

การวินิจฉัยโรคปอดบวมจากภาพรังสีทรวงอกโดยการเรียนรู้ของเครื่อง

Diagnosis of Pneumonia on Chest Radiographs Using Machine Learning

โชคมงคล นาดิ และ กฤษดา ยิงขยัน *

Chokemongkol Nadee and Krisda Yingkayun *

Received: 29 January 2022, Revised: 14 October 2022, Accepted: 7 November 2022

บทคัดย่อ

งานวิจัยนี้ได้เสนอวิธีการในการวินิจฉัยโรคปอดบวมจากภาพถ่ายรังสีทรวงอกโดยใช้วิธีการเรียนรู้ของเครื่องหลายแบบวิธีเพื่อการวิเคราะห์โรคปอดบวม โดยโรคปอดบวมส่วนใหญ่เกิดจากการติดเชื้อทางเดินหายใจโดยเชื้อแบคทีเรียหรือไวรัสและโรคปอดบวมทำให้เกิดเชื้อหุ้มปอดอักเสบเป็นภาวะที่ของเหลวเดิมลงไปปอดทำให้หายใจลำบาก ผู้วิจัยได้พัฒนาระบบวินิจฉัยโรคปอดบวมโดยใช้คอมพิวเตอร์เข้ามาช่วยเพื่อวินิจฉัยโรคปอดบวมแบบอัตโนมัติโดยทำการออกแบบโดยออกแบบกลุ่มข้อมูลและใช้โมเดลของการเรียนรู้ของเครื่องแบบซัพพอร์ตเวกเตอร์แมชชีน (SVM) ขั้นตอนวิธีการเพื่อนบ้านใกล้ที่สุด (KNN) โครงข่ายประสาทเทียม (ANN) Adaptive Boosting (AdaBoost) และการถดถอยโลจิสติกส์ โดยวิธีการดังกล่าวนี้ได้นำเทคนิคการผูกมวลน้ำหนักมาใช้จากค่าของน้ำหนักที่มอบหมายจากข้อมูลการเรียนรู้และได้ค่าคะแนน แนวทางการประเมินแบบเมตริกซ์ มาตรฐานความแม่นยำ การเรียกคืน คะแนน F1 และพื้นที่ใต้เส้นโค้งเพื่อนำมาสร้างเป็นเวกเตอร์น้ำหนักเพื่อหาแนวทางในการเรียนรู้ กลุ่มการเรียนรู้และผลการทดสอบโดยอาศัยชุดของข้อมูลภาพถ่ายรังสีทรวงอกมาใช้ในการทดสอบ โดยแบ่งภาพของปอดปกติจำนวน 1,340 ภาพ และภาพปอดไม่ปกติจำนวน 1,704 ภาพ ใช้เป็นชุดข้อมูลสำหรับการเรียนรู้ และภาพที่ใช้ในการทดสอบอีกกลุ่มหนึ่งใช้เป็นชุดข้อมูลทดสอบ โดยแบ่งออกเป็นภาพถ่ายปอดแบบปกติจำนวน 233 ภาพและภาพถ่ายปอดแบบผิดปกติจำนวน 390 ภาพ จากการวิจัยโปรแกรมที่พัฒนาสามารถวิเคราะห์ภาพทดสอบด้วยความรวดเร็วและผลที่ได้ให้ผลการแยกแยะความถูกต้องของข้อมูลที่อยู่ในการเรียนรู้และนอกฐานการเรียนรู้ที่ 94.38 % และ 84.9 % ตามลำดับ

คำสำคัญ: การแยกแยะรูปภาพ, การเรียนรู้ของเครื่อง, โรคปอดบวม, ภาพถ่ายรังสีทรวงอก

ABSTRACT

This research proposes a method for diagnosing pneumonia on chest radiographs using a variety of machine learning methods for disease analysis. Most pneumonia is caused by a respiratory infection, such as bacteria or viruses, and pneumonia causes pleurisy, a condition in which fluid fills the lungs, making it difficult to breathe. The researchers developed a computer-aided pneumonia diagnosis system for the automatic diagnosis of pneumonia by designing a data group design and using a machine learning model: support vector machine (SVM), K-Nearest Neighbor (KNN), Artificial Neural Network (ANN), Adaptive Boosting (AdaBoost) and Logistic Regression. By this method, the weight-mass binding technique was adopted by using the values of the assigned weights from learning data, obtained scores, matrix assessment guidelines, precision standard, recall, F1 score, and area under the curve to be generated as weight vectors for learning guidance. Learning groups and test results were based on a series of chest radiographs of the dataset for experimental use. In this test, the 1,340 images of normal lungs and 1,704 images of abnormal lungs were divided into data sets for learning, and another group of images used as test data that consisted of 233 images of normal lungs and 390 images of abnormal lungs. Based on the research, the developed program was able to analyze the test images with speed and the discriminatory accuracy results yielded 94.38 percent and 84.9 percent of both base-learned and non-learned data, respectively.

Key words: classification, machine learning, pneumonia, chest radiograph

บทนำ

โรคปอดบวมหรือโรคปอดอักเสบ (Pneumonia) เป็นสาเหตุของการเสียชีวิตมากที่สุดทั่วโลก จากการติดเชื้อทางเดินหายใจแบบเฉียบพลัน (Acute respiratory infections : ARI) และเป็นสาเหตุหลักต่อการเสียชีวิตของเด็กอายุต่ำกว่า 5 ปี จากการสำรวจทั่วโลกคิดเป็น 15% ข้อมูลจากองค์การอนามัยโลก (World Health Organization, 2021) และจากสถิติผู้ป่วยโรคปอดบวมในประเทศไทย (Ministry of Public Health of Thailand, 2019; Ministry of Public Health of Thailand, 2020) จากกระทรวงสาธารณสุข มักจะพบผู้ป่วยอาการปอดบวมแล้วทำให้เสียชีวิตสองอันดับแรกอยู่ในช่วงอายุมากกว่า 65 ปี และ อายุ 0-4 ปี จากสถิติดังกล่าว ผู้วิจัยจึงมีแนวคิดในการนำเสนอเครื่องมือที่ช่วยในการวินิจฉัยโรคปอดบวม

จากภาพถ่ายรังสีทรวงอก โดยใช้วิธีการประมวลผลภาพและวิเคราะห์จากวิธีการของการเรียนรู้ของเครื่องในแบบหลายวิธีการ สามารถวินิจฉัยอาการปอดบวมเบื้องต้นได้อย่างรวดเร็ว เพื่อเป็นประโยชน์ในการรักษาผู้ป่วยได้อย่างทันทั่วถึง

การวินิจฉัยโรคปอดบวมในเด็กเล็กช่วงอายุระหว่าง 1 เดือนจนถึง 5 ปี จะอาศัยวิธีการวัดจากอัตราการหายใจของเด็ก หรือเสียงที่ได้ยินจากจากปอด Crepitation หรือ Bronchial breath sound โดยมีความไวในการวินิจฉัยปอดบวมได้ถึง 75% (Cherian *et al.*, 1988; Harari *et al.*, 1991; Smyth *et al.*, 1998) แต่ในบางกรณี เพื่อความชัดเจนของการตรวจโรคในกรณีที่มิใช่สูงแต่ไม่พบตำแหน่งของการติดเชื้อที่ชัดเจน หรือผู้ป่วยที่มีอาการรุนแรงตอบสนองต่อการรักษาไม่ดี หรือสภาวะแทรกซ้อน (Bradley *et al.*,

2011; Harris *et al.*, 2011) ต้องอาศัยวิธีการตรวจทางห้องปฏิบัติการเพิ่มเติมเพื่อใช้เป็นแนวทางในการบ่งบอกเชื้อที่เป็นสาเหตุจะเป็นสาเหตุของโรค และสามารถเลือกใช้ยาต้านได้อย่างถูกต้องเหมาะสม โดยการตรวจทางห้องปฏิบัติการสามารถแบ่งเป็นวิธีการได้ดังนี้ 1. การตรวจนับจำนวนเม็ดเลือด (Complete Blood Count : CBC) 2. การตรวจการตอบสนองในระยะเฉียบพลัน (Acute phase reactants) 3. ภาพรังสีทรวงอก 4. การตรวจหาเชื้อแบคทีเรีย 5. การตรวจหา

เชื้อ Atypical bacteria 6. การตรวจหาเชื้อไวรัส และ 7. การทดสอบทูเบอร์คิวลิน (Tuberculin test)


วิธีการตรวจวินิจฉัยโรคจากภาพรังสีทรวงอกในปัจจุบันยังไม่สามารถแยกสาเหตุจากเชื้อแบคทีเรียหรือไวรัสได้อย่างชัดเจน แต่อาจเป็นแนวทางในการบ่งบอกเชื้อที่น่าจะเป็นสาเหตุ ยกตัวอย่างเช่น Perihilar peribronchial interstitial infiltration มักพบในปอดบวมที่เกิดจากไวรัสดังภาพที่ 1



(ก) ภาพปอดปกติ



(ข) ภาพปอดที่เกิดจาก
เชื้อแบคทีเรีย



(ค) ภาพปอดที่เกิดจาก
เชื้อไวรัส

ภาพที่ 1 ภาพรังสีทรวงอก

จากการทบทวนวรรณกรรมพบว่า มิงานวิจัยที่มีความเกี่ยวข้องกับการวินิจฉัยโรคจากภาพถ่ายรังสีทรวงอกในประเทศไทย เช่น นำเอาภาพถ่ายรังสีทรวงอกมาตรวจวิเคราะห์หะเร็งปอดโดยวิธีการปัญญาประดิษฐ์ (Noisiri *et al.*, 2022) การตรวจหาโควิด-19 โดยใช้การเรียนรู้เชิงลึก (Deep Learning) (Metkarunchit and Charoenpojvajara, 2020) การถ่ายภาพเอกซเรย์คอมพิวเตอร์เพื่อวินิจฉัยโรคระบาดโควิด-19 (Saengkaew *et al.*, 2021) ซึ่งงานวิจัยในต่างประเทศที่เกี่ยวข้องได้มีการแนะนำวิธีการต่าง ๆ เพื่ออธิบายกระบวนการสั้น ๆ ในการวินิจฉัยโรคปอดบวมโดยใช้ภาพรังสีทรวงอก โดยวิธีการเรียนรู้เชิงลึกบางวิธี และการเรียนรู้ของเครื่องนั้นประสบความสำเร็จในการปรับปรุงประสิทธิภาพของเทคโนโลยีการวินิจฉัยโดยใช้คอมพิวเตอร์ช่วย

(Computer-Aided Design : CAD) ในด้านการถ่ายภาพทางการแพทย์ (Le *et al.*, 2020) การแบ่งส่วนภาพ (Sanguansat, 2019; Kubat, 2015) และการสร้างภาพใหม่ (Srikaew, 2009) ในปี 2560 Kundu *et al.* (2021) เสนอเครือข่ายการเรียนรู้เชิงลึกที่ชื่อว่า DenseNet-121 ซึ่งเป็นแบบจำลอง CNN ที่มีจำนวนชั้นถึง 121 ชั้น เพื่อใช้ในการวินิจฉัยโรคปอดบวม จากงานวิจัยของ Ronneberger *et al.* (2015); Milletari *et al.* (2016); Jeelani *et al.* (2018); Schlemper *et al.* (2017); Rajpurkar *et al.* (2017); Zhang *et al.* (2021) ได้แบ่งงานวิจัยที่ใช้ภาพถ่ายรังสีทรวงอกออกเป็น 2 กลุ่มใหญ่ กลุ่มที่ 1 คือกลุ่มที่ใช้การเรียนรู้ของเครื่องเพียงวิธีการเดียว แต่ปรับพารามิเตอร์ภายในไม่ว่าจะเป็นการวนซ้ำวิธีการให้จำนวนรอบมากขึ้นเพื่อให้ผลหรือน้ำหนักที่

เหมาะสมในการตัดสินใจ และกลุ่มที่ 2 เป็นกลุ่มที่ใช้การเรียนรู้ของเครื่องแบบหลายวิธี

การประมวลผลภาพกับรูปร่างและโครงสร้างของภาพ (Morphological Image Processing) คือ กระบวนการประมวลผลภาพโดยการเปลี่ยนแปลงลักษณะรูปร่างหรือโครงสร้างของภาพ การประมวลผลเพื่อเตรียมภาพขึ้นพื้นฐานโดยทั่วไป ได้แก่ การขยายภาพ (Dilation) การย่อภาพ (Erosion) และการหาโครงสร้างหลักของภาพ (Skeleton) โดยการขยายภาพคือ การขยายขนาดภาพโดยมีสัดส่วนเท่ากันทั่วทั้งภาพ (Uniform) การย่อภาพ คือการย่อขนาดภาพ การหาโครงสร้างหลักของภาพเป็นกระบวนการหาโครงสร้างหลักของวัตถุ นอกจากนั้นยังมีวิธีการใช้โอเพอเรชันอื่นเช่น การ Opening และ Closing


การเรียนรู้ของเครื่อง ลักษณะการเรียนรู้โดยวิธีการของการเรียนรู้ของเครื่อง สามารถแบ่งออกได้เป็น 3 กลุ่มดังนี้ 1. การเรียนรู้แบบมีผู้สอน (Supervised learning) 2. การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) และ 3. การเรียนรู้แบบการเสริมแรงใจ (Reinforcement learning) นักจิตวิทยาได้ศึกษาถึงการจดจำของมนุษย์ และพบว่า มนุษย์มีการเรียนรู้เป็นแบบไม่มีความสัมพันธ์ (Non-associative learning) และการเรียนรู้แบบมีความสัมพันธ์ (Associative learning) และความจำของมนุษย์ แบ่งออกได้เป็น ความจำระยะสั้น (Short-Term Memory: STM) และ ความจำระยะยาว (Long-Term Memory: LTM) สำหรับโครงข่ายประสาทเทียมซึ่งเป็นการจำลองสมองมนุษย์ จะต้องมีการเรียนรู้เช่นกัน การ

เรียนรู้ของโครงข่ายประสาทเทียมจำแนกออกเป็น 3 กลุ่ม ได้แก่ การเรียนรู้แบบมีผู้สอน การเรียนรู้แบบไม่มีผู้สอน และการเรียนรู้แบบการเสริมแรงใจ

ดังนั้น งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อนำเสนอการพัฒนาการตรวจวิเคราะห์ภาพเพื่อการวินิจฉัยโรคปอดบวมจากภาพถ่ายรังสีทรวงอกโดยอาศัยวิธีการเรียนรู้ของเครื่อง (Machine Learning) โดยไม่จำกัดขนาดการนำเข้าภาพถ่ายรังสีและเป็นรูปแบบภาพเป็นแบบระดับสีเทา ในงานวิจัยนี้ได้ใช้วิธีการเรียนรู้ของเครื่องแบบหลายวิธีรวมกับการปรับปรุงภาพก่อนเข้าเพื่อให้ได้ค่าที่ถูกต้องมากที่สุดโดยมีจุดประสงค์เพื่อใช้สำหรับเป็นเครื่องมือเบื้องต้นสำหรับการวินิจฉัยโรคทางทรวงอกเบื้องต้นทาง การแพทย์ เป็นแนวทางในการลดการพึ่งพาเทคโนโลยีที่นำเข้าจากต่างประเทศ และการนำวิธีการวิจัยไปใช้ประโยชน์กับโรคทางทรวงอกอื่น ๆ ยกตัวอย่างเช่น โรคโควิด-19 เป็นต้น

วิธีดำเนินการวิจัย

วิธีการตรวจทางห้องปฏิบัติการโดยการนำภาพถ่ายรังสีทรวงอกมาใช้เพื่อวิเคราะห์และตรวจโรคปอดบวม ในปัจจุบันมีความรวดเร็วในการได้มาซึ่งภาพถ่ายรังสีทรวงอก แต่การที่จะวินิจฉัยโรคให้รวดเร็ว นั้นต้องอาศัยผู้เชี่ยวชาญ ทางผู้วิจัยจึงเล็งเห็นว่าถ้าสามารถสร้างเครื่องมือเพื่อใช้ในการวินิจฉัยให้เร็วขึ้น เพื่อให้การรักษาได้อย่างรวดเร็ว ดังแสดงในภาพที่ 2



ภาพที่ 2 แผนภาพระบบการวินิจฉัยโรคปอดบวม

จากภาพที่ 2 สามารถอธิบายส่วนประกอบของแผนภาพโดยรวมของระบบการวินิจฉัยโรคปอดบวมโดยแบ่งออกเป็นแผนภาพของ 1. ภาพรังสีทรวงอก 2. การประมวลผลภาพก่อน 3. การแยกลักษณะเด่นของภาพ 4. การตัดสินใจ และ 5.ฐานข้อมูล โดยจะแบ่งออกเป็นขั้นตอนได้ทั้งหมด 5 ขั้นตอน สามารถอธิบายขั้นตอนอย่างละเอียดในการทำงานวิจัยทั้งหมดดังนี้

ลำดับขั้นตอนในการทำงานวิจัย

ขั้นตอนที่ 1 ส่วนรับภาพอินพุต คือการนำภาพรังสีทรวงอกของปอดปกติ และปอดที่มีลักษณะเป็นโรคปอดบวมมาทำการเก็บข้อมูลเพื่อแบ่งกลุ่มของภาพรังสีทรวงอกที่ปกติและไม่ปกติ

ขั้นตอนที่ 2 ทำการปรับภาพก่อนเข้า เนื่องจากการรับภาพมาวิเคราะห์กลุ่มสีแบบ ขาวดำ

ภาพขาวดำต้องทำเป็นภาพเทา 256 ระดับ แล้วทำการความคมชัดโดยใช้วิธีการ Contrast Limited Adaptive Histogram Equalization (CLAHE) เป็นวิธีการปรับฮิสโตแกรมในแบบที่ปรับตัวเองได้ ดังแสดงในภาพที่ 3


ขั้นตอนที่ 3 การเตรียมข้อมูล (Data Preparation) เมื่อได้ชุดภาพถ่ายรังสีจากทรวงอกแล้วทำการกำหนด Labels ของชุดภาพรังสีทรวงอกโดยการแบ่งกลุ่มปกติ และการเป็นโรคปอดบวม โดยกำหนดชุดข้อมูลในการเรียนรู้อยู่ที่ 1,340 ภาพของภาพปอดปกติ และ 1,704 ภาพของภาพปอดที่ผิดปกติ และชุดของการทดสอบ 233 ภาพ ในแบบนอกฐานข้อมูลในแบบปอดปกติ และ 390 ภาพของภาพปอดที่ผิดปกติ



(ก)

(ข)

ภาพที่ 3 วิธีการ CLAHE ในการปรับความคมชัดของภาพ (ก) ภาพต้นฉบับ (ข) ภาพที่ปรับแล้ว



ภาพที่ 4 การหาค่าตัวถ่วงน้ำหนักและการตัดสินใจ

ขั้นตอนที่ 4 จากภาพที่ 4 การหาค่าตัวถ่วงน้ำหนัก (cost function) โดยวิธีการเรียนรู้ของเครื่องแต่ละแบบนั้นจะต้องหาตัวถ่วงน้ำหนักเพื่อหาการเคลื่อนที่ของชุดข้อมูลว่าไปในทิศทางใด ถ้าค่าตัวถ่วงน้ำหนัก ออกมามีค่าน้อยเกินไปก็ต้องกลับไปเข้าสู่วิธีการเรียนรู้หลายรอบ เพื่อปรับค่าให้ได้ค่าตัวถ่วงน้ำหนักที่ดีที่สุดในการนำไปใช้งาน ดังแสดงในภาพที่ 4

ขั้นตอนที่ 5 การตัดสินใจ (Decision) ขั้นตอนนี้จะเป็นการเปรียบเทียบข้อมูลที่นำมาทดสอบกับชุดข้อมูลที่ทำการเรียนรู้แล้ว จึงได้ผลลัพธ์จากการเรียนรู้ของเครื่องแบบหลายวิธีการเพื่อนำมาตัดสินใจในการพยากรณ์ว่าข้อมูลภาพรังสีทรวงอกเป็นปอดปกติหรือปอดไม่ปกติ

ตารางที่ 1 แสดงรายละเอียดของระบบที่ใช้ทดสอบ

ระบบที่ใช้งานในการทดลอง		
ระบบประมวลผล	ไมโครโพรเซสเซอร์	Intel corei7
	หน่วยความจำ	16 GB
การ์ดแสดงผล	Nvidia	1660
	หน่วยความจำ	6 GB
ระบบปฏิบัติการ	วินโดวส์ 10	
โปรแกรมในการประมวลผล	Matlab 2019b	Licensed: 40967708
ฐานข้อมูลสำหรับการเรียนรู้	ภาพปอดปกติ	1,340 ภาพ
	ภาพปอดไม่ปกติ	1,704 ภาพ
ฐานข้อมูลสำหรับการทดสอบนอกฐานการเรียนรู้	ภาพปอดปกติ	233 ภาพ
	ภาพปอดไม่ปกติ	390 ภาพ

จากตารางที่ 1 แสดงให้เห็นถึงเครื่องมือในการทดสอบระบบ และจำนวนข้อมูลของภาพถ่ายรังสีทรวงอก เพื่อใช้ในการทดลอง โดยแบ่งภาพของปอดปกติจำนวน 1,340 ภาพ และภาพปอดไม่ปกติจำนวน 1,704 ภาพ ในฐานข้อมูลในการเรียนรู้ และฐานข้อมูลสำหรับการทดสอบนอกฐานการเรียนรู้ โดยแบ่งภาพของปอดปกติจำนวน 233 ภาพ และภาพปอดไม่ปกติจำนวน 390 ภาพ

ตัวชี้วัดที่ใช้สำหรับการประเมินผล

เมตริกซ์ที่ใช้สำหรับการประเมินข้อมูลของงานวิจัยนั้นเพื่อจัดหรือลดการจัดประเภทข้อมูลที่ไม่

ถูกต้องในชุดข้อมูล ชุดข้อมูลถูกต้องที่มีค่าเป็นลบ Negative (N) และชุดข้อมูลถูกต้องที่มีค่าเป็นบวก Positive (P) เมตริกซ์ที่ใช้จะถูกกำหนดต่อไปนี้

- เมตริกซ์ความสับสน (Confusion Matrix)

คือตารางสำคัญในการวัดความสามารถของแบบจำลองในการแก้ปัญหาการจำแนกประเภท จากตารางที่ 2 นั้นการแยกถูกกำหนดให้เป็นจำนวนรวมของผลบวกจริง True Positive (TP) ผลลบจริง True Negative (TN) ผลบวกหลง False Positive (FP) และค่าลบเท็จ False Negative (FN) ที่ตัวแยกประเภทรู้จัก สามารถแสดงค่าได้ดังนี้ $P=TP + FN$ และ $N=TN+FP$ ผลการทำนายสรุปไว้ในตารางที่ 2 (Saraubon, 2020)

ตารางที่ 2 เมตริกซ์ของผลการคาดการณ์สำหรับการตรวจผลของภาพถ่ายรังสีทรวงอก

		Expected class	
		Positive Prediction	Negative Prediction
Classes	Positive	True positive (TP)	False negative (FN)
	Negative	False positive (FP)	True negative (TN)

- ความแม่นยำ (Accuracy) ถูกกำหนดเป็นสัดส่วนของตัวอย่างที่จัดประเภทอย่างถูกต้องเทียบกับจำนวนตัวอย่างทั้งหมด อัตราความแม่นยำแสดงในสมการที่ 1 (Saraubon, 2020)

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

- ผลบวกที่แท้จริง (True Positive : TP) คือผลของค่าของข้อมูลที่แยกแยะว่าเป็นข้อมูลของจริงที่อยู่ในกลุ่มข้อมูล ถูกกำหนดให้เป็นสัดส่วนของข้อมูลของภาพรังสีทรวงอกที่มีความถูกต้องในการแยกแยะอัตราผลบวกที่แท้จริงแสดงในสมการที่ 2 (Saraubon, 2020)

$$TP_{rate} = \frac{TP}{TP + FN} \quad (2)$$

- ผลลบหลง (False Negative : FN) คือ สิ่งที่ทำนายไม่ตรงกับที่เกิดขึ้นจริง คือทำนายว่าไม่จริง แต่สิ่งที่เกิดขึ้น คือ จริง อัตราผลลบหลงแสดงในสมการที่ 3 (Saraubon, 2020)

$$FN_{rate} = \frac{FN}{TP + FN} \quad (3)$$

- ผลบวกหลง (False Positive : FP) สิ่งที่ทำนายไม่ตรงกับสิ่งที่เกิดขึ้น คือทำนายว่า จริง แต่สิ่งที่เกิดขึ้น คือ ไม่จริง อัตราผลบวกหลงแสดงในสมการที่ 4 (Saraubon, 2020)

$$FP_{rate} = \frac{FP}{FP + TN} \quad (4)$$

- ผลลบที่แท้จริง (True Negative : TN) สิ่งที่ทำนายตรงกับสิ่งที่เกิดขึ้น ในกรณี ทำนายว่า ไม่จริง และสิ่งที่เกิดขึ้น ก็คือ ไม่จริง อัตราผลลบที่แท้จริง แสดงในสมการที่ 5 (Saraubon, 2020)

$$TN_{rate} = \frac{TN}{TN + FP} \quad (5)$$

- การเรียกคืน (Recall) ถูกกำหนดให้เป็นสัดส่วนของตัวอย่างข้อมูลที่ระบุอย่างถูกต้องโดยตัวแยกประเภทว่ามีความเกี่ยวข้องหารด้วยจำนวนรวมของผลบวกที่แท้จริงและค่าลบเท็จ แสดงไว้ในสมการที่ 6 (Saraubon, 2020)

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

- $F_{Measure}$ ถูกกำหนดให้เป็นค่าเฉลี่ยฮาร์โมนิกของความแม่นยำและการเรียกคืน แสดงไว้ในสมการที่ 7 (Saraubon, 2020)

$$F_{Measure} = \frac{2 * Precision * Recall}{Precision + Recall} \quad (7)$$


- G_{Mean} ค่าเฉลี่ยเรขาคณิตคือกำลังสองของค่าลบและการเรียกคืนที่แท้จริง แสดงในสมการที่ 8 (Saraubon, 2020)

$$G_{Mean} = \sqrt{\frac{TP}{TP + FN} * \frac{TN}{TN + FP}} \quad (8)$$

ผลการวิจัยและวิจารณ์ผล

ผลการทดลองและการแบ่งตัวอย่าง

การทดลองในงานวิจัยนี้ได้ใช้รูปภาพถ่ายรังสีทรวงอกของคนไข้โดยใช้ฐานข้อมูล Chest X-ray (Kermay et al., 2018) โดยแบ่งออกเป็นภาพของปอดปกติจำนวน 1,340 ภาพและภาพปอดที่ไม่ปกติ 1,704 ภาพโดยใช้องค์ประกอบด้วยภาพขาวดำ 256 ระดับ การทดลองเริ่มด้วยการนำภาพอินพุตที่เป็นภาพปอด นำมาทำการสอนโดยวิธีการเรียนรู้ของเครื่อง โดยงานวิจัยของ Schlemper et al. (2017); Zhang et al. (2021) ได้เสนอการใช้วิธีการของคอนโวลูชันแบบโครงข่ายใยประสาทสำหรับภาพถ่ายรังสีทรวงอก และงานวิจัยของ Kundu et al. (2021) เสนอวิธีการของเครือข่ายการเรียนรู้เชิงลึกที่ชื่อว่า DenseNet-121 ร่วมกับวิธี McNemar's และ ANOVA ในการหาความถูกต้องของอาการปอดบวมจากภาพถ่ายรังสีทรวงอก สำหรับงานวิจัยนี้ผู้แต่งเสนอการเรียนรู้ของเครื่องแบบหลายวิธีการได้แก่ 1.KNN 2. SVM 3. Neural Network 4. การวิเคราะห์การถดถอยโลจิสติก 5. AdaBoost โดยใช้วิธีการนำภาพมาคำนวณหาเวกเตอร์น้ำหนักด้วยกระบวนการของการเรียนรู้ของเครื่อง




กลุ่มเพศชาย

กลุ่มเพศหญิง

กลุ่มเด็กเล็ก

ภาพที่ 5 ภาพถ่ายรังสีทรวงอกที่มีลักษณะของปอดปกติ



กลุ่มเพศชาย

กลุ่มเพศหญิง


กลุ่มเด็กเล็ก

ภาพที่ 6 ตัวอย่างภาพถ่ายรังสีทรวงอกที่มีลักษณะของปอดไม่ปกติ

จากภาพที่ 5 เป็นภาพถ่ายรังสีทรวงอกที่มีลักษณะของปอดปกติ โดยจะแบ่งกลุ่มของผู้ชาย ผู้หญิง และเด็กเล็ก โดยลักษณะของโครงสร้างปอด เมื่อผ่านการถ่ายภาพรังสีมาแล้วจะเห็นในส่วนของ รูปร่างของปอดได้ชัดเจนตามที่ได้แสดงกรอบไว้

จากภาพที่ 6 เป็นภาพถ่ายรังสีทรวงอกที่มีลักษณะของปอดไม่ปกติ โดยจะแบ่งกลุ่มของผู้ชาย


ผู้หญิง และเด็กเล็ก โดยลักษณะของโครงสร้างปอด เมื่อผ่านการถ่ายภาพรังสีมาแล้วจะเห็นในส่วนของ รูปร่างของปอดและแสดงฝ้าขาวจาง ๆ ในบริเวณ ปอด (ลูกศรสีแดง) ซึ่งเป็นไปได้ว่าอาจเกิดจากสภาวะ ปอดอักเสบ



ภาพที่ 7 แผนภาพแสดงการแปรผันร่วมของตัวแปรสองตัวของข้อมูลที่ใช้ในการเรียนรู้

จากภาพที่ 7 เป็นกลุ่มของข้อมูลค่าสัมประสิทธิ์สหสัมพันธ์ของภาพถ่ายรังสีทรวงอกที่มีลักษณะของปอดปกติและ ไม่ปกติ โดยหาความสัมพันธ์ของข้อมูลเชิงปริมาณหรือตัวแปรแบบต่อเนื่องสัมประสิทธิ์สหสัมพันธ์เพียร์สัน โดยเขียนแทนด้วยตัวแปร r โดยค่า r มีค่าเท่ากับ 0.88 เป็นกลุ่มของภาพถ่ายรังสีทรวงอกที่มีลักษณะของปอดปกติ จะแทนในวงรีสีแดง ส่วนค่า r มีค่าเท่ากับ 0.80 เป็นกลุ่มของภาพถ่ายรังสีทรวงอกที่มีลักษณะของปอดไม่ปกติจะแทนในวงรีสีฟ้า จากการ


คำนวณหาค่าสัมประสิทธิ์สหสัมพันธ์ของข้อมูลทั้งสองกลุ่มทำให้ทราบว่าข้อมูลทั้งสองมีความสัมพันธ์เชิงบวกและมีความสัมพันธ์มาก ซึ่งทำให้ทราบว่าข้อมูลของภาพถ่ายรังสีทรวงอกที่มีลักษณะของปอดปกติมีจำนวนมากกว่าจำนวนของภาพถ่ายรังสีทรวงอกที่มีลักษณะของปอดไม่ปกติถ้าต้องการให้ข้อมูลมีความสัมพันธ์กันยิ่งขึ้นควรทำข้อมูลทั้งสองกลุ่มให้มีความใกล้เคียงกันและยังมีข้อมูลยิ่งมากยิ่งจะได้ผลความน่าเชื่อถือสูง



ภาพที่ 8 แผนภาพแสดงการแปรผันร่วมของตัวแปรสองตัวของข้อมูล นอกฐานข้อมูลที่ใช้ในการทดสอบ

จากภาพที่ 8 เป็นกลุ่มของข้อมูลค่าสัมประสิทธิ์สหสัมพันธ์ของภาพถ่ายรังสีทรวงอกที่มีลักษณะของปอดปกติและ ไม่ปกติที่อยู่บนฐานการเรียนรู้ของระบบ โดยหาความสัมพันธ์ของข้อมูลเชิงปริมาณ หรือตัวแปรแบบต่อเนื่องสัมประสิทธิ์สหสัมพันธ์เพียร์สัน โดยค่า r มีค่าเท่ากับ 0.88 ทั้งสองกลุ่มโดยกลุ่มลูกศรสีแดงคือภาพถ่ายรังสีทรวงอกที่มีลักษณะของปอดปกติและ ลูกศรสีฟ้าคือ

ภาพถ่ายรังสีทรวงอกที่มีลักษณะของปอดไม่ปกติจากการคำนวณค่าสัมประสิทธิ์สหสัมพันธ์ของข้อมูลทั้งสองกลุ่มทำให้ทราบว่าจำนวนของข้อมูลของปอดปกติมีลักษณะมีการกระจายตัวเป็นกลุ่มส่วนปอดที่ไม่ปกติมีการกระจายตัวค่อนข้างมากเนื่องจากชุดข้อมูลนอกฐานนั้นมีจำนวนค่อนข้างน้อยเมื่อเทียบกับภาพถ่ายรังสีทรวงอกที่ใช้ในการเรียนรู้



ภาพที่ 9 ผล Confusion Matrix ของการแยกแยะจากกลุ่มตัวอย่างที่อยู่ในกลุ่มการเรียนรู้

ขั้นตอนในการได้ผลทดลองจะแบ่งการทดลองออกเป็น 2 แบบ แบบที่ 1 เป็นการโมเดลการเรียนรู้ของเครื่องโดยการใช้ข้อมูลจากฐานข้อมูลในระบบดังแสดงในภาพที่ 9 และแบบที่ 2 เป็นการนำโมเดลการเรียนรู้ของเครื่องมาทำการทดสอบกับข้อมูลนอกฐานดังแสดงในภาพที่ 10

จากผลการทดลองพบว่าโมเดลการเรียนรู้ของเครื่องด้วยวิธีการวิเคราะห์การถดถอยโลจิสติก จากรูปที่ 9 (ก) การทำนายภาพถ่ายรังสีทรวงอกปอดปกติได้ถูกต้องจำนวน 1,645 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดไม่ปกติได้ถูกต้องจำนวน 1,285 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดไม่ปกติแต่ความจริงเป็นปอดปกติจำนวน 54 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดปกติแต่ความจริงเป็นไม่ปอดปกติจำนวน 59 ภาพ ซึ่งได้ค่าความถูกต้องทั้งหมด 91 %

ผลการทดลองพบว่าโมเดลการเรียนรู้ของเครื่องด้วยวิธีการ Neural Network จากรูปที่ 9 (ข) การทำนายภาพถ่ายรังสีทรวงอกปอดปกติได้ถูกต้องจำนวน 1,639 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดไม่ปกติได้ถูกต้องจำนวน 1,294 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดไม่ปกติแต่ความจริงเป็นปอดปกติจำนวน 45 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดปกติแต่ความจริงเป็นไม่ปอดปกติจำนวน 65 ภาพ ซึ่งได้ค่าความถูกต้องทั้งหมด 97.3 %

ผลการทดลองพบว่าโมเดลการเรียนรู้ของเครื่องด้วยวิธีการ KNN จากรูปที่ 9 (ค) การทำนาย

ภาพถ่ายรังสีทรวงอกปอดปกติได้ถูกต้องจำนวน 1,398 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดไม่ปกติได้ถูกต้องจำนวน 1,314 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดไม่ปกติแต่ความจริงเป็นปอดปกติจำนวน 25 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดปกติแต่ความจริงเป็นไม่ปอดปกติจำนวน 306 ภาพ ซึ่งได้ค่าความถูกต้องทั้งหมด 98.2 %

ผลการทดลองพบว่าโมเดลการเรียนรู้ของเครื่องด้วยวิธีการ SVM จากรูปที่ 9 (ง) การทำนายภาพถ่ายรังสีทรวงอกปอดปกติได้ถูกต้องจำนวน 1,614 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดไม่ปกติได้ถูกต้องจำนวน 1,221 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดไม่ปกติแต่ความจริงเป็นปอดปกติจำนวน 118 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดปกติแต่ความจริงเป็นไม่ปอดปกติจำนวน 90 ภาพ ซึ่งได้ค่าความถูกต้องทั้งหมด 93.2 %

ผลการทดลองพบว่าโมเดลการเรียนรู้ของเครื่องด้วยวิธีการ AdaBoost จากรูปที่ 9 (จ) การทำนายภาพถ่ายรังสีทรวงอกปอดปกติได้ถูกต้องจำนวน 1,477 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดไม่ปกติได้ถูกต้องจำนวน 1,107 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดไม่ปกติแต่ความจริงเป็นปอดปกติจำนวน 232 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปอดปกติแต่ความจริงเป็นไม่ปอดปกติจำนวน 227 ภาพ ซึ่งได้ค่าความถูกต้องทั้งหมด 86.4 %

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	155	78	233
	Pneumonia	11	379	390
Σ		166	457	623

(a) Number of instances

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	93.4 %	17.1 %	233
	Pneumonia	6.6 %	82.9 %	390
Σ		166	457	623

(b) Proportion of predicted

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	66.5 %	33.5 %	233
	Pneumonia	2.8 %	97.2 %	390
Σ		166	457	623

(c) Proportion of actual

(f) Logistic Regression

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	156	77	233
	Pneumonia	13	377	390
Σ		169	454	623

(a) Number of instances

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	92.3 %	17.0 %	233
	Pneumonia	7.7 %	83.0 %	390
Σ		169	454	623

(b) Proportion of predicted

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	67.0 %	33.0 %	233
	Pneumonia	3.3 %	96.7 %	390
Σ		169	454	623

(c) Proportion of actual

(g) Neural Network

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	188	45	233
	Pneumonia	57	333	390
Σ		245	378	623

(a) Number of instances

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	76.7 %	11.9 %	233
	Pneumonia	23.3 %	88.1 %	390
Σ		245	378	623

(b) Proportion of predicted

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	80.7 %	19.3 %	233
	Pneumonia	14.6 %	85.4 %	390
Σ		245	378	623

(c) Proportion of actual

(h) kNN

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	204	29	233
	Pneumonia	55	335	390
Σ		259	364	623

(a) Number of instances

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	78.8 %	8.0 %	233
	Pneumonia	21.2 %	92.0 %	390
Σ		259	364	623

(b) Proportion of predicted

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	87.6 %	12.4 %	233
	Pneumonia	14.1 %	85.9 %	390
Σ		259	364	623

(c) Proportion of actual

(i) SVM

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	140	93	233
	Pneumonia	51	339	390
Σ		191	432	623

(a) Number of instances

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	73.3 %	21.5 %	233
	Pneumonia	26.7 %	78.5 %	390
Σ		191	432	623

(b) Proportion of predicted

		Predicted		Σ
		Normal	Pneumonia	
Actual	Normal	60.1 %	39.9 %	233
	Pneumonia	13.1 %	86.9 %	390
Σ		191	432	623

(c) Proportion of actual

(j) AdaBoost

ภาพที่ 10 ผล Confusion Matrix ของการแยกแยะจากกลุ่มตัวอย่างที่ไม่อยู่ในกลุ่มการเรียนรู้

ในส่วนของผลการทดลองนอกกลุ่มฐานข้อมูลพบว่าโมเดลการเรียนรู้ของเครื่องด้วยวิธีการวิเคราะห์การถดถอยโลจิสติก จากรูปที่ 10 (ก) การทำนายภาพถ่ายรังสีทรวงอกปกติได้ถูกต้องจำนวน 379 ภาพ ทำนายภาพถ่ายรังสีทรวงอกผิดปกติได้ถูกต้องจำนวน 155 ภาพ

ทำนายภาพถ่ายรังสีทรวงอกผิดปกติได้ถูกต้องจำนวน 78 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปกติได้ถูกต้องจำนวน 11 ภาพ ซึ่งได้ค่าความถูกต้องทั้งหมด 82.9 %

ผลการทดลองนอกกลุ่มฐานข้อมูลพบว่า โมเดลการเรียนรู้ของเครื่องด้วยวิธีการ Neural Network จากรูปที่ 10 (ข) การทำนายภาพถ่ายรังสีทรวงอกผิดปกติได้ถูกต้องจำนวน 377 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปกติไม่ผิดปกติได้ถูกต้องจำนวน 156 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปกติไม่ผิดปกติแต่ความจริงเป็นปกติจำนวน 77 ภาพ ทำนายภาพถ่ายรังสีทรวงอกผิดปกติแต่ความจริงเป็นไม่ปกติจำนวน 13 ภาพ ซึ่งได้ค่าความถูกต้องทั้งหมด 83.0 %

ผลการทดลองนอกกลุ่มฐานข้อมูลพบว่า โมเดลการเรียนรู้ของเครื่องสามารถจำแนกด้วยวิธีการ KNN จากรูปที่ 10 (ค) การทำนายภาพถ่ายรังสีทรวงอกผิดปกติได้ถูกต้องจำนวน 333 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปกติไม่ผิดปกติได้ถูกต้องจำนวน 188 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปกติไม่ปกติแต่ความจริงเป็นปกติจำนวน 45 ภาพ ทำนายภาพถ่ายรังสีทรวงอกผิดปกติแต่ความจริงเป็นไม่ปกติจำนวน 57 ภาพ ซึ่งได้ค่าความถูกต้องทั้งหมด 88.1 %

ผลการทดลองนอกกลุ่มฐานข้อมูลพบว่า โมเดลการเรียนรู้ของเครื่องสามารถจำแนกด้วยวิธีการ SVM จากรูปที่ 10 (ง) การทำนายภาพถ่ายรังสีทรวงอกผิดปกติได้ถูกต้องจำนวน 335 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปกติไม่ผิดปกติได้ถูกต้องจำนวน 204 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปกติไม่ปกติแต่ความจริงเป็นปกติจำนวน 29 ภาพ ทำนายภาพถ่ายรังสีทรวงอกผิดปกติแต่ความจริงเป็นไม่ปกติจำนวน 55 ภาพ ซึ่งได้ค่าความถูกต้องทั้งหมด 92.0 %

ผลการทดลองนอกกลุ่มฐานข้อมูลพบว่า โมเดลการเรียนรู้ของเครื่องสามารถจำแนกด้วยวิธีการ AdaBoost จากรูปที่ 10 (จ) การทำนายภาพถ่ายรังสีทรวงอกผิดปกติได้ถูกต้องจำนวน 339 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปกติไม่ผิดปกติได้ถูกต้องจำนวน 140 ภาพ ทำนายภาพถ่ายรังสีทรวงอกปกติไม่ปกติแต่ความจริงเป็นปกติจำนวน 93 ภาพ ทำนายภาพถ่ายรังสีทรวงอกผิดปกติแต่ความจริงเป็นไม่ปกติจำนวน 51 ภาพ ซึ่งได้ค่าความถูกต้องทั้งหมด 78.5 %


ตารางที่ 3 ตารางเปรียบเทียบผลการทดลองของโมเดลการเรียนรู้ของเครื่อง โดยวิธีการของ 1.KNN 2. SVM 3. Neural Network 4. การวิเคราะห์การถดถอยโลจิสติก 5. AdaBoost

ความแม่นยำ	KNN	SVM	Neural Network	การวิเคราะห์การถดถอยโลจิสติก	AdaBoost	การเรียนรู้เชิงลึก	ผลรวมเฉลี่ย
ความแม่นยำของโมเดลการเรียนรู้(ที่นำเสนอ)จากฐานข้อมูล	98.2%	93.2%	97.3%	96.8%	86.4%	-	94.38%
ความแม่นยำของโมเดลการเรียนรู้(ที่นำเสนอ)นอกฐานข้อมูล	88.1%	92.0%	83.0%	82.9%	78.5%	-	84.9%
Zhang <i>et al.</i> (2021)	-	-	90.5%	-	-	-	90.5%
Kermany <i>et al.</i> (2018)	-	-	92.8%	-	-	-	92.8%
Kundu <i>et al.</i> (2021) ที่ฐานข้อมูลเดียวกัน	-	-	-	-	-	86.86%	86.86%

ตารางที่ 3 สรุปผลความถูกต้องของโมเดลการเรียนรู้ของเครื่อง 1. โดยวิธีการของ KNN ในส่วนของทดลองจากฐานข้อมูลนั้นได้ผลความถูกต้องอยู่ที่ 98.2% และนอกฐานได้เท่ากับ 88.1% 2. โดยวิธีการของ SVM ในส่วนของทดลองจากฐานข้อมูลนั้นได้ผลความถูกต้องอยู่ที่ 93.2% และนอกฐานได้เท่ากับ 92.0% 3. โดยวิธีการของ Neural Network ในส่วนของทดลองจากฐานข้อมูลนั้นได้ผลความถูกต้องอยู่ที่ 97.3% และนอกฐานได้เท่ากับ 83% 4. โดยวิธีการวิเคราะห์การถดถอยโลจิสติกในส่วนของทดลองจากฐานข้อมูลนั้นได้ผลความถูกต้องอยู่ที่ 96.8% และนอกฐานได้เท่ากับ 82.9 % และ 5. โดยวิธีการของ AdaBoost ในส่วนของทดลองจาก

ฐานข้อมูลนั้นได้ผลความถูกต้องอยู่ที่ 86.4% และนอกฐานได้เท่ากับ 78.5% ความถูกต้องโดยเฉลี่ยของวิธีการที่นำเสนอในส่วนของข้อมูลในฐานมีความถูกต้องอยู่ที่ 94.38% และนอกฐานอยู่ที่ 84.9%

จากการทดสอบและวิเคราะห์ระบบทำให้ทราบข้อผิดพลาดที่เกิดขึ้นในช่วง 7-8 เปอร์เซ็นต์ โดยข้อผิดพลาดที่เกิดขึ้นที่ทำให้ผลของการตรวจรู้นั้นให้ผลที่ผิดพลาด เกิดจากสาเหตุ 2 สาเหตุ 1. เกิดจากการบดบังของภาพถ่ายรังสีทรวงอกจากอุปกรณ์ทางการแพทย์ โดยแสดงในภาพที่ 11 และ 2. ช่วงระยะเวลาการถ่ายภาพกับอาการของโรคยังเป็นช่วงต้นอยู่ทำให้ตอบเป็นอาการปกติ



ภาพที่ 11 ภาพการเกิดจากการบดบังของภาพถ่ายรังสีทรวงอกจากอุปกรณ์ทางการแพทย์

สรุป

งานวิจัยนี้ได้แนะนำการสร้างเครื่องมือเพื่อใช้ในการวินิจฉัยโรคปอดบวม โดยการใช้ภาพถ่ายรังสีทรวงอก โดยการวิเคราะห์จากวิธีการเรียนรู้ของเครื่องแบบหลายวิธีการ โดยระบบที่นำเสนอนี้ได้ตั้งสมมติฐานที่ว่า ภาพรังสีทรวงอกเป็นลักษณะข้อมูลคุณลักษณะภาพที่มีเป็นเอกลักษณ์ ซึ่งระบบที่ได้แนะนำการวิเคราะห์ภาพรังสีทรวงอกโดยใช้การเรียนรู้ของเครื่องโดยสรุปการแยกแยะสามารถทำได้ถูกต้องเฉลี่ย 94.38 % ในส่วนของข้อมูลในฐานการเรียนรู้ และ 84.9 % ในส่วนของข้อมูลนอกฐานข้อมูลความถูกต้องโดยรวมการเรียนรู้ของเครื่องแบบหลายวิธีสำหรับงานวิจัยในแนวทางสำหรับงานวิจัยใน

อนาคตอันใกล้จะมุ่งเน้นความถูกต้องในการประมวลผลให้มีความถูกต้องมากขึ้นเพื่อวินิจฉัยโรคปอดบวม หรือโรคเกี่ยวกับปอด หรือโรคโควิด-19

ข้อเสนอแนะ

ในการทดลองทำให้ทราบว่าการทำงานวิจัยในอนาคตเพื่อลดความผิดพลาดในการตรวจวัดในการแยกแยะระหว่างเป็นหรือไม่เป็นปอดบวม ต้องใช้วิธีการลดสัดส่วนของรูปถ่ายรังสีทรวงอกลง โดยวิเคราะห์ส่วนย่อยของบริเวณเฉพาะปอดเพียงอย่างเดียว

กิตติกรรมประกาศ

งานวิจัยนี้ได้รับการสนับสนุนจากคณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลล้านนา จังหวัดเชียงใหม่ และขอบคุณสาขาวิศวกรรมไฟฟ้า มหาวิทยาลัยเทคโนโลยีราชมงคลล้านนา ที่อำนวยความสะดวกสำหรับสถานที่ทำงาน วิจัยนี้จนสำเร็จลุล่วงไปด้วยดี

เอกสารอ้างอิง

- Bradley, J.S., Byington, C.L., Shah, S.S., Alverson, B., Carter, E.R., Harrison, C., Kaplan, S.L., Mace, S. E. , McCracken, G. H. , Moore, M.R., St Peter, S.D., Stockwell, J.A. and Swanson, J.T. 2011. The management of community-acquired pneumonia in infants and children older than 3 months of age: clinical practice guidelines by the Pediatric Infectious Diseases Society and the Infectious Diseases Society of America. **Clinical Infectious Diseases** 53: e25-76.
- Cherian, T., John, T.J., Simoes, E., Steinhoff, M.C. and John, M. 1988. Evaluation of simple clinical signs for the diagnosis of acute lower respiratory tract infection. **The Lancet** 332(8603): 125-128.
- SChlemper, J., Caballero, J., Hajnal, J.V., Price, A. and Rueckert, D. 2017. A Deep cascade of convolutional neural networks for dynamic MR image reconstruction. **IEEE Transactions on Medical Imaging** 37: 491-503.
- Harari, M., Shann, F., Spooner, V., Meisner, S., Carney, M. and De Campo, J. 1991. Clinical signs of pneumonia in children. **The Lancet** 338(8772): 928-930.
- Harris, M., Clark, J., Coote, N., Fletcher, P., Hamden, A., McKean, M. and Thomson, A. 2011. British Thoracic Society guidelines for the management of community acquired pneumonia in children: update 2011. **Thorax** 66(Suppl. 2): ii1-23.
- Jeelani, H., Martin, J., Vasquez, F., Salerno, M. and Weller, D. 2018. Image quality affects deep learning reconstruction of MRI, pp. 357-360. **In 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)**. IEEE, Washington, D.C., United States.
- Kermay, D., Zhang, K. and Goldbaum, M. 2018. **Labeled Optical Coherence Tomography (OCT) and Chest X-Ray Images for Classification**. Physics. Available Source: <https://doi:10.17632/rscbjbr9sj.2>, January 6, 2018.
- Kubat, M. 2015. A Simple Machine-Learning Task, pp. 1-18. **In** Kubat, M., ed. **An Introduction to Machine Learning**. Springer, Coral Gable.
- Kundu, R., Das, R., Geem, Z.W., Han, G.T. and Sarkar R. 2021. Pneumonia detection in chest X-ray images using an ensemble of deep learning models. **PLoS One** 16(9): 1-29.
- Le, W.T., Maleki, F., Romero, F.P., Forghani, R. and Kadoury, S. 2020. Overview of Machine Learning: Part 2: Deep Learning for Medical Image Analysis. **Neuroimaging Clin N Am** 30: 417-431.
- Metkarunchit, T. and Charoenpojvajan, K. 2020. Detection of COVID-19 using Deep Learning

- with CT Scan Images. **Journal of Engineering and Digital Technology (JEDT)** 8(2): 8-17. (in Thai)
- Milletari, F., Navab, N. and Ahmadi, S.A. 2016. *V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation*, pp. 565-571. **In Proceedings of the 2016 Fourth International Conference on 3D Vision (3DV)**. California, United States.
- Ministry of Public Health of Thailand. 2019. **Pneumonia in Thailand report 2019**. Available Source: http://www.boe.moph.go.th/boedb/surdata/506wk/y62/d31_5362.pdf, February 1, 2022. (in Thai)
- Ministry of Public Health of Thailand. 2020. **Pneumonia in Thailand report 2020**. Available Source: http://www.boe.moph.go.th/boedb/surdata/506wk/y63/d31_5263.pdf, February 1, 2022. (in Thai)
- Noisiri, W., Vijitrsaguan, C., Lertrojpanya, S., Jiamjit, K., Chayjaroon, J. and Tantibundhit, C. 2022. Sensitivity and Specificity of Artificial Intelligence for Chest Diagnostic Radiology. **Journal of the Department of Medical Services** 45(4): 55-61.
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Langlotz, C., Shpanskaya, K., Lungren, M.P. and Ng, A.Y. 2017. **CheXnet: Radiologist-level pneumonia detection on chest x-rays with deep learning**. arXiv. Available Source: <https://doi.org/10.48550/arXiv.1711.05225>, September 1, 2022.
- Ronneberger, O., Fischer, P. and Brox, T. 2015. *U-net: Convolutional networks for biomedical image segmentation*, pp. 234-241. **In Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015**. Munich, Germany.
- Saengkaew, P., Lohvithee, M. and Sanghangthum, T. 2021. Computed Tomography for the Diagnosis of COVID-19. **Thai Journal of Physics** 37(2): 45-59.
- Sanguansat, P. 2019. **Artificial Intelligence with Machine Learning, AI Built with Machine Learning**. IDC Premier, Nonthaburi. (in Thai)
- Saraubon, K. 2020. **Learning Data Science and AI: Machine Learning with Python**. Media Network, Bangkok. (in Thai)
- Smyth, A., Carty, H. and Hart, C.A. 1998. Clinical predictors of hypoxaemia in children with pneumonia. **Annals of Tropical Paediatrics** 18(1): 31-40.
- Srikaew, A. 2009. **Research Report on Computational Intelligence**. Teaching Publications Electrical Engineering. Suranaree University of Technology, Nakhon Ratchasima. (in Thai)
- World Health Organization. 2021. **Pneumonia statistics worldwide 2021**. Available Source: <https://www.who.int/news-room/fact-sheets/detail/pneumonia>, February 1, 2022.
- Zhang, D., Ren, F., Li, Y., Na, L. and Ma, Y. 2021. Pneumonia Detection from Chest X-ray Images Based on Convolutional Neural Network. **Electronics** 10(3): 1512.