641, 2022, doi: 10.1177/20563051221107641.
- [14] J. K. Haas, "A History of the Unity Game Engine," Worcester Polytech. Inst., Worcester, MA, USA, Rep. E-project-030614-143124, 2014.
- [15] A. Hussain, H. Shakeel, F. Hussain, N. Uddin, and T. L. Ghouri, "Unity Game Development Engine: A Technical Survey," *Univ. Sindh J. Inf. Commun. Technol. (USJICT)*, vol. 4, no. 2, pp. 73 - 81, 2020.
- [16] D. Polancec and I. Mekterovic, "Developing MOBA Games Using the Unity Game Engine," in *2017 40th Int. Convention Inf. Commun. Technol., Electron. Microelectronics (MIPRO)*, Opatija, Croatia, 2017, pp. 1510 - 1515, doi: 10.23919/MIPRO.2017.7973661.
- [17] R. Oberhauser, "Database Model Visualization in Virtual Reality: Exploring WebVR and Native VR Concepts," *Int. J. Adv. Softw.*, vol. 12, no. 3 - 4, pp. 201 - 215, 2019.

ปัญญาประดิษฐ์แบบรู้สร้างกับการประยุกต์ใช้ทางการทหาร

กนก บุณนาค ^{1*}

วันที่รับ 12 มกราคม 2567 วันที่แก้ไข 23 กุมภาพันธ์ 2567 วันที่ตอบรับ 12 มีนาคม 2567

บทคัดย่อ

บทความนี้มีวัตถุประสงค์เพื่อ 1) ศึกษาถึงการพัฒนาและประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้าง (Generative Artificial Intelligence: Generative AI) ในด้านการทหาร 2) วิเคราะห์แนวโน้มการประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้างทางการทหาร ระหว่างปี ค.ศ. 2024 – 2030 และ 3) สังเคราะห์แนวทางในการพัฒนาขีดความสามารถทางการทหารของประเทศไทยด้วยปัญญาประดิษฐ์แบบรู้สร้าง ผลจากการวิจัยเอกสาร พบว่าบริบทที่สำคัญของการประยุกต์ใช้งานปัญญาประดิษฐ์แบบรู้สร้างทางการทหารในช่วงแรกนั้น มุ่งเน้นไปที่การนำมาใช้เป็นเครื่องมือเพื่อช่วยสนับสนุนการตัดสินใจของผู้บังคับบัญชาในการควบคุมบังคับบัญชาการปฏิบัติการทางทหาร แต่ด้วยขีดความสามารถของปัญญาประดิษฐ์แบบรู้สร้างที่เพิ่มมากยิ่งขึ้นส่งผลให้การประยุกต์ใช้งานทางการทหารมีแนวโน้มที่จะขยายขอบเขตออกไปทั้งในระดับยุทธวิธี ยุทธการ และยุทธศาสตร์

แนวโน้มการประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้างทางการทหาร ระหว่างปี ค.ศ. 2024 - 2030 สามารถแบ่งออกเป็น 3 กลุ่มหลัก ได้แก่ การควบคุมบังคับบัญชา การสงครามและการรบ และการสนับสนุนการสงคราม โดยเมื่อพิจารณาถึงความเชื่อมโยงกับระดับการทำสงคราม แนวโน้มการประยุกต์ใช้งานส่วนใหญ่จะเป็นการใช้งานในระดับยุทธวิธี สำหรับระดับยุทธการจะเป็นการใช้ประโยชน์ในการตัดสินใจในการควบคุมบังคับบัญชา การทำสงครามบนโครงข่ายดิจิทัล การปฏิบัติการจิตวิทยา และการสนับสนุนการสงคราม ในขณะที่การใช้ประโยชน์ทางยุทธศาสตร์จะเป็นการใช้ในกระบวนการตัดสินใจและการปฏิบัติที่มีผลต่อความเชื่อ ขวัญ และกำลังใจของประชาชน ซึ่งเป็นองค์ประกอบที่สำคัญของการสงคราม

เทคโนโลยีปัญญาประดิษฐ์แบบรู้สร้างเป็นเทคโนโลยีสร้างความพลิกผันที่สามารถช่วยเพิ่มประสิทธิภาพและสร้างความได้เปรียบในการปฏิบัติการทางทหาร บทความนี้จะชี้ให้เห็นแนวโน้มและแนวทางการพัฒนาขีดความสามารถทางการทหารของประเทศไทยด้วยปัญญาประดิษฐ์แบบรู้สร้างใน 4 ประเด็นหลัก ได้แก่ 1) การพัฒนาโครงสร้างพื้นฐานที่เกี่ยวข้องในการรองรับเทคโนโลยี 2) การสร้างหรือปรับปรุงโมเดลภาษาขนาดใหญ่เพื่อใช้ภายในกองทัพ 3) การกำหนดมาตรการในการใช้งาน และ 4) การริเริ่มประยุกต์ใช้งานกับโครงการพัฒนาขีดความสามารถของกระทรวงกลาโหมและกองทัพไทยที่ได้วางแผนการปฏิบัติไว้แล้ว เพื่อยกระดับขีดความสามารถในการปฏิบัติงานและขีดความสามารถทางการทหารของประเทศไทยต่อไปในอนาคต

คำสำคัญ : ปัญญาประดิษฐ์แบบรู้สร้าง, การประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้างทางการทหาร, การพัฒนาขีดความสามารถทางการทหาร

¹ ฝ่ายวิเคราะห์เทคโนโลยีป้องกันประเทศ, สถาบันเทคโนโลยีป้องกันประเทศ

* ผู้แต่ง, อีเมล: kanok.b@dti.or.th

Generative Artificial Intelligence and Its Military Application

Kanok Bunnag^{1*}

Received 12 January 2024, Revised 23 February 2024, Accepted 12 March 2024

Abstract

This article is intended to 1) explore the development and application of Generative Artificial Intelligence (Generative AI) in military contexts; 2) analyze trends in the military application of Generative AI from 2024 to 2030; and 3) synthesize approaches for enhancing Thailand's military capabilities using Generative AI. The research indicates that the initial focus of Generative AI application in military operations primarily centered on supporting commanders' decision-making processes. However, as the capabilities of Generative AI have expanded, its application in military contexts is expected to broaden in tactical, operational, and strategic levels.

The trends in military applications of Generative AI between 2024 and 2030 can be categorized into three main groups: command and control, combat and warfare, and warfare support applications. When considering the linkage to levels of warfare, the majority of applications are expected to be at the tactical level, with operational level applications encompassing decision-making in command and control, warfare in the digital domain, psychological operations, and support for warfare. Strategic level applications are anticipated to involve decision-making processes and operations affecting the morale, spirit, and strength of the populace, which are critical components of warfare.

Generative AI is a disruptive technology that can enhance efficiency and provide a competitive advantage in military operations. This analysis thus recommends four main strategies for developing Thailand's military capabilities using Generative AI: 1) establishing infrastructure to support technology; 2) creating or improving large language models for military use; 3) defining operational guidelines; and 4) initiating applications in planned development projects by the Ministry of Defence and the Thai Armed Forces to further enhance operational performance and military capabilities in the future.

Keywords : Generative artificial intelligence, Military applications of generative AI, Military capability development

¹ Defence Technology Analysis Department, Defence Technology Institute

* Corresponding author, E-mail: kanok.b@dti.or.th

1. บทนำ

เทคโนโลยีปัญญาประดิษฐ์ หรือ Artificial Intelligence (AI) ได้ก้าวขึ้นมาเป็นหนึ่งในเทคโนโลยีที่สร้างความพลิกผัน (Disruptive Technology) และได้รับความสนใจเป็นอย่างมากในทุกด้านของสังคมในโลกปัจจุบัน โดยเทคโนโลยีปัญญาประดิษฐ์นำมาซึ่งการเปลี่ยนแปลงและผลกระทบไม่เพียงแต่ในด้านวิทยาศาสตร์และเทคโนโลยี ด้านธุรกิจและด้านสังคมที่หมายรวมถึงการใช้ชีวิตประจำวันของประชากรในสังคมเพียงเท่านั้น แต่ยังมีนำมาซึ่งผลกระทบในด้านความมั่นคงที่หน่วยงานด้านความมั่นคงของประเทศต้องมีความเข้าใจก้าวทันการเปลี่ยนแปลงมีแผนการรับมือและมีขีดความสามารถในการพัฒนาและประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์ให้เกิดประโยชน์สูงสุดในการปกป้องผลประโยชน์และการรักษาความมั่นคงแห่งชาติ

ในปัจจุบันเทคโนโลยีปัญญาประดิษฐ์ได้รับการพัฒนาการเรียนรู้จนเข้าสู่ยุคของ “ปัญญาประดิษฐ์แบบรู้สร้าง” หรือ “Generative Artificial Intelligence” หรือ “Generative AI” ที่ปัญญาประดิษฐ์มีขีดความสามารถในการสร้างข้อมูลใหม่จากชุดข้อมูลที่มีอยู่เดิมซึ่งสามารถตอบสนอง รวมถึงนำเสนอข้อมูลด้วยความหลากหลายและสอดคล้องกับสถานการณ์ความต้องการใช้งานข้อมูลของมนุษย์ เทคโนโลยีปัญญาประดิษฐ์แบบรู้สร้างนี้เป็นเทคโนโลยีที่กำลังได้รับความนิยมในสังคมหรือเรียกได้ว่าเป็นเทคโนโลยีที่อยู่ในกระแส โดยตัวอย่างปัญญาประดิษฐ์แบบรู้สร้างที่มีความโดดเด่น ได้แก่ ChatGPT ที่สามารถสร้างข้อความสื่อสารตอบโต้เสมือนพูดคุยกับคน และ DALL-E ที่สามารถสร้างภาพจากข้อความการสั่งการโดยนอกเหนือจากการนำปัญญาประดิษฐ์แบบรู้สร้างมาใช้งานในภาคพลเรือนแล้วนั้น เทคโนโลยีดังกล่าว

ยังถูกนำมาประยุกต์ใช้งานทางการทหารด้วยมุมมองถึงโอกาสในการสร้างความได้เปรียบในการปฏิบัติการทางทหาร แต่ยังมีได้รับความนิยมนำมาใช้

บทความนี้จึงมีวัตถุประสงค์เพื่อศึกษาการพัฒนาและประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้างทางการทหารตั้งแต่อดีตจนถึงปัจจุบัน จากการวิจัยเอกสาร (Documentary Research) ด้วยการศึกษาค้นคว้าข้อมูลจากเอกสารทางวิชาการ งานวิจัย และแหล่งข้อมูลอิเล็กทรอนิกส์ต่าง ๆ ที่เป็นแหล่งข้อมูลเปิดและวิเคราะห์แนวโน้มการประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้างทางการทหาร ระหว่างปี ค.ศ. 2024 - 2030 โดยแสดงถึงความเชื่อมโยงกับระดับการทำสงคราม (Level of Warfare) ทั้งนี้ การกำหนดขอบเขตการวิเคราะห์แนวโน้มการประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้างทางการทหารจนถึงปี ค.ศ. 2030 ซึ่งเป็นปีสิ้นสุดทศวรรษนั้น สอดคล้องกับแนวโน้มการวางแผนเชิงยุทธศาสตร์ในรูปแบบของ Decade-Base Planning โดยเป็นการคาดการณ์แนวโน้มพัฒนาการและการใช้งานเทคโนโลยีในระยะสั้น เนื่องจากการคาดการณ์ในระยะยาวอาจมีความคลาดเคลื่อนสูงอันเนื่องมาจากพัฒนาการของเทคโนโลยีที่เป็นไปอย่างรวดเร็วและต่อเนื่อง นอกเหนือไปจากนั้น บทความนี้ได้สังเคราะห์ข้อเสนอแนะแนวทางในการพัฒนาขีดความสามารถทางการทหาร ของประเทศไทยด้วยปัญญาประดิษฐ์แบบรู้สร้าง เพื่อให้สามารถนำไปใช้ประโยชน์ต่อไป

2. ความรู้เบื้องต้นเกี่ยวกับเทคโนโลยีปัญญาประดิษฐ์แบบรู้สร้าง

เทคโนโลยีปัญญาประดิษฐ์แบบรู้สร้าง (Generative AI) เป็นประเภทของปัญญาประดิษฐ์ที่สามารถสร้างข้อมูลขึ้นมาใหม่ จากการเรียนรู้และ

ปรับปรุงตนเองจากข้อมูลที่มีอยู่ เช่น การสร้างข้อความ การสร้างเนื้อเรื่อง การสร้างภาพศิลปะ การเขียนเนื้อเพลง การสร้างภาพเคลื่อนไหว หรือการนำเสนอประเภทอื่น ๆ โดยบริษัท IBM ซึ่งเป็นบริษัทชั้นนำด้านเทคโนโลยีดิจิทัลของโลกได้ให้คำนิยามของปัญญาประดิษฐ์แบบรู้สร้างไว้ว่าเป็น “โมเดลการเรียนรู้เชิงลึกที่สามารถสร้างข้อมูลที่มีคุณภาพสูงทั้งที่เป็นข้อความ ภาพ และเนื้อหาอื่น ๆ โดยอ้างอิงข้อมูลจากการฝึกหัดเรียนรู้” [1] ในขณะที่บริษัท NVIDIA ที่มีความเชี่ยวชาญด้านการประมวลผลกราฟิก อธิบายว่าโมเดลของปัญญาประดิษฐ์แบบรู้สร้างใช้เครือข่ายเช่นเดียวกับระบบประสาท (Neural Networks) ในการระบุรูปแบบและโครงสร้างภายในฐานข้อมูลที่มีอยู่เพื่อสร้างเนื้อหาใหม่และเป็นเนื้อหาต้นฉบับได้ [2]

โดยทั่วไป ปัญญาประดิษฐ์แบบรู้สร้างใช้เทคนิคการเรียนรู้ผ่านโมเดลภาษาขนาดใหญ่ (Large Language Model หรือ LLM) ซึ่งเป็นการฝึกฝน เรียนรู้ และวิเคราะห์ข้อมูลจากฐานข้อมูลแบบคำและข้อความจำนวนมากแล้วนำมาประมวลผลสร้างความเชื่อมโยงในระดับของคำ ประโยค และบทสนทนา เพื่อสร้างข้อความในการสื่อสารให้เทียบเคียงได้กับข้อความที่มนุษย์สร้างขึ้นได้ตามธรรมชาติ โดยขีดความสามารถในการสร้างสรรค์การสื่อสารโต้ตอบ โดยอาศัยประสบการณ์จากการฝึกฝน เรียนรู้ วิเคราะห์และประมวลผลนี้ ส่งผลให้ปัญญาประดิษฐ์แบบรู้สร้างถูกนำมาใช้งานในรูปแบบของการเป็นตัวแทนการสนทนาเสมือนจริง (Conversation Agents) ที่สามารถสนทนาในภาษาธรรมชาติกับมนุษย์ [3] ตัวอย่างของตัวแทนการสนทนาเสมือนจริงที่เห็นได้ชัดและทวีการใช้งานอย่างแพร่หลายในปัจจุบัน ได้แก่ โปรแกรม ChatGPT หรือ Chat Generative Pre-Trained Transformer ที่พัฒนาขึ้นโดยบริษัท

OpenAI ของสหรัฐอเมริกา โปรแกรม ChatGPT นี้ได้รับการออกแบบมาเพื่อให้บริการข้อมูลและตอบคำถามผ่านระบบการสนทนาที่เชื่อมโยงปัญญาประดิษฐ์แบบรู้สร้างเข้ากับระบบฐานข้อมูลแบบเปิดและฐานข้อมูลบนอินเทอร์เน็ต ให้สามารถเรียนรู้และสร้างคำอธิบาย คำตอบและวิธีการแก้ปัญหาสำหรับคำถามที่ซับซ้อน ในการนี้ Sam Altman ประธานเจ้าหน้าที่บริหารของบริษัท OpenAI ได้กล่าวว่า ในอนาคตอันใกล้ ระบบ ChatGPT จะสามารถเป็นผู้ช่วยที่เป็นประโยชน์ในการพูดคุย ตอบคำถาม และให้คำแนะนำ อีกทั้งจะสามารถทำงานที่ได้รับมอบหมายรวมถึงช่วยแสวงหาความรู้ใหม่ ๆ ให้แก่ผู้ใช้บริการได้ [4]

นอกเหนือจากการพัฒนาและใช้งานเทคโนโลยีปัญญาประดิษฐ์แบบรู้สร้างในทางพลเรือนแล้ว เทคโนโลยีดังกล่าวยังได้ถูกพัฒนาและประยุกต์ใช้ทางการทหารด้วย โดยขีดความสามารถในการประมวลผลจากฐานข้อมูลขนาดใหญ่ด้วยความรวดเร็วเพื่อสร้างบริบทการสื่อสารโต้ตอบที่ตอบสนองต่อการใช้งานข้อมูลอย่างมีประสิทธิภาพ ช่วยลดระยะเวลาในการประมวลผลข้อมูลและนำเสนอหนทางปฏิบัติเพื่อการตัดสินใจของผู้บังคับบัญชา ซึ่งเอื้อต่อการสร้างความได้เปรียบในการดำเนินกลยุทธ์ทางการทหาร

3. การประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้างทางการทหารจากอดีตถึงปัจจุบัน

เทคโนโลยีปัญญาประดิษฐ์แบบรู้สร้างเป็นเทคโนโลยีสองทาง (Dual-Use Technology) ที่สามารถนำมาประยุกต์ใช้งานได้ทั้งทางภาคพลเรือนและภาคการทหาร การพัฒนาและประยุกต์ใช้งานปัญญาประดิษฐ์แบบรู้สร้างทางการทหารจึงได้รับการเอื้อประโยชน์โดยตรงจากพัฒนาการความเจริญ

ก้าวหน้าของเทคโนโลยีทางภาคพลเรือน อย่างไรก็ตาม การใช้งานทางการทหารในปัจจุบันยังอยู่ในช่วงของการพัฒนาและทดสอบทดลองใช้งาน ถึงแม้ว่าจะมีความพยายามในการพัฒนาและประยุกต์ใช้มาแล้วไม่น้อยกว่า 30 ปี โดยประเด็นการใช้งานปัญญาประดิษฐ์แบบรู้สร้างทางการทหารถือได้ว่าเป็นประเด็นที่มีความเปราะบางสูง เนื่องจากมีความเชื่อมโยงถึงผลกระทบต่อชีวิตมนุษย์ ดังนั้น จริยธรรมการใช้งาน รวมถึงความถูกต้องและความน่าเชื่อถือของข้อมูลที่ได้รับจากการประมวลผลของปัญญาประดิษฐ์แบบรู้สร้างจึงเป็นประเด็นสำคัญที่ต้องได้รับการตรวจสอบและประเมินผลอย่างถี่ถ้วนและรัดกุม ก่อนที่จะมีการรับรองมาตรฐานทางการทหารและนำมาใช้ในทางปฏิบัติจริง

จากการศึกษาข้อมูลแบบทฤษฎีภูมิจากแหล่งข้อมูลเปิด ทั้งที่เป็นเอกสารทางวิชาการและแหล่งข้อมูลออนไลน์พบว่า การเปิดเผยข้อมูลการใช้งานปัญญาประดิษฐ์แบบรู้สร้างทางการทหารยังมีความจำกัด ตัวอย่างการประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้างทางการทหารที่มีหลักฐานอย่างเป็นรูปธรรม และสามารถอ้างอิงได้นั้น ส่วนใหญ่มาจากสหรัฐอเมริกาและสาธารณรัฐประชาชนจีน ซึ่งเป็นสองชาติมหาอำนาจที่พยายามช่วงชิงความได้เปรียบจากความเป็นเลิศด้านเทคโนโลยีอุบัติใหม่

ในช่วงต้นทศวรรษที่ 90 ศูนย์ปัญญาประดิษฐ์ของสถาบันวิจัยและพัฒนา SRI International (SRI) ประเทศสหรัฐอเมริกา ได้พัฒนาต้นแบบระบบวางแผนเผชิญสถานการณ์ฉุกเฉิน SOCAP (System for Operations Crisis Action Planning) ซึ่งได้บูรณาการระบบปัญญาประดิษฐ์ขั้นสูงที่เรียกว่า SIPE-2 (System for Interactive Planning and Execution) เพื่อช่วยในการวางแผนทางทหารและพัฒนาหนทางปฏิบัติสำหรับการปฏิบัติการร่วมแบบอัตโนมัติให้

แก่กองบัญชาการ U.S. Central Command (CENTCOM) ของกองทัพสหรัฐอเมริกา โดยที่ปัญญาประดิษฐ์ดังกล่าวมีการเรียนรู้จากแหล่งฐานข้อมูลที่เป็นการประเมินความเสี่ยง การวิเคราะห์ภูมิศาสตร์ กำลังทหารที่ได้รับมอบหมาย ความสามารถในการขนส่งเป้าหมายในการวางแผน ข้อเสนอแนะสำคัญและข้อจำกัดในการดำเนินการ กอปรกับการมีปฏิสัมพันธ์ (Human Interaction) กับผู้เชี่ยวชาญด้านการวางแผนทางทหาร รวมทั้งข้อมูลจากแหล่งอื่น ๆ เช่น แหล่งข้อมูลเปิดที่สาธารณชนสามารถเข้าถึงได้แล้วนำมาวิเคราะห์ประมวลผล เพื่อสร้างแผนเผชิญสถานการณ์ฉุกเฉินที่เหมาะสมต่อเป้าหมาย [5] ต่อมาในปี 1995 ได้มีการวิจัยต่อยอดระบบเทคโนโลยีปัญญาประดิษฐ์สำหรับการวางแผน ที่เรียกว่า “Advisable Planning Systems” ให้สามารถรองรับคำสั่งการ คำแนะนำ และคำบ่งชี้ความต้องการในการดำเนินการของผู้ใช้งานได้สะดวกและมีประสิทธิภาพมากยิ่งขึ้น [6] ต้นแบบระบบวางแผนทางทหารแบบอัตโนมัติโดยใช้เทคโนโลยีปัญญาประดิษฐ์เหล่านี้ถือได้ว่าเป็นความพยายามในการพัฒนาเทคโนโลยีปัญญาประดิษฐ์แบบรู้สร้างในยุคแรก ๆ ซึ่งยังมีข้อจำกัดค่อนข้างมากโดยเฉพาะอย่างยิ่งในเรื่องของการเรียนรู้ด้านภาษา บริบทการสนทนา วัตถุประสงค์และความคาดหวังจากคำแนะนำและสั่งการต่าง ๆ เนื่องจาก ณ ขณะนั้น ฐานข้อมูลสำหรับการเรียนรู้ของปัญญาประดิษฐ์ยังมีปริมาณที่จำกัด

ในทางคู่ขนาน ความก้าวหน้าของการพัฒนาโมเดลภาษาขนาดใหญ่ ซึ่งเป็นโมเดลการเรียนรู้สำหรับปัญญาประดิษฐ์ที่รองรับการประมวลผลภาษาธรรมชาติ (Natural Language Processing: NLP) บนโครงข่ายระบบประสาทสมองเฉกเช่นเดียวกับสมองของมนุษย์ได้เปิดโอกาสในการเติมเต็มขีดความสามารถของปัญญาประดิษฐ์แบบรู้สร้าง

ในการสนับสนุนการควบคุมบังคับบัญชาทางทหาร โดยโมเดลภาษาขนาดใหญ่ได้รับการพัฒนาอย่างต่อเนื่องในภาคพลเรือนและมีประวัติย้อนไปถึงโปรแกรมแชทบอตชื่อว่า ELIZA ซึ่งเป็นโปรแกรมที่ใช้การรู้จำรูปแบบเพื่อนำมาใช้ในการจำลองการสนทนาของมนุษย์ที่พัฒนาขึ้นในปี ค.ศ. 1967 และเป็นจุดเริ่มต้นของการวิจัยพัฒนาด้านการประมวลภาษาธรรมชาติรวมถึงการพัฒนาโมเดลภาษาขนาดใหญ่ที่ซับซ้อนมากขึ้น พัฒนาการของโมเดลภาษาขนาดใหญ่นี้ มีนวัตกรรมที่โดดเด่นเกิดขึ้นเป็นระยะ โดยในปี ค.ศ. 1997 ได้มีการเปิดตัวระบบเครือข่ายความจำ Long Short-Term Memory (LSTM) Networks ที่เอื้อต่อการสร้างเครือข่ายประสาทเสมือนเชิงลึกที่มีความซับซ้อนและสามารถจัดการกับข้อมูลปริมาณมากขึ้นได้ ต่อมาในปี ค.ศ. 2010 ได้มีการเปิดตัวระบบ Stanford's CoreNLP Suite ที่เป็นชุดเครื่องมือและอัลกอริทึมในการแก้ปัญหาการประมวลผลภาษาธรรมชาติที่มีความซับซ้อน เช่น การวิเคราะห์อารมณ์และการรู้จำข้อมูลตัวบุคคล (Named Entity Recognition) ในปี ค.ศ. 2011 บริษัท Google ได้เปิดตัว Google Brain ที่เปิดโอกาสให้นักวิจัยสามารถเข้าถึงฐานข้อมูลและเครื่องมือในการคำนวณที่มีประสิทธิภาพสูงรวมถึงคุณสมบัติที่ทันสมัย อาทิ Word Embeddings ซึ่งช่วยให้ระบบการประมวลผลภาษาธรรมชาติสามารถเข้าใจบริบทของคำได้ดีขึ้น การเข้าถึงทรัพยากรของ Google Brain นี้ นับเป็นหมุดหมายที่สำคัญของการพัฒนาโมเดลภาษาขนาดใหญ่อย่างก้าวกระโดดโดยในปี ค.ศ. 2017 ได้มีการพัฒนาโมเดล Transformer สำหรับการประมวลผลโมเดลภาษาขนาดใหญ่ที่มีขนาดใหญ่และซับซ้อนยิ่งขึ้นและนำมาสู่การพัฒนา ChatGPT ในปัจจุบัน [7]

การประยุกต์ใช้งาน Generative AI ทาง

การทหารในปัจจุบันมีผลสืบเนื่องมาจากขีดความสามารถของโมเดลภาษาขนาดใหญ่ที่ได้รับการพัฒนาอย่างก้าวกระโดด โดยมีการประยุกต์ใช้งานใน 2 ด้านหลัก ได้แก่ การสนับสนุนการควบคุมบังคับบัญชาและการปฏิบัติการข้อมูลข่าวสาร

ในด้านการสนับสนุนการควบคุมบังคับบัญชา ประเทศสหรัฐอเมริกามีความพยายามในการประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้างเพื่อการควบคุมบังคับบัญชาที่มีประสิทธิภาพและเอื้อต่อการตัดสินใจของผู้บังคับบัญชา โดยในเดือนกรกฎาคม ค.ศ. 2023 กระทรวงกลาโหมสหรัฐอเมริกาได้นำโมเดลภาษาขนาดใหญ่มาทดสอบทดลองใช้งานเป็นครั้งแรก ระหว่างการฝึกด้านการบูรณาการข้อมูลดิจิทัลเพื่อประมวลผลข้อมูลการปฏิบัติการทางทหารและสร้างคำตอบและเสนอแนะทางปฏิบัติที่เป็นไปได้สำหรับการตัดสินใจของผู้บังคับบัญชา [8] และต่อมาในเดือนสิงหาคม ค.ศ. 2023 กระทรวงกลาโหมสหรัฐอเมริกาได้ประกาศจัดตั้งกองกำลังเฉพาะกิจด้านปัญญาประดิษฐ์แบบรู้สร้าง (Generative AI Task Force) ชื่อว่า กองกำลังเฉพาะกิจ Lima (Task Force Lima) โดยมีวัตถุประสงค์เพื่อประเมิน ประสานงาน และประยุกต์ใช้ขีดความสามารถของปัญญาประดิษฐ์แบบรู้สร้างในการสร้างปัจจัยความได้เปรียบสำหรับภารกิจการรักษาความมั่นคงของประเทศ การจัดตั้งกองกำลังเฉพาะกิจ Lima นี้ แสดงให้เห็นว่าปัญญาประดิษฐ์แบบรู้สร้างได้รับความสนใจและได้รับความสำคัญจากกองทัพระดับชั้นนำของโลก โดยนาวาเอก Manuel Xavier Lugo ผู้บังคับกองกำลังเฉพาะกิจ Lima ได้แสดงความคิดเห็นในเอกสารประชาสัมพันธ์ของกระทรวงกลาโหมสหรัฐอเมริกาว่า “กระทรวงกลาโหมสหรัฐอเมริกาทระหนักถึงโอกาสและความสำคัญของการประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้างในการเพิ่มประสิทธิภาพของ

ขั้นตอนและกระบวนการปฏิบัติงานทั้งในทางธุรกิจ การวางแผนทางยุทธศาสตร์และการปฏิบัติการด้าน ขาวกรอง อย่างไรก็ตาม การประยุกต์ใช้บนพื้นฐาน ความรับผิดชอบที่เหมาะสมถือเป็นกุญแจสำคัญใน การบริหารจัดการความเสี่ยงที่อาจเกิดขึ้นอย่างมี ประสิทธิภาพ” [9]

ในส่วนของประเทศสาธารณรัฐประชาชน จีนนั้น แม้ว่าจะยังไม่ปรากฏหลักฐานการประยุกต์ เทคโนโลยีปัญญาประดิษฐ์แบบรู้สร้างอย่างเป็นรูปธรรม แต่ผลงานทางวิชาการของนักวิจัยในสังกัดกองทัพ ปลดปล่อยประชาชนจีนบ่งชี้ให้เห็นถึงความพยายาม ในการพัฒนาปัญญาประดิษฐ์แบบรู้สร้างเพื่อใช้การ ควบคุมบังคับบัญชา ซึ่งอำนวยความสะดวกในการ เข้าใจสภาพสถานการณ์การรบและเอื้อต่อการตัดสินใจ ของเจ้าหน้าที่ในระดับยุทธวิธี ตัวอย่างเช่น ในปี 2022 Hsiu-Min Chuang และ Ding-Wei Cheng ได้เผยแพร่ ผลงานวิจัยการใช้ปัญญาประดิษฐ์สำหรับการ สนทนา (Conversational AI) ในการวิเคราะห์ความ ตั้งใจและสร้างบทสนทนาโต้ตอบสำหรับบริบท การปฏิบัติการทหาร เพื่อให้กำลังรบที่ปฏิบัติงาน ภาคสนามในพื้นที่ที่ไม่คุ้นเคยสามารถเข้าถึงและ รับทราบข้อมูลที่เกี่ยวข้องกับการปฏิบัติการกิจได้ อย่างทันทั่วทั้ง [10]

นอกเหนือไปจากนั้น สาธารณรัฐประชาชนจีน มีความพยายามในการใช้ปัญญาประดิษฐ์แบบรู้สร้าง เพื่อการปฏิบัติการข้อมูลข่าวสาร โดยวารสารกองทัพ ปลดปล่อยประชาชนจีนได้เผยแพร่บทความในปี ค.ศ. 2020 เกี่ยวกับการประยุกต์ใช้เทคโนโลยีอุบัติใหม่ ในการต่อสู้เพื่อความคิดเห็นของสาธารณะ โดยให้ ข้อคิดเห็นว่า เทคโนโลยีการสังเคราะห์ภาพและวิดีโอ แบบ Deepfakes มีต้นทุนต่ำและสามารถนำมาใช้งาน ในด้านการปฏิบัติการข้อมูลข่าวสารได้ง่ายภายใน ระยะเวลาอันสั้น นอกจากนี้ เทคโนโลยีปัญญาประดิษฐ์

ที่ใช้โครงข่าย Generative Adversarial Networks และ Neural Networks ยังเป็นเทคโนโลยีที่สำคัญ ยิ่งสำหรับการสร้างขีดความสามารถในการทำ สงครามข้อมูลข่าวสาร [11] หลักฐานทางวิชาการ ที่ปรากฏเหล่านี้แสดงให้เห็นถึงความพยายามหลัก ของกองทัพปลดปล่อยประชาชนจีนในการประยุกต์ ใช้ปัญญาประดิษฐ์แบบรู้สร้าง โดยเฉพาะในด้านการปฏิบัติการข้อมูลข่าวสารและการเป็นตัวแทน การสนทนาเสมือนจริงในการสนับสนุนข้อมูลให้แก่ ผู้ปฏิบัติการภาคสนาม

จากที่กล่าวมาแล้วจะเห็นได้ว่า บริบทสำคัญ ของการประยุกต์ใช้งานปัญญาประดิษฐ์แบบรู้สร้าง ทางทหารในช่วงแรกนั้นมุ่งเน้นไปที่การนำมาใช้ เป็นเครื่องมือเพื่อช่วยสนับสนุนการตัดสินใจของ ผู้บังคับบัญชาในการควบคุมบังคับบัญชาการปฏิบัติ การทางทหาร แต่ด้วยขีดความสามารถของปัญญา ประดิษฐ์แบบรู้สร้างที่เพิ่มมากยิ่งขึ้นส่งผลให้การ ประยุกต์ใช้งาน ทางทหารมีแนวโน้มที่จะขยาย ขอบเขตออกไปทั้งในรูปแบบของการเป็นเครื่องมือ ในการปฏิบัติการข้อมูลข่าวสารและการเป็น ตัวแทนการสนทนาเสมือนจริงที่สามารถช่วยในการ วิเคราะห์ประมวลผลข้อมูลและสนทนาให้คำตอบ คำแนะนำรวมถึงข้อมูลที่เกี่ยวข้องแก่การปฏิบัติ การทางทหารทั้งในระดับยุทธวิธี ยุทธการ และ ยุทธศาสตร์ ในระยะเวลาที่รวดเร็วยิ่งขึ้น

4. แนวโน้มการประยุกต์ใช้ปัญญาประดิษฐ์ แบบรู้สร้างทางการทหาร ระหว่างปี ค.ศ. 2024 – 2030

การประยุกต์ใช้ Generative AI เพื่อการ ทหารในอนาคตมีแนวโน้มจะทวีความหลากหลาย มากยิ่งขึ้นด้วยพัฒนาการของเทคโนโลยีที่เป็นไปอย่าง รวดเร็วและก้าวกระโดด กระทั่งวงกลมโหมของชาติ

มหาอำนาจทางการทหาร อาทิ สหรัฐอเมริกา เสนอแผนงบประมาณประจำปี ค.ศ. 2024 โดยร้องขอการจัดสรรงบประมาณการลงทุนในการวิจัยและพัฒนาเทคโนโลยีปัญญาประดิษฐ์และการเรียนรู้ของเครื่อง (Machine Learning) จำนวน 1.8 พันล้านดอลลาร์สหรัฐและงบประมาณสำหรับการปฏิรูประบบการควบคุมบังคับบัญชาแบบ Joint All-Domain Command and Control (JADC2) จำนวน 1.4 พันล้านดอลลาร์สหรัฐ เพื่อยกระดับขีดความสามารถของปัญญาประดิษฐ์ในการช่วยสนับสนุนกระบวนการตัดสินใจของผู้บังคับบัญชา รวมถึงการเพิ่มขีดความสามารถความเป็นอัตโนมัติให้แก่ยุทธโศปกรณ์ทางทหารต่าง ๆ [12] นอกจากนี้ กองกำลังเฉพาะกิจ Lima ของกระทรวงกลาโหมสหรัฐฯ ที่มีหน้าที่และความรับผิดชอบในการริเริ่มประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้างทางการทหารได้แบ่งระยะการพัฒนาและประยุกต์ใช้ออกเป็น 3 ระยะ ได้แก่ ระยะการเรียนรู้ (Learn Phase) เพื่อรวบรวมความต้องการใช้งาน วิเคราะห์และวางแผนการประยุกต์ใช้งานระยะผลึกตัน (Accelerate Phase) เพื่อขับเคลื่อนเร่งรัดและผลักดันให้การประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้างในกองทัพสหรัฐฯ เกิดขึ้นอย่างเป็นรูปธรรม และระยะการขึ้นนำแนวทาง (Guide Phase) เพื่อขยายการประยุกต์ใช้งานออกไปอย่างเป็นวงกว้างในกองทัพสหรัฐฯ โดยในระยะแรกนั้น กองกำลังเฉพาะกิจ Lima จะมุ่งเน้นการประยุกต์ใช้งานปัญญาประดิษฐ์แบบรู้สร้างในภารกิจที่มีความเสี่ยงระดับต่ำ [13] ซึ่งแนวโน้มการประยุกต์ใช้งานประกอบไปด้วยการนำมาใช้เพื่อเพิ่มประสิทธิภาพงานด้านธุรการ การใช้งานด้านการติดต่อสื่อสาร การส่งกำลังบำรุง การบริการและพัฒนาทรัพยากรมนุษย์ การฝึก รวมถึงด้านการปฏิบัติการสงครามไซเบอร์ [14]

ในขณะเดียวกัน สาธารณรัฐประชาชนจีน

ได้มีความพยายามในการพัฒนาและประยุกต์ใช้ขีดความสามารถในด้านนี้อย่างต่อเนื่อง Josh Baughman นักวิเคราะห์ของสถาบัน China Aerospace Studies Institute ได้ศึกษา วิเคราะห์ และจัดแบ่งแนวโน้มการประยุกต์ใช้ ปัญญาประดิษฐ์แบบรู้สร้างทางการทหารของสาธารณรัฐประชาชนจีนไว้ใน 7 ประเด็น ได้แก่ การสื่อสารระหว่างมนุษย์กับเครื่องจักร การตัดสินใจ การปฏิบัติการสงครามข้อมูลสารสนเทศ การปฏิบัติการสงครามจิตวิทยา การส่งกำลังบำรุง การปฏิบัติการด้านอวกาศและการฝึกอบรม [15] โดยสาธารณรัฐประชาชนจีนมองถึงโอกาสจากการใช้เทคโนโลยีปัญญาประดิษฐ์ในการเป็นรากฐานของพลังอำนาจแห่งชาติทั้งทางด้านการทหารและด้านเศรษฐกิจ [16]

บทความนี้ได้วิเคราะห์แนวโน้มการประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้างทางการทหารในอนาคต ระหว่างปี ค.ศ. 2024 – 2030 โดยแบ่งกลุ่มการประยุกต์ใช้เทคโนโลยีออกเป็น 3 กลุ่มหลัก ได้แก่ การควบคุมบังคับบัญชา การสงครามและการรบ และการสนับสนุนการสงคราม ซึ่งพิจารณาจากปัจจัยแนวโน้มการประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์แบบรู้สร้างทางการทหารของทั้งสหรัฐอเมริกาและสาธารณรัฐประชาชนจีน ซึ่งเป็นประเทศผู้นำด้านการพัฒนาและประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์ทางการทหารของโลกในปัจจุบัน อีกทั้งได้เชื่อมโยงการประยุกต์ใช้ดังกล่าวเข้ากับระดับการสงครามหรือ Level of Warfare อันได้แก่ ระดับยุทธศาสตร์ ระดับยุทธการ และระดับยุทธวิธี ตามตารางที่ 1

ตารางการวิเคราะห์ข้างต้นแสดงให้เห็นถึงแนวโน้มการประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์แบบรู้สร้างทางการทหารในอนาคตและความเชื่อมโยงกับระดับการทำสงครามโดยที่แนวโน้มการประยุกต์ใช้งานส่วนใหญ่จะเป็นการใช้งานในระดับยุทธวิธี

ตารางที่ 1 แนวโน้มการประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้สร้างทางการทหารระหว่างปี ค.ศ. 2024 - 2030

หัวข้อการประยุกต์ใช้	แนวทางการประยุกต์ใช้ Generative AI	ระดับการสงคราม		
		ยุทธศาสตร์	ยุทธการ	ยุทธวิธี
1. การควบคุมบังคับบัญชา (Command and Control Applications)				
1.1 การสนับสนุนกระบวนการตัดสินใจในการควบคุมบังคับบัญชา (Decision Making)	การประมวลผลข้อมูลการปฏิบัติการทางทหารและสร้างคำตอบและเสนอแนะหนทางปฏิบัติที่เป็นไปได้	☑	☑	☑
1.2 การตรวจการณ์และการข่าวกรอง (Surveillance and Intelligence)	การเพิ่มขีดความสามารถในการตรวจการณ์ รวบรวม วิเคราะห์ และสังเคราะห์ข้อมูลที่ได้จากการตรวจการณ์เพื่อเป็นข้อมูลข่าวกรองสำหรับประกอบการพิจารณาของผู้บังคับบัญชา			☑
2. การสงครามและการรบ (Combat and Warfare Applications)				
2.1 การมีปฏิสัมพันธ์หรือการสื่อสารระหว่างมนุษย์กับเครื่องจักร (Human-Machine Interaction)	ปัญญาประดิษฐ์แบบรู้สร้างสามารถเข้าใจทั้งภาษามนุษย์และภาษาเครื่องจักร จึงสามารถช่วยวิเคราะห์ข้อมูลปริมาณมากให้สอดคล้องกับความต้องการของผู้ใช้งานภายในระยะเวลาที่น้อยลง ซึ่งจะเอื้อต่อการปฏิบัติการทางทหาร โดยเฉพาะในระดับยุทธวิธีที่ได้รับผลสัมฤทธิ์ที่มีความถูกต้องและแม่นยำมากยิ่งขึ้น			☑
2.2 การประยุกต์ใช้ในระบบอาวุธอัตโนมัติ (Autonomous Weapon Systems)	การเพิ่มขีดความสามารถและประสิทธิภาพของระบบอาวุธอัตโนมัติ เช่น การระบุเป้าหมายและชี้เป้า การสร้างเส้นทางเคลื่อนที่ของระบบอาวุธและแพลตฟอร์ม อย่างไรก็ตาม แนวโน้มด้านการสั่งการในการใช้อาวุธต่าง ๆ นั้น จะยังคงมีมนุษย์อยู่ในกระบวนการ			☑
2.3 การปฏิบัติการสงครามไซเบอร์ (Cyber Warfare)	การปฏิบัติการสงครามไซเบอร์ในเชิงรุกด้วยการใช้ปัญญาประดิษฐ์แบบรู้สร้างในการออกแบบ การเขียน และการดำเนินการของรหัสคอมพิวเตอร์ที่เป็นอันตราย (Malicious Code) การสร้างบอตและเว็บไซด์ เพื่อหลอกล่อผู้ใช้ให้แชร์ข้อมูล รวมถึงการเปิดตัวแคมเปญหลอกลวงทางสังคมและพิชชิงที่มุ่งเป้าไปที่เป้าหมาย โดยเฉพาะ การปฏิบัติการสงครามไซเบอร์ในเชิงรับ ด้วยการ ใช้ปัญญาประดิษฐ์แบบรู้สร้างในการวิเคราะห์จุดอ่อนหรือช่องโหว่ของระบบการรักษาความมั่นคงทางไซเบอร์	☑	☑	☑
2.4 การปฏิบัติการสงครามสารสนเทศและสงครามจิตวิทยา (Information and Psychological Warfare)	การใช้ปัญญาประดิษฐ์แบบรู้สร้างเพื่อสร้างข่าวปลอม รูปภาพปลอม และวิดีโอปลอม เพื่อจูงใจให้ผู้รับสารมีแนวความคิดหรือความเชื่อที่เอื้อประโยชน์ต่อผู้ใช้งาน	☑	☑	☑
3. การสนับสนุนการสงคราม (Warfare Support Applications)				
3.1 การส่งกำลังบำรุง (Logistics)	การใช้ปัญญาประดิษฐ์แบบรู้สร้างในการจัดสรรทรัพยากร การจัดการคลังสินค้า วางแผนเส้นทางจัดส่ง และตรวจสอบระบบเพื่อเพิ่มประสิทธิภาพการดำเนินการ นอกจากนี้ยังสามารถใช้ในการพยากรณ์ความต้องการทางวัสดุในอนาคตและประมาณการงบประมาณสำหรับการจัดหารทรัพยากร		☑	☑
3.2 การฝึกอบรม (Training)	การสร้างสถานการณ์จำลองยุทธสำหรับการฝึกอบรมให้มีความเสมือนจริงและรวดเร็วมากขึ้น โดยเฉพาะอย่างยิ่งสถานการณ์จำลองยุทธที่มีความซับซ้อน เช่น War Gaming		☑	☑

สำหรับระดับยุทธการจะเป็นการใช้ประโยชน์ในการตัดสินใจในการควบคุมบังคับบัญชา การทำสงครามบนโครงข่ายดิจิทัล การปฏิบัติการจิตวิทยาและการสนับสนุนการสงคราม ในขณะที่การใช้ประโยชน์ทางยุทธศาสตร์จะเป็นการใช้ในกระบวนการตัดสินใจและการปฏิบัติการที่มีผลต่อความเชื่อ ขวัญและกำลังใจของประชาชน ซึ่งเป็นองค์ประกอบที่สำคัญของการสงคราม อย่างไรก็ตาม ความเชื่อมโยงตามที่แสดงนั้น เป็นเพียงความเชื่อมโยงของการใช้งานเทคโนโลยีกลุ่มหลักซึ่งอาจมิได้สะท้อนถึงการใช้งานในบางกรณีในระดับของการทำสงครามดังกล่าว

การใช้งานเทคโนโลยีปัญญาประดิษฐ์แบบรัฐสร้างทางการทหาร ระหว่างปี ค.ศ. 2024 - 2030 จะยังคงมีมนุษย์อยู่ในกระบวนการตัดสินใจ เนื่องจากมนุษย์ส่วนใหญ่ยังไม่ไว้วางใจการคิดและการตัดสินใจของเครื่องจักร ประกอบกับยังมีประเด็นการรบกวนและหารือเกี่ยวกับเรื่องของความเสี่ยงในการใช้งานเทคโนโลยีปัญญาประดิษฐ์ รวมถึงจริยธรรมและกฎหมายที่เกี่ยวข้องกับการใช้งานระบบอาวุธอัตโนมัติที่ยังดำเนินอยู่และมีแนวโน้มที่จะดำเนินต่อไปเรื่อย ๆ เกินกว่าห้วงเวลาปี ค.ศ. 2030 ซึ่งเป็นขอบเขตการวิเคราะห์ของบทความนี้

5. แนวทางในการพัฒนาขีดความสามารถทางการทหารของประเทศไทยด้วยปัญญาประดิษฐ์แบบรัฐสร้าง

กระทรวงกลาโหมของประเทศไทยยังไม่มีการพัฒนาและประยุกต์ใช้งานปัญญาประดิษฐ์แบบรัฐสร้างอย่างเป็นรูปธรรม อย่างไรก็ตาม กระทรวงกลาโหมมีความมุ่งหมายที่จะประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์มาใช้สนับสนุนการปฏิบัติราชการโดยในแผนปฏิบัติการราชการระยะ 5 ปี (พ.ศ. 2566 – 2570)

กระทรวงกลาโหมได้กำหนดกลยุทธ์ภายใต้แผนปฏิบัติการราชการเรื่องการปฏิบัติการทางทหารเพื่อรักษาอธิปไตยและผลประโยชน์ที่จะพัฒนากระทรวงกลาโหมสู่ความทันสมัยด้วยการนำระบบเทคโนโลยีการสื่อสาร สารสนเทศ ดิจิทัล ระบบข้อมูลขนาดใหญ่และเทคโนโลยีปัญญาประดิษฐ์ รวมทั้งนวัตกรรมทันสมัยมาประยุกต์ใช้กับการบริหารราชการและการให้บริการประชาชน [17] ในขณะที่แผนปฏิบัติการ ระยะเวลา 5 ปี (พ.ศ. 2566 – 2570) กองบัญชาการกองทัพไทยได้มีการระบุถึงแนวทางการพัฒนา อาทิ การพัฒนาระบบฐานข้อมูลสารสนเทศอย่างรอบด้านเพื่อสนับสนุนการตัดสินใจการกำหนดกลยุทธ์และติดตามผลการดำเนินการทุกระดับการพัฒนาระบบรวบรวมและวิเคราะห์สารสนเทศของผู้มีส่วนได้ส่วนเสียสำคัญจากทุกส่วนราชการของกองบัญชาการกองทัพไทย และหน่วยงานภายนอกอย่างบูรณาการ การพัฒนาระบบ Social Analytics สำหรับวิเคราะห์ข้อมูลขนาดใหญ่ (Big Data) ที่เกี่ยวข้องกับผู้มีส่วนได้ส่วนเสีย เพื่อวิเคราะห์ คาดการณ์ ความต้องการ และ ความคาดหวังต่อกองบัญชาการกองทัพไทยในอนาคต การพัฒนาระบบฐานข้อมูลกำลังพลในการบริหารจัดการกำลังพล การสร้าง สภาพแวดล้อมทางดิจิทัลเพื่อสนับสนุนการทำงานให้มีความยืดหยุ่น การพัฒนาระบบบริหารโครงการด้วยเทคโนโลยีสารสนเทศให้มีขีดความสามารถในการติดตามความก้าวหน้า คาดการณ์ผลลัพธ์ในการดำเนินงานและการประเมินความคุ้มค่าของโครงการ เพื่อสนับสนุนการตกลงใจของผู้บังคับบัญชาและการพัฒนาระบบงานและฐานข้อมูลในการขนส่งและเคลื่อนย้าย [18] ซึ่งประเด็นการพัฒนาเหล่านี้สอดคล้องกับแนวโน้มการประยุกต์ใช้เทคโนโลยี

ปัญญาประดิษฐ์แบบรู้สร้างทางการทหารที่ได้ทำการวิเคราะห์ไว้แล้วข้างต้น

ในการที่จะพัฒนาขีดความสามารถทางการทหารของประเทศไทยด้วยปัญญาประดิษฐ์แบบรู้สร้างนั้น สามารถสังเคราะห์เป็นแนวทางการดำเนินการที่สำคัญ ได้แก่

5.1 การพัฒนาระบบและโครงสร้างพื้นฐานที่รองรับการใช้งานปัญญาประดิษฐ์แบบรู้สร้างทางการทหารบนระบบปิดที่มีมาตรการรักษาความปลอดภัยทางไซเบอร์ในระดับสูง เนื่องจากข้อมูลทางการทหารมีระดับชั้นความลับและมีผลกระทบต่อความมั่นคงของประเทศโดยตรง การรั่วไหลของข้อมูล หรือการถูกโจมตีทางไซเบอร์จึงเป็นสิ่งที่ต้องระวังป้องกันอย่างยิ่งยวด

5.2 การสร้างโมเดลภาษาขนาดใหญ่ที่สนับสนุนภาษาไทยหรืออัลกอริทึมที่ช่วยให้ปัญญาประดิษฐ์สามารถเรียนรู้และประมวลผลภาษาไทยได้ดียิ่งขึ้น เพื่อเอื้อต่อการใช้งานและความถูกต้องของข้อมูล เนื่องจากข้อมูลภายในกระทรวงกลาโหมส่วนใหญ่อยู่นั้นอยู่ในรูปแบบของภาษาไทย ทั้งนี้ ในปัจจุบันที่มุ่งพัฒนาปัญญาประดิษฐ์ของประเทศไทยจากหลายหน่วยงาน ทั้งภาครัฐและเอกชนได้ร่วมกันพัฒนาและเปิดตัว OpenThai GPT ให้มีการทดสอบทดลองใช้งาน โดย OpenThai GPT เป็นปัญญาประดิษฐ์แบบรู้สร้างที่สนับสนุนภาษาไทยและเปิดโอกาสให้นักพัฒนาโปรแกรมสามารถปรับปรุงแก้ไขชุดคำสั่งได้ [19] กระทรวงกลาโหมจึงอาจใช้ประโยชน์จากปัญญาประดิษฐ์แบบรู้สร้างดังกล่าวเพื่อประโยชน์ในด้านความมั่นคง

5.3 การกำหนดนโยบาย ระเบียบ ข้อบังคับ และแนวทางการปฏิบัติเกี่ยวกับการใช้งานเทคโนโลยีปัญญาประดิษฐ์ภายในกระทรวงกลาโหมให้มีความชัดเจน โดยต้องมีการกำหนดกรอบ ขอบเขต และแนวความคิดที่เกี่ยวข้องกับการวิเคราะห์ให้ปัญญาประดิษฐ์ดำเนินการ กอปรกับต้องมีการตรวจสอบและประเมินความถูกต้องของข้อมูลที่เกิดขึ้นจากการประมวลผลของ AI ด้วย

5.4 การริเริ่มใช้ประโยชน์จากขีดความสามารถในการวิเคราะห์ประมวลผลข้อมูลจากฐานข้อมูลขนาดใหญ่และการให้คำแนะนำจากปัญญาประดิษฐ์แบบรู้สร้างตามแนวโน้มการประยุกต์ใช้เทคโนโลยีที่ได้ทำการวิเคราะห์ไว้แล้วข้างต้น โดยอาจมุ่งเน้นการวิจัยและพัฒนาการใช้งานระดับยุทธวิธีสำหรับภารกิจที่มีความเสี่ยงต่ำก่อน เช่น การใช้งานในเชิงธุรการในการเพิ่มประสิทธิภาพการปฏิบัติงานประจำวัน การใช้งานในการวางแผน การส่งกำลังบำรุง และการบริหารจัดการครุภัณฑ์ในสถานะปกติที่ไม่ใช่สงครามและการใช้ประโยชน์ในการสร้างสถานการณ์สำหรับการจำลองยุทธเพื่อการฝึกอบรม

แนวทางการดำเนินการตามที่กล่าวข้างต้นเป็นจุดเริ่มต้นของการประยุกต์ใช้งานปัญญาประดิษฐ์แบบรู้สร้างให้เกิดประโยชน์แก่ กระทรวงกลาโหมของประเทศไทย โดยอาจบูรณาการขีดความสามารถของปัญญาประดิษฐ์แบบรู้สร้างเข้ากับโครงการพัฒนาขีดความสามารถของกระทรวงกลาโหมและกองทัพไทยที่ได้วางแผนการปฏิบัติไว้แล้ว เพื่อยกระดับขีดความสามารถในการปฏิบัติงานและขีดความสามารถทางการทหารของประเทศไทยภายในระยะเวลาอันสั้น อีกทั้งเป็นการเตรียมความพร้อมและ

พัฒนาให้กองทัพไทยเป็นกองทัพที่มีความทันสมัย มีขีดความสามารถในการรองรับภัยคุกคามที่มี พลวัตการเปลี่ยนแปลงอย่างต่อเนื่องและรวดเร็ว

6. บทสรุป

เทคโนโลยีปัญญาประดิษฐ์แบบรู้สร้าง (Generative AI) ถือได้ว่าเป็นเทคโนโลยีสร้างความ พลิกผัน (Disruptive Technology) ซึ่งได้รับความ สนใจอย่างกว้างขวางทั้งในภาคพลเรือนและภาค การทหารโดยการพัฒนาและประยุกต์ใช้งานปัญญา ประดิษฐ์แบบรู้สร้างทางการทหารได้ประโยชน์ โดยตรงจากพัฒนาการความเจริญก้าวหน้าของ เทคโนโลยีในภาคพลเรือน ขีดความสามารถของ ปัญญาประดิษฐ์แบบรู้สร้างในการประมวลผลจาก ฐานข้อมูลขนาดใหญ่ด้วยความรวดเร็วช่วยสร้าง บริบทการสื่อสารโต้ตอบที่ตอบสนองต่อความ ต้องการใช้งานข้อมูลอย่างมีประสิทธิภาพ รวมทั้ง สามารถช่วยลดระยะเวลาในการประมวลผลข้อมูล และนำเสนอหนทางปฏิบัติเพื่อการตัดสินใจของ ผู้บังคับบัญชา ซึ่งเอื้อต่อการสร้างความได้เปรียบ ในการดำเนินกลยุทธ์ทางการทหาร การประยุกต์ ใช้งานปัญญาประดิษฐ์แบบรู้สร้างทางการทหารใน ช่วงแรกมุ่งเน้นไปที่การนำมาใช้เป็นเครื่องมือเพื่อ ช่วยสนับสนุนการตัดสินใจของผู้บังคับบัญชาในการ ควบคุมบังคับบัญชาการปฏิบัติการทางทหารแต่ ด้วยขีดความสามารถที่เพิ่มมากยิ่งขึ้นส่งผลให้การ ประยุกต์ใช้งานปัญญาประดิษฐ์แบบรู้สร้างทางการ ทหารมีแนวโน้มที่จะขยายขอบเขตออกไปทั้งในรูป แบบของการเป็นเครื่องมือในการปฏิบัติการข้อมูล ข่าวสารและการเป็นตัวแทนการสนทนาเสมือนจริง (Conversation Agents) ที่สามารถช่วยในการวิเคราะห์ ประมวลผลข้อมูลและสนทนาให้คำตอบ คำแนะนำ

รวมถึงข้อมูลที่เกี่ยวข้องแก่การปฏิบัติการทางการ ทหารในทุกระดับของการทำสงคราม ตั้งแต่ระดับ ยุทธวิธี ยุทธการ และยุทธศาสตร์ ด้วยระยะเวลา ที่รวดเร็วยิ่งขึ้น อย่างไรก็ตาม การมีส่วนร่วมของ มนุษย์ในกระบวนการตัดสินใจที่เกี่ยวข้องกับการ ประยุกต์ใช้งานปัญญาประดิษฐ์แบบรู้สร้างทางการ ทหารยังคงเป็นปัจจัยที่มีความสำคัญยิ่งยวดและ ขาดไม่ได้ เพราะมนุษย์เป็นผู้รับผิดชอบและเป็นผู้ ได้รับผลกระทบโดยตรงจากการใช้งานเทคโนโลยีนี้

ในส่วนของกระทรวงกลาโหมของ ประเทศไทยสามารถพัฒนาขีดความสามารถทาง ทหารด้วยการประยุกต์ใช้ปัญญาประดิษฐ์แบบรู้ สร้างให้เกิดประโยชน์ตามแนวโน้มการประยุกต์ ใช้เทคโนโลยีปัญญาประดิษฐ์แบบรู้สร้างทางการ ทหารของโลก โดยอาจบูรณาการขีดความสามารถ ของปัญญาประดิษฐ์แบบรู้สร้างเข้ากับโครงการ พัฒนาขีดความสามารถของกระทรวงกลาโหม และกองทัพไทยที่ได้วางแผนการปฏิบัติไว้แล้ว เพื่ ยกกระดับขีดความสามารถในการปฏิบัติงานและ ขีดความสามารถทางการทหารของประเทศไทย ต่อไปในอนาคต

7. เอกสารอ้างอิง

- [1] K. Martineau. "What is generative AI?." RESEARCH.IBM.com. <https://research.ibm.com/blog/what-is-generative-AI> (accessed Dec. 12, 2023).
- [2] NVIDIA, "Generative AI." NVIDIA.com. <https://www.nvidia.com/en-us/glossary/data-science/generative-ai> (accessed Dec. 12, 2023).
- [3] H. Gimpel et al., *Unlocking the Power*

of Generative AI Models and Systems such as GPT-4 and ChatGPT for Higher Education: A Guide for Students and Lecturers. Stuttgart, Germany: Univ. Hohenheim, 2023.

- [4] S. Lock. “What is AI Chatbot Phenomenon ChatGPT and Could It Replace Humans?.” THEGUARDIAN.com. <https://www.theguardian.com/technology/2022/dec/05/what-is-ai-chatbot-phenomenon-chatgpt-and-could-it-replace-humans> (accessed Dec. 20, 2023).
- [5] D. E. Wilkins and R. V. Desimone, *Applying an AI Planner to Military Operations Planning.* San Mateo, CA, USA: Morgan-Kaufmann Publishing, 1993.
- [6] K. L. Myers. “Advisable Planning Systems.” CDN.AAAI.org. <https://cdn.aaai.org/ARPI/1996/ARPI96-028.pdf> (accessed Dec. 13, 2023).
- [7] Scribble Data. “Large Language Models 101: History, Evolution and Future.” SCRIBBLEDATA.io. <https://www.scribbledata.io/large-language-models-history-evolutions-and-future> (accessed Dec. 15, 2023).
- [8] K. Manson. “The US Military Is Taking Generative AI Out for a Spin.” BLOOMBERG.com. <https://www.bloomberg.com/news/newsletters/2023-07-05/the-us-military-is-taking-generative-ai-out-for-a-spin> (accessed Dec. 15, 2023).
- [9] U.S. Department of Defense. “DOD Announces Establishment of Generative AI Task Force.” DEFENSE.gov. <https://www.defense.gov/News/Releases/Release/rcticle/3489803/dod-announces-establishment-of-generative-ai-task-force> (accessed Dec. 21, 2023).
- [10] H. - M. Chuang and D. - W. Cheng, “Conversational AI over Military Scenarios Using Intent Detection and Response Generation.” *Appl. Sci.*, vol. 12, no. 5, p. 2494, 2022, doi: 10.3390/app12052494.
- [11] W. Marcellino, N. Beauchamp-Mustafaga, A. Kerrigan, L. N. Chao, and J. Smith, *The Rise of Generative AI and the Coming Era of Social Media Manipulation 3.0: Next-Generation Chinese Astroturfing and Coping with Ubiquitous AI.* Santa Monica, CA, USA: RAND Corporation, 2023.
- [12] J. Harper. “Pentagon Requesting More Than \$3B for AI, JADC2.” DEFENSESCOOP.com. <https://defensescoop.com/2023/03/13/pentagon-requesting-more-than-3b-for-ai-jadc2> (accessed Dec. 21, 2023).
- [13] B. Vincent. “Inside Task Force Lima’s Exploration of 180-plus Generative AI Use Cases for DOD.” DEFENSESCOOP.com. <https://defensescoop.com/2023/11/06/inside-task-force-limas-exploration-of-180-plus-generative-ai-use-cases-for-dod> (accessed Jan. 4, 2024).
- [14] C. Malin. “Why the Military Needs Generative AI.” ARMADAINTERNATIONAL.com. <https://www.armadainternational.com>

- com/2023/10/why-the-military-needs-generative-ai (accessed Jan. 4, 2024).
- [15] J. Baughman. “China’s ChatGPT War.” AIRUNIVERSITY.AF.edu. <https://www.airuniversity.af.edu/Portals/10/CASI/documents/Research/Cyber/2023-08-21-China's-ChatGPT-War.pdf> (accessed Jan. 4, 2024).
- [16] G. C. Allen. “China’s Pursuit of Defense Technologies: Implications for U.S. and Multilateral Export Control and Investment Screening Regimes.” CSIS.org. <https://www.csis.org/analysis/chinas-pursuit-defense-technologies-implications-us-and-multilateral-export-control-and> (accessed Dec. 23, 2023).
- [17] สำนักนโยบายและแผนกลาโหม, “แผนปฏิบัติการราชการ ระยะ 5 ปี (พ.ศ. 2566 – 2570) กระทรวงกลาโหม,” สำนักงานปลัดกระทรวงกลาโหม, กระทรวงกลาโหม, กรุงเทพฯ, ไทย, 2565.
- [18] กรมยุทธการทหาร, “แผนปฏิบัติการราชการ ระยะ 5 ปี (พ.ศ. 2566 – 2570) กองบัญชาการกองทัพไทย,” กองบัญชาการกองทัพไทย, กระทรวงกลาโหม, กรุงเทพฯ, ไทย, 2565.
- [19] น. หัสธีธรรม. “ความท้าทาย ความเป็นไปได้ และโอกาสของ Open Thai GPT แซตบอทสัญชาติไทย.” THESTORYTHAILAND.com. <https://www.thestorythailand.com/13/05/2023/99502> (accessed Dec. 21, 2023).

Comparison between Equilibrium Optimization and Systune on Aircraft Blank Angle Control

Yodsadej Kanokmedhakul ^{1*} and Nantiwat Pholdee ²

Received 31 October 2023, Revised 4 January 2024, Accepted 11 January 2024

Abstract

This paper is a direct comparison of equilibrium optimization (EO) one of the classes of meta-heuristic (MH) known for nonlinear optimization capability and Systune designed specifically for control problems for aircraft blank angle control. The control structure consisted of aileron rudder interconnection, Dutch roll damping, and proportional and integral (PI) control gain. These are set as design variables with multiple objectives and constraints including performance and robustness. The model parameter is allowed to vary up to 10% of the nominal value. The worst-case gain result was then used to evaluate the performance of the controller obtained by each approach. Overall, the EO result is superior in terms of Dutch roll damping and robustness while other aspects especially in time domain requirement is only slightly better than the result acquired from Systune.

Keywords : Meta-heuristic (MH), Aileron rudder interconnect, Multi-objective tuning of fixed-structure controllers, Aircraft lateral control

¹ Department of Mechanical Engineering, Faculty of Engineering, Mahidol University.

² Sustainable Infrastructure Research and Development Center, Department of Mechanical Engineering, Faculty of Engineering

* Corresponding author, E-mail: yodsadej.kan@mahidol.ac.th

การเปรียบเทียบประสิทธิภาพระหว่าง Equilibrium Optimization กับโปรแกรม Systune ในการออกแบบระบบควบคุมมูมเอียงของเครื่องบิน

ยศเดช กนกเมธากุล^{1*} และ ณัฐธิดา พลดี²

วันที่รับ 31 ตุลาคม 2566 วันที่แก้ไข 4 มกราคม 2567 วันที่ตอบรับ 11 มกราคม 2567

บทคัดย่อ

บทความวิจัยนี้เป็นการเปรียบเทียบประสิทธิภาพระหว่าง Equilibrium Optimization (EO) ซึ่งจัดอยู่ในกลุ่มของเมต้าฮิวริสติก (Meta-heuristic) กับโปรแกรม Systune สำหรับการออกแบบระบบควบคุมมูมเอียงของเครื่องบิน เมต้าฮิวริสติก (Meta-heuristic) มีความสามารถในการแก้ปัญหาแบบไม่เป็นเชิงเส้นได้ ส่วน Systune ถูกออกแบบมาเพื่อแก้ไขปัญหาด้านการควบคุมโดยเฉพาะ โดยรูปแบบของระบบควบคุมมีการใช้ปีกเล็กแก้อียงผสมกับหางเสือเลี้ยว ตัวหน่วง Dutch roll และคอนโทรลเลอร์แบบพีไอ (PI) ซึ่งองค์ประกอบเหล่านี้ก่อให้เกิดตัวแปรอิสระเป็นจำนวน 4 ตัว โดยอยู่ภายใต้เป้าหมายและขอบเขตหลายประการ ทั้งในแง่ของประสิทธิภาพและความคงทนของระบบควบคุม แบบจำลองของเครื่องบินถูกนำเสนอในรูปแบบ State-space ซึ่งมีการเพิ่มความไม่แน่นอนเข้าไปในระบบโดยค่าตัวแปรในระบบสามารถแปรผันได้มากที่สุดถึง 10% จากค่าเริ่มต้น ค่าตัวแปรระบบที่ก่อให้เกิดสภาวะเลวร้ายที่สุดจะถูกใช้เป็นตัวชี้วัดสำหรับระบบควบคุมที่หาได้จากทั้งสองวิธี ในภาพรวมแล้วระบบควบคุมที่หาได้จาก EO ได้ผลลัพธ์ที่ดีกว่าระบบควบคุมของ Systune เมื่อมองในแง่ของการป้องกันมูมเอียงและความคงทนของเครื่องบิน แต่ในแง่ประสิทธิภาพนั้นมีความใกล้เคียงกัน

คำสำคัญ : เมต้าฮิวริสติก, การเชื่อมโยงปีกเล็กแก้อียงกับหางเสือเลี้ยว, การออกแบบระบบควบคุมหลายวัตถุประสงค์, การควบคุมมูมเอียงของเครื่องบิน

¹ ภาควิชาวิศวกรรมเครื่องกล, คณะวิศวกรรมศาสตร์, มหาวิทยาลัยมหิดล

² ศูนย์วิจัยและพัฒนาโครงสร้างมูลฐานอย่างยั่งยืน, สาขาวิชาวิศวกรรมเครื่องกล, คณะวิศวกรรมศาสตร์, มหาวิทยาลัยขอนแก่น

* ผู้แต่ง, อีเมล: yodsadej.kan@mahidol.ac.th

1. Introduction

Unmanned aerial vehicles (UAV) are very powerful tools due to their versatility and can operate without human interference. The use can be seen in many applications such as agriculture, military, surveillance, etc. UAVs can roughly be categorized as multi-rotor and fixed wing which in this work will focus on fixed wing. The control framework is the heart of UAV operation. It allows the mission to operate without human intervention through a feedback controller. The controller consisted of 2 loops, The outer loop calculates the waypoint to the aircraft behavior required to reach the point which often be the angle and speed of the aircraft [1]. The inner loop will follow the outer loop command as a reference and then execute the actuator to achieve the position commanded by the outer loop.

The fixed-wing aircraft has 3 main control surfaces, aileron, rudder, and elevator for control roll, pitch, and yaw angle of the aircraft respectively. Its dynamic can be separated between longitudinal and lateral dynamics for convenience as it has negligible effect on each other. Thus, it can be tuned separately. Tuning longitudinal dynamic is simpler than lateral dynamic, there is no coupling movement axis compared to lateral. In simple terms longitudinal captured altitude and speed, lateral captured directional

component. So, longitudinal have to take elevator deflection with constant throttle setting to control compared to aileron and rudder in lateral motion. When an aircraft needs to change direction, it can be done by aileron not the rudder, using a rudder for directional control is not effective due to higher drag, the excessive roll movement, and furthermore rudder has less control surface area compared to the aileron. So, the rudder is used only for adjusting adverse yaw angles. In the tuning procedure, lateral motion is much more difficult compared to longitudinal due to the coupling motion of bank and sideslip angle. The aircraft lateral control system is designed to track bank angles causing unintentional side slip angles throughout the process. To address this issue, aileron rudder interconnection (ARI) can be used [2], [3]. The ARI approach was invented to adjust the rudder countering excessive side slip angle while aileron is active.

Typically, gain ARI is tuned first in order to minimize Dutch roll damping followed by feedback control design. The classical tuning method obtained gain ARI by using root locus. However, the gain ARI can post the effect on bank angle tracking later in the feedback control design. Therefore, it would be more optimal to take the gain ARI together with feedback gain as one optimization procedure.

Luckily, there are tools that can be used in the problem such as Systune [4]–[6]. Systune is a very popular algorithm in automatic tuning. It can utilize both time and frequency domain requirements with capable of handling multiple objectives and constraints for an optimal set of design variables [7]. It has an advantage over some well-known methods like linear matrix inequality (LMI), LMI can optimize only in linear problems and is not capable of large dimension systems.

Meta-heuristic (MH) is known for nonlinear optimization algorithms which are categorized as single-objective and multi-objective. As the name suggests, single objective has only one objective. The weighted sum technique is used in order to clump those objectives into one [8]. Multiple objectives on the other hand provide a set of optimal objectives through the pareto front [9]. It is also used in control framework [10] and the aviation industry such as PID tuning [11], [12], aircraft path planning [13], aircraft engine modeling [14], aircraft system identification [15], [16], robust control tuning [17], [18], etc.. Thus, MH is suitable for lateral tuning control design problems.

Few studies are comparing MH and systune performance and usage which are rarer in lateral tuning applications. Thus, this paper aims to compare the performance in tuning bank angle tracking with ARI gain

with multiple objectives and constraints. Equilibrium optimization (EO) [19] was chosen to compete with Systune for its balanced exploration and exploitation. The set of design variables, objectives, and constraints are set as close as possible for both tuning approaches. More detail can be seen in the problem setup section. The result was then compared and discussed.

2. Problem formulation

Aircraft lateral dynamic can be represented in a state-space formulation which is linearized and decoupled from the longitudinal dynamic. The dynamic of DC-8 aircraft is used to demonstrate the controller tuning technique. The flight takes place at 30,000 ft. with a velocity of 824.2 ft./sec. The state space representation can be seen in Eq. 1, these dimensional derivatives are added uncertainty components using ureal function in MATLAB which can vary up to 10% of its nominal value.

$$\begin{bmatrix} \dot{\beta} \\ \dot{\Phi} \\ \dot{p} \\ \dot{r} \end{bmatrix} = \begin{bmatrix} Y_{\beta} - \frac{T^*}{mV^*} & \frac{g}{V^*} & Y_p & Y_r - 1 \\ 0 & 0 & 1 & 0 \\ L_{\beta} & 0 & L_p & L_r \\ N_{\beta} & 0 & N_p & N_r \end{bmatrix} \begin{bmatrix} \beta \\ \Phi \\ p \\ r \end{bmatrix} + \begin{bmatrix} Y_{\delta a} & Y_{\delta r} \\ 0 & 0 \\ L_{\delta a} & L_{\delta r} \\ N_{\delta a} & N_{\delta r} \end{bmatrix} \begin{bmatrix} \delta a \\ \delta r \end{bmatrix} \quad (1)$$

The uncertainty of each parameter shown in Eq. 1 is as follows:

$$\begin{aligned} Y_{b1} &= \text{ureal}('Y_{b1}', -0.0868, 'Percentage', 10) \\ T1 &= \text{ureal}('T1', T1, 'Percentage', 10) \\ mV1 &= \text{ureal}('mV1', mV1, 'Percentage', 10) \end{aligned}$$

$L_b1=ureal('L_b1',L_b1,'Percentage',10)$
 $L_p1=ureal('L_p1',L_p1,'Percentage',10)$
 $L_r1=ureal('L_r1',L_r1,'Percentage',10)$
 $N_b1=ureal('N_b1',N_b1,'Percentage',10)$
 $N_p1=ureal('N_p1',N_p1,'Percentage',10)$
 $N_r1=ureal('N_r1',N_r1,'Percentage',10)$
 $Y_dr1=ureal('Y_dr1',Y_dr1,'Percentage',10)$
 $L_da1=ureal('L_da1',L_da1,'Percentage',10)$
 $N_da1=ureal('N_da1',N_da1,'Percentage',10)$
 $N_dr1=ureal('N_dr1',N_dr1,'Percentage',10)$




Figure 1 Interconnection of aircraft controller

$$K_r = x(1) \tag{2}$$

$$K_{ari} = x(2) \tag{3}$$

$$K_\varphi = \frac{x(3)s + x(4)}{s} \tag{4}$$

Table 1 Lower and upper bound of design variables

Design variables	Lower	Upper
x(1)	-5	5
x(2)	-10	10
x(3)	0	10
x(4)	0	10

The aircraft controller is as in Figure 1 which has 4 tunable characteristics comprised of yaw or sideslip damper (K_r), aileron rudder interconnection (K_{ari}), proportional gain, and integral gain for the control blank angle of the aircraft. The set of design variables are expressed in Eq. 2-4 with lower and upper bound as in Table 1. Ideally, the sideslip angle is required to be zero as it interferes with blank angle control but in lateral dynamic, the sideslip is coupled with blank angle control. Thus, the sideslip angle can be reduced using ARI and sideslip damper. The aircraft normally tunes the sideslip damper and aileron rudder interconnection first then proceeds to the blank angle feedback controller. It may not be the optimal way of tuning because this gain can affect the controller's performance. The controller is designed to track the blank angle command using aileron as the main actuator, rudder on the other hand used as a secondary actuator assisting the movement of the aircraft.

The objective of the controller is not only tracking the blank angle reference signal but also guaranteeing robust and stability of the aircraft for this flight condition. The first objective is set to search for maximum robust and stability so it is divided by 1, how large the gain will cause the system to be unstable. Second is control effort, for this objective seeking the controller to be as efficient as possible. Third is settling time, which is the classical component considering how fast the controller handles the reference signal.

Fourth is the root mean square (RMS) of the side slip, minimizing the side slip angle that occurs while the aileron is active. Fifth and sixth are the norm of the transfer function and sensitivity function, the norm is used for noised and disturbance rejection. In summary, there are a total of 6 objectives to be considered which are combined into one objective using the weighted sum technique with weighting each objective of 2, 2, 1, 10, 1, and 1 respectively.

$$f1 = \frac{1}{\max(\text{lower}, \text{upper limit})} \quad (5)$$

robust stability(robstab command)

$$f2 = \text{RMS of control effort} \quad (6)$$

$$f3 = \text{settling time} \quad (7)$$

$$f4 = \text{RMS of beta (side slip when used aileron)} \quad (8)$$

$$f5 = \text{norm inf of } \frac{GK}{1 + GK} \quad (9)$$

$$f6 = \text{norm inf of } \frac{1}{1 + GK} \quad (10)$$

$$f = 2 * f1 + 2 * f2 + f3 + 10 * f4 + f5 + f6 \quad (11)$$

The problem is also subjected to constraints consisting of overshoot, aileron deflection, rate limit, roll rate limit, rise time, and Dutch roll damping as in Eq 12-17. These constraints are handled with a penalty function in Eq. 18.

$$g1 = \text{Overshoot} < 5\% \quad (12)$$

$$g2 = \text{Aileron deflection limit} < 20 \text{ deg} \quad (13)$$

$$g3 = \text{roll rate limit} < 30 \quad (14)$$

$$g4 = \text{Aileron deflection rate limit} < 100 \text{ deg/sec} \quad (15)$$

$$g5 = \text{Rise Time} < 4 \text{ sec} \quad (16)$$

$$g6 = \text{Dutch roll damping} > 0.2 \quad (17)$$

Penalty function

$$fp = f + 10000 * \max(g > 0) \quad (18)$$

2.1 MH set up

Equilibrium optimizer is chosen for this problem, the detail of the algorithm is shown in the original algorithm paper [19]. The population sizes are set as 100, the max iteration is set to be 50, in total of 5,000 function evaluation. The equilibrium pools are chosen as 4 pools for balancing between convergent rates and searching radius. The best result out of 5 individual runs is captured for comparison.

2.2 Systune setup

The Systune requirement is not straightforward to directly compare with MH thus, the problem is set to have as good as result with satisfied the requirement of MH. The step tracking requirement dictated the performance and constraint violation of the controller so, this value needs to be adjusted several times to get the best result for comparison. Other requirement are straight forward requirements like control effort limit, overshoot, roll rate limit, etc.. The setup is adjusted as follows.


```

overshoot=0;
tou=0.75;
Req0 = TuningGoal.StepTracking('phic','phi',
    tou,overshoot);
Req1 = TuningGoal.Gain('phic','phi',1);
Req2 = TuningGoal.Overshoot('phic','phi',5);
Req3 = TuningGoal.Gain('phic','beta',0.15);
Req4 = TuningGoal.Gain('phic','p',1.5);
Req5 = TuningGoal.Gain('phic','da',1);
Req6 = TuningGoal.Gain('phic','da_rate',20);

```

3. Result and discussion

Starting from robustness and stability, MH reaches 5.9737 over 4.7574 of Systune meaning MH is more robust. Furthermore, MH has less control effort, settling time, and side slip error when excites the system while the transfer function and sensitivity function norm are nearly identical for both approaches. Step response in Figure 2 shows the comparison of 2 different tuning techniques blank angle, both perform very well to the command. The major difference is in sideslip damping, MH approach surpasses Systune for handling unintentional sideslip as it has larger Dutch roll damping compared to Systune. Dutch roll damping effect can also be seen in Figure 3. The system is exited with duplet aileron deflection again MH is clearly rejected sideslip far better than Systune. The difference between both tuning techniques is around 1 degree. The result comparison of Systune and MH tuning approach appeared in Table 2

indicating that the MH approach performs better in every aspect. Both methods managed to pass all 6 constraints as seen in Table 3. and have an overshoot of around 2%, and aileron constraints and roll rate limits are very small compared to the setup limit. The worst-case gain from the uncertainty content can then be identified using the wcgain command which finds the worst uncertainty combination that maximizes the output gain of the system from the aileron command to roll. The uncertainty then substitutes back to the nominal system leading to a worst-case gain system which alters the performance of the design system significantly. There is only a robust stability objective that uses the uncertainty content in calculation the others are computed from the nominal value. So, the objective f1 is not present in the worst-case gain result. The worst-case gain system objectives and constraints are presented in Tables 2 and 3. Both approaches have exceeded the overshoot limit by around twice the value of 5%. Settling time is increased for MH but interestingly decreased for Systune. The others are slightly different than the nominal value. The optimal gain can be seen in Table 4, Gain ARI and integral gain obtained from MH is really small compared to Systune.

Table 2 Objective comparison of Systune VS MH

Objective	Nominal		Worst-case gain	
	Systune	MH	Systune	MH
f1 = Robust stability (norm)	4.7574	5.9737	-	-
f2 = Control effort (RMS)	0.5779	0.5205	0.5566	0.5008
f3 = Settling Time (second)	6.5758	2.7255	4.7169	4.7478
f4 = beta error (RMS)	0.0765	0.0575	0.0671	0.0509
f5 = inf norm Transfer function (norm)	1.0005	1	1.0005	1.0000
f6 = inf norm Sensitivity function (norm)	1.3968	1.381	1.3968	1.3810

Table 3 Constraints comparison of Systune VS MH

Constraints	Nominal		Worst-case gain		Limit
	Systune	MH	Systune	MH	
g1 = Overshoot	2.1716%	1.9992%	11.4646	10.8484	<5%
g2 = aileron deflection limit	2.99	2.5914	2.9853	2.5876	<20 deg
g3 = roll rate limit	2.9265	2.658	3.3572	3.041	<20 deg/ sec
g4 = aileron deflection rate limit	5.3623	4.6443	5.3604	4.6427	<100 deg/ sec
g5 = rise time	1.6644	1.8081	1.3572	1.496	<4 sec
g6 = Dutch roll damping	0.3568	0.4122	0.3568	0.4122	>0.2

Table 4 Design variables comparison

Design variables	Systune	MH
x(1)	-0.72293	-0.85563
x(2)	0.05846	1.6772e-05
x(3)	0.61153	0.52925
x(4)	0.0028251	0.00012331

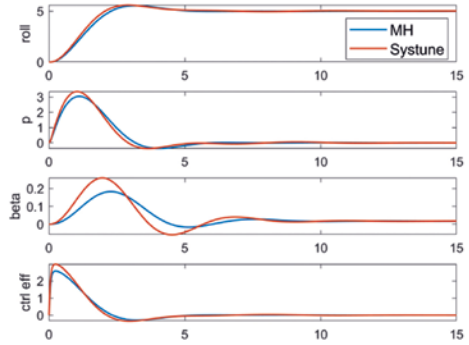


Figure 2 Step responses of plant with controller




Figure 3 Doublet responses from aileron to beta

The bode plot of an open loop plant with a controller structure with 100 sampling uncertainty is captured in figure 4. The classical gain and phase margin of the system are decent on both Systune and MH approaches which indicates the robustness of both systems. The minimum gain and phase margin on both approaches are 25 db and 70 degrees.

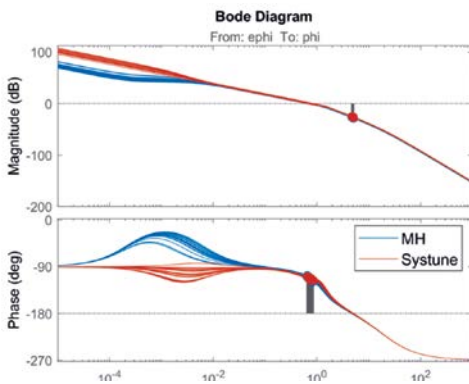


Figure 4 Bode plot of open loop roll angle

4. Conclusion

This numerical experiment compares these Systune and MH performances on tuning control structures are not simple. The problem cannot be identical due to the different processes of optimization. So, Systune is tuned as similarly as possible to meet the same requirements as MH. Tuning Systune requires the knowledge of the toolbox to adequately tune the controller to be as designed. MH, on the other hand is straightforward and more flexible. It can list the set of objectives and constraints and fulfill all the constraints while Systune usually treats constraints as soft constraints. In terms of consistency, Systune is superior to MH as it requires a couple of repetitions to guarantee the best performance. Overall MH technique is superior to Systune in robustness, error tracking, and side slip minimization. The problem can be set as accurate to the real-world system which is much more complex than this simple example.

5. Reference

- [1] J. D. Barton, "Fundamentals of Small Unmanned Aircraft Flight," *Johns Hopkins APL Tech. Dig.*, vol. 31, no. 2, pp. 132–149, 2012.
- [2] M. Jayalakshmi, V. V. Patel, and G. K. Singh, "Relook at Aileron to Rudder Interconnect," *Def. Sci. J.*, vol. 71, no. 2, pp. 153-161, 2021, doi: 10.14429/dsj.71.15347.
- [3] W. P. Gilbert, L. T. Nguyen, and R. W. Vangunst, "Simulator Study of the Effectiveness of an Automatic Control System Designed to Improve the High Angle of Attack Characteristics of a Fighter Airplane," NASA, Washington, D.C., USA, Rep. NASA TN D-8176, 1976.
- [4] A. M. Simões, P. Apkarian, and D. Noll, "Nonsmooth Multi-objective Synthesis with Applications," *Control Eng. Pract.*, vol. 17, no. 11, pp. 1338-1348, 2009, doi: 10.1016/j.conengprac.2009.06.010.
- [5] P. Apkarian and D. Noll, "Nonsmooth Optimization for Multiband Frequency Domain Control Design," *Automatica*, vol. 43, no. 4, pp. 724-731, 2007, doi: 10.1016/j.automatica.2006.08.031.
- [6] P. Apkarian, D. Noll, and A. M. Simoes, "Time-Domain Control Design: A Nonsmooth Approach," *IEEE Trans. Control Syst. Technol.*, vol. 17, no. 6, pp. 1439-1445, 2009, doi: 10.1109/TCST.2008.2008722.
- [7] P. Apkarian, "Tuning Controllers Against Multiple Design Requirements," in *2013 Proc. Amer. Control Conf.*, Washington, DC, USA, 2013, pp. 3888-3893, doi: 10.1109/ACC.2013.6580433.

- [8] J. L. Corner and J. T. Buchanan, "Experimental Consideration of Preference in Decision Making under Certainty," *J. Multi-Criteria Decis. Anal.*, vol. 4, no. 2, pp. 107-121, 1995, doi: 10.1002/mcda.4020040204.
- [9] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, "A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II," *IEEE Trans. Evol. Comput.*, vol. 6, no. 2, pp. 182 - 197, 2002, doi: 10.1109/4235.996017.
- [10] A. Rodríguez-Molina, E. Mezura-Montes, M. G. Villarreal-Cervantes, and M. Aldape-Pérez, "Multi-objective Meta-heuristic Optimization in Intelligent Control: A Survey on the Controller Tuning Problem," *Appl. Soft Comput.*, vol. 93, p. 106342, 2020, doi: 10.1016/j.asoc.2020.106342.
- [11] S. Pareek, M. Kishnani, and R. Gupta, "Optimal Tuning of PID Controller using Meta Heuristic Algorithms," in *2014 Int. Conf. Adv. Eng. Technol. Res. (ICAETR-2014)*, Unnao, India, 2014, pp. 1-5, doi: 10.1109/ICAE-TR.2014.7012816.
- [12] A. Sheta, M. Braik, D. R. Maddi, A. Mahdy, S. Aljahdali, and H. Turabieh, "Optimization of PID Controller to Stabilize Quadcopter Movements Using Meta-heuristic Search Algorithms," *Appl. Sci.*, vol. 11, no. 14, p. 6492, 2021, doi: 10.3390/app11146492.
- [13] Y. Wu, "A Survey on Population-based Meta-heuristic Algorithms for Motion Planning of Aircraft," *Swarm Evol. Comput.*, vol. 62, p. 100844, 2021, doi: 10.1016/j.swevo.2021.100844.
- [14] S. Jafari and T. Nikolaidis, "Meta-heuristic Global Optimization Algorithms for Aircraft Engines Modelling and Controller Design; A Review, Research Challenges, and Exploring the Future," *Prog. Aerosp. Sci.*, vol. 104, pp. 40-53, 2019, doi: 10.1016/j.paerosci.2018.11.003.
- [15] A. Nonut *et al.*, "A Small Fixed-wing UAV System Identification Using Metaheuristics," *Cogent Eng.*, vol. 9, no. 1, 2022, doi: 10.1080/23311916.2022.2114196.
- [16] Y. Kanokmedhakul, N. Panagant, S. Bureerat, N. Pholdee, and A. R. Yildiz, "Aircraft Control Parameter Estimation Using Self-Adaptive Teaching-Learning-Based Optimization with an Acceptance Probability," *Comput. Intell. Neurosci.*, vol. 2021, pp. 1 - 12, 2021, doi: 10.1155/2021/4740995.
- [17] P. Feyel, G. Duc, and G. Sandou, "Optimal Tuning of H^∞ Fixed-structure Robust Controller Against Multiple High-level Requirements Using Evolutionary Computation," *Int. J. Robust Nonlinear Control*, vol. 29, no. 4, pp. 949 – 972, 2018, doi: 10.1002/rnc.4412.
- [18] V. Mihaly, M. Su, D. Morar, and M. Stanese, " μ -Synthesis for Fractional-Order Robust Controllers," *Mathematics*, vol. 9, no. 8, p. 911, 2021, doi: 10.3390/math9080911.
- [19] A. Faramarzi, M. Heidarinejad, B. Stephens, and S. Mirjalili, "Equilibrium Optimizer: A Novel Optimization Algorithm," *Knowledge-Based Syst.*, vol. 191, p. 105190, 2020, doi: 10.1016/j.knosys.2019.105190.

การวิเคราะห์แบ่งส่วนพื้นที่ภาพถ่ายทางอากาศด้วย Generative Adversarial Networks

กิตติกร วิริยะศาสตร์^{1, 2*} วรากร เลื่องลือวุฒิ¹ วิชัย แผ้วเกษม¹
พันธุเทพ แก้วมงคล¹ สัญญา มิตรเอม² และ พันศักดิ์ เทียนวิบูลย์³

วันที่รับ 28 พฤศจิกายน 2566 วันที่แก้ไข 7 มีนาคม 2567 วันตอบรับ 3 เมษายน 2567

บทคัดย่อ

บทความนี้กล่าวถึงการแบ่งส่วนพื้นที่แบบ Semantic Segmentation จากภาพถ่ายทางอากาศ ซึ่งเป็นภาพที่ได้จากอากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) มาวิเคราะห์การจำแนกพื้นที่ด้วยวิธี Generative Adversarial Networks (GANs) โดยการจำแนกพื้นที่ด้วยระบบสีแบบ RGB มาทำการจำแนกพื้นที่ทั้งหมด 10 พื้นที่ เช่น สนามบิน สนามกีฬา ป่าไม้ พื้นที่ทางการเกษตร แม่น้ำ บ่อน้ำ รถ ถนน สิ่งก่อสร้าง และพื้นที่อื่น ๆ ซึ่งในการทดลองนี้ได้ใช้โมเดลใน UNET ได้แก่ MobileNetV2, ResNet50, ResNet50V2, DenseNet201 และ VGG16 มาเป็น Generator บน Generative Adversarial Networks ไว้ในการจำแนกพื้นที่ของภาพถ่ายทางอากาศ จากการทดลองพบว่า โมเดลแต่ละโมเดลมีความแม่นยำโดยประมาณ 80% และมีความเร็วในการทำงานต่อเฟรมอยู่ที่ 2 วินาที

คำสำคัญ : อากาศยานไร้คนขับ, การจำแนกพื้นที่, เครือข่ายคู่ต่อสู้ช่วยสร้าง, RGB

¹ ส่วนงานวิศวกรรมการสื่อสารข้อมูลทางอิเล็กทรอนิกส์และเครือข่ายคอมพิวเตอร์, สถาบันเทคโนโลยีป้องกันประเทศ

² ภาควิชาวิศวกรรมไฟฟ้าและคอมพิวเตอร์, คณะวิศวกรรมศาสตร์, มหาวิทยาลัยธรรมศาสตร์

³ ภาควิชาวิศวกรรมไฟฟ้า, คณะวิศวกรรมศาสตร์, มหาวิทยาลัยเกษตรศาสตร์

* ผู้แต่ง, อีเมล: kittakorn.v@dti.or.th

Analysis of Segmentated Images by Generative Adversarial Networks

Kittakorn Viriyasatr ^{1, 2*} Warakorn luangluewut ¹ Wichai Pawgasame ¹
Pantape Kaewmongkol ¹ Sanya Mitaim ² and Phunsak Thiennviboon ³

Received 28 November 2023, Revised 7 March 2024, Accepted 3 April 2024

Abstract

This article presents the study on semantic segmentation for aerial image classification using Generative Adversarial Networks (GANs). The aerial images were acquired by an Unmanned Aerial Vehicle (UAV). The proposed method utilized the RGB color space to classify into the total of 10 land-cover classes, including airport, stadium, forest, agricultural area, river, pond, car, road, building, and others. The experiments were conducted using MobileNetV2, ResNet50, ResNet50V2, DenseNet201, and VGG16 as the generator in the GAN framework. The experimental results demonstrate that each model achieved the accuracy of approximately 80% and the processing speed of 2 seconds per frame.

Keywords : Unmanned aerial vehicles, Segmentation, Generative adversarial networks, RGB

¹ Data Communication Division, Defence Technology Institute

² Department of Electrical and Computer Engineering, Faculty of Engineering, Thammasat University

³ Department of Electrical Engineering, Faculty of Engineering, Kasetsart University

* Corresponding author, E-mail: kittakorn.v@dti.or.th

1. บทนำ

บทความนี้กล่าวถึงการแบ่งส่วนพื้นที่แบบ Semantic Segmentation จากภาพถ่ายทางอากาศ โดยการนำภาพที่ได้จากอากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) มาวิเคราะห์การจำแนกพื้นที่ (Segmentation) [1] - [3] ซึ่งที่ผ่านมาได้มีงานที่คล้ายกันนี้ [4] - [5] จำแนกพื้นที่ด้วยวิธีโครงข่ายประสาทเทียมแบบคอนโวลูชัน แต่ในงานวิจัยนี้จะทำการทดลองโดยใช้ Generative Adversarial Networks (GANs) [6] - [8] ในการจำแนกพื้นที่ทั้งหมด 10 คลาส ได้แก่ สนามบิน สนามกีฬา ป่าไม้ พื้นที่ทางการเกษตร แม่น้ำ บ่อน้ำ รถ ถนน สิ่งก่อสร้าง และพื้นที่อื่น ๆ เพื่อหาความแม่นยำและความเร็วในการทำงานเพื่อให้สอดคล้องกับความเร็วของอากาศยานไร้คนขับ ซึ่งคล้ายกับการทดลอง [9] ที่ทำการตรวจจับวัตถุในภาพถ่ายทางอากาศด้วยเทคนิคโครงข่ายประสาทเทียม

สำหรับการวิเคราะห์จำแนกพื้นที่นั้น จำเป็นต้องมีผู้เชี่ยวชาญด้านภูมิศาสตร์เป็นผู้วาดแบบร่างเพื่อติกรอบจำแนกพื้นที่ ซึ่งวิธีการนี้ใช้ระยะเวลาสามารถแก้ไขให้เร็วขึ้นได้โดยผู้เชี่ยวชาญหลายท่าน ซึ่งอาจช่วยลดระยะเวลาได้ แต่ก็มีค่าใช้จ่ายที่สูงขึ้น นอกจากนี้ยังมีปัญหาด้านพื้นที่ ถ้าพื้นที่ที่เป็นจุดสนใจนั้นยากต่อการเข้าถึง เช่น พื้นที่ป่าที่เป็นเนินเขารกทึบ พื้นที่ที่ต้องใช้เจ้าหน้าที่ในการสำรวจจำนวนหลายท่าน พื้นที่อันตรายที่อยู่ในเขตการทดสอบของจรวด ซึ่งอาจทำให้เกิดอันตรายต่อตัวเจ้าหน้าที่ได้ เป็นต้น

งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อมุ่งแก้ไขปัญหาในการจำแนกพื้นที่ดังกล่าวด้วย Generative Adversarial Networks (GANs) โดยใช้ภาพถ่ายทางอากาศเพื่อให้สามารถนำไปประยุกต์ใช้งานได้ต่อไป อย่างไรก็ตาม ข้อจำกัดในงานวิจัยมีปัจจัยดังนี้

1) ด้านข้อมูลภาพถ่ายทางอากาศ คลาดเคลื่อนหรือข้อมูลไม่สมดุลที่ส่งผลให้มีข้อจำกัดในการใช้งานโมเดล ตัวอย่างเช่น เมื่อทำการติกรอบพื้นที่จำนวนภาพที่มีพื้นที่ของป่ามากกว่าแม่น้ำมาก ๆ สมมุติว่า มี 1,000 ภาพ ที่มีป่า แต่มีภาพที่มีแม่น้ำเพียง 100 ภาพ อาจทำให้ประสิทธิภาพของโมเดลเอนเอียงไปในพื้นที่ของป่ามากกว่าแม่น้ำ เป็นต้น

2) ข้อจำกัดด้านการตีความพื้นที่ ขนาดของภาพถ่ายทางอากาศเป็นสิ่งสำคัญ ภาพขนาดเล็กอาจตีความพื้นที่ได้ยากกว่าภาพที่มีขนาดใหญ่ ในการจำแนกว่าเป็นคลาสใด เนื่องจากมุมมองและความแตกต่างของภาพในการถ่าย ทำให้พื้นที่ย่อยแยกแตกต่างกัน ส่วนภาพที่ขนาดใหญ่เกินไป ในที่นี้หมายถึงมีขนาดพิกเซลจำนวนมาก เป็นอุปสรรคในการทดสอบโมเดล เนื่องจากประสิทธิภาพในการประมวลผลของคอมพิวเตอร์อาจไม่เพียงพอและระยะเวลาการประมวลผลข้อมูล อาจจำเป็นต้องแบ่งภาพหรือลดขนาดพิกเซลตามความเหมาะสมก่อนทำการทดสอบโมเดล


ดังนั้น งานวิจัยนี้จึงเน้นการแก้ไขปัญหาและข้อจำกัดดังกล่าวข้างต้น เพื่อเพิ่มประสิทธิภาพในการใช้งานโมเดลในการวิเคราะห์ภาพถ่ายทางอากาศได้มากยิ่งขึ้น และสะดวกต่อการจำแนกพื้นที่ โดยยึดหลักการเพิ่มความแม่นยำของการจำแนกพื้นที่และความน่าเชื่อถือในการจำแนกพื้นที่ในภาพถ่ายทางอากาศ รวมถึงความเร็วในการประมวลผลข้อมูลภาพถ่ายทางอากาศ

2. ทฤษฎีที่เกี่ยวข้อง

2.1 Image Segmentation

Image Segmentation คือ การจำแนกภาพพิกเซลแต่ละจุดคือพื้นที่ของคลาสใดที่เราสนใจจะได้ออกมาเป็นพื้นที่ที่ต่าง ๆ ซึ่งแต่ละสีหมายความว่า

ลักษณะที่ต่างกัน เช่น บ้าน ถนน ต้นไม้ ฯลฯ ตัวอย่างการทำงานของ Image Segmentation ดังรูปที่ 1



รูปที่ 1 ตัวอย่างการทำงานของ Image Segmentation [10]

วิธีการ Image Segmentation เหมาะกับการใช้งานเชิงพื้นที่ โดยเฉพาะกับภาพถ่ายทางอากาศ เนื่องจากต้องการตีความภาพเชิงพื้นที่ให้ละเอียดสูงสุดในระดับพิกเซล ซึ่งเพียงพอและเหมาะสมสำหรับการใช้งานดังกล่าว

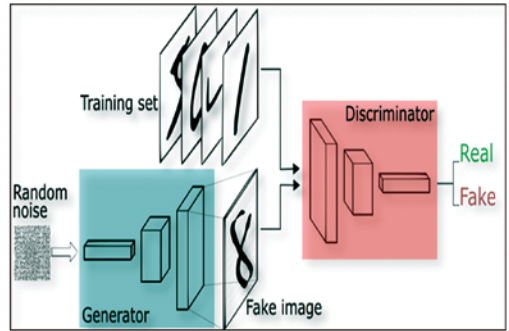
2.2 Generative Adversarial Networks (GANs)

[11] เหมาะสำหรับงาน Segmentation เนื่องจาก GANs สามารถสร้างภาพจำลองขึ้นมาเพื่อใช้ในการจำแนกพื้นที่ ซึ่งหน้าที่ของ GANs คือ การสร้างข้อมูล ซึ่งการที่ GANs จะสร้างข้อมูลออกมาได้นั้นประกอบไปด้วย 2 ส่วน คือ

2.2.1 Generator ทำหน้าที่สร้างข้อมูลให้ตรงกับข้อมูลรูปภาพจริงที่เราต้องการให้มากที่สุด

2.2.2 Discriminator จะเป็นตัว Classifier ทำการเรียนรู้ข้อมูลที่ได้รับมาว่าอะไรเป็นสิ่งที่มาจากข้อมูลจริง และอะไรมาจาก Generator ที่สร้างขึ้นมาเลียนแบบข้อมูลภาพจริงให้เหมือนภาพจริงมากที่สุดดังรูปที่ 2

Generator เป็นองค์ประกอบหลักของ GANs ที่ใช้ในการสร้างภาพ โดยเริ่มจากการใช้ Noise เป็นอินพุต (Input) สำหรับ Generator และ



รูปที่ 2 จำลองการทำงานของ GANs [12]

เอาต์พุต (Output) เป็นภาพจำลอง (Fake Image) ที่พยายามให้ใกล้เคียงกับภาพที่ต้องการมากที่สุด โดยสมการของ Generator แสดงดังสมการที่ (1)


$$\min_G V(G) = \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

Discriminator [12] เป็นตัว Classifier ที่เรียนรู้จากข้อมูลที่ได้รับมา เพื่อจำแนกว่าอะไรเป็นข้อมูลจริงและอะไรมาจาก Generator จากนั้นจะส่ง Feedback กลับไปให้ Generator เพื่อให้เรียนรู้และปรับปรุงคุณภาพของภาพจำลอง เพื่อให้ใกล้เคียงกับรูปภาพต้นฉบับมากที่สุด คล้ายกับการแข่งขันระหว่างสองฝ่าย โดยสมการของ Discriminator แสดงในสมการที่ (2)

$$\max_{\theta_d} [\mathbb{E}_{x \sim p_{data}} \log D_{\theta_d}(x) + \mathbb{E}_{z \sim p(z)} \log(1 - D_{\theta_d}(G_{\theta_g}(z)))] \quad (2)$$

Generator และ Discriminator [12] ใช้โมเดล CNN (Convolutional Neural Network) โดยงานวิจัยนี้ใช้ U-Net ซึ่งเป็นโครงข่ายประสาทเทียมแบบคอนโวลูชันชนิดหนึ่ง โดย U-Net ประกอบด้วยโมเดลหลายรูปแบบ การวิเคราะห์ว่าโมเดลใดเหมาะสมที่สุดสำหรับอากาศยานไร้คนขับ

พิจารณาจากความแม่นยำ (Accuracy) และความเร็วในการทำงานของโมเดล ผลการทดลองแสดงในรูปที่ 3 ซึ่งภาพที่ GANs อ่านได้จะแสดงผลตามสีที่กำหนดไว้ใน Label Map ว่าพื้นที่ใดควรมีสื่ออะไร




รูปที่ 3 ตัวอย่างผลการอ่านภาพด้วย GANs

ตามที่กำหนดไว้แต่แรก

2.3 U-Net [13] U-Net เป็นโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) ที่เรียนรู้แบบ Supervised Learning หรือการเรียนรู้แบบมีผู้สอน ยกตัวอย่างเช่น การทำ Classification แยกรูปภาพว่ามีรถอยู่ในภาพหรือไม่มี ในกรณีนี้รูปภาพจะถูกส่งผ่าน Layers ต่าง ๆ ของ Classification Network ที่ทำหน้าที่ เช่น Convolution, Max Pooling, Dropout จนกระทั่งได้ผลลัพธ์ออกมาดังรูปที่ 4 โดย งานวิจัยนี้เลือกใช้ U-Net ด้วยเหตุผลที่ว่าโครงสร้างนี้เป็นโครงสร้างที่มีการสกัดคุณลักษณะของภาพได้อย่างมีประสิทธิภาพจากงานวิจัยที่ผ่านมา

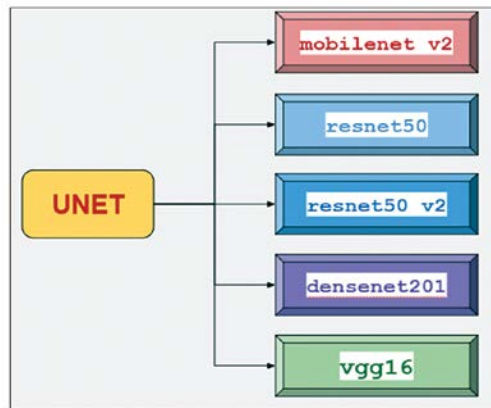
ส่วนแรก ของ U-Net (ส่วนที่ 1 ในรูปที่ 4)



รูปที่ 4 แสดงโครงสร้างของ U-Net

ประกอบด้วย Convolution Block (3x3 conv) และการลดทอน down-sampling ด้วย Max Pooling (2x2 max pool) เพื่อดึงคุณลักษณะ (Features) ออกมาจากภาพ จะเห็นว่าการดึงคุณลักษณะนี้เกิดขึ้นหลายระดับตั้งแต่ High-resolution Features ไปจนถึง Low-resolution Features

ส่วนที่สอง ของ U-Net (ส่วนที่ 2 ในรูปที่ 4) ประกอบไปด้วยการทำ Up-sampling (up-conv 2x2) และการทำ Convolution คือ การนำ Features ที่ได้จากส่วนที่ 1 มาใช้ในการสร้างภาพที่ถูกตัดเรียบเรียบร้อยแล้ว (Segmented Output) ลูกศรสีเทาในรูปแสดงให้เห็นว่า ส่วนที่ 2 จะนำ Features ในแต่ละระดับจากส่วนที่หนึ่งมารวมในการคำนวณด้วย สุดท้ายขั้นตอนจะประกอบด้วย conv 1x1 เพื่อแปลงขนาดของ Feature จาก 62 (ซึ่งเท่ากับความลึกของ Layer ก่อนสุดท้าย) ให้เหลือเท่ากับจำนวนคลาส (Class) ที่ผู้วิจัยได้จำแนกเอาไว้ในรูปที่ 4 ซึ่งใน U-Net จะประกอบด้วยโมเดลหลายโมเดลดังรูปที่ 5 โมเดลที่มีทั้งหมดใน U-Net โดยที่โมเดล U-Net นั้นจะนำมาใช้เป็นส่วน Generator ของ Generative Adversarial Networks สำหรับการทำให้ Image Segmentation



รูปที่ 5 โมเดลที่มีทั้งหมดใน U-Net

3. วิธีการดำเนินการ

3.1 การรวบรวมข้อมูล โดยชนิดข้อมูลเป็นไฟล์ภาพขนาด 5472x3648 pixels (8.8 MB)

เนื่องจากภาพต้นฉบับมีขนาดใหญ่เกินกว่าที่ U-Net จะนำเข้าข้อมูลภาพได้ จำเป็นต้องแบ่งภาพเป็นส่วน ๆ แต่ละส่วนทำหน้าที่เป็นอินพุตเพียงชุดเดียวของ U-Net ดังนั้น จึงต้องแบ่งภาพใหญ่เป็นหลายส่วน เพื่อสร้างอินพุตหลายชุด กระบวนการนี้จะอธิบายในขั้นตอนการเตรียมภาพ (Image Pre-processing) โดยรูปที่ 6 แสดงตัวอย่างภาพต้นฉบับขนาด 5472x3648 pixels มีภาพทั้งหมด 1,300 ภาพ แต่สามารถใช้ได้ 1,286 ภาพ เนื่องจากบางภาพไม่ตรงกับคลาสที่กำหนดไว้



รูปที่ 6 ตัวอย่างไฟล์รูปต้นฉบับ

3.2 การ Label ข้อมูลหรือการติกรอบจุดสังเกต


ขั้นตอนการติดป้ายกำกับ (Label) เริ่มต้นด้วยการกำหนดคลาสทั้งหมด ซึ่งผู้วิจัยสนใจทั้งหมด 10 คลาส ได้แก่ ป่า พื้นที่ทางการเกษตร รถ ถนน บ่อน้ำ แม่น้ำ สนามบิน สนามกีฬา สิ่งก่อสร้าง และพื้นที่อื่น ๆ ตามที่ผู้วิจัยต้องการวิเคราะห์จากภาพ จากนั้นผู้วิจัยจะเลือกการติดป้ายกำกับหรือการระบุตำแหน่งที่สนใจ โดยใช้โปรแกรม CVAT (Computer Vision Annotation Tool) สำหรับการติดป้ายกำกับหรือการระบุตำแหน่งที่สนใจจะใช้รูปแบบ Polygons เพื่อกำหนดให้เป็นรูปทรงที่ไม่ได้เป็น

สี่เหลี่ยม ดังแสดงในรูปที่ 7 สำหรับการติดป้ายกำกับข้อมูลแบบ Polygons



รูปที่ 7 การติดป้ายกำกับข้อมูลแบบ Polygons

หลังจากนั้นไฟล์ที่ผู้วิจัยได้จะเป็นไฟล์ RGB ในแต่ละรูปที่ทำการติดป้ายกำกับเอาไว้ ซึ่งผลที่ได้แสดงดังรูปที่ 8













รูปที่ 8 ผลที่ได้จากการติดป้ายกำกับ

ผู้วิจัยจะทำการติดป้ายกำกับให้กับแต่ละคลาสที่สนใจ ด้วยการกำหนดค่าสี RGB เพื่อแยกความแตกต่างของลักษณะพื้นที่ โดยแต่ละพื้นที่ที่มีลักษณะแตกต่างกันจะได้รับสีที่แตกต่างกันตามรูปที่ 9

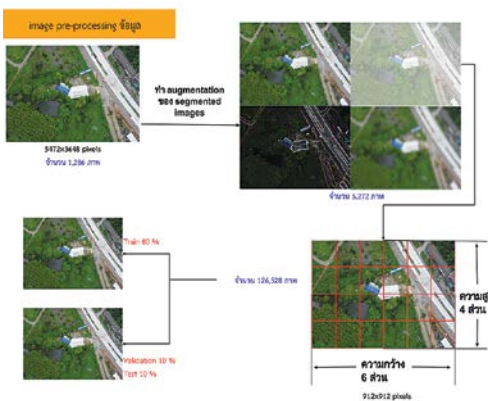
3.3 Image Pre-processing ข้อมูล

หลังจากตีความพื้นที่ที่สนใจแล้ว ภาพถ่ายทางอากาศทั้งหมด 1,286 ภาพ จะถูกขยายข้อมูล (Augmentation) ด้วยการทำภาพเบลอ การปรับความสว่างของภาพ และการเปลี่ยนสีของภาพถ่ายทางอากาศ เพื่อเพิ่มความหลากหลายของข้อมูล

รวมเป็นจำนวนทั้งหมด 5,272 ภาพ จากนั้นทำการแบ่งภาพเป็นพาร์ทิชัน (Partition) โดยแบ่งภาพตามมิติความกว้างออกเป็น 6 ส่วน และมิติความสูงออกเป็น 4 ส่วน รวมทั้งหมด 126,528 ภาพ ขั้นตอนนี้แสดงในรูปแบบที่ 10

class_image	RGB	
actions background	0,0,0	
air_field	128,0,0	
sports_field	0,128,0	
forest	128,128,0	
farm	0,0,128	
water_surface	128,0,128	
waterway	0,128,128	
car	128,128,128	
road	64,0,0	
building	192,0,0	

รูปที่ 9 จำแนกคลาสแต่ละคลาสด้วย RGB



รูปที่ 10 Image Pre-processing ข้อมูล

3.4 Train และ Test ข้อมูล

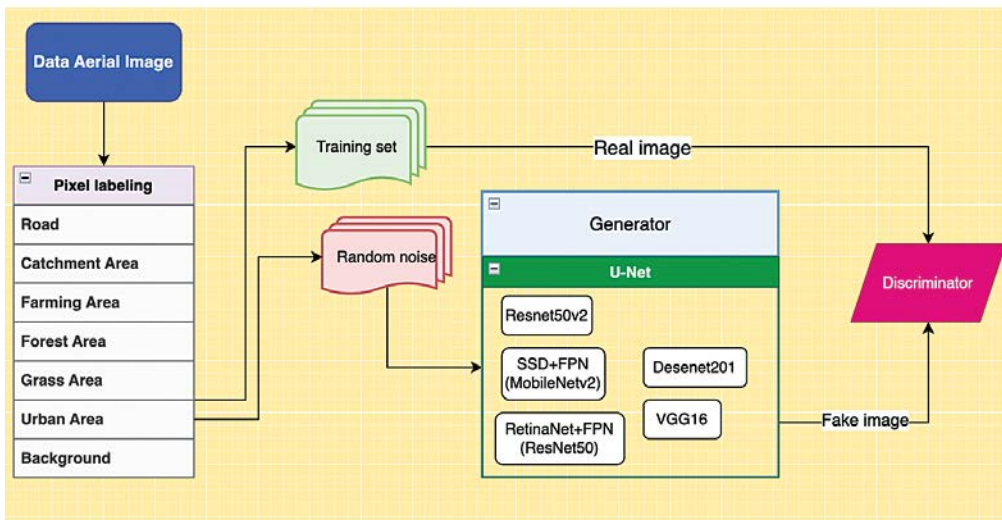
โมเดลที่เลือกสำหรับ Semantic Segmentation (U-Net) คือ MobileNetV2, ResNet50, ResNet50V2, DenseNet201 และ VGG16 ซึ่งเป็นส่วนของ U-Net สามารถแทนที่ด้วย Convolutional Neural Networks เพื่อสร้างคุณลักษณะของภาพ โมเดลเหล่านี้ถูกนำมาใช้เพื่อเปรียบเทียบประสิทธิภาพของ U-Net โดยพิจารณาจากความแม่นยำที่ได้จาก Generator ของ Generative Adversarial Networks ในการ Image Segmentation เนื่องจากภาพต้นฉบับมีขนาดใหญ่เกินกว่าที่ U-Net จะจัดการได้ ผู้วิจัยแก้ไขปัญหานี้โดยแบ่งภาพเป็นส่วน ๆ แต่แต่ละส่วนจะทำหน้าที่เป็นอินพุตเพียงชุดเดียวของ U-Net

ดังนั้น จึงต้องแบ่งภาพใหญ่ออกเป็นหลายส่วน เพื่อสร้างหลายอินพุต ผู้วิจัยพบว่า การแบ่งพาร์ทิชันที่มีประสิทธิภาพ คือ การแบ่งมิติความกว้างของภาพออกเป็น 6 ส่วน และมิติความสูงเป็น 4 ส่วน ตามแผนการฝึกรอบม (Training) ที่แสดงในรูปแบบที่ 11

ในขั้นตอนนี้ข้อมูลจะถูกแบ่งเป็น Train 80%, Validation 10% และ Test 10% สำหรับการฝึกโมเดลที่แตกต่างกัน โดยพารามิเตอร์สำหรับการฝึกจะเหมือนกันสำหรับโมเดลทั้งหมด และผู้วิจัยจะเปลี่ยนเฉพาะโมเดลพื้นฐานเท่านั้นในการทำ Image Segmentation จากจำนวนทั้งหมด 126,528 ภาพ

4. ผลการทดลอง

จากการทดลอง พบว่า โมเดลแต่ละโมเดลให้ผลความแม่นยำที่ไม่แตกต่างกันมากนัก ยกเว้น RestNet50 ซึ่งมีความแม่นยำน้อยที่สุดที่ 66.23% ส่วน MobileNetV2 มีความแม่นยำสูงสุดถึง 82.33% เนื่องจาก MobileNetV2 ออกแบบตามหลักการ Depthwise Separable Convolution เพื่อลดความ



รูปที่ 11 ผังการ Training ข้อมูล

ซับซ้อนของโมเดลและประหยัดทรัพยากร รวมถึงการใช้ Batch Normalization และ ReLU activation ระหว่าง Layers เพื่อเพิ่มความเร็วในการฝึกโมเดล นอกจากนี้ยังใช้โครงสร้างแบบ Bottleneck เพื่อลดการใช้ทรัพยากรและเพิ่มความลึกของโมเดล ทำให้ MobileNetV2 มีประสิทธิภาพสูงกว่าโมเดลอื่น ๆ ที่ทดสอบในชุดข้อมูลเดียวกัน

ตารางที่ 1 ผลการทดลองความแม่นยำของแต่ละโมเดล

Model	mAP (%)
MobileNetV2	82.33
ResNet50	66.23
ResNet50V2	79.32
DenseNet201	76.03
VGG16	80.34

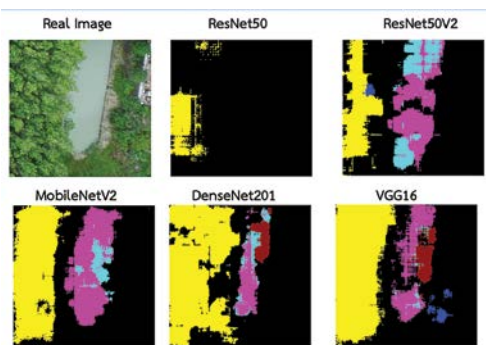
ในการทดสอบเวลาที่ใช้ทำ Image Segmentation ในแต่ละเฟรม ผู้วิจัยทำการทดลองทั้งหมด 4 ครั้ง และคำนวณค่าเฉลี่ยของเวลาที่ใช้ในการทำ Image

Segmentation ในแต่ละเฟรม ผลการทดลอง ดังแสดงในตารางที่ 2 พบว่า ResNet50V2 ใช้เวลาในการทำ Image Segmentation เร็วที่สุด

ตารางที่ 2 ผลการทดลองความเร็วของแต่ละโมเดล

Model	เวลาที่ใช้ตามจำนวนครั้ง (วินาที/sec)			
	ครั้งที่ 1	ครั้งที่ 2	ครั้งที่ 3	ครั้งที่ 4
MobileNetV2	2.46	1.50	1.50	1.81
ResNet50	4.21	4.00	3.79	4.00
ResNet50V2	1.63	1.61	1.59	1.59
DenseNet201	2.46	2.21	2.31	2.32
VGG16	2.41	2.31	2.16	2.29

จากการทำ Image Segmentation จะได้ผลการจำแนกด้วยค่าสี RGB ตามที่แสดงในรูปที่ 12 ซึ่งแสดงผลลัพธ์ของ Image Segmentation จากโมเดลต่าง ๆ ที่ได้ทดลอง



รูปที่ 12 ผลที่ได้จากโมเดลแต่ละโมเดล

5. สรุป

จากการทดลอง พบว่า โมเดลแต่ละโมเดล มีผลการจำแนกพื้นที่ที่ความแม่นยำใกล้เคียงกัน โดยจะมีความแม่นยำอยู่ที่ประมาณ 80% อย่างไรก็ตาม เวลาที่ใช้ในการทำงานมีความแตกต่างกันอย่างมีนัยสำคัญ โมเดลที่มีความแม่นยำสูงสุด คือ MobileNetV2 แต่กลับใช้เวลาทำงานเฉลี่ยช้ากว่า ResNetV2 ทั้งนี้ MobileNetV2 แสดงผลการทำงานที่เร็วที่สุดในบางเฟรม ทำให้เป็นโมเดลที่เหมาะสมที่สุดสำหรับการจำแนกพื้นที่จากภาพถ่ายทางอากาศ เมื่อเทียบกับโมเดลอื่น ๆ ที่ใช้ในการทดลอง

อย่างไรก็ตาม การทำ Segmentation ยังไม่เหมาะสำหรับการใช้ในอากาศยานไร้คนขับ เนื่องจากความเร็วของกล้องที่ใช้อ้างอิงในงานทดลองที่ผ่านมา [9] แสดงให้เห็นว่าจำเป็นต้องมีการจำแนกพื้นที่ที่เร็วขึ้นมาก เนื่องจากกล้องอากาศยานไร้คนขับมีความเร็วถึง 25 FPS ทำให้การทำ Image Segmentation เหมาะกับภาพถ่ายทางดาวเทียมที่เป็นภาพนิ่งมากกว่า

ผลการวิจัยนี้สามารถนำไปประยุกต์ใช้ในการจำแนกพื้นที่จากภาพถ่ายทางอากาศ หรือในงาน Remote Sensing หรือการทำ Change Detection

[14] - [15] ได้หลากหลาย ซึ่งข้อจำกัดที่พบในการวิจัย คือ การประมวลผลภาพที่ใช้ระยะเวลานานในการฝึก และทดสอบข้อมูล แนะนำให้ใช้ GPU (Graphics Processing Unit) ที่มีความเร็วสูงกว่า เพื่อลดระยะเวลาในการปฏิบัติงาน และควรเพิ่มจำนวนภาพต้นฉบับมากกว่า 1,300 ภาพ และใช้วิธีการ Augmentation ที่หลากหลายมากขึ้นในการวิจัยในอนาคต ผู้วิจัยหวังว่างานวิจัยนี้จะเป็นประโยชน์ต่อผู้ที่สนใจและนำไปพัฒนาต่อยอดในอนาคต

6. เอกสารอ้างอิง

- [1] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," in *MICCAI 2015 - 18th Int. Conf. Med. Imag. Comput. Comput. Assisted Intervention*, N. Navab, J. Hornegger, W. M. Wells, and A. F. Frangi, Eds., Munich, Germany, 2015, pp. 234 – 241.
- [2] Q. Chen, L. Wang, Y. Wu, G. Wu, Z. Guo, and S. L. Waslander, "Temporary Removal: Aerial Imagery for Roof Segmentation: A Large-scale Dataset Towards Automatic Mapping of Buildings," *ISPRS J. Photogramm. Remote Sens.*, vol. 147, pp. 42 - 55, 2019.
- [3] L. - C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, and A. L. Yuille, "DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 40, no. 4, pp. 834 - 848, 2018.

- [4] L. Mezeix and M. G. Casanova, "Dataset Creation Methodology for CNN Land Use/Cover Classification: Thailand's Rural Area Study Case," *Def. Technol. Acad. J.*, vol. 5, no. 11, pp. 74 - 95, Feb. 2023.
- [5] L. Mezeix, C. Arnal, S. Bassanetti, H. Corbin, and V. Mungkung, "Land Cover Analysis for Agricultural Area in Thailand Using CNN Method," *Def. Technol. Acad. J.*, vol. 5, no. 11, pp. 62 - 73, Feb. 2023.
- [6] I. Goodfellow *et al.*, "Generative Adversarial Networks," *Comm. ACM*, vol. 63, no. 11, pp. 139 - 144, 2020.
- [7] T. Karras, S. Laine, and T. Aila, "A Style-based Generator Architecture for Generative Adversarial Networks," in *2019 IEEE/CVF Conf. Comput. Vision Pattern Recognit. (CVPR)*, Long Beach, CA, USA, 2019, pp. 4396 - 4405, doi: 10.1109/CVPR.2019.00453.
- [8] T. Karras, S. Laine, M. Aittala, J. Hellsten, J. Lehtinen, and T. Aila, "Analyzing and Improving the Image Quality of StyleGAN," in *2020 IEEE/CVF Conf. Comput. Vision Pattern Recognit. (CVPR)*, Seattle, WA, USA, 2020, pp. 8107 - 8116, doi: 10.1109/CVPR42600.2020.00813.
- [9] W. Luangluewut, K. Viriyasatr, W. Pawgasame, P. Kaewmongkol, and S. Mitaim, "Detecting Objects in Aerial Photographs Using Neural Network Techniques," *Def. Technol. Acad. J.*, vol. 5, no. 12, pp. 4 - 11, Nov. 2023.
- [10] C. Sundelius, "Deep Fusion of Imaging Modalities for Semantic Segmentation of Satellite Imagery," M.S. thesis, Dept. Elect. Eng., Linköping Univ., Linköping, Sweden, 2017.
- [11] I. Goodfellow *et al.*, "Generative Adversarial Nets," 2014, arXiv:1406.2661v1.
- [12] R. Gandhi. "Generative Adversarial Networks-Explained." TOWARDSDATASCIENCE.com. <https://towardsdatascience.com/generative-adversarial-networks-explained-34472718707a> (accessed Nov. 2, 2023).
- [13] O. Ronneberger, P. Fischer, and T. Brox, "U - Net: Convolutional Networks for Biomedical Image Segmentation," 2015, arXiv:1505.04597.
- [14] R. Shao, C. Du, H. Chen, and J. Li, "SUNet: Change Detection for Heterogeneous Remote Sensing Images from Satellite and UAV Using a Dual-Channel Fully Convolution Network," *Remote Sens.*, vol. 13, no. 8, p. 3750, 2021, doi:10.3390/rs13183750.
- [15] X. Li, L. Yan, Y. Zhang, and N. Mo, "SDMNet: A Deep - Supervised Dual Discriminative Metric Network for Change Detection in High-Resolution Remote Sensing Images," *IEEE Geosc. Remote Sens. Lett.*, vol. 19, pp. 1 - 5, 2022, Art no. 5513905, doi: 10.1109/LGRS.2022.3216627.

การประยุกต์ใช้ Google's Teachable Machine ในการตรวจจับใบหน้าผู้ก่อการร้าย

ธรรมราช อาษาสุวรรณ^{1*} ชนัชฎาภรณ์ ใจแน่น² และ ภรณ์ระวี โสภณพิเชฐ¹

วันที่รับ 25 มีนาคม 2567 วันที่แก้ไข 24 เมษายน 2567 วันตอบรับ 22 พฤษภาคม 2567

บทคัดย่อ

งานวิจัยนี้มุ่งเน้นการศึกษาและประเมินความเป็นไปได้ของเครื่องมือปัญญาประดิษฐ์ (AI) คือ Google's Teachable Machine ในการตรวจจับใบหน้าผู้ก่อการร้ายในพื้นที่สามจังหวัดชายแดนภาคใต้ ผู้วิจัยมีขั้นตอนการศึกษาและวิจัย คือ ศึกษาค่าไฮเปอร์พารามิเตอร์ 3 แบบ ของ Google's Teachable Machine ได้แก่ 1) Epochs 2) Batch size และ 3) Learning rate ผู้วิจัยทำการเตรียมข้อมูลและทดสอบระบบ Google's Teachable Machine โดยการป้อนข้อมูลใบหน้าของผู้ก่อการร้ายและใบหน้าที่ไม่ใช่ผู้ก่อการร้าย เพื่อให้ AI ได้เรียนรู้และแยกแยะออกได้ หรือที่เรียกว่า Machine Learning โดยได้ทำการหาค่าไฮเปอร์พารามิเตอร์ที่เหมาะสม ศึกษา และทดลองซ้ำ ๆ เพื่อให้ได้ค่าไฮเปอร์พารามิเตอร์ ทั้ง Epochs, Batch size และ Learning rate ที่จะสามารถตรวจจับใบหน้าผู้ก่อการร้ายได้ชัดเจน และมีความคลาดเคลื่อนน้อยที่สุด ผลการศึกษาวิจัย พบว่า ค่าที่เหมาะสมของไฮเปอร์พารามิเตอร์ คือ Epochs = 100, Batch size = 256 และ Learning rate = 0.001 และจากการทดสอบ พบว่า Google's Teachable Machine มีประสิทธิภาพในการตรวจจับใบหน้าร้อยละ 96.50 การวิจัยนี้เห็นได้ว่า Google's Teachable Machine สามารถตรวจจับใบหน้าได้ และเป็นเครื่องมือที่ดี ช่วยประหยัดเวลาและลดขั้นตอนในการเขียนโปรแกรม ผู้ที่สนใจศึกษา สามารถนำ Google's Teachable Machine หรือ ปัญญาประดิษฐ์ (AI) มาใช้งานเพื่อให้ได้ผลลัพธ์ที่แม่นยำและรวดเร็วมากยิ่งขึ้น

คำสำคัญ : การเรียนรู้ของเครื่อง, ใบหน้า, การตรวจจับ, ไฮเปอร์พารามิเตอร์

¹ สาขาวิชาวิศวกรรมซ่อมบำรุงอากาศยาน, คณะวิศวกรรมศาสตร์และเทคโนโลยี, วิทยาลัยเทคโนโลยีสยาม

² สำนักงานเขตพื้นที่การศึกษาประถมศึกษาลพบุรี เขต 3, สำนักงานคณะกรรมการการศึกษาขั้นพื้นฐาน, กระทรวงศึกษาธิการ

* ผู้แต่ง, อีเมล: journal.thammarat@gmail.com

Applying Google's Teachable Machine to Detect the Faces of Criminals according to Arrest Warrants

Thammarat Arsasuwan ^{1*} Chanatdapon Jainaen ² and Pornrawee Sophonpichet ¹

Received 25 March 2024, Revised 24 April 2024, Accepted 22 May 2024

Abstract

This research focuses on studying and evaluating the feasibility of using artificial intelligence (AI), specifically Google's Teachable Machine, for detecting faces of criminals in the border areas of three southern provinces. The researchers conducted a study and research process involving the examination of three hyperparameters of Google's Teachable Machine: 1) Epochs, 2) Batch size, and 3) Learning rate. Data preparation and system testing were carried out by inputting facial data of terrorist and non-terrorist to allow the AI to learn and differentiate between the two, a process known as machine learning. The researchers sought appropriate hyperparameter values through study and iterative experimentation to achieve the clearest and least biased face detection possible. The research findings revealed that the suitable hyperparameter values were Epochs = 100, Batch size = 256, and Learning rate = 0.001. Subsequent testing demonstrated that Google's Teachable Machine achieved a face detection accuracy of 96.50%. This study illustrates that Google's Teachable Machine is effective in face detection and serves as a valuable tool, saving time and reducing programming complexities. Individuals interested in further exploration can utilize Google's Teachable Machine or AI to obtain more accurate and efficient results.

Keywords : Machine learning, Faces, Detecting, Hyperparamete

¹ Department Aircraft Maintenance Engineering, Engineering and Technology, Siam Technology College

² Chonburi Primary Educational Service Area Office 3, Office of the Basic Education Commission

* Corresponding author: journal.thammarat@gmail.com

1. บทนำ

ในปัจจุบันการก่อการร้ายเป็นภัยคุกคามร้ายแรงที่ส่งผลกระทบต่อชีวิตร่างกายและทรัพย์สิน ทั้งยังเป็นปัญหาที่มีรากฐานอันซับซ้อนเกี่ยวข้องและเชื่อมโยงกับมิติทางการเมือง ศาสนา และเชื้อชาติ แม้การก่อการร้ายจะเป็นภัยคุกคามที่เกิดขึ้นไม่บ่อยนัก แต่ในบางพื้นที่ยังคงเกิดเหตุการณ์ไม่สงบ รูปแบบและวิธีการก่อเหตุมีการพัฒนาควบคู่ไปกับความก้าวหน้าของเทคโนโลยี ซึ่งเอื้ออำนวยให้เกิดการก่อการร้ายได้โดยง่ายและสร้างความเสียหายได้อย่างเป็นวงกว้าง จากดัชนีการก่อการร้ายทั่วโลก ปี 2565 [1] ประเทศไทยได้คะแนนอยู่ในอันดับที่ 23 จาก 163 ประเทศทั่วโลก ซึ่งสูงกว่าปี 2564 ถึง 3 อันดับ นั้นหมายความว่า ประเทศไทยยังคงได้รับผลกระทบ จากการก่อการร้ายในระดับที่ค่อนข้างสูงจากเว็บไซต์ [2] ในด้านของสถานการณ์ความรุนแรงของพื้นที่สามจังหวัดชายแดนภาคใต้ที่มีความรุนแรงและมีการสร้างสถานการณ์ส่งผลให้มีผู้ได้รับบาดเจ็บทั้งผู้บริสุทธิ์และเจ้าหน้าที่ของรัฐ สร้างความเสียหายต่อชีวิตร่างกาย ทรัพย์สิน สังคม และเศรษฐกิจ จึงทำให้ต้องมีการดำเนินการปราบปรามผู้ก่อความไม่สงบที่ปะปนอยู่กับประชาชน โดยมีการนำเทคโนโลยีมาช่วยในการดำเนินการด้านนิติวิทยาศาสตร์ เพื่อยืนยันผู้กระทำความผิดและออกหมายจับหลังจากการก่อเหตุ โดยในด้านการป้องกันในพื้นที่มีการตั้งจุดตรวจ จุดสกัด ซึ่งมีความเสี่ยงต่อเจ้าหน้าที่ปฏิบัติการในการแยกแยะผู้ก่อความไม่สงบด้วยการสังเกตและตรวจสอบในระยะใกล้

ในขณะที่เดียวกันเทคโนโลยีที่มีความสำคัญอีกอย่างหนึ่ง คือ ปัญญาประดิษฐ์ (Artificial Intelligence: AI) เป็นโปรแกรมที่ถูกเขียนและพัฒนา

ให้มีความฉลาด มีความสามารถคิด วิเคราะห์วางแผน และตัดสินใจได้ จากการประมวลผลของฐานข้อมูลขนาดใหญ่ และยังสามารถดัดแปลงการประมวลผลประยุกต์ ให้เป็นไปตามสถานการณ์ต่าง ๆ [3] เป็นเทคโนโลยีที่มีการเรียนรู้ซ้ำ ๆ ผ่านการเก็บข้อมูลเดิม ๆ ได้อย่างมีประสิทธิภาพด้วยความแม่นยำ สม่ำเสมอ โดยที่สามารถเรียนรู้แบบก้าวหน้าได้ ไม่ว่าจะเป็นการศึกษาค้นคว้าจากข้อมูลเดิมหรือการรับข้อมูลใหม่ [4] จึงช่วยให้การทำงานมีประสิทธิภาพและสามารถวิเคราะห์ข้อมูลได้มากกว่าเดิม จึงได้ผลการวิเคราะห์ที่ลึกและแม่นยำมากที่สุด โดยที่จะสามารถนำข้อมูลนั้น ๆ มาประยุกต์ได้อย่างสูงสุด โดยเฉพาะการวิเคราะห์ข้อมูลขนาดใหญ่ (Big Data) ที่ปัญญาประดิษฐ์เข้ามาช่วยให้สามารถวิเคราะห์แบบจำลองได้แม่นยำมากยิ่งขึ้น โดยในปัจจุบันมีแอปพลิเคชันบนเว็บไซต์ที่สร้างโดย Google คือ Google's Teachable Machine ที่ช่วยให้ผู้ใช้งานสามารถเรียนรู้และทำ Machine Learning พื้นฐานโดยไม่ต้องเขียนโปรแกรมเพิ่มเติม สำหรับ Teachable Machine นั้น มี 3 ตัวเลือก ที่สามารถเลือกใช้สร้าง Machine Learning คือ โหมดการจำแนกภาพ การจำแนกเสียง และการจำแนกท่าทาง เป็นการใช้งานที่เข้าถึงได้ง่าย สะดวกในการใช้งาน และประหยัดเวลา

สำหรับงานวิจัยที่เกี่ยวข้องกับการประยุกต์ใช้ปัญญาประดิษฐ์ในการตรวจจับนั้น มีหลายกลุ่มวิจัย เช่น H. Jeong [5] ได้ทำการศึกษาเกี่ยวกับการวินิจฉัยลิ้นที่มีรอยฟัน โดยใช้ Teachable Machine ของ Google มีการใช้ภาพลิ้นทั้งหมด 1,250 ภาพ โดยนำภาพมาจากเว็บไซต์ Kaggle แบ่งข้อมูลเป็น 2 ชุด คือ ชุดข้อมูลสำหรับการฝึก AI 90% ใช้ภาพลิ้นที่มีรอยฟัน 634 ภาพ และภาพลิ้นที่ไม่มีรอยฟัน 491 ภาพ และชุดข้อมูลสำหรับการ

ทดสอบอีก 10% ใช้ภาพทดสอบ 125 ภาพ โดยนำไปผ่านกระบวนการตรวจจับของ Teachable Machine โดยการกำหนดค่าไฮเปอร์พารามิเตอร์ Epochs, Batch size และ Learning rate ที่มีความแม่นยำที่สุด ได้ผลลัพธ์เท่ากับ Epochs = 75, Batch size = 128 และ Learning rate = 0.0001 ตามลำดับ

S. Nupap and O. – U. Pramote [6] ได้ทำการออกแบบและพัฒนาแอปพลิเคชันรู้จำตัวอักษรบนอุปกรณ์เคลื่อนที่ เพื่อการฝึกเขียนพยางค์ภาษาไทยโดยมี 5 ขั้นตอน ในการดำเนินงาน ได้แก่ 1) การเก็บข้อมูลลายมือ 2) การสร้างโมเดลรู้จำรูปแบบ 3) การพัฒนาแอปพลิเคชัน 4) การนำไปใช้ และ 5) การประเมินผลความพึงพอใจ ซึ่งผู้วิจัยเก็บข้อมูลลายมือจากนักศึกษาวิทยาการคอมพิวเตอร์ จำนวน 100 คน โดยใช้กระดานวาดภาพอิเล็กทรอนิกส์ ได้ภาพจำนวน 4,400 ภาพ จาก 44 ตัวอักษร โดยใช้เป็นข้อมูลการสอน 3,080 ภาพ ข้อมูลการทดสอบ 1,320 ภาพ และนำภาพตัวอักษรมาผ่านกระบวนการประมวลผลภาพ เพื่อให้ได้ภาพที่เหมาะสมต่อการใช้งานสร้างโมเดลรู้จำรูปแบบด้วยเครื่องมือ Teachable Machine และพัฒนาแอปพลิเคชันด้วย Android Studio กับ TensorFlow Lite ผลการวิจัย พบว่า โมเดลรู้จำ มีความถูกต้อง (Accuracy) ร้อยละ 94 และแอปพลิเคชันมีผลการประเมินความพึงพอใจจากผู้ใช้งานในระดับมาก โดยมีค่าเฉลี่ยเท่ากับ 4.07

J. Sanuksan and O. Surinta [7] ได้ศึกษาโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึก (Deep Convolutional Neural Network: Deep CNN) เพื่อใช้จำแนกพรรณไม้ที่อยู่ในสิ่งแวดล้อมทางธรรมชาติ โดยข้อมูลพรรณไม้ที่นำมาใช้ในการทดสอบมีจำนวนทั้งสิ้น 3 ชุดข้อมูล คือ PNE, 102 Flower และ Folio ทั้งนี้ ชุดข้อมูล PNE และ 102 Flower

เป็นรูปภาพที่อยู่ในสิ่งแวดล้อมทางธรรมชาติที่มีพื้นหลังที่ซับซ้อน สำหรับข้อมูลชุด Folio เป็นรูปภาพใบไม้ที่ถ่ายในห้องทดลองโดยกำหนดให้พื้นหลังของภาพเป็นสีขาว จากผลการเปรียบเทียบระหว่างโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกโดยใช้โครงสร้าง GoogLeNet และ VGGNet พบว่า โครงสร้างแบบ GoogLeNet มีประสิทธิภาพสูงที่สุดในชุดข้อมูล PNE และ 102 Flower และยังใช้เวลาในการเรียนรู้ที่เร็วกว่าเมื่อเทียบกับโครงสร้างแบบ VGGNet โดยใช้จำนวนรอบในการเรียนรู้ 10,000 รอบ ทั้งนี้ โครงสร้างแบบ VGGNet มีอัตราความถูกต้องสูงที่สุดในชุดข้อมูล Folio ซึ่งเป็นรูปภาพที่ถ่ายในห้องทดลองที่มีพื้นหลังเป็นสีขาวและใช้จำนวนรอบในการเรียนรู้เพียง 1,000 รอบ

ดังนั้น ผู้วิจัยจึงมีความสนใจใช้เครื่องมือปัญญาประดิษฐ์บนเว็บไซต์ของ Teachable Machine เพื่อประเมินความเป็นไปได้ในการแก้ปัญหาดังกล่าว โดยการประยุกต์ใช้ปัญญาประดิษฐ์ในการตรวจจับใบหน้าผู้ก่อการร้าย เพื่อลดความเสี่ยงในการตรวจ ณ จุดตรวจ จุดสกัดของเจ้าหน้าที่

2. วัตถุประสงค์ของการวิจัย

2.1 เพื่อหาไฮเปอร์พารามิเตอร์ที่เหมาะสมในการตรวจจับใบหน้า สำหรับ Google's Teachable Machine


2.2 เพื่อศึกษาและประเมินประสิทธิภาพของ Google's Teachable Machine ในการตรวจจับ

3. ทฤษฎีที่เกี่ยวข้อง

3.1 หลักการ แนวคิด ทฤษฎีเกี่ยวกับปัญญาประดิษฐ์

J. T. Roscoe [8] กล่าวว่า ปัญญาประดิษฐ์ (AI) ประกอบไปด้วยหลาย ๆ แขนงวิชาที่ได้มีการศึกษา

และพัฒนาอัลกอริทึมที่มีความชาญฉลาด เพื่อจะนำไปใช้ประโยชน์ทางด้านการสร้างระบบที่ทำให้คอมพิวเตอร์สามารถมองเห็นการจำแนกรูปภาพหรือสิ่งต่าง ๆ ออกจากกัน ในด้านการฟังเสียงก็รับรู้และแยกแยะเสียง และจดจำคำพูดและเสียงต่าง ๆ ได้ ในกระบวนการต่าง ๆ ที่กล่าวมาจะต้องมีการฝึกสอนให้คอมพิวเตอร์มีความรู้เสียก่อน ในขั้นตอนนี้อยู่ใน Machine Learning แสดงดังรูปที่ 1



รูปที่ 1 ปัญญาประดิษฐ์ (Artificial Intelligence) การเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) [9]

3.2 Google's Teachable Machine

Google's Teachable Machine หรือ Teachable Machine เป็นระบบของ No-Code Machine Learning Platform และเป็นแอปพลิเคชันบนเว็บไซต์ที่สร้างโดย Google ช่วยให้ผู้ใช้งานสามารถเรียนรู้และทำ Machine Learning พื้นฐานได้โดยไม่ต้องเขียนโปรแกรมเพิ่มเติม สำหรับ Teachable Machine นั้นมี 3 ตัวเลือก ที่สามารถเลือกใช้สร้าง Machine Learning คือ โหมดการจำแนกภาพ การจำแนกเสียง และการจำแนกท่าทาง ในส่วนของไฮเปอร์พารามิเตอร์ (Hyperparameters) ใน Teachable Machine นั้น มีจำนวน 3 ตัว ได้แก่ Epoch, Batch Size และ Learning Rate

Epochs คือ จำนวนรอบในการสอนเครื่องโดยแต่ละรอบข้อมูลทั้งหมดจะถูกส่งไปให้

เครื่องเรียนรู้ ยิ่งจำนวนรอบมากโมเดลก็จะยิ่งมีความแม่นยำขึ้น

Batch Size คือ จำนวนข้อมูลที่ถูกส่งเข้าไปสอนเครื่องในแต่ละครั้ง เมื่อข้อมูลทั้งหมดถูกสอนเรียบร้อยแล้วจะถือว่าจบ 1 รอบ

Learning Rate คือ ตัวแปรที่ควบคุมลำดับขั้นในการเรียนรู้ในแต่ละรอบ ซึ่งการปรับค่านี้นั้นแม้เพียงเล็กน้อยก็อาจส่งผลอย่างมากในการเรียนรู้ของเครื่อง เพื่อเพิ่มค่าความถูกต้องในการตรวจจับของ Teachable Machine ผู้ใช้สามารถปรับแต่งไฮเปอร์พารามิเตอร์ (Hyperparameters Tuning) ได้เอง ก่อนที่โมเดลจะทำการเรียนรู้

3.3 การกำหนดประชากรและกลุ่มตัวอย่าง (Identifying Population and Sample)

วิธีการกำหนดขนาดของกลุ่มตัวอย่างมี 3 วิธี คือ การใช้เกณฑ์หรือการประมาณจากจำนวนประชากร การใช้สูตรคำนวณ และการใช้ตารางสำเร็จรูป

3.3.1 การใช้เกณฑ์ หรือการประมาณจากจำนวนประชากร [10]

ตารางที่ 1 การใช้เกณฑ์ หรือการประมาณจากจำนวนประชากร

จำนวนประชากร	ขนาดของกลุ่มตัวอย่าง
จำนวนประชากรทั้งหมด เป็นหลักร้อยละ	15-30%
จำนวนประชากรทั้งหมด เป็นหลักพัน	10-15%
จำนวนประชากรทั้งหมด เป็นหลักหมื่น	5-10%

3.3.2 การใช้สูตรคำนวณ

กรณีที่ประชากรมีจำนวนไม่แน่นอน ผู้วิจัยไม่ทราบจำนวนประชากร ให้ใช้สูตรดังสมการที่ (1) [8]

$$N = (Z_c \sigma / e_m)^2 \quad (1)$$

เมื่อ

N = จำนวนตัวอย่างของประชากร

Z_c = คะแนน (ตามระดับความมีนัยสำคัญที่ผู้วิจัยกำหนดให้ (α))

$Z = 1.96$ ที่ระดับความมั่นใจ 95% ($\alpha = 0.05$)

$Z = 2.58$ ที่ระดับความมั่นใจ 99% ($\alpha = 0.01$)

e_m = ค่าความคลาดเคลื่อนมากที่สุดที่ยอมรับได้

σ = ส่วนเบี่ยงเบนมาตรฐานของประชากร

4. วิธีดำเนินการวิจัย

ในการศึกษาการตรวจจับใบหน้า โดยใช้ Google's Teachable Machine มีขั้นตอนในการศึกษาที่แสดงในรูปที่ 2 โดยมีรายละเอียดดังนี้

1. ศึกษาการทำงานของโปรแกรม Teachable Machine จากแหล่งเรียนรู้ต่าง ๆ
2. ศึกษาทฤษฎีที่เกี่ยวข้องกับ AI ซึ่งประกอบไปด้วย Machine Learning และ Deep Learning
3. กำหนดขนาดกลุ่มตัวอย่าง เพื่อนำไปสร้างการเรียนรู้ให้กับ Google's Teachable Machine

โดยกำหนดให้ความคลาดเคลื่อนมากที่สุดที่ยอมรับได้เป็น 1/10 ส่วนเบี่ยงเบนมาตรฐานของประชากร และระดับความมีนัยสำคัญทางสถิติเท่ากับ 0.01 จากประชากรที่ไม่แน่นอน ผู้วิจัยจะ

ใช้กลุ่มตัวอย่างก็ภาพ

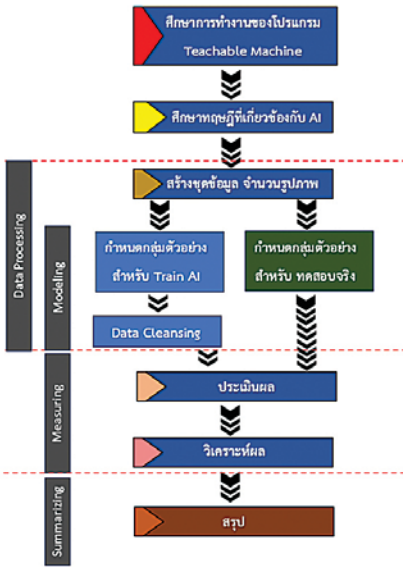
กำหนดให้ $Z_c = 2.58$, $e_m = \sigma/10$ ดังนั้น $\sigma/e_m = 10$

$$\begin{aligned} \text{แทนค่าสูตร (1)} \quad N &= (Z_c \sigma / e_m)^2 \\ &= (2.58 \times 10)^2 \\ &= 665.64 \\ &\approx 666 \end{aligned}$$


จากการคำนวณขนาดข้อมูลของจำนวนภาพที่ใช้ในการทดลอง ได้เป็น 666 ภาพ และจากการตรวจเอกสารงานวิจัยที่เกี่ยวข้องข้างต้น ใช้ข้อมูลภาพระหว่าง 700 ภาพ ดังนั้น จึงใช้ภาพในการฝึกใน Google Teachable Machine ที่ 700 ภาพ และใช้การทดสอบ 210 ครั้ง ตามการใช้เกณฑ์หรือการประมาณจากจำนวนประชากร [10] ที่ 30 %

4. เตรียมชุดข้อมูลสำหรับสอน Google's Teachable Machine โดยใช้รูปภาพใบหน้าผู้ก่อการร้ายจำนวน 700 ภาพ และรูปภาพที่ไม่ใช่ใบหน้าผู้ก่อการร้ายจำนวน 700 ภาพ รวมเป็น 1,400 ภาพ จากแหล่งข้อมูลต่าง ๆ เพื่อสอนให้ AI สามารถตรวจจับได้ เช่น ข้อมูลจากเว็บไซต์ GENERATED PHOTOS [11] ซึ่งเป็นภาพใบหน้าที่ถูกสร้างขึ้นจากเว็บไซต์ ในภาพที่ Generated Photos สร้างให้ นั้น จะเป็นภาพที่ตำแหน่งกล้องถ่ายภาพจะมีความสูงใกล้เคียงกับใบหน้าเป้าหมาย มีความใกล้เคียงกับภาพถ่ายหน้าบัตรประจำตัวประชาชน สามารถสร้างภาพใบหน้าได้หลากหลายอารมณ์ และกำหนดได้ตามต้องการ ซึ่งเหมาะกับการใช้ทำงานวิจัยและไม่ละเมิดสิทธิส่วนบุคคล โดยข้อมูลที่นำมาใช้นั้นเป็นข้อมูลที่สามารถเปิดเผยต่อสาธารณะได้ และสามารถเลือกชนิดของไฟล์ได้ โดยผู้วิจัยได้ใช้ไฟล์ภาพเป็นแบบ JPEG โดย

มีระบบสำหรับการดาวน์โหลดให้บริการ แสดงดังรูปที่ 3 และ 4



รูปที่ 2 ขั้นตอนการศึกษาวิจัย



รูปที่ 3 การสร้างภาพมนุษย์จากเว็บไซต์ GENERATED PHOTOS [11]



ผู้ก่อการร้าย ไม่ใช่ผู้ก่อการร้าย

รูปที่ 4 เปรียบเทียบภาพ ผู้ก่อการร้าย และ ไม่ใช่ผู้ก่อการร้าย

5. ทำความสะอาดข้อมูล หรือ Data Cleansing เพื่อให้ชุดข้อมูลอยู่ในสภาพพร้อมใช้งาน โดยการตัดพื้นหลังออก หรือทำพื้นหลังให้เป็นสีขาว โดยใช้โปรแกรม MATLAB

6. กำหนดคลาส (Class) ใน Teachable Machine จำนวน 2 Class ได้แก่ Class ที่ 1: terrorist (ผู้ก่อการร้าย) และ Class ที่ 2: non - terrorist (ไม่ใช่ผู้ก่อการร้าย)

7. ศึกษาหาค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมในการตรวจจับใบหน้า โดยกำหนดช่วง Epochs, Batch size และ Learning rate ต่าง ๆ

8. ทำการหาค่า Epochs โดยกำหนดให้ค่า Batch size เป็นค่าคงที่ คือ 16, 32, 64, 128, 256 และ 512 และกำหนดให้ค่า Learning rate เป็นค่าคงที่ คือ อยู่ในช่วง 0.0005, 0.0009, 0.001, .0.009, 0.01 และ 0.05

9. ทำการหาค่า Batch size โดยกำหนดให้ค่า Epochs เป็นค่าคงที่ คือ 5, 10, 30, 50, 100 และ 150 และกำหนดให้ค่า Learning rate เป็นค่าคงที่อยู่ในช่วง 0.0005, 0.0009, 0.001, .0.009, 0.01 และ 0.05

10. ทำการหาค่า Learning rate โดยกำหนดให้ค่า Epochs เป็นค่าคงที่ คือ 5, 10, 30, 50, 100 และ 150 และกำหนดให้ค่า Batch size เป็นค่าคงที่ คือ 16, 32, 64, 128, 256 และ 512

11. กำหนดขนาดกลุ่มตัวอย่างเพื่อใช้ในการทดสอบจริง โดยใช้เกณฑ์หรือการประมาณจากจำนวนประชากร [10] ซึ่งคำนวณได้ 210 ครั้ง

12. ทำการทดสอบจริงในการตรวจจับ เป็นรูปภาพ 210 ภาพ (เป็นภาพ JPEG) ซึ่งเป็นรูปภาพที่ผู้วิจัยรวบรวมมาจากเว็บไซต์ GENERATED PHOTOS


13. วิเคราะห์และสรุปผล

5. ผลการวิจัย

5.1 ผลการศึกษาประสิทธิภาพของการปรับไฮเปอร์พารามิเตอร์ใน Teachable Machine


รูปที่ 5 แสดงผลการศึกษาความแม่นยำของค่าของ Epochs ต่าง ๆ เมื่อ Batch size = 64 และ Learning rate = 0.001 ซึ่งค่าของ Epochs มีค่าอยู่ระหว่าง 5, 10, 30, 50, 100 และ 150 สำหรับค่าความแม่นยำในการตรวจจับของทั้ง 2 Class คือ Class ที่ 1: terrorist (ผู้ก่อการร้าย) และ Class ที่ 2: non - terrorist (ไม่ใช่ผู้ก่อการร้าย) ถูกแสดงในแกน y ในรูปของ Accuracy (%)

สำหรับการเรียนรู้ของ Teachable Machine มีรูปในแต่ละ Class จำนวน 700 รูป และถูกสุ่มเลือกออกมาจำนวน 105 รูป เพื่อทดสอบหาความแม่นยำ ผลการทดสอบเมื่อกำหนดค่า Epochs ต่าง ๆ เห็นได้ว่าการตรวจจับ Class: terrorist และ Class: non - terrorist ให้ค่าความแม่นยำที่ร้อยละ 100 ใน 2 ค่าของ Epochs ได้แก่ 50 และ 100 สำหรับค่าใน Epochs อื่นนั้น ยังไม่สามารถตรวจจับที่ร้อยละ 100 ได้ทั้ง 2 Class พร้อมกัน

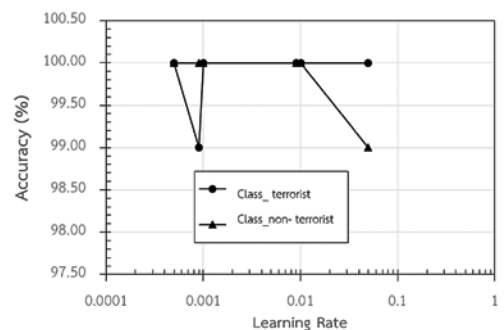


รูปที่ 5 การศึกษาความแม่นยำของ Epochs ต่าง ๆ เมื่อ Batch size = 64 และ Learning rate = 0.001

ในผลการศึกษาความแม่นยำของค่า Batch Size ต่าง ๆ เมื่อ Epochs = 30 และ Learning rate = 0.001 ซึ่งค่าของ Batch Size มีค่าอยู่ระหว่าง 16, 32, 64, 128, 256 และ 512 ได้ถูกแสดงในรูปที่ 6 ผลการศึกษาในภาพรวม พบว่า ค่าความแม่นยำอยู่ระหว่างร้อยละ 98 - 100 สามารถสังเกตได้ว่าผลการตรวจจับ Class: terrorist นั้น ให้ค่าความแม่นยำที่น้อยที่สุด คือ ร้อยละ 98 ถัดไปการตรวจจับ Class: terrorist และ Class: non - terrorist ให้ค่าความแม่นยำที่ร้อยละ 100 ใน 2 ค่าของ Batch Size ได้แก่ 64 และ 256 สำหรับค่าใน Batch Size = 512



รูปที่ 6 การศึกษาความแม่นยำของ Batch size ต่าง ๆ เมื่อ Epochs = 30 และ Learning rate = 0.001

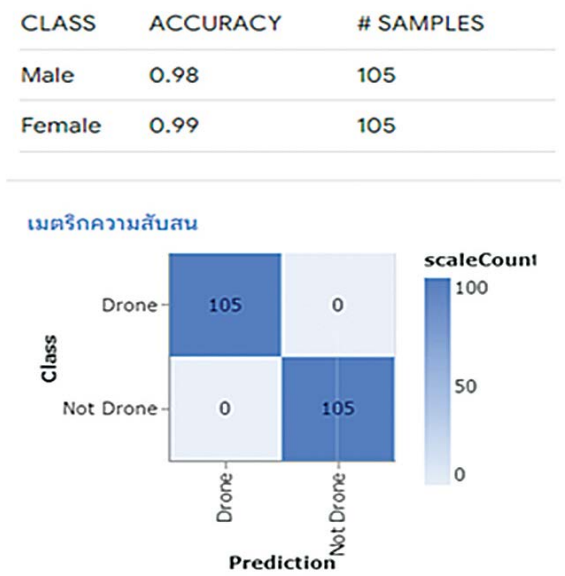


รูปที่ 7 การศึกษาความแม่นยำของ Learning rate ต่าง ๆ เมื่อ Epochs = 30 และ Batch size = 64

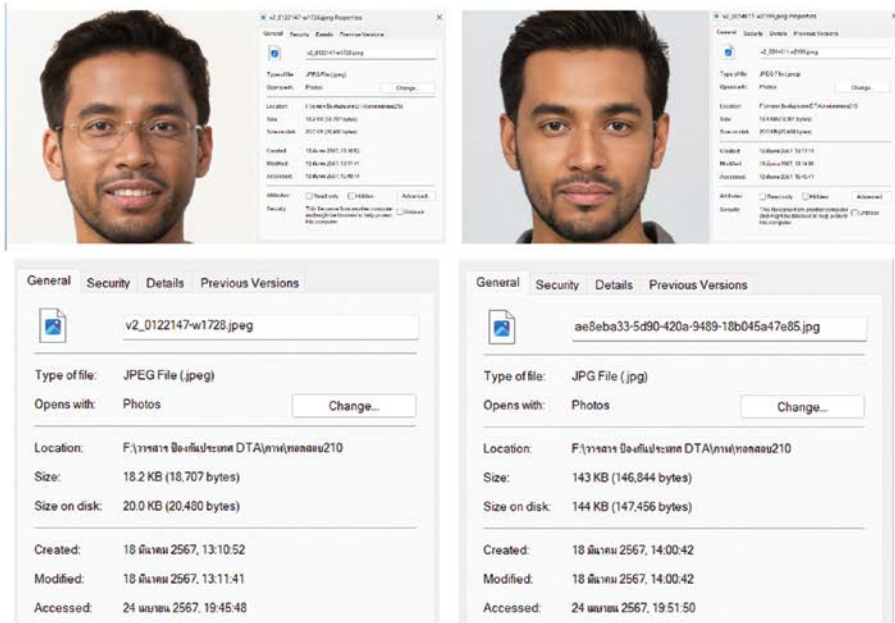
ผลการศึกษาความแม่นยำของค่าของ Learning rate ต่าง ๆ เมื่อ Epochs = 30 และ Batch size = 64 ซึ่งค่าของ Learning rate มีค่าอยู่ระหว่าง 0.0005, 0.0009, 0.001, 0.009, 0.01 และ 0.05 ถูกนำเสนอในรูปแบบที่ 7 โดยภาพรวมแล้วให้ผลการศึกษาน่าพอใจ ผลการทดสอบเมื่อกำหนดค่า Learning rate ต่าง ๆ เห็นได้ว่าการตรวจจับ Class: terrorist และ Class: non - terrorist ให้ค่าความแม่นยำที่ร้อยละ 100 ใน 4 ค่าของ Learning rate ได้แก่ 0.0005, 0.001, 0.009 และ 0.01

จากการทดสอบเปรียบเทียบไฮเปอร์พารามิเตอร์ต่าง ๆ พบว่า ค่า Epochs = 50 และ 100 ค่า Batch Size = 64 และ 256 ค่าของ

Learning rate = 0.0005, 0.001, 0.009 และ 0.01 ให้ค่าความแม่นยำร้อยละ 100 ในทั้ง 2 Class จากนั้นจึงนำค่าไฮเปอร์พารามิเตอร์เหล่านี้มาเทรนและทดสอบค่าความแม่นยำอีกครั้ง พบว่า เมื่อค่า Epochs = 100, Batch size = 256 และ Learning rate = 0.001 ให้ค่าความแม่นยำของทั้ง 2 class คือ Class: terrorist และ Class: non - terrorist ที่ร้อยละ 100 โดยแสดงดังรูปที่ 8 ดังนั้น ค่า Epochs = 100, Batch size = 256 และ Learning rate = 0.001 จึงเป็นค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมในการทดสอบและตรวจจับใบหน้า



รูปที่ 8 ค่าความแม่นยำต่อ Class เมื่อ ค่า Epochs = 100, Batch size = 256 และ Learning rate = 0.001



ก.




ข.



ค.

รูปที่ 9 ตัวอย่างภาพ ก.) ภาพที่มีขนาดต่าง ๆ
 ข.) ภาพที่มีพื้นหลังแบบต่าง ๆ ค.) ภาพที่มีตำแหน่งใบหน้าในภาพที่ตำแหน่งต่าง ๆ



รูปที่ 10 ค่าความแม่นยำในการตรวจจับภาพจริง

5.2 ผลการทดสอบจริง

จากการหาค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมในการทดสอบและตรวจจับใบหน้า หลังจากนั้นได้นำมาทดสอบจริงกับภาพใบหน้า จำนวน 210 ภาพ สำหรับการเลือกภาพนั้น ใช้วิธีการคัดเลือกภาพที่มีความหลากหลายในด้านต่าง ๆ เช่น ขนาด ความละเอียด ลักษณะพื้นหลัง และตำแหน่งของใบหน้าภายในภาพ รูปที่ 9 แสดงตัวอย่างภาพที่มีขนาดต่าง ๆ ภาพที่มีพื้นหลังแบบต่าง ๆ และภาพที่มีตำแหน่งใบหน้าในภาพที่ตำแหน่งต่าง ๆ

ในการทดสอบได้กำหนดเกณฑ์ขั้นต่ำของค่าความแม่นยำอยู่ที่ร้อยละ 95 จากการศึกษาค้นคว้าและทดสอบด้วยภาพทดสอบจำนวน 210 ภาพ พบว่ามีภาพอยู่จำนวน 201 ภาพ ที่มีค่าความแม่นยำมากกว่าร้อยละ 95 และจำนวน 7 ภาพ ที่มีค่าความแม่นยำน้อยกว่าร้อยละ 95 โดยผลแสดงดังรูปที่ 10 เห็นได้ว่าความสามารถในการตรวจจับคิดเป็นร้อยละ 96.52

6. สรุปและอภิปรายผล

จากการศึกษาและประเมินความเป็นไปได้ของเครื่องมือปัญญาประดิษฐ์บนเว็บไซต์ของ

Google's Teachable Machine ในการตรวจจับใบหน้า พบว่า ค่า Epochs = 100, Batch size = 256 และ Learning rate = 0.001 เป็นค่าที่เหมาะสมของพารามิเตอร์การเรียนรู้โดยจากการทดสอบ 210 ครั้ง ผลความแม่นยำในการตรวจจับใบหน้าเท่ากับร้อยละ 96.52 โดยมีอยู่ 7 ภาพ ที่ไม่อยู่ในเกณฑ์นั้น เป็นภาพที่มีตำแหน่งใบหน้าในภาพไม่ครบถ้วน การวิจัยนี้เห็นได้ว่า Google's Teachable Machine สามารถตรวจจับใบหน้าได้ และเป็นเครื่องมือที่ดีที่ช่วยในการ Machine learning ให้กับ AI โดยช่วยประหยัดเวลาของการเขียนโปรแกรมในการสร้างปัญญาประดิษฐ์ และช่วยให้ผู้ที่ไม่มีความรู้ในการเขียนโปรแกรมสามารถนำปัญญาประดิษฐ์มาใช้งานได้

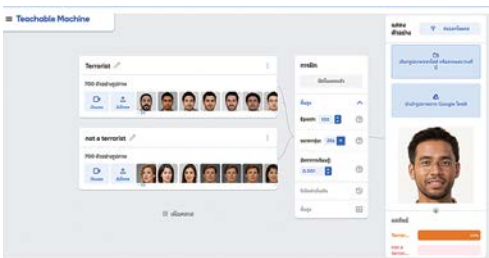
นอกจากนี้ สำหรับการนำผลการวิจัยไปประยุกต์ใช้นั้น มีข้อควรระวัง ได้แก่ ขนาดและความละเอียดของภาพ ต้องมีความละเอียดที่เพียงพอ โดยต้องมีขนาดและความละเอียดที่เท่ากันหรือมากกว่าภาพที่นำมาสร้างการเรียนรู้ให้กับ Google's Teachable Machine

ในส่วนของการวางตำแหน่งของใบหน้าในภาพนั้น ภาพที่นำมาทดสอบวัตถุต้องอยู่ตรงกลาง

ของภาพจึงจะให้ผลการตรวจจับได้ดีที่สุดดังรูปที่ 11 สังเกตได้ว่า Teachable Machine ไม่สามารถตรวจจับได้เลย และในรูปที่ 12 ได้มีการปรับตำแหน่งของใบหน้าให้อยู่ตรงกลางภาพ ส่งผลให้สามารถตรวจจับใบหน้าได้



รูปที่ 11 ภาพทดลองครั้งแรก



รูปที่ 12 ปรับปรุงการวางตำแหน่งของใบหน้าภายในภาพ

7. เอกสารอ้างอิง

- [1] Institute for Economics & Peace. “2022 Global Terrorism Index.” VISIONOFHUMANITY.org. <https://www.visionofhumanity.org/maps/global-terrorism-index/#/> (accessed Jan. 29, 2024).
- [2] Institute for Economics & Peace. “Vision of Humanity.” VISIONOFHUMANITY.org. <https://www.visionofhumanity.org/maps/global-terrorism-index/#/> (accessed Jan. 29, 2024).
- [3] ก. สระอุบล, เรียนรู้ Data Science และ AI: Machine Learning ด้วย Python. กรุงเทพฯ, ไทย: มีเดีย เนทเวิร์ค, 2563.
- [4] จ. น้อยมณี, AI Government Framework กรอบการทำงานปัญญาประดิษฐ์ภาครัฐ. กรุงเทพฯ, ไทย: บริษัท พีเอเอ็น (ไทยแลนด์) จำกัด, 2563.
- [5] H. Jeong, “Feasibility Study of Google’s Teachable Machine in Diagnosis of Tooth-Marked Tongue,” *J. Dent. Hyg. Sci.*, vol. 20, no. 4, pp. 206-212, 2020.
- [6] S. Nupap and O. - U. Pramote, “Design and Development of Character Recognition Applications on Mobile Devices for Practice Writing Thai Consonants,” in *The 13th NPRU Nat. Acad. Conf. Nakhon Pathom Rajabhat Univ.*, Nakhon Pathom, Thailand, Jul. 2021, pp. 641 - 649. (in Thai)
- [7] J. Sanuksan and O. Surinta, “Deep Convolutional Neural Networks for Plant Recognition in the Natural Environment,” *J. Sci. Technol. MSU*, vol. 38, no. 2, pp. 113-124, 2019. (in Thai)
- [8] J. T. Roscoe, *Fundamental Research Statistics for the Behavioral Sciences*. NY, USA: Holt Rinehart and Winston, 1975.
- [9] ส. เกษจำรัส. “AI คืออะไร? ทำความเข้าใจ AI แบบง่าย ๆ.” BEARTAI.com. <https://www.bear tai.com/article/tech-article/424875> (วันที่เข้าถึง ม.ค. 29, 2566).
- [10] บ. ศรีสะอาด, *หลักการวิจัยเบื้องต้น*, พิมพ์ครั้งที่ 3, กรุงเทพฯ, ไทย: สุวีริยาสาสน์, 2535.
- [11] Generated Media. “Generated faces.” GENERATED.PHOTOS. <https://generated.photos/faces> (accessed Jan. 30, 2024).

การทดสอบและพัฒนา ความแข็งแรงของโครงสร้างปีกอากาศยานไร้คนขับ

เจษฎา ชมดารา^{1*} และ ญัฐธิเบศ จารุเพ็ง¹

วันที่รับ 24 เมษายน 2567 วันที่แก้ไข 9 พฤษภาคม 2567 วันตอบรับ 22 พฤษภาคม 2567

บทคัดย่อ

งานวิจัยฉบับนี้ได้ทำการเก็บรวบรวมข้อมูลการใช้งานอากาศยานไร้คนขับไทเกอร์ชาร์ก 2 (Tigershark II) จากศูนย์วิจัยพัฒนาวิทยาศาสตร์เทคโนโลยีการบินและอวกาศกองทัพอากาศ จากข้อมูลพบว่า โครงสร้างปีกมีความแข็งแรง แต่มีน้ำหนักมาก จึงส่งผลให้อากาศยานบินด้วยความเร็วเดินทางที่สูงและทำให้สิ้นเปลืองเชื้อเพลิง คณะผู้วิจัยจึงต้องการลดน้ำหนักโครงสร้างปีก ปรับปรุงและพัฒนาองค์ประกอบโครงสร้างภายในให้มีน้ำหนักลดลง โดยมีวัตถุประสงค์เพื่อทดสอบโครงสร้างปีกของอากาศยานไร้คนขับไทเกอร์ชาร์ก 2 ตามแผนแบบเดิม โดยใช้วิธีการวิเคราะห์เชิงกล (Finite Element Analysis) ด้วยโปรแกรมวิเคราะห์เชิงกล (FEMAP และ NX-Nastran) และทำการสร้างปีกตามแผนแบบใหม่ ทดสอบสร้างแรงกระทำกับปีกด้วยถ่วงตามมาตรฐานการทดสอบปีกอากาศยานไร้คนขับ (NATO STANAG 4671) จากการทดสอบและการแผนแบบพบว่า ปีกอากาศยานไร้คนขับไทเกอร์ชาร์ก 2 ตามแผนแบบเดิม มีน้ำหนักรวม 26 กิโลกรัม รองรับภาระกรรมสูงสุดได้ 900 กิโลกรัม หรือคิดเป็น Load Factor ได้เท่ากับ 7.23 เท่าของน้ำหนักอากาศยาน และปีกที่สร้างตามแผนแบบใหม่มีน้ำหนักน้อยกว่าแผนแบบเดิมได้ถึงร้อยละ 38 (16 กิโลกรัม) มีความแข็งแรงผ่านตามาตรฐานการทดสอบปีกอากาศยานไร้คนขับ มากกว่าเกณฑ์พิสูจน์ภาระกรรม (Proof Load Factor) (4.37 เท่าของน้ำหนักอากาศยาน) อย่างไรก็ตาม ผลการวิจัยนี้ควรทำการศึกษาต่อยอดด้วยการทดสอบปีกแบบไดนามิก (Dynamic Wing Testing) หรือความล้า (Fatigue Testing) ต่อไป

คำสำคัญ : อากาศยานไร้คนขับ, การวิเคราะห์เชิงกล, การแผนแบบอากาศยาน

¹ แผนอากาศยานต้นแบบ, กองสนับสนุนการวิจัยอากาศยาน, ศูนย์วิจัยพัฒนาวิทยาศาสตร์เทคโนโลยีการบินและอวกาศกองทัพอากาศ
* ผู้แต่ง, อีเมล: jedsada_c@rtaf.mi.th

Testing and Developing the Strength of Unmanned Aircraft Wing Structures

Jedsada Chomdara^{1*} and Nuttibase Charupeng¹

Received 24 April 2024, Revised 9 May 2024, Accepted 22 May 2024

Abstract

This research has collected data on the use of the unmanned aerial vehicle Tigershark II from The Research and Development Centre for Space and Aeronautical Science and Technology, RTAF. From the data, it was found that the wing structure is robust but heavy, leading to high-speed flight and fuel inefficiency. Researchers aim to reduce wing structure weight by improving and developing internal components to decrease overall weight. The objective is to test the Tigershark II unmanned aerial vehicle wing structure according to the original plan using Finite Element Analysis with FEMAP and NX-Nastran software, and then create a new wing based on the results. Testing involved applying forces to the wing using sandbags according to NATO STANAG 4671 standards. Results showed that the original wing design weighed 26 kilograms, supporting a maximum load of 900 kilograms or a Load Factor of 7.23 times the aircraft weight. The new wing design weighed 16 kilograms less, achieving a weight reduction of 38%. It also met strength standards, exceeding the Proof Load Factor of 4.37 times the aircraft weight. However, further study is recommended, including dynamic wing testing or fatigue testing.

Keywords : Unmanned aerial vehicle (UAV), Finite element analysis, Aircraft design

¹ Aircraft Prototype Department, Aircraft Research Support Division, Research and Development Centre for Space and Aeronautical Science and Technology, RTAF

* Corresponding author, E-mail : jedsada_c@rtaf.mi.th

1. บทนำ

การลาดตระเวนทางอากาศโดยใช้อากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) ได้เข้ามามีบทบาทในการปฏิบัติงานของกองทัพอากาศเป็นอย่างมากและมีผลต่อหลักนิยมการปฏิบัติทางอากาศ เนื่องจากเทคโนโลยีด้าน UAV มีความก้าวหน้าอย่างรวดเร็ว สามารถนำมาใช้ปฏิบัติการลาดตระเวนทางอากาศและการช่วยเหลือผู้ประสบภัยพิบัติทดแทนวิธีการแบบเดิมที่ใช้เครื่องบินลาดตระเวนได้เป็นอย่างดี สามารถปฏิบัติงานได้ต่อเนื่องยาวนาน มีรัศมีปฏิบัติการไกล ประหยัดค่าใช้จ่ายและลดอันตรายในการปฏิบัติงานของนักบิน อากาศยานไร้คนขับไทเกอร์ชาร์ก 2 แสดงในรูปที่ 1 มีความยาวปีก 6 เมตรบินทำภารกิจได้นานถึง 8 ชั่วโมง จึงได้ถูกนำมาใช้ในการกิจลาดตระเวน



รูปที่ 1 อากาศยานไร้คนขับไทเกอร์ชาร์ก 2

1.1 ปัญหาและสาเหตุ

จากการใช้งานพบว่าอากาศยานไร้คนขับไทเกอร์ชาร์ก 2 มีน้ำหนักมาก ส่งผลต่อระยะเวลาปฏิบัติการอย่างเป็นนัยสำคัญ ผู้วิจัยจึงมีแนวคิดในการพัฒนาโครงสร้างปีกให้มีน้ำหนักที่เบาและยังคงความแข็งแรงตามมาตรฐาน

1.2 วัตถุประสงค์

- เพื่อทดสอบโครงสร้างปีกของไทเกอร์ชาร์ก 2
- เพื่อยืนยันความแข็งแรงของโครงสร้างปีกตามมาตรฐาน NATO (STANAG 4671)
- เพื่อพัฒนาโครงสร้างปีกไทเกอร์ชาร์ก 2

ตารางที่ 1 การแบ่งกลุ่มอากาศยานไร้คนขับ [1]

UAS CLASSIFICATION TABLE						
Class	Category	Normal Employment	Normal Operating Altitude	Normal Mission Radius	Primary Supported Commander	Example Platform
Class III (> 600 kg)	Strike/Combat*	Strategic/National	Up to 65,000 ft	Unlimited (BLOS)	Theatre COM	Reaper
	HALE	Strategic/National	Up to 65,000 ft	Unlimited (BLOS)	Theatre COM	Global Hawk
	MALE	Operational/Theatre	Up to 45,000 ft MSL	Unlimited (BLOS)	JTF COM	Heron
Class II (150 kg - 600 kg)	Tactical	Tactical Formation	Up to 10,000 ft AGL	200 km (LOS)	Bde COM	SPERWER
Class I (<150 kg)	Small (>15 kg)	Tactical Unit	Up to 5,000 ft AGL	50 km (LOS)	Battalion, Regiment	Scan Eagle
	Mini (<15 kg)	Tactical Sub-unit (manual or hand launch)	Up to 3,000 ft AGL	Up to 25 km (LOS)	Company Squad Platoon Squad	Skylark
	Micro** (<66 J)	Tactical Sub-unit (manual or hand launch)	Up to 200 ft AGL	Up to 5 km (LOS)	Platoon, Section	Black Widow


2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 อากาศยานไร้คนขับ


J. E. Mayer [1] อธิบายว่าอากาศยานไร้คนขับคือ ยานพาหนะที่ขับเคลื่อนด้วยพลังงานโดยไม่มีคนขับเคลื่อนที่ได้โดยอัตโนมัติหรือด้วยการควบคุม สามารถบรรจุอุปกรณ์ที่เป็นอันตรายหรือไม่ก็ได้ ยานพาหนะไร้คนขับเป็นส่วนประกอบขั้นพื้นฐานของระบบอากาศยานไร้คนขับ (Unmanned Aerial Systems) อากาศยานไร้คนขับมีการเติบโตอย่างรวดเร็วเพื่อให้รองรับกับวัตถุประสงค์การใช้งานที่หลากหลาย จึงมีการแบ่งอากาศยานไร้คนขับออกเป็น 5 กลุ่มตามน้ำหนัก ความสูง และระยะเวลาทำการบินเป็นหลัก แสดงในตารางที่ 1 ซึ่ง ไทเกอร์ชาร์ก 2 มีน้ำหนัก 166 กิโลกรัม บินทำภารกิจที่ความสูง 10,000 ฟุต จึงจัดอยู่ใน Class II

2.2 การวิเคราะห์โครงสร้างอากาศยานตามหลักโครงสร้างอากาศยาน

ปีกทรงสี่เหลี่ยมผืนผ้าสามารถจำลองให้เป็นคานได้ [2] ตามรูปที่ 2 โดยมีลูกศรแสดงขนาดสัมพัทธ์และทิศทางของภาระกรรม (แรงยก) ที่กระทำกับปีก โมเดลดังกล่าวนี้จะเหมาะกับปีกที่มีอัตราส่วนของความยาวคอर्डที่ปลายปีกต่อความยาวคอर्डที่โคนปีก (Taper Ratio) เท่ากับ 1 หรือ $\lambda=1$ ซึ่งหมายความว่าความยาวคอर्डที่โคนปีกและความยาวคอर्डที่ปลายปีกมีขนาดเท่ากันในรูปแบบที่ 2 และขนาดไม่เท่ากันในรูปแบบที่ 3



รูปที่ 2 ภาพจำลองภาระกรรมบนคาน (ปีก) สำหรับปีกทรงสี่เหลี่ยมผืนผ้า ($\lambda=1$)



รูปที่ 3 ภาพจำลองภาระกรรมบนคาน (ปีก) สำหรับปีกที่มี Taper Ratio ($\lambda \leq 1$)

โดย S. D. Lannoy [3] ได้แปลงสมการสำหรับการคำนวณหาระยะโก่งตัวของปีก (Wing Deflection) ดังแสดงในสมการที่ (1)


$$\delta = \frac{2WL}{EI_{root}} \left\{ \frac{1+2\lambda}{(1+\lambda)(13+35\lambda)} \right\} y^2 \quad (1)$$

เมื่อ δ = ระยะโก่งของปีก (Wing Deflection) (เมตร)
 W = น้ำหนักรวม (นิวตัน)
 L = ความยาวครึ่งหนึ่งของปีก (เมตร)
 E = ค่าโมดูลัสของยังส์ (ปาสคัล)
 I_{root} = โมเมนต์ความเฉื่อยการโก่งตัวที่โคนปีก (เมตร⁴)
 λ = อัตราส่วนของความยาวคอर्डที่ปลายปีกต่อความยาวคอर्डที่โคนปีก (Taper Ratio) (ไม่มีหน่วย)
 y = ระยะตามแนวปีกจากโคนปีก (เมตร)

2.3 การวิเคราะห์โครงสร้างอากาศยานด้วยวิธีวิเคราะห์เชิงกล (Finite Element Analysis: FEA)

เป็นการใช้โปรแกรมคอมพิวเตอร์สร้างแบบจำลอง 3 มิติ โดยใช้ทฤษฎี Finite Element Method [4] จำลองภาระกรรมที่เกิดขึ้นกับโครงสร้าง

อากาศยาน เพื่อวิเคราะห์และหาค่าความเค้น (Stress) และค่าความเครียด (Strain) ที่เกิดขึ้น รวมถึงการพิจารณาตำบลวิกฤต ซึ่งเป็นบริเวณที่เกิดค่าความเค้นสูงสุด ดังแสดงในรูปที่ 4 ซึ่งเป็นเทคนิควิธีที่นิยมอย่างแพร่หลายในปัจจุบัน เนื่องจากมีโปรแกรมจำนวนมากที่ใช้ระเบียบวิธีวิเคราะห์เชิงกล



รูปที่ 4 ตัวอย่างการวิเคราะห์โครงสร้างด้วยโปรแกรม Finite Element Analysis [5]

เพราะมีความน่าเชื่อถือและให้ผลการคำนวณอย่างรวดเร็ว ประหยัดงบประมาณและเวลาในการทดสอบ

2.4 การสร้างชิ้นส่วนอากาศยานด้วยวัสดุผสม (Composite Materials)

การสร้างชิ้นส่วนอากาศยานไร้คนขับด้วยวัสดุผสมเป็นงานที่ซับซ้อนและต้องใช้ความชำนาญในหลายด้าน เพื่อให้มีความปลอดภัยและประสิทธิภาพ มีขั้นตอนดังนี้

2.4.1 การออกแบบ: ออกแบบชิ้นส่วนอากาศยานเพื่อให้สามารถทำงานได้อย่างมีประสิทธิภาพ เช่น ใช้โปรแกรมเขียนแบบ CAD (Computer-Aided Design) เพื่อสร้างแบบแปลนที่แม่นยำและเหมาะสมกับการทำงานของอากาศยานไร้คนขับ


2.4.2 การเลือกวัสดุ: เลือกวัสดุที่มีความเหมาะสมสำหรับการใช้ในอากาศยาน เช่น พลาสติกเสริมแรง (Reinforced Plastic) พลาสติกเสริมใยแก้ว (Glass Fiber Reinforced Plastic: GFRP) พลาสติกเสริมใยคาร์บอน (Carbon Fiber Reinforced Plastic:

CFRP) พลาสติกเสริมใยสังเคราะห์ (Synthetic Reinforced Plastic) เป็นต้น

2.4.3 การผลิต: ทำการขึ้นรูปชิ้นงาน (Composite Lamination) โดยการนำวัสดุมาวางเรียงตามแบบและประสานด้วยน้ำยาเรซิน

2.5 การคำนวณความแข็งแรงของวัสดุผสม

พิจารณาชั้นของวัสดุผสม (Lamina) ตามรูปที่ 5 มีแกนหลัก 3 แกน ดังนี้ แกนที่ 1 ตามแนวของเส้นใย (Fiber) เรียกว่า Fiber Direction แกนที่ 2




รูปที่ 5 แกนหลักของชั้นของวัสดุผสม

และแกนที่ 3 ทิศทางตั้งฉากกับแนวของเส้นใยไฟเบอร์ เรียกว่า Transverse Directions [5]

วัสดุผสมเป็นวัสดุชนิดที่มีสมบัติในแต่ละทิศทางไม่เท่ากัน (Orthotropic Material) เนื่องจากการคำนวณค่าความเค้นและค่าความเครียดจะตั้งสมมติฐานว่าวัสดุผสมระหว่างเส้นใย และเมทริกซ์เป็นวัสดุเนื้อเดียวกัน ไม่แยกคำนวณค่าความเค้นและค่าความเครียดของเมทริกซ์ และของเส้นใยแต่ละเส้น

รูปที่ 6 แสดงความเค้นบนองค์ประกอบของวัสดุประกอบด้วย ความเค้นตั้งฉาก (Normal Stress) จำนวน 3 ค่า ($\sigma_1, \sigma_2, \sigma_3$) และมีความเค้นเฉือน (Shear Stress) จำนวน 3 ค่า (τ_1, τ_2, τ_3)

ความสัมพันธ์ระหว่างความเค้นและความเครียดสามารถเขียนให้อยู่ในรูปเมทริกซ์ได้ตามรูปที่ 7



รูปที่ 6 Stress บน Element ของวัสดุ

$$\begin{Bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \gamma_{23} \\ \gamma_{13} \\ \gamma_{12} \end{Bmatrix} = \begin{bmatrix} \frac{1}{E_1} & -\frac{\nu_{21}}{E_2} & -\frac{\nu_{31}}{E_3} & 0 & 0 & 0 \\ -\frac{\nu_{12}}{E_1} & \frac{1}{E_2} & -\frac{\nu_{32}}{E_3} & 0 & 0 & 0 \\ -\frac{\nu_{13}}{E_1} & -\frac{\nu_{23}}{E_2} & \frac{1}{E_3} & 0 & 0 & 0 \\ 0 & 0 & 0 & \frac{1}{G_{23}} & 0 & 0 \\ 0 & 0 & 0 & 0 & \frac{1}{G_{13}} & 0 \\ 0 & 0 & 0 & 0 & 0 & \frac{1}{G_{12}} \end{bmatrix} \begin{Bmatrix} \sigma_1 \\ \sigma_2 \\ \sigma_3 \\ \tau_{23} \\ \tau_{13} \\ \tau_{12} \end{Bmatrix}$$

รูปที่ 7 สมการความสัมพันธ์ความเค้นและความเครียด

โดย 6x6 matrix เรียกว่า เมทริกซ์การปฏิบัติตาม (Compliance Matrix) สำหรับการคำนวณความแข็งแรงของวัสดุผสม เนื่องจากการแก้เมทริกซ์การปฏิบัติตามมีความซับซ้อนมาก โปรแกรมวิเคราะห์เชิงกลจึงเข้ามาช่วยในการแก้เมทริกซ์การปฏิบัติตามเพื่อวิเคราะห์ความแข็งแรงของโครงสร้างปีกไทเกอร์ซาร์ก 2

2.6 ความแข็งแรงของวัสดุผสม

ในการคำนวณค่าโมดูลัสของยังส์ (Young's Modulus) หรือค่า E ของวัสดุผสมแบบชั้น (Laminated Composites) ในทางปฏิบัติถือว่าผิวทุกชั้นรวมเป็นเนื้อเดียวกัน หรือกระบวนการรวมให้เป็นเนื้อเดียวกัน (Homogenization) จึงคิดหาค่า E แยกตามชั้น (Ply)

ของวัสดุโดยการคำนวณชิ้นส่วนโมดูลัสยืดหยุ่น (Partial Modulus of Elasticity) ของเลเยอร์ (Layer) n ทำได้ตามสมการที่ (2) โดย D. Gay [6]

$$E_n^* = \frac{b_n}{B} E_n \quad (2)$$

เมื่อ N = จำนวนเลเยอร์ของวัสดุผสม ไม่รวมเมทริกซ์

n = Ply sequence: 1, 2, 3, ..., N

E_n = Modulus of Elastic ของเลเยอร์ n

E_n^* = Partial Modulus of Elasticity ของเลเยอร์ n

E = Total Modulus of Elasticity ของวัสดุผสม

b_n = ความหนาของวัสดุ n

B = ความหนารวมของวัสดุผสม

โมดูลัสยืดหยุ่นของวัสดุผสมสามารถคำนวณได้จากผลรวมของชิ้นส่วนโมดูลัสของทุกชั้นได้ดังสมการที่ (3)

$$E = E_1^* + E_2^* + E_3^* + \dots + E_N^* \quad (3)$$

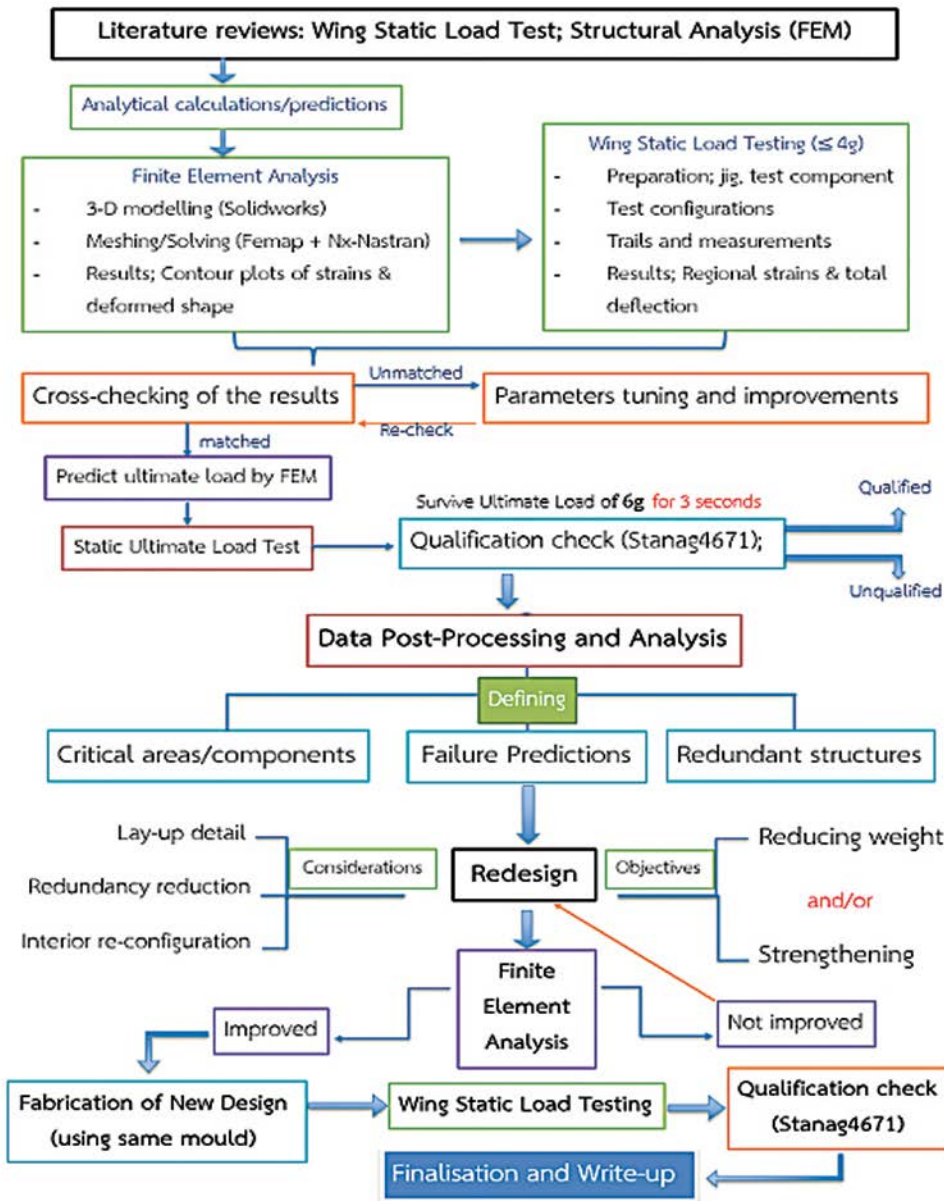
สามารถคำนวณค่าแรงดึงที่ยอมรับได้ (Allowable Tensile Strength) โดยพิจารณาค่า $\varepsilon_{f,n}$ (Elongation at Failure) ของชั้นที่ต่ำสุดจากสมการที่ (4)

$$\sigma_a = (\varepsilon_{f,n})_{min} E \quad (4)$$

3. การดำเนินงานวิจัย

3.1 ขั้นตอนการดำเนินงาน

ขั้นตอนการดำเนินงานวิจัยเพื่อบรรลุวัตถุประสงค์ในการทดสอบความแข็งแรงและพัฒนาแผนแบบโครงสร้างปีกอากาศยานไร้คนขับ มีขั้นตอนดังแสดงในรูปที่ 8



รูปที่ 8 ขั้นตอนการดำเนินการวิจัย

3.2 การทดสอบวัสดุผสมด้วยวิธีทดสอบคูปองวัสดุ (Materials Coupon Testing)

ในการวิเคราะห์โครงสร้างปีกอากาศยาน ไร้คนขับ มีความจำเป็นที่จะต้องใช้อุปกรณ์เกี่ยวกับคุณสมบัติเชิงกลของวัสดุที่เป็นองค์ประกอบของโครงสร้าง เช่น ค่าโมดูลัสของยังส์ ค่าความแข็งแรงสูงสุด เป็นต้น องค์ประกอบของวัสดุโครงสร้างปีกของไทเกอร์ชาร์ก 2 ส่วนใหญ่นั้นเป็นวัสดุผสม และวัสดุผสมที่เกิดจากการขึ้นรูปด้วยรายละเอียดขั้นตอนที่ต่างกัน มีคุณสมบัติที่แตกต่างกัน ด้วยเหตุนี้ คณะผู้วิจัยจึงดำเนินการทดสอบวัสดุ ณ ศูนย์เทคโนโลยีโลหะและวัสดุแห่งชาติ ได้แก่ การทดสอบแรงดึง ในรูปที่ 9 การทดสอบแรงกด ในรูปที่ 10 และการทดสอบแรงดัด ในรูปที่ 11



รูปที่ 10 การทดสอบแรงกด




รูปที่ 9 การทดสอบแรงดึง



รูปที่ 11 การทดสอบแรงดัด

3.3 การแผนแบบโครงสร้างปีกไทเกอร์ชาร์ก 2 เพื่อการจำลอง 3 มิติ


ทำการแผนแบบให้ตรงกับแบบสร้างไทเกอร์ชาร์ก 2 โดยมีความยาวปีก 6 เมตร ด้วยโปรแกรม Solidworks เป็นลักษณะโมเดลแบบผิวสามมิติ ซึ่งจะเหมาะสำหรับการจำลองและคำนวณต่อไป [7] ตามรูปที่ 12



รูปที่ 12 โมเดลสามมิติของปีกไทเกอร์ชาร์ก 2



รูปที่ 13 แบบสามมิติของแท่นทดสอบและการวิเคราะห์เชิงกล



รูปที่ 14 แบบสำหรับสร้างแท่นทดสอบ

3.4 การสร้างและออกแบบแท่นทดสอบโครงสร้างปีก (Test Jig Support)

ในการทดสอบโครงสร้างปีกนั้น จะต้องมีแท่นสำหรับการยึดตรึงปีกให้อยู่กับที่ โดยจะต้องนำปีกหงายขึ้นและมีการยึดตรึง ดังนั้น โครงสร้างที่จะต้องมีมารับภาระกรรมผ่านจุดยึดตรึงดังกล่าว จะต้องมี ความแข็งแรงอย่างมาก จึงเลือกใช้โครงสร้างเหล็ก โดยได้มีการออกแบบด้วยโปรแกรมคอมพิวเตอร์ เริ่มด้วยการเขียนแบบสามมิติ และวิเคราะห์ความแข็งแรง ดังแสดงในรูปที่ 13 ซึ่งเมื่อให้ผลการคำนวณที่สามารถนำมายืนยันได้ว่ามีความปลอดภัยในการใช้งาน ในการที่จะต้องแบกรับภาระกรรมตามลิมิต (Limit Loads) ที่ภาระกรรมขนาดต่าง ๆ ของน้ำหนักอากาศยานแล้ว จึงนำไปเขียนแบบสำหรับการสร้าง ดังแสดงในรูปที่ 14 แล้วดำเนินการสร้างตามแบบในรูปที่ 15 สุดท้ายนำไปติดตั้งกับปีกเพื่อทำการทดสอบ ในรูปที่ 16

3.5 การคำนวณและวิเคราะห์โครงสร้างด้วยเทคนิค FEA

ในการออกแบบโครงสร้างอากาศยาน โดยเฉพาะอย่างยิ่ง โครงสร้างในส่วนที่ต้องรองรับภาระกรรม นอกจากจะต้องทดสอบภาระกรรมปีกแล้ว ตามมาตรฐานสากลความสมควรเดินอากาศได้ แนะนำว่าควรมีการจำลองการทดสอบโดยโปรแกรม เพื่อเป็นการตรวจสอบระหว่างการทดสอบและการจำลองอีกด้วย โดยในโครงการวิจัยนี้ได้ใช้โปรแกรม Femap Version 12.0 [8] สำหรับการดูผลการคำนวณและวิเคราะห์ผลต่าง ๆ ทางวิศวกรรม และใช้โปรแกรม NX-Nastran สำหรับการคำนวณด้วยวิธีวิเคราะห์เชิงกล ดังแสดงในรูปที่ 17

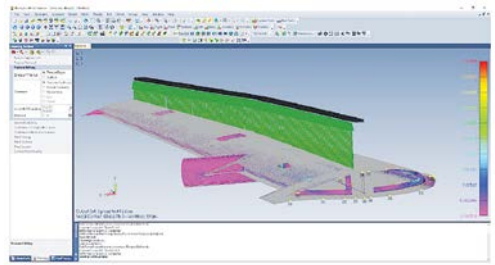


รูปที่ 15 การดำเนินการสร้างแท่นทดสอบ



รูปที่ 16 โครงสร้างปีกไทเกอร์ซาร์ก 2 (แผนแบบเดิม) ติดตั้งประจำแท่นทดสอบ

สำหรับตัวแปรสำคัญเกี่ยวกับการคำนวณนั้น คณะผู้วิจัยได้เลือกใช้การแบ่งองค์ประกอบแบบสี่เหลี่ยมขนาด 5 มิลลิเมตร และใช้เป็นองค์ประกอบสองมิติแบบ Q4 หรือ ฟังก์ชันการแก้ไขแบบไบลิเนียร์ (Bilinear Interpolation Functions) สำหรับการคำนวณ เนื่องจากการคำนวณที่ต้องใช้จำนวนองค์ประกอบค่อนข้างมาก จึงไม่สามารถแบ่งองค์ประกอบแบบ Q8 หรือสมการกำลังสองได้ เพราะจะทำให้ระยะเวลาในการคำนวณมากเกินไป นอกจากนี้ยังได้ควบคุมให้อัตราส่วนจาโคเบียน (Jacobian Ratio) มีค่าไม่เกิน 0.6 ซึ่งเป็นค่าที่มาตรฐานและให้ผลการคำนวณที่น่าเชื่อถือ งานวิจัยนี้ได้เลือกภาระกรรมขนาด 1 - 6 เท่าของน้ำหนักไทเกอร์ซาร์ก 2 โดยจำลองให้กระทำในลักษณะ



รูปที่ 17 FEMAP สำหรับการวิเคราะห์เชิงกล

ตามทฤษฎีที่กล่าวข้างต้นตามรูปที่ 3 กล่าวคือ จะมีลักษณะเป็นการกระจายแรงภาระกรรม (Distributed Load) และมีแรงขนาดใหญ่ที่สุดที่โคนปีกและลดลงแบบเส้นตรง (Linear Variation) จนน้อยที่สุดที่ปลายปีก (ดังแสดงในรูปที่ 17 ตามลูกศรสีเขียว) และในการยึดตรึง (Constraints) ของโมเดลนั้น เนื่องจากการจำลองปีกข้างเดียวโดยอาศัยหลักการสมมาตร จึงต้องใช้จุดยึดตรึงที่บริเวณแกนสมมาตร

ในการคำนวณด้วย FEA นั้น สิ่งที่มีความสำคัญต่อความแม่นยำและความถูกต้องของผลการคำนวณ นอกจากจะขึ้นอยู่กับโปรแกรมและวิธีในทาง FEA แล้ว อีกปัจจัยหนึ่งซึ่งส่งผลอย่างมาก คือ การกำหนดวัสดุ และความหนา ซึ่งรวมไปถึงการกำหนดคุณสมบัติเชิงกลของแต่ละวัสดุ โดยงานวิจัยนี้ได้ทดสอบด้วยเทคนิคคูปอง ตามมาตรฐาน American Society for Testing and Materials (ASTM) ตามที่กล่าวในข้อ 3.2 แสดงในตารางที่ 2 และการออกแบบการวางผ้าเส้นใยของโครงสร้างปีก แสดงในตารางที่ 3

3.6 การทดสอบโครงสร้างปีกด้วยถุงทราย (Wing Sandbag Testing)

ใช้ถุงทรายวางกระจายตามแรงยก (Load Distribution) เตรียมสำหรับการถ่วงน้ำหนักทั้ง 2 ข้างตามหลักการสมมาตร แสดงในรูปที่ 18 และ 19 ใช้อุปกรณ์วัดค่าความเครียด (Strain Gauge) สำหรับ

ตารางที่ 2 ข้อมูลวัสดุที่ใช้ชั้นรูปไทเกอร์ชาร์ก 2


วัสดุ หรือ Ply	ชื่อย่อ Ply	Modulus of Elasticity (Gpa)	Tensile Strength (Mpa)	Compressive Strength (Mpa)	Poisson ratio (-)	ความหนา (mm)	น้ำหนักต่อพื้นที่ (g/m ²)
Plain-Woven Carbon/Epoxy	CF/E	26.9	450	300	0.10	0.25	400
Plain-Woven E-Glass/Epoxy	GF/E	15.3	337	81	0.10	0.10	150
Unidirectional Carbon/Epoxy	UD/E	51.9	1500	1200	0.30	N/A	N/A
Plain-Woven Carbon 2mm U-PICA foam Plain-Woven Carbon	CF/f/CF	5.0	94	5	0.30	2.50	900
Foam Carbon Foam Carbon Foam	F/CF/F	3.8	53	6	0.25	12.00	2000
ไม้อัด (Plywood)	PLW	6.7	70	45	0.25	3.50	2400

การวัดค่าความเครียด และการคำนวณค่าความเค้น ติดตั้งอุปกรณ์วัดค่าความเครียดแบบแกนเดียว (Axial) ตามแนวของแกนปีก (Wing Spar) ที่ปีกกลาง (Center Wing) จำนวน 9 ตำแหน่ง และติดตั้ง Strain Gauge ชนิดหลายแกน (Rosette) 0°/45°/90° จำนวน 8 ตำแหน่ง ที่จุดต่าง ๆ ของผิวปีก ดังแสดง ในรูปที่ 20

3.7 การพัฒนาแผนแบบ

โครงสร้างหลักประกอบไปด้วย Center Wing Main Spar Ribs และ Rear Spars, Outer Wing Spar และผิวปีก คณะผู้วิจัยได้กำหนดแนวทางที่จะสามารถพัฒนาโครงสร้างภายในดังนี้

- 1) เพิ่มหรือลดจำนวน Ribs รวมไปถึงการวางตำแหน่ง
- 2) แบบ Profile ของ Center Wing Main Spar จาก C-beam เป็น I-beam พร้อมปรับเปลี่ยน



รูปที่ 18 รูปแบบการวางถุงทรายบนปีก



รูปที่ 19 การทดสอบความแข็งแรงโครงสร้างปีกด้วยถุงทราย ที่ภาระกรรมขนาด 900 กิโลกรัม



รูปที่ 20 การติดตั้ง Strain Gauges กับผิวปีก

ตารางที่ 3 การออกแบบการวางผ้าเส้นใยของโครงสร้างปีก

Wing Components	Sub-Part	Ply Sequence (Orientation)	Layer Thickness (mm)	Total Thickness (mm)
Skin	-	- GF/E ($\pm 45^\circ$)	0.10	3.95
		- 4xCF/E ($\pm 45^\circ$)	1.00	
		- CF/E (0/90°)	0.25	
		- CF/foam/CF (0/90°)	2.50	
		- GF/E ($\pm 45^\circ$)	0.10	
Centrewing Main Spar	Upper Flange	- GF/E (0/90°)	0.10	3.39
		- 3xCF/E (0/90°)	0.75	
		- UD/E	2.04	
	Lower Flange	- 2xCF/E ($\pm 45^\circ$)	0.5	2.79
		- UD/E	1.44	
		- 3xCF/E (0/90°)	0.75	
Web	- GF/E (0/90°)	0.10	1.35	
	- 5xCF/E ($\pm 45^\circ$)	1.25		
Rear Spar	-	CF/E (0/90°)	0.25	4.00
		PLW	3.50	
		CF/E (0/90°)	0.25	
Outer Wing Main Spar	-	F/CF/F	12.00	12.00
Ribs	-	CF/E (0/90°)	0.25	4.00
		PLW	3.50	
		CF/E (0/90°)	0.25	
Carbon Tube	-	8xCF/E	2.00	2.00
Sleeve	-	8xGF/E	2.00	2.00

ตำแหน่งการวางและเปลี่ยนแบบการวางผ้าเส้นใย

3) เปลี่ยนวัสดุในชั้นหลัก (Core Material) ของผิวจากโฟมประเภท PVC โฟม เป็นโฟมที่มีอัตราส่วนของความแข็งแรงต่อน้ำหนักมากกว่า

4) เปลี่ยนความยาวท่อคาร์บอน (Connector Tube)

5) เปลี่ยนแบบการยึดประกอบกันระหว่างปีกกลางและลำตัว

4. ผลการวิจัย

4.1 ผลการคำนวณ FEA


แสดงผล FEA การคำนวณความเครียดที่จะเกิดขึ้นเมื่อได้รับการกระแทกสูงสุดขนาด 900 กิโลกรัม กระทำกับปีก แสดงในรูปที่ 21 ซึ่งมุ่งเน้นวิเคราะห์ที่

จุดวิกฤตในบริเวณต่าง ๆ แสดงให้เห็นว่าโครงสร้างในจุดยึดตรึงและอื่น ๆ อาจเกิดการร้าวเพราะมีความเค้นใกล้เคียงกับค่าครากของวัสดุ (Yield Strength)


4.2 ผลการทดสอบโครงสร้างปีกด้วยถุงทราย (Sandbag Testing) (แผนแบบเต็ม)

ผลการทดสอบด้วยการถ่วงถุงทรายได้แสดงในรูปที่ 22 โดยเป็นผลการโก่งตัวของปีกเป็นระยะขจัดที่ปลายปีก มีหน่วยเป็นเซนติเมตร ที่ขนาดภาระกรรมต่าง ๆ ซึ่งให้ผลค่าความแตกต่างระหว่างผลการคำนวณเปรียบเทียบกับผลการทดสอบไม่เกินร้อยละ 15

เมื่อได้ทำการสำรวจโครงสร้างภายในด้วยสายตา (Visual Inspection) ที่จุดวิกฤตต่าง ๆ ในรูปที่ 23 ไม่พบความเสียหายที่เด่นชัด เช่น รอยร้าว



รูปที่ 21 แสดงผลการคำนวณความเค้น (Von Mises Stresses) ณ จุดต่าง ๆ



รูปที่ 22 เปรียบเทียบระยะขจัดที่ปลายปีก (แผนแบบเดิม) ณ ขนาดภาระกรรมต่าง ๆ

หรือรอยแยกชั้นผิวของวัสดุที่อาจจะเกิดจากการแยกชั้น (Debonding) สามารถอธิบายได้ว่าวัสดุยังไม่เกิดการ Debonding แต่มีการครากเกิดขึ้นเนื่องจากการยืนยันด้วยผลการวัดระยะขจัด (ปีกคั่นตัวไม่หมด) และการคำนวณด้วย FEA ซึ่งให้ผลว่าโครงสร้างบางจุดมีค่าความเค้นที่เกิดขึ้นจากภาระกรรมใกล้เคียงกับเกณฑ์ความเค้น ณ จุดคราก (Yield Strength) ของวัสดุ สามารถวิเคราะห์และสรุปได้ว่า

โครงสร้างปีกตามแผนแบบเดิมมีความแข็งแรงสูงสุด (Ultimate Strength) ที่ขนาดภาระกรรม 900 กิโลกรัม หรือ 7.26 เท่าของน้ำหนักอากาศยาน

4.3 การพัฒนาแผนแบบโครงสร้างปีกไทเกอร์ชาร์ก 2

คณะผู้วิจัยจึงได้ดำเนินการแผนแบบใหม่ตามตารางที่ 4 และ 5 ซึ่งจะทำให้โครงสร้างคงความแข็งแรงและลดน้ำหนักได้ โดยเน้นการลดความหนาของผิว เพิ่มประสิทธิภาพโครงสร้างภายในโดยใช้โครงสร้างย่อยอื่น เช่น Stringers ตามแบบโครงสร้างแบบกึ่งไร้โครง Semi-Monocoque และเปลี่ยนรูปแบบคานปีกจาก C-Section เป็นแบบ I-beam ซึ่งได้มีการวิเคราะห์เบื้องต้นด้วย FEA ดังแสดงในรูปที่ 24 และโครงสร้างปีกภายในของทั้งสองแบบ แสดงในรูปที่ 25 พร้อมผลการคำนวณที่ขนาดภาระกรรม 2,000 นิวตัน ในตารางที่ 6





รูปที่ 23 การสำรวจความเสียหายของโครงสร้างปีก (แผนแบบเดิม) หลังการทดสอบ


การดำเนินการขึ้นรูปโครงสร้างปีกตามแผนแบบใหม่ โดยรูปที่ 26 แสดงโครงสร้างภายในและสามารถสรุปน้ำหนักของปีกตามแผนแบบใหม่เท่ากับ 16 กิโลกรัม ซึ่งปีกตามแผนแบบเดิม มีน้ำหนัก 26 กิโลกรัม

ตารางที่ 4 เปรียบเทียบแผนแบบโครงสร้างปีกแผนแบบเดิมและแผนแบบใหม่


แผนแบบเดิม	แผนแบบใหม่
9 Ribs (Half-Wing)	10 Ribs (Half-Wing)
C-Section Spar	I-Beam Spar
No Stringers	Carbon Roving Stringers
Foam/Carbon Outer Spar	Carbon/Plywood Outer Spar
80 cm Tube	40 cm Tube
10-12 Layered Skin	6-8 Layered Skin
PVC Core Mat	Kevlar Nomex Honeycomb

ตารางที่ 5 เปรียบเทียบแผนแบบวางผ้าเส้นใยของชั้นวัสดุของผิวปีกและคานปีก

	Centrewing skin	Outer Wing skin	Centerwing's Main Spar
Original design	top 1x Glass 45° 100 g/m ² 1x Carbon 45° 200 g/m ² 3x Carbon 45° 200 g/m ² 1x Carbon 90° 200 g/m ² Foam 4 mm 2x Carbon 90° 200 g/m ² 1x Glass 160 g/m ²	top 1x Glass 45° 80 g/m ² 4x Carbon 45° 200 g/m ² 3x Carbon 90° 200 g/m ² Foam 2 mm 2x Carbon 90° 200 g/m ² 1x Glass 45° 80 g/m ²	 1x Glass 45° 80 g/m ² 3x Carbon 45° 200 g/m ² 12x Carbon UD 2x Carbon 45° 200 g/m ² 3x Carbon 45° 200 g/m ² 12x Carbon UD 3x Carbon 45° 200 g/m ² 1x Glass 45° 80 g/m ²
	bottom	bottom	
New design	top 1x Glass 90° 50 g/m ² 3x Carbon 45° 100 g/m ² 3x Carbon 45° 100 g/m ² Honeycomb 2 mm	top 1x Glass 90° 50 g/m ² 2x Carbon 40° 100 g/m ² Honeycomb 2 mm 2x Carbon 45° 100 g/m ²	 22x Carbon UD 200 6x Glass 15° 200 g/m ² 18x Carbon UD 200
	bottom	bottom	



รูปที่ 24 การวิเคราะห์โครงสร้างคานปีกด้วย FEA แบบ C-section (ซ้าย) ตามแผนแบบเดิม และ I-beam (ขวา) ตามแผนแบบใหม่



รูปที่ 25 แผนแบบโครงสร้างปีก ตามแผนแบบเดิม (ซ้าย) และแผนแบบใหม่ (ขวา)

ตารางที่ 6 ผลคำนวณ FEA เพื่อเปรียบเทียบคานปีก

Numerical Result	C-Section Spar	I-Beam Spar
Maximum Displacement	16.3 mm	4.2 mm
Maximum Von Mises Stress	95 MPa	35 MPa




รูปที่ 26 การขึ้นรูปโครงสร้างปีก (แผนแบบใหม่)

4.4 การยืนยันความสมควรitenอากาศของโครงสร้างปีก (แผนแบบใหม่)

ทำการคำนวณวิเคราะห์ด้วยคณิตศาสตร์ (Analytical Method) และการใช้เทคนิค FEA โดยมุ่งเปรียบเทียบผลของระยะขจัดที่ปลายปีกเมื่อมีขนาดภาระกรรมต่าง ๆ มากกระทำและทำการทดสอบปีกด้วยถ่วงทราย นำผลวิเคราะห์เพื่อยืนยันความน่าเชื่อถือ (Cross-Validation) ตามรูปที่ 27

จะเห็นว่าให้ผลตัวเลขที่ใกล้เคียงกันไม่เกินร้อยละ 15 ใกล้เคียงกับกรณีแผนแบบเดิม เมื่อได้ตรวจสอบผลของค่าความเค้น (Von Mises Stress) จากการคำนวณด้วย FEA ณ จุดวิกฤต คือ บริเวณรอยต่อระหว่างปีกกลางและปีกนอก โดยเกิดความเค้นขึ้นมากกว่า 600 เมกะปาสคาล ตามรูปที่ 28 ซึ่งเกินจุด Ultimate Strength ของวัสดุ และให้ผลการทดสอบด้วยถ่วงทรายในทำนองเดียวกันตามรูปที่ 29 สามารถสรุปได้ว่าความแข็งแรงสูงสุด (Ultimate Load)




รูปที่ 27 เปรียบเทียบระยะขจัดที่ปลายปีก (แผนแบบใหม่) ณ ขนาดภาระกรรมต่าง ๆ

ของโครงสร้างปีกตามแผนแบบใหม่มีค่าเท่ากับ 660 กิโลกรัม หรือคิดเป็นอัตราส่วนภาระกรรม (Load Factor) เท่ากับ 5.32 เท่าของน้ำหนักอากาศยาน และสามารถลดน้ำหนักได้ถึงร้อยละ 38 มีความแข็งแรงต่อน้ำหนักมากขึ้นร้อยละ 19

5. สรุปผลและข้อเสนอแนะ

5.1 สรุปผล

จากการทดสอบ Sandbag Testing กับโครงสร้างปีก ไทเกอร์ชาร์ก 2 ตามแผนแบบเดิม ซึ่งมีน้ำหนัก 26 กิโลกรัม โดยอ้างอิงเกณฑ์การทดสอบจากมาตรฐานสากล (STANAG 4671) พบว่า โครงสร้างปีกรองรับภาระกรรมสูงสุดได้ 900 กิโลกรัม คิดเป็นอัตราส่วนภาระกรรม เท่ากับ 7.23 เท่าของ น้ำหนักอากาศยาน และความแข็งแรงต่อน้ำหนัก (Strength-to-Weight Ratio) เท่ากับ 34.6 โดยผลการทดสอบดังกล่าวสามารถยืนยันได้จากการคำนวณด้วยหลักโครงสร้างอากาศยานและการคำนวณด้วย Finite Element Analysis จึงสามารถสรุปได้ว่า โครงสร้างตามแผนแบบเดิมมีน้ำหนักมากเกินไปจนเกินความจำเป็น (Oversized Structures) สมควรที่จะต้องมีการพัฒนาแผนแบบเพื่อลดน้ำหนักและมีความแข็งแรงผ่านเกณฑ์ขั้นต่ำ (Proof Load) ตามมาตรฐานสากล



รูปที่ 28 แสดงผลการคำนวณ FEA ของโครงสร้างปีก (แผนแบบใหม่) ณ จุดวิกฤตบริเวณรอยต่อระหว่างปีกกลางและปีกนอก ที่ขนาดภาระกรรม 660 กิโลกรัม



รูปที่ 29 การทดสอบปีก (แผนแบบใหม่) ด้วยถุงทราย

ในการปรับปรุงและพัฒนาแผนแบบ โครงสร้างปีกไทเกอร์ชาร์ก 2 เพื่อลดน้ำหนักนั้น ได้ทำการเปลี่ยนแปลงโครงสร้างและองค์ประกอบ ภายในใหม่ทั้งหมดโดยอาศัยแนวทางของโครงสร้างแบบกึ่งไร้โครง Semi-Monocoque มุ่งเน้นทำให้ ผิวบางลง แต่โครงสร้างภายในหลัก เช่น โครงรับ (Ribs) แขนปีกหลัก (Spars) แถบยาว (Stringers) มีความแข็งแรงมากขึ้น เมื่อทำการขึ้นรูป มีน้ำหนักรวม 16 กิโลกรัม ซึ่งน้อยกว่าแผนแบบเดิมได้ถึงร้อยละ 38 โดยส่วนใหญ่เป็นผลมาจากการลดชั้นผิวของผ้าไฟเบอร์ เมื่อทำการทดสอบ พบว่า มีความแข็งแรงผ่านตาม มาตรฐานเกณฑ์ยืนยันภาระกรรม (Proof Load Factor)

ที่ 4.37 เท่าของน้ำหนักอากาศยาน โดยมีความแข็งแรงสูงสุด เท่ากับ 5.32 เท่าของน้ำหนักอากาศยาน คิดเป็นความแข็งแรงต่อน้ำหนัก เท่ากับ 41.3 ซึ่งมากกว่าโครงสร้างเดิมอยู่ร้อยละ 19

5.2 ข้อเสนอแนะ

งานวิจัยนี้ควรมีการตรวจสอบโดยไม่ทำลาย (Non-Destructive Inspection) เพื่อยืนยันความเสียหายที่เกิดขึ้นควบคู่ไปกับการทดสอบปีก เพื่อเพิ่มความน่าเชื่อถือในการประเมินความแข็งแรง และควรทำการศึกษาต่อยอด เพื่อขยายผลเป็นการทดสอบแบบพลวัต (Dynamic Wing Testing) หรือ ความล้า (Fatigue Testing) และเพื่อนำมาปรับใช้กับโครงการวิจัยพัฒนาอากาศยานไร้คนขับในอนาคต

6. เอกสารอ้างอิง

- [1] J. E. Mayer. “State of the Art of Airworthiness Certification.” STO.NATO.int. https://www.sto.nato.int/publications/STO_Meeting_Proceedings/STO-MP-AVT-273/MP-AVT-273-08.pdf (accessed Jan. 5, 2020).
- [2] J. D. Anderson, *Fundamentals of Aerodynamics*, 4th ed. Singapore: McGraw-Hill, 2007.
- [3] S. D. Lannoy. “Wing Bending Calculation with a Single Set of Equations.” WINGBIKE.nl. http://www.wingbike.nl/Wingbike_ydrofoil/Background_files/Wing_Deflection.pdf (accessed Jan. 20, 2020).
- [4] R. H. Gallagher, *Finite Element Analysis: Fundamentals*. Englewood Cliffs, NJ,

USA: Prentice-Hall, 1975.

- [5] ส. ชื่นอารมย์, “โครงการสร้างลำตัวอากาศยานด้วยวัสดุผสม,” ศวอ.ทอ., กรุงเทพฯ, ไทย, 2016.
- [6] D. Gay, *Composite Materials: Design and Applications*, Florida, USA: CRC Press, 2015.
- [7] T. H. G. Megson, *Aircraft Structures for Engineering Students*, 4th ed. Oxford, UK: Butterworth-Heinemann, 2007.
- [8] *Femap 12.0*. (2018), Siemens Product Lifecycle Management Software. Accessed: Feb 14, 2020. [Software]. Available: <https://www.siemens.com>

การเปรียบเทียบโมเดลตรวจจับวัตถุด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันในงานภาพถ่ายทางอากาศจากอากาศยานไร้คนขับ

กิตตากร วิริยะศาสตร์^{1,2*} วรากร เลื่องลือภูมิ¹ ปิยะรส มาลีเจริญ¹ สิริภาพ สันติรัตนรงค์¹
วิชัย แผ้วเกษม¹ พันธุ์เทพ แก้วมงคล¹ สัญญา มิตรเอม² และ พันศักดิ์ เทียนวิบูลย์³

วันที่รับ 19 มีนาคม 2567 วันที่แก้ไข 19 เมษายน 2567 วันที่ตอบรับ 25 เมษายน 2567

บทคัดย่อ

ในบทความวิจัยนี้ได้ทำการศึกษาการเปรียบเทียบโมเดลตรวจจับวัตถุด้วยโครงข่ายประสาทเทียมที่ใช้ในงานภาพถ่ายทางอากาศที่ได้จากอากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) โดยได้ทำการตรวจจับวัตถุสองชนิด คือ สิ่งก่อสร้างและยานพาหนะ ทั้งนี้ อาศัยโมเดลการเรียนรู้ของเครื่อง (Machine Learning) ในการตรวจจับวัตถุ (Object Detection) โดยใช้โมเดลต่าง ๆ เพื่อหาว่ามีข้อดีข้อเสียแตกต่างกันอย่างไร ผ่านโมเดลที่ใช้เปรียบเทียบดังนี้ Faster R-CNN, MobileNetv1, Retinanet50, YOLOv4, YOLOv4-tiny, YOLOv7, EfficientDet ซึ่งจากการทดลองครั้งนี้ พบว่า YOLOv7 มีความแม่นยำในการตรวจจับ 58.5% ซึ่งมากกว่า MobileNetv1, YOLOv4, Faster R-CNN, YOLOv4-tiny, EfficientDet และ Retinanet50 ที่ 49.5%, 45.1%, 21.2%, 17.6%, 14.5%, 1.2% ตามลำดับ โมเดลที่มีความเร็วสูงสุดคือ MobileNetv1 มีความเร็วถึง 196.01 เฟรมต่อวินาที ซึ่งเป็นความแม่นยำและความเร็วที่เพียงพอต่องานตรวจจับวัตถุในงานภาพถ่ายทางอากาศจากอากาศยานไร้คนขับ

คำสำคัญ : การเรียนรู้ของเครื่อง, โครงข่ายประสาทเทียม, การตรวจจับวัตถุ, คอมพิวเตอร์วิทัศน์, ภาพถ่ายทางอากาศ

¹ ฝ่ายวิจัยและพัฒนา, สถาบันเทคโนโลยีป้องกันประเทศ

² ภาควิชาวิศวกรรมไฟฟ้าและคอมพิวเตอร์, คณะวิศวกรรมศาสตร์, มหาวิทยาลัยธรรมศาสตร์

³ ภาควิชาวิศวกรรมไฟฟ้า, คณะวิศวกรรมศาสตร์, มหาวิทยาลัยเกษตรศาสตร์

* ผู้แต่ง, อีเมล: kittakorn.v@dti.or.th

Comparison of Object Detection Models using Convolutional Neural Networks in Aerial Image from Unmanned Aerial Vehicles

Kittakorn Viriyasatr^{1,2*} Warakorn luangluewut¹ Piyarose Maleecharoen¹ Siraphob Santironnarong¹
Wichai Pawgasame¹ Pantape Kaewmongkol¹ Sanya Mitaim² and Phunsak Thiennviboon³

Received 19 March 2024, Revised 19 April 2024, Accepted 25 April 2024

Abstract

This research article studies and compares various models used for object detection in aerial imagery captured by Unmanned Aerial Vehicle (UAV). Two types of objects are detected: buildings and vehicles. Machine learning models are used for object detection, and various models are compared to identify their advantages and disadvantages. The following models are compared: Faster R-CNN, MobileNetv1, Retinanet50, YOLOV4, YOLOV4-tiny, YOLOv7, and EfficientDet. The experiments found that YOLOV7 achieved the highest detection accuracy of 58.5%, outperforming MobileNetv1, YOLOV4, Faster R-CNN, YOLOV-tiny, EfficientDet, and Retinanet50, which achieved accuracies of 49.5%, 45.1%, 21.2%, 17.6%, 14.5%, and 1.2%, respectively. The model with the highest speed was MobileNetv1, which achieved a speed of 196.01 frames per second. This accuracy and speed are sufficient for object detection tasks in aerial image from Unmanned Aerial Vehicle.

Keywords : Machine learning, Neural networks, Object detection, Computer vision, Aerial image

¹ Research & Development Department, Defence Technology Institute

² Department of Electrical and Computer Engineering, Faculty of Engineering, Thammasat University

³ Department of Electrical Engineering, Faculty of Engineering, Kasetsart University

* Corresponding author, E-mail : kittakorn.v@dti.or.th

1. บทนำ

อากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) สามารถนำมาใช้งานได้หลากหลายในการเฝ้าระวังและสำรวจพื้นที่โดยค้นหาสถานที่ขนาดใหญ่และการเข้าถึงพื้นที่ที่เข้าถึงได้ยากอย่างละเอียด ตัวอย่างเช่น สนามทดสอบระยะจะต้องใช้เวลาโดยประมาณ 1-2 สัปดาห์ในการสำรวจอย่างละเอียดด้วยการเดินเท้า ความยืดหยุ่นของอากาศยานไร้คนขับช่วยให้การใช้งานรวดเร็วและคุ้มค่า นอกจากนี้ การสำรวจด้วยการเดินเท้ายังค่อนข้างอันตรายในสนามทดสอบระยะ เนื่องจากมีเศษซากวัตถุระเบิดที่ยังไม่ปลอดภัยจากจรวด ดังนั้น อากาศยานไร้คนขับจะช่วยลดความเสี่ยงต่อชีวิตมนุษย์ เนื่องจากสามารถเข้าสู่สนามได้โดยไม่ต้องเสี่ยงต่อทีมงาน ในแง่ของการรวบรวมข้อมูล อากาศยานไร้คนขับที่ติดตั้งกล้องความละเอียดสูงสามารถรวบรวมภาพจำนวนมากได้แบบตามเวลาจริง (Real-time) ช่วยในการตัดสินใจและวิเคราะห์ภาพทางอากาศที่ได้จากอากาศยานไร้คนขับที่บินเหนือสนามทดสอบระยะ ให้ภาพรวมของพื้นที่สามารถใช้ภาพเหล่านั้นเพื่อพิจารณาว่าพื้นที่นั้นปลอดภัยและพร้อมสำหรับการทดสอบระยะพื้นที่ได้รับการพิสูจน์ว่าปลอดภัยเมื่อไม่มีสัญญาณของสิ่งก่อสร้างหรือที่พักอาศัยและยานพาหนะในภาพถ่ายทางอากาศ

วิธีนี้สามารถวิเคราะห์ได้ด้วยมนุษย์แต่ต้องใช้เวลามากในการวิเคราะห์พื้นที่ทั้งหมดอย่างละเอียด คอมพิวเตอร์วิทัศน์ที่เรียกว่า การตรวจจับวัตถุ (Object Detection) ควรใช้เพื่อระบุตำแหน่งวัตถุเป้าหมายในภาพโดยอัตโนมัติ ซึ่งความก้าวหน้าของปัญญาประดิษฐ์ (AI) เฉพาะ Convolutional Neural Networks (CNN) [1] ช่วยยกระดับ

ประสิทธิภาพของงานตรวจจับวัตถุอย่างต่อเนื่องตลอดหลายปีเมื่อเปรียบเทียบกับวิธีการตรวจจับวัตถุแบบเดิมที่ใช้คุณสมบัติที่ออกแบบเองโดยใช้มือและสายตาของมนุษย์ เช่น SIFT [2], SURF [3] และ HOG [4] วิธีการตรวจจับวัตถุที่ใช้ CNN มีข้อดีหลายด้านในส่วนของประสิทธิภาพการคำนวณ ความแม่นยำ ความทนทานและความเร็ว ทำให้โมเดลที่ใช้ CNN กลายเป็นเครื่องมือที่ใช้งานได้จริงในการตรวจจับวัตถุ ซึ่งในปัจจุบันมีโมเดลตรวจจับวัตถุที่ใช้ CNN แบบใหม่หลายรุ่น ซึ่งแต่ละรุ่นมีโครงสร้างที่แตกต่างกัน

ในงานวิจัยนี้ได้ทำการศึกษาโมเดลต่าง ๆ ที่ใช้ในงานตรวจจับวัตถุในแบบต่าง ๆ เช่น R-CNN, SSD, Retinanet, YOLO, EfficientDet ว่ามีข้อดีข้อเสียแตกต่างกันอย่างไรและโมเดลใดเหมาะสมกับงานภาพถ่ายทางอากาศ (Aerial Image) มากที่สุด งานวิจัยนี้แตกต่างจากงานวิจัยอื่น ทั้งนี้ ข้อมูลภาพถ่ายทางอากาศเป็นภาพถ่ายที่ไม่จำกัดมุมมองและความสูงของภาพถ่ายทางอากาศจากอากาศยานไร้คนขับ ซึ่งเป็นภาพถ่ายทางภูมิประเทศของไทยที่มีรูปทรงอาคารหรือยานพาหนะแตกต่างกัน

2. ทฤษฎีที่เกี่ยวข้อง

2.1 Object Detection in Aerial Images

การตรวจจับวัตถุในภาพถ่ายทางอากาศเป็นเทคนิคที่มีประโยชน์สำหรับกรณีวิเคราะห์ภาพถ่ายทางอากาศ เนื่องจากเทคนิคนี้สามารถจำแนกและระบุตำแหน่งของวัตถุต่าง ๆ ภายในภาพได้ ข้อมูลที่ได้จากการตรวจจับวัตถุสามารถนำไปใช้จำแนกและนับจำนวนอาคาร ถนน และสิ่งก่อสร้างอื่น ๆ ภายในเขตเมือง เพื่อติดตามการขยายตัวของพื้นที่เมืองและดูผลกระทบต่อสิ่งแวดล้อม โดยงานวิจัย

W. Pei *et al.* [5] ได้ใช้การวิเคราะห์ภาพเชิงวัตถุเพื่อระบุการขยายตัวของเมืองและการเปลี่ยนแปลงของสภาพแวดล้อมในพื้นที่ทำเหมืองถ่านหิน Y. Liu *et al.* [6] ใช้การวิเคราะห์การเปลี่ยนแปลงของวัตถุเพื่อศึกษาผลกระทบของการขยายตัวของเหมือง

การตรวจจับวัตถุในภาพถ่ายทางอากาศยังสามารถประยุกต์ใช้ในการติดตามสัตว์ป่าในถิ่นที่อยู่อาศัยตามธรรมชาติ ช่วยให้ให้นักวิจัยวางแผนการอนุรักษ์ได้ ดังตัวอย่างงานวิจัย [7] - [8] เทคนิคนี้ยังมีบทบาทสำคัญในการตรวจสอบป่าไม้ เนื่องจากการช่วยในการวัดลักษณะของป่าไม้ เช่น ความหนาแน่นของต้นไม้ การกระจายพันธุ์ของต้นไม้ และโครงสร้างของป่าไม้ ทั้งนี้ การระบุและนับจำนวนต้นไม้ภายในภาพถ่ายทางอากาศที่ถ่ายครอบคลุมพื้นที่ป่า [9] - [10] เทคนิคนี้ยังช่วยป้องกันไฟไหม้ [11] และการตัดไม้ทำลายป่า [12] การตรวจสอบภัยพิบัติสามารถใช้ประโยชน์จากการประเมินและระบุพื้นที่เสียหายที่ต้องการความช่วยเหลืออย่างรวดเร็ว ซึ่งได้มาจากการตรวจจับวัตถุในภาพถ่ายทางอากาศ [13] การตรวจจับวัตถุในภาพถ่ายทางอากาศต้องเผชิญกับความท้าทายที่เกี่ยวข้องกับความแปรปรวนของภาพขนาดใหญ่และมุมมองของภาพถ่ายทางอากาศ ความแม่นยำของการตรวจจับวัตถุขึ้นอยู่กับคุณภาพของภาพและประสิทธิภาพของอัลกอริทึมที่ใช้

แต่เดิมวิธีการตรวจจับวัตถุแบบดั้งเดิมอาศัยการออกแบบฟีเจอร์ด้วยมือ (Hand-crafted feature engineering) โดยฟีเจอร์ของภาพจะถูกออกแบบด้วยตนเองเพื่อแทนวัตถุในภาพ ฟีเจอร์เหล่านี้ถูกออกแบบมาเพื่อจับคุณลักษณะเฉพาะของวัตถุ เช่น รูปร่าง พื้นผิว หรือสี Scale Invariant Feature Transform (SIFT) [2] เป็นวิธีการสกัดฟีเจอร์ที่ใช้ในการอธิบายฟีเจอร์เฉพาะที่ในภาพ ฟีเจอร์ที่ SIFT อธิบายนั้นไม่แปรเปลี่ยนตามขนาดและการหมุน

รวมถึงการแปลงแบบ Affine Transformation ทำให้มีความยืดหยุ่นต่อการเปลี่ยนแปลงของมุมมองหรือแสงของวัตถุ Speeded-Up Robust Features (SURF) [3] ใช้สำหรับการตรวจจับจุดสำคัญ (Key point) ซึ่งสรุปลักษณะเฉพาะของวัตถุในภาพแบบ Local Appearance ส่วน Histogram of Oriented Gradient (HOG) [4] ใช้ฮิสโตแกรมของการไล่ระดับสี (Gradient) ในแต่ละช่องตารางของภาพ เพื่อสร้างเวกเตอร์ฟีเจอร์ที่แทนวัตถุ โดย HOG ถูกนำไปใช้กันอย่างแพร่หลายในการตรวจจับวัตถุแบบเดิมจนกระทั่งถูกแทนที่ด้วยวิธีการที่ใช้ CNN (Convolutional Neural Network) ในช่วงปีหลัง ๆ เนื่องด้วยความแม่นยำและประสิทธิภาพที่ดีกว่าแบบเดิม

วิธีการตรวจจับวัตถุแบบดั้งเดิมใช้การออกแบบฟีเจอร์ด้วยมือถูกแทนที่ด้วยวิธีการที่ใช้ CNN เนื่องจากมีข้อจำกัดด้านความแม่นยำและประสิทธิภาพในการคำนวณ วิธีการที่ใช้ CNN มีข้อดีหลายประการเหนือวิธีการแบบดั้งเดิม CNN สามารถเรียนรู้การเชื่อมโยงแบบแผนภาพ (Mapping) แบบต่อกัน (End-to-end) จากภาพที่ป้อนเข้าไปสู่ผลลัพธ์การตรวจจับวัตถุ นอกจากนี้ยังเหนือกว่าวิธีการแบบดั้งเดิมในแง่ของความแม่นยำและความเร็วในการตรวจจับวัตถุ ความแม่นยำหมายถึง ความสามารถของวิธีที่ให้การตรวจจับข้อมูลที่ถูกต้องกับสิ่งที่สนใจในภาพ ความเร็ว หมายถึง ระยะเวลาในการประมวลผลภาพยังมีค่าน้อยลงยิ่งดีในวิธีการนั้น ๆ

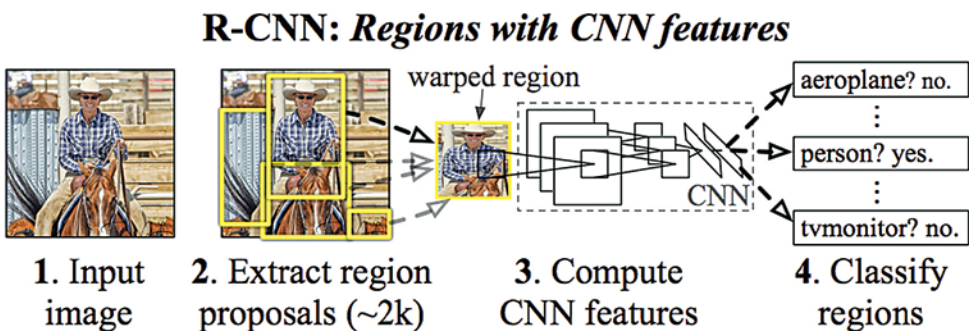
2.2 Regions with Convolutional Neural Network Features (R-CNN)

พัฒนาการของการตรวจจับวัตถุโดยใช้ CNN ในยุคแรกอาศัย Region Based Convolutional

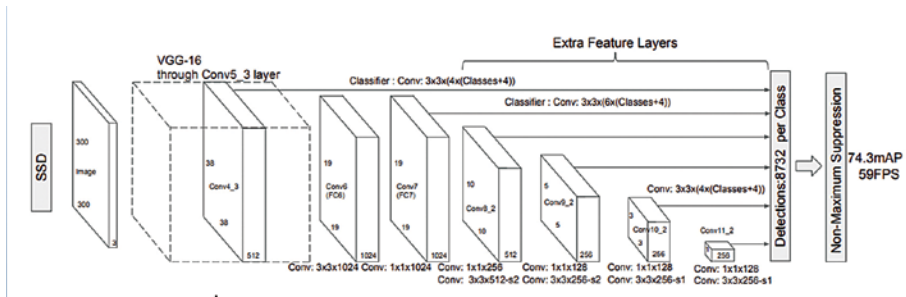
Neural Networks (R-CNN) ตามที่ R. Girshick *et al.* [14] เสนอ R-CNN เป็นวิธีการตรวจจับวัตถุแบบสองขั้นตอน ผ่านการค้นหาชุดของบริเวณที่เป็นไปได้ (Candidate regions) ก่อนที่จะจำแนกบริเวณเหล่านั้นเป็นคลาสของวัตถุที่ต่างกัน และปรับแต่งกรอบ (Bounding boxes) ของวัตถุ R-CNN มีข้อเสีย คือ ใช้ทรัพยากรในการคำนวณสูง เนื่องจากต้องใช้การสกัดพีเจอร์ด้วย CNN สำหรับแต่ละบริเวณที่เป็นไปได้ มีการพัฒนาต่อยอดจาก R-CNN หลายรูปแบบเพื่อปรับปรุงประสิทธิภาพการคำนวณ จาก Fast R-CNN ซึ่งเสนอ โดย R. Girshick *et al.* [15] ช่วยปรับปรุงประสิทธิภาพการคำนวณให้ดีขึ้นกว่า R-CNN แบบเดิม ด้วยการใช้ CNN เพียงตัวเดียวในการสกัดพีเจอร์จากทั้งภาพแทนที่การแยกพีเจอร์สำหรับแต่ละบริเวณที่เป็นไปได้ ซึ่ง Faster R-CNN [16] พัฒนาต่อยอดจาก Fast R-CNN ด้วยการนำเสนอ Region Proposal Network (RPN) เพื่อสร้างบริเวณที่เป็นไปได้ภายในภาพ ช่วยลดความจำเป็นในการใช้ Selective Search และลดการคำนวณของโมเดล ตัวอย่างโมเดล R-CNN ดังแสดงในรูปที่ 1

2.3 Single-Shot MultiBox Detection (SSD)

การพัฒนาโมเดลถัดมา คือ การตรวจจับวัตถุแบบ Single-Shot MultiBox Detection (SSD) [17] ซึ่งเป็นวิธีการแบบขั้นตอนเดียว (One-Step) ที่มุ่งเน้นการตรวจจับวัตถุในภาพด้วยขั้นตอนเดียว โดย SSD ไม่ต้องใช้ขั้นตอนการค้นหาบริเวณที่เป็นไปได้ของ R-CNN เนื่องจาก SSD ใช้ CNN เพียงขั้นตอนเดียวในการทำนายทั้งความน่าจะเป็นของคลาสวัตถุและกรอบ (Bounding boxes) สำหรับชุดของกรอบยึด (Anchor box) ที่ครอบคลุมทั้งภาพผ่านกรอบยึดเหล่านี้จะถูกกำหนดขึ้นจากอัตราส่วนภาพ (Aspect ratio) โดยอัตราส่วนภาพประกอบด้วย ความกว้าง (แนวนอน) และความสูง (แนวตั้ง) ของภาพ ทั้งนี้เลขทั้งสองตัวจะถูกคูณด้วยเครื่องหมาย (:) เช่น 3:2 คือ ภาพนั้นมีความกว้าง 3 ส่วน และความสูง 2 ส่วน เป็นต้น และสเกลของวัตถุในข้อมูลชุดฝึก (Training set) ใช้เป็นจุดยึดในการทำนายกรอบของวัตถุ โดย SSD ใช้ CNN หลายชั้นที่ทำงานกับความละเอียดของภาพที่ต่างกัน (multi-resolution CNN layers) ซึ่งแต่ละชั้นสามารถดึงพีเจอร์จากภาพที่ความละเอียดต่าง ๆ โครงสร้างแบบนี้เรียกว่าปริมาตรพีเจอร์ลำดับชั้น



รูปที่ 1 ตัวอย่างโมเดล Regions with Convolutional Neural Network Features (R-CNN) [14]



รูปที่ 2 ตัวอย่างโมเดล Single-Shot MultiBox Detection (SSD) [17]

(Pyramidal feature hierarchy) อย่างไรก็ตาม ชั้น CNN ที่มีความละเอียดต่ำไม่สามารถนำพีเจอร์จากชั้นความละเอียดสูงมาใช้ซ้ำได้ ด้วยโครงสร้างแบบนี้ทำให้ SSD รุ่นแรก [17] อาจไม่สามารถตรวจจับวัตถุขนาดเล็กได้ T. - Y. Lin *et al.* [18] ได้แก้ไขพร้อมทั้งปรับปรุงด้วย Feature Pyramid Network (FPN) เพื่อปรับปรุงประสิทธิภาพในการตรวจจับวัตถุหลายขนาดของ SSD โครงสร้างของ FPN ช่วยให้สามารถรวมพีเจอร์ความละเอียดต่ำเข้ากับพีเจอร์ความละเอียดสูงได้และแก้ไขปัญหาความแปรปรวนของขนาดวัตถุในการตรวจจับได้ โดยโมเดล SSD ดังแสดงในรูปที่ 2

2.4 RetinaNet

โมเดลนี้ได้พัฒนามาจากปัญหาความไม่สมดุลของคลาส (Class imbalance) ในการตรวจจับวัตถุ หมายถึง สถานการณ์ที่จำนวนตัวอย่างของบางคลาสของวัตถุที่สนใจ อาจมีมากกว่าคลาสอื่น ๆ อย่างมากหรือบริเวณส่วนใหญ่ของภาพไม่มีวัตถุอยู่เลย ปัญหานี้ส่งผลต่อการตรวจจับวัตถุ เนื่องจากโมเดลอาจมีความเอนเอียงไปทางคลาสที่มีจำนวนมากและอาจตรวจจับวัตถุในคลาสที่มีจำนวนน้อยผิดพลาดได้ ซึ่งโมเดลนี้จะมาแก้ปัญหาความไม่สมดุลของคลาสโดยบทความนี้มี 2 คลาส คือ ยานพาหนะและสิ่งก่อสร้าง

สำหรับภาพถ่ายทางอากาศที่ถ่ายครอบคลุมพื้นที่กว้างมักจะพบว่ามีเพียงวัตถุประปรายและอาจมีบางภาพที่ไม่มีวัตถุเลย ดังนั้น โมเดลตรวจจับวัตถุที่ใช้กับภาพถ่ายทางอากาศเหล่านี้อาจมีประสิทธิภาพต่ำในการตรวจจับวัตถุที่น่าสนใจ ซึ่งอยู่ในกลุ่มที่มีจำนวนน้อยกว่า ตัวอย่างเช่น T. - Y. Lin *et al.* [19] จุดเด่นสำคัญของ RetinaNet คือ ฟังก์ชันการสูญเสีย (Loss function) รูปแบบใหม่ที่เรียกว่า Focal Loss for Dense Object Detection หรือเรียกสั้น ๆ คือ Focal Loss ดังสมการที่ (1) ซึ่งช่วยแก้ปัญหาความไม่สมดุลของคลาสในการตรวจจับวัตถุ ฟังก์ชัน Focal Loss กำหนดน้ำหนักให้กับแต่ละตัวอย่างใน Training สำหรับข้อมูลตามคลาสของวัตถุ คือ คลาสที่มีจำนวนมากจะได้รับน้ำหนักน้อยกว่าคลาสที่มีจำนวนน้อยกว่า เพื่อปรับฐานให้ใกล้เคียงกันและมีความสำคัญเท่า ๆ กันในแต่ละคลาส โดยตัวอย่างโมเดล RetinaNet ดังแสดงในรูปที่ 3

สมการ Focal Loss สามารถเขียนได้ดังนี้

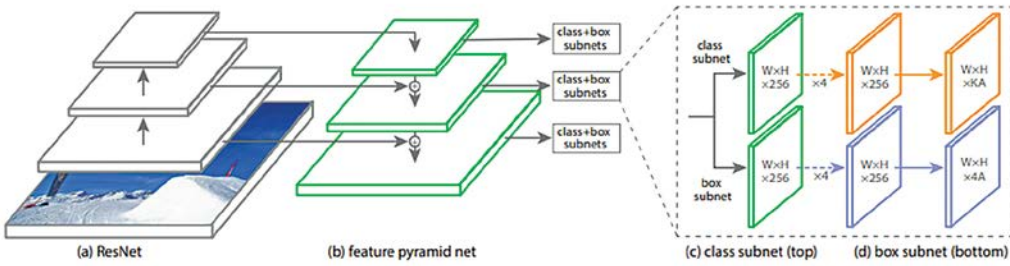
$$FL(p_t) = -\alpha_t(1 - p_t)^\gamma \log(p_t) \quad (1)$$

เมื่อ

p_t ความน่าจะเป็นที่ทำนายของคลาสที่เป็นจริง

α_t ตัวปรับสมดุลเพื่อแก้ไขปัญหาความไม่สมดุลของคลาส

γ พารามิเตอร์ในการเน้นที่ปรับการกระทำของความสูญเสีย



รูปที่ 3 ตัวอย่างโมเดล RetinaNet [19]

โดยส่วน $-\alpha_t (1-p_t)^\gamma$ เป็นตัวควบคุม พร้อมทั้ง γ ปรับอัตราที่ตัวอย่างที่ง่ายหรือมีจำนวนมาก ในคลาสนั้น ๆ ให้ลดน้ำหนักลง เมื่อ γ ถูกตั้งค่า เป็น 0 Focal Loss ก็จะเทียบเท่ากับความสูญเสีย ของ Cross-entropy โดยมาตรฐาน Cross-entropy (Standard Cross-entropy) ดังสมการที่ (2) เป็น ฟังก์ชัน Loss ที่ใช้ประเมินประสิทธิภาพของโมเดล สมการ Standard Cross-Entropy เขียนได้ ดังนี้

$$CE(y, \hat{y}) = - \sum_i y_i \log(\hat{y}_i) \quad (2)$$

เมื่อ

y คือ ค่าเป้าหมาย (Ground truth) ของคลาสนั้น ที่ต้องการจำแนก


\hat{y} คือ ค่าทำนาย (Prediction) ที่ได้จากโมเดล

y_i และ \hat{y}_i คือ ค่าเป้าหมายและค่าทำนายของ คลาสที่ i

โดย Cross-entropy ใช้กำหนดค่า ความผิดพลาดระหว่างการทำนายและค่าเป้าหมาย ซึ่งมีลักษณะที่จะให้ค่าความผิดพลาดมากขึ้นเมื่อค่า ทำนายแตกต่างจากค่าเป้าหมายมากขึ้นและให้ค่า ความผิดพลาดน้อยลงเมื่อค่าทำนายใกล้เคียงค่า เป้าหมายมากขึ้น

2.5 You Only Look Once (YOLO)

การประยุกต์ใช้งานที่ต้องการการตัดสินใจ แบบตามเวลาจริง (Real-time) หรือในช่วงเวลานั้น ๆ ความเร็วในการตรวจจับวัตถุเป็นสิ่งสำคัญ เช่น ในการติดตามทางอากาศ ซึ่งใช้ภาพถ่ายทางอากาศ ที่ถ่ายด้วยความเร็วสูง ยิ่งโมเดลตรวจจับวัตถุสามารถ ตรวจจับวัตถุได้เร็วเท่าใด การตัดสินใจที่ได้ก็จะยิ่ง น่าเชื่อถือมากขึ้น ในงานวิจัย J. Redmon *et al.* [20] เสนอโมเดลตรวจจับวัตถุแบบ One-Shot ที่ทันสมัย เรียกว่า You Only Look Once (YOLO) ซึ่งมุ่งเน้น การแก้ไขปัญหาความเร็วในการตรวจจับ YOLO แบ่งภาพที่ป้อนเข้าเป็นตารางกริดที่มีขนาดเท่ากัน โดยใช้ CNN เพียงตัวเดียวในการทำนายความน่าจะเป็น คลาส ของวัตถุและกรอบ (Bounding boxes) ของวัตถุ ในแต่ละกริด (Grid cell) ต่างจาก SSD โดย YOLO ใช้ กรอบยึด (Anchor box) ที่กำหนดไว้ล่วงหน้า ซึ่งมี ขนาดและอัตราส่วนภาพ (Aspect ratio) ที่ต่างกันเพื่อ ประมาณกรอบของวัตถุในภาพผ่านการกำหนดกรอบ ยึดไว้สำหรับแต่ละกริดตั้งแต่มีการนำเสนอ YOLO ใน [20] ได้มีการพัฒนาต่อยอดจากสถาปัตยกรรมของ YOLO ออกมาอีกหลายรูปแบบด้วย YOLOv4 [21] และ YOLOv7 [22] เป็นหนึ่งในสถาปัตยกรรมที่ได้รับความนิยมมากที่สุด นอกจากนี้ยังมี YOLOv4 และ YOLOv4-tiny เวอร์ชันที่เล็กและเร็วกว่า ใช้โครงสร้าง ที่ไม่ซับซ้อน ซึ่งรุ่นล่าสุดของ YOLO แสดงถึงการ



รูปที่ 4 ขั้นตอนการทำงานในการตรวจจับวัตถุของ YOLO [20]

ปรับปรุงที่สำคัญเหนือรุ่นก่อนหน้า ด้วยความแม่นยำที่สูงขึ้น ประสิทธิภาพที่ดีกว่า และมีพีเจอรที่ทันสมัยมากขึ้น ตัวอย่างโมเดล YOLO ดังแสดงในรูปที่ 4

2.6 EfficientDet


โมเดลการตรวจจับวัตถุในภาพถ่ายทางอากาศมักจะทำงานภายใต้ข้อจำกัดของทรัพยากรในการคำนวณ เช่น ระบบฝังตัวบนอากาศยานไร้คนขับ ขนาดของโมเดลส่งผลโดยตรงต่อปริมาณทรัพยากรในการคำนวณที่จำเป็นสำหรับการดำเนินการของโมเดลที่ใช้จริง ทั้งนี้ โดยทั่วไปแล้วโมเดลขนาดใหญ่ต้องการการประมวลผล หน่วยความจำ และพื้นที่จัดเก็บข้อมูลในจำนวนที่มากกว่าซึ่งอาจทำให้ไม่สามารถใช้งานบนระบบที่มีทรัพยากรจำกัดได้ ตัวอย่างเช่น เมื่อทำการติดตั้งที่อากาศยานไร้คนขับ ต้องทำให้ตัวอากาศยานไร้คนขับมีน้ำหนักเบาและใช้ตัวประมวลผลที่มีขนาดเล็กและขนาดตัวความจุขนาดเล็ก รวมถึงความร้อน จากในงานวิจัย M. Tan *et al.* [23] เสนอ EfficientDet ซึ่งมุ่งเน้นการแก้ไขประสิทธิภาพในการคำนวณของโมเดลตรวจจับวัตถุ EfficientDet ใช้แนวทางการปรับขนาดแบบผสม (Compound Scaling Approach) ตามที่ [24] เสนอไว้ในการปรับขนาด

ของโครงสร้างเครือข่าย ความละเอียดของภาพที่ป้อนเข้า และขนาดของชุดข้อมูล (Batch Size) อย่างพร้อมกัน เพื่อให้ได้ผลลัพธ์ที่ดีที่สุดระหว่างความแม่นยำและประสิทธิภาพ ตัวอย่างโมเดล EfficientDet ดังแสดงในรูปที่ 5

2.7 การตรวจจับวัตถุในภาพถ่ายทางอากาศด้วยเทคนิคโครงข่ายประสาทเทียม (Detecting Objects in Aerial photographs using Neural Network Techniques) [25]

ในงานวิจัยนี้ได้กล่าวถึงการนำโมเดลของ Objects Detection แต่ละโมเดลประกอบไปด้วย YOLO, RetinaNet และ Fast R-CNN ในการตรวจจับวัตถุ 2 อย่าง คือ สิ่งก่อสร้างและยานพาหนะ ซึ่งความน่าสนใจของงานวิจัยนี้ คือ โมเดล YOLO ที่เหมาะสมต่อกล้องของอากาศยานไร้คนขับที่มีความเร็วในการทำงานอยู่ที่ 25 เฟรมต่อวินาที โดย YOLO ในงานวิจัยที่กล่าวมานี้ให้ความเร็วและความแม่นยำในการตรวจจับวัตถุที่น่าสนใจของภาพขนาด 5472x3648 pixels ดังแสดงในรูปที่ 6

ทั้งนี้ เทคโนโลยีที่เกี่ยวข้องในแต่ละโมเดลใช้พีเจอรที่แตกต่างกันสรุปได้ดังตารางที่ 1



รูปที่ 5 ขั้นตอนการทำงานในการ ตรวจจับวัตถุของ EfficientDet [23]



รูปที่ 6 ภาพถ่ายทางอากาศมุมสูงโดยอากาศยานไร้คนขับขนาด 5472x3648 pixels (ภาพต้นฉบับ)



รูปที่ 7 Image With Dense Class Instances



รูปที่ 8 Image With Sparse Class Instances

ตารางที่ 1 แสดงการใช้ฟีเจอร์ที่แตกต่างกันในโมเดลต่าง ๆ

Model	Feature Extractor	Feature Detection	Feature Matching	Feature Descriptor
ResNet50	โครงข่าย CNN ที่มีความลึก (50 ชั้น)	ใช้ในการจำแนกภาพมากกว่าการตรวจจับวัตถุ	ไม่มีใน ResNet50 โดยตรง	คุณลักษณะภาพที่ได้ใช้ในการจำแนกภาพ
EfficientDet	EfficientNet	BiFPN (Bi-directional Feature Pyramid Network)	Non-maximum suppression (NMS)	ใช้คุณลักษณะจาก feature maps
YOLOv4	CSPDarknet53	แบ่งภาพเป็นกริดและตรวจจับวัตถุในแต่ละกริด	Non-maximum suppression (NMS)	ใช้คุณลักษณะจาก feature maps
YOLOv4-tiny	โครงข่ายที่เบากว่า YOLOv4	แบ่งภาพเป็นกริดและตรวจจับวัตถุในแต่ละกริด	Non-maximum suppression (NMS)	ใช้คุณลักษณะจาก feature maps
Faster R-CNN	ResNet50 หรือ VGG16	Region Proposal Network (RPN)	Non-maximum suppression (NMS)	ใช้คุณลักษณะจาก feature maps
MobileNetv1	โครงข่าย CNN ที่เบาและมีประสิทธิภาพ	ใช้ในการจำแนกภาพมากกว่าการตรวจจับวัตถุ	ไม่มีใน MobileNetv1 โดยตรง	คุณลักษณะภาพที่ได้ใช้ในการจำแนกภาพ
YOLOv7	YOLOv7-backbone	แบ่งภาพเป็นกริดและตรวจจับวัตถุในแต่ละกริด	Non-maximum suppression (NMS)	ใช้คุณลักษณะจาก feature maps

3. วิธีการดำเนินการ

3.1 วิธีการเทรนโมเดล

ข้อมูลที่ใช้เป็นภาพถ่ายทางอากาศที่ไม่จำกัดมุมมองและความสูงและองศาจากอากาศยานไร้คนขับขนาด 5472x3648 pixels (ภาพต้นฉบับ) อุปกรณ์ติดตั้งกล้องถ่ายภาพกลางวัน/กลางคืน (EO/IR Payload Camera System) รัศมีปฏิบัติการ 100 - 200 กิโลเมตร เพดานบินสูงสุด 10,000 ฟุต บนอากาศยานไร้คนขับ ซึ่งเป็นเพียงการนำภาพมาใช้ในการวิจัยเท่านั้นและนำมาทำ Objects labeling ผ่านการแบ่งคลาสออกเป็น 2 คลาส คือ สิ่งก่อสร้างและยานพาหนะ ซึ่งมีภาพทั้งหมด 730 ภาพ มีรูปภาพที่มีลักษณะแตกต่างกันดังนี้

1. กระจายแบบหนาแน่น มี 382 ภาพ ในแต่ละภาพจะมีวัตถุมากกว่า 10 วัตถุ ดังรูปที่ 7 (Image with Dense Class Instances) ซึ่งเป็นรูปที่มีคลาสที่สนใจอยู่มากกว่า 10 วัตถุในภาพ 1 ภาพ ตัวอย่าง เช่น จำนวนบ้านหรืออาคาร และจำนวนรถในภาพ 1 ภาพ นั่นคือ รูปภาพที่มีการปรากฏ

ของคลาสหรือวัตถุที่เราสนใจมีจำนวนมากในภาพนั้น ๆ

2. กระจายห่างกัน มี 294 ภาพ แต่ละภาพมีวัตถุน้อยกว่า 10 วัตถุ เช่น ในรูปที่ 8 (Image with Sparse Class Instances) ซึ่งเป็นตัวอย่างของรูปที่มีคลาสที่สนใจอยู่น้อยกว่า 10 วัตถุ ในภาพ 1 ภาพ เช่น จำนวนบ้าน หรืออาคาร หรือจำนวนรถในภาพ 1 ภาพ นั่นคือ รูปภาพที่มีการปรากฏของคลาสหรือวัตถุที่เราสนใจมีจำนวนน้อยในภาพนั้น ๆ

3. ไม่มีวัตถุที่สนใจตามคลาส มี 54 ภาพที่ไม่มีรถ หรือบ้าน หรืออาคารในภาพ นั่นคือรูปภาพที่ไม่มีมีการปรากฏของคลาสหรือวัตถุที่เราสนใจในภาพนั้น ๆ

สำหรับแต่ละคลาส ข้อมูลเหล่านี้แสดงถึงความไม่สมดุลระหว่างจำนวนของวัตถุที่ป้ายชื่อว่า 'ยานพาหนะ' และจำนวนของวัตถุที่ป้ายชื่อว่า 'อาคาร' ข้อมูลภาพทางอากาศมีมุมมองที่แตกต่างกันในแต่ละภาพ แต่มีขนาดที่เปลี่ยนแปลงไม่ได้เสมอ โมเดลการตรวจจับวัตถุที่ดีควรสามารถใช้งานได้

ทั้งในมุมมองที่ต่างกันและขนาดที่ต่างกัน โดยเพื่อแก้ไขปัญหานี้ ภาพทางอากาศขนาดเดิม 5472x3648 pixels ถูกเปลี่ยนขนาดใหม่เป็นขนาดที่ต่างกัน เช่น 4104x2736, 2736x1824 และ 1368x912 pixels

ซึ่งเครื่องมือที่ใช้ในการติดป้ายกำกับ (Label) คือ Computer Vision Annotation Tool (CVAT) สำหรับใช้ในการติกรอบของวัตถุที่สนใจในภาพ โดยทำการติกรอบตามรูปแบบของ YOLO หรือ PASCAL VOC2007 เพื่อใช้ Training จากนั้นรูปภาพทั้งหมดที่มีขนาดแตกต่างกันถูกผสมเข้าด้วยกันเป็นชุดข้อมูลเดียวกัน ภาพที่ไม่มีวัตถุจะถูกลบทิ้ง ดังนั้น ชุดข้อมูลหลายระดับจึงเหลืออยู่ 2,704 ภาพ ในการทดลองนี้ได้ Training Model บนชุดข้อมูล 2 ชุด ที่แตกต่างกัน โดยขั้นตอนทั้งหมดเป็นการเทรนโมเดลใหม่ตั้งแต่ต้น ดังนี้

• ชุดข้อมูลที่ 1 No scaling datasets

ถูกสร้างขึ้นโดยการครอบรูปภาพแต่ละรูปในชุดข้อมูลภาพทางอากาศขนาดเดิม 5472x3648 pixels (ทั้งนี้ไม่รวมภาพที่ไม่มีวัตถุ) ซึ่งใช้การครอบขนาด 912x912 pixels และเลือกตำแหน่งการครอบแบบสุ่ม (Randomly Crop) และหมุนภาพ ที่สุ่มองศาระหว่าง 0-90 องศา (Rotate Cropped Images) ข้อมูลนี้เรียกว่า "No scaling" มีภาพทั้งหมด 90,364 ภาพ ในชุดข้อมูล เหตุผลที่ใช้ขนาด 912x912 pixels เพื่อแบ่งภาพให้มีขนาดที่เหมาะสมในการเข้าโมเดล เพราะโมเดลไม่สามารถรับภาพขนาด 5472x3648 pixels ได้ จึงทำการปรับสเกลในชุดข้อมูลที่ 2

• ชุดข้อมูลที่ 2 Multi-scaling datasets

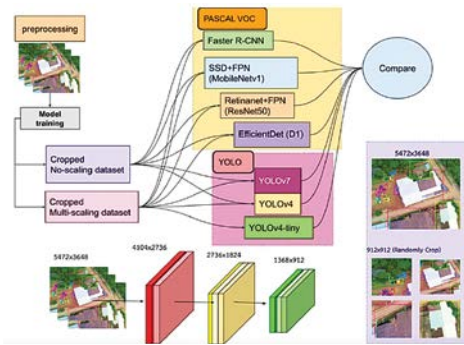
ถูกสร้างขึ้นด้วยกระบวนการเดียวกัน แต่บนชุดข้อมูลที่มีการเปลี่ยนขนาดหลายระดับ

(Rescale) ชุดข้อมูลนี้เรียกว่า "Multi-scaling" และมีภาพทั้งหมด 93,689 ภาพ


ผ่านการนำชุดข้อมูลที่ 1 และ 2 มาแบ่งเป็นส่วนสำหรับการฝึกโมเดล 80% ส่วนสำหรับการตรวจสอบความถูกต้อง 10% และส่วนสำหรับการทดสอบ 10% หลังจากนั้นในการเทรนโมเดลใช้โมเดลทั้งหมด 7 โมเดล ดังนี้ R-CNN, SSD, Retinanet, YOLOv4, YOLOv4tiny, YOLOv7 และ EfficientDet ข้อมูลภาพที่ติกรอบนั้นจะแยกเป็น 2 ประเภท คือ

1. ข้อมูลรูปแบบของ YOLO แต่ละภาพจะมีไฟล์ข้อความป้ายชื่อที่เชื่อมโยงอยู่ในไฟล์ข้อความป้ายชื่อแต่ละบรรทัดแสดงป้ายชื่อวัตถุในภาพ ป้ายชื่อวัตถุเป็นสตริงของค่าที่คั่นด้วยช่องว่างที่ระบุหมายเลขการระบุคลาสของวัตถุ พิกัดศูนย์กลางในแกนอนและตั้งของกล่องสำหรับโมเดล YOLOv4, YOLOv4-tiny และ YOLOv7

2. รูปแบบชื่อของ PASCAL VOC2007 แต่ละภาพจะมีเอกสาร XML ที่เชื่อมโยงโดเมน XML กำหนดแต่ละวัตถุในภาพด้วยแท็ก '<object>' แท็ก '<name>' ภายในแท็ก '<object>' ระบุชื่อของคลาสวัตถุ แท็ก '<bndbox>' ระบุพิกัดมุมบนซ้ายและมุมล่างขวาของกล่องค่า โดยไม่มีการปรับให้มีมาตรฐาน อาจใช้รูปแบบแท็กอย่างไรก็ได้ ใช้สำหรับโมเดล Faster R-CNN, MobileNetv1, ResNet50 และ EfficientDet (D1) แสดงในรูปแบบที่ 9 ขั้นตอน Training model จากนั้นนำ Weight ที่ได้จากโมเดลแต่ละโมเดลไปทำการทดสอบโมเดลว่าได้ผลลัพธ์อย่างไรและนำมาวิเคราะห์เปรียบเทียบกันว่าโมเดลทั้ง 7 โมเดล แตกต่างกันอย่างใดและเหมาะสมกับงานประเภทใด ดังแสดงในรูปแบบที่ 10



รูปที่ 9 ขั้นตอน Training model



รูปที่ 10 ตัวอย่างการทำงานที่ได้
จากโมเดล YOLOv4 ขนาด 5472x3648 pixels

3.2 วิธีการทดสอบโมเดล

บทความนี้ประเมินประสิทธิภาพของโมเดลตรวจจับวัตถุ (Objects Detection) โดยอาศัยเกณฑ์การวัด 3 ประเภท ได้แก่

3.2.1 ความแม่นยำ (Accuracy)

คือการวัดประสิทธิภาพของโมเดลในการระบุและกำหนดตำแหน่งของวัตถุในภาพได้อย่างถูกต้อง ซึ่งใช้กรอบสี่เหลี่ยม (Bounding Box) ประเมินผล ค่าความแม่นยำที่นิยมใช้ คือ ค่า mAP (Mean Average Precision) เป็นการรวมกันระหว่าง Precision ดังสมการที่ (3) วัดสัดส่วนของการตรวจจับวัตถุได้ถูกต้อง (True Positive) จากการตรวจจับทั้งหมด และ Recall ดังสมการที่ (4) วัดสัดส่วนของการตรวจจับวัตถุได้ถูกต้อง (True Positive) จากจำนวนวัตถุทั้งหมดที่มีจริงในภาพ การตรวจจับ

ถือว่าถูกต้อง เมื่อโมเดลระบุประเภทวัตถุได้ถูกต้อง มีคะแนนความมั่นใจ (Confidence Score) สูงกว่าเกณฑ์ที่กำหนด และมีค่า IoU (Intersection over Union) ระหว่างกรอบที่โมเดลระบุกับกรอบที่กำหนดไว้สำหรับวัตถุนั้น ๆ สูงกว่าเกณฑ์ที่กำหนด โดย Precision มีค่าระหว่าง 0 ถึง 1 ทั้งนี้ ค่ายิ่งมากยิ่งขึ้นดี เมื่อค่า Precision เข้าใกล้หรือเป็น 1 แสดงว่าระบบมีความแม่นยำมากในการระบุ Positive class หากมีน้อยมากของการทำนายผิดพลาดว่าเป็น Positive class แต่ถ้า Precision มีค่าเข้าใกล้หรือเป็น 0 แสดงว่า ระบบมีการทำนาย Positive class ผิดพลาดมาก ๆ ซึ่งมีการทำนายว่าเป็น Positive class มากเกินไปในสิ่งจริง ๆ และมีความคลาดเคลื่อนมากในการระบุ Positive class ที่ถูกต้อง

สมการ Precision เขียนได้ดังนี้

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

เมื่อ

True Positives (TP) = จำนวนข้อมูลที่ถูกต้องที่ทำนายว่าเป็น Positive class

False Positives (FP) = ข้อมูลที่ถูกต้องที่ถูกทำนายว่าเป็น Positive class แต่ควรจะเป็น Negative class

สมการ Recall เขียนได้ดังนี้

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

เมื่อ

True Positives (TP) = จำนวนข้อมูลที่ถูกต้องที่ทำนายว่าเป็น Positive class

False Negatives (FN) = ข้อมูลที่ถูกต้องที่ถูกทำนายว่าเป็น Negative class แต่ควรจะเป็น Positive class

โดย Recall มีค่าระหว่าง 0 ถึง 1 ทั้งนี้ค่ายิ่งมากยิ่งดี เมื่อค่า Recall เข้าใกล้หรือเป็น 1 แสดงว่า ระบบมีความสามารถในการระบุ Positive class ที่ถูกต้องมาก เนื่องจากระบบสามารถหาข้อมูล Positive class ทั้งหมดที่มีในข้อมูลได้เต็มที่ แต่ถ้า Recall มีค่าเข้าใกล้หรือเป็น 0 แสดงว่า ระบบมีความสามารถในการระบุ Positive class ที่ถูกต้องน้อย เนื่องจากมีการพลาดในการระบุข้อมูล Positive class ที่มีในข้อมูลไปมากทำให้ระบบมีข้อบกพร่องในการระบุ Positive class ที่มีในข้อมูล

Intersection over Union (IoU) คือ อัตราส่วนของพื้นที่ที่ทับซ้อนระหว่างกรอบที่โมเดลระบุกับกรอบที่กำหนดไว้ โดยหลักการ IOU แสดงดังรูปที่ 11

โมเดลการตรวจจับวัตถุที่ดีจะมีค่า Precision และ Recall สูง ซึ่งหมายความว่าโมเดลสามารถตรวจจับวัตถุส่วนใหญ่ได้อย่างถูกต้องและตรวจจับวัตถุได้เกือบทั้งหมดที่มีจริงในภาพ บทความนี้จึงต้องการศึกษากราฟแสดงความสัมพันธ์ระหว่าง Precision และ Recall ที่แปรผันตามค่า Confidence Score กราฟ Precision-Recall Curve แสดงความสัมพันธ์ระหว่างอัตราการตรวจจับวัตถุที่ถูกต้อง (Precision) กับสัดส่วนของวัตถุที่ตรวจจับได้ (Recall) ค่า Average Precision (AP) คือพื้นที่ใต้กราฟ Precision-Recall Curve ใช้ประเมินประสิทธิภาพโดยรวมของโมเดล โมเดลที่ดีจะมีค่า AP ใกล้เคียงกับ 1 หมายความว่าโมเดลมีความแม่นยำสูงในทุกระดับของ Recall ซึ่งทั่วไปจะคำนวณค่า AP สำหรับแต่ละประเภทของวัตถุ ค่า mAP ได้มาจากการนำค่า AP ของทุกประเภทของวัตถุมารวมกัน โดยค่า mAP อาจเปลี่ยนแปลงไปตามเกณฑ์ของค่า IoU ที่กำหนด บทความนี้ใช้เกณฑ์ IoU ตั้งแต่ 0.5 ถึง 0.95 และคำนวณ mAP ผ่านการแบ่งวัตถุดังนี้

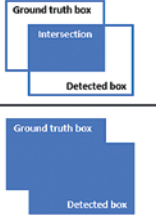
- วัตถุขนาดเล็ก หมายถึง ยานพาหนะ
- วัตถุขนาดกลาง หมายถึง บ้าน และอาคาร

ขนาดเล็ก

- วัตถุขนาดใหญ่ หมายถึง อาคารขนาดใหญ่ โรงงาน โรงพยาบาล โรงเรียน สิ่งก่อสร้างขนาดใหญ่

3.2.2 ความเร็ว (Speed)

วัดด้วยค่า FPS (Frames per Second)

$$IoU = \frac{\text{Area of Overlap}}{\text{Area of Union}} = \frac{\text{Intersection}}{\text{Union}}$$


รูปที่ 11 หลักการทำงานของ Intersection over Union (IOU)

หมายถึง จำนวนเฟรมภาพที่โมเดลประมวลผลได้ใน 1 วินาที ค่า FPS ยิ่งสูง ยิ่งหมายความว่าโมเดลประมวลผลภาพได้เร็ว ความเร็วของโมเดลขึ้นอยู่กับโครงสร้างของโมเดล ฮาร์ดแวร์ที่ใช้ประมวลผลและสภาพแวดล้อมของซอฟต์แวร์ บทความนี้ได้ปรับแต่งโมเดลทั้งหมดให้ทำงานบน NVIDIA Tesla V100 GPU ร่วมกับ TensorRT engine โดยแปลงค่าพารามิเตอร์ของโมเดลเป็นเลขจุดทศนิยมแบบ 16 บิต (16-bit floating-point) เพื่อให้ประมวลผลได้เร็วขึ้น แต่ส่งผลให้ความแม่นยำลดลงเล็กน้อยเมื่อเทียบกับโมเดลที่ไม่ได้ปรับแต่ง

3.2.3 ความซับซ้อน (Complexity)

วัดด้วยจำนวนพารามิเตอร์ของโมเดลแต่ละโมเดล การวัดความซับซ้อนเป็นสิ่งสำคัญอย่างยิ่ง โดยเฉพาะเมื่อทรัพยากรบนอุปกรณ์เป้าหมายมีจำกัด เช่น ในการตรวจจับวัตถุในภาพถ่ายทางอากาศ เราต้องคำนึงถึงการนำระบบตรวจจับวัตถุไปใช้งานบนอุปกรณ์คอมพิวเตอร์บนอากาศยานไร้คนขับ ซึ่งมักจะมีทรัพยากรการคำนวณและหน่วยความจำ

ที่จำกัด (Model Size) ดังนั้น โมเดลการตรวจจับวัตถุที่นำไปใช้งานต้องเป็นไปตามข้อกำหนดของอุปกรณ์เป้าหมาย เพื่อให้มีประสิทธิภาพในการทำงานได้

อย่างเหมาะสม น้ำหนักเบา และการประมวลผลที่อาจมีขนาดเล็กกว่าคอมพิวเตอร์ทั่วไป

4. ผลการศึกษา/ผลการดำเนินการ

ผลจากการนำ Weight ของโมเดลที่ได้จากการเทรนโมเดลไปทดสอบโมเดลทั้งหมด 7 โมเดล คือ Faster R-CNN, MobileNetV1, ResNet50, YOLOv4, YOLOv4-tiny, YOLOv7 และ EfficientDet

ตารางที่ 2 แสดงจำนวนรวมของวัตถุสำหรับแต่ละ

Objects	Total number of objects	Avg. number of objects per image
Vehicle	3937	5.39
Building	14263	19.54

จากตารางที่ 2 แสดงจำนวนรวมของวัตถุสำหรับแต่ละคลาสและจำนวนเฉลี่ยของวัตถุในภาพสำหรับแต่ละคลาส ข้อมูลเหล่านี้แสดงถึงความไม่สมดุลระหว่างจำนวนของวัตถุที่ป้ายชื่อว่า 'ยานพาหนะ' และจำนวนของวัตถุที่ป้ายชื่อว่า 'อาคาร' ข้อมูลภาพทางอากาศมีมุมมองที่แตกต่างกันในแต่ละภาพส่งผลให้โมเดลที่ไม่มีการปรับน้ำหนักหรือให้ความสำคัญจำนวนคลาสนี้ที่มีภาพจำนวนน้อย มีประสิทธิภาพที่ลดลง เช่น โมเดล ResNet50 ในตารางที่ 3

จากตารางที่ 3 แสดงขนาดความจุของโมเดลและความเร็วของโมเดลในแต่ละตัว จะเห็นได้ว่า SSD+FPN (MobileNetV1) มีความน่าสนใจคือ มีความเร็วกว่าโมเดลอื่น ๆ ที่ได้ทำการทดลองมา ซึ่งมีความเร็วถึง 196.01 เฟรมต่อวินาที แต่ในเชิง

ตารางที่ 3 ความเร็ว (fps) และขนาดความจุของโมเดล

Model	Evaluation Metrics	
	speed in FPS (ms)	Model Size (MB)
YOLOv4	74.89	64.00
Faster R-CNN	101.25	28.30
EfficientDet (D1)	115.06	5.29
RetinaNet+FPN (ResNet50)	152.56	50.70
YOLOv7	158.13	36.50
YOLOv4-tiny	158.30	5.88
SSD+FPN (MobileNetV1)	196.01	29.90

ขนาดความจุของโมเดลนั้น พบว่า YOLOv4-tiny มีความจุโมเดลที่ต่ำกว่า 5.09 เมกะ และมีความเร็วเป็นรอง MobileNetV1 อยู่ที่ 158.3 เฟรมต่อวินาทีเท่านั้น ในเรื่องของ Model Size จะได้เปรียบเนื่องจากในการประมวลผลภาพถ้าต้องการให้ประมวลผลภาพแบบ Real-time ไม่จำเป็นต้องใช้ทรัพยากรในการประมวลผลที่มากและมีขนาดใหญ่ Memory ที่มากอาจส่งผลให้ชิ้นส่วนมีขนาดใหญ่ขึ้นและการประมวลผลที่มากขึ้น ดังนั้น ในการเก็บข้อมูลและประมวลผลภาพต้องคำนึงถึงน้ำหนักในอากาศยานไร้คนขับด้วย ซึ่งความจุในที่นี้หมายถึง Capacity ที่ใช้ในหน่วยความจำ

จากตารางที่ 4 จะเห็นได้ว่า YOLOv7 มีความแม่นยำที่สูงที่สุดจากทุกโมเดลที่ได้ทำการทดลองมาอยู่ที่ 58.5% และรองลงมา คือ SSD+FPN (MobileNetV1) มีความแม่นยำที่รองลงมาจาก YOLOv7 ทั้งนี้ จากตารางที่ 3 และตารางที่ 4 จะเห็นได้ว่า SSD+FPN (MobileNetV1) เป็นโมเดลที่เกือบดีที่สุดในงานตรวจจับวัตถุจากภาพถ่ายทางอากาศทั้งเรื่องความเร็วและความแม่นยำ ถึงแม้ YOLOv7 ที่มี

ตารางที่ 4 ความแม่นยำและขนาดความจุของโมเดล

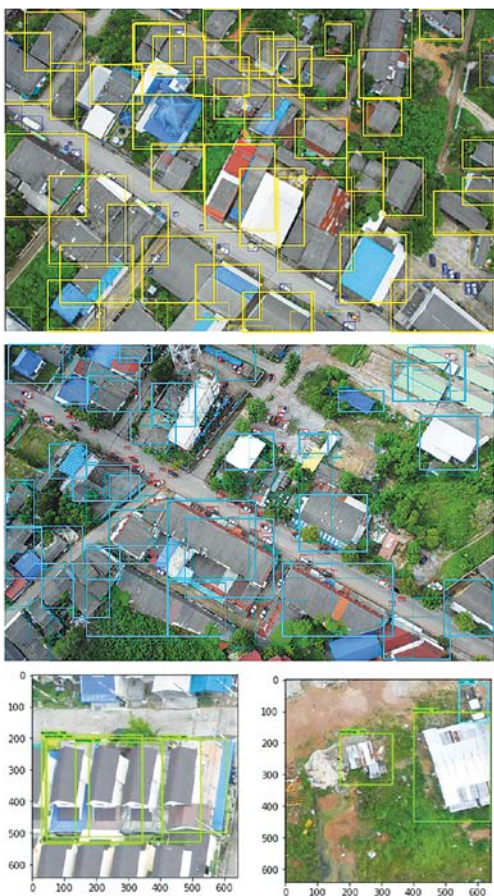
Model	Evaluation Metrics	
	mAP (%)	Model Size (MB)
RetinaNet+FPN (ResNet50)	1.2	50.70
EfficientDet (D1)	14.5	5.29
YOLOv4-tiny	17.6	5.88
Fasster R-CNN	21.2	28.30
YOLOv4	45.1	64.00
SSD+FPN (MobileNet1)	49.5	29.90
YOLOv7	58.5	36.50

แม่นยำสูงกว่ายังมีความเร็วที่ช้ากว่า เมื่อเทียบกับ SSD+FPN (MobileNet1) อยู่ระดับหนึ่ง ส่วนในโมเดลตัวอื่น ๆ ความเร็วอาจใกล้เคียงกัน ยกเว้น YOLOv4 ที่มีความเร็วต่ำสุดอยู่เพียงแค่ 74.89 เฟรมต่อวินาที ส่วนในด้านความจุ พบว่า YOLOv4-tiny มีความจุโมเดลที่ต่ำอยู่ที่ 5.88 MB เท่านั้น แต่ในความแม่นยำยังไม่สูงเมื่อเทียบกับ SSD+FPN (MobileNet1) และ YOLOv7 แต่ยังคงมีความแม่นยำสูงกว่า RetinaNet+FPN (ResNet50) ที่มีเพียง 1.2 % เท่านั้น ดังแสดงในรูปที่ 12 ตัวอย่างภาพถ่ายทางอากาศที่ทดสอบเสร็จสิ้น

5. สรุปและอภิปรายผลการทดลอง

จากการทดลองทั้งหมด 7 โมเดล พบว่าความแม่นยำสูงสุดคือ YOLOv7 อยู่ที่ 58.5% ซึ่งยังไม่ถือว่าสูงมากถึงแม้ในงานวิจัยที่ผ่านมา [21] - [27] โมเดลตรวจจับวัตถุจะมีความแม่นยำถึง 70 - 80% เนื่องจากจำนวนข้อมูลของงานวิจัยนั้นมีจำนวนมากว่าและเป็นข้อมูลที่แตกต่างจากข้อมูลในบทความนี้ โดยปัจจัยหนึ่งมาจากข้อมูลที่ใช้ในการทำการทดลองมีจำนวนน้อยกว่า หากมีชุดข้อมูล

ที่ใช้ทดลองมากขึ้น ความแม่นยำจะมีค่าสูงมากขึ้น และอีกปัญหาหนึ่งในภาพถ่ายทางอากาศคือ มีการถ่ายในความสูงที่ไม่เท่ากันและมุมมองแตกต่างกัน ทำให้ผลความแม่นยำต่ำลง หากต้องการความแม่นยำที่สูงกว่าจำเป็นต้องมีข้อมูลภาพที่มากขึ้น และมีมุมมองและความสูงในระยะที่กำหนดที่ทราบผลจากการบินในระยะนั้น ๆ ถ้าหากต้องการโมเดลที่ใช้ความจุต่ำแต่ความแม่นยำสูง แต่ไม่สูงที่สุดควรเลือก YOLOv4-tiny ที่ใช้ความจุเพียงแค่ 5.88 MB เท่านั้นและโมเดลที่ดีที่สุดที่ได้ทำการทดลองมาคือ SSD+FPN (MobileNet1) มีความเร็วในการทำงานสูงที่สุดถึงแม้ความแม่นยำจะเป็นรอง YOLOv7 อยู่ แต่ก็ดีกว่าโมเดลอื่น ๆ ที่ทำการทดลองมาในทุก ๆ โมเดล ซึ่งจากความเร็วจะเห็นได้ว่าโมเดลทุกโมเดลมีความเร็วเกิน 25 เฟรมต่อวินาทีที่เป็นความเร็วของความเร็วกล้องของอากาศยานไร้คนขับทั้งหมด โดยโมเดลที่ได้ทำการทดลองเหมาะสมในงานภาพถ่ายทางอากาศจากอากาศยานไร้คนขับซึ่งจำนวนรวมของวัตถุสำหรับแต่ละคลาสและจำนวนเฉลี่ยของวัตถุในภาพสำหรับแต่ละคลาสข้อมูลเหล่านี้แสดงถึงความไม่สมดุลระหว่างจำนวนของวัตถุที่ป้ายชื่อว่า 'ยานพาหนะ' และจำนวนของวัตถุที่ป้ายชื่อว่า 'อาคาร' ข้อมูลภาพทางอากาศมีมุมมองที่แตกต่างกันในแต่ละภาพส่งผลให้ในโมเดลที่ไม่มีการปรับน้ำหนักหรือให้ความสำคัญจำนวนคลาสที่มีภาพจำนวนน้อย มีประสิทธิภาพที่ลดลง ตัวอย่างเช่น โมเดล ResNet50 ที่มีประสิทธิภาพลดลง ซึ่งขนาดความจุของโมเดลและความเร็วของโมเดลในแต่ละตัวมีลักษณะแตกต่างกัน จะเห็นได้ว่า SSD+FPN (MobileNet1) มีความน่าสนใจ คือมีความเร็วกว่าโมเดลอื่น ๆ ที่ได้ทำการทดลองมา ซึ่งมีความเร็วถึง 196.01 เฟรมต่อวินาที แต่ในเชิงขนาดความจุของโมเดลนั้น พบว่า YOLOv4-tiny มีความจุ



รูปที่ 12 ตัวอย่างภาพถ่ายทางอากาศที่ทดสอบเสร็จสิ้น

โมเดลที่ต่ำกว่า 5.09 เทา และมีความเร็วเป็นรอง MobileNetv1 อยู่ที่ 158.3 เฟรมต่อวินาที เท่านั้น ในเรื่องของ Model Size จะได้เปรียบเนื่องจากการประมวลผลภาพถ้าต้องการให้ประมวลผลภาพแบบ Real-time ไม่จำเป็นต้องใช้ทรัพยากรในการประมวลผลที่มากและมีขนาดใหญ่ Memory ที่มากอาจส่งผลให้ชิ้นส่วนมีขนาดใหญ่ขึ้นและการประมวลผลที่มากขึ้น ดังนั้น ในการเก็บข้อมูลและประมวลผลภาพต้องคำนึงถึงน้ำหนักในอากาศยานไร้คนขับด้วย ซึ่งความจุในที่นี้หมายถึง Capacity ที่ใช้ในหน่วยความจำ

ทั้งนี้ การใช้ GPU, CPU ที่แตกต่างกันอาจมีผลในเรื่องการประมวลผลที่แตกต่างกัน งานวิจัยนี้ได้นำข้อมูลทั้งหมด Training บน GPU ของ NVIDIA V100 TENSOR CORE GPU 32GB ใช้ Ubuntu 18.04 Desktop ในการพัฒนาต่อจากงานวิจัยนี้สามารถนำเทคโนโลยี Object Detection ไปใช้ในงานภาพถ่ายทางอากาศในด้านทางการทหารที่มีประโยชน์มากมาย ตัวอย่างเช่น

1. การตรวจจับและระบุวัตถุบนภาพถ่ายทางอากาศได้อย่างรวดเร็วและแม่นยำ เช่น รถถังที่กำลังเคลื่อนที่ เรือ หรือเครื่องบินศัตรู เป็นต้น ซึ่งสามารถช่วยให้ทหารมีข้อมูลที่สำคัญในการวางแผนการทำงานและการตอบสนองต่อสถานการณ์ได้อย่างมีประสิทธิภาพมากขึ้น

2. การตรวจสอบพื้นที่ในบริเวณที่ภาพถ่ายถูกถ่ายมา เช่น การตรวจสอบพื้นที่ที่เป็นเขตอันตราย การตรวจสอบสภาพอากาศหรือการตรวจสอบพื้นที่สำคัญสำหรับการวางกองทัพที่สามารถช่วยให้ทหารได้ข้อมูลที่สำคัญ

3. การแสดงข้อมูลในเวลาจริง การนำเทคโนโลยี Object Detection มาใช้ในภาพถ่ายทางอากาศช่วยในการแสดงข้อมูลที่รวดเร็วในเวลาจริงที่สามารถช่วยให้ทีมงานทหารได้รับข้อมูลสถานการณ์ที่อัปเดตและแม่นยำได้

6.เอกสารอ้างอิง

- [1] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based Learning Applied to Document Recognition," *Proc. IEEE*, vol. 86, no. 11, pp. 2278 – 2324, 1998.
- [2] D. G. Lowe, "Object Recognition from Local Scale-invariant Features," in *Proc. 7th IEEE Int. Conf. Comput. Vision (ICCV'99)*, Kerkyra,

- Greece, 1999, pp. 1150-1157.
- [3] H. Bay, A. Ess, T. Tuytelaars, and L. V. Gool, "Speeded-Up Robust Features (SURF)," *Comput. Vis. Image Underst.*, vol. 110, no. 3, pp. 346 - 359, 2008.
- [4] N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection," in *2005 IEEE Comput. Soc. Conf. Comput. Vision Pattern Recognit. (CVPR'05)*, San Diego, CA, USA, 2005, pp. 886-893.
- [5] W. Pei *et al.*, "Mapping and Detection of Land Use Change in a Coal Mining Area Using Object-based Image Analysis," *Environ. Earth Sci.*, vol. 76, pp. 1 – 16, 2017.
- [6] Y. Liu, S. U. Din, and Y. Jiang, "Urban Growth Sustainability of Islamabad, Pakistan, Over the Last 3 Decades: A Perspective based on Object-based Backdating Change Detection," *GeoJournal*, vol. 86, pp. 2035 – 2055, 2020.
- [7] M. Choinski, M. Rogowski, P. Tynecki, D. P. J. Kuijper, M. Churski, and J. W. Bubnicki, "A First Step Towards Automated Species Recognition from Camera Trap Images of Mammals Using AI in a European Temperate Forest," in *Int. Conf. Comput. Inf. Syst. Ind. Manage. (CISIM 2021)*, Etk, Poland, 2021, pp. 299 – 310.
- [8] W. Dai, H. Wang, Y. Song, and Y. Xin, "Wildlife Small Object Detection based on Enhanced Network in Ecological Surveillance," in *2021 33rd Chin. Control Decis. Conf. (CCDC)*, Kunming, China, 2021, pp. 1164-1169.
- [9] L. Dutrieux *et al.*, "Tree Species Detection and Identification from UAV Imagery to Support Tropical Forest Monitoring," in *EGU General Assem. Conf. (EGU 2020)*, 2020, p. 17759.
- [10] W. Lim, K. Choi, W. Cho, B. Chang, and D. W. Ko, "Efficient Dead Pine Tree Detecting Method in the Forest Damaged by Pine Wood Nematode (*Bursaphelench usxylophilus*) Through Utilizing Unmanned Aerial Vehicles and Deep Learning-based Object Detection Techniques," *Forest Sci. Technol.*, vol. 18, no. 1, pp. 36 – 43, 2022.
- [11] G. D. Georgiev, G. Hristov, P. Zahariev, and D. Kinaneva, "Forest Monitoring System for Early Fire Detection Based on Convolutional Neural Network and UAV Imagery," in *2020 28th Nat. Conf. Int. Participation (TELECOM 2020)*, Sofia, Bulgaria, 2020, pp. 57 - 60.
- [12] L. Shumilo, M. Lavreniuk, N. Kussul, and B. Shevchuk, "Automatic Deforestation Detection based on the Deep Learning in Ukraine," in *2021 11th IEEE Int. Conf. Intell. Data Acquisition Adv. Comput. Syst.: Technol. Appl. (IDAACS 2021)*, Cracow, Poland, 2021, pp. 337 - 342.
- [13] K. - C. Chang, S. - H. Lin, J. - W. Huang, and Y. - F. Wu, "Automatic Incremental Training of Object Detection by Using GAN for River Level Monitoring," in *2021 IEEE Int. Conf. Consum. Electron. - Taiwan (ICCE-TW)*, Penghu, Taiwan, China, 2021, pp. 1 – 2.
- [14] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich Feature Hierarchies for Accurate Object Detection and Semantic

- Segmentation,” in *2014 IEEE Conf. Comput. Vision Pattern Recognit.*, Columbus, OH, USA, 2013, pp. 580 - 587.
- [15] R. Girshick, “Fast R-CNN,” in *2015 IEEE Int. Conf. Comput. Vision (ICCV 2015)*, Santiago, Chile, 2015, pp. 1440 - 1448.
- [16] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 39, no. 6, pp. 1137 - 1149, 2017.
- [17] W. Liu *et al.*, “SSD: Single Shot MultiBox Detector,” in *14th Eur. Conf. Comput. Vision (ECCV 2016)*, Amsterdam, Netherlands, 2016, pp. 21 - 37.
- [18] T. - Y. Lin, P. Dollár, R. Girshick, K. He, B. Hariharan, and S. Belongie, “Feature Pyramid Networks for Object Detection,” in *2017 IEEE Conf. Comput. Vision Pattern Recognit. (CVPR 2017)*, Honolulu, HI, USA, 2017, pp. 936 - 944.
- [19] T. - Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollár, “Focal Loss for Dense Object Detection,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 42, no. 2, pp. 318 - 327, 2017.
- [20] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” in *2016 IEEE Conf. Comput. Vision Pattern Recognit. (CVPR)*, Las Vegas, NV, USA, 2016, pp. 779 - 788.
- [21] A. Bochkovskiy, C. - Y. Wang, and H. - Y. Liao, “YOLOv4: Optimal Speed and Accuracy of Object Detection,” 2020, arXiv: 2004.10934.
- [22] C. - Y. Wang, A. Bochkovskiy, and H. - Y. M. Liao, “YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors,” in *2023 IEEE/CVF Conf. Comput. Vision Pattern Recognit. (CVPR)*, Vancouver, BC, Canada, 2023, pp. 7464 - 7475.
- [23] M. Tan, R. Pang, and Q. V. Le, “EfficientDet: Scalable and Efficient Object Detection,” in *2020 IEEE/CVF Conf. Comput. Vision Pattern Recognit. (CVPR)*, Seattle, WA, USA, 2020, pp. 10778 - 10787.
- [24] M. Tan and Q. V. Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,” 2019, ArXiv: 1905.11946.
- [25] W. Luangluewut, K. Viriyasatr, W. Pawgasame, P. Kaewmongkol, and S. Mitaim, “Detecting Objects in Aerial Photographs Using Neural Network Techniques”, *Def. Technol. Acad. J.*, vol. 5, no. 12, pp. 4-11, Nov. 2023.
- [26] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” in *2016 IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, Las Vegas, NV, USA, 2016, pp. 770 - 778.
- [27] A. G. Howard *et al.*, “MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications,” 2017, ArXiv: 1704.04861.

การหาค่าเหมาะสมที่สุดของการออกแบบตามแนวคิดของ กามิกาเซโดรอนปีกรูปตัวเอ็กซ์ขับเคลื่อนด้วยระบบไฟฟ้าด้วยเมตาฮิวริสติกส์

ภาควิชาวิศวกรรมเครื่องกลและการบิน-อวกาศ
ภาควิชาวิศวกรรมศาสตร์, มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ^{1*}

วันที่รับ 19 เมษายน 2567 วันที่แก้ไข 3 พฤษภาคม 2567 วันที่ตอบรับ 23 พฤษภาคม 2567

บทคัดย่อ

งานวิจัยชิ้นนี้ได้นำเสนอการหาค่าเหมาะสมที่สุดของการออกแบบตามแนวคิดของกามิกาเซโดรอนปีกรูปตัวเอ็กซ์ขับเคลื่อนด้วยระบบไฟฟ้าด้วยวิธีเมตาฮิวริสติกส์ ฟังก์ชันเป้าหมายของการออกแบบประกอบไปด้วยการหาค่าต่ำที่สุดของน้ำหนักเครื่องบินและค่าสูงที่สุดของเวลาในการบิน โดยคำนึงถึงภารกิจในการบินและเสถียรภาพในการบินเป็นเงื่อนไขบังคับ วิธีแถบตาข่ายลมนวน (Vortex Lattice Method: VLM) ถูกนำมาใช้เพื่อคำนวณทางด้านอากาศพลศาสตร์และเสถียรภาพในการบิน และวิธีทฤษฎีโมเมนต์ใบเมเนตัม (Blade Element Momentum Theory: BEMT) ถูกนำมาใช้ในการวิเคราะห์ใบพัด อัลกอริทึม Multi-objective Metaheuristic with Interactive Parameter Distribution Estimation (MMIPDE) ถูกนำมาเป็นเครื่องมือในการหาค่าเหมาะสมที่สุด ผลการออกแบบได้ถูกเลือกออกมา 3 ตัวอย่าง จากขอบหน้าพาเรโต (Pareto front) ความจุแบตเตอรี่ส่งผลโดยตรงต่อฟังก์ชันเป้าหมายทั้งสอง พารามิเตอร์ของอากาศยานจะเปลี่ยนไปหากมีน้ำหนักที่เปลี่ยนแปลง ค่าเหมาะสมที่สุดจากการออกแบบอากาศยานจะถูกนำไปออกแบบในขั้นตอนการออกแบบขั้นกลาง

คำสำคัญ : การออกแบบตามแนวคิดของเครื่องบิน, เมตาฮิวริสติกส์, กามิกาเซโดรอน, ใบพัด

¹ ภาควิชาวิศวกรรมเครื่องกลและการบิน-อวกาศ, คณะวิศวกรรมศาสตร์, มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
* ผู้แต่ง, อีเมล: pakin.c@eng.kmutnb.ac.th

Optimum Design of Electric X-Kamikaze Drone in Conceptual Design Phase using Metaheuristic

Pakin Champasak ^{1*}

Received 19 April 2024, Revised 3 May 2024, Accepted 23 May 2024

Abstract

This research presents the optimization of the concept design of an electrically powered X-wing kamikaze drone using metaheuristics. The objective function consists of finding the minimum of aircraft weight and maximum of endurance taking into account of the flight mission and flight stability requirement. Vortex lattice method (VLM) is used to calculate the aerodynamics and flight stability, and the blade element momentum theory (BEMT) method is used for the analysis the propeller. Multi-objective metaheuristic with new concept of parameter adaptation (MMIPDE) is used as an optimizer. Three optimal design results were selected from the pareto front. Battery capacity directly affects both objective functions. Another design variable of the aircraft will change up to weight. The optimum values from the aircraft design will be taken into consideration in the next phase.

Keywords : Aircraft conceptual design, Metaheuristic, Kamikaze drone, Propeller

¹ Department of Mechanical and Aerospace Engineering, Faculty of Engineering, King Mongkut's University of Technology North Bangkok

* Corresponding author: pakin.c@eng.kmutnb.ac.th

1. บทนำ

อากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) หรือที่คุ้นเคยกันในชื่อโดรน (Drone) กลายเป็นเครื่องมือที่ถูกนำไปประยุกต์ใช้งานได้หลากหลาย ตั้งแต่การลาดตระเวนทางทหารไปจนถึงการใช้งานพลเรือน เช่น เกษตรกรรม การเฝ้าระวัง และการจัดการภัยพิบัติ ในช่วงไม่กี่ปีที่ผ่านมา มีการปรับเปลี่ยนแนวคิดเกี่ยวกับเรื่องโลกร้อน จึงส่งผลต่อระบบขับเคลื่อนของ UAV คือ เปลี่ยนจากเครื่องยนต์สันดาปสู่มอเตอร์ไฟฟ้า เพื่อที่จะเป็นมิตรต่อสิ่งแวดล้อมและลดค่าใช้จ่ายในการดำเนินงานลงเมื่อเทียบกับเครื่องยนต์ที่ใช้สันดาปแบบดั้งเดิม อย่างไรก็ตาม การออกแบบ UAV ไฟฟ้ายังมีความท้าทายที่สำคัญหลายประการในการออกแบบ ปัญหาหลักอย่างหนึ่งในการออกแบบอากาศยานไร้คนขับโดยขับเคลื่อนด้วยไฟฟ้า (Electric Unmanned Aerial Vehicle: eUAV) คือ การจัดเก็บและการจัดการพลังงาน eUAV อาศัยแบตเตอรี่ในการขับเคลื่อน ความหนาแน่นของพลังงาน น้ำหนัก และประสิทธิภาพของแบตเตอรี่ส่งผลกระทบต่ออย่างมีนัยสำคัญต่อสมรรถนะและความสามารถในการบินของ eUAV แม้ว่าจะมีการปรับปรุงเทคโนโลยีแบตเตอรี่ในปัจจุบันอย่างต่อเนื่อง แต่ก็ยังเผชิญกับข้อจำกัดในแง่ของความหนาแน่นของพลังงานและความทนทานและความสามารถในการบรรทุกของ eUAV ดังนั้น การออกแบบ eUAV อย่างมีประสิทธิภาพ หรือการออกแบบ eUAV ให้เหมาะสมที่สุด จึงเป็นปัจจัยหลักของการรับประกันความสำเร็จของภารกิจในการบินโดรนถูกใช้อย่างแพร่หลายมากขึ้นในสงครามยุคใหม่ เนื่องจากความคล่องตัว การเข้าถึงเป้าหมายได้ง่าย และประสิทธิภาพในสถานการณ์การต่อสู้ต่าง ๆ โดรนเหล่านี้มีข้อได้เปรียบหลายประการสำหรับกองกำลังทหาร รวมถึงการลาดตระเวน การเฝ้าระวัง การได้มาซึ่งเป้าหมาย หรือ

แม้กระทั่งความสามารถในการรุก ประโยชน์หลักอีกประการหนึ่งของการใช้โดรนในสงครามร่วมสมัยคือ ความสามารถในการรวบรวมข้อมูลแบบเรียลไทม์ (Real time) โดยไม่ทำให้ทหารตกอยู่ในความเสี่ยง โดรนที่ติดตั้งกล้องความละเอียดสูงและเซนเซอร์ต่าง ๆ สามารถให้ข้อมูลอันมีค่าเกี่ยวกับตำแหน่ง การเคลื่อนไหว และโครงสร้างพื้นฐานของศัตรู ข้อมูลเหล่านี้ช่วยให้ผู้บัญชาการทหารสามารถตัดสินใจอย่างทันท่วงทีและวางแผนปฏิบัติการทางยุทธวิธีได้อย่างมีประสิทธิภาพมากขึ้น นอกเหนือจากการลาดตระเวนและการเฝ้าระวังแล้ว โดรนยังถูกนำมาใช้เพื่อวัตถุประสงค์เชิงรุกในสงครามสมัยใหม่มากขึ้นอีกด้วย โดรนติดอาวุธหรือที่รู้จักกันในชื่อ กามิกาเซโดรน (Kamikaze drone) สามารถบรรทุกและปรับใช้อาวุธยุทธโธปกรณ์ต่าง ๆ ไม่ว่าจะเป็น หีวระเบิด และขีปนาวุธนำวิถี ความสามารถนี้ช่วยให้กองกำลังทหารทำการโจมตีเป้าหมายศัตรูได้อย่างแม่นยำโดยสร้างความเสียหายต่อตนเองให้น้อยที่สุด ซึ่งลดความเสี่ยงต่อพลเรือนและโครงสร้างพื้นฐาน ในสงครามระหว่างรัสเซียและยูเครน พบว่ามีกามิกาเซโดรนให้เห็นหลากหลายรูปแบบ ไม่ว่าจะเป็น Harop ที่มีรูปทรงแบบคานาร์ด (Canard) และมีลักษณะลำตัวแบบเบรนต์วิง (Blended wing) ซึ่งถูกพัฒนาโดย Israel Aerospace Industries [1] สวิตช์เบรต (Switchblade) ที่พัฒนาโดย Aero Vironment มีลักษณะเรียบง่ายแบบอากาศยานทั่วไป (Conventional aircraft) [2] หรือแลนเซต 3 (LANCET3) ซึ่งถูกพัฒนาโดย ZALA Aero Group ที่มีลักษณะเป็นปีกรูปตัวเอ็กซ์ โดยมีข้อดีคือ ประสิทธิภาพในการควบคุมรอบแกน z (Yawing) ที่สูงขึ้นกว่าเครื่องบินแบบ Conventional aircraft ส่งผลให้ความสามารถในการติดตามเป้าหมายที่เคลื่อนที่ได้ดีขึ้น [3]

การออกแบบอากาศยานแบ่งเป็น 3 ส่วน คือ การออกแบบตามแนวคิด (Conceptual Design) การออกแบบขั้นกลาง (Preliminary Design) และการออกแบบขั้นละเอียด (Detail Design) โดยการออกแบบตามแนวคิดและการออกแบบในขั้นกลางนั้น จะเป็นการออกแบบรูปร่างภายนอกและรายละเอียด โครงสร้างภายในเครื่องบินตามลำดับส่วนขั้นละเอียด จะเป็นการออกแบบรายละเอียดชิ้นส่วน การประกอบ การขึ้นรูป รวมถึงการวิเคราะห์อากาศยานที่สร้างขึ้น อย่างละเอียด ความสำคัญของการแก้ไขปัญหาที่กล่าวมา ในย่อหน้าก่อนหน้านี พบว่า ในขั้นตอนการออกแบบ ตามแนวคิดมีผลอย่างมากต่อระยะเวลาและค่าใช้จ่าย ในการออกแบบถึง 70% กล่าวคือ หากสามารถ ออกแบบในขั้นตอนการออกแบบตามแนวคิดได้ดี จะช่วยลดเวลาและค่าใช้จ่ายได้เป็นอย่างมาก [4] การออกแบบอากาศยานในขั้นตอนการออกแบบตาม แนวคิด (Aircraft conceptual design) ในปัจจุบัน ได้ใช้องค์ความรู้ทางด้านคอมพิวเตอร์ช่วยในการ คำนวณทางวิศวกรรม (Computer-Aided Engineering: CAE) ร่วมกับการนำคอมพิวเตอร์มาช่วยในการออกแบบ (Computer-Aided Design: CAD) ในการวิเคราะห์ ประสิทธิภาพของอากาศยาน วิธีแลตตาข่ายลมนวน (Vortex Lattice Method: VLM) เป็นวิธีที่ได้รับความนิยมอย่างแพร่หลายในการออกแบบอากาศยาน ในขั้นตอนการออกแบบตามแนวคิด เนื่องจากสามารถ ทำนายโมเดลอากาศพลศาสตร์และสามารถ วิเคราะห์เสถียรภาพของอากาศยานได้อย่างแม่นยำ ใกล้เคียงการทดลองด้วยอุโมงค์โดยใช้เวลาในการ คำนวณที่ต่ำกว่าวิธีพลศาสตร์ของไหลเชิงคำนวณ (Computational Fluid Dynamic: CFD) หลายเท่าตัว ภายใต้อัจฉริยภาพที่วิธี VLM ไม่สามารถทำนายโมเดล ของอากาศพลศาสตร์เมื่อเกิดการไหลแยกของ

อากาศและไม่สามารถทำนายแรงเสียดทาน (Friction drag) ของอากาศได้ แต่ด้วยข้อดีที่ว่าวิธี VLM ใช้เวลาในการคำนวณค่อนข้างน้อยเมื่อเทียบกับวิธีอื่น ๆ จึงเหมาะใช้เป็นเครื่องมือในการวิเคราะห์ ร่วมกับวิธีการหาค่าเหมาะสมที่สุด (Optimisation) ที่ต้องอาศัยรอบในการคำนวณ ในการออกแบบ

โดยทั่วไปแล้วปัญหาการออกแบบเครื่องบิน ในขั้นตอนการออกแบบตามแนวคิดด้วยวิธี Optimisation สามารถกำหนดฟังก์ชันเป้าหมาย (Objective function) ได้ทั้ง ฟังก์ชันเป้าหมายเดียว (Single-objectives) หรือแบบ แบบหลายฟังก์ชัน เป้าหมาย (Multi-objectives) ประกอบด้วย การหาค่า ต่ำที่สุดของน้ำหนักรวมของเครื่องบิน การหาค่าต่ำที่สุด ของระยะ take-off หรือ หาค่าสูงที่สุดของระยะทาง หรือระยะเวลาในการบิน ภายใต้อัตราสิ้นเปลืองของภารกิจ ในการบิน เสถียรภาพของอากาศยาน โดยวิธีที่นิยม นำมาแก้ไขปัญหาการออกแบบเครื่องบินในขั้นตอน การออกแบบตามแนวคิด คือ วิธีเมตาฮิวริสติกส์ ซึ่งข้อดีของวิธีนี้คือ เหมาะกับปัญหาที่ไม่สามารถ คำนวณเกรเดียนต์ (Gradient) ได้ หรือ กล่าวคือ วิธี เมตาฮิวริสติกส์อยู่ในรูปแบบของการไม่ใช้เกรเดียนต์ ในการออกแบบ (Gradient-free) อัลกอริทึมยอดนิยม ที่จัดอยู่ในประเภทของเมตาฮิวริสติกส์ ไม่ว่าจะเป็น Differential Evolution (DE) [5] หรือ Particle Swarm Optimization (PSO) [6] อัลกอริทึม ที่ใช้แก้ปัญหาแบบหลายฟังก์ชันเป้าหมาย ไม่ว่าจะเป็น Multi-objective Ant Lion Optimizer: A Multi-objective Optimization Algorithm (MOALO) [7] หรือ Multi-objective Whale Optimization Algorithm (MWO) [8] แม้กระทั่ง อัลกอริทึมที่ถูกปรับปรุงเพื่อเพิ่มประสิทธิภาพ ในการหาค่าตอบ [9] - [10]

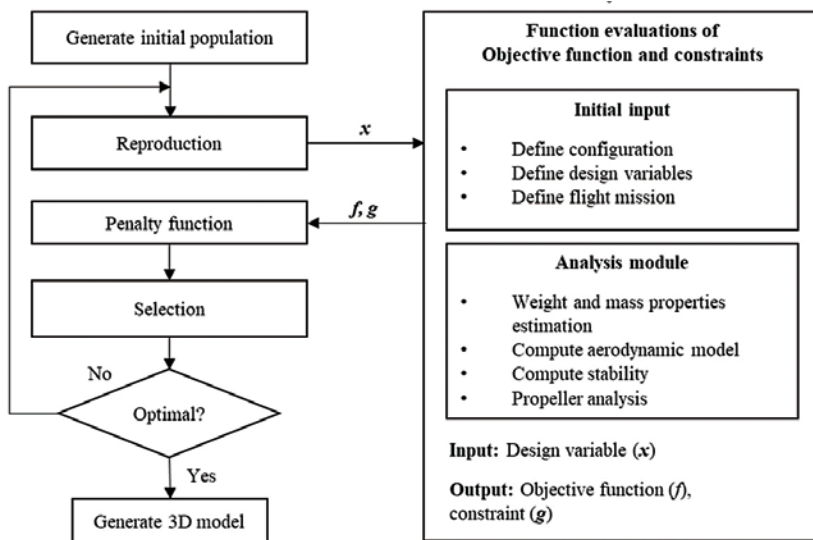
เป้าหมายของงานวิจัยชิ้นนี้คือ การหาค่าเหมาะสมที่สุดของการออกแบบกามิกาเซ่โดรนแบบปีกและหางรูปตัวเอ็กซ์โดยขับเคลื่อนด้วยระบบไฟฟ้า ด้วยวิธี MMIPDE [11] โดยมีฟังก์ชันเป้าหมายแบบ 2 ฟังก์ชันเป้าหมาย คือ หาค่าต่ำที่สุดของน้ำหนักเครื่องบิน (Total weight) และหาค่าสูงที่สุดของเวลาในการบิน (Endurance) โดยมีตัวแปรในการออกแบบประกอบไปด้วยพารามิเตอร์ของรูปร่างและขนาดของอากาศยานและพารามิเตอร์ของใบพัด โดยมีเงื่อนไขบังคับประกอบด้วย การกำหนดภารกิจในการบินและเสถียรภาพของอากาศยาน ในหัวข้อที่ 2 จะกล่าวถึงหลักการและทฤษฎีที่เกี่ยวข้องของการออกแบบตามแนวคิดของกามิกาเซ่โดรนปีกรูปตัวเอ็กซ์ด้วยวิธีเมตาฮิวริสติกส์ ไม่ว่าจะเป็น การวิเคราะห์อากาศพลศาสตร์และเสถียรภาพด้วยวิธี VLM ด้วยซอฟต์แวร์ AVL (Athena Vortex

Lattice) [12] การขึ้นรูปเครื่องบินสามมิติด้วยซอฟต์แวร์ OpenVSP (Open Vehicle Sketch Pad) [13] การกำหนดปัญหาการออกแบบตามแนวคิดของกามิกาเซ่โดรนปีกรูปตัวเอ็กซ์ จากนั้นกระบวนการหาค่าเหมาะสมที่สุดของปัญหาการออกแบบตามแนวคิดของกามิกาเซ่โดรนปีกรูปตัวเอ็กซ์ถูกแสดงในหัวข้อที่ 3 ผลการออกแบบ สรุปและอภิปรายผล จะแสดงให้เห็นในหัวข้อที่ 4 และ 5 ตามลำดับ

2. หลักการและทฤษฎีที่เกี่ยวข้องของการออกแบบตามแนวคิดของกามิกาเซ่โดรนปีกรูปตัวเอ็กซ์ด้วยวิธีเมตาฮิวริสติกส์

ขั้นตอนการออกแบบตามแนวคิดของอากาศยานสามารถอธิบายได้ตามรูปที่ 1


โดยเริ่มต้นการกำหนดรูปร่างของอากาศยานโมเดลอากาศยานแบบปีกและหางรูปตัวเอ็กซ์



รูปที่ 1 ขั้นตอนการออกแบบตามแนวคิดของอากาศยาน

ดังรูปที่ 2 ได้ถูกนำมาออกแบบในงานวิจัยชิ้นนี้ ปีกทุกชิ้นจะมีระยะความยาวปีก (Span), ความยาวของคอร์ดที่โคนปีก (Root chord) ความยาวของคอร์ดที่ปลายปีก (Tip chord) เท่ากัน และมีอัตราส่วนของความยาวคอร์ดที่ปลายปีก (Taper ratio) ที่เท่ากับ 1 แต่ละปีกจะทำมุมต่อกัน 45 องศา และเป็นปีกแบบไม่มีมุมลู่ออกของปีก (Non-sweep angle) โดยปีกด้านหน้าและด้านหลังจะใช้ แพนอากาศ (Airfoil) ที่มีชื่อว่า ClarkY และ naca0012 ตามลำดับ ขนาดของลำตัวจะถูกกำหนดให้เป็นค่าคงที่โดยมีความยาวเท่ากับ 0.8 เมตร และมีเส้นผ่านศูนย์กลางเท่ากับ 0.01 เมตร มอเตอร์ไฟฟ้าและใบพัดจะถูกติดตั้งอยู่ด้านหลังลำตัวในรูปแบบเครื่องยนต์ผลักจากด้านหลัง (Pusher) เพื่อลดการก่อกวนของลมที่กระทำต่อแพนบังคับอากาศยาน (Control surface)

การกำหนดภารกิจการบิน (Flight mission) โดยอากาศยานที่ออกแบบจะต้องได้เวลาในการบิน



รูปที่ 2 โมเดลอากาศยานแบบปีกและหางรูปตัวเอ็กซ์


(Endurance) และระยะการบิน (Range) มากกว่า 30 นาที และ 40 กิโลเมตร ตามลำดับ โดยมีความเร็วครูซ (Cruise speed) น้อยกว่า 30 เมตรต่อวินาที และต้องแบกน้ำหนักบรรทุกเท่ากับ 0.8 กิโลกรัม ภายใต้งานที่เครื่องบินจะต้องมีเสถียรภาพในการบิน

ในกระบวนการหาค่าที่เหมาะสมที่สุดของปัญหาในนี้ พารามิเตอร์ของปีกและหาง ไม่ว่าจะเป็น Span, Root Chord, มุมยกปีก (Incidence) และ พารามิเตอร์ของใบพัด เช่น รัศมีใบพัด (Blade radius) มุมบิดใบพัด (Blade twist angle), มุมพิตช์รวมใบพัด (Blade collective pitch angle) ถูกกำหนดให้เป็นตัวแปรออกแบบ เพื่อให้บรรลุฟังก์ชันเป้าหมาย คือ หาค่าต่ำที่สุดของน้ำหนักเครื่องบิน (Minimum total weight) และค่าสูงที่สุดของเวลาในการบิน (Maximum endurance) การคำนวณฟังก์ชันเป้าหมายและเงื่อนไขบังคับ (Function evaluation) ประกอบไปด้วย 4 หัวข้อหลัก ๆ คือ


1. การคำนวณโมเดลทางอากาศพลศาสตร์ (Compute Aerodynamic Model) วิธีการ VLM มีพื้นฐานมากจากหลักการไหลแบบโพเทนเชียล (Potential flow) โดยวิธีนี้ใช้ในการประมาณค่าแรงอากาศพลศาสตร์ (Aerodynamic force) ซึ่งเป็นแรงที่เกิดจากความแตกต่างระหว่างผิวบนและล่างของปีก โดยแต่ละผิวนั้นถูกเรียกว่า พื้นที่ยกปีก (Lifting surface) ดังรูปที่ 3 โดยจุดเด่นของวิธี VLM คือใช้เวลาในการวิเคราะห์ Aerodynamic force ต่ำกว่าวิธี CFD มาก เนื่องจากการลดความซับซ้อนของสมการการไหล ดังนั้น วิธี VLM จึงเหมาะกับการออกแบบเครื่องบินในขั้นตอน Conceptual Design ซึ่งเป็นช่วงของการออกแบบที่อาศัยรอบในการคำนวณเป็นจำนวนมาก ดังนั้น หากต้องการนำวิธี VLM มาใช้ได้ จึงจะต้องทำการ Validated ผลกับวิธี CFD ซึ่งมีความแม่นยำกว่า เพื่อที่จะทราบข้อจำกัดและความเป็นไปได้ในการนำวิธี VLM มาใช้ในการ

ออกแบบในขั้นตอน Conceptual Design ดังนั้นผู้จัดทำจึงทำการวิเคราะห์ผลของแรงในแนวแกนลำตัว (Body axis) ของทั้งวิธี VLM และ CFD ของโมเดล ดังรูปที่ 3 เพื่อศึกษาความเป็นไปได้ของการนำวิธี VLM มาใช้ในการออกแบบอากาศยาน การศึกษาพบว่า ผลการเปรียบเทียบแสดงให้เห็นดังรูปที่ 4 และ 5 จากรูปที่ 4 พบว่า ตั้งแต่มุม Angle of attack ที่ -5 องศาถึง 9 องศา ค่า CFZ ของทั้งวิธี VLM และ CFD มีค่าใกล้เคียงกันมาก แต่ที่ 9 องศา ถึง 15 องศา กราฟมีความโค้ง ค่า CFZ ลดลง เมื่อ Angle of Attack (AOA) มากกว่า 12 องศา โดยเหตุการณ์นี้เกิดจากการไหลแยกเนื่องจากเกิดการไหลแยก (Stall) จากมุมปะทะที่สูง และจะสังเกตได้ว่าผลของ VLM ในช่วงนี้จะยังเป็นเส้นตรง เนื่องจากวิธี VLM ไม่สามารถทำนายของไหลที่เกิดการไหลแยกได้ เพราะฉะนั้นการออกแบบในขั้นตอนการออกแบบตามแนวคิดควรตั้งลิมิต (Limit) ของการบินไว้ที่ Angle of Attack ต่ำกว่า 9 องศา เพื่อหลีกเลี่ยงความผิดพลาดจากการใช้วิธี VLM ผลจากรูปที่ 5 ที่ช่วง Angle of Attack ระหว่าง -5 ถึง 9 องศา ค่า CFx มีแนวโน้มขนานกัน ให้ค่าที่แตกต่างกันเล็กน้อย เกิดจากวิธี VLM ด้วยหลักการของ Potential flow ไม่สามารถคำนวณแรงต้านจากแรงเสียดทานได้ ต่างกับวิธี CFD ที่สามารถวิเคราะห์แรงเสียดทานของอากาศจากชั้นขอบ (Boundary layer) ได้ ดังนั้น หากต้องการใช้วิธี VLM ในการออกแบบ จะต้องเพิ่มผลจากแรงเสียดทานของอากาศเข้ามาด้วย เมื่อทราบข้อจำกัดของวิธี VLM แล้วงานวิจัยชิ้นนี้จะทำการวิเคราะห์อากาศพลศาสตร์โดยใช้วิธี VLM ด้วยซอฟต์แวร์ AVL โดยการป้อนรูปร่าง ขนาดและรูปทรงของอากาศยาน คุณสมบัติของน้ำหนักรวมและสถานะในการบิน

ที่ต้องการวิเคราะห์เป็นอินพุตของซอฟต์แวร์ ผลจากการวิเคราะห์ด้วยซอฟต์แวร์ AVL จะสามารถนำไปคำนวณหา Endurance, Range และ Cruise speed ซึ่งเป็นเงื่อนไขบังคับในการออกแบบได้



รูปที่ 3 Lifting surface ที่ใช้ในการวิเคราะห์ด้วยวิธี VLM



รูปที่ 4 กราฟเปรียบเทียบค่า C_{FX} ที่ได้จากการวิเคราะห์ CFD (สีส้ม) และ VLM (น้ำเงิน)



รูปที่ 5 กราฟเปรียบเทียบค่า C_{FZ} ที่ได้จากการวิเคราะห์ CFD (น้ำเงิน) และ VLM (เหลือง)

2. การคำนวณเสถียรภาพของเครื่องบิน (Compute Aircraft Stability) สามารถวิเคราะห์ได้ด้วยซอฟต์แวร์ AVL เช่นกัน โดยปกติแล้วการออกแบบอากาศยานจะสามารถระบุเสถียรภาพในการบินทั้ง 3 แกน (Longitudinal axis, Lateral axis, Directional axis) ได้จากตัวแปร $C_{m,\alpha} < 0$, $C_{n,\beta} > 0$ และ $C_{l,\beta} < 0$ ตามลำดับ

3. การประมาณค่าน้ำหนัก (Weight Estimation) ปกติแล้วการประมาณค่าน้ำหนักในขั้นตอนการออกแบบตามแนวคิดของอากาศยานสามารถทำได้โดยใช้ข้อมูลทางสถิติของอากาศยานที่มีอยู่แล้วในการทำนาย โดยวิธีนี้จะใช้ได้กับอากาศยานที่เคยสร้างขึ้นมาเป็นต้นแบบแล้ว เช่น เครื่องบินพาณิชย์ แต่จะไม่สามารถทำนายอากาศยานในรูปแบบใหม่ ๆ ได้แม่นยำ ดังนั้น เพื่อให้การประมาณค่าน้ำหนักมีประสิทธิภาพมากขึ้น จำนวนของชั้นคอมโพสิตที่ถูกใช้ในการขึ้นรูปผิวของอากาศยานได้กำหนดให้เท่ากับ 3 ชั้น และโครงสร้างของปีกประกอบด้วยโครงสร้างตามขวาง (Rib) และโครงสร้างตามยาว (Spar) ถูกกำหนดให้เท่ากับ 5 และ 2 ชั้น สำหรับแต่ละปีกตามลำดับ น้ำหนักของชั้นคอมโพสิตต่อพื้นที่ผิวสามารถหาได้จากการทดลองขึ้นรูปวัสดุคอมโพสิตของผ้าคาร์บอนลายหนึ่ง โดยมีการวางผ้าจำนวน 3 ชั้น แล้วทำการขึ้นรูปเป็นแผ่นด้วยวิธี Resin Infusion พบว่า มีน้ำหนักต่อพื้นที่ประมาณ 1,000 กิโลกรัมต่อตารางเมตร ดังนั้น น้ำหนักของอากาศยานจะสามารถคำนวณได้โดยการวัดพื้นที่ผิวทั้งหมดคูณกับความหนาแน่นของวัสดุคาร์บอนไฟเบอร์ก็จะประมาณค่าน้ำหนักที่แม่นยำของโครงสร้างได้ น้ำหนักของแบตเตอรี่สามารถคำนวณได้จากข้อมูลน้ำหนักของแบตเตอรี่ที่มีอยู่ในท้องตลาดโดยน้ำหนักแบตเตอรี่ประเภท Li-Po ขนาด 5500 mAh

จะมีน้ำหนัก 800 กรัมต่อ 1 ก้อน หรือสามารถคำนวณเป็นฟังก์ชันเส้นตรง 1 mAh ต่อน้ำหนัก 0.1454 กรัม

4. การวิเคราะห์ใบพัด (Propeller Analysis) การเลือกใบพัดให้เหมาะสมกับการออกแบบเป็นโจทย์ที่ทำนายสำหรับนักออกแบบ โดยปกติแล้วการเลือกใบพัดทำให้ได้โดยใช้ประสบการณ์ในการออกแบบ เพื่อลดการตัดสินใจในการออกแบบ ใบพัดถูกนำมาเป็นตัวแปรในการออกแบบ ดังนั้น ในการศึกษาครั้งนี้จึงได้นำวิธี BEMT [14] มาใช้ในการวิเคราะห์ประสิทธิภาพของใบพัด เช่น อัตราการกินพลังงาน (Power consumption) และ แรงขับ (Thrust)

3. กระบวนการหาค่าเหมาะสมที่สุดของปัญหาการออกแบบตามแนวคิดของกามิกาเซโดรนปีกรูปตัวเอ็กซ์

การหาค่าเหมาะสมที่สุดของปัญหาการออกแบบตามแนวคิดของกามิกาเซโดรนปีกรูปตัวเอ็กซ์สามารถอธิบายได้ด้วยสมการที่ (1)

$$\min_x f(x) = \{f_1(x), f_2(x)\}^T = \{W_{total}, -E\}^T \quad (1)$$

subject to

$$g(x) \leq 0, i = 1, \dots, m$$

$$\underline{x}^L \leq x \leq \underline{x}^U$$

โดยที่สมการจัดอยู่ในรูปแบบของความสัมพันธ์ระหว่าง ฟังก์ชันเป้าหมาย (f) ตัวแปรในการออกแบบ (x) และเงื่อนไขบังคับ (g) เป้าหมายของการออกแบบคือ การหาค่าต่ำที่สุดของน้ำหนักเครื่องบิน (W_{total}) และหาค่าสูงที่สุดของเวลาในการบิน (E) ภายใต้วแปรออกแบบทั้งหมด 12 ตัว ดังตารางที่ 1 ตัวแปร x_1 คือความจุแบตเตอรี่ที่ใช้ในการปฏิบัติการการบิน ตัวแปร $x_2 - x_6$ คือ พารามิเตอร์ของใบพัด ในขณะที่ตัวแปร $x_7 - x_{12}$

คือ พารามิเตอร์ของปีกอากาศยาน เงื่อนไขบังคับของการออกแบบแสดงให้เห็นดังตารางที่ 2 เงื่อนไขบังคับของภารกิจการบินแสดงให้เห็นดังตัวแปรที่ $g_1 - g_4$ โดยที่เสถียรภาพของการบินประกอบด้วย $g_5 - g_8$

อัลกอริทึม MMIPDE ถูกนำมาใช้เพื่อแก้ปัญหาการออกแบบตามแนวคิดของกามิกาชเโดรณปีกรูปตัวเอ็กซ์ การตั้งค่าพารามิเตอร์เริ่มต้นของอัลกอริทึม MMIPDE และกระบวนการปรับแต่ง (Reproduction) และ การคัดเลือก (Selection)

ได้กำหนดตามอัลกอริทึมต้นฉบับ โดยในกระบวนการหาค่าเหมาะสมที่สุดได้กำหนดจำนวนประชากรเท่ากับ 50 แล้วให้จำนวนวนรอบซ้ำเท่ากับ 200 การเก็บจำนวนประชากรต่อรอบเท่ากับ 50 และให้จำนวนฐานสอง (Binary) เท่ากับ 16 การทดลองได้มีการทำซ้ำทั้งหมด 10 ครั้ง จากนั้นหาผลลัพธ์ที่ดีที่สุด โดยสามารถวัดค่าการเปรียบเทียบปริมาตรเกิน (Hypervolume) ผลที่ได้จะแสดงออกมาอยู่ในรูปแบบของ Pareto front ของทั้งสองฟังก์ชันเป้าหมาย

ตารางที่ 1 ตัวแปรออกแบบ

No.	Design variables	Lower limit	Upper limit
1	ความจุแบตเตอรี่ (Battery capacity, mAh)	5500	16500
2	เส้นผ่านศูนย์กลาง (Blade diameter, m)	0.20	0.30
3	ความยาวของคอร์ดที่โคนใบพัด (Blade root chord, m)	0.02	0.03
4	อัตราส่วนของความยาวคอร์ดที่ปลายใบพัด (Blade taper ratio)	0.40	0.60
5	มุมปะทะเริ่มต้นใบพัด (Blade incidence angle at tip, deg.)	4.00	8.00
6	มุมบิดใบพัด (Blade twist, deg.)	-45.00	-30.00
7	จุดศูนย์กลางถ่วงออกแบบ (Designed centre of gravity in x-axis, m)	0.30	0.50
8	ความยาวครึ่งปีก (Wing half span, m)	0.40	0.60
9	มุมยกปีก (Wing dihedral, deg.)	30.00	45.00
10	ความยาวของคอร์ดที่โคนปีก (Wing root chord) (m)	0.14	0.18
11	มุมปะทะเริ่มต้นปีก (Wing incidence, deg.)	3.00	6.00
12	จุดวางปีกในแนวแกนเอ็กซ์ (Wing translational position on x axis, m)	0.30	0.40


ตารางที่ 2 เงื่อนไขบังคับในการออกแบบ

No.	Constraints	Lower limit	Upper limit
1	เวลาการบิน (Endurance, hr.)	-	>0.5
2	ระยะทางการบิน (Range, km)	-	>50
3	ความเร็วครุซ (Cruise speed, m/s)	<30	-
4	ความเร็วปีน (Rate of climb, m/s)	-	>5
5	สัมประสิทธิ์โมเมนต์เงยเทียบกับมุมปะทะ (Coefficient of the pitching moment versus angle of attack)	<0	-
6	สัมประสิทธิ์โมเมนต์เอียงเทียบกับมุมปะทะ (Coefficient of the yawing moment versus side slip angle)	-	>0
7	สัมประสิทธิ์โมเมนต์หมุนเทียบกับมุมปะทะ (Coefficient of the rolling moment versus side slip angle)	<0	-
8	มุมปะทะสูงสุดของแพนบังคับ (Maximum deflection of the control surface, deg.)	-5	5
9	Static margin (%)	5	15

4. ผลการออกแบบ

หลังจากทำการทดลองซ้ำทั้งหมด 10 ครั้งของการแก้ปัญหาการออกแบบตามแนวคิดของกามิกาชโรนปีกรูปตัวเอ็กซ์ด้วยอัลกอริทึม MMIPDE พบว่า Pareto front ของการออกแบบที่ให้ค่า Hypervolume สูงที่สุดสามารถแสดงให้เห็นดังรูปที่ 6 ตัวอย่างผลการออกแบบ 3 จุดบน Pareto front ไม่ว่าจะเป็นฟังก์ชันเป้าหมายตัวแปรในการออกแบบและเงื่อนไขบังคับ ถูกนำมาแสดงให้เห็นดังตารางที่ 3, 4 และ 5 ตามลำดับ

จากผลลัพธ์ พบว่า ขนาดของความจุแบตเตอรี่ (x1) ส่งผลโดยตรงต่อฟังก์ชันเป้าหมาย ไม่ว่าจะเป็นน้ำหนักของอากาศยานและระยะเวลาในการบิน ยิ่งความจุของแบตเตอรี่มากก็จะทำให้น้ำหนักมากขึ้น เช่นเดียวกับความจุของแบตเตอรี่มากขึ้นก็จะทำให้ระยะเวลาในการบินมากขึ้นเช่นกัน



รูปที่ 6 Pareto front ของการหาค่าเหมาะสมที่สุด

ดังผลลัพธ์ของ Solution ที่ 1 เปรียบเทียบกับ Solution ที่ 2 พบว่า รูปทรงของอากาศยานและใบพัดแทบไม่มีความแตกต่างกัน แต่เมื่อเปรียบเทียบกับ Solution ที่ 3 พบว่า ตัวแปร x1 คือ ขนาดของแบตเตอรี่ได้เท่ากับค่าสูงสุดของขอบเขตตัวแปร

ตารางที่ 3 ฟังก์ชันเป้าหมายของผลลัพธ์ที่ถูกเลือก

No.	Objective functions	Solution 1	Solution 2	Solution 3
1	Total weight (kg)	7.7299	8.0823	10.0248
2	Endurance (hr)	0.5433	0.6830	1.3820

ตารางที่ 4 ตัวแปรในการออกแบบของผลลัพธ์ที่ถูกเลือก

No.	Design variables	Solution 1	Solution 2	Solution 3
1	Battery capacity (mAh)	7,385	9,737	16,500
2	Blade diameter (m)	0.2987	0.2986	0.2000
3	Blade root chord (m)	0.0300	0.0300	0.0200
4	Blade taper ratio	0.4000	0.4038	0.4000
5	Blade incidence angle at tip (deg.)	7.9911	8.0000	8.0000
6	Blade twist (deg.)	-44.9971	-44.9924	-45.0000
7	Designed centre of gravity in x-axis (m)	0.5000	0.5000	0.5000
8	Wing half span (m)	0.4000	0.4000	0.6000
9	Wing dihedral (deg.)	30.0000	30.0000	30.0000
10	Wing root chord (m)	0.1401	0.1400	0.1400
11	Wing incidence (deg.)	6.0000	6.0000	3.0000
12	Wing translational position on x axis (m)	0.3595	0.3583	0.3369

ตารางที่ 5 เงื่อนไขบังคับของผลลัพธ์ที่ถูกเลือก

No.	Constraints	Solution 1	Solution 2	Solution 3
1	Endurance (hr.)	0.5433	0.6831	1.3820
2	Range (km)	55.4086	71.6676	146.7115
3	Cruise speed (m/s)	29.2805	29.8990	29.9930
4	Rate of climb (m/s)	12.6496	12.9180	11.0142
5	Coefficient of the pitching moment versus angle of attack	-0.5426	-0.5336	-0.8692
6	Coefficient of the yawing moment versus side slip angle	0.2979	0.2948	0.4808
7	Coefficient of the rolling moment versus side slip angle	-0.1412	-0.1430	-0.150236
8	Maximum deflection of the control deflection (deg.)	1.4450	1.3801	4.1749
9	Static margin	8.34	8.21	7.46

ส่งผลให้มีระยะเวลาในการบินมากกว่า Solution ที่ 1 และ 2 เป็นเท่าตัว และด้วยเหตุผลนี้ทำให้น้ำหนักของ Solution ที่ 3 เท่ากับ 10.0248 กิโลกรัม เมื่อน้ำหนักอากาศยานมากขึ้นพื้นที่ปีกของอากาศยานก็เพิ่มขึ้นเช่นกัน ดังตัวแปร x_8 (Wing half span) มีค่าเท่ากับ 0.6 เมตร ซึ่งเท่ากับค่าสูงสุดของขอบเขตในการออกแบบ การเพิ่มขึ้นของความยาวปีกนั้นหมายความว่าปีกมีพื้นที่ผิวเพิ่มขึ้นเช่นกันในขณะที่ Wing root chord มีค่าเท่าเดิม ดังนั้น การเพิ่มขึ้นของความยาวปีกของ Solution ที่ 3 จะส่งผลให้อากาศยานสามารถเพิ่มแรงยก เพื่อช่วยในการต้านแรงจากน้ำหนักที่เพิ่มขึ้น จากตารางที่ 5 การเปรียบเทียบระหว่างเงื่อนไขบังคับของแต่ละผลลัพธ์พบว่า Cruise speed เป็นเงื่อนไขบังคับที่มีปัจจัยสำคัญในการออกแบบอากาศยาน เนื่องจากผลลัพธ์ที่ได้เข้าใกล้ค่ามากที่สุดของเขตบังคับ ค่า Endurance และ Range มีแนวโน้มไปในทางเดียวกัน และผลลัพธ์จากเงื่อนไขบังคับ $g_5 - g_9$ บ่งบอกว่าเครื่องบินมีเสถียรภาพในทั้งสามแนวแกน

5. สรุปและอภิปรายผล

ในการศึกษาการออกแบบตามแนวคิดของกามิกาเซโดรอนปีกรูปตัวเอ็กซ์โดยใช้วิธีเมตาฮีริสติกส์ อัลกอริทึมที่ถูกนำมาใช้คือ MMIPDE ซึ่งสามารถใช้ในการหาค่าที่เหมาะสมที่สุดแบบหลายฟังก์ชันเป้าหมายได้ ฟังก์ชันเป้าหมายของการออกแบบคือหาค่าต่ำที่สุดของน้ำหนักเครื่องบินและหาค่าสูงที่สุดของเวลาในการบิน ตัวแปรในการออกแบบคือรูปร่างและขนาดของปีกอากาศยานและพารามิเตอร์ของใบพัดโดยมีภารกิจในการบินและเสถียรภาพในการบินเป็นเงื่อนไขบังคับในการออกแบบ ก่อนที่จะเริ่มทำการออกแบบได้มีการตรวจสอบเครื่องมือในการวิเคราะห์ผลของอากาศพลศาสตร์ของวิธี VLM เทียบกับวิธี

CFD พบว่า VLM ให้ผลที่ใกล้เคียงกับวิธี CFD และยังใช้เวลาในการคำนวณที่ต่ำกว่ามาก เหมาะสำหรับใช้ในการออกแบบร่วมกับวิธี Optimisation แต่จะต้องคำนึงถึงเงื่อนไขของการใช้งานวิธี VLM เช่นไม่สามารถวิเคราะห์การไหลแยกและแรงเสียดทานของอากาศได้ ผลของการออกแบบแสดงให้เห็นอยู่ในรูปของ Pareto front ตัวอย่างการออกแบบถูกเลือกมาทั้งสิ้น 3 ตัวอย่าง เพื่อวิเคราะห์ผลการออกแบบพบว่า ความจุของแบตเตอรี่ส่งผลต่อฟังก์ชันเป้าหมายโดยตรงต่อฟังก์ชันเป้าหมายพารามิเตอร์ของอากาศยานและใบพัดจะถูกนำไปออกแบบในการออกแบบขั้นกลาง (Preliminary Design) ต่อไป ในมุมมองภาพรวมของกระบวนการพบว่า วิธีการหาค่าที่เหมาะสมที่สุดสามารถใช้ในการออกแบบอากาศยานได้เป็นอย่างดี และสามารถใช้กับอากาศยานรูปแบบใหม่ ๆ ได้อย่างเหมาะสม แต่ต้องอาศัยองค์ความรู้ที่หลากหลาย เพื่อที่จะพัฒนาปัญหาให้ใกล้เคียงกับความเป็นจริงมากที่สุดข้อเสนอนี้ในการออกแบบแบ่งออกเป็นสองข้อ คือ 1. ควรพิจารณาความไม่แน่นอนของการออกแบบด้วย เช่น ความไม่แน่นอนของการประมาณค่าน้ำหนักความไม่แน่นอนของการวิเคราะห์อากาศพลศาสตร์ และอื่น ๆ 2. ควรพิจารณาระบบควบคุมเบื้องต้นในกระบวนการออกแบบในขั้นตอนการออกแบบตามแนวคิดด้วย

6. เอกสารอ้างอิง

- [1] Wikipedia. "IAI Harop." EN.WIKIPEDIA.org. https://en.wikipedia.org/wiki/IAI_Harop (accessed Apr. 17, 2024).
- [2] AeroVironment. "SWITCHBLADE® 300 BLOCK 20." AVINC.com. <https://www.avinc.com/lms/switchblade> (accessed Apr. 17, 2024).

- [3] Wikipedia. "ZALA Lancet." EN.WIKIPEDIA.org. https://en.wikipedia.org/wiki/ZALA_Lancet (accessed Apr. 17, 2024).
- [4] M. H. Sadraey, *Aircraft Design: A Systems Engineering Approach*, Hoboken, NJ, USA: Wiley, 2012.
- [5] R. Storn and K. Price, "Differential Evolution - A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces," *J. Glob. Optim.*, vol. 11, no. 4, pp. 341 - 359, 1997, doi: 10.1023/A:1008202821328.
- [6] J. Kennedy and R. Eberhart, "Particle Swarm Optimization," *ICNN'95 - Int. Conf. Neural Netw.*, Perth, WA, Australia, 1995, pp.1942-1948, doi:10.1109/ICNN.1995.488968.
- [7] S. Mirjalili, P. Jangir, and S. Saremi, "Multi-objective Ant Lion Optimizer: A Multi-objective Optimization Algorithm for Solving Engineering Problems," *Appl. Intell.*, vol. 46, no. 1, pp. 79 - 95, 2017.
- [8] M. A. E. Aziz, A. A. Ewees, A. E. Hassanien, M. Mudhsh, and S. Xiong, "Multi-objective Whale Optimization Algorithm for Multilevel Thresholding Segmentation," in *Advances in Soft Computing and Machine Learning in Image Processing*, A. E. Hassanien and D. A. Oliva, Eds., Cham, Switzerland: Springer, 2018, pp. 23 - 39.
- [9] J. Zhang and A. C. Sanderson, "JADE: Adaptive Differential Evolution with Optional External Archive," *IEEE Trans. Evol. Comput.*, vol. 13, no. 5, pp. 945-958, 2009.
- [10] S. Wang, Y. Li, and H. Yang, "Self-adaptive Mutation Differential Evolution Algorithm based on Particle Swarm Optimization," *Appl. Soft Comput.*, vol. 81, p. 105496, 2019.
- [11] K. Wansasueb, N. Pholdee, N. Panagant, and S. Bureerat, "Multiobjective Meta-heuristic with Iterative Parameter Distribution Estimation for Aeroelastic Design of an Aircraft Wing," *Eng. Comput.*, vol. 38, pp. 695 - 713, 2022.
- [12] K. Budziak, *Aerodynamic Analysis with Athena Vortex Lattice (AVL)*. Hamburg, Germany: Hamburg Aircraft Design and Systems Group (AERO), Department of Automotive and Aeronautical Engineering, Hamburg University of Applied Sciences, 2015. [Online]. Available: <https://nbn-resolving.org/urn:nbn:de:gbv:18302-aero-2015-09-20.015>
- [13] R. A. McDonald and J. R. Gloude-mans, "Open Vehicle Sketch Pad: An Open Source Parametric Geometry and Analysis Tool for Conceptual Aircraft Design," in *2022 AIAA SCITECH Forum*, 2022, doi: 10.2514/6.2022-0004.
- [14] Cotri. "Blade Element Momentum Theory: Developed during My Bachelor Thesis in Aerospace Engineering." GITHUB.com. <https://github.com/cotri/BEMT> (accessed Apr. 17, 2024).

วารสารวิชาการเทคโนโลยีป้องกันประเทศ ปีที่ 6 ฉบับที่ 13 มกราคม – มิถุนายน 2567

บทความวิชาการ (Academic Articles)

- การจำแนกประเภทอาวุธโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน
ที่มีการปรับรูปแบบให้เหมาะสมสำหรับอุปกรณ์พกพา
เอกราช นินทรา, สุรพันธุ์ เอื้อไพบูลย์ และ สมชาติ จิรวิภากร
- โปรแกรมสำหรับเรียนรู้แบบโต้ตอบโดยใช้ฐานข้อมูลแบบ MySQL
เพื่อเก็บข้อมูลของรถฐานยิงจรวดหลายลำกล้องอเนกประสงค์
กันต์ธร นาทอง, เจษฎา ไกรขาว, รัฐชิตา ชันทอง, ปิยะรส มาลีเจริญ,
สิรภพ สันติธรรรงค์ และ นริศ จันทร์น้ำ

บทความวิเคราะห์เทคโนโลยีป้องกันประเทศ (Defence Analysis Article)

- ปัญญาประดิษฐ์แบบรู้สร้างกับการประยุกต์ใช้ทางการทหาร
กนก บุณนาค

บทความวิจัย (Research Articles)

- Comparison between Equilibrium Optimization and Systune
on Aircraft Blank Angle Control
Yodsadej Kanokmedhakul and Nantiwat Pholdee
- การวิเคราะห์แบ่งส่วนพื้นที่ภาพถ่ายทางอากาศด้วย Generative Adversarial Networks
กิตตากร วิริยะศาสตร์, วรากร เลื่องลือวุฒิ, วิชัย แผ้วเกษม, พันธุ์เทพ แก้วมงคล,
สัญญา มิตรเอม และ พันศักดิ์ เทียนวิบูลย์
- การประยุกต์ใช้ Google's Teachable Machine ในการตรวจจับใบหน้าผู้ก่อการร้าย
ธรรมราช อาษาสุวรรณ, ชนัชฎาภรณ์ ใจแน่น และ ภรณ์ระวี โสภณพิเชฐ
- การทดสอบและพัฒนาความแข็งแรงของโครงสร้างปีกอากาศยานไร้คนขับ
เจษฎา ชมดารา และ ณัฐธิเบศ จารุเพ็ง
- การเปรียบเทียบโมเดลตรวจจับวัตถุด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน
ในงานภาพถ่ายทางอากาศจากอากาศยานไร้คนขับ
กิตตากร วิริยะศาสตร์, วรากร เลื่องลือวุฒิ, ปิยะรส มาลีเจริญ, สิรภพ สันติธรรรงค์,
วิชัย แผ้วเกษม, พันธุ์เทพ แก้วมงคล, สัญญา มิตรเอม และ พันศักดิ์ เทียนวิบูลย์
- การหาค่าเหมาะสมที่สุดของการออกแบบตามแนวคิดของกามิกาเซโดรอนปีกรูปตัวเอ็กซ์
ขับเคลื่อนด้วยระบบไฟฟ้าด้วยเมต้าฮีโรสติกส์
ภาคิน จำปาศักดิ์

