

การจำแนกความผิดปกติของเล็บด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน

Classification of Nail Abnormalities using Convolutional Neural Network

ณัฐธิดา ลาภธนชัย¹, อาทิตยา ชมทอง¹, สัจจาภรณ์ ไวจรรย์^{2,*}, ณัฐโชติ พรหมฤทธิ์^{2,*}
Nuttida Lapthanachai¹, Arthitaya Chomthong¹, Sajjaporn Waijanya^{2,*}, Nuttachot Promrit^{2,*}

¹ สาขาวิชาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากร นครปฐม 73000 ประเทศไทย

² ศูนย์เชี่ยวชาญปัญญาประดิษฐ์และภาษารธรรมชาติ ภาควิชาคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากร นครปฐม 73000 ประเทศไทย

¹ Data Science Program, Faculty of Science, Silpakorn University

² Center of Excellence in AI and NLP, Department of Computing, Faculty of Science, Silpakorn University, Nakhon Pathom 73000, Thailand

* Corresponding Author: Sajjaporn Waijanya, Nuttachot Promrit, {waijanya_s, promrit_n}@silpakorn.edu

Received:

26 March 2022

Revised:

23 September 2022

Accepted:

28 September 2022

คำสำคัญ:

เล็บผิดปกติ, การจำแนกภาพ, โครงข่ายประสาทเทียม, โครงข่ายประสาทเทียมแบบคอนโวลูชัน

Keywords:

Abnormal Nails, Image Classification, Neural Network, Convolutional Neural Network

บทคัดย่อ: เล็บเป็นอวัยวะหนึ่งของร่างกาย ซึ่งลักษณะของเล็บสามารถบ่งบอกถึงสุขภาพดีหรือโรคร้ายที่เกิดต่อร่างกายได้ เพื่อสร้างโมเดลที่สามารถนำไปประยุกต์เป็นเครื่องมือจำแนกความผิดปกติของเล็บได้ด้วยตนเอง บทความนี้เสนอการศึกษาและวิเคราะห์การจำแนกความผิดปกติของเล็บ 7 ลักษณะ ได้แก่ 1) เล็บเป็นร่องลึกตามแนวขวาง 2) เล็บเป็นแถบสีดำ 3) นิ้วบวม 4) เล็บมีแถบขวางสีขาวสลับกับสีชมพู 5) ปลายเล็บร่น 6) เล็บเป็นสีขาวเกือบทั้งเล็บและมีแถบสีชมพูที่ปลายเล็บ และ 7) เล็บมีจุดสีขาว โดยรวบรวมข้อมูลจาก Google images จำนวน 700 ภาพ แบ่งเป็นชุดข้อมูลสำหรับฝึกฝนโมเดล ชุดข้อมูลสำหรับตรวจสอบโมเดล และชุดข้อมูลสำหรับทดสอบโมเดล คิดเป็นอัตราส่วน 64:16:20 ด้วยวิธีการสร้างโมเดลแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันที่พัฒนาจากโมเดลแบบโครงข่ายประสาทเทียม พบว่า โมเดลแบบโครงข่ายประสาทเทียมแบบคอนโวลูชัน ได้ค่าความถูกต้องอยู่ที่ 81.43% ซึ่งมีประสิทธิภาพจำแนกความผิดปกติของเล็บได้มากกว่าโมเดลแบบโครงข่ายประสาทเทียมที่ได้ค่าความถูกต้องเพียง 43.57%

Abstract: Nails are one organ which can indicate the status of a health condition through its own appearance. To create a model which can be applied as a tool for self-classifying nail abnormalities, this article presents the study and analysis on seven abnormalities of nails: 1) Beau's lines on Nails, 2) Black line on Nails, 3) Nails Clubbing, 4) Muehrcke's nails, 5) Onycholysis, 6) Terry's nail, and 7) White spots on Nails. The data is composed of seven hundred

images compiled from Google images. They are separated into training sets, validation sets, and test sets and arranged into a 64:16:20 ratio, respectively. The Convolutional Neural Network (CNN) model method was developed from the Artificial Neural Network (ANN) model. It points out that CNN achieves 81.43% accuracy, which is more efficient in classifying nail abnormalities than ANN, which only has 43.57% accuracy.

1. บทนำ

เล็บเกิดจากโปรตีนชนิดหนึ่ง เรียกว่า เคราตินอัดแน่นเป็นแผ่นแข็งติดชั้นหนังกำพร้า เล็บถือว่าเป็นเซลล์ชั้นหนังกำพร้าที่ตายแล้ว หรือเรียกว่าอวัยวะหนึ่งของร่างกาย ปกคลุมอยู่บริเวณปลายนิ้วมือและนิ้วเท้า มีหน้าที่สำคัญเพื่อป้องกันปลายประสาทและเส้นเลือดที่ปลายนิ้วที่ช่วยในการควบคุมการทำงานของนิ้ว (ชนิดา ฉันทวนิชย์, 2558) นอกจากนี้ลักษณะของเล็บสามารถบ่งบอกถึงสุขภาพดีหรือโรคร้ายที่เกิดขึ้นต่อร่างกายได้ด้วยเช่นกัน

บุคคลที่มีสุขภาพดี จะมีลักษณะผิวเล็บเรียบเป็นเงา เนื้อใต้เล็บเป็นสีชมพูอ่อน เนื้อเล็บมีความแข็งแรงและสามารถยืดหยุ่นได้ แต่บุคคลที่มีลักษณะเล็บผิดปกติจากที่กล่าวมา ลักษณะความผิดปกติอาจเป็นสัญญาณเตือนถึงอาการผิดปกติของร่างกายหรือโรคร้ายที่จะเกิดขึ้นได้ (Fawcett, Thomas & Daniel, 2004) เช่น เล็บมีลักษณะเป็นร่องลึกตามแนวขวางเกิดจากภาวะขาดสารอาหาร ขาดธาตุสังกะสี เล็บมีเส้นสีดำที่ได้ผิวเล็บ บ่งบอกถึงการเกิดโรคมะเร็งผิวหนังที่อันตราย เล็บโค้งไปรอบๆ เกี่ยวข้องกับโรคหัวใจ โรคปอด โรคตับ หรือโรคเอดส์ เล็บหลุดออกจากฐาน บ่งบอกถึงโรคต่อมไทรอยด์ หรือโรคสะเก็ดเงิน เล็บมีเส้นสีขาวในแนวขวาง พบในผู้ป่วยโรคไต ไตอักเสบ โรคตับหรือผู้ที่ได้รับสารหนู เล็บเป็นสีขาวแต่มีปลายเป็นสีชมพู สามารถเกิดจากโรคหัวใจล้มเหลว โรคเบาหวานหรือโรคตับ เล็บมีจุดสีขาว เกิดได้จากหลายสาเหตุ เช่น อาการแพ้ การติดเชื้อรา อาการบาดเจ็บที่เล็บ การขาดแร่ธาตุ เป็นต้น

บทความนี้เสนอการศึกษาและวิเคราะห์การจำแนกความผิดปกติของเล็บ มีวัตถุประสงค์ ดังนี้

1) เพื่อศึกษาลักษณะความผิดปกติของเล็บต่อการเกิดอาการผิดปกติหรือโรคร้ายที่เกิดขึ้นแก่ร่างกาย

2) เพื่อสร้างโมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNN) สำหรับการจำแนกลักษณะความผิดปกติของเล็บ


บทความนี้สามารถนำไปใช้เป็นแนวทางและวิธีการเบื้องต้นในการดูแลหรือตรวจสอบสุขภาพตัวเอง เพื่อทราบถึงอาการผิดปกติที่อาจจะเกิดขึ้นของร่างกายและการตัดสินใจเข้าพบแพทย์ตรวจสุขภาพร่างกายต่อไป


2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 ลักษณะความผิดปกติของเล็บ

จากการศึกษาลักษณะความผิดปกติของเล็บ (Fawcett, Thomas & Daniel, 2004) พบว่าความผิดปกติของเล็บมีลักษณะที่หลากหลาย และในแต่ละลักษณะสามารถบ่งบอกถึงสาเหตุการเกิดความผิดปกติ และอาการหรือโรคที่อาจจะเกิดขึ้นกับร่างกายได้ เพื่อแสดงให้เห็นถึงภาพลักษณะความผิดปกติของเล็บที่ชัดเจนยิ่งขึ้น แสดงดังตาราง 1

ตาราง 1 ลักษณะ สาเหตุ และอาการหรือโรคจากความผิดปกติของเล็บ

เล็บผิดปกติ	ลักษณะ	สาเหตุ	อาการ/โรค
Beau's lines on Nails 	มีร่องลึกตามแนวขวาง	การเจริญเติบโตของเล็บ ถูกขัดขวาง	ขาดสารอาหาร สังกะสี โรคปอดบวม
Black line on Nails 	มีเส้นสีดำที่ใต้ผิวเล็บ	หลอดเลือดใต้เล็บได้รับ ความเสียหาย หรือ ผลจาก การใช้ยาบางชนิด	โรคมะเร็งผิวหนัง ที่อันตราย
Nails Clubbing 	มีความโค้งลงไปรอบๆ เล็บหนาและกลม	ผลจากออกซิเจนในเลือดต่ำ	โรคหัวใจ โรคปอด โรคตับ หรือโรคเอดส์
Muehrcke's nails 	มีแถบขาวในแนวขวาง บนเล็บ	ปรากฏในบุคคลที่มีภาวะ Hypoalbuminemia หรือ ภาวะ Albumin ในเลือดต่ำ	โรคไต ไตอักเสบ โรคตับ หรือผู้ที่ร่างกาย ได้รับสารหนู
Onycholysis 	ปลายหลุดออกจากฐาน เล็บ และเปลี่ยนเป็นสีขาว	การบาดเจ็บที่เล็บ หรือ แพ้ผลิตภัณฑ์ที่เข้ากับเล็บ	อาการของโรคเชื้อรา โรคต่อมไทรอยด์ หรือ โรคสะเก็ดเงิน
Terry's nail 	เล็บเป็นสีขาวแต่มีสีชมพู แคบๆ ที่ปลายเล็บ	มาจากความชรา	โรคตับ ภาวะหัวใจ ล้มเหลว ไตวาย หรือ โรคเบาหวาน
White spots on Nails 	มีจุด หรือแถบสีขาวบนเล็บ	อาการแพ้การติดเชื้อรา อาการบาดเจ็บที่เล็บ หรือ การขาดแร่ธาตุ	เป็นปัญหาที่เกิดขึ้น โดยทั่วไปและไม่เป็น อันตราย



ภาพประกอบ 1 Data Augmentation (Brownlee, 2019)

2.2 Batch Normalization

Batch Normalization เป็นการ Scaling Data หรือ Normalization ให้อยู่ในช่วงที่กำหนด ซึ่งจะใช้ในระหว่างการฝึกฝนโมเดล ในการคำนวณ จะคำนวณจากขนาดของ Batch หรือกลุ่มของข้อมูล ที่ถูกกำหนดจำนวนไว้ ซึ่งการทำ Normalization สามารถทำได้หลายวิธี เช่น Rescaling (Min-Max Normalization), Mean Normalization และ Standardization (Z-Score Normalization) เป็นต้น (ณัฐโชติ พรหมฤทธิ์, 2564)

2.3 Drop Out

Drop Out เป็นเทคนิคของการทำ Regularity ซึ่งเป็นการสุ่มปิด Node ของ Layer นั้นชั่วคราว ในระหว่างการฝึกฝนโมเดล และสามารถช่วยลดการ เกิดปัญหา Overfitting ได้ (ณัฐโชติ พรหมฤทธิ์, 2564)

2.4 Data Augmentation

Data Augmentation เป็นการเพิ่มจำนวน ข้อมูลให้กับชุดข้อมูลฝึกฝน (train set) โดยนำรูปภาพ มาปรับเปลี่ยน เพื่อให้โมเดลเรียนรู้ได้มากขึ้น สามารถ ทำได้ในหลากหลายวิธี เช่น ย่อ ขยาย ตัดรูป หมุน หรือเลื่อนตำแหน่งภาพ เป็นต้น (ณัฐโชติ พรหมฤทธิ์, 2564) ดังภาพประกอบ 1 ทั้งนี้ การทำ Data Augmentation สามารถช่วยลดปัญหา Overfitting

ของโมเดล นั่นคือ โมเดลเรียนรู้จากชุดข้อมูลฝึกฝน ได้ดี แต่ไม่สามารถนำไปใช้กับชุดข้อมูลทดสอบได้หรือ ข้อมูลที่เป็น unseen data ได้ คือ ผลจากการวัด ประสิทธิภาพโมเดลได้ค่าความถูกต้องของชุดข้อมูล ทดสอบต่ำกว่าค่าความถูกต้องของชุดข้อมูลฝึกฝน

งานวิจัยที่นำเทคนิค Data Augmentation มาใช้งาน

1) พิมพ์ ชีวประกอบกิจ (2562) ได้ศึกษา เกี่ยวกับการปรับปรุงประสิทธิภาพในการจำแนกภาพ ด้วยโครงข่ายประสาทแบบคอนโวลูชันโดยใช้เทคนิค การเพิ่มภาพ งานวิจัยนี้มีวัตถุประสงค์เพื่อปรับปรุง ประสิทธิภาพในการจำแนกภาพด้วยโครงข่ายประสาท แบบคอนโวลูชันโดยใช้เทคนิค Data Augmentation โดยจะสุ่มใช้เทคนิคต่างๆ เช่น การปรับสีของภาพ การหมุนภาพ การย่อ เป็นต้น ใช้เทคนิคอย่างใด อย่างหนึ่งในแต่ละภาพ ผลการทดลองพบว่าการใช้ เทคนิคการเพิ่มภาพด้วยการสร้างภาพเทียมจะช่วย ให้ประสิทธิภาพในการจำแนกภาพแม่นยำสูงขึ้น จาก 84.79% เป็น 87.57%

2) ศิริชัย โชติชาติมาลา และณัฐวี ววัฒนวัฒน์ (2563) ได้ศึกษาและสร้างแบบจำลองการคัดแยกผล ไม้แบบหนึ่งชนิดด้วยการเรียนรู้ของเครื่องเพื่อตรวจจับ รูปแอปเปิ้ล จากงานวิจัยนี้ พบว่า วิธี IANET พร้อม กับการใช้ Data Augmentation ให้ค่าความถูกต้อง

98.60% ซึ่งเมื่อ เทียบกับวิธี IANET และไม่ใช่ Data Augmentation จะได้ค่าความถูกต้องเพียง 98.06%

2.5 High Boost Filtering

การใช้ Filter สำหรับการทำ Image Processing จะคล้ายกับการทำ Point Operation เป็นการปรับค่าที่อยู่ในแต่ละ Pixel โดยไม่สนใจ Pixel ที่อยู่รอบๆ เพื่อให้รูปภาพนั้นมีความสว่างหรือคมชัดมากขึ้น เป็นต้น แต่การใช้ Filter นั้น จะปรับค่าของแต่ละ Pixel โดยสนใจ Pixel อื่นที่อยู่รอบๆ Pixel นั้นด้วย ซึ่งสามารถกำหนดจำนวนของ Pixel ที่สนใจ จะนำมาคำนวณด้วยได้ จำนวน Pixel ถูกกำหนด ในรูปแบบของเมทริกซ์จัตุรัส เช่น 3x3 หรือ 5x5 เป็นต้น

High Boost Filtering (Alirezanejad, Saffari, Amirgholipour, & Sharifi, 2014) เป็นหนึ่งในหมวดหมู่ของ Filter ที่ใช้ในการปรับความคมชัดของรูปภาพ โดย High Boost Filter มีรูปแบบมาตรฐาน ดังภาพประกอบ 2

2.6 Image Classification ด้วย Convolutional Neural Network (CNN)

Image Classification เป็นการจำแนกข้อมูลที่อยู่ในรูปแบบรูปภาพ เพื่อแยกประเภทรูปภาพหรือสิ่งที่ปรากฏบนรูปภาพที่เป็นชนิดเดียวกันหรือแตกต่างกัน โดยจำแนกตามกลุ่มหรือหมวดหมู่ที่สนใจ วิธีการจำแนกประเภทของรูปภาพโดยทั่วไปมีหลายวิธี ซึ่งในการสร้างโมเดลจำแนกภาพด้วยวิธีการทาง Machine Learning สามารถทำได้ทั้งแบบ Supervised Learning และ Unsupervised Learning โดยในบทความวิจัยนี้จะพัฒนา Model แบบ Supervised Learning ด้วยเทคนิค Convolution Neural Network หรือ CNN (ณัฐโชติ พรหมฤทธิ์ และสัจจาภรณ์ ไวยรรยา, 2564) ที่เป็น Deep Learning ชนิดหนึ่ง โดย Neural Network ชนิดนี้ จะใช้ Convolution

$$Filter = \begin{bmatrix} -1 & -1 \\ -1 & -1 \\ -1 & -1 \\ -1 & -1 \end{bmatrix}$$

ภาพประกอบ 2 Image Filter

เพื่อดึงลักษณะที่เป็นประโยชน์สำหรับการทำโมเดลมาใช้งาน (อุมารณณ์ สายแสงจันทร์, รพีพร ชำของ และ อรรถพล สุวรรณษา, 2565) การทำงานในลักษณะนี้จะช่วยให้โมเดลสามารถเรียนรู้ได้ดีขึ้น

งานวิจัยที่จำแนกภาพเกี่ยวกับด้านสุขภาพ ด้วย CNN

1) ณัฐวุฒิ ศรีวิบูลย์ (2563) ได้ศึกษาเกี่ยวกับการปรับปรุงประสิทธิภาพของการจำแนกภาพเอกซเรย์ทรวงอกด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยใช้เทคนิคการเพิ่มภาพสำหรับวินิจฉัยโรคโควิด-19 เนื่องจาก CNN มีข้อจำกัดคือประสิทธิภาพการจำแนกรูปภาพขึ้นอยู่กับจำนวนรูปภาพที่นำเข้าสู่ขั้นตอนการฝึกสอน หรือ Train งานวิจัยนี้จึงมีการนำเทคนิคการเพิ่มภาพมาใช้ร่วมกับ CNN โดยจะมีการเปรียบเทียบเทคนิคการเพิ่มภาพในแต่ละวิธี เพื่อเพิ่มความถูกต้องให้กับกระบวนการฝึกสอนของ CNN ผลของการวิจัยพบว่า การหมุนภาพ ให้ประสิทธิภาพการฝึกสอนที่ 99.67%

2) วิชชุดา ธงกิ่งและคณะ (2564) ได้ศึกษาเกี่ยวกับการวิเคราะห์และการจำแนกกระดูกสันหลังที่ผิดปกติด้วยขั้นตอนวิธีโครงข่ายประสาทแบบคอนโวลูชัน โดยใช้ภาพเอกซเรย์คอมพิวเตอร์ CT (Computerized Tomography) ของกระดูกสันหลังมนุษย์ เป็นข้อมูลของผู้ป่วยที่ได้รับการสนับสนุนจากโรงพยาบาลมหาวิทยาลัยเทคโนโลยีสุรนารี นครราชสีมา ประเทศไทย โดยในขั้นตอนสุดท้ายของการวิจัย ได้มีการสร้างแบบจำลองขั้นตอนวิธีโครงข่ายแบบคอนโวลูชัน เพื่อจำแนกการจัดแนวกระดูกสันหลังของ


มนุษย์ที่ปกติและผิดปกติจากภาพที่ผ่านการประมวลผล จากผลการศึกษาพบว่าแบบจำลองที่ดีที่สุดสามารถทำงานได้ดีมากอีกทั้งยังเป็นแบบจำลองที่สามารถทำนายได้อย่างไม่มีข้อผิดพลาด ซึ่งประสิทธิภาพการวิเคราะห์และจำแนกความผิดปกติประกอบไปด้วยความแม่นยำร้อยละ 100 ความถูกต้องร้อยละ 100 และค่าเรียกคืนร้อยละ 100

3. กระบวนการออกแบบและพัฒนาโมเดล

3.1 ภาพรวมของกระบวนการ (Process Overview)

งานวิจัยนี้ใช้ภาษาโปรแกรม Python 3.8 ในกระบวนการทำงาน ดังภาพประกอบ 3 แบ่งออกเป็น 3 ส่วน ได้แก่

ส่วนที่ 1 การเก็บรวบรวมข้อมูลและเตรียมข้อมูลให้พร้อมใช้งาน



ภาพประกอบ 3 ภาพรวมของกระบวนการดำเนินงาน

ส่วนที่ 2 การแบ่งข้อมูลและสร้างโมเดล


ส่วนที่ 3 การทำนาย ประเมินและวัดประสิทธิภาพโมเดล

3.2 การรวบรวมข้อมูลและเตรียมข้อมูลให้พร้อมใช้งาน

3.2.1 ขั้นแรก Data Collection รวบรวมภาพลักษณะความผิดปกติของเล็บโดยใช้ Image Search จาก Google ทั้งหมด 7 ลักษณะ ลักษณะละ 100 ภาพ เก็บในรูปแบบไฟล์ .jpg แสดงตัวอย่างภาพลักษณะความผิดปกติของเล็บในดังภาพประกอบ 4



ภาพประกอบ 4 ตัวอย่างภาพลักษณะความผิดปกติของเล็บ



ภาพประกอบ 5 ตัวอย่างภาพเปรียบเทียบ
การใช้ Image Filtering

3.2.2 ขั้นตอน Data Preparation

ตัดส่วนขอบของภาพเพื่อให้เห็นความผิดปกติของเล็บ
ได้ชัดเจนขึ้น และปรับขนาดของภาพให้มีขนาดเท่ากัน
กำหนดความกว้าง เท่ากับ 100 Pixels และความยาว
เท่ากับ 100 Pixels เพื่อให้ขนาดไฟล์ภาพไม่ใหญ่
จนเกินไปและใช้เวลาในการฝึกฝนโมเดลน้อยลง
หลังจากนั้นนำภาพมาทำ Image Filtering ใช้ขนาด
ของเมทริกซ์เป็น 3×3 และใช้ Filter ที่เป็นมาตรฐาน
ของ High Boost Filtering ดังภาพประกอบ 2

เนื่องจากการใช้ Filter ในรูปแบบนี้จะทำให้
รูปมีความคมชัดและเห็นรายละเอียดของเล็บมากขึ้น
ซึ่งสามารถเปรียบเทียบได้ ดังภาพประกอบ 5

3.3 การแบ่งข้อมูลและการสร้างโมเดล

3.3.1 การแบ่งข้อมูล ใช้ sklearn แบ่งข้อมูล
ออกเป็น 3 ชุด ได้แก่ ชุดข้อมูลสำหรับฝึกฝนโมเดล
(Train Dataset) ชุดข้อมูลสำหรับตรวจสอบโมเดล
(Valid Dataset) และชุดข้อมูลสำหรับทดสอบโมเดล
(Test Dataset) ซึ่งผู้วิจัยจะแบ่งชุดข้อมูลฝึกฝนกับ

ชุดข้อมูลทดสอบก่อน ใช้อัตราส่วน 80:20 โดยแบ่ง
ภาพในแต่ละลักษณะ หลังจากนั้นจึงแบ่งชุดข้อมูล
ตรวจสอบจากชุดข้อมูลฝึกฝน ใช้อัตราส่วน 80:20
เช่นกัน จะได้ชุดข้อมูลทั้งหมด 3 ชุด ดังนี้ ชุดข้อมูล
สำหรับฝึกฝน 448 ภาพ ชุดข้อมูลสำหรับตรวจสอบ
112 ภาพ และชุดข้อมูลสำหรับทดสอบ 140 ภาพ
คิดเป็นอัตราส่วนทั้งหมด 64:16:20

3.3.2 การสร้างโมเดล เริ่มจากการสร้างโมเดล
โครงข่ายประสาทเทียม (ANN) เพื่อเป็น Baseline
model พัฒนาไปสู่โมเดลโครงข่ายประสาทเทียม
แบบคอนโวลูชัน (CNN) โดยนิยามโมเดล ดังนี้

1) โมเดลโครงข่ายประสาทเทียม (Artificial
Neural Network) รายละเอียดพารามิเตอร์ของโมเดล
ในตาราง 2 และสร้างโมเดลซึ่งประกอบด้วย layer
ต่างๆ ดังภาพประกอบ 6 มีรายละเอียดของแต่ละ
layer ดังต่อไปนี้


Input layer กำหนด input shape =
(90, 90, 3)

Hidden layer ใช้ ReLu activation
function


Output layer ใช้ Softmax activation
function และ กำหนด Neuron เท่ากับ 7 (จำนวน
ความผิดปกติของเล็บ) กำหนด Optimizer แบบ
Adam (Adaptive Moment Estimation) จำนวน
Epoch 1000 รอบ และขนาดของ Batch จำนวน
32 ภาพ เพื่อใช้ทำ Batch Normalization

ตาราง 2 รายละเอียดของโมเดลโครงข่ายประสาทเทียม

Layer (Type)	Output Shape	Number of Parameters
Input	(90, 90, 3)	-
Conv2D (filters=32, kernel_size=(3,3), padding='same', activation='relu')	(90, 90, 32)	896
Conv2D (filters=32, kernel_size=(3,3), padding='same', activation='relu')	(90, 90, 32)	9248
MaxPooling2D (pool_size=(5, 5))	(18, 18, 32)	0
Conv2D (filters=64, kernel_size=(3,3), padding='same', activation='relu')	(18, 18, 64)	18496
Conv2D (filters=64, kernel_size=(3,3), padding='same', activation='relu')	(18, 18, 64)	36928
MaxPooling2D (pool_size=(5, 5))	(3, 3, 64)	0
Flatten	(576)	0
Dense (activation='relu')	(256)	147712
Dense (activation='softmax')	(7)	1799



ภาพประกอบ 6 โครงสร้างของโมเดลโครงข่ายประสาทเทียม



ภาพประกอบ 7 ตัวอย่างภาพเปรียบเทียบการใช้ Image Augmentation

2) โมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network) นำชุดข้อมูลสำหรับฝึกฝน มาทำ Image Augmentation โดยกำหนดรายละเอียด ดังนี้

1. การหมุนภาพแบบสุ่ม กำหนดในช่วงไม่เกิน 0.05 องศา
2. การขยายภาพแบบสุ่ม กำหนดในช่วงไม่เกิน 30%
3. การเลื่อนภาพแนวขวางแบบสุ่ม กำหนดในช่วงไม่เกิน 10%
4. การเลื่อนภาพในแนวยาวแบบสุ่ม กำหนดในช่วงไม่เกิน 10%

5. การบิดภาพแบบสุ่ม กำหนดในช่วงไม่เกิน 0.05%

หลังจากกำหนดรายละเอียด Image Augmentation แสดงตัวอย่างในภาพประกอบ 7

ขั้นตอนต่อไปจะสร้างโมเดล โดยรายละเอียดพารามิเตอร์ของโมเดล ในตาราง 3 และสร้างโมเดลซึ่งประกอบด้วย layer ต่างๆ ดังภาพประกอบ 8 มีรายละเอียดของแต่ละ layer ดังต่อไปนี้

Input layer กำหนด input shape = (90, 90, 3)

Hidden layer ใช้ ReLU activation function กำหนดค่า Dropout เท่ากับ 0.1 และทำ Batch Normalization

Output layer ใช้ Softmax activation function และกำหนด Neuron เท่ากับ 7 (จำนวนความผิดปกติของเส้น)


กำหนด Optimizer แบบ Adam (Adaptive Moment Estimation) Learning Rate เท่ากับ 0.001 จำนวน Epoch 1000 รอบ และขนาดของ Batch จำนวน 10 ภาพ เพื่อใช้ทำ Batch Normalization

3.4 ทำนายและการประเมินโมเดล

หลังจากที่สร้างและฝึกฝนโมเดลเสร็จแล้ว จึงนำชุดข้อมูลสำหรับทดสอบมาทดสอบความถูกต้องและความแม่นยำของการทำนายของโมเดล โดยคำนวณค่า AUC ของภาพแต่ละคลาส สร้าง ROC Curve และ Confusion matrix (Nasritha *et al.*, 2018) โดยใช้การเทียบค่า True Positive

ตาราง 3 รายละเอียดของโมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชัน

Layer (Type)	Output Shape	Number of Parameters
Input	(90, 90, 3)	-
Conv2D (filters=32, kernel_size=(3,3), padding='same', activation='relu')	(90, 90, 32)	896
Batch Normalization	(90, 90, 32)	128
Dropout 10 %	(90, 90, 32)	0
Conv2D (filters=32, kernel_size=(3,3), padding='same', activation='relu')	(90, 90, 32)	9248
Batch Normalization	(90, 90, 32)	128
MaxPooling2D (pool_size=(5, 5))	(18, 18, 32)	0
Dropout 10 %	(18, 18, 32)	0
Conv2D (filters=64, kernel_size=(3,3), padding='same', activation='relu')	(18, 18, 64)	18496
Batch Normalization	(18, 18, 64)	256
Dropout 10 %	(18, 18, 64)	0
Conv2D (filters=64, kernel_size=(3,3), padding='same', activation='relu')	(18, 18, 64)	36928
Batch Normalization	(18, 18, 64)	256
MaxPooling2D (pool_size=(5, 5))	(3, 3, 64)	0
Dropout 10 %	(3, 3, 64)	0
Flatten	(576)	0
Dense (activation='relu')	(256)	147712
Batch Normalization	(256)	1024
Dropout 10 %	(256)	0
Dense (activation='softmax')	(7)	1799



ภาพประกอบ 8 โครงสร้างของโมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชัน

ตาราง 4 ตารางเทียบค่าคำนวณความถูกต้อง
และความแม่นยำ


		Actual	
		Positive	Negative
Predict	Positive	TP	FP
	Negative	FN	TN

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


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

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

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



ภาพประกอบ 9 กราฟ Training & Validation accuracy โมเดล ANN



ภาพประกอบ 10 กราฟ Training & Validation loss โมเดล ANN

(TP), False Positive (FP), False Negative (FN) และ True Negative (TN) ดังตาราง 4 จะได้ค่า Accuracy ดังสมการที่ 1, ค่า Precision ดังสมการที่ 2, ค่า Recall ดังสมการที่ 3 และ ค่า F1-score ดังสมการที่ 4 จากนั้นสร้างกราฟ Accuracy และกราฟ Loss ของชุดข้อมูลสำหรับฝึกฝนโมเดลกับชุดข้อมูลสำหรับตรวจสอบโมเดล เพื่ออธิบายวิเคราะห์ผล และประเมินโมเดล

4. ผลการดำเนินการวิจัย

การจำแนกความผิดปกติของเล็บใช้ชุดข้อมูลสำหรับฝึกฝนโมเดล 448 ภาพ ชุดข้อมูลสำหรับตรวจสอบโมเดล 112 ภาพ และชุดข้อมูลสำหรับทดสอบโมเดล 140 ภาพ ได้ผลลัพธ์การจำแนกความผิดปกติของเล็บทั้ง 2 โมเดล ดังต่อไปนี้


4.1 ผลการประเมินประสิทธิภาพการจำแนกของโมเดลโครงข่ายประสาทเทียม

กำหนดค่า epochs 1000 รอบ และ batch size เท่ากับ 32 ในการทดสอบโมเดล แสดงผลลัพธ์ที่ได้จากการสังเกตค่า Accuracy ในกราฟภาพประกอบ 9 และค่า Loss ในภาพประกอบ 10

จากการสังเกตกราฟค่า Training accuracy กับ Validation accuracy พบว่า ค่า Accuracy สำหรับชุดข้อมูลฝึกฝนโมเดลเพิ่มขึ้นอย่างต่อเนื่องในช่วงประมาณรอบที่ 1 ถึงรอบที่ 20 จากนั้นคงที่ที่ค่า Accuracy เท่ากับ 1.0 และสำหรับชุดข้อมูลตรวจสอบโมเดลค่า Accuracy เพิ่มขึ้นอย่างต่อเนื่องในช่วงประมาณรอบที่ 1 ถึงรอบที่ 20 จากนั้นค่าคงที่ที่ค่า Accuracy ประมาณ 0.5


จากการสังเกตกราฟค่า Training loss กับ Validation loss พบว่า ค่า Loss สำหรับชุดข้อมูลฝึกฝนโมเดลลดลงอย่างต่อเนื่องในช่วงประมาณรอบที่ 1 ถึงรอบที่ 20 จากนั้นค่าคงที่ที่ค่า Loss เท่ากับ 0 และสำหรับชุดข้อมูลตรวจสอบโมเดลมีแนวโน้มค่า Loss เพิ่มขึ้นอย่างต่อเนื่อง

จากกราฟแสดงค่า Accuracy และ ค่า Loss ของชุดข้อมูลสำหรับฝึกฝนโมเดลและชุดข้อมูลสำหรับตรวจสอบโมเดลสามารถประเมินโมเดล ANN พบว่า โมเดลเกิดปัญหา Overfitting หรือ โมเดลมีการเรียนรู้ที่มากเกินไปจากชุดข้อมูลสำหรับฝึกฝนโมเดล นำชุดข้อมูลทดสอบโมเดลไปทำนายผล ได้ค่าทำนายเปรียบเทียบผลเฉลย แสดงค่า AUC และ ROC Curve ในภาพประกอบ 11 และแสดง Confusion Matrix ในภาพประกอบ 12



ROC Curve and AUC


ภาพประกอบ 11 กราฟ ROC Curve & AUC แต่ละคลาสของโมเดล ANN



ภาพประกอบ 12 ค่า Confusion Matrix โมเดล ANN

ตาราง 5 Precision Recall และ F1 Score โมเดล ANN

	Precision	Recall	F1-score	Support	Accuracy
Be	0.3200	0.4000	0.3556	20	0. 4357
Bl	0.6471	0.5500	0.5946	20	
Cl	0.5882	0.5000	0.5405	20	
Mu	0.5000	0.4000	0.4444	20	
On	0.4167	0.5000	0.4545	20	
Te	0.2917	0.3500	0.3182	20	
Wh	0.4118	0.3500	0.3784	20	
Be = Beau's lines on Nails, Bl = Black line on Nails, Cl = Nail Clubbing, Mu = Muehrcke’s Nails, On = Onycholysis, Te = Terry’s Nail, Wh = White Spots on the Nails					



ภาพประกอบ 13 กราฟ Training & Validation accuracy โมเดล CNN

จากภาพประกอบ 11 พบว่าค่า AUC ของคลาส Bl หรือ Black line มีค่าสูงที่สุดเท่ากับ 0.8479 และค่า AUC ของคลาส Be หรือ Beau's line มีค่าต่ำที่สุดเท่ากับ 0.6856


จากภาพประกอบ 12 ค่า Confusion Matrix ข้างต้น เมื่อนำมาเทียบค่า คำนวณความถูกต้องและความแม่นยำ จะได้ค่า Accuracy, Precision, Recall และ F1-score ดังตาราง 5

จากตาราง 5 ได้ผลลัพธ์การจำแนกความผิดปกติของเล็บด้วยโมเดล ANN มีค่าความถูกต้องอยู่ที่


43.57% อธิบายได้ว่า โมเดลโครงข่ายประสาทเทียมไม่สามารถจำแนกความผิดปกติของเล็บทั้ง 7 ลักษณะนี้ได้

4.2 ผลการประเมินประสิทธิภาพการจำแนกของโมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชัน

กำหนดค่า epochs 1000 รอบ และ batch size เท่ากับ 10 ในการทดสอบโมเดล แสดงผลลัพธ์ที่ได้จากการสังเกตค่า Accuracy ในกราฟภาพประกอบ 13 และค่า Loss ในกราฟภาพประกอบ 14



ภาพประกอบ 14 กราฟ Training & Validation Loss โมเดล CNN



ROC Curve and AUC


ภาพประกอบ 15 กราฟ ROC Curve & AUC แต่ละคลาสของโมเดล CNN

จากการสังเกตกราฟค่า Training accuracy กับ Validation accuracy พบว่า ค่า Accuracy สำหรับชุดข้อมูลฝึกฝนโมเดลและชุดข้อมูลตรวจสอบโมเดลมีแนวโน้มเพิ่มขึ้นเรื่อยๆ ในช่วงประมาณรอบที่ 1 ถึงรอบที่ 200 หลังจากนั้นค่า Accuracy เริ่มคงที่ใกล้เคียงค่า 1.0

จากการสังเกตกราฟค่า Training loss กับ Validation loss พบว่า ค่า Loss สำหรับชุดข้อมูลฝึกฝนโมเดลและชุดข้อมูลตรวจสอบโมเดลมีแนวโน้มลดลงเรื่อยๆ ในช่วงประมาณรอบที่ 1 ถึงรอบที่ 200 จากนั้นค่า Loss เริ่มคงที่ ใกล้เคียงค่า 0

จากกราฟแสดงค่า Accuracy และ ค่า Loss ของชุดข้อมูลสำหรับฝึกฝนโมเดลและชุดข้อมูลสำหรับตรวจสอบโมเดลสามารถประเมินโมเดล CNN ได้ว่าโมเดลสามารถทำนายข้อมูลที่ไม่เคยเห็นได้อย่างมีประสิทธิภาพ นำชุดข้อมูลทดสอบโมเดลไปทำนายผลได้ค่าทำนายเปรียบเทียบผลเฉลย แสดงค่า AUC และ ROC Curve ในภาพประกอบ 15 และแสดง Confusion Matrix ในภาพประกอบ 16

จากภาพประกอบ 15 พบว่าค่า AUC ของคลาส CI หรือ Nail Clubbing มีค่าสูงที่สุดเท่ากับ 0.9975 และค่า AUC ของคลาส Be หรือ Beaux lines on Nails มีค่าต่ำที่สุดเท่ากับ 0.9483



ภาพประกอบ 16 ค่า Confusion Matrix โมเดล CNN



ภาพประกอบ 17 คลาส Be จาก Test Dataset ที่จำแนกผิด



ภาพประกอบ 18 คลาส Bl จาก Test Dataset ที่จำแนกผิด

จากภาพประกอบ 16 พบว่า คลาส On (Onycholysis) สามารถจำแนกได้ถูกมากที่สุด จำนวน 19 ภาพจากทั้งหมด 20 ภาพ รองลงมาเป็น คลาส Cl (Nail Clubbing) และ Wh (White Spots) จำแนกได้ถูกจำนวน 18 ภาพ คลาส Te (Terry's Nail) จำแนกได้ถูกจำนวน 16 ภาพ คลาส Be (Beau's lines) และ Mu (Muehrcke's Nails) จำแนกได้ถูกจำนวน 15 ภาพ และคลาส Bl (Black line) จำแนกได้ถูกน้อยที่สุด จำนวน 13 ภาพ แสดงภาพ Test Dataset ที่จำแนกผิดของแต่ละคลาส ดังภาพประกอบ 17 - 23 เพื่อตรวจสอบและทำความเข้าใจเกี่ยวกับ Dataset และโมเดลที่สร้างขึ้น

จากภาพประกอบ 17 ภาพคลาส Be จาก Test Dataset ที่จำแนกผิดเป็นคลาส Bl และ On เนื่องจากภาพเห็นร่องตามแนวขวางของเล็บไม่ชัด จำแนกผิดเป็นคลาส Wh เนื่องจากภาพแรกจะเห็นว่า มีแสงจากการถ่ายรูปสะท้อนอาจทำให้เห็นเป็นแถบสีขาว และสำหรับภาพที่สองอาจเกิดจากการ Label ผิดพลาด ควร Label เป็นคลาส Wh (White Spots) มากกว่า เนื่องจากมีจุดสีและแถบสีขาวอย่างเห็นได้ชัด

จากภาพประกอบ 18 ภาพคลาส Bl จาก Test Dataset ที่จำแนกผิดเป็นคลาส Be, On, Wh, Te และ Cl เนื่องจากมีเส้นดำเพียงเล็กน้อย หรืออาจจะเป็นเส้นดำที่ไม่ชัดเจน ไม่เป็นเส้นตรง




ภาพประกอบ 19 คลาส Cl จาก Test Dataset ที่จำแนกผิด




ภาพประกอบ 20 คลาส Mu จาก Test Dataset ที่จำแนกผิด



ภาพประกอบ 21 คลาส On จาก Test Dataset ที่จำแนกผิด



ภาพประกอบ 22 คลาส Te จาก Test Dataset ที่จำแนกผิด



ภาพประกอบ 23 คลาส Wh จาก Test Dataset ที่จำแนกผิด

จากภาพประกอบ 19 ภาพคลาส Cl จาก Test Dataset ที่จำแนกผิดเป็นคลาส Be และ Bl เนื่องจาก คลาส Cl ต้องสังเกตลักษณะโค้งของเล็บ ดังนั้นภาพที่ไม่เห็นลักษณะของเล็บชัดและอาจจะมีลักษณะอื่นที่เด่นกว่า ทำให้โมเดลจำแนกผิด

จากภาพประกอบ 20 ภาพคลาส Mu จาก Test Dataset ที่จำแนกผิดเป็นคลาส Bl, Te และ Wh เนื่องจากเห็นแถบขวางสีขาวสลับกับสีชมพูไม่ชัดเจน

จากภาพประกอบ 21 ภาพคลาส On จาก Test Dataset ที่จำแนกผิดเป็นคลาส Te เนื่องจากความกว้างของปลายเล็บสีขาวมีขนาดเล็ก และสีหน้าเล็บของทั้งสองคลาสมีลักษณะคล้ายกัน ซึ่งทำให้โมเดลจำแนกผิดพลาด

จากภาพประกอบ 22 ภาพคลาส Te จาก Test Dataset ที่จำแนกผิดเป็นคลาส Wh, Cl, Bl และ Mu จะเห็นว่าภาพไม่ชัดและแสงจากการถ่ายภาพอาจทำให้ไม่เห็นรายละเอียดของลักษณะผิวเล็บ

ตาราง 6 Precision Recall และ F1 Score โมเดล CNN

	Precision	Recall	F1-score	Support	Accuracy
Be	0.7895	0.7500	0.7692	20	0.8143
Bl	0.6500	0.6500	0.6500	20	
Cl	0.9000	0.9500	0.9000	20	
Mu	0.9375	0.7500	0.8333	20	
On	0.8261	0.9500	0.8837	20	
Te	0.8421	0.8000	0.8205	20	
Wh	0.7826	0.9000	0.8372	20	
Be = Beau's lines on Nails, Bl = Black line on Nails, Cl = Nail Clubbing, Mu = Muehrcke's Nails, On = Onycholysis, Te = Terry's Nail, Wh = White Spots on the Nails					

จากภาพประกอบ 23 ภาพคลาส Wh จาก Test Dataset ที่จำแนกผิดเป็นคลาส On และ Be จะเห็นว่าเป็นภาพเล็บที่มีจุดขาวเพียงเล็กน้อยและมีแสงจากการถ่ายรูป ซึ่งทำให้เห็นเป็นจุดสีขาวไม่ชัดเจน

จากภาพประกอบ 16 ค่า Confusion Matrix ข้างต้น เมื่อนำมาเทียบค่า คำนวณความถูกต้องและความแม่นยำ จะได้ค่า Accuracy, Precision, Recall และ F1-score ดังตาราง 6

จากตาราง 6 ได้ผลลัพธ์การจำแนกความผิดปกติของเล็บด้วยโมเดล CNN มีค่าความถูกต้องอยู่ที่ 81.43% อธิบายได้ว่า โมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชันมีประสิทธิภาพสามารถจำแนกความผิดปกติของเล็บทั้ง 7 ลักษณะนี้ได้

5. สรุป และแนวทางในอนาคต

บทความนี้เสนอการศึกษาและวิเคราะห์การจำแนกความผิดปกติของเล็บ 7 ลักษณะ ได้แก่ 1) เล็บเป็นร่องลึกตามแนวขวาง (Beau's Lines on Nails) 2) เล็บเป็นแถบสีดำ (Black line on Nails) 3) นิ้วบวม (Nail Clubbing) 4) เล็บมีแถบขวางสีขาวสลับกับสีชมพู (Muehrcke's nails) 5) ปลายเล็บร่น (Terry's nail) 6) เล็บเป็นสีขาวเกือบทั้งเล็บและมีแถบสีชมพู

ที่ปลายเล็บ และ 7) เล็บมีจุดสีขาว (White Spots on Nails) โดยรวบรวมข้อมูลจาก Google images จำนวน 700 ภาพ แบ่งเป็น Train set, Validation set และ Test set อัตราส่วน 64:16:20 และเปรียบเทียบโมเดลโครงข่ายประสาทเทียม (ANN) กับโมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) พบว่าโมเดลโครงข่ายประสาทเทียม (ANN) เกิดปัญหา Overfitting อธิบายได้ว่าโมเดลมีการเรียนรู้ที่เกินไปจากชุดข้อมูลสำหรับฝึกฝนโมเดล รวมถึงความผันผวนของชุดข้อมูลสำหรับฝึกฝน จึงทำให้โมเดลไม่สามารถจำแนกความผิดปกติของเล็บได้อย่างถูกต้อง ซึ่งได้ค่าความถูกต้องเพียง 43.57 % เมื่อเทียบกับโมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่ได้ค่าความถูกต้องถึง 81.43 % เนื่องจากโมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชันมีการสกัดคุณลักษณะจากภาพเพิ่มขึ้นในแต่ละ layer และทำ Image Augmentation เพื่อเพิ่มจำนวนภาพสำหรับชุดข้อมูลฝึกฝนช่วยลดปัญหาการเกิด Overfitting ทำให้โมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชันมีประสิทธิภาพในการจำแนกความผิดปกติของเล็บที่ดีกว่าโมเดลแบบโครงข่ายประสาทเทียม

ลักษณะความผิดปกติของเล็บมีลักษณะที่หลากหลายมากกว่าที่ผู้วิจัยนำมาจำแนกในบทความนี้

ดังนั้นสามารถพัฒนาโมเดลให้ครอบคลุมความผิดปกติของเล็บในลักษณะอื่นๆ เพิ่มขึ้น และเนื่องจากผลที่ได้จากการจำแนกความผิดปกติของเล็บยังมีความผิดพลาดและมีความแม่นยำในการจำแนกที่น้อยหากนำไปใช้จริง ดังนั้นงานวิจัยในอนาคตอาจจำเป็นต้องสร้างโมเดลในแบบอื่นๆ และอาจนำเทคนิคการแบ่งส่วนภาพ (Image Segmentation) เพื่อแบ่งส่วนภาพเลือกเฉพาะบริเวณผิวเล็บและสามารถนำไปต่อยอดสร้างการตรวจสอบวัตถุ (Object Detection) เพื่อนำไปประยุกต์เป็นเครื่องมือจำแนกความผิดปกติของเล็บและสามารถตรวจสอบสุขภาพได้ด้วยตนเองเพื่อทราบถึงอาการผิดปกติที่อาจเกิดขึ้น นำไปสู่การพบแพทย์และการเข้ารับการรักษา

6. เอกสารอ้างอิง

- ชนิดา ฉันทวนิชย์. (2558). *การวิจัยและพัฒนาผลิตภัณฑ์เคลือบเล็บชนิดลอกออกได้*. เชียงราย: มหาวิทยาลัยแม่ฟ้าหลวง.
- ณัฐวุฒิ ศรีวิบูลย์. (2563). *การปรับปรุงประสิทธิภาพการจำแนกภาพเอกซเรย์ทรวงอกด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการโดยใช้เทคนิคการเพิ่มภาพสำหรับวินิจฉัยโรคโควิด-19*. กาลสินธุ์: มหาวิทยาลัยกาฬสินธุ์.
- ณัฐโชติ พรหมฤทธิ์. (2564). *Fundamental of DEEP LEARNING in Practice*. (พิมพ์ครั้งที่ 1). กรุงเทพฯ: สำนักพิมพ์อินโฟเพรส.
- พิมพา ชีวาประกอบกิจ. (2562). *การปรับปรุงประสิทธิภาพในการจำแนกภาพด้วยโครงข่ายประสาทแบบคอนโวลูชันโดยใช้เทคนิคการเพิ่มภาพ*. สระบุรี: มหาวิทยาลัยนานาชาติเอเชีย-แปซิฟิก.
- วิชชุดา ธงกิ่ง, ภูษิต มิตรสมหวัง, บุระ สิ้นธุภากร และเจษฎา ตัณฑนุช. (2565). การวิเคราะห์และการจำแนกกระดูกสันหลังที่ผิดปกติด้วยขั้นตอนวิธีโครงข่ายประสาทสังวัตนาการ. *วารสารเทคโนโลยีสุรนารี*, 16(1), 1-13. <https://doi.org/10.14456/jait.2023.2>
- ศิรัชย์ โชติชาติมาลา และณัฐวี วิวัฒนวัฒนา. (2563). *แบบจำลองการคัดแยกผลไม้แบบหนึ่งชนิดด้วยการเรียนรู้ของเครื่องเพื่อตรวจจบบรูบแอปเปิ้ล*. กรุงเทพฯ: มหาวิทยาลัยศรีนครินทรวิโรฒ.
- อุมาภรณ์ สายแสงจันทร์, รพีพร ชำของ และอรรณพ สุวรรณษา. (2565). การเปรียบเทียบวิธีการวิเคราะห์โรคใบเมฆขาวด้วยการเรียนรู้เชิงลึก. *วารสารวิทยาการสารสนเทศและเทคโนโลยีประยุกต์*, 4(1), 71-86. <https://ph01.tci-thaijo.org/index.php/jait/article/view/248021>
- Alirezanejad, M., Saffari, V., Amirgholipour, S., & Sharifi, A. M. (2014). Effect of locations of using high boost filtering on the watermark recovery in spatial domain watermarking. *Indian Journal of Science and Technology*, 7(4), 517-524. <https://doi.org/10.17485/ijst/2014/v7i4.12>
- Brownlee, J. (2019). *Deep learning for computer vision*. Retrieved 23 May 2022. Retrieved from <https://machinelearningmastery.com/how-to-configure-image-data-augmentation-when-training-deep-learning-neural-networks/>
- Fawcett, R. S., Thomas, M., & Daniel, L. (2004). Nail abnormalities: Clues to systemic disease. *American Family Physician*, 69(6), 1417-1424. <https://www.aafp.org/pubs/afp/issues/2004/0315/p1417.html>

Nasritha, K., Kerdprasop, K., & Kerdprasop, N. (2018). Comparison of sampling techniques for imbalanced data classification. *Journal of Applied Informatics and Technology*, 1(1), 20-37. <https://ph01.tci-thaijo.org/index.php/jait/article/view/90569>