

การจำแนกลายผ้าไทย 12 ลายด้วยเทคนิคการเรียนรู้เชิงลึก

Classification of 12 Thai Fabric Patterns Using Deep Learning Techniques

เฉลิมวุฒิ คำเมือง^{1*}, วัชรระ วงศา¹, ไพรัช จันทรงาม², ธราทิพย์ เกตุหอม² และ วรัชชา ทองแสน²

Chalermwut Comemuang^{1*}, Watchara Wongsat¹, Pairat Janngam², Tarathit Kethom² and Waratchaya Tongsan²

¹สาขาวิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยราชภัฏบุรีรัมย์ ประเทศไทย

²สาขาวิชาคณิตศาสตร์ คณะครุศาสตร์ มหาวิทยาลัยราชภัฏบุรีรัมย์ ประเทศไทย

¹ Department of Mathematics, Faculty of Science, Buriram Rajabhat University, Thailand

² Department of Mathematics, Faculty of Education, Buriram Rajabhat University, Thailand

Received : 21 August 2025, Received in revised form : 5 November 2025, Accepted : 19 November 2025

Available online : 21 November 2025

บทคัดย่อ

วัตถุประสงค์และที่มา: ผ้าทอไทยไม่เพียงแต่เป็นเครื่องนุ่งห่ม แต่ยังเป็นองค์ประกอบสำคัญของมรดกทางวัฒนธรรมที่จับต้องได้ของชาติไทย ซึ่งถักทอเรื่องราว ประวัติศาสตร์ ภูมิปัญญา และสะท้อนอัตลักษณ์ของชุมชนท้องถิ่นมาช้านาน การทอผ้าในประเทศไทยมีประวัติศาสตร์ย้อนกลับไปถึงยุคก่อนประวัติศาสตร์ โดยใช้วัสดุธรรมชาติอย่างฝ้ายและไหมในการสร้างสรรค์ ในแต่ละภูมิภาคลวดลายผ้าได้ถูกพัฒนาให้มีเอกลักษณ์เฉพาะตัว ซึ่งสะท้อนถึงสภาพแวดล้อม ความเชื่อทางศาสนา และโครงสร้างทางสังคม ลวดลายเหล่านี้จึงเปรียบเสมือนบันทึกทางประวัติศาสตร์ที่ไร้ตัวอักษร ทำหน้าที่ส่งต่อภูมิปัญญาจากรุ่นสู่รุ่น ทำให้ผ้าทอไทยกลายเป็นสินทรัพย์ทางวัฒนธรรมที่มีคุณค่ายิ่ง อย่างไรก็ตาม การอนุรักษ์ จัดเก็บ และจำแนกลวดลายผ้าทอที่มีความหลากหลายและซับซ้อนนั้นยังคงเป็นความท้าทายที่สำคัญ องค์ความรู้และความชำนาญในการจดจำลวดลายที่ซับซ้อนมักจำกัดอยู่ในกลุ่มช่างทออาวุโส ซึ่งมีความเสี่ยงที่จะสูญหายไปพร้อมกับ การลดจำนวนลงของช่างฝีมือเหล่านี้ นอกจากนี้ ความหลากหลายและความคล้ายคลึงกันของลายผ้าทำให้การจำแนกประเภทอย่างแม่นยำเป็นเรื่องยากสำหรับคนทั่วไป อุปสรรคเหล่านี้ไม่เพียงแต่เป็นข้อจำกัดในการจัดทำฐานข้อมูลที่เป็นมาตรฐาน แต่ยังส่งผลกระทบต่อการศึกษา และการต่อยอดในเชิงพาณิชย์อีกด้วย ด้วยความท้าทายดังกล่าว งานวิจัยนี้จึงนำเสนอการศึกษาความเป็นไปได้ในการประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์ (AI) โดยเฉพาะอย่างยิ่งการเรียนรู้เชิงลึก เพื่อพัฒนาระบบจำแนกลายผ้าไทย เทคโนโลยีการเรียนรู้เชิงลึกและโครงข่ายประสาทเทียมที่มีความสามารถโดดเด่นในการจดจำและวิเคราะห์รูปแบบภาพ ซึ่งเหมาะสมอย่างยิ่งกับการจำแนกรายละเอียดที่ซับซ้อนของลวดลายบนผืนผ้า การประยุกต์ใช้เทคโนโลยีนี้สอดคล้องกับแนวโน้มระดับสากลในการใช้ AI เพื่อการอนุรักษ์มรดกทางวัฒนธรรม และเป็นการวางรากฐานทางเทคโนโลยีที่สำคัญสำหรับการจัดทำคลังข้อมูลดิจิทัล การอนุรักษ์มรดก และการเผยแพร่องค์ความรู้ให้กว้างขวางยิ่งขึ้น

วิธีดำเนินการวิจัย: ในการดำเนินงานวิจัยนี้ได้มีการรวบรวมชุดข้อมูลภาพลายผ้าไทย 12 ลาย ประกอบด้วย ลายกระจับ, ลายขาเบี่ยง, ลายคมห้า, ลายดอกกรักราชกัญญา, ลายนกยูง, ลายฟองน้ำ, ลายมูลสีคราม, ลายเมล็ดข้าวผสมดอกดาวเรือง,

ลายวชิรภักดิ์, ลายหมีคั่นนาคนาโบราณ, ลายแห และลายโสรั้ง โดยแต่ละลายมีจำนวน 120 ภาพ รวมทั้งสิ้น 1,440 ภาพ ชุดข้อมูลทั้งหมดได้ผ่านกระบวนการเตรียมข้อมูลเพื่อให้มีความเหมาะสมและเพิ่มความทนทานของแบบจำลอง เริ่มตั้งแต่การปรับขนาดภาพทั้งหมดให้เป็น 224x224 พิกเซล การปรับปรุงคอนทราสต์โดยใช้เทคนิคการปรับสมดุลฮิสโตแกรม กับช่องความสว่าง (Y) เพื่อให้ลายผ้าโดดเด่นขึ้น การลดสัญญาณรบกวนด้วยฟิลเตอร์ bilateral เพื่อรักษาความคมชัดของขอบลายผ้า การเพิ่มความคมชัดของขอบด้วยฟิลเตอร์ kernel เพื่อช่วยให้โมเดลตรวจจับลักษณะเฉพาะได้ง่ายขึ้น และการทำให้เป็นมาตรฐาน โดยปรับค่าสีของพิกเซลให้อยู่ในช่วง 0.0 ถึง 1.0 นอกจากนี้ยังมีการใช้เทคนิคการเพิ่มข้อมูล เช่น การหมุนภาพและการพลิกภาพ เพื่อป้องกันการเกิดภาวะการเรียนรู้เกิน จากนั้นชุดข้อมูลถูกแบ่งออกเป็นชุดสำหรับฝึกสอนและตรวจสอบ 80% (1,152 ภาพ) และชุดสำหรับทดสอบ 20% (288 ภาพ) งานวิจัยนี้ได้ประเมินประสิทธิภาพของโมเดลการเรียนรู้เชิงลึก 6 รูปแบบที่แตกต่างกัน ได้แก่ Custom_CNN: แบบจำลองที่ออกแบบขึ้นโดยเฉพาะสำหรับงานวิจัยนี้ VGG16: โมเดลที่มีโครงสร้างเรียบง่ายแต่มีความลึก 16 ชั้น ResNet50: โมเดลลึก 50 ชั้นที่ใช้เทคนิค Residual Connections เพื่อแก้ปัญหาการเลือนหายของเกรเดียน MobileNetV2: โมเดลน้ำหนักเบาที่ออกแบบมาสำหรับอุปกรณ์พกพา InceptionV3: โมเดลที่สามารถสกัดคุณลักษณะได้จากหลายระดับขนาดภายในชั้นเดียวกัน DenseNet121: โมเดลที่โดดเด่นด้วยการเชื่อมต่อแบบหนาแน่นเพื่อส่งเสริมการนำคุณลักษณะกลับมาใช้ใหม่

ผลการวิจัย: ผลการทดลองบนชุดข้อมูลทดสอบชี้ให้เห็นว่าโมเดล Custom_CNN มีประสิทธิภาพสูงสุด โดยมีความแม่นยำโดยรวมสูงถึง 99.65% สามารถทำนายภาพได้ถูกต้อง 287 ภาพจาก 288 ภาพ ตามมาด้วยโมเดล VGG16 ที่มีความแม่นยำ 99.31% และ DenseNet121 ที่ 98.61% ในทางตรงกันข้าม โมเดล ResNet50 กลับให้ประสิทธิภาพต่ำที่สุดอย่างมีนัยสำคัญที่ 81.25% โดยทำนายภาพผิดพลาดถึง 54 ภาพ

สรุปผลการวิจัย: ผลการวิจัยนี้แสดงให้เห็นถึงความสำคัญของการเลือกโมเดลที่เหมาะสมกับลักษณะของชุดข้อมูล การที่โมเดล Custom_CNN ซึ่งมีโครงสร้างไม่ซับซ้อนสามารถให้ประสิทธิภาพสูงสุดได้นั้น อาจอธิบายได้ว่าชุดข้อมูลลายผ้าไทยเป็นชุดข้อมูลที่มีความเฉพาะทางสูงและมีคุณภาพดี ทำให้โมเดลที่มีความซับซ้อนมากเกินไปอย่าง ResNet50 ซึ่งออกแบบมาสำหรับชุดข้อมูลที่ใหญ่และหลากหลายกว่าอย่าง ImageNet อาจเกิดภาวะการเรียนรู้เกิน กล่าวคือ โมเดลที่ซับซ้อนเกินไปอาจเริ่มจดจำรายละเอียดของข้อมูลฝึกฝนแทนที่จะเรียนรู้คุณลักษณะทั่วไปของลายผ้า ความลึกที่มากเกินไปและคุณลักษณะระดับสูงที่เรียนรู้มาจากชุดข้อมูลอื่นอาจไม่เหมาะสมกับคุณลักษณะเชิงพื้นผิวที่ละเอียดอ่อนของลายผ้า ทำให้โมเดลไม่สามารถปรับตัวเข้ากับงานใหม่ได้ดี งานวิจัยนี้ไม่เพียงแต่แสดงให้เห็นถึงความสำเร็จในการสร้างระบบจำแนกลายผ้าไทย 12 ชนิดที่มีความแม่นยำสูง แต่ยังเป็นการวางรากฐานทางเทคโนโลยีที่สำคัญสำหรับการสร้างคลังข้อมูลดิจิทัลเพื่อการอนุรักษ์มรดกทางวัฒนธรรมและเผยแพร่องค์ความรู้ให้กว้างขวางยิ่งขึ้น ข้อค้นพบนี้ยังเน้นย้ำว่าโมเดลที่ดีที่สุดไม่จำเป็นต้องเป็นโมเดลที่ซับซ้อนที่สุดเสมอไป แต่คือโมเดลที่เหมาะสมกับลักษณะของปัญหาและชุดข้อมูลมากที่สุด

คำสำคัญ : การเรียนรู้เชิงลึก ; โครงข่ายประสาทเทียม ; ลายผ้า

Abstract

Background and Objectives: Thai woven textiles are not merely garments but are a vital component of the nation's tangible cultural heritage, weaving together the stories, history, wisdom, and reflecting the identity of local communities over a long period. The history of weaving in Thailand dates back to prehistoric times, using natural materials such as cotton and silk. In each region, textile patterns have been developed with unique characteristics that reflect the environment, religious beliefs, and social structures. These patterns are thus like non-textual historical records, serving to pass down wisdom from generation to generation, making Thai textiles an invaluable cultural asset. However, the conservation, storage, and classification of the diverse and complex patterns of these textiles remain a significant challenge. The knowledge and expertise in recognizing complex patterns are often limited to a group of elderly weavers, who are at risk of this knowledge being lost as their numbers decline. Furthermore, the variety and similarity among patterns make accurate classification difficult for the general public. These obstacles are not only a limitation in creating a standardized database but also impact education and commercial development. To address these challenges, this research presents a feasibility study on the application of Artificial Intelligence (AI) technology, particularly Deep Learning, to develop a classification system for Thai textile patterns. Deep learning technology and convolutional neural networks have outstanding capabilities in recognizing and analyzing visual patterns, which is highly suitable for classifying the complex details of patterns on fabric. The application of this technology aligns with the international trend of using AI for the conservation of cultural heritage and lays an important technological foundation for creating a digital database, preserving heritage, and disseminating knowledge more widely.

Methodology: The research utilized a dataset of 12 Thai textile patterns, comprising Lai Krajap, Lai Kha Pia, Lai Khom Ha, Lai Dok Rak Ratchakanya, Lai Nok Yung, Lai Fong Nam, Lai Mun Si Khram, Lai Met Khao Phasom Dok Daoruang, Lai Wachiraphak, Lai Mi Khan Nak Boran, Lai Hae, and Lai Sarong. There were 120 images for each pattern, totaling 1,440 images. The entire dataset underwent a data preparation process to ensure its suitability and to enhance model robustness. This began with resizing all images to 224x224 pixels. Contrast was enhanced using the Histogram Equalization technique on the luma (Y) channel to make the textile patterns more prominent. Noise was reduced using a bilateral filter to preserve the sharpness of the pattern edges. Edge sharpness was enhanced using a kernel filter to help the model detect specific features more easily. Normalization was performed by adjusting the pixel color values to a range of 0.0 to 1.0. Additionally, data augmentation techniques such as image rotation and flipping were used to prevent overfitting. The dataset was then split into a training and validation set of 80% (1,152 images) and a test set of 20% (288 images). This research evaluated the performance of six different deep

learning models was evaluated Custom_CNN: A model designed specifically for this research. VGG16: A model with a simple structure but with a depth of 16 layers. ResNet50: A deep 50-layer model that uses Residual Connections to solve the vanishing gradient problem. MobileNetV2: A lightweight model designed for mobile devices. InceptionV3: A model that can extract features from multiple scales within the same layer. DenseNet121: A model distinguished by its dense connectivity to promote feature reuse.

Main Results: The experimental results on the independent test set indicate that the Custom_CNN model had the highest performance, with an overall accuracy of 99.65%, followed by VGG16 at 99.31%. In contrast, the ResNet50 model yielded the lowest performance, with a significantly lower accuracy of 81.25%, making 54 incorrect predictions.

Conclusions: These research findings demonstrate the importance of selecting a model that is appropriate for the characteristics of the dataset. The fact that the Custom_CNN model, which has a less complex structure, could achieve the highest performance can be explained by the highly specialized and high-quality nature of the Thai fabric dataset. This caused overly complex models like ResNet50, which was designed for larger and more diverse datasets like ImageNet, to potentially suffer from overfitting. That is, an overly complex model may start to memorize the details of the training data instead of learning the general features of the patterns. The excessive depth and high-level features learned from other datasets may not be suitable for the delicate texture-based features of the fabric patterns, causing the model to adapt poorly to the new task. This research not only demonstrates the successful creation of a highly accurate classification system for 12 types of Thai textile patterns but also lays an important technological foundation for creating a digital database for cultural heritage preservation and wider knowledge dissemination. This finding also emphasizes that the best model is not necessarily the most complex one, but rather the model that is most suitable for the nature of the problem and the dataset.

Keywords : deep learning ; Convolutional Neural Networks ; textile patterns

*Corresponding author. E-mail : chalermwut.cm@bru.ac.th

Introduction

ผ้าทอไทยมิได้เป็นเพียงเครื่องนุ่งห่ม แต่เป็นมรดกทางวัฒนธรรมที่จับต้องได้ซึ่งถักทอเรื่องราว ประวัติศาสตร์ และอัตลักษณ์ของชาติไทยมายาวนาน การทอผ้าในประเทศไทยมีร่องรอยย้อนกลับไปได้ถึงยุคก่อนประวัติศาสตร์ โดยมีการใช้วัสดุจากธรรมชาติ เช่น ฝ้ายและไหม มาสร้างสรรค์เป็นผืนผ้าเพื่อตอบสนองความต้องการพื้นฐานในการดำรงชีวิต ในแต่ละภูมิภาคของประเทศ ลวดลายผ้าได้ถูกพัฒนาให้มีเอกลักษณ์เฉพาะตัว สะท้อนถึงสภาพแวดล้อม ความเชื่อทางศาสนา พิธีกรรม และ

โครงสร้างทางสังคมของชุมชนผู้สร้างสรรค์ ลวดลายบนผืนผ้าจึงเปรียบเสมือนบันทึกทางประวัติศาสตร์ที่ไว้ตัวอักษร บอกเล่าเรื่องราวและส่งต่อภูมิปัญญาจากรุ่นสู่รุ่น ทำให้ผ้าทอไทยกลายเป็นสินทรัพย์ทางวัฒนธรรมที่มีคุณค่าสูงยิ่ง แม้ว่าผ้าทอไทยจะมีความสำคัญอย่างยิ่ง แต่การอนุรักษ์และสืบสานองค์ความรู้กำลังเผชิญกับความท้าทายหลายประการ ความรู้ความชำนาญในการทอและการจดจำลวดลายที่ซับซ้อนมักจำกัดอยู่ในกลุ่มช่างทออาวุโส ซึ่งมีความเสี่ยงที่จะสูญหายไปเมื่อช่างฝีมือเหล่านี้ลดจำนวนลง นอกจากนี้ ความหลากหลายของลวดลายที่มีอยู่เป็นจำนวนมาก และความคล้ายคลึงกันในบางลวดลาย ทำให้การจำแนกประเภทอย่างถูกต้องแม่นยำกลายเป็นเรื่องยากสำหรับบุคคลทั่วไปหรือแม้แต่ นักวิชาการที่ไม่ได้เชี่ยวชาญโดยตรง อุปสรรคเหล่านี้ไม่เพียงแต่เป็นข้อจำกัดในการจัดทำระบบฐานข้อมูลและแคตตาล็อกที่เป็นมาตรฐาน แต่ยังส่งผลกระทบต่อการศึกษาวิจัย การออกแบบ และการต่อยอดในเชิงพาณิชย์อีกด้วย

ในยุคดิจิทัล เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence: AI) โดยเฉพาะอย่างยิ่งการเรียนรู้เชิงลึก (Deep Learning) และโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNNs) ได้กลายเป็นเครื่องมือที่มีศักยภาพสูงในการปฏิวัติวงการอนุรักษ์มรดกทางวัฒนธรรม เทคโนโลยีเหล่านี้มีความสามารถโดดเด่นในการจดจำและวิเคราะห์รูปแบบภาพ (Visual Pattern Recognition) ซึ่งเหมาะสมอย่างยิ่งกับการนำมาประยุกต์ใช้กับงานที่ต้องการความแม่นยำในการจำแนกรายละเอียดที่ซับซ้อน เช่น ลวดลายบนผืนผ้า ในระดับสากล มีการนำ AI ไปใช้ในงานด้านมรดกวัฒนธรรมอย่างแพร่หลาย ตั้งแต่การบูรณะโบราณวัตถุที่เสียหาย การจำแนกประเภทศิลปวัตถุในพิพิธภัณฑ์ ไปจนถึงการวิเคราะห์เอกสารโบราณ การประยุกต์ใช้เทคโนโลยีเหล่านี้จึงเป็นการเปิดประตูสู่ความเป็นไปได้ใหม่ ๆ ในการสร้าง มรดกดิจิทัล (Digital Heritage) ที่สามารถเข้าถึงและศึกษาได้โดยคนรุ่นหลังอย่างยั่งยืน

งานวิจัยที่ผ่านมาได้แสดงให้เห็นว่าการประมวลผลภาพด้วยโครงข่ายประสาทเทียมแบบ convolutional (CNN) สามารถจำแนกลายผ้าได้อย่างมีประสิทธิภาพ (Cychnerski *et al*, 2017; Poonsilp, 2018; Hussain *et al*, 2020; Albelwi, 2022; Ghosh & Gupta, 2023; Ingo *et al.*, 2023; Mbonu *et al*, 2025; Muangkarn *et al*, 2025) Chaichana *et al.* (2022) ได้ใช้โมเดล ResNet50 ในการจำแนกลายผ้าย้อมครามเชิงภูมิศาสตร์ (GI) จำนวน 216 ลาย พบว่าได้ความแม่นยำสูงสุดถึง 93% นอกจากนี้ ในด้านวิจัยเกี่ยวกับภาพทั่วโลก โครงข่ายประสาทเทียมเชิงลึกยังถูกพัฒนามาอย่างต่อเนื่อง He *et al.* (2016) แสดงให้เห็นว่าโครงข่าย Residual (ResNet) ที่มีความลึกมากทำให้ได้ผลลัพธ์ดีเยี่ยมบนชุดข้อมูล ImageNet อย่างไรก็ตาม งานวิจัยส่วนใหญ่ยังคงมุ่งเน้นไปที่สถาปัตยกรรม CNN เป็นหลัก การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกแขนงอื่น ๆ เช่น Generative Adversarial Networks (GANs) สำหรับการสังเคราะห์ลายผ้าเพื่อเพิ่มข้อมูล หรือ Vision Transformers (ViT) ซึ่งกำลังเป็นที่นิยมใน การจำแนกภาพ ยังมีจำกัดในบริบทของผ้าไทย งานวิจัยนี้จึงมุ่งเน้นที่การเปรียบเทียบประสิทธิภาพของสถาปัตยกรรม CNN ที่หลากหลาย (ทั้งแบบสร้างเองและแบบ Transfer Learning) เพื่อสร้างแบบจำลองพื้นฐาน (baseline model) ที่มีประสิทธิภาพสูงสุดสำหรับชุดข้อมูลลายผ้าไทย 12 ลายนี้

ด้วยเหตุนี้ การนำเทคนิคการเรียนรู้เชิงลึกมาประยุกต์ใช้กับการจำแนกลายผ้าไทยทั้ง 12 แบบ จึงเป็นประเด็นที่น่าสนใจศึกษาเป็นอย่างยิ่ง ทั้งในด้านการพัฒนาชุดข้อมูลเฉพาะสำหรับลายผ้าไทยและการเปรียบเทียบประสิทธิภาพของ

สถาปัตยกรรมโมเดลต่าง ๆ งานวิจัยนี้จึงมุ่งเน้นการรวบรวมข้อมูลภาพถ่ายผ้าไทย 12 ลาย และประเมินผลการจำแนกโดยใช้โมเดล deep learning 6 แบบ รวมทั้งวิเคราะห์ประสิทธิภาพเพื่อระบุโมเดลที่ให้ผลดีที่สุด

Methodology

การวิจัยนี้มีกระบวนการวิเคราะห์ข้อมูล 5 ขั้นตอนหลักดังแสดงในแผนภาพ (Figure X) และใช้เครื่องมือวิจัย (Tools) ได้แก่ ภาษา Python, ไลบรารี TensorFlow และ Keras ในการสร้างโมเดล, OpenCV (cv2) ในการประมวลผลภาพ, และ Scikit-learn ในการแบ่งและประเมินข้อมูล การพัฒนาระบบการเรียนรู้เชิงลึกในงานวิจัยนี้ ใช้ผ้าทอไทย 12 ชนิด ได้แก่ ลายกระจับ, ลายขาเป๋, ลายคَمْห้ำ, ลายดอกกรักราชกัญญา, ลายนกยูง, ลายพองน้ำ, ลายมูลสีคราม, ลายเมล็ดข้าวผสมดอกดาวเรือง, ลายวชิรภักดิ์, ลายหมี่คั่นนาคโบราณ, ลายแห และลายโล่ธง ลายละ 120 ภาพ รวมทั้งสิ้น 1,440 ภาพ โมเดล Transfer Learning (VGG16, ResNet50 ฯลฯ) ได้ใช้ค่าน้ำหนักที่เรียนรู้ล่วงหน้า (pre-trained weights) จากชุดข้อมูล ImageNet ซึ่งเป็นชุดข้อมูลภาพขนาดใหญ่มาตรฐาน การใช้ค่าน้ำหนักจาก ImageNet ช่วยให้โมเดลมีความสามารถในการสกัดคุณลักษณะพื้นฐานของภาพ (เช่น ขอบ, พื้นผิว) มาก่อน ซึ่งสามารถนำมาปรับใช้กับงานจำแนกลายผ้าไทยได้

กระบวนการเตรียมข้อมูลได้ดำเนินการเพื่อให้ข้อมูลมีความเหมาะสมต่อการนำเข้าแบบจำลอง CNN และเพื่อเพิ่มความทนทานของแบบจำลอง ดังนี้

1. อ่านรูปภาพ เป็นการโหลดข้อมูลรูปภาพจากไฟล์เข้ามาในหน่วยความจำเพื่อเตรียมพร้อมสำหรับการประมวลผลในขั้นตอนต่อไป



Figure 1 Sample Images from the Dataset

2. การปรับขนาดภาพ (Image Resizing) ภาพถ่ายทั้งหมดถูกปรับขนาดให้เป็น 224x224 พิกเซล ซึ่งเป็นขนาดมาตรฐานที่ใช้กันอย่างแพร่หลายสำหรับโมเดล CNN ที่ผ่านการฝึกสอนล่วงหน้าบนชุดข้อมูล ImageNet การกำหนดขนาดภาพให้เท่ากันทั้งหมดช่วยให้แบบจำลองสามารถประมวลผลข้อมูลได้อย่างสม่ำเสมอ



0

Figure 2 Images Processed by Resizing

3. ปรับปรุงคอนทราสต์ (Contrast Enhancement) แปลงสีของรูปภาพจาก BGR (Blue-Green-Red) ไปเป็น YUV ซึ่งเป็นการแยกช่องความสว่าง (Luma - Y) ออกจากช่องสี (Chroma - U, V) ใช้เทคนิค Histogram Equalization กับช่องความสว่าง (Y) เพียงช่องเดียว เพื่อกระจายระดับความสว่างของพิกเซลให้สม่ำเสมอทั่วทั้งภาพ ทำให้ส่วนที่มืดหรือสว่างเกินไปมีรายละเอียดที่ชัดเจนขึ้น เพื่อเพิ่มความคมชัดและความแตกต่างระหว่างส่วนมืดและส่วนสว่างในรูปภาพ ทำให้ลายผ้าไทยโดดเด่นและมองเห็นได้ง่ายขึ้น



Figure 3 Images processed with Contrast Enhancement

4. ลดสัญญาณรบกวน (Noise Reduction) ใช้ฟิลเตอร์ bilateral เพื่อลดสัญญาณรบกวน (Noise) ที่ไม่ต้องการในรูปภาพ ฟิลเตอร์ชนิดนี้มีความพิเศษคือสามารถลดสัญญาณรบกวนในบริเวณที่เป็นพื้นผิวเรียบ ๆ ได้ดี โดยยังคงรักษาความคมของขอบ (Edges) ของวัตถุไว้ ซึ่งสำคัญมากสำหรับการแยกลายผ้าไทย



Figure 4 Images processed with Noise-reduced

5. เพิ่มความคมชัดของขอบ (Edge Enhancement) ใช้ฟิลเตอร์ kernel เพื่อเน้นขอบของลวดลายในภาพให้คมชัดยิ่งขึ้น การทำให้ขอบของลวดลายผ้าชัดขึ้น จะช่วยให้โมเดลสามารถตรวจจับและเรียนรู้ลักษณะเฉพาะของแต่ละลายได้ง่ายและแม่นยำขึ้น




Figure 5 Images processed with Edge Enhancement

6. การทำให้เป็นมาตรฐาน (Normalization) ปรับค่าสีของแต่ละพิกเซล ซึ่งเดิมมีค่าอยู่ในช่วง 0 ถึง 255 ให้กลายเป็นค่าศนียมในช่วง 0.0 ถึง 1.0 โดยการหารด้วย 255.0 เป็นขั้นตอนมาตรฐานในการเตรียมข้อมูลสำหรับโมเดล การเรียนรู้เชิงลึก เพื่อช่วยให้โมเดลฝึกสอนได้เร็วขึ้น มีเสถียรภาพ และลดโอกาสเกิดปัญหาทางคณิตศาสตร์ระหว่างการคำนวณ




Figure 6 Images processed with Normalized Image

การเพิ่มข้อมูล (Data Augmentation) เพื่อป้องกันการเกิดภาวะการเรียนรู้เกิน (Overfitting) และเพิ่มความสามารถในการจำแนกภาพที่มีความหลากหลายในโลกความเป็นจริง เทคนิคการเพิ่มข้อมูลได้ถูกนำมาใช้ในระหว่างการฝึกสอนแบบจำลอง ซึ่งรวมถึงการหมุนภาพแบบสุ่ม (Random Rotations) การพลิกภาพในแนวนอนและแนวตั้ง (Flips) และการปรับเปลี่ยนความสว่างและคอนทราสต์ของภาพแบบสุ่ม

การแบ่งข้อมูล (Data Splitting): ชุดข้อมูลทั้งหมด 1,440 ภาพ ถูกแบ่งออกเป็นชุดข้อมูลสำหรับฝึกสอนและตรวจสอบความถูกต้อง (Training and Validation Set) จำนวน 80% (1,152 ภาพ) และชุดข้อมูลสำหรับทดสอบ (Test Set) จำนวน 20% (288 ภาพ) โดยในชุดข้อมูลทดสอบจะมีภาพของแต่ละหมวดหมู่จำนวน 24 ภาพเท่า ๆ กัน

เพื่อทำการประเมินอย่างครอบคลุม การวิจัยนี้ทำการทดลองเปรียบเทียบโมเดล 6 แบบ ดังนี้

1. Custom_CNN: เป็นแบบจำลองพื้นฐานที่ถูกออกแบบขึ้นโดยเฉพาะสำหรับงานวิจัยนี้ ประกอบด้วยชั้นคอนโวลูชัน (Convolutional Layers) ชั้นพูลลิง (Pooling Layers) และชั้นเชื่อมต่อสมบูรณ์ (Dense Layers)
2. VGG16: เป็นโมเดลที่มีชื่อเสียงและได้รับการยอมรับอย่างกว้างขวาง โดดเด่นด้วยโครงสร้างที่เรียบง่ายและสม่ำเสมอ แต่มีความลึก 16 ชั้น โดยใช้ตัวกรอง (Filter) ขนาด 3x3 ซ้อนกันเป็นชั้นเล็ก ๆ (Simonyan & Zisserman, 2014)
3. ResNet50: เป็นโมเดลที่มีความลึก 50 ชั้น และใช้เทคนิคการเชื่อมต่อแบบเหลือ (Residual Connections) เพื่อช่วยแก้ปัญหาการเลือนหายของเกรเดียนต์ (Vanishing Gradient Problem) ในโครงข่ายที่ลึกมาก (Ermata et al., 2024)
4. MobileNetV2: เป็นโมเดลน้ำหนักเบาที่ออกแบบมาเพื่อการใช้งานบนอุปกรณ์พกพาและระบบสมองกลฝังตัว โดยใช้เทคนิค Depthwise Separable Convolutions เพื่อลดจำนวนพารามิเตอร์และการคำนวณ (Sandler et al., 2018)
5. InceptionV3: เป็นโมเดลที่ใช้ Inception Module ซึ่งเป็นแนวคิดที่ช่วยให้แบบจำลองสามารถทำการสกัดคุณลักษณะได้จากหลายระดับขนาด (multi-scale) ภายในชั้นเดียวกัน (Viswanath, 2020)
6. DenseNet121: เป็นโมเดลที่โดดเด่นด้วยแนวคิดการเชื่อมต่อแบบหนาแน่น (Dense Connectivity) โครงข่ายเชื่อมต่อแบบหนาแน่น 121 ชั้น โดยแต่ละชั้นจะรับข้อมูลจากทุกชั้นก่อนหน้ามาเป็นอินพุต แนวคิดนี้ส่งเสริมการนำคุณลักษณะกลับมาใช้ใหม่ (Feature Reuse) และช่วยให้แบบจำลองมีจำนวนพารามิเตอร์น้อยลง (Albelwi, 2022)

แบบจำลองทั้ง 6 รูปแบบได้รับการฝึกสอนภายใต้เงื่อนไขที่เป็นมาตรฐานเดียวกันเพื่อการเปรียบเทียบที่เป็นธรรม โมเดลทั้งหมดฝึกสอน โดยใช้ Adam optimizer ด้วยอัตราการเรียนรู้ (learning rate) 0.001, ฟังก์ชันสูญเสีย categorical crossentropy, ขนาด batch (batch size) 16, และฝึกสอนสูงสุด 50 epochs, EarlyStopping หยุดการฝึกสอนหาก val_loss ไม่ดีขึ้น 15 epochs, ReduceLROnPlateau ลดอัตราการเรียนรู้หาก val_loss ไม่ดีขึ้น 10 epochs ModelCheckpoint บันทึกเฉพาะโมเดล ที่มี val_loss ต่ำที่สุดนอกจากนี้ ยังใช้ Callbacks เพื่อควบคุมการฝึกสอน และใช้ Categorical Cross-Entropy เป็นฟังก์ชันการสูญเสีย (Loss Function) ซึ่งเหมาะสมกับงานจำแนกประเภทแบบหลายคลาส (Ghosh & Gupta, 2023)

Results

จากการประเมินผลบนชุดข้อมูลทดสอบจำนวน 288 ภาพ โมเดลทั้ง 6 แบบ ให้ผลลัพธ์ด้านความแม่นยำดังแสดงใน Table 1

Table 1 Summary of Overall Model Performance in Thai Fabric Pattern Classification

Model Name	Overall Accuracy (%)	Correctly Predicted Images	Incorrectly Predicted Images
Custom_CNN	99.65	287	1
VGG16	99.31	286	2
DenseNet121	98.61	284	4
MobileNetV2	98.26	283	5
InceptionV3	94.10	271	17
ResNet50	81.25	234	54

จาก Table 1 เห็นได้อย่างชัดเจนว่าโมเดล Custom_CNN ให้ประสิทธิภาพสูงสุด ตามมาด้วย VGG16 และ DenseNet121 ในขณะที่ ResNet50 มีประสิทธิภาพต่ำที่สุดค่อนข้างน่าประหลาดใจ เพื่อให้เห็นภาพที่ลึกซึ้งยิ่งขึ้น Table 2 ได้แสดงค่าความแม่นยำรายประเภทของแต่ละโมเดล

Table 2 Comparison of Per-Class Accuracy (%) for Each Model

Fabric Pattern	Custom_CNN	VGG16	ResNet50	MobileNetV2	InceptionV3	DenseNet121
Lai Dok Rak Ratcha Kan Ya	100.00	91.67	91.67	95.83	95.83	91.67
Lai Fong Nam	100.00	95.83	62.50	100.00	95.83	100.00
Lai Hae	100.00	100.00	83.33	95.83	100.00	100.00
Lai Kha Pia	100.00	100.00	83.33	95.83	100.00	100.00
Lai Khom Ha	100.00	100.00	66.67	100.00	100.00	100.00
Lai Kra Jap	100.00	100.00	79.17	100.00	95.83	100.00
Lai Ma Let Khao	100.00	100.00	87.50	100.00	95.83	100.00
Lai Mee Kan Nak Bo Ran	100.00	100.00	100.00	100.00	100.00	100.00
Lai Moon See Kram	100.00	100.00	70.83	95.83	95.83	100.00
Lai Nok Yoong	95.83	100.00	79.17	95.83	91.67	100.00
Lai So Rong	100.00	100.00	91.67	100.00	100.00	100.00
Lai Wa Chi Ra Pak	100.00	95.83	79.17	95.83	83.33	100.00

Table 2 แสดงให้เห็นว่า โมเดลส่วนใหญ่มีค่าความแม่นยำโดยรวมสูง แต่ประสิทธิภาพในการจำแนกลายผ้าแต่ละชนิดนั้นแตกต่างกันอย่างมีนัยสำคัญ Custom_CNN และ DenseNet121 สามารถจำแนกความหลากหลายของลายผ้าไทยได้ดีที่สุด ในขณะที่ ResNet50 แสดงให้เห็นถึงข้อจำกัดในการแยกแยะลายผ้าที่มีความละเอียดอ่อนหรือซับซ้อน

Discussion

จาก Table 1 และ Table 2 แสดงให้เห็นว่า โมเดล Custom_CNN ซึ่งเป็นโมเดลที่มีความลึกน้อยกว่า สามารถทำ ความแม่นยำได้สูงสุดที่ 99.65% สามารถอธิบายได้ว่าชุดข้อมูลลายผ้าไทย แม้จะมีความหลากหลาย แต่ก็ เป็นชุดข้อมูลที่มีความเฉพาะทางสูง (Domain-specific) และมีคุณภาพดี (ภาพชัดเจน, จัดวางดี) ความแปรปรวนภายในแต่ละคลาส (Intra-class variance) ค่อนข้างต่ำเมื่อเทียบกับชุดข้อมูลขนาดใหญ่อย่าง ImageNet ที่มีถึง 1,000 คลาสที่แตกต่างกันอย่างสิ้นเชิง โมเดลที่มีความซับซ้อนสูงและลึกมาก เช่น ResNet50 ซึ่งถูกออกแบบมาเพื่อแก้ปัญหาที่ยากกว่าบน ImageNet จึงมีแนวโน้มที่จะเกิดการเรียนรู้เกิน (Overfitting) เมื่อนำมาใช้กับชุดข้อมูลที่ง่ายกว่า กล่าวคือ โมเดลมีความจุ (Capacity) มากเกินไปจนเริ่มจดจำรายละเอียดของข้อมูลฝึกฝนแทนที่จะเรียนรู้คุณลักษณะทั่วไปที่สามารถนำไปใช้กับข้อมูลที่ไม่เคยเห็นได้ ในทางตรงกันข้าม โมเดล Custom_CNN ที่มีความจุพอเหมาะ สามารถเรียนรู้คุณลักษณะที่จำเป็นในการจำแนกลายผ้าได้อย่างมีประสิทธิภาพโดยไม่เกิดการเรียนรู้เกิน ซึ่งสะท้อนให้เห็นถึงหลักการที่สำคัญว่า โมเดลที่ดีที่สุดคือโมเดลที่เหมาะสมกับปัญหาที่สุด ไม่ใช่โมเดลที่ซับซ้อนที่สุดเสมอไป

ผลการทดลองที่ต่ำอย่างผิดปกติของ ResNet50 (ร้อยละ 81.25) ถือเป็นกรณีศึกษาที่สำคัญ โมเดล ResNet ได้รับการสร้างขึ้นเพื่อแก้ปัญหาคือการเสื่อมถอยของประสิทธิภาพในเครือข่ายที่ลึกมาก ๆ ผ่านการใช้ Shortcut Connection แต่สำหรับปัญหานี้ ซึ่งชุดข้อมูลมีขนาดเล็กและไม่หลากหลายและโมเดลไม่จำเป็นต้องลึกถึง 50 ชั้น กลไกที่เคยเป็นจุดแข็งกลับกลายเป็นจุดอ่อน ความลึกที่มากเกินไปประกอบกับคุณลักษณะระดับสูงที่เรียนรู้มาจาก ImageNet (เช่น คุณลักษณะสำหรับจำแนกรถยนต์หรือสัตว์) อาจไม่เกี่ยวข้องหรือไม่เหมาะสมกับคุณลักษณะเชิงพื้นผิว (Texture) ที่ละเอียดอ่อนของลายผ้า ทำให้โมเดลไม่สามารถปรับตัวเข้ากับงานใหม่ได้ดีเท่าที่ควร

แม้ว่าโมเดล Custom_CNN จะให้ความแม่นยำสูงถึง 99.65% แต่ผลลัพธ์นี้ควรพิจารณาในบริบทของข้อจำกัดหลายประการ

1. ขนาดชุดข้อมูล: ชุดข้อมูลมีขนาดเล็กค่อนข้าง (1,440 ภาพ) ซึ่งอาจไม่เพียงพอที่จะรับประกันว่าโมเดลจะสามารถสรุปผล (generalize) ได้ดีในสถานการณ์จริง
2. สภาพแวดล้อมที่ควบคุม (Controlled Environment): ภาพที่ใช้ในการทดลองเป็นภาพที่ถ่ายในสภาพแวดล้อมที่ค่อนข้างควบคุม (ภาพชัด, ไม่มีสิ่งรบกวน) ความแม่นยำที่สูงมากนี้อาจลดลงอย่างมีนัยสำคัญเมื่อนำโมเดลไปใช้กับภาพถ่ายลายผ้าในโลกจริง (real-world data) ที่มีสภาพแสง, มุมกล้อง, การยับของผ้า, หรือคุณภาพของภาพที่แตกต่างออกไป

3. ความเสี่ยงของ Overfitting: แม้จะใช้ Validation Set และ Early Stopping ความแม่นยำที่เกือบสมบูรณ์บนชุดทดสอบ (99.65%) อาจยังคงสะท้อนถึงการที่โมเดลเรียนรู้ลักษณะเฉพาะของชุดข้อมูลนี้ได้ดีเกินไป มากกว่าที่จะเรียนรู้คุณลักษณะทั่วไปของลายผ้า

Conclusions

งานวิจัยนี้แสดงให้เห็นถึงศักยภาพของโครงข่ายประสาทเทียมในการจำแนกอัตลักษณ์ลายผ้าไทย 12 ชนิดด้วยความแม่นยำสูง ผลการศึกษาเชิงเปรียบเทียบระหว่างโมเดล 6 แบบที่แตกต่างกันได้เผยให้เห็นข้อค้นพบที่สำคัญว่า โมเดล Custom_CNN ที่มีโครงสร้างเรียบง่ายและได้รับการออกแบบมาโดยเฉพาะ สามารถให้ประสิทธิภาพที่เหนือกว่าโมเดล Pre-trained ที่มีความซับซ้อนและลึกกว่าอย่าง VGG16, ResNet50, MobileNetV2, InceptionV3 และ DenseNet121 โดยเฉพาะอย่างยิ่งกรณีของ ResNet50 ที่มีประสิทธิภาพต่ำอย่างมีนัยสำคัญ ได้ชี้ให้เห็นว่าความซับซ้อนของโมเดลที่มากเกินไปอาจเป็นผลเสียต่อการเรียนรู้บนชุดข้อมูลที่มีความเฉพาะทางสูงและมีขนาดจำกัด การวิเคราะห์ข้อผิดพลาดยังแสดงให้เห็นว่าลักษณะทางทัศนศิลป์ของลวดลายแต่ละชนิด ไม่ว่าจะเป็นลายเรขาคณิต ลายรูปธรรม หรือลายที่เกิดจากกระบวนการย้อม ล้วนมีผลโดยตรงต่อความสามารถในการจำแนกของโมเดล

Acknowledgments

งานวิจัยนี้ได้รับทุนสนับสนุนจากสำนักงานคณะกรรมการส่งเสริมวิทยาศาสตร์ วิจัยและนวัตกรรม (สกสว.) และมหาวิทยาลัยราชภัฏวชิรวิทยาคาร งบประมาณสนับสนุนงานพื้นฐาน Fundamental fund ประจำปีงบประมาณ 2568 ขอขอบคุณสำหรับการสนับสนุนและข้อเสนอแนะในการเก็บข้อมูลวิจัยครั้งนี้เป็นอย่างดี

References

- Albelwi, S. A. (2022). Deep Architecture based on DenseNet-121 Model for Weather Image Recognition. *International Journal of Advanced Computer Science and Applications*, 13(10), 559-565.
- Chaichana, C., Wongkalasin, S., & Jiamram, C. (2022). A Development of Information Retrieval System of Indigo Fabric Pattern with Deep Learning Techniques. *UTK RESEARCH JOURNAL*, 16(1), 68–83. (in Thai)
- Cychnerski, J., Brzeski, A., & Trojanowicz, M. (2017). Clothes detection and classification using convolutional neural networks. *IEEE International Conference on Image Processing (ICIP)*.

- Ermatita, Noprisson, H., & Abdiansah. (2024). Palembang songket fabric motif image detection with data augmentation based on ResNet using dropout. *Bulletin of Electrical Engineering and Informatics*, 13(3), 1991-1999.
- Ghosh, J., & Gupta, S. (2023). ADAM Optimizer and CATEGORICAL CROSSENTROPY Loss Function-Based CNN Method for Diagnosing Colorectal Cancer. In *2023 International Conference on Computational Intelligence and Sustainable Engineering Solutions (CISES)*. (pp. 470–474). IEEE.
- 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*. (pp. 770-778).
- Hussain, M., Khan, S. D., & Ahmad, J. (2020). Woven fabric pattern recognition and classification based on deep convolutional neural networks. *Electronics*, 9(6), 1048.
- Ingo, N., Phatichaikiart, B., & Tongleamnak, S. (2023). Thai Silk Patterns Classification with Deep Neural Networks. *Journal of Applied Informatics and Technology*, 5(2), 116-129.(in Thai)
- Mbonu, C. E., Anigbogu, K., Asogwa, D., & Belonwu, T. (2025). *An Explorative Analysis of SVM Classifier and ResNet50 Architecture on African Food Classification*. arXiv preprint arXiv:2505.13923.
- Muangkarn, P., Suanoom, C., & Phopan, W. (2025). Designing Cotton Weaving Patterns Using Mathematical Knowledge of Boolean Operations. *Asian Creative Architecture, Art and Design: ACAAD*, 38(1), 1-15. (in Thai)
- Poonsilp, K. (2018). The Development of Thai Local Woven Fabric Pattern Recognition. *Veridian E-Journal, Silpakorn University*, 11(3), 2056-2068. (in Thai)
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4510-4520.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.

Viswanath. C. Burkapalli, & Priyadarshini. C. Patil. (2020). An efficient food image classification by inception-V3 based cnns. *International Journal of Scientific & Technology Research*, 9(3), 6987–6992.