

การจำแนกลายผ้าไหมด้วยการเรียนรู้โครงข่ายประสาทเทียมเชิงลึก

Thai Silk Patterns Classification with Deep Neural Networks

นครินทร์ อินทรโก¹, บุศราทิพย์ ผาติชัยเกียรติ¹, ศักดิ์พงษ์ ทองเลี่ยมนาค¹, ธนพล ตั้งชูพงศ์^{1,*}
Nakharin Ingo¹, Budsarathip Phatichaikiart¹, Sakpod Tongleamnak¹,
Thanaphon Tangchoopong^{1,*}

¹ สาขาวิชาวิทยาการคอมพิวเตอร์ วิทยาลัยการคอมพิวเตอร์ มหาวิทยาลัยขอนแก่น ขอนแก่น 40002 ประเทศไทย

¹ Department of Computer Science, College of Computing, Khon Kaen University, Khon Kaen 40002, Thailand

* Corresponding Author: Thanaphon Tangchoopong, thanaphon@kku.ac.th

Received:

5 March 2023

Revised:

6 April 2023

Accepted:

29 May 2023

คำสำคัญ:

โครงข่ายประสาทเทียม,
โครงข่ายประสาทเทียมเชิงลึก,
โครงข่ายประสาทเทียมแบบ
คอนโวลูชัน, ลวดลายผ้าไหม,
การจำแนกประเภท

Keywords:

Neural Network, Deep
Neural Network, Convolutional
Neural Network, Silk Pattern,
Classification

บทคัดย่อ: การทอผ้าไหมเป็นภูมิปัญญาพื้นบ้านที่สืบทอดจากรุ่นสู่รุ่น โดยแต่ละชุมชนจะมีการออกแบบลายผ้าไหมที่เป็นเอกลักษณ์เฉพาะพื้นที่ ทั้งนี้การจำแนกลวดลายผ้าไหมนั้นจะต้องใช้ผู้ที่มีความรู้ความเชี่ยวชาญและจะต้องคลุกคลีอยู่กับผ้าไหม จึงทำให้ผู้เชี่ยวชาญด้านผ้าไหมมีจำนวนจำกัด ดังนั้น งานวิจัยนี้มีจุดมุ่งหมายที่จะพัฒนาระบบการจำแนกลายผ้าไหม โดยนำเอาเทคโนโลยีการประมวลผลภาพด้วยคอมพิวเตอร์มาเพื่อช่วยในการรู้จำลายผ้าไหมจากภาพถ่าย ในงานวิจัยนี้ได้มุ่งเน้นในการเก็บข้อมูลลายผ้าไหมจากอำเภอชนบท จังหวัดขอนแก่น โดยได้เลือกลายผ้าไหมมาทั้งสิ้น 15 ลาย และเก็บรวบรวมรูปภาพจากการถ่ายรูปลายผ้าไหมจำนวนทั้งสิ้น 2,156 รูปภาพ โดยวิจัยได้นำเสนอโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) จำนวน 2 ตัวแบบ ซึ่งทั้งสองรูปแบบนั้นมีความแตกต่างกันในส่วนของการสกัดคุณลักษณะพิเศษและเรกูไลเซชันด้วยวิธีดรอพเอาต์ จากผลการทดลองพบว่า CNN ตัวแบบที่ 1 ให้ค่า F1-score ที่ 0.62 และ CNN ตัวแบบที่ 2 ซึ่งได้เพิ่มส่วนการสกัดคุณลักษณะพิเศษด้วยการใช้ค่าน้ำหนักของตัวแบบพรีเทรน และการเพิ่มชั้นดรอพเอาต์ ส่งผลให้ค่า F1-score ที่ 0.92 ซึ่งสามารถช่วยแก้ปัญหาความสับสนในการจำแนกลายผ้าไหม

Abstract: The art of silk weaving has been transferred through generations as part of folk wisdom. Every locality has its distinct silk pattern design. Expertise and familiarity with silk are necessary for the classification of silk patterns. Therefore, only a few experts can recognize the silk's pattern. This study aims to implement

a system for classifying silk patterns using image processing technology to help identify silk patterns from images. This research collected silk pattern data from the Chonnabot district, Khon Kaen Province. We selected 15 silk patterns and collected a total of 2,156 images. We examined two convolutional neural networks (CNNs), which differed in feature extraction and regularization via the dropout technique. The experimental results showed that CNN model 1 achieved an F1-score of 0.62. The CNN model 2, in which feature extraction using the pre-trained model was added to the CNN model 2, achieved an F1-score of 0.92, which can assist in resolving the confusion in silk pattern classification.

1. บทนำ

ปัจจุบันมีการสืบสานวัฒนธรรมโดยการสนับสนุนให้สวมใส่ชุดผ้าไหมเพื่อให้เป็นเอกลักษณ์ประจำชาติไทย เนื่องจากผ้าไหมเป็นศิลปหัตถกรรมที่สำคัญของประเทศไทยที่ได้รับการสืบทอดมาอย่างยาวนาน อีกทั้งยังเป็นศิลปะที่งดงามควรค่าแก่การอนุรักษ์ จึงทำให้ผ้าไหมนั้นเป็นที่นิยมในการนำมาเป็นเครื่องแต่งกาย เนื่องจากมีความโดดเด่นทั้งลักษณะของสีที่เป็นธรรมชาติ รวมทั้งลวดลายที่เป็นเอกลักษณ์ ซึ่งลวดลายผ้าไหมโดยส่วนใหญ่เกิดจากจินตนาการของผู้ออกแบบลวดลาย โดยได้รับอิทธิพลมาจากสิ่งต่างๆ ที่พบเห็นได้ในชีวิตประจำวัน จึงทำให้นักออกแบบได้ออกแบบและตั้งชื่อลวดลายผ้าไหมอย่างมากมาย ทั้งนี้บุคคลทั่วไปที่ไม่มีความรู้และไม่ได้คลุกคลีกับผ้าไหมอาจจะไม่สามารถจดจำลวดลายผ้าไหมได้ ดังนั้น จึงจำเป็นต้องใช้ผู้เชี่ยวชาญในการจำแนกลวดลายผ้าไหม (Keereemek, 2016; Kaewmongkol & Kittilap, 2016)

ในอำเภอชนบท จังหวัดขอนแก่น ถือได้ว่าเป็นแหล่งผลิตผ้าไหมที่สำคัญของภาคอีสาน ซึ่งผู้ออกแบบได้ออกแบบลวดลายผ้าไหมที่มีเอกลักษณ์จำนวนมาก (National News Bureau of Thailand, 2022) ทั้งนี้ ผู้วิจัยจึงมีความสนใจที่จะนำลวดลายผ้าไหมที่ออกแบบและจำหน่ายในอำเภอชนบท จังหวัดขอนแก่น มาเพื่อเป็นแหล่งข้อมูลสำหรับการพัฒนาตัวแบบ (Model) ที่ช่วยจำแนกลายผ้าไหม ทั้งนี้หากตัวแบบที่พัฒนามีความแม่นยำในการจำแนกลายผ้าไหม

จะสามารถนำไปประยุกต์ต่อยอดเป็นระบบสารสนเทศลายผ้าไหมที่สามารถสืบค้น และให้ข้อมูลที่สำคัญของลายผ้าไหมได้

ในงานวิจัยของ Raksaard & Surinta (2018) ได้ศึกษาถึงวิธีการที่จะค้นคืนรูปภาพลายผ้าไหม โดยศึกษาระหว่างวิธีการหาคุณลักษณะเฉพาะพื้นที่ (Local Descriptor) และวิธีการเรียนรู้เชิงลึก (Deep Learning) ในการศึกษาครั้งนี้ได้เก็บรวบรวมลายผ้าไหมจากบ้านหนองเพื่อนช้าง จังหวัดมหาสารคามจำนวน 10 ลาย เช่นลายนกยูง ลายกระจับหนาม ลายกุญแจใจ ลายน้าฟ้าคาดทอง ลายกระจับจั่ว ลายนาคน้อย ลายตะขอ ลายสร้อยดอกหมาก ลายสร้อยดอกหมากเล็ก และลายไข่มดแดง สำหรับวิธีการหาคุณลักษณะเฉพาะพื้นที่ ได้ใช้วิธี Histogram of Oriented Gradients (HOG) และ Scale-Invariant Features Transform (SIFT) สำหรับการคำนวณหาคุณลักษณะเฉพาะพื้นที่ จากนั้นคุณลักษณะเฉพาะพื้นที่จะถูกนำไปเรียนรู้และสร้างโมเดลด้วยวิธี Support Vector Machine (SVM) และ K-Nearest Neighbor (KNN) และสำหรับวิธีการเรียนรู้เชิงลึก ได้ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network) จำนวน 2 สถาปัตยกรรม คือ LeNet-5 และ AlexNet เพื่อสร้างโมเดล จากงานวิจัยพบว่าการหาคุณลักษณะเฉพาะพื้นที่ร่วมกับ SVM มีความถูกต้องในการค้นคืนที่สูงกว่า CNN ทั้งนี้เนื่องจากจำนวนข้อมูลที่ใช้ในการทดลองมีจำนวนจำกัด และข้อมูลที่ใช้เป็นข้อมูลที่ถูกครอบ (Crop) เฉพาะพื้นที่จึงทำให้วิธีการหา

คุณลักษณะเฉพาะพื้นที่ที่เหมาะสมกับการค้นคืน
ลายผ้าไหมมากกว่า

ปัจจุบันการเรียนรู้เชิงลึกถูกนำไปใช้อย่าง
แพร่หลาย เช่นในงานวิจัยของ Butploy & Boonying
(2020) ได้นำการเรียนรู้เชิงลึกไปช่วยในการจำแนก
ภาพพระเครื่องเบญจภาคี โดยผู้วิจัยได้เก็บรวบรวม
รูปภาพพระเครื่องจำนวน 500 ภาพ และยังเพิ่ม
จำนวนของรูปภาพที่จะนำไปสร้างตัวแบบด้วยวิธี
Data Augmentation ซึ่งประกอบด้วยการหมุนภาพ
ในแนวตั้งและแนวนอน ในการสร้างตัวแบบนั้นผู้วิจัย
ได้ออกแบบสถาปัตยกรรม CNN ขึ้นมาเองซึ่งประกอบ
ด้วย 5 ชั้น (Layer) และในงานวิจัยของ Kumpala
et al. (2022) ได้นำวิธี CNN มาใช้สำหรับสร้างโมเดล
และจำแนกภาพใบอ้อยที่เป็นโรค ซึ่งมีความถูกต้องสูง
ถึง 95.90% จากนั้นนักวิจัยได้พัฒนาเว็บไซต์เพื่อให้
ผู้ใช้งานสามารถถ่ายภาพใบอ้อยที่เป็นโรคและนำมา
ตรวจสอบโรคได้

เนื่องจากวิธีการเรียนรู้เชิงลึกเป็นอัลกอริทึม
ที่ใช้กันอย่างแพร่หลายในงานทางด้านการประมวลผล
ภาพ (Image Processing) และการจำแนกรูปภาพ
(Image Classification) (Vaddi & Manoharan,
2020) ผู้วิจัยจึงเลือกนำเทคโนโลยีการเรียนรู้เชิงลึก
โดยเลือกโครงข่ายประสาทเทียมแบบคอนโวลูชัน
เข้ามาพัฒนาตัวแบบเพื่อการจำแนกลายผ้าไหม

2. โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN)

โครงข่ายประสาทเทียม (Neural Network)
เป็นการจำลองรูปแบบการประมวลผลของสมองมนุษย์
โดยใช้โครงข่ายคล้ายเซลล์ประสาทในการประมวลผล
โดยงานวิจัยนี้เลือกใช้โครงข่ายประสาทเทียมแบบ
คอนโวลูชันซึ่งเป็นโครงสร้างหนึ่งของการเรียนรู้เชิงลึก
(Deep Learning) โดยจุดเด่นของโครงข่ายประสาท
เทียมแบบคอนโวลูชันคือ เหมาะสมกับการนำไปใช้ใน

การรู้จำรูปภาพ (Image Recognition) โดยโครงข่าย
จะแบ่งการทำงานออกเป็นสองส่วนหลัก คือการหา
คุณลักษณะพิเศษ (Feature Extraction) และการ
รู้จำ (Recognition)

ดังนั้น การสกัดคุณลักษณะพิเศษ (Feature)
จึงสามารถสกัดจากข้อมูลประเภทที่ไม่มีโครงสร้างเป็น
รูปแบบเฉพาะตัว (Unstructured Data) เช่น รูปภาพ
โดยโครงข่ายจะเรียนรู้รูปจากทุกพื้นที่ของรูปภาพและ
สกัดลักษณะพิเศษออกมา และส่งต่อไปยังชั้นของ
การรู้จำเพื่อจำแนกว่ารูปภาพนั้นเป็นภาพของสิ่งใด
โดยทั่วไปโครงข่ายประสาทเทียมแบบคอนโวลูชัน
ประกอบไปด้วย 3 ชั้น (Layer) (Kittinaradorn, 2020;
Saisangchan, Chamchong & Suwannasa, 2022;
Lapthanachai *et al.*, 2023) คือ ชั้นคอนโวลูชัน
ชั้นพูลลิง และชั้นการเชื่อมต่อกันของแต่ละเลเยอร์
อย่างสมบูรณ์ โดยตัวอย่างของโครงข่ายประสาท
เทียมแบบคอนโวลูชันแสดงดังภาพประกอบ 1 และ
รายละเอียดของทั้ง 3 ชั้น แสดงดังต่อไปนี้

2.1 ชั้นคอนโวลูชัน (Convolutional Layer)


ชั้นคอนโวลูชันมีหน้าที่หลักคือการสกัด
คุณลักษณะพิเศษ (Feature) หรือเรียกว่าฟีเจอร์
จากรูปภาพ โดยชั้นคอนโวลูชันมีความพิเศษตรงที่
จะคงความสัมพันธ์ของพิกเซล (Pixel) ที่อยู่บริเวณ
พื้นที่ใกล้เคียงกันเอาไว้ (LeCun & Bengio, 1995;
Kummong, 2022) โดยรูปภาพที่ส่งเข้าไปคำนวณ
นั้นจะถูกปรับขนาดให้เป็นสี่เหลี่ยมจัตุรัส เช่น โครง
ข่าย VGG จะกำหนดให้รูปภาพที่นำเข้ามีขนาด
224x224 พิกเซล หรือ EfficientNetB1 ขนาดของ
รูปภาพจะเพิ่มขึ้นเป็น 240x240 พิกเซล จากนั้น
เคอร์เนล (Kernel) ขนาดต่างๆ เช่น 3x3, 5x5, 7x7
จะถูกนำไปคำนวณกับทุกพื้นที่ของรูปภาพเพื่อสร้าง
ฟีเจอร์แมป (Feature Map) ซึ่งฟีเจอร์แมปนี้จะ
เรียกว่าคุณลักษณะพิเศษที่ได้จากการคำนวณด้วย
วิธีคอนโวลูชัน (Convolution)

2.2 ชั้นพูลลิง (Pooling Layer)


ชั้นพูลลิงเป็นชั้นที่ดำเนินการลดขนาดของฟีเจอร์แมป โดยการคำนวณนั้นรูปภาพจะถูกแบ่งออกเป็นพื้นที่ย่อย เช่นใน VGG ชั้นพูลลิงจะถูกกำหนดให้มีขนาด 2x2 และ AlexNet จะถูกกำหนดเป็น 3x3 จากนั้นจะใช้กระบวนการ (Operator) เช่นหาค่าสูงสุด (Max) หรือหาค่าต่ำสุด (Min) ซึ่งเรียกว่า Max Pooling หรือ Min Pooling ดังนั้น หากกำหนดให้ใช้ Max Pooling การคำนวณก็จะหาค่าสูงสุดเพื่อใช้เป็นตัวแทนในพื้นที่ย่อยนั้นๆ ดังนั้น การคำนวณจากพื้นที่ย่อยแรก ไปยังพื้นที่ถัดไปจะทำการเลื่อน หรือเรียกว่า Stride ไปครั้งละ 1 หรือ 2 พิกเซล ขึ้นอยู่กับการกำหนด วิธีการนี้จะทำให้ขนาดของชั้นพูลลิงมีขนาดลดลงถึงครึ่งหนึ่งหากเปรียบเทียบกับชั้นคอนโวลูชัน เช่น ชั้นคอนโวลูชันมีขนาด 224x224 พิกเซลเมื่อผ่านกระบวนการเช่น Max Pooling และกำหนดให้ค่า Stride เท่ากับ 2 จะทำให้ชั้นพูลลิงมีขนาดลดลงเหลือ 112x112 พิกเซล

2.3 ชั้นการเชื่อมต่อกันอย่างสมบูรณ์ (Fully Connected Layer)

ชั้นการเชื่อมต่อกันอย่างสมบูรณ์ชั้นนี้เป็นชั้นสุดท้ายของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (ดังแสดงในภาพประกอบ 1) โดยการเชื่อมต่อกันอย่างสมบูรณ์หมายถึงทุกโหนด (Node) ของแต่ละชั้นจะถูกเชื่อมเข้าหากัน หรือเรียกชั้นนี้ว่าชั้นของนิวรอลเน็ตเวิร์ก (Neural Network) โดยการเชื่อมต่อกันอย่างสมบูรณ์ชั้นที่ 1 คือการนำชั้นพูลลิงมาทำให้เป็นเวกเตอร์ (Vector) หรือเรียกว่า Flatten จากนั้นจะถูกส่งต่อไปยังชั้นเชื่อมต่อกันอย่างสมบูรณ์ชั้นที่ 2 และส่งต่อไปยังชั้นแสดงผล (Output Layer) เพื่อหาคำตอบ ดังนั้น จากตัวอย่างของโครงสร้าง VGG16 นั้น ชั้นการเชื่อมต่อกันอย่างสมบูรณ์ถูกกำหนดให้มีจำนวน 2 ชั้น ชั้นแรกและชั้นที่สองถูกกำหนดให้มีขนาดเท่ากันคือ 4096 โหนด แต่ทั้งนั้น ในชั้นสุดท้ายหรือชั้นแสดงผลจะถูกกำหนดให้มีขนาดเท่ากับจำนวนของประเภท (Class) ของรูปภาพที่โครงข่ายประสาทเทียมแบบคอนโวลูชันจะจำแนก (Classification) เช่นหากเป็นการรู้จำตัวเลข (0-9) ชั้นแสดงผลผลลัพธ์ก็จะถูกกำหนดเป็น 10 โหนดเป็นต้น โดยการคำนวณเพื่อจำแนกรูปภาพนั้น จะใช้การคำนวณหาความน่าจะเป็นโดยใช้ฟังก์ชันซอฟต์แมกซ์ (Softmax Function) โดยผลรวมของทั้ง 10 โหนดนั้นจะมีค่าเท่ากับ 1



ภาพประกอบ 1 ตัวอย่างโครงข่ายประสาทเทียมแบบคอนโวลูชัน



(a)



(b)

ภาพประกอบ 2 ตัวอย่างผ้าไหม (a) ลายแคนแก่นคูณ และ (b) ลายขันหมากเบ็ง

3. วิธีการดำเนินงานวิจัย

ในการวิจัยการจำแนกลายผ้าไหมด้วยการเรียนรู้โครงข่ายประสาทเทียมเชิงลึก ผู้วิจัยได้เลือกใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน หรือเรียกว่า CNN เพื่อเรียนรู้และจำแนกรูปภาพลายผ้าไหมที่ได้เก็บรวบรวมมาจากอำเภอนบพ จังหวัดขอนแก่น โดยวิธีการดำเนินงานวิจัยแบ่งเป็นขั้นตอนดังต่อไปนี้

3.1 การเก็บรวบรวมข้อมูล

สำหรับการเก็บรวบรวมข้อมูลลายผ้าไหมนั้น ผู้วิจัยได้ลงพื้นที่โดยเลือกร้านจำหน่ายผ้าไหมที่อยู่ในอำเภอนบพ จังหวัดขอนแก่น โดยมุ่งเน้นลายผ้าไหมจำนวนทั้งสิ้น 15 ลายประกอบด้วย ลายกัญแจจิ้น ลายขอพระเทพ ลายขอเจ้าฟ้า ลายขุมทรัพย์ ลายจั่ว ลายจีเพชร ลายนกยูงทอง ลายนาคเข็งเทียน ลายบุษบก ลายปีกหงส์ ลายหมีบักบก ลายหางปลาหวา ลายแคนแก่นคูณ ลายโดมทอง และลายไปไม้ โดยภาพประกอบ 2(a) แสดงตัวอย่างลายแคนแก่นคูณ และภาพประกอบ 2(b) แสดงตัวอย่างลายขันหมากเบ็ง


ในการเก็บรวบรวมนั้นผู้วิจัยใช้กล้องถ่ายภาพยี่ห้อ Fuji รุ่น X-T3 โดยปรับความละเอียดภาพให้มีขนาด 2080x2080 พิกเซล โดยบันทึกในรูปแบบของภาพสี (Color Image) และเก็บรวบรวมตัวอย่างผ้าไหมได้ทั้งสิ้น 2,556 รูปภาพ

3.2 การเตรียมชุดข้อมูล

ในขั้นตอนการเตรียมชุดข้อมูลนั้น ผู้วิจัยได้ปรับขนาดของรูปภาพให้มีขนาด 128x128 พิกเซล และปรับภาพให้อยู่ในรูปแบบสีเทา (Grayscale Image) โดยรูปภาพลายผ้าไหมทั้งสิ้น 2,556 รูปภาพนั้นจะถูกแบ่งเป็น 70:30 เพื่อใช้เป็นชุดฝึกสอน (Training Set) และชุดตรวจสอบ (Test Set) ดังนั้น ชุดฝึกสอนจึงมีรูปภาพจำนวน 1,509 รูปภาพ และชุดตรวจสอบจึงมีจำนวนรูปภาพทั้งสิ้น 647 รูปภาพ

3.3 การออกแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันและฝึกสอนตัวแบบ

ในขั้นตอนนี้ผู้วิจัยทำได้ออกแบบตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) จำนวน 2 ตัวแบบ จากนั้นจะนำตัวแบบทั้ง 2 นั้นไปฝึกสอน



ภาพประกอบ 3 โครงข่ายประสาทเทียม CNN Model 1

ตาราง 1 โครงสร้างสถาปัตยกรรมของ CNN Model 1

Layer	Output Shape	Param #
Conv2D	(126, 126, 128)	3584
MaxPooling2D	(63, 63, 128)	0
Conv2D	(61, 61, 128)	147584
MaxPooling2D	(30, 30, 128)	0
Dense	(30, 30, 16)	2064
Flatten	(14400)	0
Dense	15	216015
Total params: 369,247		
Trainable params: 369,247		
Non-trainable params: 0		


(Train) กับรูปภาพกล้วยไม้ใหม่จำนวนทั้งสิ้น 1,509 รูปภาพ โดยมีจำนวนทั้งสิ้น 15 Class ดังนั้น ชั้นแสดงผลลัพธ์ของ CNN ที่ได้ออกแบบจะถูกกำหนดให้เป็น 15 โหนด โดยรายละเอียดของตัวแบบ CNN ทั้ง 2 ตัวแบบนี้แสดงดังต่อไปนี้

3.3.1 โครงสร้างตัวแบบที่ 1 (CNN Model 1)

โครงสร้างตัวแบบที่ 1 หรือเรียกว่า CNN Model 1 แสดงดังภาพประกอบ 3 ซึ่งมีสถาปัตยกรรมที่ประกอบด้วย 1) ชั้น Conv2D ซึ่งใช้เคอร์เนล (Kernel) ขนาด 3x3 พิกเซล โดยกำหนดให้มีฟีเจอร์แมป

(Feature Map) จำนวนทั้งหมด 128 ฟีเจอร์แมป 2) การลดขนาดฟีเจอร์แมปด้วย MaxPooling2D ขนาด 2x2 พิกเซล 3) การทำ Conv2D ด้วยเคอร์เนลขนาด 3x3 พิกเซล และในขั้นนี้กำหนดให้มีฟีเจอร์แมปจำนวนทั้งสิ้น 128 ฟีเจอร์แมป 4) การทำ MaxPooling2D ขนาด 2x2 พิกเซล 5) ชั้น Dense ขนาด 16 โหนด 6) ชั้น Flatten เพื่อแปลงข้อมูลให้เหลือ 1 มิติ และ 7) ชั้น Dense ขนาดเท่ากับ 15 โหนด ซึ่งมีขนาดเท่ากับจำนวนกล้วยไม้ใหม่หรือคลาส (Class)

โดยรายละเอียดของโครงสร้างสถาปัตยกรรมของ CNN Model 1 แสดงดังตาราง 1



ภาพประกอบ 4 โครงข่ายประสาทเทียม CNN Model 2

ตาราง 2 โครงสร้างสถาปัตยกรรมของ CNN Model 2

Layer	Output Shape	Param #
MobileNetV2_1.00_128	(4, 4, 1280)	2257984
Conv2D	(2, 2, 128)	1474688
MaxPooling2D	(1, 1, 128)	0
Dropout	(1, 2, 128)	0
Conv2D	(1, 1, 16)	2064
Flatten	(16)	0
Dense	15	255
Total params: 3,734,991		
Trainable params: 1,477,007		
Non-trainable params: 2,257,984		

3.3.2 โครงสร้างตัวแบบที่ 2 (CNN Model 2)

โครงสร้างตัวแบบที่ 2 หรือเรียกว่า CNN Model 2 แสดงดังภาพประกอบ 4 ซึ่งมีสถาปัตยกรรมที่ประกอบด้วย 1) โครงสร้างของ MobileNetV2 โดยตัวแบบที่ 2 นี้จะเริ่มต้นการเรียนรู้โดยใช้ตัวแบบพรีเทรน (Pre-trained Model) ของโครงข่าย MobileNetV2 2) ชั้น Conv2D ปรับให้มิตทั้งหมด

128 พิกเซลและคำนวณด้วยคอนโวลูชันขนาด 3x3 พิกเซล 3) ชั้น MaxPooling2D ขนาด 2x2 พิกเซล 4) ชั้น Dropout ซึ่งได้กำหนดค่าการ drop ไว้ที่ 0.25 5) ชั้น Dense ขนาด 16 โหนด 6) ชั้น Flatten เพื่อแปลงข้อมูลให้เหลือ 1 มิติ และ 7) ชั้น Dense ขนาดเท่ากับ 15 โหนด ซึ่งมีขนาดเท่ากับจำนวนคลาส (Class)

โดยรายละเอียดของโครงสร้างสถาปัตยกรรมของ CNN Model 2 แสดงดังตาราง 2

ตาราง 3 ผลลัพธ์การประเมินประสิทธิภาพของ CNN Model 1

Silk Pattern Name	Precision	Recall	F1-score	Support
ลายขอพระเทพ	0.43	0.74	0.54	58
ลายนาคนางค์เขียว	0.46	0.19	0.27	31
ลายนกยูงทอง	0.49	0.74	0.59	45
ลายหมี่บัวบก	0.49	0.77	0.60	47
ลายจั่ว	0.52	0.39	0.44	36
ลายแคนแก่นคูณ	0.62	0.86	0.72	93
ลายหมี่บัวบก	0.68	0.50	0.58	42
ลายจี่เพชร	0.76	0.87	0.81	46
ลายกุญแจจีน	0.81	0.51	0.63	41
ลายใบไม้	0.83	0.23	0.36	22
ลายขอเจ้าฟ้า	0.85	0.84	0.84	61
ลายบุษบก	0.86	0.27	0.41	45
ลายชุมทรัพย์	0.87	0.52	0.65	25
ลายโดมทอง	0.88	0.42	0.57	36
ลายปีกหงส์	1.00	0.68	0.81	19
accuracy			0.62	647

3.4 การวัดประสิทธิภาพของตัวแบบ

ตัวแบบ CNN 1 และตัวแบบ CNN 2 ที่
ได้จากการฝึกสอนจากรูปภาพจำนวนทั้งสิ้น 1,509
รูปภาพ จะถูกนำไปทดสอบกับชุดตรวจสอบ (Test
Set) ที่มีรูปภาพผ้าไหมจำนวนทั้งสิ้น 647 รูปภาพ
โดยจะประเมินประสิทธิภาพของตัวแบบทั้ง 2
ด้วยค่า F1-score

F1-score คือค่าเฉลี่ยแบบฮาร์โมนิก
(Harmonic Mean) ระหว่างค่าความแม่นยำ
(Precision) และค่าความไวหรือค่าระลึก (Recall)
โดยสร้างค่า F1 ขึ้นมาเพื่อเป็นเมตริก (Metric) ที่
วัดประสิทธิภาพของตัวแบบ (Model) (Ukwuoma
et al., 2023) โดยสมการของ F1-score แสดง
ดังต่อไปนี้

$$F1 - score = 2 \times \left(\frac{precision \times recall}{precision + recall} \right) \quad (1)$$

โดยที่

Precision หมายถึง ค่าความแม่นยำ
เกิดจากการนำค่า True Positive (TP) มาเทียบกับ
False Positive (FP)

Recall หมายถึง ค่าความไวหรือค่าระลึก
เกิดจากการนำค่า มาเทียบกับ False Negative
(FN)

4. ผลการทดลอง

จากขั้นตอนการดำเนินงานที่กล่าวมาข้างต้น สามารถแบ่งการทดลองออกเป็น 3 ส่วน คือ 1) การทดลอง CNN Model 1 และ 2) การทดลอง CNN Model 2 และ 3) เปรียบเทียบประสิทธิภาพของ CNN Model โดยมีผลการทดลองดังต่อไปนี้

4.1 ผลการทดสอบประสิทธิภาพของ CNN Model 1

ในการออกแบบ CNN Model 1 และการฝึกสอน CNN Model 1 นั้นผู้วิจัยได้ดำเนินการบนกูเกิลโคแล็บ (Google Colab) โดยผลการทดลองแสดงดังตาราง 3

จากตาราง 3 ผลลัพธ์จากการประเมินประสิทธิภาพของ CNN Model 1 สรุปได้ว่ามีความถูกต้อง (Accuracy) ที่ 0.62% และเมื่อแยกประเมินการจำแนกของผ้าไหมแต่ละลายพบว่า ลายที่แสดงประสิทธิภาพ F1-score ที่ดีที่สุดคือ ลายขอเจ้าฟ้า มีค่า F1-score เท่ากับ 0.84 นอกจากนี้ ยังมีลายจีเพชรและลายปีกหงส์ที่มีค่า F1-score ที่เท่ากันคือ 0.81 ในทางตรงกันข้าม การจำแนกผ้าไหมลายนาคเชิงเทียนมีประสิทธิภาพต่ำที่สุด โดยมีค่า F1-score เพียง 0.27

4.2 ผลการทดสอบประสิทธิภาพของ CNN Model 2

ผลการทดสอบประสิทธิภาพของ CNN Model 2 แสดงดังตาราง 4

ตาราง 4 ผลลัพธ์การประเมินประสิทธิภาพของ CNN Model 2

Silk Pattern Name	Precision	Recall	F1-score	Support
ลายปีกหงส์	0.84	0.84	0.84	19
ลายขอพระเทพ	0.84	0.88	0.86	58
ลายจีเพชร	0.86	0.84	0.85	46
ลายขุมทรัพย์	0.88	0.88	0.88	25
ลายแคนแก่นคูณ	0.89	0.98	0.93	93
ลายหางปลาวาฬ	0.91	0.93	0.92	42
ลายขอเจ้าฟ้า	0.91	1.00	0.95	61
ลายนาคเชิงเทียน	0.92	0.77	0.84	31
ลายนกยูงทอง	0.92	0.78	0.85	45
ลายหมี่ปักบก	0.92	0.96	0.94	47
ลายบุษบก	0.92	1.00	0.96	45
ลายโดมทอง	0.94	0.92	0.93	36
ลายกุญแจเงิน	0.97	0.95	0.96	41
ลายจั่ว	1.00	0.83	0.91	36
ลายใบไม้	1.00	0.82	0.90	22
Accuracy			0.92	647


จากตาราง 4 ผลลัพธ์จากการประเมินประสิทธิภาพของ CNN Model 2 สรุปได้ว่าสามารถจำแนกลายผ้าไหมลายบุษบกและลายกนกยูงเงิน โดยวัดจากค่า F1-score ที่สูงถึง 0.96 โดยค่า F1-score ของลายแคนแก่นคูณ ลายหางปลาวาฬ ลายขอเจ้าฟ้า ลายหมีปักบก ลายโดมทอง ลายจั่ว และลายใบไม้ มีค่าที่สูงกว่า 0.90 ในทางตรงกันข้ามค่า F1-score ของลายปีกหงส์และลายนาคเชิงเทียน มีค่าเพียง 0.84 ในภาพรวม CNN Model 2 มีความถูกต้องที่ 0.92

4.3 การเปรียบเทียบประสิทธิภาพของ CNN Model


จากการทดลองทั้ง CNN Model 1 และ 2 ผู้วิจัยจึงเปรียบเทียบให้เห็นถึงประสิทธิภาพของ CNN Model ทั้ง 2 ตัวแบบ โดยผลการเปรียบเทียบแสดงดังตาราง 5

ตาราง 5 แสดงผลการเปรียบเทียบ Model 1 และ Model 2


Silk Pattern Name	F1-Score	
	Model 1	Mode 2
ลายนาคเชิงเทียน	0.27	0.84
ลายใบไม้	0.36	0.90
ลายบุษบก	0.41	0.96
ลายจั่ว	0.44	0.91
ลายขอพระเทพ	0.54	0.86
ลายโดมทอง	0.57	0.93
ลายหางปลาวาฬ	0.58	0.92
ลายนกยูงทอง	0.59	0.85
ลายหมีปักบก	0.60	0.94
ลายกนกยูงเงิน	0.63	0.96
ลายขุมทรัพย์	0.65	0.88
ลายแคนแก่นคูณ	0.72	0.93
ลายปีกหงส์	0.81	0.84
ลายจีเพชร	0.81	0.85
ลายขอเจ้าฟ้า	0.84	0.95
accuracy	0.62	0.92



ภาพประกอบ 5 Confusion Matrix
ของ CNN Model 1



(a)




(b)


ภาพประกอบ 6 ภาพลายผ้าไหม (a) ลายนาคเชิงเทียน และ (b) ลายขอพระเทพ

จากตาราง 5 แสดงผลการเปรียบเทียบ CNN Model 1 และ CNN Model 2 โดยประเมินประสิทธิภาพจากชุดข้อมูลตรวจสอบ (Test Set) ที่มีจำนวนรูปภาพลายผ้าไหมทั้งสิ้น 647 รูปภาพ ผลการทดลองแสดงให้เห็นว่า CNN Model 2 ที่ใช้ Pre-train Model ของ MobileNetV2 ให้ค่า F1-score ที่สูงกว่า 0.84 โดยค่า F1-score ที่สูงสุดคือ 0.96 ในทางกลับกัน CNN Model 1 ที่ไม่ได้ใช้ Pre-train Model มีค่า F1-score สูงที่สุดเพียง 0.84 และเมื่อเปรียบเทียบค่าความถูกต้อง (Accuracy) พบว่า CNN Model 2 มีความถูกต้องสูงถึง 0.92 และ CNN Model 1 มีความถูกต้องเพียง 0.62


จากภาพประกอบ 5 แสดงตารางการวัดประสิทธิภาพของตัวแบบ (Confusion Matrix) ของ CNN Model 1 โดยคลาสที่มีความแม่นยำคือ ลายขอเจ้าฟ้า ลายจีเพชร และลายปีกหงส์ แต่สำหรับผ้าไหมบางลายยังมีความสับสนในการจำแนก ได้แก่ ลายนาคเชิงเทียนและลายไปไม้ ซึ่งจะสับสนกับลายขอพระเทพ



ภาพประกอบ 7 Confusion Matrix ของ CNN Model 2



(a)



(b)

ภาพประกอบ 8 ตัวอย่างผ้าไหม (a) ลายนกยูงทอง และ (b) ลายหางปลาวาฬ

จากภาพประกอบ 6(a) คือลายนาคเชิงเทียน และภาพประกอบ 6(b) คือลายขอพระเทพ แสดงให้เห็นว่าเมื่อมองด้วยตาจะเห็นถึงความคล้ายคลึงกันของทั้ง 2 ลวดลายจึงทำให้ตัวแบบที่ 1 เกิดความสับสนในการจำแนก ซึ่งจากผลการวัดประสิทธิภาพด้วย F1-score มีค่าอยู่ที่ 0.84 โดยจากทั้งหมด 31 ภาพ ทำนายถูกไป 24 ภาพ ทำนายผิดไป 7 ภาพ ทำนายผิดเป็นลายขอพระเทพ 5 ภาพ และเป็นลายบุษบกและแก่นคูณอย่างละ 1 ภาพ

จากภาพประกอบ 7 แสดงตาราง Confusion Matrix ของตัวแบบที่ 2 ในข้อมูลชุด Test โดยคลาสที่มีความแม่นยำคือ ลายกุญแจจีน ลายขอเจ้าฟ้า ลายบุษบก ลายหมีบักบก ลายแคนแก่นคูณ ลายโดมทอง แต่ในบางลายยังมีความสับสนในการจำแนก ได้แก่ ลายนาคเชิงเทียนสับสนกับลายขอพระเทพ และลายนกยูงทองสับสนกับลายหางปลาวาฬ

จากภาพประกอบ 8(a) คือผ้าไหมลายนกยูงทอง และภาพประกอบ 8(b) คือลายหางปลาวาฬ โดยทั้ง 2 ภาพ แสดงให้เห็นถึงตัวอย่างลายผ้าไหมที่เกิดความสับสนจากตัวแบบ ซึ่งจากผลการ

วัดประสิทธิภาพด้วย F1-score มีค่าอยู่ที่ 0.85 ทั้งนี้จากรูปภาพทั้งหมด 45 ภาพทำนายถูกทั้งสิ้น 36 ภาพ และทำนายผิด 9 ภาพ ซึ่งในการทำนายของตัวแบบนี้ทำนายผิดเป็นลายหางปลาวาฬ 5 ภาพ และเป็นการทำนายเป็นลายขอเจ้าฟ้า ลายนาคเชิงเทียน ลายปีกหงส์ ลายหมีบักบก และลายโดมทอง อย่างละ 1 ภาพ

5. สรุปผลการวิจัย

ผู้วิจัยได้รวบรวมข้อมูลรูปภาพลายผ้าไหมจากอำเภอชนบท จังหวัดขอนแก่น โดยใช้กล้องถ่ายภาพรุ่น Fuji X-T3 โดยปรับความละเอียดของภาพเป็น 2080x2080 พิกเซล ซึ่งเก็บรวบรวมรูปภาพลายผ้าไหมมาทั้งสิ้น 2,156 รูป โดยมีจำนวนทั้งสิ้น 15 ลวดลาย ประกอบด้วย ลายนาคเชิงเทียน ลายใบไม้ ลายบุษบก ลายจั่ว ลายขอพระเทพ ลายโดมทอง ลายหางปลาวาฬ ลายนกยูงทอง ลายหมีบักบก ลายกุญแจจีน ลายขุมทรัพย์ ลายแคนแก่นคูณ ลายปีกหงส์ ลายจีเพชร และลายขอเจ้าฟ้า ในการทดลองนั้นผู้วิจัยได้ออกแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันจำนวนทั้งสิ้น 2 ตัวแบบ ซึ่งตัวแบบ 1 (Model 1) ประกอบด้วย Conv2D

และ MaxPooling2D จำนวน 2 ชั้น และต่อด้วยชั้น Dense, Flatten และ Dense ตามลำดับ โดย Dense ชั้นสุดท้ายคือคำตอบของตัวแบบที่กำหนดให้มีทั้งสิ้น 15 โหนด (Node) และตัวแบบ 2 (Model 2) ใช้ตัวแบบพรีเทรน (Pre-trained Model) จาก MobileNetV2 และได้เพิ่มชั้น Conv2D, MaxPooling2D, Dropout, Conv2D เข้าไปยังตัวแบบจากนั้น ได้เพิ่มชั้น Flatten และ Dense โดยกำหนดให้มีจำนวนทั้งสิ้น 15 โหนด จากการศึกษาพบว่า ตัวแบบ 1 นั้นมีจำนวนของพารามิเตอร์ที่จะใช้คำนวณเพียง 369,247 พารามิเตอร์ แต่ Model 2 นั้นมีจำนวนพารามิเตอร์มากขึ้น 3,734,991 พารามิเตอร์ ซึ่งมากกว่าตัวแบบ 1 ถึง 10 เท่า จากการทดลองพบว่า ถึงแม้ตัวแบบ 2 จะมีพารามิเตอร์จำนวนมาก แต่เมื่อนำไปสร้างเป็นโมเดลเพื่อจำแนกรูปภาพกล้วยไม้พบว่าตัวแบบ 2 มีผลการจำแนกรูปภาพกล้วยไม้ที่ดีกว่าตัวแบบ 1 โดยตัวแบบ 2 มีค่า F1-score เท่ากับ 0.92 และตัวแบบ 1 มีค่า F1-score เพียง 0.62 เท่านั้น

งานวิจัยในอนาคต ผู้วิจัยมีความสนใจที่จะนำวิธีการ Ensemble CNN (Shah *et al.*, 2023) มาเพื่อเพิ่มประสิทธิภาพของการจำแนกกล้วยไม้ใหม่เนื่องจากการใช้โมเดลของ CNN จำนวนที่มากกว่า 1 โมเดล และนำผลลัพธ์ของ CNN มาทำการเรียนรู้ด้วยวิธี Ensemble Learning อาจจะช่วยเพิ่มความสามารถในการจำแนกกล้วยไม้ได้ดีขึ้น แต่ทั้งนี้ อาจจะต้องเลือกใช้โมเดล CNN ตัวอื่น เช่น EfficientNet และ MobileNetV3 มาช่วยในการเรียนรู้รูปภาพกล้วยไม้ใหม่ ทั้งนี้ วิธี Fusion of RGB image (Kaya & Gürsoy, 2023) ก็เป็นอีกวิธีการหนึ่งที่น่าสนใจที่น่ารูปภาพไปประมวลผลก่อน (Pre-processing) จากนั้นจึงนำรูปภาพทั้งรูปต้นฉบับ (Original Image) และรูปภาพที่ผ่านการประมวลผล (Processing Image) มารวมกัน (Fusion) เพื่อส่งไปให้โมเดล CNN ทำการเรียนรู้

เอกสารอ้างอิง

- Butploy, N., & Boonying, S. (2020). Classification of Benjapakee Buddha amulets image by deep learning. *RMUTSB Academic Journal*, 8(1), 100-111. [In Thai]
- Kaewmongkol, J. & Kittilap, R. (2016). Guidelines for development of silk weaving of the silk weavers group In Khon Kaen. *Dhammathas Academic Journal*, 16(2), 67-74. <https://so06.tci-thaijo.org/index.php/dhammathas/article/view/78799> [In Thai]
- Kaya, Y., & Gürsoy, E. (2023). A novel multi-head CNN design to identify plant diseases using the fusion of RGB images. *Ecological Informatics*, 75. 101998. <https://doi.org/10.1016/j.ecoinf.2023.101998>
- Keereemek, P. (2016). กล้วยไม้ดินหมื่นอำเภอนบพิตำขอนแก่น [Mudmee silk, Amphoe Chonnabot Khon Kaen]. Retrieved from https://oer.learn.in.th/search_detail/result/28874 [In Thai]
- Kittinaradorn, C. (2020). *Convolutional neural network*. Retrieved from <https://guo-pai.github.io/ml-blog19.html> [In Thai]
- Kummong, R. (2022). Mangosteen detection using deep learning. *Information Technology Journal*, 18(1), 47-55. [In Thai]
- Kumpala, I., Wichapha, N., & Prasomsab, P. (2022). Sugar cane red stripe disease detection using YOLO CNN of deep learning technique. *Engineering Access*, 8(2), 192-197. <http://doi.org/10.14456/mijet.2022.25>

- Lapthanachai, N., Chomthong, A., Waijanya, S., & Promrit, N. (2023). Classification of nail abnormalities using convolutional neural network. *Journal of Applied Informatics and Technology*, 5(1), 18-35. <https://doi.org/10.14456/jait.2023.2> [In Thai]
- LeCun, Y. & Bengio, Y. (1995). Convolutional networks for images, speech, and time-series. *The handbook of brain theory and neural networks*. MIT Press. pp. 276-278. https://www.researchgate.net/publication/216792820_Convolutional_Networks_for_Images_Speech_and_Time-Series
- National News Bureau of Thailand. (2022). ศูนย์หม่อนไหมฯ ขอนแก่น ติดตามการผลิตเส้นไหม อ.โนนศิลา และ GAP หม่อนผล อ.อุบลรัตน์ และ GAP หม่อนใบ อ.พล จ.ขอนแก่น [Khon Kaen Sericulture Center follow up production of silk thread, Non Sila District and GAP mulberry fruit Ubolratana District and GAP mulberry Phon District, Khon Kaen]. Retrieved from <https://thainews.prd.go.th/th/news/detail/TCATG220420155320810>. [In Thai]
- Raksaard, N. & Surinta, O. (2018). Comparative study between local descriptors and deep learning for silk pattern image retrieval. *Science and Technology Journal Mahasarakham*, 37(6), 736-746. [In Thai]
- Saisangchan, U., Chamchong, R. & Suwannasa, A. (2022). Comparison of lime leaf disease analysis using deep learning. *Journal of Applied Informatics and Technology*, 4(1), 71-86. <https://doi.org/10.14456/jait.2022.6> [In Thai]
- Shah, A.A., Malik, H.A.M., Muhammad, A., Alourani, A., & Butt Z.A. (2023). Deep learning ensemble 2D CNN approach towards the detection of lung cancer. *Scientific Reports*, 13, 2987 (2023). <https://doi.org/10.1038/s41598-023-29656-z>
- Vaddi, R. & Manoharan, P. (2020). Hyperspectral image classification using CNN with spectral and spatial features integration. *Infrared Physics & Technology*, 107. <https://doi.org/10.1016/j.infrared.2020.103296>
- Ukwuoma, C.C., Qin, Z., Heyat, B.B., Akhtar, F., Bamisile, O., Muaad, A.Y., Addo, D., & Al-antari, M.A. (2023). A hybrid explainable ensemble transformer encoder for pneumonia identification from chest X-ray images. *Journal of Advanced Research*, 48, 191-211. <https://doi.org/10.1016/j.jare.2022.08.021>