



ปัญหาพิเศษ

การประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทืองด้วย
โครงข่ายประสาทแบบคอนโวลูชัน

Seed Physical Purity Assessment of Sunn Hemp Using Convolutional
Neural Networks

นางสาว ณิชกร แผลงภู

ภาควิชาพืชไร่ฯ คณะเกษตร มหาวิทยาลัยเกษตรศาสตร์

DEPARTMENT OF AGRONOMY

FACULTY OF AGRICULTURE KASETSART UNIVERSITY



ใบรับรองปัญหาพิเศษ

คณะเกษตร มหาวิทยาลัยเกษตรศาสตร์

วิทยาศาสตร์บัณฑิต (วิทยาศาสตร์เกษตร)

ปริญญา

..... วิทยาศาสตร์เกษตร

..... ฟิสิกส์

สาขา

ภาควิชา

เรื่อง การประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทืองด้วยโครงข่ายประสาทแบบ
คอนโวลูชัน

Seed Physical Purity Assessment of Sunn Hemp Using Convolutional Neural Networks

นามผู้วิจัย นางสาวณิชากร แผลงภู

ได้รับการพิจารณาเห็นชอบโดย

อาจารย์ที่ปรึกษาปัญหาพิเศษหลัก

(ผู้ช่วยศาสตราจารย์ดำรงวุฒิ อ่อนวิมล, ปร.ด.)

อาจารย์ที่ปรึกษาปัญหาพิเศษร่วม

(รองศาสตราจารย์กัศจี้ คงศีล, Ph.D.)

หัวหน้าภาควิชา

(ผู้ช่วยศาสตราจารย์ ปาริชาติ พรหมโชติ, Ph.D.)

วันที่ 5 เดือน เมษายน พ.ศ. 2568

ปัญหาพิเศษ

เรื่อง

การประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทืองด้วยโครงข่ายประสาทแบบคอนโวลูชัน

Seed Physical Purity Assessment of Sunn Hemp Using Convolutional Neural Networks

โดย

นางสาวณิชกร แผลงภู

เสนอ

ภาควิชาพืชไร่นา คณะเกษตร มหาวิทยาลัยเกษตรศาสตร์

DEPARTMENT OF AGRONOMY

FACULTY OF AGRICULTURE KASETSART UNIVERSITY

บทคัดย่อ

นิชากร แผลงภู 2568: การประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทืองด้วย
โครงข่ายประสาทแบบคอนโวลูชัน ปัญหาพิเศษปริญญาตรี สาขาวิทยาศาสตร์เกษตร
ภาควิชาพืชไร่นา อาจารย์ที่ปรึกษา: ผู้ช่วยศาสตราจารย์ดำรงวุฒิ อ่อนนิมิต, ประ.ศ. 39 หน้า

ปัญหาสำคัญในการผลิตเมล็ดพันธุ์ปอเทืองคือการปนกับเมล็ดพันธุ์พืชอื่นที่มีลักษณะทาง
กายภาพคล้ายคลึงกัน เช่น เมล็ดพันธุ์ผักบุ้ง การวิจัยนี้มีวัตถุประสงค์เพื่อ 1) ดำรวจปัญหาประดิษฐ์
สำหรับการวิเคราะห์ภาพถ่ายเมล็ดพันธุ์ปอเทือง 2) ทดสอบคุณภาพความบริสุทธิ์ทางกายภาพของ
เมล็ดพันธุ์ปอเทือง ผลการทดลองพบว่าโมเดล Inception V3 ที่ได้รับการฝึกฝนล่วงหน้า โดยใช้
อัลกอริทึม Adaptive Moment Estimation (ADAM) ให้ค่าความแม่นยำ สูงสุดถึง 98.10% เมื่อ
เปรียบเทียบกับโมเดลอื่นๆ เช่น VGG19 และ GoogLeNet (ImageNet) ซึ่งให้ค่าความแม่นยำ
97.37% และ 98.00% ตามลำดับ (เมื่อใช้อัลกอริทึม ADAM เช่นกัน) ผลลัพธ์นี้แสดงให้เห็นว่า
Inception V3 ร่วมกับ ADAM มีประสิทธิภาพสูงสุดในการจำแนกเมล็ดปอเทืองออกจากเมล็ดผักบุ้ง
อย่างมีนัยสำคัญ ซึ่งอาจเป็นผลมาจากสถาปัตยกรรมของ Inception V3 ที่เหมาะสมกับการ
ประมวลผลภาพที่มีความซับซ้อน จึงมีศักยภาพนำไปประยุกต์ใช้ประเมินความบริสุทธิ์ทางกายภาพของ
เมล็ดพันธุ์บนโทรศัพท์มือถือและสายพานการผลิตได้

คำสำคัญ: เมล็ดพันธุ์ปอเทือง, ความบริสุทธิ์ทางกายภาพ, ปัญหาประดิษฐ์, Inception V3

นิชากร แผลงภู

ลายมือชื่อนิติ

ลายมือชื่ออาจารย์ที่ปรึกษาปัญหาพิเศษหลัก

30 / 03 / 68

ABSTRACT

Nichakon Malaengphu 2025: Seed Physical Purity Assessment of Sunn Hemp Using Convolutional Neural Networks. Bachelor's special problem in Agricultural Science, Department of Agronomy. Special problem advisor: Assistant Professor Damrougvudhi Onwimol, Ph.D. 39 pages.

The major challenge in Sunn hemp seed production is contamination with seeds from other species that share similar physical characteristics, such as morning glory seeds. This research aimed to 1) explore the artificial intelligence application for analyzing Sunn hemp seed images and 2) evaluate the physical purity of Sunn hemp seeds. The results showed that the pre-trained Inception V3 model, using the Adaptive Moment Estimation (ADAM) algorithm, achieved the highest accuracy of 98.10% compared to other models like VGG19 and GoogLeNet (ImageNet), which achieved 97.37% and 98.00% accuracy, respectively (using the ADAM algorithm as well). These findings demonstrate that Inception V3 with ADAM is highly effective in distinguishing Sunn hemp seeds from morning glory seeds. This may be attributed to Inception V3's architecture, which is well-suited for complex image processing. Therefore, it has the potential to be applied for assessing seed physical purity on mobile phones and production lines.

Keywords: Sunn hemp seed, physical purity, artificial intelligence, Inception V3

Nichakon Malaengphu

Student's signature

D. Onwimol

Special Problem Advisor's signature

30 / 03 / 68

กิตติกรรมประกาศ

ผู้วิจัยขอกราบขอบพระคุณผู้ช่วยศาสตราจารย์ดำรงวุฒิ อ่อนวิมล ที่ให้ความช่วยเหลือในงานวิจัยในการทำวิทยานิพนธ์และให้คำแนะนำจนเล่มเสร็จสมบูรณ์ ผู้วิจัยขอกราบขอบพระคุณเป็นอย่างสูง

ขอขอบคุณกรมพัฒนาที่ดิน กระทรวงเกษตรและสหกรณ์สำหรับเมล็ดพันธุ์ปอเทืองที่ใช้ในงานวิจัยครั้งนี้

สุดท้ายนี้ข้าพเจ้าขอกราบขอบพระคุณครอบครัวที่คอยสนับสนุนการศึกษาและให้กำลังใจตลอดมา

นิชากร แผลงภู

มีนาคม 2568

สารบัญ

หน้า

สารบัญ	(1)
สารบัญตาราง	(2)
สารบัญภาพ	(3)
คำนำ	1
วัตถุประสงค์	2
การตรวจเอกสาร	3
อุปกรณ์และวิธีการ	11
วิธีการ	12
สถานที่และระยะเวลาการทำวิจัย	14
ผลและวิจารณ์	15
สรุป	21
เอกสารและสิ่งอ้างอิง	22
ภาคผนวก	25
ประวัติการศึกษาและการทำงาน	30

สารบัญตาราง

ตารางที่		หน้า
1	เปรียบเทียบความแม่นยำแต่ละโมเดลและOptimizer	19
2	Accuracy, Precision, Recall/sensitivity และ F1 Score	20

สารบัญภาพ

ภาพที่		หน้า
1	การวัดความยาวและความกว้างของเมล็ดปอเทืองแต่ละรูปทรง	3
2	โครงสร้างการทำงานของโครงข่ายประสาทแบบคอนโวลูชัน	7
3	โครงสร้างการทำงานของโมเดล GoogLeNet (ImageNet)	8
4	โครงสร้างการทำงานของโมเดล VGG19	9
5	โครงสร้างการทำงานของโมเดล InceptionV3	10
6	ความแม่นยำของการประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทือง ด้วยโมเดล GoogLeNet (ImageNet)	16
7	ความแม่นยำของการประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทือง ด้วยโมเดล VGG19	17
8	ความแม่นยำของการประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทือง ด้วยโมเดล InceptionV3	18
9	Confusion Matrix InceptionV3 อัลกอริทึม ADAM (Learning rate 0.0001)	20
 ภาคผนวกที่		 หน้า
1	ภาพถ่ายเมล็ดพันธุ์ปอเทือง พร้อมพื้นหลัง	26
2	ภาพถ่ายเมล็ดพันธุ์ฝักบัว พร้อมพื้นหลัง	26
3	การเตรียมภาพถ่ายเมล็ดพันธุ์ปอเทืองพร้อมพื้นหลัง ด้วยโทรศัพท์มือถือ พร้อมเลนส์มือถือมาโคร	27
4	การเตรียมภาพถ่ายเมล็ดพันธุ์ฝักบัวพร้อมพื้นหลัง ด้วยโทรศัพท์มือถือพร้อม เลนส์มือถือมาโคร	27
5	ภาพถ่ายเมล็ดพันธุ์ปอเทือง ใน 5,000 เมล็ดจัดเก็บไว้ในคอมพิวเตอร์	28
6	ภาพถ่ายเมล็ดพันธุ์ฝักบัว ใน 5,000 เมล็ดจัดเก็บไว้ในคอมพิวเตอร์	28
7	นำภาพถ่ายที่จัดเก็บไว้มาปรับเปลี่ยนขนาด	29
8	การวิเคราะห์ภาพถ่ายโดยใช้ CNN ผ่านวิธี Transfer learning จาก Pre-trained model	29

การประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทืองด้วยโครงข่ายประสาทแบบคอนโวลูชัน

Seed Physical Purity Assessment of Sunn Hemp Using Convolutional Neural Networks

คำนำ

ปอเทือง (*Crotalaria juncea* L.) เป็นพืชตระกูลถั่วที่นิยมนำมาปลูกเป็นปุ๋ยพืชสดเพื่อปรับปรุงบำรุงดิน (กรมพัฒนาที่ดิน, 2550) ปัจจุบัน เกษตรกรในเขตพื้นที่ราบลุ่มภาคกลางและภาคเหนือตอนล่างได้กลายเป็นแหล่งพื้นที่ใหม่สำหรับการผลิตเมล็ดพันธุ์ปอเทืองในเชิงเดี่ยว อย่างไรก็ตาม ในพื้นที่ใหม่นี้ พบว่ามีการแข่งขันกับพืชเศรษฐกิจชนิดอื่นที่เป็นแหล่งผลิตเมล็ดพันธุ์ในพื้นที่เดียวกัน ซึ่งคือเมล็ดพันธุ์ผักบุ้ง (*Ipomoea aquatica*) อีกทั้งเมล็ดพันธุ์ของพืชทั้งสองชนิดยังมีลักษณะทางกายภาพและสีที่ใกล้เคียงกันมาก ซึ่งส่งผลกระทบต่อคุณภาพและปริมาณของเมล็ดพันธุ์ปอเทืองที่ผลิตได้ เนื่องจากการคัดแยกเมล็ดพันธุ์ด้วยวิธีการแบบดั้งเดิมโดยใช้แรงงานคนนั้นมีความยากลำบาก ต้องใช้เวลานาน มีต้นทุนสูง และอาจเกิดความคลาดเคลื่อนได้ ด้วยเหตุนี้ ทางผู้วิจัยจึงเล็งเห็นถึงความสำคัญของการนำเทคโนโลยีปัญญาประดิษฐ์เข้ามาประยุกต์ใช้เพื่อช่วยแก้ไขปัญหาดังกล่าว

ในปัจจุบันโครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network: CNN) ได้รับการยอมรับอย่างกว้างขวางในด้านการประมวลผลภาพและการจำแนกวัตถุ เทคโนโลยีนี้มีศักยภาพสูงในการเรียนรู้ลักษณะเฉพาะของพืชแต่ละชนิดจากข้อมูลภาพถ่าย ดังนั้น งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อสำรวจความเป็นไปได้ในการประยุกต์ใช้ปัญญาประดิษฐ์สำหรับการวิเคราะห์ภาพถ่ายเมล็ดพันธุ์ปอเทือง และเพื่อทดสอบความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทือง ดังนั้น งานวิจัยนี้มีวัตถุประสงค์เพื่อสำรวจปัญญาประดิษฐ์สำหรับการวิเคราะห์ภาพถ่ายเมล็ดพันธุ์ปอเทือง และทดสอบความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทือง

วัตถุประสงค์

1. ดำรงปัญหาประดิษฐ์สำหรับการวิเคราะห์ภาพถ่ายเมล็ดพันธุ์ปอเทือง
2. ทดสอบความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทือง


การตรวจเอกสาร

ปอเทือง (Sunn Hemp)

ชื่อวิทยาศาสตร์ *Crotalaria juncea* เป็นพืชล้มลุกในวงศ์ Fabaceae (วงศ์ถั่ว) ที่นิยมนำมาปลูกเป็นปุ๋ยพืชสดเพื่อปรับปรุงบำรุงดิน (กรมพัฒนาที่ดิน, 2550) ปัจจุบันตลาดเมล็ดพันธุ์ปอเทืองทั่วโลกมีมูลค่าถึง 121.2 ล้านดอลลาร์สหรัฐในปี 2565 และคาดการณ์ว่าจะเติบโตเป็น 194.93 ล้านดอลลาร์สหรัฐภายในปี 2573 โดยมีอัตราการเติบโตเฉลี่ยต่อปี (CAGR) ที่ 6.1% ในช่วงคาดการณ์ปี 2567-2574 (DataM Intelligence, 2024)

ลักษณะทางกายภาพของเมล็ดพันธุ์ปอเทือง

เมล็ดมีลักษณะเป็นรูปทรงไตไปจนถึงรูปทรงหัวใจ (พิน) ปลายเรียวโค้งมนมาก ยาวได้ถึง 6 มม. สีน้ำตาลเข้มจนถึงสีดำ (Heuzé, Thiollet, Tran, & Lebas, 2018; Ninkaew et al., 2017)



ภาพที่ 1 การวัดความยาวและความกว้างของเมล็ดปอเทืองแต่ละรูปทรง A) รูปทรงไต B)

รูปทรงพิน (L = ความยาว , W = ความสูง)

ที่มา : Ninkaew et al., (2017)

การผลิตเมล็ดพันธุ์ปอเทือง

ปอเทืองสามารถขึ้นได้ดีบนที่ดอนและในที่ลุ่มที่ไม่มีน้ำแช่ขัง ปอเทืองยังทนต่อความแห้งแล้งขึ้นได้ในดินเลว จึงสามารถสร้างธาตุอาหารขึ้นเองได้โดยเฉพาะไนโตรเจน (กรมพัฒนาที่ดิน, 2550)

ฤดูกาลปลูกที่เหมาะสม

ปอเทืองปลูกได้ 2 ช่วง ในภาคตะวันออกเฉียงเหนือช่วงแรกเริ่มปลูกตั้งแต่เดือนมิถุนายน จนถึงปลายเดือนกรกฎาคม ช่วงที่ 2 ปลูกหลังฤดูทำนาเดือนตุลาคม-พฤศจิกายน สำหรับภาคอื่น ๆ ปรับช่วงเวลาตามความเหมาะสม (กรมพัฒนาที่ดิน, 2550)

การเตรียมดิน

ไถเตรียมดินครั้งแรก แล้วตากทิ้งไว้ประมาณ 7 วัน เพื่อให้วัชพืชแห้งตาย และยังเป็นการกำจัดโรคและแมลงต่าง ๆ ที่เป็นศัตรูพืช หลังจากนั้นทำการไถพรวน ครั้งที่ 2 (กรมพัฒนาที่ดิน, 2550)

การปลูก

ระยะแถว 80 -100 เซนติเมตร หรือปลูกเป็นหลุม ระยะปลูก 50 x 100 เซนติเมตร หลุมละ 1 – 3 ต้น (2 – 4 กิโลกรัมต่อไร่) หรือปลูกแบบหว่านใช้เมล็ดพันธุ์ 5 กิโลกรัมต่อไร่คลุมเชื้อโรโซเบียม หว่านทั่วแปลง หลังจากนั้นหว่านปุ๋ยเคมีสูตร 15-15-15 หรือสูตร 12-24-12 จำนวน 10 กิโลกรัมต่อไร่ โดยหว่านให้สม่ำเสมอทั่วแปลงแล้วคราดกลบ (กรมพัฒนาที่ดิน, 2550)

การใส่ปุ๋ย

ใส่ปุ๋ยสูตร 15-15-15 หรือ 12-24-12 อัตรา 20 กิโลกรัมต่อไร่ โรยรอบโคนต้นให้ห่างจากโคนต้นพอประมาณแล้วจึงพูนโคนกลบปุ๋ย (กรมพัฒนาที่ดิน, 2550)

การกำจัดโรคและแมลง

พื้นที่ที่ไม่เคยปลูกปอเทืองมาก่อน มักจะไม่มีปัญหาเรื่องโรคแมลงศัตรูพืช ในระยะติดฝักอ่อนและระยะที่ฝนทิ้งช่วง ต้องหมั่นตรวจดูแปลงขยายพันธุ์ เพราะมักจะมีแมลงประเภทปากดูด เช่น เพลี้ยอ่อน แมลงหวี่ขาว ระบาดให้พ่นสารเคมีประเภทดูดซึมผสมน้ำยาจับใบ เช่น อะไซครินและเซฟวิน เป็นต้น (กรมพัฒนาที่ดิน, 2550)

เมื่อปอเทืองติดฝัก จะมีหนอนแมลงเจาะทำลายฝักโดยให้พ่นสารเคมีประเภทถูกตัวตายผสมกับน้ำยาจับใบ เช่น ชูมินิคริม เป็นต้น (กรมพัฒนาที่ดิน, 2550)

โรคที่สำคัญ คือ โรคโมเซคหรือชาวบ้านเรียกว่า ต้นปอเทืองเป็นกัญชา หรือโรคใบกระดิม ต้นและใบจะมีสีขาวอมเขียวฉวม ใบหงิกงอไม่ออกดอก สามารถระบาดไปยังต้นอื่นได้ ให้รีบถอน และเผาทิ้งทันที (กรมพัฒนาที่ดิน, 2550)

การเก็บเกี่ยว

ปอเทืองมีอายุประมาณ 120 – 150 วัน ในช่วงแรกจะเก็บเกี่ยวเดือนพฤศจิกายน-ธันวาคม ในช่วงที่ 2 จะเก็บเกี่ยวเดือนกุมภาพันธ์-มีนาคม ต้นและฝักปอเทืองจะทยอยแห้ง ฝักที่แก่จัดจะเปลี่ยนจากสีเขียวอ่อนเป็นสีน้ำตาลอ่อน ถ้าเขย่าต้นจะมีเสียงดัง เมล็ดทั้งหมดจะนอนอยู่ที่ก้นฝัก มีจำนวนเมล็ดตั้งแต่ 5 – 10 เมล็ดต่อฝัก เมล็ดที่คุณภาพดีจะมีสีม่วงปนดำ ผิวเป็นมันฝักของเมล็ดปอเทืองเมื่อแก่เต็มที่จะไม่แตกและไม่ร่วงหล่นจากต้น การเก็บเกี่ยวจะเก็บเกี่ยวเพียงครั้งเดียวโดยใช้เกี่ยวเกี่ยวโคนต้น ตากแดดทิ้งไว้ 3 – 4 แดด แล้วนำมาผึ่ง (กรมพัฒนาที่ดิน, 2550) ด้วยเหตุนี้ กระบวนการเก็บรักษาหรือการเก็บเกี่ยวเมล็ดพันธุ์ซึ่งมีความเสี่ยงต่อการปนจากเมล็ดพืชอื่น จึงอาจเป็นสาเหตุให้คุณภาพของเมล็ดพันธุ์ลดลง การตรวจสอบความบริสุทธิ์ของเมล็ดพันธุ์จึงมีความสำคัญอย่างยิ่งต่อการรักษามาตรฐานการผลิต

การนวด

การนวดอาจทำได้หลายวิธี เช่น ใช้รถยนต์เหยียบย่ำ หรือนำฝักบรรจุถุง แล้วใช้ไม้ทุบให้ฝักแตก จากนั้นคัดเอาสิ่งเจือปนและเมล็ดลีบออก แล้วบรรจุกระสอบ (กรมพัฒนาที่ดิน, 2550)

การตรวจสอบความบริสุทธิ์ของเมล็ดพันธุ์ (Purity Test)

การตรวจสอบความบริสุทธิ์ของเมล็ดพันธุ์เป็นการวิเคราะห์ว่า เมล็ดพันธุ์แต่ละกองมีองค์ประกอบอะไรบ้างในจำนวนหรือปริมาณมากน้อยเพียงใด องค์ประกอบของเมล็ดพันธุ์ที่ต้องตรวจสอบคือ (1)เมล็ดพันธุ์สุทธิหรือเมล็ดพันธุ์บริสุทธิ์ (pure seed) (2) เมล็ดพันธุ์ชนิดอื่น (other crop seed) (3) เมล็ดพันธุ์วัชพืช (weed seed) และ (4) สิ่งเจือปนอื่น ๆ (inert matter) เมล็ดพันธุ์กองใดมีเมล็ดพันธุ์สุทธิ หรือเมล็ดพันธุ์สุทธิต่ำ เป็นเมล็ดพันธุ์ที่มีความบริสุทธิ์สูง ความบริสุทธิ์ของเมล็ดพันธุ์นี้ รายงานเป็นเปอร์เซ็นต์โดยน้ำหนัก (จวงจันทร์, 2529) จากข้อจำกัดของวิธีการตรวจสอบความบริสุทธิ์ของเมล็ดพันธุ์แบบเดิม ซึ่งมีข้อจำกัดด้านทรัพยากรบุคคล งบประมาณ ระยะเวลา และความแม่นยำ การนำเทคโนโลยีหุ่นยนต์และปัญญาประดิษฐ์ (AI) มาใช้ในการตรวจสอบ จึงเป็นทางเลือกที่น่าสนใจในการเพิ่มประสิทธิภาพ ลดต้นทุน และยกระดับความน่าเชื่อถือ ของกระบวนการดังกล่าว

ปัญญาประดิษฐ์

ปัญญาประดิษฐ์ (Artificial Intelligence หรือ AI) หมายถึง เทคโนโลยีหรือเครื่องจักรที่สามารถทำงานที่ซับซ้อน ซึ่งโดยทั่วไปเกี่ยวข้องกับสติปัญญาของมนุษย์ เช่น การแก้ปัญหา การวางแผน การให้เหตุผล และการตัดสินใจ (Rowan University, 2024). AI ทำงานโดยการจำลองสติปัญญาของมนุษย์ผ่านการใช้อัลกอริทึม ข้อมูล และพลังการประมวลผล เพื่อให้เครื่องจักรหรือซอฟต์แวร์สามารถทำงานที่ต้องใช้สติปัญญาของมนุษย์ได้ เช่น การเรียนรู้ การให้เหตุผล การแก้ปัญหา การรับรู้ และการเข้าใจภาษา (NASA, 2024).

คำว่า "ปัญญาประดิษฐ์" ครอบคลุมระบบที่ใช้เครื่องจักร ซึ่งสามารถทำการคาดการณ์ ให้คำแนะนำ หรือตัดสินใจที่มีอิทธิพลต่อสภาพแวดล้อมจริงหรือเสมือนจริงได้ โดยมีเป้าหมายที่มนุษย์กำหนดไว้ (Google Cloud, 2022; University of Notre Dame, 2024). AI ยังเป็นชุดของเทคโนโลยีที่ช่วยให้คอมพิวเตอร์สามารถทำงานขั้นสูงต่างๆ ได้ รวมถึงความสามารถในการมองเห็น เข้าใจ และแปลภาษาพูดและภาษาเขียน วิเคราะห์ข้อมูล และให้คำแนะนำ (University of Illinois Chicago, 2023; NASA, 2024)

โดยสรุป AI เป็นสาขาวิทยาการคอมพิวเตอร์ที่มุ่งสร้างเครื่องจักรที่สามารถทำงานที่โดยทั่วไปต้องใช้สติปัญญาของมนุษย์ได้ ซึ่งรวมถึงการเรียนรู้จากประสบการณ์ (Machine learning) การเข้าใจภาษาธรรมชาติ การจดจำรูปแบบ การแก้ปัญหา และการตัดสินใจ (Scottish AI Alliance, 2024) แม้ปัญญาประดิษฐ์มีหลากหลายรูปแบบ แต่ด้วยลักษณะงานตรวจสอบความบริสุทธิ์ของเมล็ดพันธุ์เป็นการวิเคราะห์ภาพถ่าย โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network) จึงมีความเหมาะสมสูงสุด ในการเรียนรู้และสกัดคุณลักษณะสำคัญจากภาพเมล็ดพันธุ์ และเป็นเหตุผลหลักในการเลือกใช้ CNN สำหรับงานนี้

โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network)


โครงข่ายประสาทแบบคอนโวลูชัน หรือ CNNs เป็นโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (feedforward neural network) ที่ถูกออกแบบมาเป็นพิเศษเพื่อประมวลผลข้อมูลที่มีโครงสร้างแบบกริด เช่น รูปภาพ (IBM, 2020) CNNs มีประสิทธิภาพอย่างมากในการจัดการกับรูปภาพขนาดใหญ่ เนื่องจากสามารถใช้ประโยชน์จากโครงสร้างสองมิติของข้อมูลได้ (UFLDL, 2020) แนวคิดหลักของ CNNs คือการเรียนรู้คุณลักษณะ (features) โดยตรงจากข้อมูลผ่าน

กระบวนการปรับปรุงตัวกรอง (filter optimization) ทำให้ CNNs เป็นโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่มีการปรับปรุง (regularized) (LeCun, Bengio, & Hinton, 2015)

ข้อได้เปรียบที่สำคัญของ CNNs คือความสามารถในการสกัดคุณลักษณะที่เกี่ยวข้องได้โดยอัตโนมัติ ซึ่งแตกต่างจากอัลกอริทึมแบบดั้งเดิมที่ต้องมีการออกแบบคุณลักษณะโดยผู้เชี่ยวชาญ (พิมพา ชีวาประกอบกิจ, 2562) นอกจากนี้ CNNs ยังมีคุณสมบัติที่สำคัญคือความไม่แปรผันต่อการเลื่อนตำแหน่ง (shift invariance หรือ space invariance) ซึ่งเป็นผลมาจากสถาปัตยกรรมที่ใช้ตัวกรอง (convolution kernels) ที่มีการแบ่งปันน้ำหนัก (shared-weight) และเลื่อนไปบนข้อมูลนำเข้าเพื่อสร้างผลลัพธ์ที่ไม่แปรผันต่อการเลื่อนตำแหน่งที่เรียกว่าแผนที่คุณลักษณะ (feature maps) (LeCun, Bengio, & Hinton, 2015)

ส่วนประกอบหลักของโครงข่ายประสาทแบบคอนโวลูชัน

โดยทั่วไป โครงข่ายประสาทแบบคอนโวลูชันประกอบด้วยชั้น (layers) หลักสามประเภท ได้แก่ เลเยอร์คอนโวลูชัน (Convolutional Layer), เลเยอร์พูลลิง (Pooling Layer), และเลเยอร์เชื่อมต่อเต็มรูปแบบ (Fully Connected Layer) (IBM, 2020)



ภาพที่ 2 โครงสร้างการทำงานของโครงข่ายประสาทแบบคอนโวลูชัน


ที่มา : <https://www.mathworks.com/discovery/convolutional-neural-network.html>

โครงข่ายประสาทแบบคอนโวลูชันโมเดล GoogLeNet (ImageNet)

GoogLeNet (ImageNet) หรือที่รู้จักกันในชื่อ Inception V1 เป็นสถาปัตยกรรม CNN ที่ได้รับการพัฒนาโดยนักวิจัยของ Google และเป็นผู้ชนะในการแข่งขัน ImageNet Large Scale Visual Recognition Challenge (ILSVRC) ประจำปี 2014 สถาปัตยกรรมนี้มีความโดดเด่นด้วยการใช้

"Inception modules" ซึ่งเป็นหน่วยการประมวลผลแบบขนานที่ประกอบด้วยตัวกรอง (filter) ขนาดต่างๆ (1x1, 3x3, 5x5) และชั้นการรวมกลุ่ม (max-pooling layer) การออกแบบเช่นนี้ช่วยให้เครือข่ายสามารถดึงคุณลักษณะ (feature) ที่หลากหลายจากภาพได้พร้อมกัน ทำให้สามารถวิเคราะห์วัตถุที่มีขนาดและลักษณะแตกต่างกันได้อย่างมีประสิทธิภาพ (GeeksforGeeks, 2021)

Pittan, M R, and Divya (2019) ได้ประยุกต์ใช้โมเดล GoogLeNet และ VGG-16 ในการจำแนกพืชโดยใช้ลักษณะของเส้นใบ (leaf venation) ได้รับการฝึกและทดสอบด้วยชุดข้อมูล Dleaf, Flavia และ Leaf1 โดยใช้ตัวจำแนก CNN และ Support Vector Machine (SVM) พบว่าโมเดล GoogLeNet (ImageNet) ที่ปรับแต่งมาอย่างดีนั้นมีประสิทธิภาพเหนือกว่า โมเดล VGG-16 ที่ 99.2% บนชุดข้อมูล Leaf1 โดยใช้ตัวจำแนก SVM




ภาพที่ 3 โครงสร้างการทำงานของโมเดล GoogLeNet (ImageNet)

ที่มา : <https://paperswithcode.com/model/googlenet>

โครงข่ายประสาทแบบคอนโวลูชันโมเดล VGG19

VGG19 ซึ่งพัฒนาโดย Visual Geometry Group จาก University of Oxford เป็นสถาปัตยกรรม CNN เชิงลึกที่เป็นที่รู้จักในด้านความเรียบง่ายและความลึก ประกอบด้วยเลเยอร์ที่มีน้ำหนัก 19 ชั้น (16 convolutional layers และ 3 fully connected layers) (Simonyan & Zisserman, 2015)

Nguyen, Thanh-Hai, Nguyen, Thanh-Nghia and Ngo, Ba-Viet (2022) จากการศึกษาเกี่ยวกับการวิเคราะห์และตรวจจับโรคพืช ได้ความแม่นยำถึง 99.72% ในการจำแนกโรคใบมะเขือเทศ โดยใช้โมเดล VGG19 ร่วมกับการถ่ายทอดการเรียนรู้และเทคนิคการแบ่งส่วนภาพ ผลลัพธ์แสดงให้เห็นว่าโมเดล VGG19 มีประสิทธิภาพและสามารถพัฒนาสำหรับชุดข้อมูลภาพที่ซับซ้อนได้



ภาพที่ 4 โครงสร้างการทำงานของโมเดล VGG19

ที่มา : <https://www.geeksforgeeks.org/vgg-net-architecture-explained/>


โครงข่ายประสาทแบบคอนโวลูชันโมเดล InceptionV3

InceptionV3 เป็นรุ่นที่สำคัญในตระกูลสถาปัตยกรรมเครือข่ายประสาทเทียมแบบ convolutional ของ Inception ซึ่งเป็นชุดของแบบจำลองที่พัฒนาโดย Google ได้ถูกนำเสนอครั้งแรกในงานวิจัยที่มีชื่อว่า "Rethinking the Inception Architecture for Computer Vision" ซึ่งตีพิมพ์ในปี 2015 InceptionV3 สร้างขึ้นบนความสำเร็จพื้นฐานของรุ่นก่อนหน้า ได้แก่ สถาปัตยกรรม Inception ดั้งเดิม (GoogLeNet หรือ Inception V1 และ Inception V2) จุดเน้นหลักของการออกแบบ InceptionV3 คือการสร้างเครือข่ายประสาทเทียมที่ทั้งลึกและกว้างขึ้น ทำให้สามารถเรียนรู้คุณสมบัติที่ซับซ้อนมากขึ้น ในขณะที่เดียวกันก็มีประสิทธิภาพมากขึ้นในแง่ของทรัพยากรการคำนวณและจำนวนพารามิเตอร์ เมื่อเทียบกับโมเดลรุ่นก่อนหน้า เพื่อให้บรรลุเป้าหมายเหล่านี้ InceptionV3 ได้รวมเอาการปรับปรุงสถาปัตยกรรมและเทคนิคใหม่ๆ หลายประการ เมื่อเทียบกับรุ่นก่อนหน้า (Szegedy et al., 2015b)

ความก้าวหน้าเหล่านี้สะท้อนให้เห็นถึงความพยายามอย่างต่อเนื่องในสาขาการเรียนรู้เชิงลึก เพื่อพัฒนาสถาปัตยกรรมแบบโมดูลาร์ที่ซับซ้อนและได้รับการปรับปรุงให้ดีขึ้น ซึ่งสามารถสร้างสมดุลที่ดีขึ้นระหว่างประสิทธิภาพการคำนวณและความแม่นยำสูงสำหรับงานจดจำภาพและคอมพิวเตอร์วิทัศน์อื่นๆ ความก้าวหน้าจาก Inception V1 ไปยัง V3 แสดงให้เห็นถึงกระบวนการปรับปรุงซ้ำๆ โดยได้รับแรงผลักดันจากความต้องการอย่างต่อเนื่องในการปรับปรุงประสิทธิภาพ

ในขณะที่จัดการกับความต้องการด้านการคำนวณที่เพิ่มขึ้น ซึ่งเกี่ยวข้องกับการฝึกอบรมเครือข่ายประสาทเทียมที่ลึกและซับซ้อนมากขึ้นอย่างมีประสิทธิภาพ

InceptionV3 ได้ถูกนำมาใช้สำเร็จในการประเมินความเสียหายประเภทต่างๆ ที่เกิดขึ้นกับพืชผลทางการเกษตร รวมถึงความเสียหายที่เกิดจากทั้งโรคและศัตรูพืช สถาปัตยกรรมนี้ได้แสดงให้เห็นถึงระดับความแม่นยำสูงในการระบุโรคที่ส่งผลกระทบต่อพืช เช่น ฝอย ซึ่งมีความแม่นยำสูงถึง 99.85% (Maeda-Gutiérrez et al., 2025)



ภาพที่ 5 โครงสร้างการทำงานของโมเดล InceptionV3

ที่มา : <https://viso.ai/deep-learning/googlenet-explained-the-inception-model-that-won-imagenet/>

ด้วยเหตุผลดังกล่าวมาข้างต้น เราจึงมีความจำเป็นต้องทดสอบประสิทธิภาพของ pre-train CNN model เพื่อบรรลุวัตถุประสงค์หลักของงานวิจัย ได้แก่ การสำรวจปัญหาประดิษฐ์สำหรับการวิเคราะห์ภาพถ่ายเมล็ดพันธุ์ปอเทือง และการทดสอบความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทือง

อุปกรณ์และวิธีการ

อุปกรณ์

1. เมล็ดพันธุ์พืชที่ใช้ในการทดลอง
 - 1.1 เมล็ดพันธุ์ปอเทือง 1 ตัวอย่าง
 - 1.2 เมล็ดพันธุ์ผักบุ้ง 1 ตัวอย่าง
2. อุปกรณ์ที่ใช้ในการทดลอง
 - 2.1 เลนส์มือถือมาโคร
 - 2.2 กระดาษสี
 - 2.3 โคมไฟ
 - 2.4 ถังอคูมิเนียมฟอยล์
 - 2.5 เม็ดดูดความชื้น
 - 2.6 กล่องพลาสติกขนาดเล็ก
 - 2.7 ฝากลมสำหรับสุ่มตัวอย่าง
 - 2.8 โทรศัพท์มือถือ
 - 2.9 คอมพิวเตอร์และซอฟต์แวร์ที่เกี่ยวข้อง
 - 2.9.1 โปรแกรม MATLAB R2021a

วิธีการ

1. การเตรียมเมล็ดพันธุ์

1.1 เมล็ดพันธุ์ปอเทืองและผักบุ้ง เก็บรักษาเมล็ดพันธุ์ในถุงอับอากาศ (Hermetic bag) ควบคู่กับใช้เม็ดดูดความชื้น (Drying bead) ที่อุณหภูมิ 10 – 12 องศาเซลเซียส ความชื้นสัมพัทธ์ประมาณ 7 เปอร์เซ็นต์ จนกระทั่งถูกนำไปทดสอบคุณภาพเมล็ดพันธุ์

1.2 ดำเนินการสุ่มตัวอย่างเมล็ดพันธุ์ปอเทืองและผักบุ้ง ตามกฎ ISTA (2023) และบันทึกภาพถ่ายด้วยโทรศัพท์พร้อมเลนส์มือถือมาโคร ชนิดละ 5,000 เมล็ด (ภาพผนวกที่ 1 และภาพผนวกที่ 2) ภายหลังการบันทึกภาพ ซึ่งภาพถ่ายจะจัดเก็บไว้ในคอมพิวเตอร์ (ภาพผนวกที่ 5 และภาพผนวกที่ 6) ตัวอย่างเมล็ดพันธุ์ที่บันทึกภาพแล้วจะถูกจัดเก็บแยกในถุงอลูมิเนียมฟอยล์ ร่วมกับสารดูดความชื้น ภายใต้สภาวะอุณหภูมิห้อง

2. การวิเคราะห์ข้อมูล

รายละเอียดของคอมพิวเตอร์ซีปประมวลผล CPU INTEL CORE i5-13400F 2.5 GHz (SOCKET LGA 1700) หน่วยประมวลผลแรม 16 GB และการ์ดจอ RTX 3060 (GDDR6 12 GB)

2.1 ดำเนินการปรับเปลี่ยนขนาดของภาพถ่ายที่จัดเก็บไว้ จำนวน 10,000 ภาพ จากความละเอียดที่ 3024 x 3024 pixels โดยเปลี่ยนขนาดตามสถาปัตยกรรม ดังนี้ ด้วยโปรแกรม MATLAB R2021a (ภาพผนวกที่ 7)

1.1 GoogLeNet (ImageNet) และ VGG19 เปลี่ยนเป็นความละเอียดที่ 224 x 224 pixels

1.2 InceptionV3 เปลี่ยนเป็นความละเอียดที่ 299 x 299 pixels

2.2 การวิเคราะห์ภาพถ่าย

โดยใช้ CNN ผ่านวิธี Transfer learning จาก Pre-trained model จำนวน 3 โมเดล (ภาพผนวกที่ 8) ประกอบด้วย GoogLeNet (ImageNet) ประกอบด้วยประมาณ 6.8 ล้านพารามิเตอร์ (Szegedy et al., 2015a), VGG19 ประกอบด้วยประมาณ 144 ล้านพารามิเตอร์ (Simonyan and Zisserman, 2015) และ InceptionV3 ประกอบด้วยประมาณ 24 ล้านพารามิเตอร์ (Szegedy et al., 2015b) โดยแต่ละโมเดลจะใช้ optimization algorithm 2 ตัวคือ Stochastic Gradient Descent with Momentum (SGDM) และ Adaptive Moment Estimation (ADAM) โดยการทดลองจะมีการแบ่งภาพเป็น 2 ส่วนสำหรับการฝึกอบรม (Train) 70 เปอร์เซ็นต์ และการตรวจสอบความถูกต้อง (Validation) 30 เปอร์เซ็นต์ ด้วย

โปรแกรม MATLAB R2021a พิจารณาความก้าวหน้าของการเรียนรู้ของ AI จากกราฟความถูกต้องและความผิดพลาด (Accuracy and loss validation) (Gurney, 2018; Kelleher, 2019)

2.3 การประเมินศักยภาพการจำแนกด้วยโครงข่ายประสาทแบบคอนโวลูชัน

ประเมินศักยภาพการจำแนกเมื่อดัชนีชี้วัดต่อไปนี้: ความถูกต้อง, ความแม่นยำ, ความไว, และ F1 Score ดังสมการ (1 – 4) โดยค่าที่ได้ยิ่งมากยิ่งสะท้อนศักยภาพการจำแนก (Ghayoumi, 2021)

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad \text{—————} \quad 1$$

$$Precision = \frac{TP}{TP + FP} \quad \text{—————} \quad 2$$

$$Recall = \frac{TP}{TP + FN} \quad \text{—————} \quad 3$$

$$F1 \text{ score} = 2 \times \frac{Precision * Recall}{Precision + Recall} \quad \text{—————} \quad 4$$

1) True positive (TP) คือ ผลที่โมเดลทำนายตรงกับข้อมูลจริงในชนิดพืชที่กำลังพิจารณา

2) True negative (TN) คือ ผลที่โมเดลทำนายผิดกับข้อมูลจริงในชนิดพืชที่กำลังพิจารณา

3) False positive (FP) คือ ผลที่โมเดลทำนายผิดกับข้อมูลจริงในชนิดพืชที่ไม่ได้กำลัง

พิจารณา

4) False negative (FN) คือ ผลที่โมเดลทำนายตรงกับข้อมูลจริงในชนิดพืชที่ไม่ได้กำลัง

พิจารณา

สถานที่และระยะเวลาการทําวิจัย

1. สถานที่การทําวิจัย

ภาควิชาพืชไร่นา คณะเกษตร มหาวิทยาลัยเกษตรศาสตร์ กรุงเทพมหานคร


2. ระยะเวลาการทําวิจัย

เริ่มต้นเดือนตุลาคม พ.ศ. 2566 ถึง เดือนมกราคม พ.ศ. 2568


ผลและวิจารณ์

ผลการประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทืองด้วยโครงข่ายประสาทแบบคอนโวลูชันผ่านวิธีการถ่ายทอดการเรียนรู้ (Transfer Learning) จาก Pre-trained model จำนวน 3 แบบ ได้แก่ GoogLeNet (ImageNet), VGG19 และ InceptionV3 โดยโมเดลแต่ละแบบได้ถูกฝึกด้วยขั้นตอนวิธีปรับปรุงน้ำหนัก (Optimization Algorithm) จำนวน 2 แบบ คือ Stochastic Gradient Descent with Momentum (SGDM) และ Adaptive Moment Estimation (ADAM) Learning rate ที่ 0.0001


ผลการวิเคราะห์พบว่า โมเดลแต่ละแบบให้ค่าความแม่นยำในการจำแนกอยู่ในช่วง 90.77% ถึง 98.1% โดย InceptionV3 ซึ่งเป็นแบบจำลองขนาดกลาง ให้ค่าความแม่นยำสูงสุด (ภาพที่ 8) รองลงมาคือ GoogLeNet (ImageNet) ซึ่งเป็นแบบจำลองขนาดเล็ก (ภาพที่ 6) ในขณะที่ VGG19 ซึ่งเป็นแบบจำลองที่มีขนาดใหญ่ที่สุด กลับให้ค่าความแม่นยำต่ำที่สุด (ภาพที่ 7) ปรากฏการณ์ดังกล่าวอาจมีสาเหตุจากปัจจัยหลายประการ อาทิ การที่ VGG19 ต้องการทรัพยากรในการประมวลผลสูง และมีจำนวนพารามิเตอร์มากเมื่อเปรียบเทียบกับสถาปัตยกรรมอื่นๆ ที่ถูกพัฒนาขึ้นในยุคเดียวกัน หรือรุ่นใหม่มากกว่า โดย InceptionV3 มีเป้าหมายในการสกัดคุณสมบัติที่มีคุณภาพสูงพร้อมทั้งลดภาระค่าใช้จ่ายในการคำนวณของโมเดล (DigitalOcean, 2025) ซึ่งแตกต่างจาก VGG19 ในงานวิจัยนี้จะพบว่าอัลกอริทึม ADAM มีแนวโน้มที่จะให้ผลลัพธ์ที่ดีกว่าอัลกอริทึม SGDM เนื่องจาก ADAM มีกลไกการปรับอัตราการเรียนรู้แบบแปรผัน (adaptive learning rate) (Kingma & Ba, 2014) ซึ่งช่วยให้การฝึกโมเดล CNN มีความรวดเร็วและมีเสถียรภาพในการเข้าสู่ผลลัพธ์ที่ดีกว่า



ภาพที่ 6 ความแม่นยำของการประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทืองด้วย
 โมเดล GoogLeNet (ImageNet) (A) Stochastic Gradient Descent with Momentum (SGDM)
 (B) Adaptive Moment Estimation (ADAM)



ภาพที่ 7 ความแม่นยำของการประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทืองด้วย
 โมเดล VGG19 (A) Stochastic Gradient Descent with Momentum (SGDM)
 (B) Adaptive Moment Estimation (ADAM)



ภาพที่ 8 ความแม่นยำของการประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทืองด้วย
โมเดล InceptionV3 (A) Stochastic Gradient Descent with Momentum (SGDM)
(B) Adaptive Moment Estimation (ADAM)

Model	Optimizer	Learning rate	Accuracy (%)
GoogLeNet (ImageNet)	SGDM	0.0001	97.53
GoogLeNet (ImageNet)	ADAM	0.0001	98.00
VGG19	SGDM	0.0001	97.33
VGG19	ADAM	0.0001	97.37
InceptionV3	SGDM	0.0001	90.77
InceptionV3	ADAM	0.0001	98.10

ตารางที่ 1 เปรียบเทียบความแม่นยำแต่ละโมเดลและOptimizer

SGDM = Stochastic Gradient Descent with Momentum


ADAM = Adaptive Moment Estimation

หลังจากเปรียบเทียบความแม่นยำในแต่ละโมเดล(ตารางที่ 1) พบว่า InceptionV3 อัลกอริทึม ADAM (Learning rate 0.0001) ให้ความแม่นยำที่ 98.1 % ให้ค่าความแม่นยำในการจำแนกความแตกต่างของเมล็ดพันธุ์ปอเทียบกับเมล็ดพันธุ์ผักนึ่งที่ 98.10 เปอร์เซนต์ แสดงให้เห็นว่า InceptionV3 ไม่เพียง แต่ได้รับความแม่นยำสูงสุดเท่านั้น แต่ยังมีการสูญเสียต่ำสุดอีกด้วย ซึ่งบ่งชี้ว่าเป็น โมเดลที่มีประสิทธิภาพมากที่สุดสำหรับงานจำแนกประเภทนี้ (Jaithavil et al., 2022) จากชุดข้อมูลที่ถูกการแบ่งภาพเป็น 2 ส่วนสำหรับการฝึกอบรม (Train) และการตรวจสอบความถูกต้อง (Validation) 70:30 ตามลำดับ ดังนั้นชุดฝึกอบรมและการตรวจสอบความถูกต้องในแต่ละคลาสจึงประกอบด้วย ภาพ 3500 และ 1500 ภาพตามลำดับ

หลังจากนั้นเราจึงประเมินศักยภาพการจำแนกเมล็ดพันธุ์ปอเทียบกับผักนึ่งด้วย Confusion Matrix (ภาพที่ 9) ดังนี้

- 1) True positive (TP) คือ โมเดลบอกปอเทียบกับ ผลจริงคือปอเทียบกับ 1451 รูป
- 2) True negative (TN) คือ โมเดลบอกปอเทียบกับ ผลจริงคือผักนึ่ง 49 รูป
- 3) False positive (FP) คือ โมเดลบอกผักนึ่ง ผลจริงคือปอเทียบกับ 8 รูป
- 4) False negative (FN) คือ โมเดลบอกผักนึ่ง ผลจริงคือผักนึ่ง 1493 รูป

มีการคำนวณค่าต่างๆดังนี้ Accuracy, Precision, Recall/sensitivity และ F1 Score (ตารางที่



ภาพที่ 9 Confusion Matrix InceptionV3 อัลกอริทึม ADAM (Learning rate 0.0001)

*Class 1 ปอเทือง (*Crotalaria juncea*)

*Class 2 ผักบุ้ง (*Ipomoea aquatica*)

Accuracy	98.9%
Precision	99.5%
Recall/sensitivity	96.7%
F1 Score	98.1%

ตารางที่ 2 Accuracy, Precision, Recall/sensitivity และ F1 Score

สรุป

จากการทดลองนี้ พบว่าโมเดล Inception V3 อัลกอริทึม ADAM Learning rate 0.0001 สามารถให้ผลลัพธ์ความแม่นยำสูงสุดถึง 98.10% ในการจำแนกความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ปอเทือง ซึ่งแสดงให้เห็นถึงศักยภาพในการพัฒนาเป็นระบบปัญญาประดิษฐ์สำหรับการวิเคราะห์ภาพถ่ายเมล็ดพันธุ์ปอเทืองได้อย่างมีประสิทธิภาพ ผลลัพธ์ดังกล่าวมีความสอดคล้องกับงานวิจัยของ G C, Sunil et al. (2022) ที่ได้กล่าวถึงการประยุกต์ใช้การเรียนรู้เชิงลึกสำหรับการสร้างภาพแบบปริมาณงานสูงในการจำแนกเมล็ดพันธุ์ โดยเฉพาะอย่างยิ่งในกรณีที่เมล็ดพันธุ์มีความคล้ายคลึงกันสูง นอกจากนี้ ผลการวิจัยนี้ยังเป็นแนวทางสำหรับการพัฒนาต่อยอดเทคโนโลยีดังกล่าว เพื่อใช้งานบนอุปกรณ์เคลื่อนที่ เช่น โทรศัพท์มือถือ และในระบบสายพานการผลิตจริงในอนาคต

ข้อเสนอแนะ

พิจารณาปรับปรุงในส่วนของการถ่ายภาพ โดยการลบพื้นหลังออก เพื่อเพิ่มความแม่นยำในการวิเคราะห์ให้ดียิ่งขึ้น รวมถึงการปรับแต่งฟังก์ชันในการเทรนเพื่อเสริมประสิทธิภาพเพิ่มเติม

เอกสารและสิ่งอ้างอิง

- กรมพัฒนาที่ดิน. 2550. การปลูกปอเทืองเพื่อผลิตเมล็ดพันธุ์พืชปุ๋ยสด. เอกสารเพื่อการถ่ายทอดเทคโนโลยี ชุดความรู้และเทคโนโลยีการพัฒนาที่ดิน. สำนักนิเทศและถ่ายทอดเทคโนโลยีการพัฒนาที่ดิน กรมพัฒนาที่ดิน กระทรวงเกษตรและสหกรณ์.
- จวงจันทร์ ดวงพัตรา. 2529. เทคโนโลยีเมล็ดพันธุ์ (พิมพ์ครั้งที่ 2). ม.ป.ท.
- พิมพ์วิภา ประกอบกิจ. 2562. การปรับปรุงประสิทธิภาพในการจำแนกภาพด้วยโครงข่ายประสาทแบบคอนโวลูชันโดยใช้เทคนิคการเพิ่มภาพ. วารสารสถาบันเทคโนโลยีไทย-ญี่ปุ่น : วิศวกรรมศาสตร์และเทคโนโลยี, 7(1), 59-64. แหล่งที่มา
<https://ph01.tci-thaijo.org/index.php/TNIJournal/article/download/182318/137882/>
- DataM Intelligence. 2024. **Sunn Hemp Seeds Market**. Retrieved from
<https://www.datamintelligence.com/research-report/sunn-hemp-seeds-market>
- DigitalOcean. 2025. **Popular Deep Learning Architectures: ResNet, InceptionV3, SqueezeNet**. Retrieved from <https://www.digitalocean.com/community/tutorials/popular-deep-learning-architectures-resnet-inceptionv3-squeezenet>
- G C, Sunil & Zhang, Yu & Koparan, Cengiz & Ahmed, Mohammed & Howat, Kirk & Sun, Xin. 2022. Weed and crop species classification using computer vision and deep learning technologies in greenhouse conditions. **Journal of Agriculture and Food Research**. 9. 100325. 10.1016/j.jafr.2022.100325.
- GeeksforGeeks. 2021. **Understanding GoogleNet Model - CNN Architecture**. Retrieved from
<https://www.geeksforgeeks.org/understanding-googlenet-model-cnn-architecture/>
- Ghayoumi, M. 2021. **Deep Learning in Practice**. CRC Press.
- Google Cloud. 2022. **What is artificial intelligence?** Retrieved from
<https://cloud.google.com/learn/what-is-artificial-intelligence/>
- Gurney, K. 2018. **An Introduction to Neural Networks**. CRC Press.
- Heuzé V., Thiollot H., Tran G., Lebas F., 2018. **Sunn hemp (Crotalaria juncea)**. Feedipedia, a programme by INRAE, CIRAD, AFZ and FAO. <https://feedipedia.org/node/313>
- IBM. 2022. **What are convolutional neural networks (CNNs)?** Retrieved from
<https://www.ibm.com/think/topics/convolutional-neural-networks>


- ISTA. 2023. **International Rules for Seed Testing**, Bassersdorf, Switzerland, International Seed Testing Association.
- Jaithavil, D., Triamlumlerd, S., & Pracha, M. 2022. **Paddy seed variety classification using transfer learning based on deep learning.** 1–4. <https://doi.org/10.1109/IEECON53204.2022.9741677>
- Kelleher, J. D. 2019. **Deep Learning**. MIT Press.
- Kingma, D.P., & Ba, J. 2014. **Adam: A Method for Stochastic Optimization**. CoRR, abs/1412.6980.
- LeCun, Y., Bengio, Y. & Hinton, G. 2015. **Deep learning**. *Nature*, 521, 436-444. <http://dx.doi.org/10.1038/nature14539>
- Maeda-Gutiérrez, V., Oropeza-Valdez, J. J., Reveles-Gómez, L. C., Padron-Manrique, C., Resendis-Antonio, O., Solís-Sánchez, L. O., Guerrero-Osuna, H. A., & Olvera Olvera, C. A. 2025. AI-Driven Plant Health Assessment: A Comparative Analysis of Inception V3, ResNet-50 and ViT with SHAP for Accurate Disease Identification in Taro. **Agronomy**, 15(1), 77. <https://doi.org/10.3390/agronomy15010077>
- NASA. 2024. **What is Artificial Intelligence?** แหล่งที่มา <https://www.nasa.gov/what-is-artificial-intelligence/>
- Nguyen, T.-H., Nguyen, T.-N., & Ngo, B.-V. 2022. A VGG-19 Model with Transfer Learning and Image Segmentation for Classification of Tomato Leaf Disease. **AgriEngineering**, 4(4), 871-887. <https://doi.org/10.3390/agriengineering4040056>
- Ninkaew, S., Pornpongrueng, P., Balslev, H., & Chantaranothai, P. 2017. Seed morphology of nineteen *Crotalaria* L. (Fabaceae) species in Thailand. **Thai Forest Bulletin (Botany)**, 45(1), 47–57. <https://doi.org/10.20531/tfb.2017.45.1.09>
- Pittan, Jasitha & M R, Dileep & Divya, M. 2019. **Venation Based Plant Leaves Classification Using GoogLeNet and VGG**. 715-719. 10.1109/RTEICT46194.2019.9016966.
- Rowan University. 2024. **AI Benefits**. Retrieved from <https://irt.rowan.edu/about/news/2024/10/ai-benefits.html>
- Scottish AI. 2024. **The History of AI**. Retrieved from <https://www.scottishai.com/news/the-history-of-ai>

- Simonyan, K., & Zisserman, A. 2015. Very deep convolutional networks for large-scale image recognition. **3rd International Conference on Learning Representations (ICLR 2015)**, 1– 14.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S. E., Anguelov, D., Erhan, D., Vanhoucke, V. & Rabinovich, A. 2015a. Going deeper with convolutions.. CVPR (p./pp. 1-9), : **IEEE Computer Society**. ISBN: 978-1-4673-6964-0
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. 2015b. **Rethinking the Inception Architecture for Computer Vision**. arXiv: Computer Vision and Pattern Recognition. <https://arxiv.org/abs/1512.00567>
- UFLDL. 2020. **Convolutional Neural Network. UFLDL Tutorial**. Retrieved from <http://ufldl.stanford.edu/tutorial/supervised/ConvolutionalNeuralNetwork/>
- University of Illinois Chicago. 2023. **AI (Artificial Intelligence): What is the definition of AI and how does AI work?**. Retrieved from <https://meng.uic.edu/news-stories/ai-artificial-intelligence-what-is-the-definition-of-ai-and-how-does-ai-work/>
- University of Notre Dame. 2024. **AI overview and definitions**. Retrieved from <https://learning.nd.edu/resource-library/ai-overview-and-definitions/>

ภาคผนวก



ภาพผนวกที่ 1 ภาพถ่ายเมล็ดพันธุ์ปอเทือง พร้อมพื้นหลัง




ภาพผนวกที่ 2 ภาพถ่ายเมล็ดพันธุ์ผักนึ่ง พร้อมพื้นหลัง




ภาพผนวกที่ 3 การเตรียมภาพถ่ายเมล็ดพันธุ์ปอเทืองพร้อมพื้นหลัง ด้วยโทรศัพท์มือถือพร้อมเลนส์มือถือมาโคร




ภาพผนวกที่ 4 การเตรียมภาพถ่ายเมล็ดพันธุ์ผักบุ้งพร้อมพื้นหลัง ด้วยโทรศัพท์มือถือพร้อมเลนส์มือถือมาโคร




ภาพผนวกที่ 5 ภาพถ่ายเมล็ดพันธุ์ปอเทือง ใน 5,000 เมล็ดจัดเก็บไว้ในคอมพิวเตอร์



ภาพผนวกที่ 6 ภาพถ่ายเมล็ดพันธุ์ฝักบัว ใน 5,000 เมล็ดจัดเก็บไว้ในคอมพิวเตอร์



ภาพผนวกที่ 7 นำภาพถ่ายที่จัดเก็บไว้มาปรับเปลี่ยนขนาด



ภาพผนวกที่ 8 การวิเคราะห์ภาพถ่ายโดยใช้ CNN ผ่านวิธี Transfer learning จาก Pre-trained model

ประวัติการศึกษาและการทำงาน

ชื่อ-นามสกุล	ณิชกร แผลงภู
วัน เดือน ปี เกิด	15 ธันวาคม พ.ศ.2545
สถานที่เกิด	อำเภอห้วยคต จังหวัดอุทัยธานี
ประวัติการศึกษา	โรงเรียนบ้านไร่วิทยา จังหวัดอุทัยธานี
ตำแหน่งหน้าที่การงานปัจจุบัน	-
สถานที่ทำงานปัจจุบัน	-
ผลงานดีเด่นและรางวัลทางวิชาการ	-
ทุนการศึกษาที่ได้รับ	-