

Received: 2 พ.ค. 2567

Revised: 13 พ.ย. 2567

Accepted: 18 พ.ย. 2567

การปรับปรุงภาพโดยใช้ฮาร์เวฟเลตสำหรับจำแนกโรคใบสตรอเบอรี่ ด้วยโครงข่ายประสาท
แบบคอนโวลูชัน

Image Enhancement using Haar Wavelet for Image Classification of Diseases on
Strawberry Leaves with Convolutional Neural Networks

สุทธวีร์ วงศ์สารภี¹ และ วุฒิชัย ปวงมณี^{1*}

¹สาขาวิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์และเทคโนโลยี มหาวิทยาลัยนอร์ท-เชียงใหม่

Sutthawee Wongsarapee¹ and Wutthichai Puangmanee^{1*}

¹Department of Computer Engineering, Faculty of Engineering and Technology

North-Chiang Mai University

*Corresponding author E-mail: wutichai@northcm.ac.th

Abstract

The classification of diseases on strawberry leaves is interesting and important in agriculture. It can help enhance the efficiency of disease management and pesticide management for diseases such as leaf spot, leaf blight, and powdery mildew. The photographs need to be clear because each disease on the strawberry leaves has distinct characteristics. This article proposes a method to improve the efficiency of strawberry leaf disease classification with Convolutional Neural Networks (CNNs), using the Haar wavelet for image enhancement. A total of 2,192 images of strawberry leaves were used, and the results were compared with images that did not use the Haar wavelet method. Training is conducted for 300 and 500 epochs. The experimental results showed that the proposed method increased accuracy from 94.61% to 96.08% and the F1-Score from 94.89% to 96.33% for 300 epochs, using a processing time of 36 minutes, and from 95.59% to 97.44% and the F1-Score from 95.65% to 97.63% for 500 epochs, using a processing time of 62 minutes.

Keywords: *Convolutional neural network; Haar wavelet; Data augmentation; Leaf spot; Leaf scorch; Powdery mildew*

บทคัดย่อ

วิธีการจำแนกเพื่อตรวจสอบโรคบนใบสตรอเบอรี่เป็นเรื่องที่น่าสนใจและมีความสำคัญในด้านการเกษตร ซึ่งสามารถช่วยเพิ่มประสิทธิภาพในการจัดการโรคและสารป้องกันกำจัดศัตรูพืช เช่น โรคจุดด่างก โรคใบไหม้และโรคราแป้ง ภาพถ่ายจึงต้องมีความคมชัดเพราะแต่ละโรคบนใบสตรอเบอรี่มีลักษณะที่แตกต่างกัน บทความนี้เสนอวิธีการปรับปรุงประสิทธิภาพการจำแนกภาพใบสตรอเบอรี่ด้วยโครงข่ายคอนโวลูชันสำหรับการจำแนกโรคบนใบสตรอเบอรี่ โดยใช้วิธีฮาร์เวฟเล็ทสำหรับการปรับปรุงภาพ ใช้ภาพใบสตรอเบอรี่ทั้งหมดจำนวน 2,192 ภาพ เปรียบเทียบกับภาพที่ไม่ใช้วิธีฮาร์เวฟเล็ททำการฝึกสอน 300 และ 500 รอบ ผลการทดลองพบว่าวิธีที่นำเสนอเพิ่มประสิทธิภาพความแม่นยำสูงขึ้นในการฝึกสอน 300 รอบ จากร้อยละ 94.61 เป็นร้อยละ 96.08 และค่า F1-Score จากร้อยละ 94.89 เพิ่มขึ้นร้อยละ 96.33 ใช้เวลาในการประมวลผล 36 นาทีและในการฝึกสอน 500 รอบ จากร้อยละ 95.59 เป็นร้อยละ 97.44 และ F1-Score จากร้อยละ 95.65 เพิ่มขึ้นร้อยละ 97.63 ใช้เวลาประมวลผล 62 นาที

คำสำคัญ : โครงข่ายคอนโวลูชัน; วิธีฮาร์เวฟเล็ท; โรคจุดด่างก; โรคใบไหม้; โรคราแป้ง

1. บทนำ

โรคที่เกิดขึ้นกับใบของต้นสตรอเบอรี่เป็นอีกหนึ่งปัญหาที่มีความสำคัญอย่างมากในอุตสาหกรรมเกษตร เพราะจะส่งผลกระทบต่อผลผลิต ซึ่งแนวทางในการแก้ไขปัญหานี้สามารถใช้วิธีการจำแนกภาพอาการของโรคและปัจจุบันมีการนำเอาวิธีการเรียนรู้เชิงลึก (Deep learning) มาใช้กันอย่างแพร่หลาย โดยประสิทธิภาพในการจำแนกและความแม่นยำจะขึ้นอยู่กับจำนวนของข้อมูลและความคมชัดของภาพ การปรับปรุงคุณภาพของภาพจึงเป็นอีกขั้นตอนที่สำคัญเพื่อให้สามารถจำแนกโรคได้อย่างแม่นยำและมีประสิทธิภาพ

การเรียนรู้เชิงลึกโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Networks : CNNs) (Y. Lecun, et al., 2019) ได้รับความนิยมเป็นอย่างมากสำหรับการนำมาใช้ในการจำแนกโรคบนใบพืช (Andre da Silva Abade, et al., 2019 ; M. I. Dinata, 2021 ; ภาณุวัฒน์ เมฆะ และคณะ, 2566 ; A. D. Ermolaev, 2024) ซึ่งมีความแตกต่างกันทั้งในด้านการปรับแต่งสถาปัตยกรรมที่ออกแบบสำหรับชุดข้อมูลตามความเหมาะสมในด้านประสิทธิภาพ จำนวนข้อมูลและ

ความคมชัดของภาพ เพื่อให้สถาปัตยกรรมสามารถสกัดคุณลักษณะ (Feature extraction) ที่ได้ผลลัพธ์ที่ดี มีความแม่นยำสูงสำหรับการจำแนกโดย นัศพ์ชาณัน ชินปัญชรณะ (2566) รายงานว่าการใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อจำแนกโรคใบมะเขือเทศได้ค่าความถูกต้องที่ร้อยละ 87.96% ซึ่งจะเห็นได้ว่าการนำโครงข่ายประสาทเทียมแบบคอนโวลูชันได้รับความนิยมเป็นอย่างมากในการนำมาจำแนกภาพ เพราะมีความสามารถในการเรียนรู้คุณลักษณะของภาพ

การปรับปรุงภาพ (Image Enhancement) มีอยู่หลายวิธีด้วยกันซึ่งก็ขึ้นอยู่กับนำไปประยุกต์ใช้งานเพื่อเพิ่มประสิทธิภาพในการเรียนรู้ Wiangsamut, et al. (2017) เสนอวิธีการปรับปรุงคุณภาพภาพถ่ายนิ้วมือที่ถ่ายด้วยเครื่องสแกนเพื่อให้การตรวจสอบลายนิ้วมือมีความแม่นยำยิ่งขึ้น โดยใช้วิธี Short Time Fourier Transform (STFT) และตัวกรองกาเบอร์ (Gabor filtering) วิธีการนี้สามารถลดสัญญาณรบกวนและเพิ่มความคมชัดของลายนิ้วมือได้ Akira Taguchi (2017) ทำการสำรวจการปรับปรุงภาพสี โดยเน้นการปรับปรุงภาพให้มีความคมชัดและสีที่สวยงาม มีการใช้เทคนิคต่าง ๆ เช่น Histogram Equalization, Gamma Correction และ Retinex Algorithm เพื่อปรับปรุงคุณภาพของภาพสี ผลที่ได้สามารถทำให้ภาพสีมีคุณภาพสูงขึ้นและเป็นประโยชน์ในหลายสาขา เช่น การแพทย์ การบันเทิง และการสื่อสาร ซึ่งต้องการภาพที่มีความคมชัดและสีที่ถูกต้อง Sripuangsuwan, et al. (2024) เสนอเทคนิคการปรับปรุงภาพโดยการแบ่งส่วนฮิสโตแกรม โดยใช้ค่าสูงสุดในพื้นที่เฉพาะ (Local maxima) ประกอบด้วยการวิเคราะห์ฮิสโตแกรมของภาพเพื่อหาจุดที่มีค่าสูงสุดในแต่ละส่วน จากนั้นใช้ข้อมูลเหล่านี้ในการปรับปรุงภาพให้มีความชัดเจนและความละเอียดสูงขึ้น จะเห็นว่าการปรับปรุงภาพมีความสำคัญอย่างมากในการเพิ่มประสิทธิภาพและส่งผลให้การจำแนกภาพมีความแม่นยำและประสิทธิภาพสูงขึ้น

การประยุกต์ใช้วิธีฮาร์เวฟเลตมีนักวิจัยจำนวนมากที่นำมาใช้ในการปรับปรุงข้อมูล เช่น R. Lionnie และ M. Alaydrus (2016) เสนอการวิเคราะห์โดยใช้วิธีการแปลงฮาร์เวฟเลต เพื่อระบุรูปแบบของเส้นผมที่มีลักษณะเด่นทางแอนโดรยีน (Androgenic hair pattern recognition) ที่ทำลายเส้นผมและเกี่ยวข้องกับการเสริมสร้างฮอร์โมน O. Y. Fai, et al. (2016) เสนอการใช้ค่าสัมประสิทธิ์ของคลื่นเวฟเลต (Wavelet coefficients) ในการจำแนกประเภทของภาพเพื่อการควบคุมการตรวจสอบวิดีโอ โดยจะเน้นการวิเคราะห์ภาพจากกล้องโทรทัศน์เพื่อตรวจจับการเคลื่อนไหวหรือเหตุการณ์ที่สำคัญและ Y. Jusman, et al. (2022) ใช้วิธีการแปลงฮาร์เวฟเลตเพื่อตรวจจับภาพที่เกี่ยวข้องกับ Covid-19 โดยใช้ลักษณะของเนื้อหยา (Texture based) ในภาพสำหรับ

แยกแยะลักษณะเฉพาะของภาพที่เกี่ยวข้องกับโรคและการจำแนกประเภทของภาพในงานตรวจจับภาพทางการแพทย์ ซึ่งพบว่าการนำวิธีฮาร์เวฟเลตสำหรับการประมวลผลภาพดิจิทัล (Image processing) ให้ผลลัพธ์อยู่ในระดับที่ดีมาก โดยปัญหาที่พบเมื่อนำภาพมาจากหลายแหล่งข้อมูลจะมีความแตกต่างกัน เช่น สี แสงและขนาดของภาพ เมื่อนำมาทำการเตรียมความพร้อมของข้อมูล โดยทำการปรับขนาดของภาพให้เท่ากันทั้งหมดก่อนนำไปประมวลผลในขั้นตอนต่อไป ภาพที่มีขนาดใหญ่และแสดงรายละเอียดภายในภาพได้ชัดเจนเมื่อปรับขนาดภาพให้เล็กลงรายละเอียดภายในภาพจะมีขนาดเล็กลงตามไปด้วย ซึ่งส่งผลต่อประสิทธิภาพในการจำแนก (นัศพชาณัณ ชินปัญชชนะ, 2566) ถึงแม้ว่าปัจจุบันจะมีผู้เสนอการใช้สถาปัตยกรรม YOLOv8 (S. G. E. Brucal. et al., 2023; S. A. A. Qadri et al., 2023) สำหรับการติดตามและจำแนกโรคบนใบพืช แต่ด้วยความต้องการทรัพยากรในการประมวลผลที่สูงและต้องใช้ข้อมูลการฝึกสอนจำนวนมาก ซึ่งการรวบรวมและสร้างชุดข้อมูลที่เพียงพอสำหรับการฝึกสอนนั้นอาจใช้เวลาามากและมีค่าใช้จ่ายสูง

จากที่ได้กล่าวไปข้างต้นพบว่าในขั้นตอนการเตรียมข้อมูลจะใช้วิธีการปรับขนาด (Resize) ของภาพให้เท่ากันก่อนนำไปประมวลผลซึ่งจะทำให้ภาพสูญเสียรายละเอียดภายในภาพ ดังนั้นเมื่อใช้วิธีฮาร์เวฟเลตสำหรับการปรับปรุงภาพและปรับขนาดภาพสามารถช่วยเพิ่มประสิทธิภาพในการจำแนกโรคบนใบของพืช ในบทความนี้ผู้วิจัยจึงเสนอแนวทางการใช้วิธีฮาร์เวฟเลตในการปรับปรุงภาพก่อนที่จะนำไปประมวลผลในโครงข่ายประสาทเทียมแบบคอนโวลูชัน ผลลัพธ์ที่ได้จากงานวิจัยนี้อาจมีความสำคัญในการพัฒนาเทคโนโลยีทางการเกษตร โดยช่วยเพิ่มความแม่นยำในการตรวจสอบและจำแนกโรคบนใบสตรอเบอรี่ สามารถนำไปประยุกต์ใช้ในการจัดการและวางแผนการดูแลรักษาต้นสตรอเบอรี่ให้ปลอดจากโรคต่าง ๆ ที่ส่งผลกระทบต่อผลผลิตต่อไป

2. วัตถุประสงค์ของงานวิจัย

2.1 เพื่อปรับปรุงคุณภาพของภาพโดยใช้วิธีฮาร์เวฟเลตสำหรับเพิ่มประสิทธิภาพในการจำแนกโรคบนใบสตรอเบอรี่

3. วิธีดำเนินการ

งานวิจัยนี้เป็นการประยุกต์ใช้วิธีฮาร์เวฟเลตสำหรับปรับปรุงภาพรวมกับการใช้สถาปัตยกรรมโครงข่ายประสาทแบบคอนโวลูชัน สำหรับการฝึกสอน (Training) การทดสอบ (Testing) และการ

ตรวจสอบ (Validation) ในการจำแนกโรคบนใบสตรอเบอรี่โดยใช้อุปกรณ์ เครื่องมือและทฤษฎีที่เกี่ยวข้องดังนี้

3.1 อุปกรณ์และเครื่องมือที่ใช้ในงานวิจัย

3.1.1 เครื่องคอมพิวเตอร์หน่วยประมวลผลกลาง (CPU) Core-i7 แรม (RAM) 16 GB และการ์ดจอ (GPU) 4 GB

3.1.2 ซอฟต์แวร์ใช้ภาษา Python เวอร์ชัน 3.9, Tensor Flow เวอร์ชัน 2.10.0 และ Keras เวอร์ชัน 2.10.0

3.2 ชุดข้อมูล (Data set)

ในการทดลองและทดสอบใช้ชุดข้อมูลภาพจำนวน 4 ชุด ประกอบด้วยชุดข้อมูลภาพใบสตรอเบอรี่ปกติที่ไม่ติดโรค โรคจุดตานก (Leaf spot) โรคใบไหม้ (Bacterial leaf scorch) และโรคราแป้ง (Powdery mildew) แต่ละชุดข้อมูลภาพจะมีความแตกต่างกันในด้านความคมชัด แสงสว่าง ความละเอียด ขนาดของภาพและจำนวนภาพ โดยใช้ภาพทั้งหมดจำนวน 2,192 ภาพ แสดงตัวอย่างดังภาพที่ 1



(ก) ใบสตรอเบอรี่ปกติที่ไม่ติดโรค



(ข) โรคจุดตานก



(ค) โรคใบไหม้



(ง) โรคราแป้ง

ภาพที่ 1 ตัวอย่างภาพใบสตรอเบอรี่ ชุดข้อมูลทั้ง 4 ชุด

จากภาพที่ 1 (ก)- (ข) มีขนาดเท่ากัน 256x256 พิกเซล (Nikit Kashyap, 2022) และภาพที่ 1 (ค) - (ง) มีขนาดเท่ากัน ขนาด 416x416 พิกเซล (Afzaal, et al., 2021) ภาพที่ 1 (ก) ใบสตรอเบอรี่ที่ไม่ติดโรค จะใช้เป็นชุดข้อมูลสำหรับเพิ่มประสิทธิภาพในการทดสอบเพื่อประเมินประสิทธิภาพและความแม่นยำในการจำแนก เนื่องจากเป็นภาพที่ไม่ปรากฏโรคใด ๆ บนใบสตรอเบอรี่ซึ่งมีความคล้ายคลึงกับภาพที่ 1 (ง) โรคราแป้ง ซึ่งมีลักษณะเป็นสีขาวหรือสีเทา คล้ายกับราที่ปกคลุมบนใบหรือใต้ใบสตรอเบอรี่ หากทำการเปรียบเทียบโดยมีบริเวณที่ติดโรคมิขนาดเล็กลงจะมีความใกล้เคียงเป็นอย่างมากกับใบที่ไม่ติดโรค อีกทั้งเมื่อมีการลดขนาดภาพหรือปรับขนาดของภาพให้มีขนาดที่เท่ากันของชุดข้อมูลภาพทั้ง 4 ชุดแล้วนั้น หากรายละเอียดของโรคบนใบสตรอเบอรี่ลดลงก็จะส่งผลกับความแม่นยำในการจำแนกด้วย

3.3 การแปลงฮาร์เวฟเลต (Haar wavelet transform)

การแปลงฮาร์เวฟเลต (Gonzalez, R. C., & Woods, R. E, 2008: 474) เป็นวิธีที่ใช้ในการแยกสัญญาณเป็นส่วนย่อย ๆ ในการวิเคราะห์ภาพจะทำการแบ่งภาพเป็นส่วนย่อยขนาดเล็กและการปรับปรุงภาพจะดำเนินการโดยการลดระดับสัญญาณรบกวนที่ไม่จำเป็นออกจากภาพ เพื่อให้ภาพมีความชัดเจนมากขึ้น สามารถแสดงได้ในรูปแบบเมทริกซ์ $A = HBH$ โดยที่ B คือ เมทริกซ์ของภาพขนาดความกว้างและความสูง $N \times N$ และ H คือ เมทริกซ์ $N \times N$ ของการแปลงฮาร์เวฟเลต A คือ ผลลัพธ์การแปลง $N \times N$ ที่มีฟังก์ชันการแปลงพื้นฐาน โดยที่ $h_k(Z)$ กำหนดไว้ตามช่วงระยะเวลาเมื่อ $Z \in [0, 1]$ สำหรับ $k = 0, 1, 2, \dots, N-1$ เมื่อ $N = 2^n$ เพื่อที่จะสร้าง H โดยที่ k ถูกกำหนด $k=2^p+q-1$ โดยที่ $0 \leq p \leq n-1$, $q = 0$ หรือ 1 สำหรับ $p=0$ และ $1 \leq q \leq 2^p$ กรณีที่ $p \neq 0$ ฟังก์ชันพื้นฐานการแปลงฮาร์เวฟเลตแสดงดังสมการที่ (1) และ (2)

$$h_0(Z) = h_{00}(z) = \frac{1}{\sqrt{N}}, \quad z \in [0, 1] \quad (1)$$


$$h_k(Z) = h_{pq}(Z) = \frac{1}{\sqrt{N}} \begin{cases} 2^{p/2} & (q-1)/2^p \leq z < (q-0.5)/2^p \\ -2^{p/2} & (q-0.5)/2^p \leq z < q/2^p, \\ 0 & \text{otherwise: } z \in [0, 1] \end{cases} \quad (2)$$

แถวที่ 3 ของ $N \times N$ เมทริกซ์การแปลงฮาร์เวฟเลตจะมียอดประกอบของ $h_k(Z)$ เมื่อ $Z=0/N, 1/N, 2/N, \dots, (N-1)/N$ สมมติตัวอย่าง ขนาด $N \times N$ หรือ 4×4 เมทริกซ์ของการแปลงฮาร์เวฟเลตดังสมการที่ (3)


$$H_4 = \frac{1}{\sqrt{4}} \begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & 1 & -1 & -1 \\ \sqrt{2} & -\sqrt{2} & 0 & 0 \\ 0 & 0 & \sqrt{2} & -\sqrt{2} \end{bmatrix} \quad (3)$$

การแปลงเวฟเลตแบบแยกแต่ละแถวของภาพ จะถูกกรองด้วยตัวกรองความถี่ต่ำผ่าน (Low pass filter) และตัวกรองความถี่สูงผ่าน (High pass filter) โดยที่เอาต์พุตของตัวกรองแต่ละตัวจะถูกสุ่มตัวอย่าง เพื่อสร้างภาพระดับกลาง L และ H เมื่อ L คือ ภาพต้นฉบับที่กรองผ่านความถี่ต่ำและสุ่มตัวอย่างในทิศทาง X และ H คือ ภาพต้นฉบับที่กรองผ่านความถี่สูงและสุ่มตัวอย่างในทิศทาง X หลังจากนั้นแต่ละคอลัมน์ของรูปภาพใหม่จะถูกกรองด้วยฟิลเตอร์ผ่านความถี่ต่ำและความถี่สูง (LH และ HH) และสุ่มตัวอย่างเพื่อสร้างภาพย่อยจำนวนสี่ภาพ (LL, LH, HL และ HH) แสดงดังภาพที่ 2 (ก) และภาพที่ถูกแบ่งทั้งสี่ส่วน สามารถนำมารวมกันเพื่อสร้างภาพที่ส่งออกโดยมีจำนวนตัวอย่าง

เท่ากับภาพต้นฉบับ ดังภาพที่ 2 (ข) โดยที่ LL เป็นภาพต้นฉบับผ่านการกรองความถี่ต่ำในทิศทางแนวนอนและแนวตั้ง



ภาพที่ 2 (ก) 1-Layer (Single level decomposition) (ข) 2-Layer (Two level decomposition) (ค) 3-Layer (Three level decomposition)




ภาพที่ 3 บล็อกไดอะแกรมการทำงานการแปลงเวฟเล็ต

ดังภาพที่ 3 ขั้นตอนต่อไปเมื่อ HL เป็นตัวกรองความถี่สูงผ่านในทิศทางแนวตั้งและ LH เป็นตัวกรองความถี่สูงผ่านในทิศทางแนวนอนและ HH เป็นตัวกรองความถี่สูงผ่านทั้งในทิศทางแนวนอนและแนวตั้ง โดยภาพแถบความถี่ย่อยทั้ง 4 ภาพ ประกอบด้วยข้อมูลทั้งหมดที่มีอยู่ในภาพต้นฉบับ แต่ลักษณะที่กระจายกระจายของแถบย่อย LH, HL และ HH ที่อธิบายไว้ข้างต้นจะถูกนำไปใช้กับรูปภาพ LL อีกครั้ง ทำให้เกิดภาพแถบความถี่ย่อยใหม่ 4 ภาพ ดังภาพที่ 2 (ค) โดยงานวิจัยนี้เลือกใช้ ดังภาพที่ 2 (ข) 2-Layer (Two level decomposition)

3.4 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks :


CNNs)

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Y. Lecun, et al., 1998) เป็นโมเดลการเรียนรู้เชิงลึกที่ได้รับความนิยมในการประมวลผลภาพและวิดีโอ การออกแบบอาจประกอบไปด้วยหนึ่งชั้นหรือหลายชั้นและประกอบรวมกับชั้นเชื่อมต่อสมบูรณ์ (Fully connected layer) ในชั้นสุดท้าย โดยให้ผลลัพธ์ที่ดีกว่าโครงสร้างการเรียนรู้เชิงลึกแบบอื่น ๆ แสดงดังภาพที่ 4



ภาพที่ 4 สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน

ในงานวิจัยนี้ได้ออกแบบสถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน ดังภาพที่ 4 โดยกำหนดขนาดของภาพสำหรับอินพุตขนาด 150x150 พิกเซล มีทั้งหมด 7 ชั้น ใช้ฟังก์ชันกระตุ้น ReLU (Rectified linear unit) มีพารามิเตอร์ทั้งหมด 1,081,025 พารามิเตอร์และคลาสที่ใช้ในการทำนายจำนวน 4 คลาส ประกอบด้วย ภาพใบปกติไม่ติดโรค ภาพใบโรคจุดตาข่าย ภาพใบโรคใบไหม้ และภาพใบโรคราแป้ง โดยวิธีที่เสนอในบทความนี้แสดงขั้นตอนการทำงานประกอบด้วยขั้นตอนการทำงานหลัก 2 ขั้นตอน แสดงดังภาพที่ 5



ภาพที่ 5 ขั้นตอนการทำงานการจำแนกโรคบนใบสตรอเบอรี่

จากภาพที่ 5 เริ่มต้นจากรับภาพอินพุตไบสโตรอเบอร์ขนาด 256x256 พิกเซลและ 416x416 พิกเซล ทำการลดขนาดภาพและปรับปรุงภาพด้วยวิธีฮาร์เวฟเล็ท ด้วยขั้นตอนการลดขนาดของภาพ เมื่อรายละเอียดภายในภาพมีขนาดเล็กและต้องทำการลดขนาดของภาพลง ก่อนส่งต่อไปยังโครงข่ายประสาทแบบคอนโวลูชันที่ออกแบบไว้ หากภาพนั้นมีรายละเอียดไม่ชัดเจนอาจจะส่งผลอย่างมากต่อประสิทธิภาพในการฝึกสอนและความแม่นยำในการทำนายคลาสที่กำหนดไว้

3.4 การวัดประสิทธิภาพโมเดล

การประเมินประสิทธิภาพของโมเดลในการจำแนกข้อมูลจะใช้รูปแบบตาราง Confusion matrix (Tom Fawcett, 2006) โดยเป็นการวัดผลจากข้อมูลที่ได้ในการจำแนกที่ถูกต้องและทำการสรุปผลของการจำแนกที่ได้แสดงตัวอย่างดังตารางที่ 1

ตารางที่ 1 Confusion matrix

ประเภทเหตุการณ์		ผลการจำแนก (Predicted)		ผลรวมการจำแนก
		Negative (PN)	Positive (PP)	
ผลที่เกิดขึ้น (Actual)	Negative (N)	TN	FP	TN+FP
	Positive (P)	FN	TP	FN+TP
ผลรวมการจำแนก		TN+FN	FP+TP	TN+FN+FP+TP

จากข้อมูลที่แสดงในตารางที่ 1 โดย

TP (True positive) คือ จำนวนภาพที่ถูกต้องที่ตรวจพบได้ถูกต้อง

TN (True negative) คือ จำนวนภาพที่ถูกต้องที่ตรวจพบไม่ถูกต้อง

FP (False positive) คือ จำนวนภาพที่ตรวจพบได้แต่ไม่ถูกต้อง

FN (False negative) คือ จำนวนภาพที่ตรวจพบไม่ได้แต่ถูกต้อง

สามารถเขียนเป็นสมการในการคำนวณเพื่อประเมินประสิทธิภาพโมเดลได้ดังนี้

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad (4)$$

$$Precision = \frac{TP}{TP + FP} \quad (5)$$


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

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (7)$$

โดยสมการที่ (4) ค่า Accuracy คือ ค่าความถูกต้องในการจำแนกภาพจากข้อมูลภาพทั้งหมดที่ใช้ในการทดสอบ สมการที่ (5) ค่า Precision คือ ค่าความแม่นยำในการทำนายของกลุ่มเป้าหมาย สมการที่ (6) ค่า Recall คือ อัตราส่วนหรือจำนวนความถูกต้องในการจำแนกข้อมูลกลุ่มเป้าหมายเป็นจริง (True Positive Rate : TPR) สมการที่ (7) ค่า F1-Score คือ ค่าระหว่างความแม่นยำในการทำนายของกลุ่มเป้าหมาย (Precision) และจำนวนความถูกต้องในการจำแนกข้อมูลกลุ่มเป้าหมาย (Recall)

4. ผลการศึกษา


การทดลองใช้วิธีแบ่งข้อมูลภาพทั้งหมดในสัดส่วน 70:15:15 ประกอบด้วยชุดข้อมูลสำหรับการฝึกสอน การทดสอบและชุดข้อมูลการตรวจสอบ ของข้อมูลภาพทั้ง 4 ชุด จำนวน 2,192 ภาพ ประกอบด้วย ชุดข้อมูลฝึกสอนจำนวน 1,534 ภาพ ชุดข้อมูลทดสอบจำนวน 329 ภาพและชุดข้อมูลตรวจสอบจำนวน 329 ภาพ โดยภาพที่ใช้ในการทดลองและทดสอบนั้นมีภาพอยู่ 2 ขนาดด้วยกัน คือ ขนาด 256x256 พิกเซลและ 416x416 พิกเซล จะต้องทำการปรับขนาดของภาพให้เท่ากันทั้งหมด โดยขั้นตอนการใช้วิธีฮาร์วเฟลิตส์สำหรับการลดขนาดและปรับปรุงภาพ ทำการเปรียบเทียบกับ การลดขนาดภาพโดยไม่ใช้วิธีฮาร์วเฟลิตส์ เพื่อให้ได้ขนาดของภาพ 150x150 พิกเซล ก่อนนำไปประมวลผลในขั้นตอนต่อไป แสดงตัวอย่างดังภาพที่ 6



(ก) ภาพต้นฉบับ (ข) ภาพที่ไม่ใช้วิธีฮาร์เวฟเลต (ค) ภาพที่ใช้วิธีฮาร์เวฟเลต


ภาพที่ 6 ภาพตัวอย่างเปรียบเทียบการปรับลดขนาดกับภาพต้นฉบับ

ดังภาพที่ 6 จะเห็นว่าเมื่อทำการลดขนาดภาพให้ได้ขนาด 150x150 พิกเซล ภาพที่ 6 (ข) ภาพที่ไม่ใช้วิธีฮาร์เวฟเลตมีความคมชัดต่ำกว่าภาพที่ 6 (ค) ภาพที่ใช้วิธีฮาร์เวฟเลต โดยสถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ออกแบบสำหรับการจำแนกใบสตรอเบอรี่ ได้กำหนดค่าอัตราการเรียนรู้ (Learning rate) ที่ 0.001 ค่า Batch size (Kandel & Castelli, 2020) เท่ากับ 16 และจำนวนรอบสูงสุดในการเรียนรู้ (Maximum epoch) จำนวน 300 และ 500 รอบ (Epoch) โดยทำการทดลองจำนวน 4 ครั้ง ผลลัพธ์ที่ได้แสดงดังภาพที่ 7




(ก) จำนวน 300 รอบ (Epoch) ข้อมูลชุดที่ 1 ภาพปกติ


ภาพที่ 7 กราฟผลลัพธ์จำนวนรอบการเรียนรู้ 300 และ 500 รอบ ของข้อมูลชุดที่ 1 และ 2



(ข) จำนวน 500 รอบ (Epoch) ข้อมูลชุดที่ 1 ภาพปกติ




(ค) จำนวน 300 รอบ (Epoch) ข้อมูลชุดที่ 2 ภาพที่ผ่านการปรับปรุงด้วยวิธีฮาร์เวฟเล็ต



(ง) จำนวน 500 รอบ (Epoch) ข้อมูลชุดที่ 2 ภาพที่ผ่านการปรับปรุงด้วยวิธีฮาร์เวฟเล็ต


ภาพที่ 7 กราฟผลลัพธ์จำนวนรอบการเรียนรู้ 300 และ 500 รอบ ของข้อมูลชุดที่ 1 และ 2 (ต่อ)

จากการทดลองดังภาพที่ 7 ได้ทำการสรุปในตารางที่ 2 เมื่อพิจารณาจากผลลัพธ์ที่ได้จะเห็นว่าจำนวนรอบการเรียนรู้ 500 รอบ มีความแม่นยำที่สูงกว่าจำนวนรอบการเรียนรู้ 300 รอบ แต่เวลาในการประมวลผลก็เพิ่มขึ้นเช่นกัน การปรับปรุงด้วยวิธีฮาร์เวฟเลตสามารถช่วยลดการสูญเสียรายละเอียดบางประการภายในภาพและยังคงมีรายละเอียดใกล้เคียงกับภาพต้นฉบับมากที่สุด โดยค่า Confusion Matrix ของการจำแนกภาพเปรียบเทียบระหว่างข้อมูลชุดที่ 1 และ 2 แสดงดังภาพที่ 8



(ก) จำนวน 300 รอบ ข้อมูลชุดที่ 1

(ข) จำนวน 500 รอบ ข้อมูลชุดที่ 1



(ค) จำนวน 300 รอบ ข้อมูลชุดที่ 2

(ง) จำนวน 500 รอบ ข้อมูลชุดที่ 2

ภาพที่ 8 Confusion Matrix เปรียบเทียบการจำแนก (ก) - (ข) ข้อมูลชุดที่ 1 ภาพปกติ
(ค) - (ง) ข้อมูลชุดที่ 2 ภาพที่ใช้วิธีฮาร์เวฟเลต

ดังภาพที่ 8 (ก) จะเห็นว่า ค่า TP เท่ากับ 2,074 ค่า TN เท่ากับ 97 และภาพที่ 8 (ค) ค่า TP เท่ากับ 2,098 เพิ่มขึ้นและค่า TN เท่ากับ 84 ลดลง สำหรับรอบการเรียนรู้ 300 รอบ และรอบการ

เรียนรู้จำนวน 500 รอบ ดังภาพที่ 8 (ข) ค่า TP เท่ากับ 2,101 ค่า TN เท่ากับ 85 และภาพที่ 8 (ง) ค่า TP เท่ากับ 2,139 มีค่าเพิ่มขึ้นและค่า TN เท่ากับ 57 มีค่าที่ลดลง จากนั้นทำการคำนวณหา Accuracy, Loss, Recall และ F1 Score โดยแสดงดังตารางที่ 2

ตารางที่ 2 แสดงการเปรียบเทียบผลการทดลองการจำแนกโรคบนใบสตรอเบอร์รี่

ชุดข้อมูล/ผลการทดลอง		ข้อมูลชุดที่ 1 ภาพปกติ	ข้อมูลชุดที่ 2 ภาพที่ใช้วิธีฮาร์เวฟเล็ด
300 รอบ (Epoch)	Accuracy	94.61	96.08
	Loss	0.86	1.85
	Recall	94.78	96.22
	F1-Score	94.89	96.33
	เวลาประมวลผล (นาที)	45	36
500 รอบ (Epoch)	Accuracy	95.59	97.44
	Loss	1.24	2.10
	Recall	95.62	97.56
	F1-Score	95.65	97.63
	เวลาประมวลผล (นาที)	68	62

จากข้อมูลตารางที่ 2 ผลการทดลองประเมินประสิทธิภาพการจำแนกโรคบนใบสตรอเบอร์รี่พบว่าวิธีที่เสนอข้อมูลชุดที่ 2 ภาพที่ใช้วิธีฮาร์เวฟเล็ด ส่งผลให้ได้ค่า Accuracy, Recall และ F1-Score สูงกว่าข้อมูลชุดที่ 1 ภาพปกติ โดยค่า F1-Score จะสูงกว่า Accuracy ซึ่งแสดงถึงการไม่เบี่ยงเบนไปยังคลาสหรือชุดข้อมูลภาพใบสตรอเบอร์รี่ที่มีจำนวนภาพมากกว่า ทั้งในกรณีจำนวนรอบการเรียนรู้ที่ 300 และ 500 รอบ การเพิ่มจำนวนรอบการเรียนรู้ช่วยเพิ่มประสิทธิภาพสำหรับการจำแนกของโมเดลทั้ง 2 ชุดข้อมูล อีกทั้งเวลาในการประมวลผลลดลงเมื่อใช้ข้อมูลชุดที่ 2 ภาพที่ใช้วิธีฮาร์เวฟเล็ด โดยเฉพาะจำนวนรอบการเรียนรู้ที่ 300 รอบ ใช้เวลาในการประมวลผล 36 นาที

5. สรุปผลและอภิปรายผล

จากการทดลองพบว่า การจำแนกโรคบนใบสตรอเบอร์รี่จากชุดข้อมูลภาพจำนวน 4 ชุด ซึ่งประกอบด้วยชุดข้อมูลภาพใบสตรอเบอร์รี่ปกติที่ไม่ติดโรค โรคจุดตาดำ โรคใบไหม้ และโรคราแป้ง โดยทำการเปรียบเทียบกับข้อมูลชุดที่ 1 ภาพปกติและข้อมูลชุดที่ 2 ภาพที่ผ่านการปรับปรุงด้วยวิธี

ฮาร์เวฟเล็ท โดยทำการทดลองจำนวน 4 ครั้ง จากข้อมูลตารางที่ 2 พบว่าข้อมูลชุดที่ 2 ภาพที่ผ่านการปรับปรุงด้วยวิธีฮาร์เวฟเล็ทให้ค่า Accuracy และ F1-Score สูงกว่าทั้งจำนวนรอบการเรียนรู้ 300 และ 500 รอบ โดยภาพที่ผ่านการปรับปรุงด้วยวิธีฮาร์เวฟเล็ทที่จำนวนรอบการเรียนรู้ 300 รอบ ค่า Accuracy จากร้อยละ 94.61 เพิ่มขึ้นร้อยละ 96.08 ค่า F1-Score จากร้อยละ 94.89 เพิ่มขึ้นร้อยละ 96.33 ใช้เวลาในการประมวลผล 36 นาที ซึ่งน้อยกว่าข้อมูลชุดที่ 1 ภาพปกติที่ใช้เวลาประมวลผล 45 นาที และเมื่อเพิ่มจำนวนรอบการเรียนรู้เป็น 500 รอบ ค่า Accuracy จากร้อยละ 95.59 เพิ่มขึ้นร้อยละ 97.44 ค่า F1-Score จากร้อยละ 95.65 เพิ่มขึ้นร้อยละ 97.63 โดยข้อมูลชุดที่ 2 ภาพที่ใช้วิธีฮาร์เวฟเล็ทใช้เวลาประมวลผล 62 นาที ในขณะที่ข้อมูลชุดที่ 1 ภาพปกติใช้เวลาประมวลผล 68 นาที แสดงให้เห็นว่าภาพที่ใช้วิธีฮาร์เวฟเล็ทสามารถเพิ่มประสิทธิภาพในการจำแนกและลดเวลาในการประมวลผลสอดคล้องกับงานวิจัยของ Wiangsamut, et al. (2017) และ Sripuangsuwan, et al. (2024) ซึ่งการใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันเมื่อเพิ่มจำนวนรอบการเรียนรู้เพิ่มมากขึ้น ส่งผลให้มีความแม่นยำเพิ่มขึ้นเช่นเดียวกับงานวิจัยของ นัศพ์ชาณัณ ชินปัญชธนะ (2566) ถึงแม้ว่าค่า Loss จะเพิ่มขึ้นก็ตามด้วยจำนวนรอบการเรียนรู้ที่แตกต่างกันทั้งจำนวน 300 และ 500 รอบ จากความไม่สมดุลของจำนวนข้อมูลภาพไบสโตรอเบอร์รี่ในแต่ละโรคที่มีจำนวนไม่เท่ากัน เพราะทำการคำนวณจากการปรับค่าการทำนายแต่ละครั้งและโดยรวมค่า F1-Score จากผลการทดลองทั้ง 4 ครั้ง สูงกว่าค่า Accuracy ซึ่งแสดงให้เห็นถึงความสมดุลที่ดีระหว่างค่า Precision และค่า Recall ทำให้เป็นตัวชี้วัดที่เหมาะสมสำหรับการประเมินโมเดลที่ได้ทำการออกแบบสำหรับการจำแนกโรคบนไบสโตรอเบอร์รี่ที่มีลักษณะของโรคที่แตกต่างกัน

สำหรับการศึกษาและการดำเนินการวิจัยต่อไปเพื่อปรับปรุงประสิทธิภาพการจำแนกเพื่อให้ได้ผลลัพธ์ความแม่นยำที่สูงขึ้นและเป็นแนวทางสำหรับผู้สนใจเพื่อเพิ่มความแม่นยำในการจำแนกโรคบนไบสโตรอเบอร์รี่ ซึ่งช่วยในการวินิจฉัยและการจัดการโรคได้อย่างมีประสิทธิภาพ ลดการใช้สารเคมีโดยไม่จำเป็น เนื่องจากการตรวจจับโรคที่ถูกต้องและรวดเร็ว สามารถช่วยเกษตรกรในการเพิ่มผลผลิตและลดการสูญเสียจากโรคพืช ควรดำเนินการเก็บรวบรวมภาพไบสโตรอเบอร์รี่ให้มากขึ้นและหลากหลายสายพันธุ์ โดยเฉพาะสายพันธุ์ที่เพาะปลูกในประเทศไทยตลอดจนการใช้กล้องถ่ายภาพที่มีความคมชัดสูงที่สามารถแสดงรายละเอียดภายในภาพได้ชัดเจน จึงเป็นอีกแนวทางหนึ่งที่ผู้วิจัยคิดว่าน่าจะก่อให้เกิดประโยชน์ต่อผู้ที่สนใจและนำไปพัฒนาต่อไปได้

6. เอกสารอ้างอิง

- นัศพัชชาณัน ชินปัญชชนะ. (2566). การจำแนกภาพโรคใบมะเขือเทศด้วยเทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน, **วารสารวิทยาการและเทคโนโลยีสารสนเทศ** 13(2): 40-49.
- ภาณุวัฒน์ เมฆะ พฤติพงศ์ มุสิกกอง ญัฐภาส ผลากอง พาสน์ ปราโมกษ์ชน และพญงค์ศักดิ์ เกษมสำราญ. (2566). การเปรียบเทียบประสิทธิภาพของโมเดลจำแนกภาพสำหรับโรคใบข้าวโพด, **วารสารแม่โจ้เทคโนโลยีสารสนเทศและนวัตกรรม** 9(2): 1-16.
- A. D. Ermolaeva. (2024, January). **Plant Disease Detection Using Small Convolutional Neural Networks**, Conference of Young Researchers in Electrical and Electronic Engineering (ElCon) (pp. 10-12).
- Abade, A. S., de Almeida, A. P. G. S., & Vidal, F. B. (2019, January). **Plant Diseases Recognition from Digital Images using Multichannel Convolutional Neural Networks**, International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications (VISIGRAPP) (pp 450-458).
- Afzaal, U., Bhattarai, B., Pandeya, Y.R., & Lee, J. (2021). An Instance Segmentation Model for Strawberry Diseases Based on Mask R-CNN. **Sensors** 21(19).
- Dinata, M. I., Nugroho, S. M. S., & Rachmadi, R. F. (2021, June). **Classification of strawberry plant diseases with leaf image using CNN**. In International Conference on Artificial Intelligence and Computer Science Technology (ICAICST) (pp. 68-72).
- Fawcett, T. (2006). An introduction to ROC analysis. **Pattern Recognition Letters**, 27(8), 861-874.
- Gonzalez, R. C., & Woods, R. E. (2008). **Digital image processing**. 3rd ed. Prentice Hall.
- Ibrahim, K., & Castelli, M. (2020). **The effect of batch size on the generalizability of the convolutional neural networks on a histopathology dataset**, ICT Express. (Vol. 6, pp. 312-315).
- Jusman, Y., Mubarak, D. W., Widyasmoro, & Mohd, S. N. A. (2022, August). **Texture-based Covid-19 images detection system using Haar wavelet**

- transformation algorithm.** International Conference on Information and Communications Technology (pp. 497-502).
- Kashyap, N. (2022). **Fruit Infection Disease Dataset.** ค้นเมื่อ 12 ธันวาคม 2556 ค้นจาก <https://www.kaggle.com/datasets/nikitkashyap/fruit-infection-disease-dataset>
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, 86(11), 2278–2324.
- O. Y. Fai, Y. V. Voon & H. Nisar. (2016, December). **Image classification using wavelet coefficients for video surveillance**, IEEE Conference on Systems, Process and Control (pp. 107-112).
- Qadri, S. A. A., Huang, N.-F., Wani, T. M., & Bhat, S. A. (2023, August). **Plant disease detection and segmentation using end-to-end YOLOv8: A comprehensive approach.** In International Conference on Control System, Computing and Engineering (pp. 155-160).
- R. Lionnie & M. Alaydrus. (2016, October). **An analysis of Haar Wavelet Transformation for androgenic hair pattern recognition**, International Conference on Informatics and Computing (ICIC) (pp. 22-26).
- S. G. E. Brucal, L. C. M. de Jesus, S. R. Peruda, L. A. Samaniego and E. D. Yong. (2023, October). **Development of Tomato Leaf Disease Detection using YoloV8 Model via RoboFlow 2.0**, Global Conference on Consumer Electronics (pp. 692-694).
- Sripuangsuwan, C., Kiatwuthiamorn, J., & Cumpim, C. (2024). Histogram segmentation technique using local maxima for image enhancement. **Journal of Advanced Development in Engineering and Science**, 13(38), 28–44.
- Taguchi, A. (2017). Color Systems and Color Image Enhancement Methods. **ECTI Transactions on Computer and Information Technology** 10(2): 97–110.

Wiangsamut, S., Sunat, K., Chiewchanwattana, S., & Saisangchan, U. (2017). Fingerprint image enhancement using voting algorithm. **Asia-Pacific Journal of Science and Technology**, 11(3), 213–227.