



การจำแนกโควิด 19 จากภาพ CT Scan ด้วยการเรียนรู้แบบรวมกลุ่ม

พงษ์ศธร เชิดสม*

งานวิชาการและวิจัย, คณะสถาปัตยกรรมศาสตร์, มหาวิทยาลัยขอนแก่น

* ผู้ประสานงานเผยแพร่ (Corresponding Author), E-mail: pongche@kku.ac.th

วันที่รับบทความ: 8 มีนาคม 2568; วันที่ทบทวนบทความ: 19 พฤษภาคม 2568; วันที่ตอบรับบทความ: 6 มิถุนายน 2568

วันที่เผยแพร่ออนไลน์: 19 สิงหาคม 2568

บทคัดย่อ: การระบาดใหญ่ของเชื้อไวรัสโควิด 19 ได้เน้นย้ำถึงความจำเป็นอย่างยิ่งในการพัฒนาเครื่องมือวินิจฉัยที่มีประสิทธิภาพซึ่งสามารถช่วยบุคลากรทางการแพทย์ในการประเมินผู้ป่วยได้อย่างรวดเร็วและแม่นยำมากยิ่งขึ้น งานวิจัยนี้นำเสนอการพัฒนาแบบจำลองสำหรับการจำแนกเชื้อไวรัสโควิด 19 จากภาพเอกซเรย์คอมพิวเตอร์ทรวงอก (CT Scan) ด้วยเทคนิคการเรียนรู้แบบรวมกลุ่ม (Ensemble Method) ด้วยชุดข้อมูล COVID-19 Radiography จำนวน 7,232 ภาพ แบ่งเป็นเชื้อโควิด 3,616 ภาพ ไม่มีเชื้อโควิด 3,616 ภาพ แบ่งชุดข้อมูลสำหรับการทดลองเป็นชุดสำหรับเรียนรู้ร้อยละ 70 (Training Set) จำนวน 2,531 ภาพ ชุดสำหรับการตรวจสอบการเรียนรู้ร้อยละ 20 (Validation set) จำนวน 723 ภาพ ชุดสำหรับการทดสอบการเรียนรู้ร้อยละ 10 (Test set) 362 ภาพ และใช้รวมเทคนิคการแบ่งข้อมูล (K-Fold Cross Validation) จำนวน 5 ชุด (K=5) การทดลองได้แบ่งออกเป็น 3 กลุ่ม กลุ่มที่ 1 ใช้แบบจำลองที่ได้รับความนิยม 38 แบบจำลอง เลือกแบบจำลองที่ได้รับค่าความถูกต้อง (Accuracy) มากที่สุด 3 ลำดับนำไปใช้กับกลุ่มการทดลองที่ 2 และ 3 กลุ่มที่ 2 เชื่อมแบบจำลองโดยใช้เทคนิค Bagging ร่วมกับชุดข้อมูล 5 ชุด จำนวน 3 รูปแบบการทดลอง กลุ่มที่ 3 เชื่อมแบบจำลองโดยใช้เทคนิค Bagging โดยใช้แบบจำลองที่มีค่าความถูกต้องมากที่สุดในแต่ละแบบจำลอง จำนวน 2 รูปแบบการทดลอง พบว่าการทดลองในกลุ่มที่ 3 แบบจำลอง MobileNet ร่วมกับ DenseNet121 มีค่าความถูกต้องร้อยละ 99.30 เมื่อเปรียบเทียบกับแบบจำลองพื้นฐานในกลุ่มที่ 1 มีค่าความถูกต้องร้อยละ 97.23 พบว่ามีค่าความถูกต้องที่สูงขึ้นร้อยละ 2.07

คำสำคัญ: การจำแนกโควิด 19; ภาพเอกซเรย์ CT Scan; เทคนิคการเรียนรู้แบบรวมกลุ่ม; โครงข่ายประสาทเทียม

Classification of COVID-19 from Chest CT Images Using Ensemble Techniques

Pongsathorn Chedsom *

Academic Affairs and Research, Faculty of Architecture, Khon Kaen University

* Corresponding author, E-mail: pongche@kku.ac.th

Received: 8 March 2025; Revised: 19 May 2025; Accepted: 6 June 2025

Online Published: 19 August 2025

Abstract: The COVID-19 pandemic has emphasized the critical need for effective diagnostic tools that can assist medical personnel in evaluating patients more rapidly and accurately. This research presents the development of a model for classifying COVID-19 from chest computed tomography (CT) scans using ensemble learning methods. The study utilized the COVID-19 Radiography dataset containing 7,232 images, evenly divided between 3,616 COVID-19 positive images and 3,616 COVID-19 negative images. The dataset was split data to a training set (70%, 2,531 images), a validation set (20%, 723 images), and a test set (10%, 362 images), with 5-fold cross-validation ($K=5$). The experimental methodology was divided into three groups: Group 1 involved testing 38 popular deep learning models and selecting the three highest-accuracy models for further experimentation. Group 2 combined these models using bagging techniques across the five cross-validation data folds in three different experimental configurations. Group 3 utilized bagging to combine the highest-performing versions of each selected model in two experimental configurations. The results show that the experiment group 3 using MobileNet and DenseNet121 together achieved an accuracy of 99.30%, compared to the baseline model in group 1 with an accuracy of 97.23%, which is 2.07% higher.

Keywords: Classification of COVID-19; Chest CT scan; Ensemble Techniques; Deep Learning



1. บทนำ

การระบาดของเชื้อไวรัส COVID-19 ส่งผลกระทบต่อระบบสาธารณสุข เศรษฐกิจ และสังคมทั่วโลกอย่างรุนแรง โดยเฉพาะอย่างยิ่งในกลุ่มประชากรที่มีความเสี่ยงสูง [1] เช่น ผู้สูงอายุ ผู้มีโรคประจำตัว และบุคลากรทางการแพทย์ แม้จะมีงานวิจัยจำนวนมากเกี่ยวกับเชื้อไวรัส COVID-19 เพื่อตอบสนองต่อความต้องการในหลาย ๆ ปัจจัยรวมทั้งการการรักษารักษาคัดกรองหาเชื้อไวรัสโดยกระบวนการต่าง ๆ

ปัจจุบันมีการพัฒนาแบบจำลองหรืองานวิจัยที่เกี่ยวข้องเพิ่มมากขึ้นปัจจุบันการใช้เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence: AI) ในทางการแพทย์ได้รับความนิยมมากยิ่งขึ้น โดยเฉพาะโครงข่ายประสาทเทียมเชิงลึก (Convolutional Neural Networks: CNN) กำลังปฏิวัติวงการแพทย์ด้วยความสามารถในการวิเคราะห์ภาพทางการแพทย์ได้อย่างรวดเร็วและแม่นยำสูงทำให้การวินิจฉัยโรคเบื้องต้นหรือการวินิจฉัยโดยละเอียดเป็นไปอย่างมีประสิทธิภาพมากขึ้น

การนำเทคโนโลยีปัญญาประดิษฐ์มาช่วยให้แพทย์ตรวจพบความผิดปกติหรือแนวโน้มของโรคได้ตั้งแต่ระยะเริ่มต้น สามารถเพิ่มโอกาสในการรักษาที่ประสบความสำเร็จและยกระดับคุณภาพชีวิตของผู้ป่วยมากยิ่งขึ้นการจำแนกประเภทของเชื้อไวรัส COVID-19 จากภาพเอกซเรย์คอมพิวเตอร์ (CT) ของทรวงอกโดยใช้แบบการเรียนรู้แบบกลุ่ม(Ensemble) เป็นความก้าวหน้าในด้านการถ่ายภาพทางการแพทย์และปัญญาประดิษฐ์ เนื่องจากการระบาดของ COVID-19 จำเป็นต้องมีวิธีการวินิจฉัยที่รวดเร็วและแม่นยำเทคนิคการเรียนรู้แบบกลุ่มจึงเป็นเครื่องมือที่มีประสิทธิภาพในการปรับปรุงความถูกต้องและ

ประสิทธิภาพของการตรวจจำแนกเชื้อไวรัส COVID-19 โดยการใช้ประโยชน์จากแบบจำลอง (Model) หรืออัลกอริทึมหลายตัวในการวิเคราะห์ภาพ CT Scan จากภาพทรวงอกซึ่งแบบจำลองหรืออัลกอริทึมนี้ช่วยเพิ่มประสิทธิภาพการจำแนกและพยากรณ์เชื้อไวรัสเบื้องต้น ซึ่งมีความสำคัญอย่างยิ่งสำหรับการวินิจฉัยและรักษาโรคเร็วขึ้นขึ้นเทคนิคการเรียนรู้แบบกลุ่มแบ่งออกเป็น 3 ประเภทหลัก ๆ ได้แก่ แบ็กกิง (Bagging) บูส ตั๊ง (Boosting) และ สแต็กกิง (Stacking) รวมการทำงานของแบบจำลองและของอัลกอริทึมต่าง ๆ เข้าด้วยกันเพื่อให้ได้ผลลัพธ์จากการพยากรณ์ที่มีความน่าเชื่อถือและมีความเสถียรมากขึ้นเมื่อเทียบกับแบบจำลองเดียวในบริบทของ COVID-19 ได้แสดงให้เห็นว่าวิธีการแบบกลุ่มนั้นสามารถแก้ไขปัญหา เช่น ความไม่สมดุลของข้อมูล (Data Imbalance) ซึ่งเกิดจากการที่ตัวอย่างของโรคหรือความผิดปกติมีจำนวนน้อยกว่าตัวอย่างปกติอย่างมากและมีมิติข้อมูลสูง (High Dimensionality) โดยภาพทางการแพทย์มีความละเอียดสูง เช่น ภาพ CT scan หรือ MRI ที่มีขนาดหลายพิกเซลในแต่ละมิติหรือภาพสามมิติทำให้มีพารามิเตอร์จำนวนมากที่ต้องนำมาใช้ในการเรียนรู้ของแบบจำลอง (Training) ซึ่งปัจจุบันการนำเทคโนโลยีปัญญาประดิษฐ์มาใช้เกิดขึ้นอย่างแพร่หลายมากยิ่งขึ้นการวิจัยนี้จึงมีวัตถุประสงค์เพื่อการจำแนกเชื้อไวรัส COVID-19 จากภาพ CT Scan โดยใช้เทคนิคการเรียนรู้แบบรวมกลุ่มเพื่อให้ประสิทธิภาพในการจำแนกมากยิ่งขึ้นอีกทั้งยังเป็นการลดความเสี่ยงในการตัดสินใจของแบบจำลองเดียวกระจายความเสี่ยงและเพิ่มความมั่นใจในการจำแนกโรคของแบบจำลอง



2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎี


2.1.1 เทคนิคการเรียนรู้แบบรวมกลุ่ม

เทคนิคการเรียนรู้แบบรวมกลุ่ม (Ensemble Method) เป็นเทคนิคในการเรียนรู้ของเครื่อง (Machine Learning) ที่ใช้การรวมผลลัพธ์จากการพยากรณ์ของแบบจำลองหลาย ๆ ตัว (Weak Learners) เพื่อสร้างแบบจำลองที่มีความแม่นยำที่ดีขึ้น (Strong Learner) หลักการพื้นฐานของการเรียนรู้แบบรวมกลุ่มคือการที่แบบจำลองแต่ละตัวอาจมีข้อผิดพลาดที่แตกต่างกัน โดยใช้การรวมผลลัพธ์ของแบบจำลองเหล่านั้นเข้าด้วยกันจะช่วยลดข้อผิดพลาดและเพิ่มความน่าเชื่อถือในการพยากรณ์ผลลัพธ์ซึ่งมีความแม่นยำสูงกว่าการใช้แบบจำลองเดี่ยว [2]

2.1.2 รูปแบบเทคนิคการเรียนรู้แบบรวมกลุ่ม

การแบ่งเทคนิคการเรียนรู้แบบกลุ่มสามารถแบ่งออกเป็น 3 ประเภทหลัก ๆ ได้แก่

Boosting เป็นเทคนิคการเรียนรู้ของเครื่องที่มุ่งเน้นการพัฒนาแบบจำลองที่อ่อนแอ (Weak Learner) ให้กลายเป็นแบบจำลองที่แข็งแกร่ง (Strong Learner) โดยการฝึกโมเดลแบบตามลำดับ (Sequentially) แบบจำลองใหม่แต่ละตัวจะถูกฝึกสอนเพื่อแก้ไขข้อผิดพลาดของแบบจำลองก่อนหน้า โดยให้ความสำคัญกับข้อมูลที่ถูกจำแนกผิดในรอบก่อนหน้ามากขึ้น การปรับน้ำหนักของข้อมูลในลักษณะนี้ช่วยให้กลุ่มโมเดลเรียนรู้จากข้อผิดพลาดของตนเอง ส่งผลให้ได้โมเดลสุดท้ายที่มีประสิทธิภาพสูงขึ้น อัลกอริทึม Boosting ที่ได้รับความนิยม ได้แก่ AdaBoost และ Gradient Boosting ดังแสดงในรูปที่ 1 (1) [2, 3]



รูปที่ 1 รูปแบบเทคนิคการเรียนรู้แบบรวมกลุ่ม 3 ประเภท Boosting (1) Stacking (2) Bagging (3) [2]

Stacking หรือ Stacked Generalization เป็นเทคนิคการเรียนรู้ของเครื่องที่แตกต่างจาก Bagging และ Boosting โดยอนุญาตให้ใช้แบบจำลองที่มีความหลากหลาย (Diverse Algorithms) แทนที่จะใช้เพียงแบบจำลองประเภทเดียวกันในเทคนิคแบบจำลองดั้งเดิม (Base Models) จะถูกฝึกสอนบนชุดข้อมูลฝึกสอน จากนั้นโมเดลเมตา (Meta-Learner) จะถูกฝึกสอนบนผลลัพธ์การทำนายของโมเดลฐาน เพื่อรวมผลลัพธ์การทำนายเหล่านั้นให้เหมาะสมที่สุด ความยืดหยุ่นนี้มักจะนำไปสู่ประสิทธิภาพของแบบจำลองที่ดีขึ้นโดยใช้ประโยชน์จากจุดแข็งของอัลกอริทึมการเรียนรู้ที่หลากหลาย ดังแสดงในรูปที่ 1 (2) [2, 4]



Bagging (Bootstrap Aggregating) เป็นเทคนิคการเรียนรู้ของเครื่องที่ช่วยลดความแปรปรวน (Variance) ของแบบจำลอง โดยสร้างแบบจำลองย่อยหลาย ๆ ตัว ขึ้นมาจากชุดข้อมูลฝึกสอนที่สุ่มเลือกแบบมีการแทนที่ (With Replacement) ซึ่งหมายความว่าข้อมูลบางส่วน อาจถูกเลือกซ้ำหลายครั้ง ขณะที่บางส่วนอาจไม่ได้ถูกเลือกเลย หลังจากฝึกสอนโมเดลย่อยแล้ว ผลลัพธ์การทำนายของแต่ละโมเดลจะถูกรวมเข้าด้วยกัน โดยทั่วไป จะใช้การหาค่าเฉลี่ยสำหรับงานถดถอย (Regression) และการโหวตเสียงข้างมากสำหรับงานจำแนกประเภท (Classification) ตัวอย่างที่รู้จักกันดีของเทคนิค Bagging คือ Random Forest Algorithm ดังแสดงในรูปที่ 1 (3) [2, 5] จุดเด่นและข้อดีของ Ensemble Learning เป็นการเพิ่มความแม่นยำในการทำนายผลที่ ให้ได้มากยิ่งขึ้น อีกทั้งยังช่วยลดทั้ง Bias (ความลำเอียง ในการทำนาย) และ Variance (ความแปรปรวนของการทำนาย) ซึ่งเป็นปัญหาสำคัญในการสร้างโมเดล Machine Learning และช่วยลดความเสี่ยงที่จะเกิด Overfitting (โมเดลจำข้อมูลฝึกมากเกินไป) หรือ Underfitting (โมเดลไม่สามารถจับรูปแบบของข้อมูลได้) และเพิ่มความสามารถในการจัดการกับข้อมูลที่ซับซ้อน สามารถค้นหาและเรียนรู้ความสัมพันธ์ที่ซับซ้อนของ ข้อมูลได้ดีกว่าการเลือกใช้แบบจำลองเดี่ยว รวมทั้งการเรียนรู้แบบรวมกลุ่มสามารถจัดการกับข้อมูลที่มี สัญญาณรบกวน (Noise) หรือข้อมูลที่ขาดหายไป (Missing Data) ได้ดี เนื่องจากข้อผิดพลาดจากโมเดล หนึ่งอาจถูกชดเชยด้วยโมเดลอื่น

2.2 งานวิจัยที่เกี่ยวข้อง

Chaurasia et. al. [6] นำเสนอวิธีการใหม่ในการตรวจจับโรค COVID-19 โดยใช้เทคนิค Ensemble

Learning ร่วมกับการปรับปรุงคุณภาพภาพถ่าย เอกซเรย์ทรวงอกโดยใช้เทคนิคการปรับปรุงภาพ 2 วิธี คือ CLAHE และ BCET เพื่อเพิ่มคุณภาพของภาพ เอกซเรย์ทรวงอกและพัฒนาโมเดล Ensemble Learning โดยรวมโมเดล CNN หลายตัวเข้าด้วยกัน ได้แก่ Inception V3, ResNet50, Xception และ VGG16 ทำการจำแนกภาพเป็น 3 ประเภท คือ ปกติ, ติดเชื้อ COVID-19 และปอดบวม ทดสอบกับชุดข้อมูล ขนาดใหญ่ที่มีภาพ 7,045 ภาพ ผลการทดสอบพบว่าการใช้ CLAHE และ BCET ร่วมกันช่วยเพิ่มความแม่นยำได้อย่างมีนัยสำคัญ และแบบจำลอง DSENetk (Xception + ResNet50) ให้ความแม่นยำสูงสุดที่ 95% มีประสิทธิภาพดีกว่าการใช้แบบจำลองเดี่ยวและวิธีการ อื่นๆ ที่มีอยู่เดิม

Chandrika et. al. [7] พัฒนาแบบจำลองการเรียนรู้เชิงลึกสำหรับการวินิจฉัยโรค COVID-19 จากภาพ เอกซเรย์ทรวงอก ใช้ชุดข้อมูลภาพเอกซเรย์ทรวงอก จำนวน 16,000 ภาพ ประกอบด้วยทั้งผู้ป่วย COVID-19 และผู้ที่ไม่ได้ติดเชื้อ ใช้โครงข่ายประสาทเทียมแบบ คอนโวลูชัน (CNN) ที่ผ่านการเรียนรู้มาก่อนจำนวน 4 แบบจำลอง นำผลลัพธ์จากทั้ง 4 แบบจำลองมา รวมกันด้วยเทคนิคการเรียนรู้แบบรวมกลุ่ม (Ensemble Learning) ใช้เทคนิคการเพิ่มข้อมูล (Data Augmentation) เพื่อปรับปรุงความสามารถในการทำนายของแบบจำลอง แบ่งการจำแนกเป็น 5 ประเภท (ปกติ, ติดเชื้อ COVID-19, ไม่ติดเชื้อ COVID-19, ผื่นขาวในปอดและไวรัส) มีความความแม่นยำร้อยละ 97.30 การจำแนก 3 ประเภท (ติดเชื้อ COVID-19, ไม่ติดเชื้อ COVID-19 และสุขภาพดี) มีความแม่นยำร้อยละ 98.20 การจำแนก 2 ประเภท (ติดเชื้อ COVID-19, ไม่ติดเชื้อ COVID-19) มีความแม่นยำร้อยละ 97.60



Geroski et. al. [8] พัฒนารูปแบบการจำแนกความรุนแรงของ COVID-19 จากภาพเอกซเรย์ทรวงอก โดยใช้เทคนิคการถ่ายโอนการเรียนรู้ (Transfer Learning) กับโครงข่าย DenseNet121 จำแนกความรุนแรงของ COVID-19 เป็น 4 ระดับ เล็กน้อย ปานกลาง รุนแรง และวิกฤต ทดสอบการใช้น้ำหนักเริ่มต้น (Initial Weights) 3 แบบ ได้แก่ ImageNet น้ำหนักจากการเรียนรู้ภาพทั่วไป CheXNeXt น้ำหนักจากการเรียนรู้ภาพโรคปอดต่าง ๆ (ไม่รวม COVID-19) DeepCOVID-XR น้ำหนักจากการเรียนรู้ภาพ COVID-19 โดยเฉพาะ พบว่า ImageNet ให้ผลแย่มากที่สุด (ค่าเฉลี่ย AUC = 0.700) DeepCOVID-XR ให้ผลดีขึ้น (ค่าเฉลี่ย AUC = 0.774) ให้ผลดีที่สุดอย่างมีนัยสำคัญ (ค่าเฉลี่ย AUC = 0.917) เมื่อรวมระดับ รุนแรง และวิกฤตเข้าด้วยกันพบว่า ImageNet ได้ค่า AUC เพิ่มขึ้นเป็น 0.867 CheX-NeXt ได้ค่า AUC เพิ่มขึ้นเป็น 0.900 DeepCOVID-XR ได้ค่า AUC เพิ่มขึ้นเป็น 0.974 จากการทดลองการใช้น้ำหนักเริ่มต้นที่มีลักษณะใกล้เคียงกับชุดข้อมูลใหม่ให้ผลลัพธ์ที่ดีกว่า โดยเฉพาะในกรณีที่มีชุดข้อมูลขนาดเล็กและไม่สมดุล

Kumar et. al. [9] ได้พัฒนาแบบจำลองในการจำแนกโรค COVID-19 จากภาพเอกซเรย์ทรวงอกโดยใช้เทคนิค Machine Learning (ML) และ Transfer Learning (TL) ใช้ชุดข้อมูล COVID-Xray-5k ขนาดภาพ 224 X 224 ในการทดลอง ใช้ Gaussian blur เพื่อจัดการความเบลอ-ชัดและใช้เทคนิค CLAHE เพื่อปรับปรุงความคมชัดและความสว่างของภาพ แบ่งสัดส่วนของชุดข้อมูลออกเป็น 3 รูปแบบได้แก่ 80:20, 75:25 และ 70:30 พบว่าแบบจำลอง Efficient-VGG16 (สถาปัตยกรรม EfficientNet-B0 และ VGG16) ที่ใช้เทคนิค Ensemble ได้ค่าความแม่นยำร้อยละ 99.46 และการแบ่งชุดข้อมูล 80:20 ได้ผลค่าความแม่นยำ

ที่ดีที่สุด Asif et. al. [10] ได้นำเสนอแบบจำลอง LSWE (Lightweight Stacked Ensemble) เป็นแบบจำลองแบบ Stacked Ensemble ที่รวมแบบจำลอง MobileNet และ Lightweight CNN เพื่อปรับปรุงประสิทธิภาพการจัดประเภทโดยมี MLP (Multi-Layer Perceptron) เป็นการเรียนรู้จากการเรียนรู้ (Meta-learner) โดยใช้ชุดข้อมูล 3 ชุดข้อมูล ขนาด 224 X 224 และเพิ่มข้อมูลโดยใช้เทคนิคการเพิ่มข้อมูล (Data Augmentation) ชุดข้อมูลที่ 1 แบ่งออกเป็น 3 ประเภทได้แก่ ติดเชื้อโควิด ไม่ติดเชื้อโควิด ปอดบวม พบว่าแบบจำลองที่นำเสนอ (LSWE) มีความแม่นยำร้อยละ 96.40 ชุดข้อมูลที่ 2 แบ่งออกเป็น 4 ประเภท ได้แก่ ติดเชื้อโควิด ไม่ติดเชื้อโควิด วัณโรค ปอดบวม พบว่าแบบจำลองที่นำเสนอ (LSWE) มีความแม่นยำร้อยละ 97.90 ชุดข้อมูลที่ 3 ติดเชื้อโควิด ไม่ติดเชื้อโควิด พบว่าแบบจำลองที่นำเสนอ (LSWE) มีความแม่นยำร้อยละ 98.30 ทั้งสามชุดข้อมูลแบบจำลองที่นำเสนอ (LSWE) ให้ประสิทธิภาพและมีความแม่นยำมากที่สุด

Wang et. al. [11] งานวิจัยนี้นำเสนอแบบจำลองวินิจฉัย โควิด-19 จากภาพถ่ายเอกซเรย์ทรวงอกโดยใช้เครือข่ายน้ำหนักเบา (Lightweight Network) MobileNetV3 ที่ได้รับการปรับปรุงเพิ่มเติมด้วยโครงสร้าง Dense Block และ Layer สำหรับลดขนาดและจำนวนช่อง (Transition Layer) เพื่อลดจำนวนพารามิเตอร์ของแบบจำลอง นอกจากนี้ยังประยุกต์ใช้ loss แบบ label smoothing เพื่อแก้ปัญหาความเหมือนหรือคล้ายคลึงระหว่างข้อมูลแต่ละประเภทผลการทดลองพบว่ามีความถูกต้องร้อยละ 98.71 และมีจำนวนพารามิเตอร์ 5.94 ล้านพารามิเตอร์ (ลดจำนวนพารามิเตอร์ได้สูงสุดถึง 5 เท่าเมื่อเทียบกับ Inception-V3 ที่ใช้ 24 ล้านพารามิเตอร์)



3. วิธีดำเนินการวิจัย

3.1 เครื่องมือและซอฟต์แวร์ในการทดลอง

- GPU: Nvidia RTX 4070 SUPER (12GB)
- CPU: Intel Core i9-13900KS
- RAM: 32GB
- Operation System: Ubuntu 22.04 LTS
- Deep Learning Framework: Keras (TensorFlow)
- Programming Language: Python

3.2 การเตรียมข้อมูลและจัดการชุดข้อมูล


3.2.1 ชุดข้อมูล

การทดลองได้นำชุดข้อมูล COVID-19 Radiography [12] มาใช้ในกระบวนการพัฒนาแบบจำลองซึ่งชุดข้อมูลประกอบไปด้วยภาพจาก CT Scan จำนวน 13,803 ภาพ (เฉพาะ 2 ประเภท มีเชื้อโควิด 3,616 ภาพและไม่มีเชื้อ 10,192 ภาพ) นำมาแบ่งเพื่อสร้างแบบจำลองโดยใช้จำนวนประเภทที่มีน้อยที่สุดเป็นตัวกำหนด คือมีเชื้อโควิด 3,616 ภาพ ไม่มีเชื้อโควิด 3,616 ภาพ (สุ่มคัดเลือกจาก 10,192 ภาพ) และในการทดลองได้ใช้ข้อมูลทั้งสองกลุ่มข้อมูลที่เท่ากัน คือ 1,252 ภาพ ดังแสดงในรูปที่ 2 และภาพตัวอย่างชุดข้อมูลในรูปที่ 3


3.2.2 การเตรียมชุดข้อมูล

การแบ่งชุดข้อมูลสำหรับการทดลองแบ่งเป็น 70:20:10 ชุดข้อมูลสำหรับการเรียนรู้ (Training Set) 70% สำหรับชุดข้อมูลการประเมิน (Validation Set) 20% และชุดข้อมูลสำหรับการทดสอบ (Test Set)


10% และใช้เทคนิคการแบ่งข้อมูลด้วย K-Fold Cross Validation (K=5) [1] มาใช้ในการทดสอบประสิทธิภาพแบบจำลองและเพื่อให้ข้อมูลในการพัฒนาแบบจำลองกระจายตัวอย่างสม่ำเสมอ ช่วยให้การประเมินค่าความถูกต้อง (Accuracy) หรือค่าความผิดพลาด (Error) ของโมเดลมีความสอดคล้องกับข้อมูลทั้งหมด ไม่อิงกับ Train/Test ชุดเดียวและทำให้การประเมินจะมาจากค่าเฉลี่ยของแต่ละ Fold ลดโอกาสที่จะเกิดกรณีผลลัพธ์ผิดปกติจากการแบ่งข้อมูลแบบสุ่มครั้งเดียวดังแสดงในรูปที่ 4 รูปแบบการแบ่งข้อมูลด้วยเทคนิค K-Fold Cross Validation. (K = 5) และการแบ่งข้อมูลในการพัฒนาแบบจำลองในการวิจัยนี้แสดงดังรูปที่ 5



รูปที่ 2 การเตรียมชุดข้อมูลสำหรับการพัฒนาแบบจำลอง



รูปที่ 3 ตัวอย่างชุดข้อมูล ภาพติดเชื้อโควิด 19 (บน) ภาพไม่ติดเชื้อโควิด 19 (ล่าง) [11]




รูปที่ 4 รูปแบบการแบ่งข้อมูลด้วยเทคนิค K-Fold Cross Validation. (K = 5)

3.3 การประเมินประสิทธิภาพแบบจำลอง

3.3.1 การวัดค่าความถูกต้อง (Accuracy)

การวัดประสิทธิภาพของการเรียนรู้แบบจำลองได้ใช้การวัดค่าความถูกต้อง (Accuracy) ความถูกต้องระหว่างสิ่งที่ทำนายกับสิ่งที่เกิดขึ้นจริงโดยมีสมการในการคำนวณดังนี้ [1] [13]

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



รูปที่ 5 การแบ่งข้อมูลของชุดข้อมูลในการพัฒนาแบบจำลอง

โดย TP คือค่าที่พยากรณ์ถูกต้องเชิงบวก
 TN คือค่าที่พยากรณ์ถูกต้องเชิงลบ
 FP คือค่าที่พยากรณ์ผิดพลาดเชิงบวก
 FN คือค่าที่พยากรณ์ผิดพลาดเชิงลบ



3.3.2 การวัดความสูญเสีย (Loss Function)

ฟังก์ชันที่ใช้ในการวัด "ความผิดพลาด" หรือ "ความแตกต่าง" ระหว่างค่าที่โมเดลทำนายได้กับค่าจริงในการฝึกแบบจำลองทาง Machine Learning หรือ Deep Learning เน้นไปที่การลดค่า Loss Function ให้น้อยที่สุด เป็นการทำให้แบบจำลองมีความแม่นยำในการทำนายมากยิ่งขึ้น [1, 13]

3.4 พารามิเตอร์พื้นฐาน (Hyper-Parameters)

ในการทดลองได้กำหนดพารามิเตอร์พื้นฐานเพื่อให้สภาพแวดล้อมมีสภาวะที่เหมือนกันได้แก่

- Batch size 32
- Learning rate 0.001 (ค่าพื้นฐานของ Adam optimizer) [10]
- Epoch 15
- Optimizer Adam [13, 14]

3.5 การออกแบบการทดลอง


การทดลองแบ่งออกเป็น 3 กลุ่ม กลุ่มที่ 1 สร้างแบบจำลองพื้นฐานจาก keras 38 แบบจำลองที่ได้รับความนิยมดังแสดงในตารางที่ 1 กับชุดข้อมูล COVID-19 Radiography [12] และนำแบบจำลองที่ได้ค่าความถูกต้องมากที่สุด 3 ลำดับไปใช้ในการทดลองกลุ่มที่ 2 และ 3

กลุ่มที่ 2 ทดลองด้วยวิธีการเชื่อมต่อแบบจำลองโดยใช้เทคนิค Bagging (Bootstrap Aggregating) ร่วมกับชุดข้อมูล 5 ชุด ดังแสดงในรูปที่ 11 ขั้นตอนการพัฒนาแบบจำลองในการวิจัย แบ่งออกเป็น

- รูปแบบที่ 1 ทดลอง 1 แบบจำลอง กระบวนการทดลองดังแสดงในรูปที่ 6


- รูปแบบที่ 2 ทดลองจับคู่ 2 แบบจำลอง กระบวนการทดลองดังแสดงในรูปที่ 7
- รูปแบบที่ 3 ทดลองจับคู่ 3 แบบจำลอง กระบวนการทดลองดังแสดงในรูปที่ 8

Training Process : Group 2 - 1



รูปที่ 6 การทดลองกลุ่มที่ 1


Training Process : Group 2 - 2



รูปที่ 7 การทดลองกลุ่มที่ 2 รูปแบบที่ 2



Training Process : Group 2 - 3




รูปที่ 8 การทดลองกลุ่มที่ 2 รูปแบบที่ 3

กลุ่มที่ 3 ทดลองในลักษณะเดียวกับกลุ่มการทดลองที่ 2 ทดลองด้วยวิธีการเชื่อมต่อแบบจำลองโดยใช้เทคนิค Bagging (Bootstrap Aggregating) และใช้แบบจำลองที่มีค่าความถูกต้องมากที่สุดในแต่ละแบบจำลองจับคู่การทดลองออกเป็น


- รูปแบบที่ 1 ทดลองจับคู่ 2 แบบจำลอง กระบวนการทดลองดังแสดงในรูปที่ 9
- รูปแบบที่ 2 ทดลองจับคู่ 3 แบบจำลอง กระบวนการทดลองดังแสดงในรูปที่ 10

Training Process : Group 3 - 1



รูปที่ 9 การทดลองกลุ่มที่ 3 รูปแบบที่ 1

Training Process : Group 3 - 2



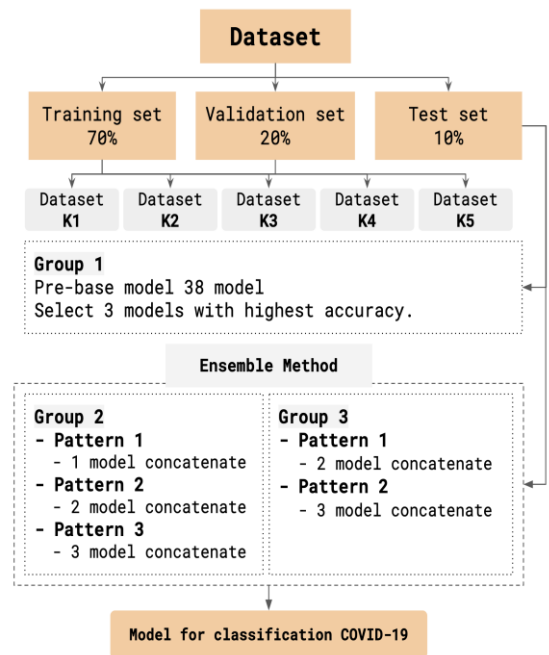
รูปที่ 10 การทดลองกลุ่มที่ 3 รูปแบบที่ 2



บทความวิจัย

ตารางที่ 1 แบบจำลองที่ได้รับความนิยม 38 แบบจำลอง
จาก Keras

แบบจำลอง (Model)	ขนาด (MB)
VGG16	528
VGG19	549
MobileNet	16
Xception	88
ConvNeXtTiny	109.42
ResNet50V2	98
MobileNetV2	14
ResNet50	98
EfficientNetB0	29
EfficientNetV2B0	29
EfficientNetV2B1	34
ConvNeXtLarge	755.07
ConvNeXtXLarge	1310
ConvNeXtSmall	192.29
EfficientNetB1	31
ConvNeXtBase	338.58
EfficientNetB2	36
InceptionV3	92
EfficientNetV2B2	42
ResNet101V2	171
ResNet101	171
EfficientNetB3	48
EfficientNetV2B3	59
DenseNet121	33
EfficientNetB4	75
EfficientNetV2S	88
ResNet152V2	232
ResNet152	232
EfficientNetB5	118
DenseNet169	57
EfficientNetB6	166
NASNetMobile	23
DenseNet201	80
EfficientNetV2M	220
EfficientNetB7	256
InceptionResNetV2	215
NASNetLarge	343
EfficientNetV2L	479



รูปที่ 11 ขั้นตอนการพัฒนาแบบจำลองในการวิจัย

4. ผลการดำเนินการวิจัย

การทดลองแบ่งออกเป็น 3 กลุ่ม กลุ่มที่ 1 สร้างแบบจำลองพื้นฐานจากแบบจำลองที่ได้รับความนิยม 38 แบบจำลองพบว่าแบบจำลองที่มีค่าความถูกต้อง 3 อันดับ มากที่สุด ได้แก่ VGG16, MobileNet, DenseNet121 และนำไปใช้ในกลุ่มการทดลองที่ 2 และกลุ่มการทดลองที่ 3 รวมทั้งได้นำเทคนิค K-Fold Cross Validation มาใช้ในการทดสอบแบบจำลองทั้ง 3 กลุ่มการทดลอง

- แบบจำลอง VGG16 มีค่าความถูกต้องร้อยละ 97.23 และค่าความสูญเสียร้อยละ 0.11
- แบบจำลอง MobileNet มีค่าความถูกต้องร้อยละ 96.96 และค่าความสูญเสียร้อยละ 0.34
- แบบจำลอง DenseNet121 มีค่าความถูกต้องร้อยละ 95.99 และค่าความสูญเสียร้อยละ 0.1



ตารางที่ 2 ผลการทดลองกลุ่มการทดลองที่ 1

ลำดับ (No.)	การทดลอง (Model)	ความถูกต้อง (Accuracy)
1	VGG16	97.23
2	MobileNet	96.96
3	DenseNet121	95.99

กลุ่มที่ 2 จับคู่ การทดลองใช้แบบจำลอง 3 แบบจำลองจากกลุ่มการทดลองที่ 1 โดยใช้เทคนิค Bagging (Bootstrap Aggregating) ร่วมกับชุดข้อมูล 5 ชุด จำนวน 3 รูปแบบการทดลอง

- รูปแบบที่ 1 ทดลอง 1 แบบจำลองพบว่า
 - แบบจำลอง MobileNet มีค่าความถูกต้องร้อยละ 96.96
 - แบบจำลอง VGG16 มีค่าความถูกต้องร้อยละ 92.12
 - แบบจำลอง DenseNet121 มีค่าความถูกต้องร้อยละ 48.06
- รูปแบบที่ 2 จับคู่ 2 แบบจำลองพบว่า
 - แบบจำลอง VGG16 ร่วมกับ MobileNet มีค่าความถูกต้องร้อยละ 49.30
 - แบบจำลอง MobileNet ร่วมกับ DenseNet121 มีค่าความถูกต้องร้อยละ 49.03
 - แบบจำลอง VGG16 ร่วมกับ DenseNet121 มีค่าความถูกต้องร้อยละ 43.23
- รูปแบบที่ 3 จับคู่ 3 แบบจำลองพบว่า
 - แบบจำลอง VGG16 ร่วมกับ MobileNet และ DenseNet121 มีค่าความถูกต้องร้อยละ 52.20

ตารางที่ 3 ผลการทดลองกลุ่มการทดลองที่ 2

ลำดับ (No.)	การทดลอง (Model)	ความถูกต้อง (Accuracy)
1	MobileNet	96.96
2	VGG16	92.12
3	DenseNet121	48.06
4	VGG16 + MobileNet	49.30
5	MobileNet + DenseNet121	49.03
6	VGG16 + DenseNet121	43.23
7	VGG16 + MobileNet + DenseNet121	52.20

กลุ่มที่ 3 จับคู่ การทดลองใช้แบบจำลอง 3 แบบจำลองจากกลุ่มการทดลองที่ 1 โดยใช้เทคนิค Bagging (Bootstrap Aggregating) และใช้แบบจำลองที่มีค่าความถูกต้องมากที่สุดในแต่ละรูปแบบจากกลุ่มการทดลองที่ 2 จำนวน 2 รูปแบบการทดลอง

- รูปแบบที่ 1 จับคู่ 2 แบบจำลองพบว่า
 - แบบจำลอง VGG16 ร่วมกับ MobileNet มีค่าความถูกต้องร้อยละ 49.30
 - แบบจำลอง VGG16 ร่วมกับ DenseNet121 มีค่าความถูกต้องร้อยละ 50.00
 - แบบจำลอง MobileNet ร่วมกับ DenseNet121 มีค่าความถูกต้องร้อยละ 99.30
- รูปแบบที่ 2 จับคู่ 3 แบบจำลองพบว่า
 - แบบจำลอง VGG16 ร่วมกับ MobileNet และ DenseNet121 มีค่าความถูกต้องร้อยละ 42.54



บทความวิจัย

ตารางที่ 4 ผลการทดลองกลุ่มการทดลองที่ 3

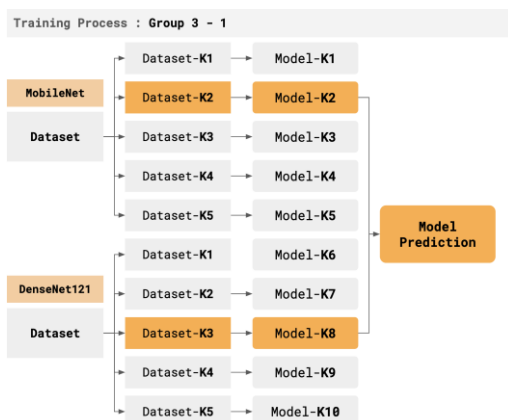
ลำดับ (No.)	การทดลอง (Model)	ความถูกต้อง (Accuracy)
1	MobileNet + DenseNet121	99.30
2	VGG16 + DenseNet121	50.00
3	VGG16 + MobileNet	49.86
4	VGG16 + MobileNet + DenseNet121	42.54

เมื่อเปรียบเทียบผลการทดลองในตารางที่ 5 ซึ่งแสดงให้เห็นว่าจำนวนพารามิเตอร์และเวลาในการเรียนรู้ของแบบจำลองไม่มีความสัมพันธ์กันและแบบจำลองที่มีความซับซ้อนไม่สามารถให้ผลที่ดีตามจำนวนพารามิเตอร์ได้เช่นการทดลองที่ 11 ในตารางที่ 5 มีพารามิเตอร์ 10.36 ล้านตัว ให้ค่าความถูกต้องที่ดีที่สุดเทียบกับการทดลองที่ 10 มีพารามิเตอร์ 125.33 ล้านตัวและเมื่อเปรียบเทียบเวลาที่ใช้ในการเรียนรู้ของแบบจำลองและจำนวนพารามิเตอร์แสดงให้เห็นว่ามีความสอดคล้องกันเมื่อมีจำนวนพารามิเตอร์ที่มากขึ้นเวลาที่ใช้ในการเรียนรู้ของแบบจำลองก็มากขึ้นตามไปด้วยเช่น การทดลองที่ 10 มีพารามิเตอร์มากที่สุด 125.53 ล้านตัว ใช้เวลามากที่สุด 24.20 นาทีในขณะที่การทดลองที่ 2 มีพารามิเตอร์น้อยที่สุด 3.28 ล้านตัว ใช้เวลาน้อยที่สุด 1.70 นาที และเมื่อเปรียบเทียบระหว่างเวลาและค่าความถูกต้องไม่มีความสัมพันธ์กันกับแสดงให้เห็นว่าการเลือกแบบจำลองหรือโครงสร้างของแบบจำลองขึ้นหรือเทคนิคในการทดลองอยู่กับ


ลักษณะของข้อมูลที่ใช้ในการเรียนรู้รวมทั้งทรัพยากรและเวลา

จากการทดลองทั้ง 3 กลุ่มการทดลองพบว่ากลุ่มการทดลองที่ 3 รูปแบบที่ 1 จับคู่ 2 แบบจำลองตั้งแสดงในรูปที่ 12 ได้แก่แบบจำลอง MobileNet [15] ร่วมกับ DenseNet121 [16] มีค่าความถูกต้องร้อยละ 99.30 และแสดง Confusion matrix ในการจำแนกในรูปที่ 13 ซึ่งแบบจำลองสามารถจำแนกภาพไม่ติดเชื้อโควิด 19 (Non-covid) ได้อย่างถูกต้องจำนวน 359 ภาพ (TN = 359) โดยมีข้อผิดพลาดในการจำแนกว่าติดเชื้อโควิด 19 (covid) เพียง 3 ภาพ (FP = 3) และแบบจำลองมีความสามารถในการจำแนกติดเชื้อโควิด 19 (covid) ได้อย่างถูกต้องจำนวน 358 ภาพ (TP = 358) มีข้อผิดพลาดในการจำแนกว่าไม่ติดเชื้อโควิด 19 (Non-covid) จำนวน 4 ภาพ (FN = 4)


เมื่อเปรียบเทียบกับแบบจำลองในแต่ละกลุ่มพบว่าแบบจำลองกลุ่มที่ 2 รูปแบบที่ 1 แบบจำลอง MobileNet และ VGG16 ให้ค่าความถูกต้องมากที่สุดมากกว่าร้อยละ 90.00 ซึ่งแตกต่างจากแบบจำลอง DenseNet121 ให้ค่าความถูกต้องไม่ถึงร้อยละ 50 แต่เมื่อนำแบบจำลอง MobileNet ร่วมกับแบบจำลอง DenseNet121 ในกลุ่มการทดลองที่ 3 รูปแบบที่ 1 พบว่าให้ค่าความถูกต้องเพิ่มสูงขึ้น ซึ่งเป็นผลมาจากการเลือกแบบจำลองร่วมกับชุดข้อมูลที่ให้ค่าความถูกต้องมากที่สุดดังแสดงรูปแบบการพัฒนาในรูปที่ 12 ซึ่งแตกต่างจากการทดลองกลุ่มที่ 2 ที่นำทุกแบบจำลองจากชุดข้อมูลทั้ง 5 ชุดข้อมูลการรวมกัน และได้แสดงผลการเปรียบเทียบค่าความถูกต้องในรูปที่ 14 โดยเฉลี่ยค่าความถูกต้องคือร้อยละ 61.14



รูปที่ 12 รูปแบบการพัฒนาแบบจำลองที่มีค่าความถูกต้องมากที่สุด MobileNet ร่วมกับ DenseNet121 (กลุ่มการทดลองที่ 3 รูปแบบที่ 1)



รูปที่ 13 Confusion matrix แบบจำลองกลุ่มที่ 3 MobileNet + DenseNet121 ที่มีค่าความถูกต้องมากที่สุด



รูปที่ 14 กราฟแสดงผลประสิทธิภาพค่าความถูกต้องกลุ่มทดลองที่ 2 และกลุ่มทดลองที่ 3

**ตารางที่ 5** การเปรียบเทียบผลการทดลองกลุ่มการทดลองที่ 1 - 3

ลำดับ (No.)	การทดลอง (Model)	ความถูกต้อง (Accuracy)	เวลา/นาที (Time)	พารามิเตอร์ (Parameter)
กลุ่มการทดลองที่ 1				
1	VGG16	97.23	02.55	14,739,777
2	MobileNet	96.96	01.70	3,279,041
3	DenseNet121	95.99	01.78	7,087,681
กลุ่มการทดลองที่ 2				
4	MobileNet	96.96	12.40	16,395,211
5	VGG16	92.12	03.23	73,698,891
6	DenseNet121	48.06	08.41	35,438,411
7	VGG16 + MobileNet	49.30	15.25	90,094,101
8	MobileNet + DenseNet121	49.03	20.41	51,833,621
9	VGG16 + DenseNet121	43.23	11.45	109,137,301
10	VGG16 + MobileNet + DenseNet121	52.20	24.20	125,532,511
กลุ่มการทดลองที่ 3				
11	MobileNet + DenseNet121	99.30	03.16	10,366,725
12	VGG16 + DenseNet121	50.00	04.19	21,827,461
13	VGG16 + MobileNet	49.86	02.22	18,018,821
14	VGG16 + MobileNet + DenseNet121	42.54	04.49	25,106,503

5. สรุปผลการวิจัย

จากการทดลองเพื่อพัฒนาแบบจำลองสำหรับการจำแนกโควิด 19 จากภาพ CT Scan โดยใช้การเรียนรู้แบบรวมกลุ่มเทคนิคBagging (Bootstrap Aggregating) พบว่าแบบจำลอง MobileNet ร่วมกับ DenseNet121 ให้ค่าความถูกต้องมากที่สุดความถูกต้องร้อยละ 99.30 เหมาะกับบุคลากรทางการแพทย์ที่เกี่ยวข้องกับการตรวจหาโรคโควิด 19 จากภาพ CT Scan ช่วยให้สามารถวิเคราะห์และวินิจฉัยผู้ป่วยได้อย่างมีประสิทธิภาพมากขึ้น ลดความผิดพลาด มีความสะดวกรวดเร็วในการเข้ารับบริการของผู้ป่วย เพิ่มโอกาสการเข้ารับรักษาได้อย่างรวดเร็วมากยิ่งขึ้น

6. เอกสารอ้างอิง

- [1] M.M. Hossain, Md.A.A. Walid, S.M.S. Galib, M.M. Azad, W. Rahman, AS.M. Shafi and M.M. Rahman, COVID-19 detection from chest CT images using optimized deep features and ensemble classification, Systems and Soft Computing, 2024, 6, 200077.
- [2] M.A. Ganaie, M. Hu, A.K. Malik, K. Tanveer and P.N. Suganthan, Ensemble deep learning: A review, Engineering Applications of Artificial Intelligence, 2022, 115, 105-151.



- [3] H.-C. Kim, S. Pang, H.-M. Je, D. Kim and S.-Y. Bang, Support vector machine ensemble with bagging, *Pattern Recognition with Support Vector Machines*, 2002, 397-408.
- [4] M. LesBlanc and R. Tibshirani, Combining estimates in regression and classification, *Journal of the American Statistical Association*, 1996, 91(436), 1641-1650.
- [5] L. Breiman, Bagging predictors, *Machine learning*, 1997, 24, 123-140.
- [6] S. Chaurasia, A.K. Gupta, P.P. Tiwari, A. Smirti and M. Jangid, DSENetk: An efficient deep stacking ensemble approach for COVID-19 induced pneumonia prediction using radiograph images, *SN Computer Science*, 2025, 6, 68.
- [7] G.N. Chandrika, R. Chowdhury, P. Kumar, K. Sangamithrai, E. Glory and M.D. Saranya, Ensemble learning based convolutional neural network – depth fire for detecting COVID-19 in chest X-Ray images, *Journal of Electronics Electromedical Engineering, and Medical Informatics*, 2024, 7(1), 47-55.
- [8] T. Geroski, V. Rankovic, O. Pavic, L. Dasic, M. Petrovic, D. Milovanovic and N. Filipovic, Enhancing COVID-19 disease severity classification through advanced transfer learning techniques and optimal weight initialization schemes, *Biomedical Signal Processing and Control*, 2025, 100, Part C, 107103.
- [9] S. Kumar and H. Kumar, Efficient-VGG16: A novel ensemble method for the classification of COVID-19 X-ray images in contrast to machine and transfer learning, *Procedia Computer Science*, 2024, 235, 1289-1299.
- [10] S. Asif, M. Zhao, F. Tang and Y. Zhu, LWSE: a lightweight stacked ensemble model for accurate detection of multiple chest infectious diseases including COVID-19, *Multimedia Tools and Applications*, 2024, 83(8), 23967-24003.
- [11] S. Wang, J. Ren and X. Guo, A high-accuracy lightweight network model for X-ray image diagnosis: A case study of COVID detection, *PLoS ONE*, 2024, 19(6), e0303049.
- [12] <https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database/>. (Accessed on 10 January 2025)



- [13] P. Chedsom and W. Kanarkard, Analysis of student engagement in online classroom using convolutional neural networks (CNN), ECTI Transaction on Application Research and Development, 2023, 3(3), 39-52.
(in Thai)
- [14] D.P. Kingma and J. Ba, Adam: A method for stochastic optimization, The 3rd International Conference for Learning Representations, Proceeding, 2015.
- [15] A.G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand M. Andreetto and H. Adam, Mobilenets: Efficient convolutional neural networks for mobile vision applications, arXiv, 2017, 1704.04861.
- [16] G. Huang, Z. Liu, L. Maaten and Q. Weinberger, Densely connected convolutional networks, IEEE conference on computer vision and pattern recognition, Proceedings, 2017, 4700-4708.