

การทำนายมะเร็งปอดจากภาพ CT scan โดยใช้ Convolutional Neural Network

จิรายุ ทองคำ¹, ชุตินันท์ สวอยสม¹ และ เสถียร หันตา^{1*}

Lung Cancer Prediction from CT Scan Images Using Convolutional Neural Network

Jirayu Thongkam¹, Chutinun Suaysom¹ and Sathien Hunta^{1*}

¹ School of Information and Communication Technology, University of Phayao, Phayao, 56000

* Corresponding author: sathien.hu@up.ac.th

Received: 19 June 2025; Revised: 13 October 2025; Accepted: 21 October 2025

บทคัดย่อ

มะเร็งปอดเป็นโรคที่มีความรุนแรงและเป็นสาเหตุสำคัญของการเสียชีวิตทั้งในประเทศไทยและต่างประเทศ การตรวจพบโรคตั้งแต่ระยะเริ่มต้นมีความสำคัญอย่างยิ่ง เนื่องจากสามารถเพิ่มโอกาสในการรักษาและลดอัตราการเสียชีวิตได้อย่างมีนัยสำคัญ งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษา จัดเตรียมข้อมูลที่เหมาะสม และพัฒนาแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) สำหรับการทำนายมะเร็งปอดโดยใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้ชุดข้อมูล Chest CT-Scan Images Dataset จากเว็บไซต์ Kaggle ซึ่งประกอบด้วยข้อมูลภาพ CT scan มะเร็งปอดที่ไม่ใช่ชนิดเซลล์เล็ก จำนวนทั้งหมด 1,000 ภาพ แบ่งออกเป็น 4 คลาส ได้แก่ มะเร็งอะดีโนคาร์ซิโนมา, มะเร็งสควamous เซลล์, มะเร็งชนิดเซลล์ใหญ่ และปอดปกติ

งานวิจัยนี้ได้เปรียบเทียบประสิทธิภาพของแบบจำลอง 4 แบบ ได้แก่ ResNet50, VGG16, InceptionV3 และ DenseNet121 จากนั้นนำผลลัพธ์ของแต่ละแบบจำลองมาผสานด้วยวิธี Stacking Ensemble โดยใช้เทคนิคการเรียนรู้ของเครื่องเป็นแบบจำลองเมตา 5 แบบ ได้แก่ Random Forest, Logistic Regression, Support Vector Machine, K-Nearest Neighbors และ Naive Bayes ผลการทดลองแสดงให้เห็นว่าแบบจำลองที่รวมผลลัพธ์โดยใช้ Random Forest มีความแม่นยำสูงสุดที่ร้อยละ 98.73 ซึ่งสูงกว่าแบบจำลองเดี่ยวทั้งหมด

คำสำคัญ: มะเร็งปอด, เอกซเรย์คอมพิวเตอร์, การเรียนรู้ของเครื่อง, โครงข่ายประสาทเทียมแบบคอนโวลูชัน, เทคนิคการรวมแบบจำลอง

¹ คณะเทคโนโลยีสารสนเทศและการสื่อสาร มหาวิทยาลัยพะเยา จังหวัดพะเยา 56000

Abstract

Lung cancer is a serious disease and a leading cause of death both in Thailand and worldwide. Early detection is crucial, as it significantly increases the chances of successful treatment and reduces mortality rates. This research aims to study and develop a deep neural network model for lung cancer prediction using computed tomography scan images. The dataset consists of 1,000 images classified into four categories: adenocarcinoma, squamous cell carcinoma, large cell carcinoma, and normal lung.

The study compared the performance of four deep learning models ResNet50, VGG16, InceptionV3, and DenseNet121. The results from each model were then combined using the Stacking Ensemble method with 5 machine learning techniques as meta models: Random Forest, Logistic Regression, Support Vector Machine, K-Nearest Neighbors, and Naive Bayes. Experimental results showed that the ensemble model using Random Forest achieved the highest accuracy of 98.73 percent, outperforming all individual models.

Keywords: Lung Cancer, CT Scan, Machine Learning, Convolutional Neural Network, Ensemble Method

Introduction

โรคมะเร็งปอดเป็นหนึ่งในโรคมะเร็งที่เสียชีวิตมากที่สุดในโลก องค์การอนามัยโลก (WHO) ระบุว่าในปี พ.ศ. 2563 มีผู้เสียชีวิตจากโรคมะเร็งเกือบ 10 ล้านคนทั่วโลก และในปีเดียวกันพบผู้ป่วยมะเร็งรายใหม่เพิ่มขึ้นถึง 18.1 ล้านคน มะเร็งปอดมีผู้ป่วยรายใหม่ 2.2 ล้านคนรองลงมาจาก มะเร็งเต้านมที่มีผู้ป่วยมากที่สุดในโลก (World Health Organization, 2025) สำหรับในประเทศไทยพบผู้ป่วยเป็นมะเร็งปอดเป็นอันดับที่ 2 ของผู้ป่วยโรคมะเร็ง โดยมีผู้ป่วยรายใหม่เฉลี่ย 48 คนต่อวัน หรือ 17,222 คนต่อปี ในขณะที่ข้อมูลจากสำนักงานปลัดกระทรวงสาธารณสุขปี 2565 ระบุว่ามียุติชีวิตจากมะเร็งปอดเฉลี่ย 40 คนต่อวัน หรือ 14,534 คนต่อปี (Thai Health Promotion Foundation, 2024) สาเหตุที่พบได้มากที่สุด โดยผู้ป่วยส่วนใหญ่เข้าพบแพทย์เมื่อโรคอยู่ในระยะลุกลาม ส่งผลให้การรักษาเป็นไปได้อย่างยากลำบาก โรคมะเร็งปอดสามารถแบ่งได้สองชนิดหลัก ได้แก่ มะเร็งปอดชนิดเซลล์เล็ก (Small Cell Lung Cancer: SCLC) พบได้ประมาณ 10–15% มีแนวโน้มในการเจริญเติบโตและแพร่กระจายรวดเร็วกว่ามะเร็งปอดไม่ใช่เซลล์เล็ก (Non-Small Cell Lung Cancer: NSCLC) ที่พบได้ประมาณ 80–85% โดยแบ่งออกเป็น 3 ชนิด ได้แก่ ชนิด Adenocarcinoma เกิดจากเซลล์เยื่อบุผิวที่ผลิตเมือกในปอด อาจเกิดในผู้ที่ไม่เคยสูบบุหรี่โดยมักพบในผู้หญิงและคนอายุน้อย ชนิด Large Cell Carcinoma สามารถเกิดได้ทั่วทั้งปอด และมีการเติบโตแพร่กระจายอย่างรวดเร็ว และชนิด Squamous Cell Carcinoma เกิดจากเซลล์เยื่อบุทางเดินหายใจ มักพบในบริเวณส่วนกลางของปอดใกล้กับหลอดลมใหญ่ (American Cancer Society, 2024) เพราะทั้งสองชนิดหลักมีการเจริญเติบโต และการรักษาที่แตกต่างกัน สำหรับบุคคลที่มีปัจจัยความเสี่ยงสูงต่อการเกิดมะเร็งปอด ได้แก่ ผู้ที่สูบบุหรี่ รับประทานบุหรี่มือสอง มีประวัติครอบครัวเคยเป็นมะเร็ง หรือผู้ที่สัมผัสสารก่อมะเร็ง หรือฝุ่นควันเป็นประจำทุกวัน โดยเฉพาะฝุ่น PM 2.5 ซึ่งประกอบด้วยสารเคมีปนเปื้อนหลายชนิดที่เป็นสารก่อเกิดมะเร็ง (Department of Medical Services, 2024) โดยผู้ที่มีความเสี่ยงดังนี้ การตรวจสุขภาพด้วย (Computerized Tomography Scan: CT scan) เป็นวิธีที่มีประสิทธิภาพในการตรวจพบมะเร็ง และรักษาให้หายได้หากพบได้ตั้งแต่ระยะเริ่มต้น ฉะนั้นจะเป็นการช่วยเพิ่มโอกาสในการรักษาของผู้ป่วย (BNH Hospital, 2025) จากการศึกษาศึกษาของ U.S. National Lung Screening Trial (NLST) พบว่าการตรวจคัดกรองด้วย CT scan สามารถลดความเสี่ยงการเสียชีวิตจากโรคมะเร็งปอดได้ถึง 20% เมื่อมะเร็งถูกตรวจพบได้ในระยะแรกๆ เช่น ระยะที่ 1 หรือ ระยะที่ 2 สามารถได้รับการรักษาได้อย่างรวดเร็ว และสามารถรักษาให้หายขาดเพิ่ม

โอกาสรอดชีวิตในระยะยาว หากมะเร็งลุกลามไปในระยะที่ 3 และ 4 ผู้ป่วยจะต้องได้รับการรักษาที่หลากหลายขั้นตอน เป็นไปได้อย่างยากลำบาก (National Cancer Institute, 2021)

การเรียนรู้ของเครื่อง (Machine Learning) เป็นเทคโนโลยีในการพัฒนาของอัลกอริทึมมาใช้ในการสร้างแบบจำลอง และการปรับปรุงประสิทธิภาพของแบบจำลอง โดยนำมาช่วยในการวินิจฉัยทางการแพทย์ และประเมินความเสี่ยงของโรคต่าง ๆ รวมถึงมะเร็งปอดได้ โดยใช้เทคโนโลยีปัญญาประดิษฐ์ Artificial Intelligence (AI) สามารถทำให้คอมพิวเตอร์ทำงานที่ซับซ้อน วิเคราะห์ข้อมูล ปรับปรุงประสิทธิภาพได้อย่างต่อเนื่อง ช่วยลดความผิดพลาดในการทำงาน รวดเร็วและแม่นยำ (Alowais et al., 2023) ทั้งนี้ การประมวลผลภาพ (Image Processing) มีบทบาทสำคัญในการแปลงข้อมูลภาพทางการแพทย์ให้อยู่ในรูปแบบที่เหมาะสมสำหรับการวิเคราะห์ รวมถึงเทคนิคต่าง ๆ ที่ใช้ในการปรับปรุงคุณภาพของภาพ ได้แก่ การลดสัญญาณรบกวน การเพิ่มความคมชัด และการปรับแต่งคุณสมบัติของภาพเพื่อให้ข้อมูลที่ได้มีความชัดเจน ช่วยเพิ่มประสิทธิภาพในการวินิจฉัยและการทำนาย (Tawfik et al., 2024)

การเรียนรู้เชิงลึก (Deep Learning) โดยเฉพาะสถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน Convolutional Neural Network (CNN) ได้รับความนิยมอย่างแพร่หลายในงานวิเคราะห์ภาพทางการแพทย์ เนื่องจากสามารถเรียนรู้คุณลักษณะของภาพได้โดยอัตโนมัติ และมีความสามารถในการตรวจจับวัตถุ จำแนกภาพที่มีความซับซ้อนสูง (Li, Zhang, Chen, & Wang, 2025) ดังนั้น งานวิจัยนี้จึงดำเนินการศึกษาและพัฒนากระบวนการแบบจำลองที่เหมาะสม โดยใช้เทคนิคการเรียนรู้เชิงลึกอาศัยสถาปัตยกรรมของ Convolutional Neural Network (CNN) สำหรับการทำนายชนิดของมะเร็งปอดชนิดไม่ใช้เซลล์ขนาดเล็ก (NSCLC) โดยใช้แบบจำลอง CNN ที่เคยถูกฝึกมาแล้วและนำมาพัฒนาเพิ่มเติม โดยเน้นการเตรียมข้อมูลภาพให้มีคุณภาพ เช่น การตัดขอบพื้นหลังของภาพเพื่อลดข้อมูลที่ไม่เกี่ยวข้อง และช่วยแบบจำลองสามารถเรียนรู้เฉพาะบริเวณของเนื้องอก จากนั้นใช้เทคนิค Data Augmentation เพื่อเพิ่มความหลากหลายของข้อมูล เช่น การหมุนภาพ การปรับความชัด และการพลิกภาพ ช่วยลดการเกิด overfitting ของแบบจำลอง นอกจากนี้ยังทำการ Fine-tuning ของแบบจำลอง โดยการปรับพารามิเตอร์ เช่น การเพิ่มชั้น Dense และใช้ Dropout เพื่อเพิ่มประสิทธิภาพของแบบจำลองในการเรียนรู้ลักษณะเฉพาะของมะเร็งปอดจากภาพ CT scan เพื่อเพิ่มความแม่นยำในการทำนาย ทั้งนี้งานวิจัยนี้ประยุกต์ใช้เทคนิคการรวมแบบจำลอง (Ensemble Method) โดยใช้วิธีการแบบ Stacking ซึ่งเป็นการรวมผลลัพธ์จากแบบจำลองย่อยหลายตัวเข้าด้วยกัน เพื่อสร้างแบบจำลองใหม่ที่สามารถเรียนรู้จากข้อมูลการทำนายของแบบจำลองย่อยเหล่านั้น และช่วยเพิ่มประสิทธิภาพในการทำนายได้ดียิ่งขึ้น

Objectives

1. เพื่อศึกษากระบวนการที่เหมาะสมสำหรับการสร้างแบบจำลองสำหรับการทำนายมะเร็งปอด
2. เพื่อจัดเตรียมข้อมูลให้เหมาะสมและเพิ่มประสิทธิภาพความแม่นยำของแบบจำลอง
3. เพื่อพัฒนาแบบจำลองสำหรับทำนายมะเร็งปอดจากภาพ CT scan โดยใช้ CNN

Related Works

การศึกษางานวิจัยของ Lanjewar et al. (2023) เกี่ยวกับการทำนายและจำแนกประเภทมะเร็งปอดจากภาพ CT Scan ชุดข้อมูล Chest CT-Scan Images Dataset จากเว็บไซต์ Kaggle เลือกใช้แบบจำลอง DenseNet201 มีการปรับแต่งกับการใช้เทคนิค Feature Selection เพื่อคัดเลือกคุณลักษณะที่ดีที่สุดจากแบบจำลอง โดยคุณลักษณะถูกคัดเลือกผ่าน 2 วิธี ดังนี้ วิธี ETC และ วิธี MRMR จากนั้นคุณลักษณะที่ได้ถูกรวมเข้าด้วยกันและนำไปใช้กับตัวแบบจำแนกประเภทในการเรียนรู้ของเครื่อง ได้แก่ (Support Vector Machine: SVM) และ (Logistic Regression: LR) พบว่ามีผลการวิจัยดีกว่า (Random Forest: RF), (Decision Tree: DT), (Naive Bayes: NB) และ (K-Nearest Neighbors: KNN) นอกจากนี้เลือกใช้

เทคนิคประเมินผลด้วยวิธี 5-fold cross-validation พบว่าความแม่นยำเฉลี่ยสูงสุดอยู่ที่ 95% ในทำนองเดียวกัน Mamun et al. (2023) ใช้ชุดข้อมูลเดียวกัน ทั้งหมด 964 ภาพ ทำการวิเคราะห์เปรียบเทียบแบบจำลอง ได้แก่ InceptionV3, Xception และ ResNet50 โดยเลือกใช้เทคนิคในการประเมินประสิทธิภาพ ดังนี้ ความแม่นยำ, พื้นที่ใต้กราฟ, ค่าการเรียกกลับ และ ค่าความสูญเสีย จากการศึกษพบว่า Inception V3, Xception และ ResNet50 ได้ค่าความแม่นยำ 84.13%, 82.1% และ 82.07% ตามลำดับ ในขณะที่แบบจำลอง CNN (Custom CNN) ให้ผลลัพธ์ที่ดีที่สุดได้ค่าความแม่นยำ 92% ค่าคะแนนพื้นที่ใต้กราฟ 98.21% ค่าการเรียกกลับ 91.72% และค่าความสูญเสีย 0.328 ผลลัพธ์นี้เห็นว่าแบบจำลอง Custom CNN ที่ออกแบบขึ้นมามีประสิทธิภาพสูงในการตรวจจับมะเร็งปอดจากภาพ CT scan Ishrat Khan et al. (2022) ได้พัฒนาแบบจำลองโดยแบ่งข้อมูลมะเร็งปอดออกเป็น 4 กลุ่ม งานวิจัยนี้ทดลองใช้แบบจำลองของ CNN ได้แก่ ResNet101, InceptionV3, VGG16 และ DenseNet169 ที่ถูกฝึกมาก่อนผ่านเทคนิค Transfer Learning ซึ่งช่วยให้แบบจำลองสามารถเรียนรู้คุณลักษณะเฉพาะของภาพ CT Scan และทำการปรับแต่งบางชั้นของแบบจำลอง (Fine-tuning) เพื่อให้แบบจำลองเข้าใจลักษณะของกลุ่มมะเร็งปอดที่ดีกว่าเดิม และได้ความแม่นยำ 90.95%, 91.74%, 82.78% และ 88.97% ตามลำดับ จากนั้นทดลองนำเทคนิค Ensemble CNN โดยทำการรวมแบบจำลอง ResNet101 และ InceptionV3 เข้าด้วยกัน ผลการศึกษพบว่าการทำเทคนิค Ensemble ให้ผลสูงที่สุดโดยมีความแม่นยำอยู่ที่ 93.7%

ในงานวิจัยของ Anil Kumar Swain et al. (2024) ได้ทำการเปรียบเทียบประสิทธิภาพระหว่างแบบจำลอง VGG16, ResNet50 และ InceptionV3 สำหรับการจำแนกมะเร็งปอดชนิด NSCLC ผลลัพธ์แสดงให้เห็นว่า InceptionV3 มีประสิทธิภาพดีที่สุด โดยให้ค่าความแม่นยำ 98.29% นอกจากนี้งานของ Asadullah Shaikh et al. (2025) เกี่ยวกับการตรวจจับและแบ่งส่วนเนื้อเยื่อจากภาพ MRI โดยใช้เทคนิคการเรียนรู้เชิงลึกร่วมกับ Stacking Ensemble Learning (SEL) โดยออกแบบให้ DenseNet201 ทำหน้าที่เป็น meta model รวมการทำนายจาก 6 แบบจำลองพื้นฐาน ได้แก่ MobileNetv3, 3DCNN, VGG16, VGG19, ResNet50 และ AlexNet นอกจากนี้ยังใช้เทคนิค Image enhancement และ Augmentation การทดลองพบว่า SEL-DenseNet201 ทำงานได้ดีที่สุดโดยมีความแม่นยำ 99.65% และงานวิจัยของ Robiul Islam & Nahiduzzaman (2022) ประยุกต์ใช้ Convolutional Neural Network (CNN) ในการสกัดคุณลักษณะสำคัญจากภาพ CT Scan ของผู้ป่วย COVID-19 โดยก่อนประมวลผลได้นำเทคนิค Contrast Limited Histogram Equalization (CLAHE) มาปรับปรุงคุณภาพของภาพ จากนั้นคุณลักษณะที่สกัดได้ถูกนำไปเข้าสู่ แบบจำลองการเรียนรู้เครื่องหลายแบบ ได้แก่ Gaussian Naive Bayes, SVM, Decision Tree, Logistic Regression และ Random Forest และใช้ Soft Voting Ensemble เพื่อรวมผลการทำนายของแต่ละแบบจำลอง ผลการทดลองพบว่าแบบจำลอง Ensemble ที่พัฒนาขึ้นสามารถจำแนกภาพ CT ของ COVID-19 ได้อย่างแม่นยำสูงสุด โดยมีความแม่นยำถึง 99.73%

Methodology

งานวิจัยนี้พัฒนาแบบจำลองโดยใช้ภาษา Python โดยใช้ไลบรารีของ TensorFlow และ Keras สำหรับการพัฒนาแบบจำลองของ CNN บนแพลตฟอร์ม Google Colaboratory (Colab) ซึ่งเป็นเครื่องมือช่วยในการประมวลผลชุดข้อมูลจาก Kaggle (Mohamed Hany, 2024) ในหัวข้อ Chest CT-Scan Images Dataset ซึ่งเป็นแหล่งข้อมูลแบบเปิดที่สามารถเข้าถึงสาธารณะ ประกอบด้วยภาพ CT Scan ที่มีการติดฉลากและแบ่งชนิดต่าง ๆ ของมะเร็งปอดชนิดไม่ใช้เซลล์เล็ก (NSCLC) และปอดปกติ ภาพเหล่านี้เป็นรูปแบบ RGB โดยประเภทไฟล์ภาพเป็น jpeg และ png แสดงใน Figure 1 และมีรายละเอียดดังต่อไปนี้




Figure 1 Representative CT scan images of different types of lung cancer and normal lung tissue

กระบวนการเตรียมข้อมูล

งานวิจัยนี้มีการวางแผนกระบวนการพัฒนาแบบจำลอง โดยแสดงลำดับการดำเนินงานตั้งแต่การคัดเลือกชุดข้อมูล การจัดเตรียมข้อมูล การจัดเตรียมภาพ การฝึกแบบจำลอง การประเมินผล ไปจนถึงการใช้เทคนิครวมผลลัพธ์แสดงใน Figure 2 และมีรายละเอียดดังต่อไปนี้




Figure 2 Flowchart of the model development process

การเตรียมข้อมูลสำหรับการศึกษานี้ ชุดข้อมูลประกอบด้วยภาพ CT Scan ของมะเร็งปอด (NSCLC) จำนวนทั้งหมด 1,000 ภาพ โดยข้อมูลภาพถูกแบ่งตามชนิดของมะเร็งปอดทั้ง 4 คลาส ได้แก่ คลาส 0 = Adenocarcinoma, คลาส 1 = Large Cell Carcinoma, คลาส 2 = Normal (ปอดปกติ) และคลาส 3 = Squamous Cell Carcinoma โดยแบ่งออกเป็น 3 ชุด ได้แก่ ชุดฝึกฝน (Training set) จำนวน 613 ภาพ (ร้อยละ 70), ชุดตรวจสอบ (Validation set) จำนวน 72 ภาพ (ร้อยละ 10) และ ชุดทดสอบ (Testing set) จำนวน 315 ภาพ (ร้อยละ 20) โดยแต่ละภาพจะถูกตัดขอบพื้นหลังเพื่อแสดงเฉพาะบริเวณของเนื้อปอดก่อนนำเข้าสู่กระบวนการพัฒนาแบบจำลอง ซึ่งการตัดขอบภาพสามารถช่วยลดข้อมูลรบกวนและเรียนรู้ลักษณะได้อย่างมีประสิทธิภาพมากขึ้น แสดงใน Figure 3




Figure 3 CT scan images before and after background removal

กระบวนการสร้างแบบจำลอง

งานวิจัยนี้ได้ดำเนินการเลือกใช้สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ได้แก่ ResNet50, VGG16, InceptionV3, DenseNet121 ซึ่งเป็นแบบจำลองที่นิยมใช้ในงานด้านการประมวลผลภาพ ดังรายละเอียดต่อไปนี้

1. ResNet50 พัฒนาโดยทีมวิจัยของ Kaiming He, Xiangyu Zhang, Shaoqing Ren และ Jian Sun จาก Microsoft Research Asia (MSRA) ถูกนำเสนอครั้งแรกในงานประชุม CVPR ในปี 2015 มีความลึก 50 ชั้น ถูกออกแบบมาเพื่อลดปัญหาการสูญเสียข้อมูลระหว่างการเรียนรู้ รองรับขนาดนำเข้าของภาพที่ 224×224 พิกเซล และเป็นหนึ่งในแบบจำลองยอดนิยมสำหรับงานด้านการจำแนกภาพ การตรวจจับวัตถุ และการแยกส่วนของภาพ (He et al., 2015)




Figure 4 Architecture of the ResNet50 model

2. VGG16 พัฒนาโดยทีมวิจัยของ Karen Simonyan และ Andrew Zisserman จาก Visual Geometry Group (VGG) University of Oxford ถูกเผยแพร่ผ่าน arXiv ในปี 2014 มีความลึก 16 ชั้น ถูกออกแบบมาเพื่อเพิ่มประสิทธิภาพในการจำแนกภาพโดยใช้ฟิลเตอร์ขนาดเล็ก (3×3) หลายชั้นต่อเนื่องกันแทนการใช้ฟิลเตอร์ขนาดใหญ่ รองรับขนาดนำเข้าของภาพที่ 224×224 พิกเซล (Simonyan & Zisserman, 2014)




Figure 5 Architecture of the VGG16 model

3. DenseNet121 ถูกพัฒนาโดยทีมวิจัยของ Gao Huang, Zhuang Liu, Laurens van der Maaten และ Kilian Q. Weinberger จาก Cornell University และ Facebook AI Research (FAIR) ถูกนำเสนอครั้งแรกในงานประชุม IEEE Conference on Computer Vision and Pattern Recognition (CVPR) ในปี 2017 ออกแบบมาให้มีการเชื่อมต่อระหว่างทุกชั้นของโครงข่ายโดยตรง ซึ่งช่วยให้การไหลของข้อมูลและเกราดิเอนต์ดีขึ้น ลดปัญหาการสูญเสียข้อมูล และช่วยให้สามารถใช้พารามิเตอร์น้อยกว่ารุ่นก่อนหน้า เช่น ResNet โดย DenseNet ที่มีความลึก 121 ชั้น และรองรับขนาดภาพนำเข้า 224×224 พิกเซล (Huang et al., 2017)




Figure 6 Architecture of the DenseNet121 model

4. InceptionV3 ถูกพัฒนาโดย Christian Szegedy และคณะ จาก Google Research และถูกนำเสนอครั้งแรกในงานประชุม CVPR ปี 2016 เป็นโครงข่ายประสาทเทียมแบบ CNN ที่มีความลึก 48 ชั้น ถูกออกแบบมาเพื่อลดจำนวนพารามิเตอร์โดยใช้ Factorized Convolutions และ Batch Normalization ซึ่งช่วยเพิ่มประสิทธิภาพในการเรียนรู้ รองรับขนาดนำเข้าของภาพที่ 299×299 พิกเซล (Szegedy et al., 2016)




Figure 7 Architecture of the InceptionV3 model

กระบวนการเพิ่มข้อมูลฝึก

เนื่องจากข้อมูลภาพที่ใช้ในการฝึกฝนมีความหลากหลายไม่เพียงพอ และแบบจำลองเรียนรู้รายละเอียดและสัญญาณรบกวนในชุดข้อมูลฝึกมากเกินไป จนไม่สามารถทำนายผลได้อย่างแม่นยำเมื่อประเมินด้วยข้อมูลใหม่ที่ไม่เคยเห็นมาก่อน จากข้อมูลที่มีจำกัด งานวิจัยนี้เลือกใช้เทคนิค Data Augmentation เพื่อเพิ่มความหลากหลายของภาพ ช่วยให้แบบจำลองเรียนรู้ได้จากข้อมูลที่หลากหลายมากขึ้น โดยวิธีการที่งานวิจัยนี้เลือกใช้มีดังต่อไปนี้

1. การพลิกภาพ (Image Flipping) คือ การพลิกภาพตามแนวนอนหรือแนวตั้ง การพลิกภาพช่วยให้แบบจำลองสามารถเรียนรู้ลักษณะของภาพจากหลายมุมมอง (Shorten & Khoshgoftaar, 2019)
2. การปรับปรุงความชัด (Contrast Adjustment) คือ การปรับปรุงภาพต้นฉบับ เช่น การเปลี่ยนแปลงค่าความเข้มสีของภาพ เพื่อให้วัตถุในภาพมองเห็นได้ชัดเจนขึ้น (Shorten & Khoshgoftaar, 2019)
3. การหมุนภาพ (Rotation) คือ หมุนภาพด้วยองศาที่แตกต่างกันตามมุมที่กำหนด และเกิดการเปลี่ยนแปลงของตำแหน่งและรูปร่างของวัตถุในภาพ (Perez & Wang, 2017)

ภาพต้นฉบับที่ใช้ในกระบวนการฝึกแบบจำลองเป็นภาพที่ได้จากชุดข้อมูล ซึ่งยังไม่เข้าสู่กระบวนการปรับแต่งหรือการเพิ่มข้อมูลด้วยเทคนิค Data Augmentation แสดงใน Figure 8



Figure 8 Original CT scan images

ภาพแสดงผลลัพธ์จากการนำภาพเข้าสู่กระบวนการ Data Augmentation ซึ่งแปลงจากภาพต้นฉบับให้มีความหลากหลาย โดยใช้เทคนิคต่าง ๆ ได้แก่ การพลิกภาพ การปรับปรุงความชัด และการหมุนภาพ แสดงใน Figure 9




Figure 9 CT scan images after data augmentation

กระบวนการพัฒนาแบบจำลอง

การพัฒนาแบบจำลอง CNN ได้แก่ ResNet50, VGG16, DenseNet121 และ InceptionV3 เพื่อจำแนกมะเร็งปอดจากภาพ CT scan จำเป็นต้องกำหนดขนาดภาพนำเข้าให้เหมาะสมกับแบบจำลอง เนื่องจากมีข้อกำหนดมาตรฐานที่แตกต่างกัน โดยแต่ละแบบจำลองมีลักษณะการกำหนดขนาดภาพดังนี้ ResNet50, VGG16 และ DenseNet121 กำหนดให้มีการปรับปรุงพารามิเตอร์และการ Fine-tune แต่ละแบบจำลองเป็นส่วนสำคัญของกระบวนการฝึกฝน โดยการกำหนดค่าขนาดชุดข้อมูล (Batch Size), ขนาดภาพนำเข้า (Input Size), การลือกชั้น (Freeze) และ การปลดลือกชั้น (Unfreeze layers), การตั้งค่าชั้นเชื่อมโยง (Dense Layer), ชั้นตัดการเชื่อมโยง (Dropout Layer) และจำนวนรอบการฝึก (Epochs) ของแต่ละแบบจำลองมีรายละเอียด แสดงใน Table 1

Table 1 Parameter optimization and fine-tuning strategies of each model

Model	Batch Size	Input Size	Freeze Layers	Unfreeze Layers	Dense Layer	Dropout Layer	Epochs
ResNet50	32	224 × 224		block5	1024 512	0.3 0.2	100
VGG16	32	224 × 224		block4 ~ block5	256 64	0.4 0.3	100
InceptionV3	32	299 × 299	All	Last 50	512 256	0.3 0.2	100
DenseNet121	32	224 × 224		Last 50	512 256	0.3 0.2	100

กระบวนการประเมินผลและวัดประสิทธิภาพของแบบจำลอง

การวัดประสิทธิภาพของแบบจำลอง (Performance Evaluation of Models) ในการประเมินผลการทำนายมะเร็งปอดจากภาพ CT scan โดยแต่ละแบบจำลองทำการวัดประสิทธิภาพโดยใช้ตัวชี้วัด ดังต่อไปนี้

1. Accuracy คือ อัตราการทำนายถูกต้องทั้งหมดของแบบจำลองจากข้อมูลทั้งหมด (Google Developers, 2025) ดังสมการที่ 1

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

2. Precision คือ อัตราการทำนายว่าเป็นชนิดของมะเร็งแล้วถูกต้องจริงๆ จากทั้งหมดที่แบบจำลองทำนายว่าเป็นชนิดของมะเร็ง (Google Developers, 2025) ดังสมการที่ 2

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

3. Recall คือ อัตราการตรวจจับมะเร็งได้ครบถ้วนจากจำนวนของชนิดมะเร็งทั้งหมดในชุดข้อมูล โดยพิจารณาจากตัวอย่างทั้งหมดที่เป็นมะเร็งในข้อมูลจริง (Google Developers, 2025) ดังสมการที่ 3

$$Recall = \frac{TP}{TP + FN} \quad (\text{Equation 3})$$

โดยที่

TP (True Positives) = จำนวนตัวอย่างที่แบบจำลองทำนายถูกต้องและเป็นคลาสเนลยจริง

FN (False Negatives) = จำนวนตัวอย่างที่แบบจำลองทำนายผิดและไม่ใช้คลาสเนลยจริง

FP (False Positives) = จำนวนตัวอย่างที่แบบจำลองทำนายผิดและเป็นคลาสเนลยจริง

TN (True Negatives) = จำนวนตัวอย่างที่แบบจำลองทำนายถูกต้องและไม่ใช้คลาสเนลยจริง

4. F1-Score คือ ค่าที่ใช้วัดประสิทธิภาพในการทำนายผลระหว่าง Precision และ Recall ซึ่งแสดงถึงความสมดุลระหว่างความสามารถในการทำนายผลบวกได้อย่างถูกต้อง (Taha & Hanbury, 2015) ดังสมการที่ 4

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (\text{Equation 4})$$

5. Confusion Matrix คือ แสดงการเปรียบเทียบระหว่างค่าทำนายที่ได้กับค่าจริงของแต่ละคลาสของมะเร็งปอด (Powers, 2011)

การประเมินผลแบบจำลองสำหรับ Multiclass Classification เนื่องจากงานวิจัยทำนาย 4 คลาส รวมถึงการใช้เมตริกต่าง ๆ ที่เหมาะสมกับประเภทการจำแนกหลายคลาส

1. Macro คือ การคำนวณค่า Precision, Recall, และ F1-Score แยกตามแต่ละคลาส จากนั้นนำค่าที่ได้มาหาค่าเฉลี่ยเลขคณิต เพื่อประเมินประสิทธิภาพโดยรวมของแบบจำลองอย่างเท่าเทียมกันในแต่ละคลาส (Juri Opitz & Sebastian Burst, 2021) ดังสมการที่ 5

$$Macro\ Average = \frac{1}{N} \sum_{i=1}^N Matric_i \quad (\text{Equation 5})$$

โดยที่

N คือ จำนวนคลาส

Matric_i คือ ค่า Precision, Recall หรือ F1-Score ของคลาสที่ i

2. Weighted คือ การถ่วงน้ำหนักค่า Precision, Recall, และ F1-Score สำหรับแต่ละคลาสนำจำนวนตัวอย่างในแต่ละคลาสมาเป็นน้ำหนักในการเฉลี่ยผลลัพธ์ (Juri Opitz & Sebastian Burst, 2021) ดังสมการที่ 6

$$\text{Weighted Average} = \frac{\sum_{i=1}^N (\text{Metric}_i \times \text{Support}_i)}{\sum_{i=1}^N \text{Support}_i} \quad (\text{Equation 6})$$

โดยที่ Support_i คือจำนวนตัวอย่างในคลาสที่ i

เทคนิคการรวมผลลัพธ์แบบ Stacking ด้วยแบบจำลอง Deep Learning

แนวคิดของ Stacking Model มีรากฐานจาก Wolpert (1992) ซึ่งเสนอแนวทาง Stacked Generalization โดยใช้ meta learner ประมวลผลผลลัพธ์จากแบบจำลองฐานหลายตัว เพื่อลดความผิดพลาดและเพิ่มความแม่นยำของแบบจำลอง การทดลองของแสดงให้เห็นว่า Stacking สามารถเพิ่มความแม่นยำได้ทั้งเมื่อใช้หลายแบบจำลองพร้อมกัน โดยงานของ Jannatul Ferdous & Rifat Shahriyar (2024) พัฒนาแบบจำลอง ENSNET สำหรับทำนายโรคหลอดเลือดสมอง โดยรวมแบบจำลอง InceptionV3 และ Xception ผ่านวิธี averaging ensemble ขณะที่ Dhaval J. Rana & Keyur Rana (2025) ใช้ Transfer Learning ร่วมกับแบบจำลองเชิงลึกหลายแบบ และพัฒนาแบบจำลอง Stacking เพื่อรวมผลลัพธ์จากแบบจำลองฐานหลายตัวเข้าด้วยกัน

ในการศึกษาวิจัยนี้ได้ประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องที่ทำการรวมหลายๆ แบบจำลองเข้าด้วยกัน เพื่อให้ได้ผลลัพธ์ที่แม่นยำและเสถียรกว่าแบบจำลองเดี่ยว เรียกว่า Stacking Model (IBM, 2024) กระบวนการดำเนินงานประกอบด้วย 2 ขั้นตอนหลัก ได้แก่ ขั้นตอนการสร้างแบบจำลองฐาน (base models) โดยเลือกแบบจำลองของ CNN จำนวน 4 แบบจำลอง ได้แก่ VGG16, ResNet50, DenseNet121, และ InceptionV3 โดยแบบจำลองทั้งหมดผ่านการฝึกฝนบนชุดข้อมูลภาพ CT Scan ของปอด โดยผลลัพธ์ของแต่ละแบบจำลองจะอยู่ในรูปของค่าความน่าจะเป็น (probabilities) ของแต่ละคลาส ในส่วนค่าผลลัพธ์จากทั้ง 4 แบบจำลองจะถูกนำมารวมกันด้วยวิธีการเชื่อมต่อกันในแนวนอน (concatenation) เพื่อสร้างเวกเตอร์ขนาด 4x4 ซึ่งประกอบไปด้วยคุณลักษณะ (features) ถูกใช้เป็นข้อมูลนำเข้าให้กับแบบจำลองเมตา (meta model) แสดงใน Figure 10 โดยงานวิจัยนี้ได้ทดลองใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning Algorithms) ประเภทการจำแนกต่าง ๆ จำนวน 5 แบบ เพื่อการทำนายผลลัพธ์ขั้นตอนสุดท้าย ได้แก่

1. RF เป็นแบบจำลองป่าสุ่มประกอบด้วยต้นไม้การตัดสินใจหลายต้น วิธีการเรียนรู้แบบรวมกลุ่มประกอบด้วยชุดของตัวจำแนกประเภท โดยการคาดการณ์จะถูกรวบรวมเพื่อระบุผลลัพธ์ที่ได้รับความนิยมมากที่สุด (IBM, 2025)
2. LR เป็นแบบจำลองทางสถิติชนิดหนึ่งที่ใช้สำหรับทำนายความน่าจะเป็นของเหตุการณ์ที่มีผลลัพธ์เป็นสองกลุ่มโดยจะใช้ฟังก์ชันลอจิสติก (logistic function) หรือที่เรียกว่า sigmoid function เพื่อแปลงค่าผลรวมเชิงเส้นของตัวแปรอิสระให้เป็นค่าความน่าจะเป็นที่อยู่ระหว่าง 0 ถึง 1 (Friedman, Hastie, & Tibshirani, 2020)
3. SVM เป็นทำการจำแนกข้อมูลโดยการหาค่ากราฟเส้นตรงหรือไฮเปอร์เพลน (hyperplane) ที่เหมาะสมที่สุดในเชิงคณิตศาสตร์ ซึ่งช่วยเพิ่มระยะห่างสูงสุดระหว่างแต่ละคลาส (IBM, 2025)
4. KNN เป็นการใช้ระยะห่างจากจำนวน K จุด เพื่อจำแนกประเภทคลาสเสียงส่วนใหญ่ของข้อมูลจากเพื่อนบ้านที่ใกล้ที่สุดแต่ละจุดในบริเวณนั้น (IBM, 2025)
5. NB เป็นอัลกอริทึมที่ใช้หลักการหาค่าความน่าจะเป็นที่ในการจำแนกประเภทคลาสคำนึงถึงอิสระต่อกันของคุณลักษณะแต่ละตัว (IBM, 2025)




Figure 10 Stacking ensemble framework for model integration

Results


จากการศึกษากระบวนการและการจัดเตรียมข้อมูลที่เหมาะสมในการพัฒนาสำหรับการสร้างแบบจำลอง CNN เพื่อทำนายมะเร็งปอดจากภาพ CT scan งานวิจัยนี้เลือกใช้สถาปัตยกรรมต่าง ๆ ได้แก่ ResNet50, VGG16, InceptionV3, และ DenseNet121 โดยมุ่งทำการเปรียบเทียบผลลัพธ์ของแต่ละแบบจำลองผ่านการปรับพารามิเตอร์ต่าง ๆ โดยเฉพาะอัตราการเรียนรู้ (Learning Rate) ซึ่งในแต่ละการทดลอง งานวิจัยนี้เลือกใช้ Optimizer ต่าง ๆ เช่น Adam และ Adamax พร้อมกำหนดค่าอัตราการเรียนรู้ที่ 3 ระดับ คือ 0.01, 0.001 และ 0.0001 เพื่อประเมินผลต่อค่าความแม่นยำ และค่าการสูญเสียของแบบจำลองในแต่ละชุดข้อมูล

จากการทดลองของแบบจำลอง ResNet50 พบว่า การใช้ Optimizer แบบ Adamax ร่วมกับค่า Learning Rate ที่ 0.001 ให้ผลลัพธ์ที่ดีที่สุด โดยสามารถจำแนกข้อมูลในชุด Train, Validation และ Test ได้ด้วยค่า Accuracy เท่ากับ 99.84%, 93.06% และ 95.56% ตามลำดับ ขณะที่แบบจำลอง VGG16 ให้ผลลัพธ์ดีที่สุดเมื่อใช้ Optimizer แบบ Adamax และ Learning Rate ที่ 0.0001 โดยได้ค่า Accuracy เท่ากับ 97.39%, 87.50% และ 95.87% ตามลำดับ ในส่วนของแบบจำลอง InceptionV3 ผลการทดลองแสดงให้เห็นว่าการใช้ Optimizer แบบ Adam ร่วมกับ Learning Rate ที่ 0.001 ให้ผลลัพธ์ที่ดีที่สุด โดยมี Accuracy เท่ากับ 99.67% บนชุด Train, 94.44% บนชุด Validation และ 96.19% บนชุด Test ขณะที่แบบจำลอง DenseNet121 ให้ผลลัพธ์สูงสุดเมื่อใช้ Optimizer แบบ Adamax และค่า Learning Rate ที่ 0.001 เช่นเดียวกับ ResNet50 โดยให้ค่า Accuracy เท่ากับ 99.51%, 91.67% และ 95.87% ในชุดข้อมูล Train, Validation และ Test ตามลำดับ แสดงใน Table 2


Table 2 Experimental results of different optimizers and learning rates for each model

Model	Optimizer	Learning Rate	Accuracy			Loss		
			Train	Val	Test	Train	Val	Test
ResNet50	Adam	0.01	99.51	88.89	93.97	0.01	0.61	0.23
		0.001	99.35	87.50	93.02	0.009	0.48	0.20
		0.0001	99.67	91.67	93.65	0.008	0.43	0.20
	Adamax	0.01	99.35	87.50	94.29	0.01	0.40	0.24
		0.001	99.84	93.06	95.56	0.008	0.50	0.25
		0.0001	99.02	86.11	90.48	0.03	0.39	0.25
VGG16	Adam	0.01	70.96	48.61	65.07	0.67	1.29	0.95
		0.001	71.13	52.78	73.97	0.66	1.05	0.78
		0.0001	98.04	83.33	92.69	0.07	0.57	0.33
	Adamax	0.01	69.00	47.22	66.35	0.70	1.09	0.90
		0.001	69.98	56.94	70.79	0.62	0.96	0.68
		0.0001	97.39	87.50	95.87	0.08	0.45	0.24
InceptionV3	Adam	0.01	99.51	93.06	95.24	0.01	0.50	0.19
		0.001	99.67	94.44	96.19	0.008	0.33	0.30
		0.0001	99.02	86.11	93.65	0.02	0.49	0.32
	Adamax	0.01	99.35	91.67	94.92	0.01	0.47	0.27
		0.001	99.51	91.67	93.97	0.01	0.42	0.26
		0.0001	98.69	83.33	88.25	0.05	0.44	0.33
DenseNet121	Adam	0.01	98.86	87.50	95.24	0.02	0.73	0.37
		0.001	99.02	91.67	93.01	0.01	0.51	0.48
		0.0001	98.37	88.89	91.11	0.05	0.53	0.26
	Adamax	0.01	99.67	91.67	95.55	0.01	0.39	0.36
		0.001	99.51	91.67	95.87	0.02	0.30	0.24
		0.0001	93.31	81.94	84.76	0.18	0.57	0.38

ในการประเมินความสามารถของแบบจำลองในการจำแนกภาพในแต่ละคลาส งานวิจัยนี้ใช้ Confusion Matrix จากชุดข้อมูลทดสอบที่มีข้อมูลภาพจำนวนทั้งหมด 315 ภาพ ซึ่งช่วยให้เห็นถึงความแม่นยำในการจำแนกของแต่ละคลาส โดยแสดงจำนวนตัวอย่างที่จำแนกถูกต้องและผิดพลาดอย่างชัดเจน แสดงใน Figure 11



(1) InceptionV3



(2) ResNet50




Figure 11 Confusion matrices of each deep learning model

งานวิจัยนี้ได้พิจารณาความแม่นยำ และค่าความสูญเสีย จากชุดข้อมูล Train และ Validation เพื่อดูว่าแบบจำลองสามารถเรียนรู้และปรับตัวได้ดีเพียงใดระหว่างการฝึกฝน โดยสรุปผลลัพธ์ในแต่ละแบบจำลองแสดงในรูปแบบกราฟให้เห็นแนวโน้มค่าความแม่นยำ และค่าสูญเสียตลอดช่วงการฝึกของแบบจำลอง แสดงใน Figure 12




Figure 12 Training and validation accuracy and loss curves of each model


จากผลการทดลองพบว่า แบบจำลอง ResNet50, VGG16, InceptionV3 และ DenseNet121 สามารถจำแนกประเภทของมะเร็งปอดได้อย่างแม่นยำ โดยทุกแบบจำลองให้ค่า Precision, Recall และ F1-Score สูงสุดถึง 0.98 และ 1.00 ตามลำดับ นอกจากนี้ ค่าคะแนนเฉลี่ยแบบ Macro และ Weighted ของแบบจำลองประมาณ 0.96 แสดงใน Table 3 และมีรายละเอียดดังต่อไปนี้

Table 3 Class-wise performance, Macro and Weighted averages of each model

Model	Metric	Class 0	Class 1	Class 2	Class 3	Macro	Weighted
ResNet50	Precision	0.94	0.92	1.00	0.97	0.96	0.96
	Recall	0.94	0.96	0.98	0.96	0.96	0.96
	F1-Score	0.94	0.94	0.99	0.96	0.96	0.96
VGG16	Precision	0.97	0.89	1.00	0.96	0.96	0.96
	Recall	0.93	0.96	0.98	0.99	0.96	0.96
	F1-Score	0.95	0.92	0.99	0.97	0.96	0.96
InceptionV3	Precision	0.98	0.89	1.00	0.96	0.96	0.96
	Recall	0.93	0.98	0.96	1.00	0.97	0.96
	F1-Score	0.95	0.93	0.98	0.98	0.96	0.96
DenseNet121	Precision	0.96	0.89	1.00	0.98	0.96	0.96
	Recall	0.94	1.00	0.96	0.96	0.97	0.96
	F1-Score	0.95	0.94	0.98	0.97	0.96	0.96

จากการทดลองแบบจำลอง InceptionV3 มีค่าความแม่นยำจากการทดสอบสูงที่สุด เท่ากับ 96.19 แต่มีค่าสูญเสีย ที่สูงสุดเมื่อเทียบกับแบบจำลองอื่น ๆ ในขณะที่แบบจำลอง VGG16 และ DenseNet121 ให้ผลลัพธ์ที่ดีที่สุดในส่วนของการสูญเสียที่ต่ำที่สุดโดยทั้งสองแบบจำลองมีความแม่นยำเท่ากันที่ 95.87% สำหรับ ResNet50 ถึงแม้จะมีความแม่นยำต่ำสุด แต่ยังคงมีผลลัพธ์ที่ดีในการทำนายมะเร็งปอดจากภาพ CT Scan

จากผลการทดลองพบว่า InceptionV3 สามารถจำแนกภาพ CT scan ได้ถูกต้องสำหรับแต่ละคลาส ได้แก่ adenocarcinoma (0), large cell carcinoma (1), normal (2) และ squamous cell carcinoma (3) โดยแสดงผลการทำนาย (Pred) และ ค่าจริง (GT) แสดงใน Figure 13


**Figure 13** Sample classification results of InceptionV3 for different types of lung cancer

จากการประเมินแบบจำลองเมตา ด้วยเทคนิค Ensemble Method พบว่า RF ให้ผลดีที่สุด โดยมี Accuracy สูงถึง 98.73% และค่า Precision, Recall และ F1-score ทั้งแบบ Macro และ Weighted เท่ากับ 0.99 แสดงถึงความแม่นยำในการจำแนกคลาสได้แม่นยำ ขณะที่ LR และ SVM ให้ผลใกล้เคียงกันที่ 96.83% และ 96.51% ส่วน KNN และ NB มีความแม่นยำที่ 97.46% โดย NB มีค่า Recall แบบ Macro สูงถึง 0.98 แสดงใน Table 4

Table 4 Performance evaluation of the meta-model (Stacking Ensemble)

ML Algorithm	Accuracy	Precision		Recall		F1-score	
		Macro	weighted	Macro	weighted	Macro	weighted
RF	98.73	0.99	0.99	0.99	0.99	0.99	0.99
LR	96.83	0.96	0.97	0.97	0.97	0.97	0.97
SVM	96.51	0.96	0.97	0.97	0.97	0.97	0.97
KNN	97.46	0.97	0.97	0.97	0.97	0.97	0.97
NB	97.46	0.97	0.98	0.98	0.97	0.98	0.97

ผลลัพธ์ของตาราง Confusion Matrix จากการทดลองใช้เทคนิคการเรียนรู้ของเครื่อง ประเภทการจำแนกจำนวน 5 แบบ ได้แก่ RF, LR, SVM, KNN และ NB เพื่อทำหน้าที่เป็นแบบจำลองเมตา ในการจำแนกขั้นตอนสุดท้าย โดยระบบสามารถทำนายผลลัพธ์ได้ถูกต้องจากชุดภาพทดสอบทั้งหมด 315 ภาพ แสดงใน Figure 14

**Figure 14** Confusion matrix of the stacking ensemble meta-model

Conclusion and Discussion

จากผลการทดลองการพัฒนาแบบจำลองสำหรับการทำนายมะเร็งปอดโดยใช้ CNN พบว่า InceptionV3 ให้ค่าความแม่นยำสูงสุดที่ 96.19% ขณะที่ VGG16, ResNet50 และ DenseNet121 ให้ค่าความแม่นยำที่ 95.87%, 95.56% และ 95.87% ตามลำดับ นอกจากนี้ยังพบว่าทางเลือก Optimizer ที่เหมาะสมและการปรับแต่งพารามิเตอร์ต่าง ๆ มีผลต่อการเพิ่มประสิทธิภาพของแบบจำลองอย่างมีนัยสำคัญ จากนั้นได้มีการนำผลลัพธ์จากแบบจำลองพื้นฐานมาใช้ในการ Ensemble Method แบบ Stacking โดยมีอัลกอริทึมการเรียนรู้ของเครื่อง 5 แบบ ได้แก่ RF, LR, SVM, KNN และ NB ทำหน้าที่เป็นแบบจำลองเมตาผลการทดลองแสดงให้เห็นว่า RF ให้ค่าความแม่นยำสูงสุดที่ 98.73% ขณะที่อัลกอริทึม

อื่น ๆ ได้แก่ LR, SVM, KNN และ NB ให้ค่าความแม่นยำที่ 96.83%, 96.51%, 97.46% และ 97.46% ตามลำดับ สอดคล้องกับ Lanjewar et al. (2023) ได้พัฒนาแบบจำลอง DenseNet201 เป็นตัวดึงคุณลักษณะ และประยุกต์ใช้วิธีคัดเลือกคุณลักษณะ ได้แก่ ETC และ MRMR ก่อนนำไปใช้กับอัลกอริทึมการจำแนก SVM และ LR ผลลัพธ์ได้ค่าความแม่นยำเฉลี่ยสูงถึง 95% ซึ่งใกล้เคียงกับแบบจำลอง InceptionV3 ของงานวิจัยนี้ ในทำนองเดียวกัน Mamun et al. (2023) ใช้ชุดข้อมูลเดียวกันกับงานวิจัยนี้ โดยทำการเปรียบเทียบประสิทธิภาพของ InceptionV3, Xception และ ResNet50 กับแบบจำลองที่พัฒนาเอง ผลการทดลองพบว่า Custom CNN มีค่าความแม่นยำสูงถึง 92% นอกจากนี้ Ishrat Khan et al. (2022) ได้พัฒนาแบบจำลองโดยใช้ ResNet101, InceptionV3, VGG16 และ DenseNet169 ผ่านเทคนิค Transfer Learning และ Fine-tuning ผลการทดลองแสดงว่า การใช้ Ensemble CNN ซึ่งรวมผลจาก ResNet101 และ InceptionV3 สามารถเพิ่มค่าความแม่นยำได้สูงสุด 93.7% ดีกว่าการใช้แบบจำลองเดี่ยว ในงานวิจัยของ Rehan Raza et al. (2023) ซึ่งเสนอแบบจำลองชื่อ Lung-EffNet พัฒนาระบบสถาปัตยกรรม EfficientNet (ตั้งแต่ B0 ถึง B4) โดยอาศัยแนวคิด Transfer Learning และการปรับแต่งเลเยอร์ของแบบจำลอง รวมถึงใช้เทคนิคการตัดภาพ และการใช้เทคนิคเพิ่มข้อมูล โดยค่าความแม่นยำได้สูงถึง 99.10% แม้ว่าจะใช้สถาปัตยกรรมมีความซับซ้อนสูงกว่า แต่การประยุกต์ใช้ Ensemble ในงานวิจัยนี้สามารถให้ผลลัพธ์ใกล้เคียงกันในด้านประสิทธิภาพการจำแนกภาพ ในทำนองเดียวกัน Sampangi Rama Reddy B. R. et al. (2024) เสนอ Stacked Neural Network (SNN) ซึ่งรวมการเรียนรู้จากแบบจำลอง ANN และ CNN เข้าไว้ด้วยกัน เพื่อเพิ่มประสิทธิภาพในการตรวจจับและจำแนกมะเร็งปอดจากภาพ CT Scan ให้ค่าความแม่นยำสูงถึง 96% อย่างไรก็ตาม เมื่อเปรียบเทียบกับงานวิจัยนี้ ซึ่งไม่เพียงแต่อาศัยการเปรียบเทียบสถาปัตยกรรม CNN หลายรูปแบบเท่านั้น แต่งานวิจัยนี้ยังต่อยอดด้วยการสร้าง Ensemble Method แบบ Stacking ที่ใช้ผลลัพธ์ของแบบจำลองพื้นฐานร่วมกับอัลกอริทึมการเรียนรู้ของเครื่อง ทำหน้าที่เป็นแบบจำลองเมตาทำให้สามารถเพิ่มค่าความแม่นยำโดยรวมเป็น 98.73%

ผลจากการศึกษาและพัฒนากระบวนการที่เหมาะสมในการสร้างแบบจำลอง CNN เพื่อทำนายมะเร็งปอดจากภาพ CT scan โดยใช้ชุดข้อมูล Chest CT-Scan Images Dataset จากเว็บไซต์ Kaggle ซึ่งประกอบด้วยภาพ CT scan รวมทั้งหมด 1,000 ภาพ แบ่งออกเป็นชุดข้อมูลสำหรับฝึก ชุดตรวจสอบ และชุดทดสอบ โดยแต่ละภาพมีการติดฉลากระบุประเภทของมะเร็งปอดชนิดไม่ใช้เซลล์เล็ก (NSCLC) และปอดปกติ แบ่งออกเป็น 4 คลาส ได้แก่ Adenocarcinoma (มะเร็งชนิดต่อมน้ำเหลืองในปอด), Large Cell Carcinoma (มะเร็งเซลล์ขนาดใหญ่), Squamous Cell Carcinoma (มะเร็งเซลล์สควamous) และ Normal (ปอดปกติ) งานวิจัยนี้ได้ทำการเปรียบเทียบประสิทธิภาพของแต่ละแบบจำลอง โดยใช้สถาปัตยกรรมหลัก ๆ ได้แก่ VGG16, ResNet50, InceptionV3 และ DenseNet121 พร้อมทั้งประยุกต์ใช้เทคนิคเพื่อเพิ่มประสิทธิภาพของแบบจำลอง เช่น การเพิ่มข้อมูลด้วย Data Augmentation, การปรับแต่งค่าพารามิเตอร์ และการปรับแต่งแบบจำลอง นอกจากนี้ ยังมีการตัดขอบภาพ เพื่อขจัดพื้นที่ที่ไม่เกี่ยวข้องออก เหลือเพียงบริเวณเนื้อปอด ซึ่งเป็นส่วนสำคัญในการเรียนรู้ของแบบจำลอง สำหรับงานวิจัยในอนาคต สามารถนำกระบวนการที่ได้ไปต่อยอดสู่การพัฒนาแอปพลิเคชันทางการแพทย์ที่สามารถสนับสนุนการวินิจฉัยได้จริง

References

- Alowais, S. A., Alghamdi, S. S., Alsuhbany, N., Alqahtani, T., Alshaya, A. I., Almohareb, S. N., ... & Albekairy, A. M. (2023). *Revolutionizing healthcare: The role of artificial intelligence in clinical image analysis*. BMC Medical Education. from <https://doi.org/10.1186/s12909-023-04698-z>.
- American Cancer Society. (2024, 12 September). *What is lung cancer?*. From <https://www.cancer.org/cancer/lung-cancer/about/what-is.html>.

- Aziz Taha, Abdel. (2015). Metrics for evaluating 3D medical image segmentation: Analysis, selection, and tool. *BMC Medical Imaging*, 15(29), 1–28. from <https://doi.org/10.1186/s12880-015-0068-x>.
- BNH Hospital. (2024, 10 September). *How are X-ray and CT scan for lung cancer screening different? Which is better & is it true that frequent scans pose a cancer risk?*. From <https://www.bnhhospital.com/th/>. (in Thai)
- Department of Medical Services. (2024, 10 September). *Headline: National Cancer Institute recommends avoiding lung cancer risk factors*. From https://www.dms.go.th/Content/Select_Landding_page?contentId=47994. (in Thai)
- Friedman, J., Hastie, T., & Tibshirani, R. (2020). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer.
- Ferdous, M. J., & Shahriyar, R. (2024). *An ensemble convolutional neural network model for brain stroke prediction using brain computed tomography images*. *Healthcare Analytics*, 6, Article 100368. From <https://doi.org/10.1016/j.health.2024.100368>.
- Google Developers. (2025, 5 May). *Classification: Accuracy, recall, precision, and related metrics*. from <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall?hl=th>.
- Hany, M. (2024, 10 September). *Chest CT-scan images dataset* [Dataset]. Kaggle. From <https://www.kaggle.com/datasets/mohamedhanyyy/chest-ctscan-images>.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 770–778). From <https://doi.org/10.1109/CVPR.2016.90>.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 4700–4708). from <https://doi.org/10.1109/CVPR.2017.243>.
- IBM. (2025, 5 May). *Support vector machine, random forest, naive Bayes, and k-nearest neighbors*. From <https://www.ibm.com/think/topics/>.
- Islam, M. R., & Nahiduzzaman, M. (2022). Complex features extraction with deep learning model for the detection of COVID-19 from CT scan images using ensemble based machine learning approach. *Expert Systems with Applications*, 195, 116554. from <https://doi.org/10.1016/j.eswa.2022.116554>.
- Khan, I. I., & Fattah, H. M. A. (2022). An ensemble technique of CNN for lung cancer identification. *International Journal of Engineering Research and Management*, 9(11), 7–11. From https://www.ijerm.com/download_data/IJERM0911003.pdf.
- Li, X., Zhang, Y., Chen, Z., & Wang, H. (2025). *FPA-based weighted average ensemble of deep learning models for classification of lung cancer using CT scan images* (Scientific Reports). Advance online publication. from <https://doi.org/10.1038/s41598-025-02015-w>.

- Lanjewar, M. G., Panchbhai, K. G., & Charanarur, P. (2023). Lung cancer detection from CT scans using modified DenseNet with feature selection methods and ML classifiers. *Expert Systems with Applications*, 224, 119961. from <https://doi.org/10.1016/j.eswa.2023.119961>.
- Mamun, M., Mahmud, M. I., Meherin, M., & Abdelgawad, A. (2023). *LCDctCNN: Lung cancer diagnosis of CT scan images using CNN based model*. arXiv. from <https://doi.org/10.48550/arXiv.2304.04814>.
- Mamun, S., Patil, A., & Gite, S. (2023). Lung cancer detection from CT scans using modified DenseNet with feature selection methods and machine learning classifiers. *Expert Systems with Applications*. From <https://doi.org/10.1016/j.eswa.2023.119961>.
- National Cancer Institute. (2021, 24 May). *Lung cancer screening (PDQ®) – Patient version*. U.S. Department of Health and Human Services, National Institutes of Health. From <https://www.cancer.gov/types/lung/patient/lung-screening-pdq>.
- Opitz, J., & Burst, S. (2019). *Macro F1 and macro F1*. arXiv preprint arXiv:1911.03347. From <https://doi.org/10.48550/arXiv.1911.03347>.
- Perez, L., & Wang, J. (2017). *The effectiveness of data augmentation in image classification using deep learning*. arXiv preprint arXiv:1712.04621.
- Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness & correlation. *Journal of Machine Learning Technologies*, 2(1), 37–63.
- Rana, D. J., & Rana, K. (2025). SEMLCC: A stacked ensemble model with transfer learning for high-accuracy lung cancer classification from CT images. *Procedia Computer Science*, 258(C), 2584–2596. From <https://doi.org/10.1016/j.procs.2025.04.520>.
- Raza, R., Zulfiqar, F., Khan, M. O., Arif, M., Alvi, A., Iftikhar, M. A., & Alam, T. (2024). Lung-EffNet: Lung cancer classification using EfficientNet from CT-scan images. *Engineering Applications of Artificial Intelligence*, 130, 105086. from <https://doi.org/10.1016/j.engappai.2023.106902>.
- Reddy, S. R. B. R., Sen, S., Bhatt, R., Dhanetwal, M. L., Sharma, M., & Naaz, R. (2024). Stacked neural nets for increased accuracy on classification on lung cancer. *Biomedical Signal Processing and Control*, 90, 105491. from <https://doi.org/10.1016/j.measen.2024.101052>.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 60.
- Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *International Conference on Learning Representations (ICLR)*. from <https://arxiv.org/abs/1409.1556>.
- Swain, A. K., Swetapadma, A., Rout, J. K., & Balabantaray, B. K. (2024). Classification of non-small cell lung cancer types using sparse deep neural network features. *Biomedical Signal Processing and Control*, 87, Article 105485. from <https://doi.org/10.1016/j.bspc.2023.105485>.
- Shaikh, A., Amin, S., Zeb, M. A., Sulaiman, A., & Al Reshan, M. S. (2025). *Computers in Biology and Medicine*. Advance online publication. From <https://doi.org/10.1016/j.compbiomed.2025.109703>.

Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 2818–2826). from <https://doi.org/10.1109/CVPR.2016.308>.

Tawfik, N., et al. (2024). Enhancing early detection of lung cancer through advanced image processing techniques and deep learning architectures for CT scans. *Computational Materials and Continua*, 81(1), 271–307.

Thai Health Promotion Foundation. (2024, 10 September). *Lung cancer: A risk that is close to you*. From <https://www.thaihealth.or.th/>. (in Thai)

World Health Organization. (2024, 10 September). *Cancer*. From <https://www.who.int/news-room/fact-sheets/detail/cancer>.

Wolpert, D. H. (1992). Stacked generalization. *Neural Networks*, 5(2), 241–259. From [https://doi.org/10.1016/S0893-6080\(05\)80023-1](https://doi.org/10.1016/S0893-6080(05)80023-1).