

# การจำแนกประเภทอาวุธโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันที่มีการปรับรูปแบบให้เหมาะสมสำหรับอุปกรณ์พกพา

เอกราช นินทรา<sup>1\*</sup> สุรพันธุ์ เอื้อไพบูลย์<sup>2</sup> และ สมชาติ จิรวิภากร<sup>3</sup>

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

<sup>1</sup> ภาควิชาวิศวกรรมป้องกันประเทศ, คณะวิศวกรรมศาสตร์, สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

<sup>2</sup> ภาควิชาอิเล็กทรอนิกส์, คณะวิศวกรรมศาสตร์, สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

<sup>3</sup> ภาควิชาวิศวกรรมไฟฟ้า, คณะวิศวกรรมศาสตร์, สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

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

# Classification of Weapons using Convolution Neural Networks Suitable for Portable Devices

Eakarach Nintra <sup>1\*</sup> Surapan Airphaiboon <sup>2</sup> and Somchat Jiriwibhakorn <sup>3</sup>

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

---

<sup>1</sup> Defence Engineering, School of Engineering, King Mongkut's Institute of Technology Ladkrabang

<sup>2</sup> Electronics Engineering, School of Engineering, King Mongkut's Institute of Technology Ladkrabang

<sup>3</sup> 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 หาวีกำหนดรูปแบบที่เหมาะสมที่สุดในการปรับใช้คุณสมบัติของโมเดลให้สามารถตรวจจับประเภทของมีเสียงด้วยการถ่ายภาพมีเสียงแบบเรียลไทม์หรือเลือกหนึ่งภาพได้ 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

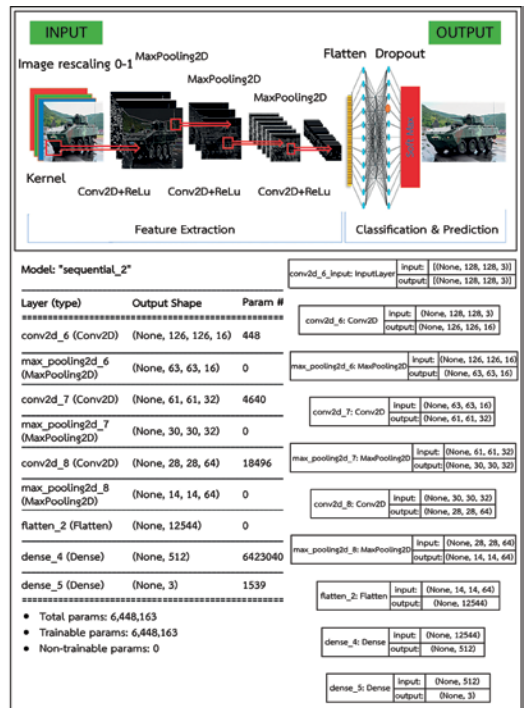
นำข้อมูลรูปภาพอาวุธขนาดไม่เกิน 640x480 พิกเซลต่อหนึ่งภาพ มาทำการแบ่งชุดข้อมูลสำหรับฝึกฝนโมเดล จากกลุ่มที่ 1 จำนวน 10,789 ภาพ ชุดข้อมูลรูปภาพอาวุธ รถถัง (Tank) เครื่องบินรบ (Military Aircraft) อาวุธปืน (Gun) เรือรบ (Military Ship) ขีปนาวุธ (Missile Rocket) เครื่องยิงจรวด (Missile Launcher) มีด (Knife) 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 ตัวอย่าง  
ชุดข้อมูลรูปภาพอาวุธ 8 ชนิด ขนาด 128x128 พิกเซล  
จำนวน 10,789 ภาพ ใช้ในการเรียนรู้ 8,651 ภาพ  
ใช้สำหรับตรวจสอบ 1,069 ภาพ และใช้สำหรับ  
ทดสอบ 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  
และโมเดลพร้อมใช้งานที่ได้รับการฝึกฝนมาก่อน  
แล้วล่วงหน้า 8 โมเดล ที่ถูกรวมไว้ใน Keras API ตาม  
ตารางที่ 1 ได้แก่ VGG19, ResNet50V2, MobileNetV2,  
EfficientNet-B0, B1, B2, B5 และ B7 โดยนำเข้าชุดข้อมูล  
รูปภาพจำนวนเท่ากันในแต่ละชุดการทดลอง

จากการทดสอบ Keras Applications [16]  
โมเดลพร้อมใช้งานที่ได้รับการฝึกฝนมาก่อนแล้ว  
ล่วงหน้า 8 แบบ ตามตารางที่ 1 รายละเอียดของการ  
เปรียบเทียบโมเดล ได้ทำการเทียบประสิทธิภาพของ  
โมเดลระหว่าง Accuracy กับ Parameters ดังแสดง  
จากตัวอย่างของโมเดล 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 ก่อนนำไปเรียนรู้ เมื่อพิจารณากราฟในรูปที่ 3(A) การทดลองพบว่า ค่า Accuracy มีแนวโน้มเพิ่มขึ้น แต่ยังมีช่วงห่างระหว่าง Training Accuracy กับ Validation Accuracy สูง ซึ่งแสดงว่ามีข้อมูลภาพในการเรียนรู้ไม่เพียงพอในการ Train Model รวมทั้งกราฟในรูปที่ 3(B) พิจารณาจากค่า Loss เป็นหลัก พบว่า ยังมีการ 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 ซึ่งสามารถนำมาส่วส่วนของ 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	

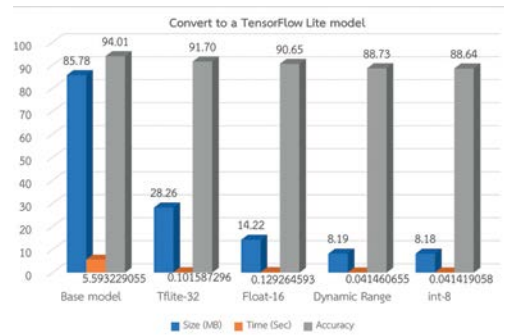
รูปที่ 5 Confusion Matrix ของการจำแนกอาวุธ 8 ชนิด

## 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] ระบบการเรียนรู้เชิงลึกเพื่อการจดจำและการรู้จำหุ่นยนต์ซีเรียลแอมบนเคลื่อนที่บนแป้นในฮาร์ดดิสก์ กระบวนการทดสอบประสิทธิภาพด้วย EfficientNet-B0 ให้ความแม่นยำมากกว่า 99% แสดงให้เห็นประสิทธิภาพการจัดหมวดหมู่ที่เหนือกว่าการอ่านของมนุษย์ แต่ในการศึกษาครั้งนี้ให้ค่าความแม่นยำน้อยกว่า เนื่องจากการศึกษานี้เป็นการจำแนกรูปภาพของวัตถุที่มีลักษณะทางกายภาพที่ใกล้เคียงกัน คุณลักษณะของภาพมีความซับซ้อนและหลากหลายซึ่งยากต่อการจำแนก ผลการศึกษาพบว่าผลลัพธ์จากการทดลองนี้ EfficientNet-B0 มีความเหมาะสมในการนำไปใช้งาน สามารถทำงานได้อย่างถูกต้องแม่นยำสูงสุด 94.01%

5.1.4 จากรูปที่ 6 ผลการ Convert ไปเป็น TFLite Model แสดงการเปรียบเทียบคุณสมบัติของโมเดลในการลดขนาด ลดการใช้เวลาแฝงในการโต้ตอบกับระบบประมวลผลภาพ และค่าความแม่นยำลดลงจากเดิมเมื่อเทียบกับ

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. Cheewaparakobkit, "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](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.