

เทคนิคการเพิ่มความแม่นยำสำหรับการจำแนกสายพันธุ์ของยุงด้วยวิธีการเรียนรู้แบบถ่ายโอน การ  
เพิ่มปริมาณข้อมูลภาพ และสัญญาณตกหายเชิงพื้นที่



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต  
สาขาวิชาวิศวกรรมไฟฟ้า ภาควิชาวิศวกรรมไฟฟ้า  
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย  
ปีการศึกษา 2565  
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Techniques for Mosquito Classification Accuracy Improvement Using Transfer  
Learning, Data Augmentation, and Spatial Dropout



A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of Master of Engineering in Electrical Engineering

Department of Electrical Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2022

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	เทคนิคการเพิ่มความแม่นยำสำหรับการจำแนกสายพันธุ์ของยุงด้วยวิธีการเรียนรู้แบบถ่ายโอน การเพิ่มปริมาณข้อมูลภาพ และสัญญาณตกหายเชิงพื้นที่
โดย	นายกตัญญู ธาราวัชรศาสตร์
สาขาวิชา	วิศวกรรมไฟฟ้า
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	รองศาสตราจารย์ ดร.วันเฉลิม โปรา

---

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้บัณฑิตวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

.....	คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)	
คณะกรรมการสอบวิทยานิพนธ์	ประธานกรรมการ
.....	
(รองศาสตราจารย์ ดร.นริศรา จริยะพันธุ์)	อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
.....	
(รองศาสตราจารย์ ดร.วันเฉลิม โปรา)	กรรมการ
.....	
(ผู้ช่วยศาสตราจารย์ ดร.สุรีย์ พุ่มรินทร์)	กรรมการภายนอกมหาวิทยาลัย
.....	
(ศาสตราจารย์ ดร.สัญญา มิตรเอม)	



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

กัตัญญู ธาธาวัชรศาสตร์ : เทคนิคการเพิ่มความแม่นยำสำหรับการจำแนกสายพันธุ์ของยุงด้วยวิธีการเรียนรู้แบบถ่ายโอน การเพิ่มปริมาณข้อมูลภาพ และสัญญาณตกหายเชิงพื้นที่. ( Techniques for Mosquito Classification Accuracy Improvement Using Transfer Learning, Data Augmentation, and Spatial Dropout) อ.ที่ปรึกษาหลัก : รศ. ดร.วันเฉลิม โปรา

งานวิจัยนี้มีวัตถุประสงค์เพื่อปรับปรุงประสิทธิภาพของโครงข่ายประสาทเทียมสำหรับการจำแนกยุงโดยใช้การเรียนรู้แบบถ่ายโอน การเพิ่มข้อมูล และเทคนิคสัญญาณตกหายเชิงพื้นที่ ยุง 7 ชนิดรวบรวมจากหลายจังหวัดของประเทศไทย ได้แก่ *Aedes aegypti*, *Aedes albopictus*, *Aedes vexans*, *Anopheles tessellatus*, *Culex quinquefasciatus*, *Culex vishnui* และยุงชนิดอื่นๆ รวมถึง *Aedes aegypti*, *Aedes albopictus* และ *Culex quinquefasciatus* ที่เลี้ยงในภาควิชาปรสิตวิทยา คณะแพทยศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ได้นำมาใช้ในการศึกษาครั้งนี้ ภาพยุงถูกถ่าย 3 ถึง 5 ครั้งต่อตัวอย่าง และครอบตัดรอบๆ ยุง จากนั้นปรับขนาดเป็น 512 x 512 พิกเซล หลังจากนั้นจึงนำภาพไปใช้โดยใช้เทคนิคการเพิ่มข้อมูล ได้แก่ การหมุน การครอบตัดแบบสุ่ม ความสว่างแบบสุ่ม สีสุ่ม และการฉีดสัญญาณรบกวนแบบเกาส์เซียน แบบจำลอง VGG-16 ประยุกต์เทคนิคการเรียนรู้การถ่ายโอนโดยใช้น้ำหนัก ImageNet เป็นน้ำหนักเริ่มต้น และดัดแปลงเป็นแบบจำลอง VGG-16 แบบสองอินพุต นอกจากนี้ แบบจำลองยังใช้เลเยอร์ดรอปเอาต์เชิงพื้นที่หลังจากบล็อกคอนโวลูชัน โมเดล VGG-16 สองอินพุตสามแบบได้รับการพัฒนา ได้แก่ VGG-16 แบบรวมในช่วงต้น, VGG-16 แบบรวมตรงกลาง และ VGG-16 แบบรวมในภายหลัง และแบบจำลองทั้งชุดได้รับการพัฒนาโดยใช้ผลลัพธ์ของแบบจำลอง 3 แบบเป็นอินพุตสำหรับการจำแนกยุง โมเดลเหล่านี้มีความแม่นยำในการจำแนกโดยเฉลี่ยที่ 95.76%, 97.08%, 96.76% และ 99.44% จากการฝึกและทดสอบ 10 ครั้ง ตามลำดับ นอกจากนี้ ยังนำแบบจำลองเหล่านี้ ไปใช้ในการบริการจำแนกยุงผ่านแอปพลิเคชัน LINE และอนุญาตให้ผู้เชี่ยวชาญขอภาพยุงและส่งข้อมูลผลการจำแนกยุงไปยังระบบผ่านแอปพลิเคชัน LINE ไปยังฐานข้อมูลได้

จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

สาขาวิชา วิศวกรรมไฟฟ้า  
ปีการศึกษา 2565

ลายมือชื่อนิสิต .....  
ลายมือชื่อ อ.ที่ปรึกษาหลัก .....

# # 6272001921 : MAJOR ELECTRICAL ENGINEERING

KEYWORD: convolutional neural network, mosquito classification, VGG-16 model, transfer learning, data augmentation, spatial dropout

Katanyu Tharawatcharasart : Techniques for Mosquito Classification Accuracy Improvement Using Transfer Learning, Data Augmentation, and Spatial Dropout.  
Advisor: Assoc. Prof. WANCHALERM PORA

The objective of this research was to improve the performance of a convolutional neural network for mosquito classification using transfer learning, data augmentation, and spatial dropout technique. Seven species of mosquitoes collected from several provinces of Thailand including *Aedes aegypti*, *Aedes albopictus*, *Aedes vexans*, *Anopheles tessellatus*, *Culex quinquefasciatus*, *Culex vishnui*, and other mosquitoes, and also *Aedes aegypti*, *Aedes albopictus* and *Culex quinquefasciatus* reared in an insectary at the Department of Parasitology, Faculty of Medicine, Chulalongkorn University were used in this study. Mosquito images were taken 3 to 5 times per specimen and cropped around the mosquito, then resized to 512 x 512 pixels. After that, the images were applied using data augmentation techniques including zoom, rotation, random crop, random brightness, random hue, and Gaussian noise injection. VGG-16 model was applied transfer learning technique using ImageNet weights as initial weights and modified to be two-inputs VGG-16 models. Furthermore, models applied spatial dropout layers after convolutional blocks. Three two-input VGG-16 models were developed including early-combined VGG-16, middle-combined VGG-16, and late-combined VGG-16, and an ensemble model was also developed using the results of 3 models as inputs for mosquito classification. These models achieved an average classification accuracy of 95.76%, 97.08%, 96.76%, and 99.44% over 10 train and test runs respectively. Moreover, these models were deployed for mosquito classification service via the LINE application, and the experts are allowed to request mosquito images and send their classification results to the system via the LINE application to the database.

Field of Study: Electrical Engineering

Student's Signature .....

Academic Year: 2022

Advisor's Signature .....

## กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้จะไม่สำเร็จได้หากปราศจาก รศ.ดร. วันเฉลิม โปรา อาจารย์ที่ปรึกษาที่ได้ให้การสนับสนุนช่วยเหลือในด้านคำปรึกษาในงานวิจัย อุปกรณ์งานวิจัย และเรื่องอื่น ๆ ที่นอกเหนือไปจากด้านการศึกษา รวมไปถึงอาจารย์และสมาชิกในห้องปฏิบัติการวิจัยระบบสมองกลฝังตัวและการออกแบบวงจรรวม (Embedded System and IC Design Research Laboratory) ที่ให้คอยความช่วยเหลือและคำปรึกษา และขอขอบคุณครอบครัวที่คอยให้กำลังใจและสนับสนุนเรื่อยมา

ขอขอบพระคุณ รศ.ดร. นริศรา จริยะพันธุ์ และ คุณ รินนารา อัมพล ภาควิชาปรสตีวิทยา คณะแพทยศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย สำหรับการเก็บตัวอย่างและเพาะเลี้ยงยุง รวมไปถึงการถ่ายรูปยุงที่นำมาใช้ในวิทยานิพนธ์ฉบับนี้



กตัญญู ธาธาวัชรศาสตร์

จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

## สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย .....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ .....	ฉ
สารบัญตาราง .....	ญ
สารบัญรูปภาพ .....	ฎ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	2
1.3 ขอบเขตงานวิจัย.....	2
1.4 วิธีการดำเนินการวิจัย.....	3
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	3
บทที่ 2 หลักการและทฤษฎีที่เกี่ยวข้อง .....	4
2.1 การเรียนรู้ของเครื่อง (Machine Learning).....	4
2.1.1 กลุ่มปัญหาการเรียนรู้ (Learning Problems).....	4
2.1.2 กลุ่มปัญหาการเรียนรู้แบบไฮบริด (Hybrid Learning Problems).....	5
2.1.3 กลุ่มการอนุมานทางสถิติ (Statistical Inference).....	6
2.1.4 กลุ่มกลวิธีการเรียนรู้ (Learning Technique) .....	6
2.2 โครงข่ายประสาทเทียม (Neural Networks).....	7

2.2.1	ชนิดของโครงข่ายประสาทเทียม (Neural Networks)	7
2.2.2	ส่วนประกอบของโครงข่ายประสาทเทียมแบบคอนโวลูชัน	9
1.	ชั้น Conv2D	9
2.	ฟังก์ชันกระตุ้น (Activation Function)	10
2.1	ฟังก์ชัน Sigmoid	11
2.2	ฟังก์ชัน Tanh	11
2.3	ฟังก์ชัน ReLU (Rectified Linear Unit)	12
2.4	ฟังก์ชัน LeakyReLU	13
2.5	ฟังก์ชัน Softmax	13
3.	ชั้น Pooling	14
4.	ชั้น Flatten	15
5.	ชั้น Fully connected	15
6.	ชั้น Dropout	15
7.	ชั้น Dropout ภายในชั้นคอนโวลูชัน	15
2.2.3	วิธีการประเมินความแม่นยำของโครงข่ายประสาทเทียม	17
2.2.3.1	ค่าความแม่นยำ (Accuracy)	17
2.2.3.2	ค่าความเที่ยงตรง (Precision)	18
2.2.3.3	ค่าการเรียกคืน (Recall)	18
2.2.3.4	ค่า F1 หรือ F-Measure	18
2.3	สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Architecture of CNN)	18
2.3.1	LeNet	18
2.3.2	AlexNet	19
2.3.3	GoogLeNet	19
2.3.4	VGGNet	21



2.3.5 ResNet .....	21
2.4 สายพันธุ์ของยุงที่ปรากฏในงานวิจัย.....	22
2.5 โรคที่เกิดจากยุงเป็นพาหะนำโรค (Mosquito-borne Diseases).....	24
2.5.1 ไข้มาลาเรีย (Malaria) .....	24
2.5.2 ไข้เหลือง (Yellow Fever) .....	24
2.5.3 ไข้เลือดออก (Dengue).....	25
2.5.4 โรคไขสมองอักเสบเจอี (Japanese Encephalitis Virus).....	25
2.5.5 โรคไขสมองอักเสบจากไวรัสเวสต์ไนล์ (West Nile Virus).....	25
2.5.6 โรคชิคุนกุนยา (Chikungunya) .....	25
2.5.7 โรคเท้าช้าง (Filariasis).....	26
2.6 การจำแนกสายพันธุ์ยุง (Mosquito Classification).....	26
บทที่ 3 การเพิ่มความแม่นยำของโครงข่ายประสาทเทียม .....	28
3.1 การเรียนรู้แบบถ่ายโอน (Transfer Learning).....	28
3.2 การเพิ่มปริมาณข้อมูล (Data Augmentation) .....	28
3.3 การสร้างชุดข้อมูล (Dataset) และการติดป้าย (Labeling).....	30
3.4 กรรณวิธีพัฒนาโครงข่ายประสาทเทียมสำหรับการจำแนกประเภทสายพันธุ์ยุง.....	39
บทที่ 4 ผลการทำงานของระบบ.....	46
4.1 ผลลัพธ์การทำงานของแบบจำลอง VGG-16 และ VGG-19 บนชุดข้อมูลยุงจากประเทศเกาหลีใต้.....	46
4.1.1 การเพิ่มปริมาณข้อมูลภาพ (Data Augmentation) ชุดข้อมูลภาพยุงจากประเทศเกาหลีใต้ .....	46
4.1.2 แบบจำลอง VGG-16 .....	52
4.1.3 แบบจำลอง VGG-19 .....	56
4.2 ผลลัพธ์การทำงานของแบบจำลอง VGG-16 บนชุดข้อมูลของยุงในประเทศไทย .....	60

4.3 การจำแนกยูจจากภาพอัตโนมัติผ่าน LINE API.....	77
4.4 การใช้งานผ่านแอปพลิเคชันไลน์.....	78
บทที่ 5 บทสรุปงานวิจัย .....	84
5.1 สรุปผลงานวิจัย .....	84
5.2 แนวการพัฒนางานวิจัย .....	85
บรรณานุกรม .....	88
ประวัติผู้เขียน .....	92



## สารบัญตาราง

	หน้า
ตารางที่ 1 ชนิดตัวอย่างยุงในประเทศไทย แหล่งที่เก็บตัวอย่าง และจำนวนภาพ.....	24
ตารางที่ 2 ความเป็นเชิงเส้น-ไม่เป็นเชิงเส้นของฟังก์ชันที่ใช้เพิ่มขนาดชุดข้อมูลภาพ.....	68
ตารางที่ 3 ค่าความแม่นยำของแบบจำลอง early-combined VGG-16 middle-combined VGG-16 late-combined VGG-16 และ แบบจำลอง ensemble บนชุดข้อมูลยุงในประเทศไทย.....	68



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

## สารบัญรูปภาพ

	หน้า
รูปที่ 1 ชนิดของโครงข่ายประสาทเทียม (Neural Network) ที่เกี่ยวข้องกับงานวิจัย .....	8
รูปที่ 2 โครงสร้างโครงข่ายประสาทเทียมแบบคอนโวลูชัน [10] .....	9
รูปที่ 3 ชั้น Conv2D ที่กำหนดค่า padding เป็น valid .....	10
รูปที่ 4 ชั้น Conv2D ที่กำหนดค่า padding เป็น same .....	10
รูปที่ 5 ฟังก์ชัน Sigmoid.....	11
รูปที่ 6 ฟังก์ชัน tanh.....	12
รูปที่ 7 ฟังก์ชัน ReLU .....	12
รูปที่ 8 ฟังก์ชัน LeakyReLU.....	13
รูปที่ 9 max pooling .....	14
รูปที่ 10 average pooling.....	14
รูปที่ 11โครงข่ายประสาทเทียมแบบปกติ และโครงข่ายประสาทเทียมที่ใช้วิธี dropout .....	15
รูปที่ 12 Standard Dropout.....	16
รูปที่ 13 Spatial Dropout.....	16
รูปที่ 14 confusion matrix.....	17
รูปที่ 15 โครงสร้างสถาปัตยกรรม LeNet-5 [12].....	19
รูปที่ 16 โครงสร้างสถาปัตยกรรม AlexNet [9] .....	19
รูปที่ 17 โครงสร้างสถาปัตยกรรม GoogLeNet [13] .....	20
รูปที่ 18 โครงสร้างสถาปัตยกรรม VGG-16 [15] .....	21
รูปที่ 19 โครงสร้างสถาปัตยกรรม ResNet-12 [17].....	22
รูปที่ 20 ภาพถ่ายยุง <i>Aedes albopictus</i> ที่ผ่านการเพิ่มปริมาณข้อมูลภาพด้วยฟังก์ชัน Rotate....	28

รูปที่ 21 ภาพถ่ายยุง <i>Aedes albopictus</i> ที่ผ่านการเพิ่มปริมาณข้อมูลภาพด้วยฟังก์ชัน MultiplyHue.....	28
รูปที่ 22 ภาพถ่ายยุง <i>Aedes albopictus</i> ที่ผ่านการเพิ่มปริมาณข้อมูลภาพด้วยฟังก์ชัน MultiplyBrightness.....	29
รูปที่ 23 ภาพถ่ายยุง <i>Aedes albopictus</i> ที่ผ่านการเพิ่มปริมาณข้อมูลภาพด้วยฟังก์ชัน Scale.....	29
รูปที่ 24 ภาพถ่ายยุง <i>Aedes albopictus</i> ที่ผ่านการเพิ่มปริมาณข้อมูลภาพด้วยฟังก์ชัน LinearContrast.....	29
รูปที่ 25 ภาพถ่ายยุง <i>Aedes albopictus</i> ที่ผ่านการเพิ่มปริมาณข้อมูลภาพด้วยฟังก์ชัน CenterCropToFixedSize .....	29
รูปที่ 26 ตัวอย่างยุงสายพันธุ์ <i>Aedes albopictus</i> .....	30
รูปที่ 27 ตัวอย่างยุงสายพันธุ์ <i>Aedes vexans</i> .....	31
รูปที่ 28 ตัวอย่างยุงสายพันธุ์ <i>Anopheles sinensis</i> .....	31
รูปที่ 29 ตัวอย่างยุงสายพันธุ์ <i>Culex pipiens</i> .....	32
รูปที่ 30 ตัวอย่างยุงสายพันธุ์ <i>Culex tritaeniorhynchus</i> .....	32
รูปที่ 31 ตัวอย่างยุงสายพันธุ์ <i>Aedes koreikus</i> .....	33
รูปที่ 32 ตัวอย่างยุงสายพันธุ์ <i>Aedes dorsalis</i> .....	33
รูปที่ 33 ตัวอย่างยุงสายพันธุ์ <i>Culex inatomii</i> .....	34
รูปที่ 34 ชุดอุปกรณ์ถ่ายภาพยุง .....	35
รูปที่ 35 ตัวอย่างภาพยุงจากกล้องโทรศัพท์มือถือ.....	35
รูปที่ 36 ตัวอย่างยุงสายพันธุ์ <i>Aedes aegypti</i> .....	36
รูปที่ 37 ตัวอย่างยุงสายพันธุ์ <i>Aedes albopictus</i> .....	36
รูปที่ 38 ตัวอย่างยุงสายพันธุ์ <i>Aedes vexans</i> .....	37
รูปที่ 39 ตัวอย่างยุงสายพันธุ์ <i>Anopheles tessellatus</i> .....	37
รูปที่ 40 ตัวอย่างยุงสายพันธุ์ <i>Culex quinquefasciatus</i> .....	38
รูปที่ 41 ตัวอย่างยุงสายพันธุ์ <i>Culex vishnui</i> .....	38

รูปที่ 42 ตัวอย่างยุงอื่น ๆ.....	39
รูปที่ 43 ตัวอย่างการติดป้ายข้อมูลตามคลาส .....	40
รูปที่ 44 แบบจำลอง VGG-16.....	41
รูปที่ 45 แบบจำลอง VGG-16 ที่มีการเพิ่มขึ้น spatial dropout.....	42
รูปที่ 46 (ซ้าย) dropout แบบทั่วไปของแผนที่คุณลักษณะ 3 มิติ (ขวา) spatial dropout ของแผนที่คุณลักษณะ 3 มิติ .....	42
รูปที่ 47 การรวมข้อมูลเข้าด้วยกันโดยมีแนวความคิดจาก spatial dropout .....	43
รูปที่ 48 แบบจำลอง early-combined VGG-16 .....	43
รูปที่ 49 แบบจำลอง middle-combined VGG-16 .....	44
รูปที่ 50 แบบจำลอง late-combined VGG-16 .....	44
รูปที่ 51 การบวนการทำนายผลซึ่งประกอบไปด้วยแบบจำลอง VGG-16 ทั้ง 3 แบบจำลอง และนำผลลัพธ์ที่ได้ไปทำนายร่วมกันโดยใช้แบบจำลอง ensemble .....	45
รูปที่ 52 ตัวอย่างชุดข้อมูลภาพ <i>Aedes albopictus</i> ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ .....	46
รูปที่ 53 ตัวอย่างชุดข้อมูลภาพ <i>Aedes albopictus</i> หลังได้รับการเพิ่มปริมาณข้อมูลภาพ.....	47
รูปที่ 54 ตัวอย่างชุดข้อมูลภาพ <i>Aedes vexans</i> ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ.....	47
รูปที่ 55 ตัวอย่างชุดข้อมูลภาพ <i>Aedes vexans</i> หลังได้รับการเพิ่มปริมาณข้อมูลภาพ .....	48
รูปที่ 56 ตัวอย่างชุดข้อมูลภาพ <i>Anopheles sinensis</i> ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ .....	48
รูปที่ 57 ตัวอย่างชุดข้อมูลภาพ <i>Anopheles sinensis</i> หลังได้รับการเพิ่มปริมาณข้อมูลภาพ.....	49
รูปที่ 58 ตัวอย่างชุดข้อมูลภาพ <i>Culex pipiens</i> ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ .....	49
รูปที่ 59 ตัวอย่างชุดข้อมูลภาพ <i>Culex pipiens</i> หลังได้รับการเพิ่มปริมาณข้อมูลภาพ.....	50
รูปที่ 60 ตัวอย่างชุดข้อมูลภาพ <i>Culex tritaeniorhynchus</i> ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ .....	50
รูปที่ 61 ตัวอย่างชุดข้อมูลภาพ <i>Culex tritaeniorhynchus</i> หลังได้รับการเพิ่มปริมาณข้อมูลภาพ..	51
รูปที่ 62 ตัวอย่างชุดข้อมูลภาพ Non vectors ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ.....	51
รูปที่ 63 ตัวอย่างชุดข้อมูลภาพ Non vectors หลังได้รับการเพิ่มปริมาณข้อมูลภาพ.....	52

รูปที่ 64 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 1.....	53
รูปที่ 65 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 2.....	54
รูปที่ 66 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 3.....	55
รูปที่ 67 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 4.....	56
รูปที่ 68 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 1.....	57
รูปที่ 69 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 2.....	58
รูปที่ 70 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 3.....	59
รูปที่ 71 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 4.....	60
รูปที่ 72 ตัวอย่างชุดข้อมูลภาพ <i>Aedes aegypti</i> ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ .....	61
รูปที่ 73 ตัวอย่างชุดข้อมูลภาพ <i>Aedes aegypti</i> หลังได้รับการเพิ่มปริมาณข้อมูลภาพ.....	61
รูปที่ 74 ตัวอย่างชุดข้อมูลภาพ <i>Aedes albopictus</i> ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ .....	62
รูปที่ 75 ตัวอย่างชุดข้อมูลภาพ <i>Aedes albopictus</i> หลังได้รับการเพิ่มปริมาณข้อมูลภาพ.....	62
รูปที่ 76 ตัวอย่างชุดข้อมูลภาพ <i>Aedes vexans</i> ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ.....	63
รูปที่ 77 ตัวอย่างชุดข้อมูลภาพ <i>Aedes vexans</i> หลังได้รับการเพิ่มปริมาณข้อมูลภาพ .....	63
รูปที่ 78 ตัวอย่างชุดข้อมูลภาพ <i>Anopheles tessellatus</i> ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ....	64
รูปที่ 79 ตัวอย่างชุดข้อมูลภาพ <i>Anopheles tessellatus</i> หลังได้รับการเพิ่มปริมาณข้อมูลภาพ....	64
รูปที่ 80 ตัวอย่างชุดข้อมูลภาพ <i>Culex quinquefasciatus</i> ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ..	65
รูปที่ 81 ตัวอย่างชุดข้อมูลภาพ <i>Culex quinquefasciatus</i> หลังได้รับการเพิ่มปริมาณข้อมูลภาพ ..	65
รูปที่ 82 ตัวอย่างชุดข้อมูลภาพ <i>Culex vishnui</i> ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ.....	66
รูปที่ 83 ตัวอย่างชุดข้อมูลภาพ <i>Culex vishnui</i> หลังได้รับการเพิ่มปริมาณข้อมูลภาพ .....	66
รูปที่ 84 ตัวอย่างชุดข้อมูลภาพ Others ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ .....	67
รูปที่ 85 ตัวอย่างชุดข้อมูลภาพ Others หลังได้รับการเพิ่มปริมาณข้อมูลภาพ.....	67
รูปที่ 86 โครงสร้างแบบจำลอง early-combined VGG-16 .....	69
รูปที่ 87 ผลลัพธ์การฝึกของแบบจำลอง early-combined VGG-16.....	70

รูปที่ 88 confusion matrix ของแบบจำลอง early-combined VGG-16 บนชุดข้อมูลทดสอบ.....	70
รูปที่ 89 ค่าความเที่ยงตรง (Precision) ค่าการเรียกคืน (Recall) และค่า F1 ของแต่ละคลาสของชุดข้อมูลทดสอบ.....	71
รูปที่ 90 โครงสร้างแบบจำลอง middle-combined VGG-16 .....	71
รูปที่ 91 ผลลัพธ์การฝึกของแบบจำลอง middle-combined VGG-16.....	72
รูปที่ 92 confusion matrix ของแบบจำลอง middle-combined VGG-16 บนชุดข้อมูลทดสอบ.....	72
รูปที่ 93 ค่าความเที่ยงตรง (Precision) ค่าการเรียกคืน (Recall) และค่า F1 ของแต่ละคลาสของชุดข้อมูลทดสอบ.....	73
รูปที่ 94 โครงสร้างแบบจำลอง late-combined VGG-16 .....	73
รูปที่ 95 ผลลัพธ์การฝึกของแบบจำลอง late-combined VGG-16.....	74
รูปที่ 96 confusion matrix ของแบบจำลอง late-combined VGG-16 บนชุดข้อมูลทดสอบ.....	74
รูปที่ 97 ค่าความเที่ยงตรง (Precision) ค่าการเรียกคืน (Recall) และค่า F1 ของแต่ละคลาสของชุดข้อมูลทดสอบ.....	75
รูปที่ 98 กระบวนการการทำงานของการทำงานโดยใช่การใช้การบวกผลลัพธ์ค่าความมั่นใจของแบบจำลองทั้งสามแบบ .....	75
รูปที่ 99 confusion matrix ของการทำงานโดยใช่แบบจำลองทั้งสามแบบในการร่วมกันทำนายผล.....	76
รูปที่ 100 ค่าความเที่ยงตรง (Precision) ค่าการเรียกคืน (Recall) และค่า F1 ของแต่ละคลาสของชุดข้อมูลทดสอบ.....	76
รูปที่ 101 ตัวอย่างผลการทำงานการทำงานผลร่วมกันโดยใช้แบบจำลอง ANN.....	77
รูปที่ 102 กระบวนการทำงานของระบบจำแนกยู่งอัตโนมัติผ่าน LINE API.....	77
รูปที่ 103 โลโก้ Official Account สำหรับการจำแนกยู่ง.....	79
รูปที่ 104 ข้อความตอบกลับเมื่อผู้ใช้ทำการส่งข้อความที่ไม่ใช่รูปภาพ.....	80
รูปที่ 105 ข้อความตอบกลับเมื่อผู้ใช้ทำการส่งข้อความที่เป็นรูปภาพที่ไม่ใช่ยู่ง .....	80
รูปที่ 106 ข้อความตอบกลับเมื่อผู้ใช้ทำการส่งภาพยู่งเข้ามาแต่ไม่ผ่านเกณฑ์การตรวจสอบค่าความคมชัด.....	81



รูปที่ 107 ข้อความตอบกลับเมื่อผู้ใช้ทำการส่งภาพพุงภาพที่ 1.....	81
รูปที่ 108 ข้อความตอบกลับเมื่อผู้ใช้ทำการส่งภาพที่ 2.....	82
รูปที่ 109 ข้อความตอบกลับเมื่อผู้ใช้ทำการส่งภาพที่ 3 และสถานที่เข้าสู่ระบบ และข้อความตอบกลับ เป็นชนิดยุง.....	82
รูปที่ 110 ผู้เชี่ยวชาญส่งคีย์เวิร์ด ‘Identify’ ผ่านไลน์.....	83
รูปที่ 111 ผู้เชี่ยวชาญส่งข้อความตัวอักษรชนิดของยุง.....	83



## บทที่ 1 บทนำ

### 1.1 ที่มาและความสำคัญของปัญหา

ทั่วโลกมีประชากรป่วยจากโรคที่มีเยุงเป็นพาหะ เช่น โรคไข้เลือดออก โรคชิกุนงุนยา มาลาเรีย เป็นจำนวนมากในทุก ๆ ปี ในปี พ.ศ. 2562 ประเทศไทยมีจำนวนผู้ป่วยโรคไข้เลือดออกสะสมตั้งแต่วันที่ 1 มกราคม ถึง 21 ธันวาคม จำนวน 126,708 ราย และมีผู้เสียชีวิต จำนวน 132 ราย [1] จากข้อมูลของโครงการกำจัดโรคไข้มาลาเรียประเทศไทย (Thailand Malaria Elimination Program) พบว่า ในปี พ.ศ. 2563 มีผู้ที่ถูกตรวจพบเชื้อมาลาเรีย 3,939 ราย จากจำนวนผู้ที่ถูกตรวจหาเชื้อทั้งสิ้น 793,431 ราย [2] และในปี พ.ศ. 2563 มีจำนวนผู้ป่วยโรคชิกุนงุนยา จำนวน 5,728 ราย [3] ส่วนระดับโลกนั้นมีจำนวนผู้ติดเชื้อไข้เลือดออกในปี ค.ศ. 2019 (พ.ศ. 2562) มีผู้ติดเชื้อเป็นจำนวน 4.2 ล้านราย [4] ส่วนโรคมมาลาเรียในปี ค.ศ. 2019 (พ.ศ. 2563) มีจำนวนผู้ติดเชื้อถึง 229 ล้านราย และมีผู้เสียชีวิตจากโรคมมาลาเรียเป็นจำนวน 409,000 ราย [5] ถึงแม้จะมีการป้องกันด้วยการฉีดพ่นหมอกควันแต่ก็จะเป็นการป้องกันหลังจากที่เกิดการระบาดของโรคไปแล้ว อีกทั้งยังยังมีหลากหลายสายพันธุ์และแต่ละสายพันธุ์มีความเสี่ยงในการเป็นพาหะของโรคต่าง ๆ ไม่เท่ากัน จึงมีความจำเป็นต้องใช้ผู้เชี่ยวชาญในการจำแนกสายพันธุ์ยุง เพื่อที่จะวางแผนป้องกันโรคที่มีเยุงเป็นพาหะอย่างเหมาะสม ซึ่งการที่จะจำแนกยุงนั้นมีความจำเป็นต้องใช้บุคลากรที่เชี่ยวชาญและได้รับการฝึกจำแนกสายพันธุ์ยุงมาอย่างดี และต้องใช้เวลาในการดำเนินการซึ่งอาจจะทำให้การวางแผนป้องกันโรคเป็นไปได้อย่างล่าช้า

การจำแนกสายพันธุ์อย่างอัตโนมัติไม่ได้มีความจำเป็นเพียงเฉพาะในด้านการจำแนกยุง แต่ยังรวมถึงการจำแนกแมลงชนิดอื่น เพื่อที่จะใช้งานในด้านการตรวจวัดสภาพแวดล้อม การวิเคราะห์ตรวจจับแมลงที่เป็นศัตรูพืช และ ในด้านพาหะของโรคต่าง ๆ เป็นต้น ซึ่งงานวิจัยที่เกี่ยวข้องกับการจำแนกสายพันธุ์ของยุงและแมลงอย่างอัตโนมัติได้มีการใช้เทคนิคต่าง ๆ ในการจำแนกชนิดสายพันธุ์ เช่น การใช้เสียง [6] การใช้ข้อมูลจากรหัสพันธุกรรม (DNA) [7] และฝึกสอนด้วยโครงข่ายประสาทเทียม (Neural Networks) สามารถให้ความแม่นยำในการจำแนกสายพันธุ์ที่สูง แต่การที่จะเก็บข้อมูลมาใช้ในการประมวลผลนั้นต้องเสียเวลาในการดำเนินการมาก [8] และไม่สามารถประมวลผลได้แบบออนไลน์ จึงเริ่มมีการศึกษาการประยุกต์ใช้คอมพิวเตอร์วิชั่นโดยใช้รูปภาพ 2 มิติ เพื่อที่จะจำแนกสายพันธุ์ของแมลงต่าง ๆ

ระบบที่ใช้รูปภาพเป็นพื้นฐานนั้นมีกระบวนการดำเนินการ 3 ขั้นตอน ได้แก่ 1.การเก็บข้อมูล 2.การสกัดคุณลักษณะเฉพาะ (Feature Extraction) 3.การจำแนกสายพันธุ์ โดยในปัจจุบันโมเดลการเรียนรู้เชิงลึกได้ถูกพัฒนาขึ้น เช่น โครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึก (Deep Convolutional Neural Networks) ได้ให้ผลลัพธ์ในการทำงานด้านการรู้จำที่ดีมาก เช่น การจำแนกรถ การจำแนกพืช การจำแนกสัตว์ [9]

วิทยานิพนธ์ฉบับนี้เล็งเห็นถึงความสำคัญของการป้องกันการเกิดโรคที่มีผู้เป็นพาหะ เนื่องจากมีผู้คนจำนวนมากที่เจ็บไข้ได้ป่วยจากโรคเหล่านี้ การป้องกันล่วงหน้าจะสามารถลดอัตราการแพร่ระบาดของโรคที่มีผู้เป็นพาหะได้ โดยการที่จะมีการป้องกันล่วงหน้าที่ดีนั้น ระบบตรวจจับต้องมีความสามารถในการจำแนกสายพันธุ์ของยุงที่มีความแม่นยำที่สูงเพียงพอ นอกจากนี้ระบบยังต้องมีการทำงานได้อย่างออนไลน์ หรือใช้เวลาในการประมวลผลให้น้อยที่สุด เพื่อที่จะได้ระบบที่มีประสิทธิภาพสูง

ผู้วิจัยจึงมีแนวคิดในการพัฒนาโครงข่ายประสาทเทียมแบบคอนโวลูชันที่สามารถช่วยลดระยะเวลา และจำแนกสายพันธุ์ยุงได้อย่างแม่นยำ ส่งผลให้การเตรียมการป้องกันทำได้มีประสิทธิภาพ โดยประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน มาใช้ในการจำแนกชนิดของยุง

## 1.2 วัตถุประสงค์ของงานวิจัย

1. เพื่อเพิ่มความแม่นยำของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks) ด้วยเครื่องมือแบบ Open Source สำหรับการจำแนกสายพันธุ์ยุง ด้วยเทคนิคการเรียนรู้แบบถ่ายโอน การเพิ่มปริมาณข้อมูลภาพ และสัญญาณตกหายเชิงพื้นที่
2. พัฒนาแอปพลิเคชันที่อนุญาตให้ผู้ใช้อัปโหลดรูปภาพยุง แล้วตอบกลับเป็นสปีชีส์ (Species) ของยุง

## 1.3 ขอบเขตงานวิจัย

1. สร้างฐานข้อมูลภาพจากงานวิจัยของ Park et al [8] ซึ่งงานวิจัยชิ้นนี้ได้เป็นแบบ Open Access จึงได้ทำการนำข้อมูลภาพมาเป็นพื้นฐานของการฝึกแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยใช้ชุดทดสอบเดียวกันสำหรับประเมินเทียบความแม่นยำของแบบจำลองที่ได้ทำการฝึก
2. เพิ่มความแม่นยำของแบบจำลองโครงข่ายประสาทเทียม (Fine Tuning) ด้วยเทคนิคการเรียนรู้แบบถ่ายโอน การเพิ่มปริมาณข้อมูลภาพ และสัญญาณตกหายเชิงพื้นที่ และให้ผลลัพธ์แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันที่มีความแม่นยำไม่ต่ำกว่าร้อยละ 90
3. สร้างฐานข้อมูลภาพถ่ายยุงที่เป็นพาหะนำโรคในประเทศไทย อย่างน้อย 4 ชนิด ชนิดละไม่น้อยกว่า 500 รูป
4. ปรับใช้แบบจำลองที่ได้จากข้อ 2 โดยการฝึกด้วยข้อมูลจากข้อ 3 ให้ได้แบบจำลองที่เหมาะสมกับการจำแนกยุงในประเทศไทยยิ่งขึ้น และให้ผลลัพธ์แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันที่มีความแม่นยำไม่ต่ำกว่าร้อยละ 80

5. สร้างแอปพลิเคชันให้ผู้ใช้งานทั่วไปสามารถอัปโหลดภาพยุงที่ถูกถ่ายขณะหยุดนิ่งคมชัด และมีรายละเอียดภาพไม่ต่ำกว่า 1600 x 1200 พิกเซล ให้ผลลัพธ์เป็นสายพันธุ์ของยุงพร้อมทั้งโรคติดต่อที่อาจเกิดจากยุงชนิดนั้น

6. สร้างแอปพลิเคชันให้ผู้เชี่ยวชาญสามารถอัปโหลดภาพยุง พร้อมทั้งระบุสายพันธุ์ยุงมาด้วย

#### 1.4 วิธีการดำเนินการวิจัย

1. ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์
2. ศึกษาแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันแบบต่าง ๆ
3. ศึกษาลักษณะของภาพ และทำการเพิ่มปริมาณข้อมูลภาพ
4. ฝึกการเรียนรู้ของแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน จากภาพยุงชนิดต่าง ๆ ด้วยการใช้ GPU ในการฝึกสอน
5. ทำการเพิ่มความแม่นยำของแบบจำลองโครงข่ายประสาทเทียม ด้วยเทคนิคการเรียนรู้แบบถ่ายโอนการเพิ่มปริมาณข้อมูลภาพ และสัญญาณตกหายเชิงพื้นที่
6. สรุปผลการดำเนินการ และ เขียนรายงานวิทยานิพนธ์
7. ตีพิมพ์เผยแพร่วิทยานิพนธ์

จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

#### 1.5 ประโยชน์ที่คาดว่าจะได้รับ

1. ได้โมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ได้รับการฝึกแล้ว และมีความสามารถในการจำแนกชนิดของยุงในประเทศไทยซึ่งมีความแม่นยำไม่ต่ำกว่าร้อยละ 80
2. ได้ชุดข้อมูลภาพยุงในประเทศไทยรวมถึงการเพิ่มปริมาณข้อมูลภาพ (Data Augmentation) ไม่น้อยกว่า 20,000 ภาพ
3. ได้แอปพลิเคชัน (Application) ที่ผู้เชี่ยวชาญสามารถอัปโหลดรูปยุงพร้อมระบุสายพันธุ์ของยุง และผู้ใช้ทั่วไปสามารถอัปโหลดรูปยุงและได้ผลลัพธ์เป็นสายพันธุ์ของยุงพร้อมทั้งโรคติดต่อที่อาจเกิดจากยุงชนิดนั้น

## บทที่ 2 หลักการและทฤษฎีที่เกี่ยวข้อง

ทฤษฎีและงานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์ฉบับนี้ประกอบไปด้วย 6 หัวข้อ ได้แก่ 1.) การเรียนรู้ของเครื่อง 2.) โครงข่ายประสาทเทียม 3.) สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบคอนโวลูชัน 4.) สายพันซ์ของยุงที่ปรากฏในงานวิจัย 5.) โรคที่เกิดจากยุงเป็นพาหะนำโรค 6.) การจำแนกสายพันซ์ยุง

### 2.1 การเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่อง (Machine Learning) เป็นส่วนหนึ่งที่อยู่ในขอบเขตของปัญญาประดิษฐ์ (Artificial Intelligence) รูปแบบหนึ่งที่ใช้วิธีการเรียนรู้จากข้อมูลที่มีมาก่อนหน้าเพื่อให้บรรลุเป้าหมายที่ต้องการ ในการจัดการกับชุดข้อมูลใหม่ได้อย่างเหมาะสม ต่างจากปัญญาประดิษฐ์บางแขนงที่ไม่ได้ใช้วิธีการเรียนรู้ชุดข้อมูลเพื่อให้ประสิทธิภาพการทำงานในอนาคตดียิ่งขึ้น

กระบวนการการเรียนรู้ของเครื่องนั้นมีอยู่มากมายสามารถจัดพวกเป็น 4 กลุ่มใหญ่ได้แก่

#### 2.1.1 กลุ่มปัญหาการเรียนรู้ (Learning Problems)

กระบวนการในกลุ่มนี้เรียนรู้จากชุดข้อมูล และสามารถแบ่งเป็นกลุ่มย่อยอีก ได้แก่

- การเรียนรู้แบบมีผู้สอน (Supervised Learning)

การเรียนรู้แบบมีผู้สอน เป็นการพัฒนาแบบจำลองจากความสัมพันธ์ ระหว่างตัวอย่างที่ป้อนเข้าสู่แบบจำลอง (Input Examples) กับ ตัวแปรเป้าหมาย (Target Variable) ชุดข้อมูลที่จะใช้ฝึกกระบวนการในกลุ่มนี้จะต้องมีข้อมูลขาเข้าและผลลัพธ์หรือเรียกอีกอย่างว่าข้อมูลที่ถูกลดป้าย (Labeled) และนำไปใช้ทดสอบประสิทธิภาพกับชุดข้อมูลทดสอบ (Test Set) โดยได้รับเฉพาะข้อมูลขาเข้า (Input) เพียงอย่างเดียวเพื่อสร้างแบบจำลองและนำมาเทียบกับผลลัพธ์จริง ๆ ที่ถูกลดป้ายไว้ว่ามีความถูกต้องมากน้อยเพียงใด การเรียนรู้แบบมีผู้สอนมีวัตถุประสงค์ 2 แบบคือ การแบ่งประเภท (Classification) เป็นการทำนายว่าข้อมูลที่ถูกลดป้ายไปจัดอยู่ในกลุ่มใด เช่น การทำนายว่าภาพที่เข้ามาเป็นหมาหรือแมว และการถดถอย (Regression) เป็นการทำนายตัวเลขที่มีความต่อเนื่อง เช่น ราคาหุ้นในวันพรุ่งนี้จะลดลงหรือเพิ่มขึ้นเท่าใด ปริมาณของน้ำฝนในเดือนหน้าจะตกกี่มิลลิเมตร เป็นต้น

- การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

การเรียนรู้แบบไม่มีผู้สอน เป็นการพัฒนาแบบจำลองเพื่อที่จะอธิบาย หรือหาความสัมพันธ์ของข้อมูลและตัวแปรเป้าหมายแต่การเรียนรู้แบบไม่มีผู้สอนจะรับเพียงข้อมูลเข้าเพียงอย่างเดียวที่ไม่มีผลลัพธ์หรือการติดป้าย ซึ่งทำให้การเรียนรู้แบบไม่มีผู้สอนนั้นไม่ได้มีข้อมูลขาออกที่จะช่วยปรับแบบจำลองเหมือนกับกรณีของการเรียนรู้แบบมีผู้สอนจะต้องเรียนรู้จากข้อมูลขาเข้าเพียงอย่างเดียว จึงมักใช้เพื่อแบ่งประเภทของข้อมูลเท่านั้น กระบวนการในกลุ่มย่อยนี้ยังสามารถแยกย่อยไปได้เป็น 2 กลุ่ม คือ การแบ่งกลุ่มแบบไม่มีผู้สอน (Clustering Unsupervised) เป็นการแบ่งประเภทจากการหาความสัมพันธ์ของข้อมูล เช่นการแบ่งส้มออกจากกล้วย และการประมาณความหนาแน่น (Density Estimation) เป็นการหาการกระจายตัวของข้อมูล ซึ่งการแบ่งกลุ่มและการประมาณความหนาแน่นนั้นสามารถใช้ในการหารูปแบบของข้อมูลได้ เช่นการประมาณการแจกแจงความน่าจะเป็น (Probability Distribution) ของข้อมูลแต่ละชนิด

- การเรียนรู้แบบเสริมแรง (Reinforcement Learning)

การเรียนรู้แบบเสริมแรง เป็นการพัฒนาแบบจำลองที่ใช้งานอยู่แล้วให้มีประสิทธิภาพมากขึ้น แบบจำลองจะถูกใช้งานในสภาพแวดล้อมสถานการณ์และเรียนรู้โดยใช้การป้อนกลับ (Feed Back) การเรียนรู้แบบเสริมแรงจึงไม่มีข้อมูลฝึกที่คงที่ แต่จะใช้เป้าหมาย (Goal) ที่เป็นตัวกำหนดว่าเครื่องต้องทำให้ได้ตามเป้าหมาย การกระทำ (Action) ที่เครื่องจะทำ และ การป้อนกลับเกี่ยวกับความสามารถหรือประสิทธิภาพในการเข้าถึงเป้าหมาย มาเป็นข้อมูลสำหรับการเรียนรู้

### 2.1.2 กลุ่มปัญหาการเรียนรู้แบบไฮบริด (Hybrid Learning Problems)

กระบวนการในกลุ่มนี้จะเป็นการใช้เทคนิคผสมผสานกัน และสามารถแบ่งเป็นกลุ่มย่อย ได้แก่

- การเรียนรู้แบบกึ่งมีผู้สอน (Semi-Supervised Learning)

การเรียนรู้แบบกึ่งมีผู้สอน เป็นการเรียนรู้แบบมีผู้สอนที่ชุดข้อมูลฝึกมีข้อมูลที่มีป้ายกำกับ (Labeled) เป็นส่วนน้อย และข้อมูลที่ไม่มีป้ายกำกับ (Unlabeled) เป็นส่วนใหญ่ ซึ่งการเรียนรู้แบบกึ่งมีผู้สอนนี้จะประกอบไปด้วยข้อมูลบางส่วนที่ถูกติดป้ายและข้อมูลบางส่วนที่ไม่ถูกติดป้าย แบบจำลองจะใช้ข้อมูลที่มีการติดป้ายเป็นแนวทางในการเรียนรู้เพื่อที่จะจำแนกชนิดของข้อมูลที่ยังไม่ได้ถูกติดป้าย

- การเรียนรู้แบบตัวเองเป็นผู้สอน (Self-Supervised Learning)

การเรียนรู้แบบตัวเองเป็นผู้สอน เป็นการเรียนรู้แบบไม่มีผู้สอนซึ่งทำงานในขอบเขตเหมือนกับการเรียนรู้แบบมีผู้สอน โดยแก้ปัญหาจากงานที่ได้รับมอบหมาย (Pretext Task) ให้กับเครื่อง ตัวอย่างเช่น งานที่ได้รับมอบหมายคือการจัดวางตำแหน่งของชิ้นส่วนรูปที่ถูกต้อง เครื่องจะทำการเรียนรู้และนำชิ้นส่วนรูปที่ไม่มีข้อมูลกำกับมาจัดเรียงในตำแหน่งที่ถูกต้อง

- การเรียนรู้แบบกลุ่มตัวอย่าง (Multi-Instance Learning)

การเรียนรู้แบบกลุ่มตัวอย่าง เป็นการเรียนรู้แบบมีผู้สอน โดยตัวอย่างแต่ละตัวไม่ได้ถูกกำกับ แต่กลุ่มของตัวอย่างจะถูกกำกับ ตัวอย่างเช่น กลุ่มของกุญแจที่เปิดประตูได้แม้เพียงกุญแจดอกเดียวจะเป็นกลุ่มตัวอย่างบวก และกลุ่มของกุญแจที่ไม่สามารถเปิดประตูได้เลยจะถูกจัดเป็นตัวอย่างลบ การทำงานของวิธีนี้คือเมื่อได้รับกุญแจมา จะสามารถทำนายได้ว่ากุญแจนั้นสามารถเปิดประตูได้หรือไม่

### 2.1.3 กลุ่มการอนุมานทางสถิติ (Statistical Inference)

กระบวนการในกลุ่มนี้จะเป็นการใช้การอนุมานทางสถิติ และสามารถแบ่งเป็นกลุ่มย่อย ได้แก่

- การเรียนรู้แบบอุปนัย (Inductive Learning)

การเรียนรู้แบบอุปนัย แบบจำลองจะหาข้อสรุปทั่วไปจากข้อมูลฝึก โดยเชื่อว่าข้อมูลใหม่ที่ได้รับจะยังคงสอดคล้องกับสิ่งที่เรียนมา

- การเรียนรู้แบบนิรนัย (Deductive Learning)

การเรียนรู้แบบนิรนัย ในบริบทของการเรียนรู้ของเครื่องคือ เมื่อเราใช้การเรียนรู้แบบอุปนัยในการเรียนรู้บนชุดข้อมูลฝึก และแบบจำลองนั้นสามารถนำมาใช้ในการทำนายได้ การใช้แบบจำลองในการทำนายคือการเรียนรู้แบบนิรนัย

- การเรียนรู้แบบทรานสดักชัน (Transductive Learning)

การเรียนรู้แบบทรานสดักชัน เป็นการใช้อย่างเฉพาะในการทำนายผล โดยที่ไม่ได้มีการหาข้อสรุปโดยทั่วไปก่อน

จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

### 2.1.4 กลุ่มกลวิธีการเรียนรู้ (Learning Technique)

กระบวนการในกลุ่มนี้จะเป็นการใช้เทคนิควิธีการเรียนรู้ และสามารถแบ่งเป็นกลุ่มย่อย ได้แก่

- การเรียนรู้แบบหลายภารกิจ (Multi-Task Learning)

การเรียนรู้แบบหลายภารกิจ เป็นการเรียนรู้แบบมีผู้สอนโดยใช้ข้อมูลฝึกเดียวกันในการเรียนรู้งานหลาย ๆ งานที่เกี่ยวข้องกันซึ่งสามารถช่วยเพิ่มประสิทธิภาพการเรียนรู้และความแม่นยำสำหรับการทำนายผลของแบบจำลองหนึ่ง ๆ ได้เมื่อเทียบกับการฝึกแบบจำลองโดยแยกกันฝึก

- การเรียนรู้เชิงรุก (Active Learning)

การเรียนรู้เชิงรุก กลวิธีการเรียนรู้แบบจำลองที่สามารถที่จะร้องขอให้มนุษย์เข้าช่วยในระหว่างกระบวนการเรียนรู้เพื่อแก้ปัญหาที่กำกวมระหว่างกระบวนการฝึก

- การเรียนรู้แบบออนไลน์ (Online Learning)

การเรียนรู้แบบออนไลน์ เป็นการเรียนรู้โดยใช้ข้อมูลใหม่ ๆ และมีการปรับแบบจำลองโดยตรงก่อนที่จะมีการนำไปใช้ทำนาย

- การเรียนรู้แบบถ่ายโอน (Transfer Learning)

การเรียนรู้แบบถ่ายโอน เป็นการเรียนรู้จากแบบจำลองที่ถูกฝึกเรียบร้อยแล้วสำหรับงานหนึ่ง ๆ และบางส่วนหรือทั้งหมดของแบบจำลองนั้นถูกนำมาใช้เป็นจุดเริ่มต้นในงานที่เกี่ยวข้อง

- การเรียนรู้แบบร่วมกัน (Ensemble Learning)

การเรียนรู้แบบร่วมกัน เป็นกลวิธีที่ใช้แบบจำลองตั้งแต่ 2 แบบจำลองขึ้นไปในการฝึกบนชุดข้อมูลเดียวกัน และการทำนายจะใช้แบบจำลองทั้งหมดมาทำงานร่วมกัน

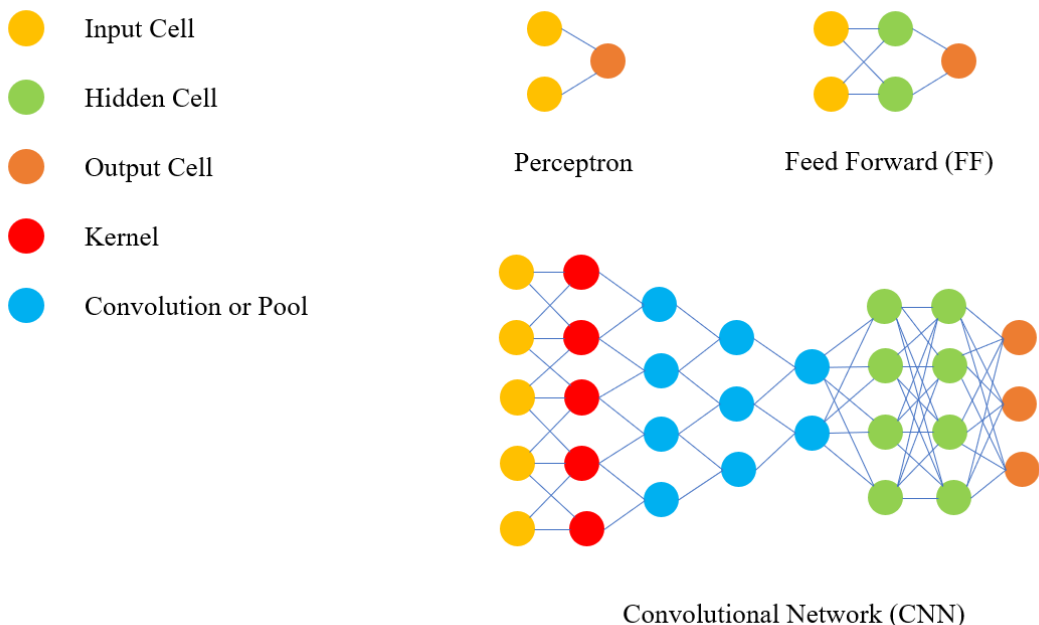
## 2.2 โครงข่ายประสาทเทียม (Neural Networks)

เป็นระบบการคำนวณที่ได้รับแรงบันดาลใจจาก โครงข่ายประสาทในสมองของสัตว์ โดยโครงข่ายประสาทประกอบไปด้วยเซลล์ประสาท (Neuron) ที่เชื่อมต่อกัน เซลล์ประสาท 1 เซลล์ อาจจะเชื่อมต่อกับเซลล์ประสาทอื่น ๆ อีกหลายเซลล์ จำนวนเซลล์ประสาทและการเชื่อมต่อกันในระบบประสาทนั้นมีจำนวนมาก การเชื่อมต่อกันของนิวรอนถูกเรียกว่าจุดประสานประสาท (Synapse) ส่วนมากสัญญาณประสาทถูกส่งจาก โยประสาทนำออก (Axon) ไปยัง โยประสาทนำเข้า (Dendrite)

โครงข่ายประสาทเทียมประกอบไปด้วยเซลล์ประสาทเทียม (Artificial Neuron) ซึ่งจำลองมาจากเซลล์ประสาทในสมอง การเชื่อมต่อกันระหว่างเซลล์ประสาทถูกจำลองด้วย ค่าน้ำหนัก (Weights) ค่าน้ำหนักที่เป็นบวกจำลองการกระตุ้นในสมอง ค่าน้ำหนักที่เป็นลบจำลองสัญญาณการยับยั้งในสมอง ข้อมูลเข้าจะถูกถ่วงด้วยน้ำหนักและความเอนเอียง (Bias) หลังจากนั้นส่งไปยัง ฟังก์ชันกระตุ้น (Activation Function)

### 2.2.1 ชนิดของโครงข่ายประสาทเทียม (Neural Networks)






รูปที่ 1 ชนิดของโครงข่ายประสาทเทียม (Neural Network) ที่เกี่ยวข้องกับงานวิจัย

ในส่วนนี้จะเป็นการกล่าวถึงชนิดของโครงข่ายประสาทที่จะนำไปประยุกต์ใช้กับงานวิจัยชิ้นนี้ โดยจะกล่าวถึง โครงข่ายประสาทเทียมแบบไปข้างหน้า (Feed Forward Neural Networks : FFNN) และ Perceptron (P) ซึ่ง Perceptron จะเป็นโครงข่ายประสาทเทียมแบบไปข้างหน้า แบบง่ายที่สุดโดยมีเพียงชั้นรับข้อมูลขาเข้า (Input) และ ชั้นข้อมูลขาออก (Output) เท่านั้นโดยที่ไม่มีชั้นถูกซ่อน (Hidden Layer) อยู่ภายในโครงข่ายส่วนโครงข่ายประสาทเทียมแบบไปข้างหน้า นั้นจะมีชั้นถูกซ่อนอยู่ระหว่างชั้นข้อมูลขาเข้าและชั้นข้อมูลขาออก และอาจจะมีจำนวนชั้นที่มากกว่า 1 ชั้น ขึ้นไปซึ่งชั้นถูกซ่อนชั้นก่อนหน้าจะทำหน้าที่เป็นชั้นข้อมูลขาเข้าของชั้นถูกซ่อนชั้นถัดไป โดยโครงข่ายประสาทเทียมแบบไปข้างหน้าจะถูกฝึกโดยให้ชุดข้อมูลฝึกเป็นข้อมูลเข้าและข้อมูลที่ถูกรู้ค่า ซึ่งเป็นสิ่งที่เราอยากให้เป็นข้อมูลออกของโครงข่ายประสาทเทียม การเรียนรู้ประเภทนี้เป็นการเรียนรู้แบบมีผู้สอน โครงข่ายประสาทเทียมจะถูกฝึกให้เรียนรู้ผ่านการหาค่าความผิดพลาดด้วยวิธีการแพร่ถอยหลัง (Backward Propagation) เพื่อทำให้โครงข่ายประสาทเทียมหาความสัมพันธ์ระหว่างข้อมูลขาเข้า และข้อมูลขาออกได้ ส่วนมากโครงข่ายประสาทเทียมแบบไปข้างหน้าจะถูกใช้ร่วมกับโครงข่ายประสาทเทียมอื่น ๆ เพื่อที่จะได้เป็นโครงข่ายประสาทชนิดใหม่

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) เป็นการจำลองจากการมองเห็นของมนุษย์โดยแต่ละเซลล์ประสาทจะมองเห็นเป็นพื้นที่ส่วนย่อย ๆ (Receptive Field) และนำมาประกอบโดยการทับซ้อนบางส่วน (Overlap) เพื่อที่จะรวมเป็นพื้นที่การมองเห็นทั้งหมด โดยเริ่มต้นจากการรับรูปภาพขาเข้าและป้อนเข้าสู่ชั้นคอนโวลูชัน โดยการเลื่อน kernel ซึ่ง kernel จะเป็นตัวกำหนดขนาดของพื้นที่ส่วนย่อย ๆ จากการทำคอนโวลูชันเชิงพื้นที่ (Spatial Convolution) การเลื่อนของ Kernel ถูกกำหนดจากค่าของ Stride ที่กำหนดหลังจากที่ได้พื้นที่ย่อยแล้ว

จึงนำผลลัพธ์มารวมต่อกันก่อนที่จะนำไปเข้าสู่ฟังก์ชันกระตุ้น โดยการทำคอนโวลูชันผลลัพธ์ขนาดของผลลัพธ์ที่ได้จะมี 2 แบบด้วยกัน คือผลลัพธ์มีขนาดเล็กกว่าข้อมูลขาเข้าเนื่องจากการทำคอนโวลูชัน และผลลัพธ์มีขนาดเท่ากับหรือใหญ่กว่าข้อมูลขาเข้าซึ่งเกิดจากการทำ padding โดยอาจจะมีการทำ pooling หลังจากออกจากฟังก์ชันกระตุ้น เพื่อที่จะลดขนาดเชิงพื้นที่ของผลลัพธ์ที่ได้จากการทำคอนโวลูชัน ซึ่งทำให้ลดการใช้พลังงานในการคำนวณให้น้อยลง การทำ pooling จะมีอยู่ 2 แบบด้วยกันได้แก่ max pooling และ average pooling โดย max pooling จะเป็นการคืนค่าที่สูงที่สุดของบริเวณที่ถูกครอบคลุมด้วย kernel และ average pooling จะคืนค่าเป็นค่าเฉลี่ยของบริเวณที่ถูกครอบคลุมด้วย kernel ชั้นคอนโวลูชันนั้นจะเป็นการหาคุณลักษณะของรูปนั้น ๆ โดยชั้นที่อยู่ต้นๆ จะดึงคุณลักษณะระดับต่ำ เช่น ขอบ สี ส่วนชั้นที่อยู่ลึกมากขึ้นจะทำหน้าที่ในการดึงคุณลักษณะระดับที่สูงขึ้น หลังจากที่ทำคอนโวลูชันเรียบร้อยแล้วจะทำการส่งข้อมูลไปที่ชั้น Flatten ซึ่งทำให้ข้อมูลที่อยู่ในหลายมิติเรียงตัวอยู่ในมิติเดียว และทำการส่งต่อไปที่ชั้น Fully connected ซึ่งเป็น FFNN และเข้าสู่ฟังก์ชันกระตุ้น โดยที่ชั้นขาออกชั้นสุดท้ายฟังก์ชันกระตุ้นจะใช้ฟังก์ชันกระตุ้น Soft max ในการทำนายกลุ่มของข้อมูลขาเข้า




รูปที่ 2 โครงสร้างโครงข่ายประสาทเทียมแบบคอนโวลูชัน [10]

## 2.2.2 ส่วนประกอบของโครงข่ายประสาทเทียมแบบคอนโวลูชัน

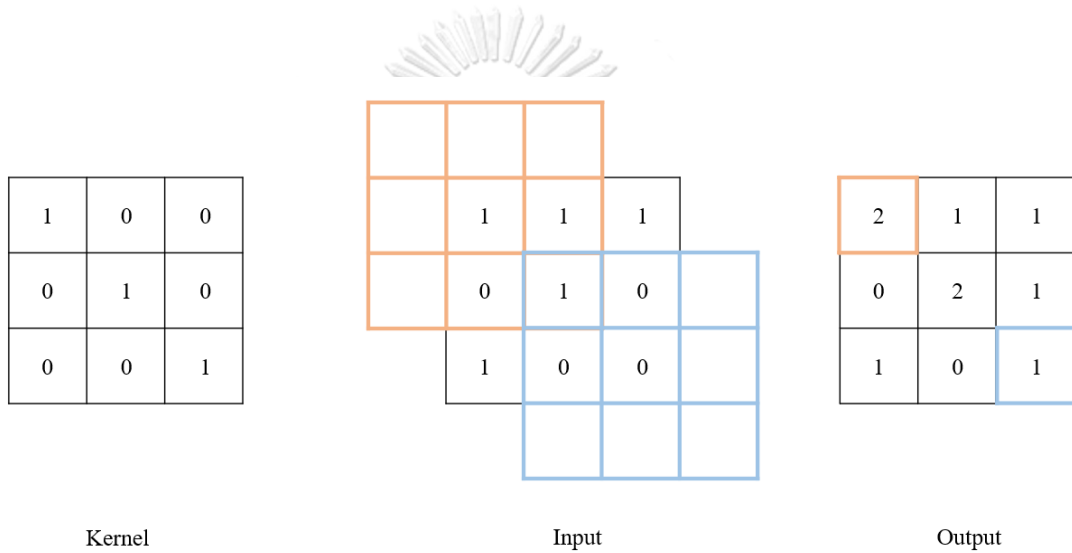
ในโครงข่ายประสาทเทียมแบบคอนโวลูชันจะมีส่วนประกอบดังนี้

### 1. ชั้น Conv2D

ชั้น Conv2D เป็นชั้นคอนโวลูชัน 2 มิติ เป็นการทำคอนโวลูชันเชิงพื้นที่ทั่วทั้งภาพ โดยชั้นคอนโวลูชันนี้จะสร้างคอนโวลูชันเคอร์เนลและทำการคอนโวลูชันกับภาพโดยเลื่อนไปยังจุดถัดไปด้วยค่า stride ที่กำหนดไว้ และสามารถกำหนด padding ได้คือ same จะให้ผลลัพธ์ของการทำคอนโวลูชันมีขนาดเท่ากับรูปเดิม และ valid จะเป็นการทำคอนโวลูชันโดยเคอร์เนลจะอยู่บนรูปเดิมเท่านั้นทำให้ผลลัพธ์มีขนาดที่เล็กลงกว่ารูปเดิม



รูปที่ 3 ชั้น Conv2D ที่กำหนดค่า padding เป็น valid



รูปที่ 4 ชั้น Conv2D ที่กำหนดค่า padding เป็น same

### 2. ฟังก์ชันกระตุ้น (Activation Function)

ภายในโครงข่ายประสาทเทียมฟังก์ชันกระตุ้นจะเป็นตัวที่นิยามว่าผลรวมแบบถ่วงน้ำหนัก (Weighted Sum) และบวกด้วยค่าเบี่ยงเบน (Bias) ของข้อมูลขาเข้าจะแปลงไปเป็นข้อมูลออก จากโหนดในแต่ละชั้นภายในโครงข่ายประสาทเทียมอย่างไร ฟังก์ชันกระตุ้นในโครงข่ายประสาทเทียมที่นิยมใช้งานจะมีลักษณะที่ไม่เป็นเชิงเส้น (Non-linear) เพื่อที่จะช่วยให้โครงข่ายประสาทเทียมสามารถเรียนรู้ข้อมูลที่ซับซ้อน และได้ผลลัพธ์ที่มีความแม่นยำ โดยฟังก์ชันกระตุ้นมีกระบวนการทำงานดังสมการ


$$Y = \sum(\text{weight} * \text{input}) + \text{bias} \tag{2.1}$$

ฟังก์ชันกระตุ้นที่ผู้วิจัยจะกล่าวถึงได้แก่

## 2.1 ฟังก์ชัน Sigmoid

ฟังก์ชัน Sigmoid เป็นฟังก์ชันแบบไม่เป็นเชิงเส้น โดยฟังก์ชันนี้จะแปลงค่าให้อยู่ในช่วง 0 ถึง 1 สามารถอธิบายด้วยสมการ

$$S(x) = \frac{1}{1+e^{-x}} \quad (2.2)$$



รูปที่ 5 ฟังก์ชัน Sigmoid  
 จุฬาลงกรณ์มหาวิทยาลัย  
 CHULALONGKORN UNIVERSITY


## 2.2 ฟังก์ชัน Tanh

ฟังก์ชัน Tanh เป็นฟังก์ชันแบบไม่เป็นเชิงเส้นและแปลงค่าให้อยู่ในช่วง -1 ถึง 1 สามารถอธิบายได้ด้วยสมการ

$$f(x) = \tanh(x) = \frac{2}{1+e^{-2x}} - 1 \quad (2.3)$$

จากสมการ (2.2) และสมการ (2.3) สามารถเขียนให้อยู่ในรูป

$$f(x) = 2S(2x) - 1 \quad (2.4)$$



รูปที่ 6 ฟังก์ชัน tanh


ซึ่งจะเห็นว่าเป็นฟังก์ชัน Sigmoid ที่มีการเลื่อนให้มียค่ากลางเป็น 0

### 2.3 ฟังก์ชัน ReLU (Rectified Linear Unit)

ฟังก์ชัน ReLU เป็นฟังก์ชันแบบไม่เป็นเชิงเส้นและแปลงค่าโดยให้ค่าลบมีค่าเป็น 0 และคืนค่าเดิมสำหรับค่าที่เป็นบวก สามารถอธิบายได้ดังสมการ

$$f(x) = \max(0, x)$$

(2.5)




รูปที่ 7 ฟังก์ชัน ReLU

## 2.4 ฟังก์ชัน LeakyReLU

ฟังก์ชัน LeakyReLU เป็นฟังก์ชัน ReLU ที่ช่วงค่าลบจะคืนค่าเป็นค่าที่น้อยมาก ๆ เช่น ค่าเดิมคูณด้วย 0.01 ส่วนค่าที่เป็นบวกจะคืนค่าเดิม สามารถอธิบายได้ดังสมการ

$$f(x) = 0.01x, x < 0 \quad (2.6)$$

$$f(x) = x, x \geq 0 \quad (2.7)$$



รูปที่ 8 ฟังก์ชัน LeakyReLU

## 2.5 ฟังก์ชัน Softmax


ฟังก์ชัน Softmax เป็นฟังก์ชันรูปทั่วไปของฟังก์ชัน sigmoid สามารถใช้ในการจำแนกกลุ่มที่มากกว่า 2 กลุ่ม ซึ่งต่างจากฟังก์ชัน sigmoid ที่สามารถจำแนกได้แค่ 2 กลุ่มเท่านั้น อธิบายได้ดังสมการ

$$\sigma(\mathbf{z})_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad \text{โดยที่ } j = 1, \dots, K \quad (2.8)$$


ฟังก์ชัน Softmax จะถูกใช้ในชั้นสุดท้ายของโครงข่ายประสาทเทียมเพื่อใช้ในการจำแนกประเภท

### 3. ชั้น Pooling

ชั้น Pooling เป็นการลดขนาด (Dimension) ของข้อมูลโดยหลังจากการทำคอนโวลูชันและผ่านฟังก์ชันกระตุ้นเสร็จสิ้นแล้วข้อมูลจะถูกลดขนาด เพื่อลดพลังงานที่ต้องใช้ในการคำนวณโดยที่ยังคงคุณลักษณะเพื่อใช้ในการฝึก pooling ที่นิยมใช้มี 2 แบบได้แก่ max pooling จะเป็นการหาค่าสูงสุดในหน้าต่างและนำค่านั้นมาเป็นผลลัพธ์ ซึ่งเราสามารถกำหนดขนาดของหน้าต่าง (Pooling Size) โดยผลลัพธ์จะมีขนาดเท่ากับขนาดเดิมหารด้วยขนาดของหน้าต่าง เช่น ขนาดก่อนเข้า Pooling เท่ากับ  $32 \times 32 \times 8$  และขนาดของหน้าต่างมีค่าเท่ากับ  $2 \times 2$  ผลลัพธ์จะมีขนาดที่ได้เป็น  $16 \times 16 \times 8$  และอีกหนึ่งวิธีที่นิยมใช้คือ average pooling จะเป็นการหาค่าเฉลี่ยภายในหน้าต่างแล้วนำค่าที่ได้มาเป็นผลลัพธ์ โดยมีขนาดเท่ากับขนาดเดิมหารด้วยขนาดของหน้าต่างเช่นเดียวกับ max pooling



รูปที่ 9 max pooling  
 จุฬาลงกรณ์มหาวิทยาลัย  
 CHULALONGKORN UNIVERSITY



รูปที่ 10 average pooling

#### 4. ชั้น Flatten


ชั้น Flatten จะเป็นการทำให้ข้อมูลที่อยู่ในหลายมิติ (Dimension) มาเรียงกันให้มีขนาดเพียง 1 มิติ เพื่อที่จะส่งต่อไปยังชั้น fully connected

#### 5. ชั้น Fully connected


ชั้น Fully connected เป็นชั้นที่ชั้นของนิวรอนเชื่อมต่อกับชั้นของนิวรอนก่อนหน้าทั้งหมด โดยในชั้นสุดท้ายจะใช้ฟังก์ชันกระตุ้นสำหรับการใช้ทำงานกลุ่ม เช่น ฟังก์ชัน sigmoid ฟังก์ชัน softmax

#### 6. ชั้น Dropout

ชั้น Dropout เป็นการสุ่มให้นิวรอนในชั้นก่อนหน้าบางนิวรอนมีค่าเป็น 0 เพื่อลดปัญหาการที่แบบจำลองเรียนรู้จากข้อมูลมากเกินไป (Overfitting) โดยปกตินิวรอนที่มีค่าน้ำหนักมากจะมีน้ำหนักที่เพิ่มมากขึ้น แล้วนิวรอนที่มีค่าน้ำหนักน้อยจะมีน้ำหนักน้อยลง เมื่อทำการฝึกหลาย ๆ รอบ การสุ่มให้บางนิวรอนมีค่าเป็น 0 บ้างในบางครั้งจะช่วยลดเหตุการณ์ข้างต้นได้ ทำให้โครงข่ายประสาทเทียมทำงานได้แม่นยำมากขึ้น



โครงข่ายประสาทเทียมทั่วไป




โครงข่ายประสาทเทียมที่ใช้วิธี dropout

รูปที่ 11 โครงข่ายประสาทเทียมแบบปกติ และโครงข่ายประสาทเทียมที่ใช้วิธี dropout

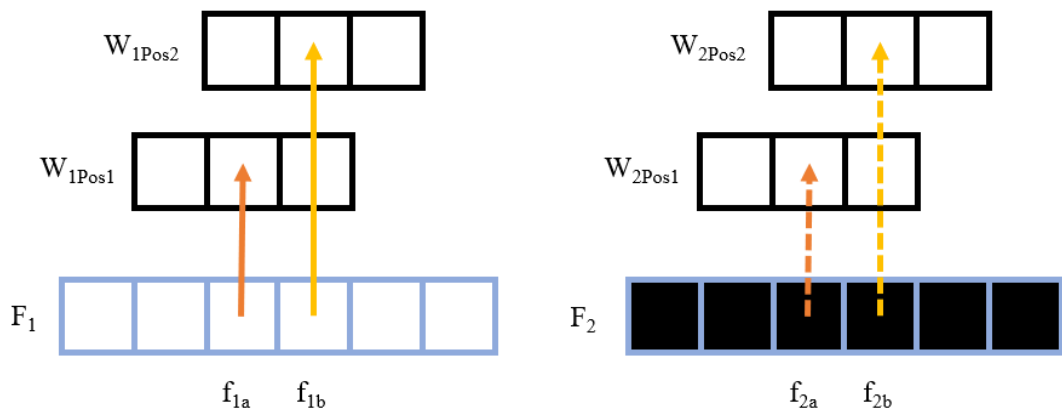
#### 7. ชั้น Dropout ภายในชั้นคอนโวลูชัน

ชั้น Dropout ภายในชั้นคอนโวลูชันมีอยู่ 2 แบบด้วยกันได้แก่ Standard Dropout และ Spatial Dropout การ dropout เป็นการทำให้จุดบางจุดส่งค่าออกไปเป็น 0 ผังคุณลักษณะ (feature map) บางจุดก่อนที่จะเข้าสู่คอร์เนลคอนโวลูชัน โดยผังคุณลักษณะจะแสดงด้วยสัญลักษณ์  $F$  และ คอร์เนลคอนโวลูชันจะแสดงด้วยสัญลักษณ์  $W$





รูปที่ 12 Standard Dropout



รูปที่ 13 Spatial Dropout

รูปที่ 12 จะเห็นว่า Standard Dropout จะทำการสุ่มให้บางจุดในฟังก์ชันลักษณะมีค่าเป็น 0 แต่สำหรับโครงข่ายคอนโวลูชันจุดที่อยู่ข้าง ๆ กันมักก็มีความสัมพันธ์กันมาก เช่นจุด  $f_{2a}$  กับจุด  $f_{2b}$  การที่ส่งค่าเป็น 0 จุดหนึ่งและอีกจุดยังส่งค่าอยู่ทำให้ประสิทธิภาพของการทำ dropout ลดลง ในส่วนของ รูปที่ 13 Spatial Dropout จะเป็นการทำให้ทั้งแถวของฟังก์ชันลักษณะส่งค่าเป็น 0 ทั้งหมดหรือส่งค่าเดิมทั้งหมดไปยังคอร์เนลคอนโวลูชัน

### 2.2.3 วิธีการประเมินความแม่นยำของโครงข่ายประสาทเทียม

		True Class	
		Positive	Negative
Predicted Class	Positive	TP	FP
	Negative	FN	TN

รูปที่ 14 confusion matrix

ค่าที่แสดงในตารางประเมินผลลัพธ์ประกอบไปด้วย

1.ค่าจริงเชิงบวก (True Positive; TP) คือกรณีที่ทำนายว่าเป็นบวกและค่าจริงเป็นบวก ตัวอย่างเช่น สมมติให้ฝนตกเป็นบวกและฝนไม่ตกเป็นลบ พยากรณ์อากาศว่าฝนตก และฝนตกจริง

2.ค่าจริงเชิงลบ (True Negative; TN) คือกรณีที่ทำนายว่าเป็นลบและค่าจริงเป็นลบ ตัวอย่างเช่น พยากรณ์อากาศว่าฝนไม่ตก และฝนไม่ตก

3.ค่าเท็จเชิงบวก (False Positive; FP) คือกรณีที่ทำนายว่าบวก แต่ค่าจริงเป็นลบ ตัวอย่างเช่นพยากรณ์อากาศว่าฝนตก แต่ฝนไม่ตก

4.ค่าเท็จเชิงลบ (False Negative; FN) คือกรณีที่ทำนายว่าลบ แต่ค่าจริงคือบวก ตัวอย่างเช่นพยากรณ์อากาศว่าฝนไม่ตก แต่ฝนตก

#### 2.2.3.1 ค่าความแม่นยำ (Accuracy)

ค่าความแม่นยำ (Accuracy) เป็นสัดส่วนที่บอกความสามารถในการทำนายที่ถูกต้องต่อเหตุการณ์ทั้งหมด

$$\text{Accuracy} = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (2.9)$$

หากค่า accuracy มีค่าสูงเข้าใกล้ 1 แสดงว่าแบบจำลองโครงข่ายประสาทเทียมนั้น ๆ มีความแม่นยำสูง

### 2.2.3.2 ค่าความเที่ยงตรง (Precision)

ค่าความเที่ยงตรง (Precision) เป็นสัดส่วนค่าจริงเชิงบวกต่อค่าเชิงบวกทั้งหมด เช่นถ้ารู้แล้วว่าพยากรณ์ว่าฝนตกโอกาสฝนตกจริงเป็นเท่าไร

$$\text{Precision} = \frac{TP}{(TP+FP)} \quad (2.10)$$

หากค่า precision มีค่าเข้าใกล้ 1 แสดงว่าแบบจำลองโครงข่ายประสาทเทียมนั้นมีความสามารถในการพยากรณ์ค่าจริงเชิงบวกได้ดี

### 2.2.3.3 ค่าการเรียกคืน (Recall)

ค่าการเรียกคืน (Recall) เป็นการบ่งบอกความสามารถในการพยากรณ์ได้อย่างถูกต้องเมื่อรู้ภายหลังว่าเหตุการณ์ที่เกิดขึ้นจริงเป็นบวก

$$\text{Recall} = \frac{TP}{(TP+FN)} \quad (2.11)$$

หากค่า Recall มีค่าเข้าใกล้ 1 แสดงว่าแบบจำลองโครงข่ายประสาทเทียมสามารถค้นหาค่าบวกได้ดีเหมาะสมกับข้อมูลที่มีสัดส่วนข้อมูลที่เป็นบวกน้อย ๆ ยกตัวอย่างเช่น การบ่งบอกปอดที่มีมะเร็งจากภาพเอกซเรย์ตรวจสุขภาพประจำปี เราต้องการให้ค่า Recall ใกล้เคียง 1 เพื่อให้โอกาสที่มีมะเร็งจริงแล้วตรวจจับไม่ได้มีค่าน้อย

### 2.2.3.4 ค่า F1 หรือ F-Measure

ค่า F1 หรือ F-Measure เป็นการบ่งบอกความสามารถของแบบจำลองโครงข่ายประสาทเทียมด้วยการใช้ค่าความเที่ยงตรงและค่าการเรียกคืนร่วมกัน บางครั้งแบบจำลองที่ได้ อาจจะมีค่าความเที่ยงตรงที่ดีแต่มีค่าการเรียกคืนที่แย่ และในทางกลับกันแบบจำลองอาจจะมีค่าความเที่ยงตรงที่แย่แต่มีค่าการเรียกคืนที่ดี จึงใช้คะแนนทั้งสองในการคำนวณค่า F1

$$F1 = \frac{(2 * \text{Precision} * \text{Recall})}{(\text{Precision} + \text{Recall})} \quad (2.12)$$

หากค่า F1 มีค่าเข้าใกล้ 1 แสดงว่าแบบจำลองโครงข่ายประสาทเทียมสามารถพยากรณ์ได้ดี


## 2.3 สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Architecture of CNN)

ในหัวข้อนี้จะกล่าวถึงสถาปัตยกรรมของโครงข่ายประสาทเทียมแบบคอนโวลูชัน

### 2.3.1 LeNet

LeCun et al [11, 12] ได้นำเสนอสถาปัตยกรรมโครงสร้าง LeNet ขึ้นในปี 1990 และพัฒนาต่อยอดขึ้นในปี 1998 โดยงานวิจัยนี้ได้เกี่ยวกับการรู้จำตัวเลขที่เป็นลายมือโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน และพบว่าสามารถนำไปประยุกต์ใช้ในด้านการอ่านรหัสไปรษณีย์ การอ่านตัวเลข เป็นต้น แต่ในช่วงเวลาที่ทำงานวิจัยนั้น


ยังขาดเครื่องที่มีการคำนวณที่มีพลังในการคำนวณมากพอส่งผลให้โครงข่ายประสาทเทียมแบบคอนโวลูชันหยุดใช้งานไปชั่วคราว โครงสร้างแบบจำลองแสดงในรูปที่ 15



รูปที่ 15 โครงสร้างสถาปัตยกรรม LeNet-5 [12]

### 2.3.2 AlexNet

Alex Krizhevsky Ilya Sutskever และ Geoff Hinton [9] ได้ทำการพัฒนาโครงสร้างขึ้นและได้รับรางวัลชนะเลิศในงาน ILSVRC ปี 2012 โครงสร้างของสถาปัตยกรรม AlexNet มีความคล้ายกับโครงสร้างของสถาปัตยกรรม LeNet แต่ต่างกันในส่วนชั้นคอนโวลูชัน และชั้น pooling ซึ่งโครงสร้างของสถาปัตยกรรม AlexNet นั้นมีความลึกและมีขนาดของโครงข่ายที่ใหญ่กว่า LeNet โครงสร้างแบบจำลองแสดงในรูปที่ 16



รูปที่ 16 โครงสร้างสถาปัตยกรรม AlexNet [9]

### 2.3.3 GoogLeNet

GoogLeNet หรืออีกชื่อคือ Inception-v1 Szegedy et al [13] ได้ทำการพัฒนาสถาปัตยกรรมนี้ขึ้น โดยนำเสนอโครงสร้างสถาปัตยกรรมที่มีความลึกมากขึ้นประกอบไปด้วยโมดูล Inception จำนวนทั้งสิ้น 22 โมดูล ถึงแม้จะเป็นโครงสร้างที่มีความลึกแต่มีจำนวนของพารามิเตอร์น้อยกว่าสถาปัตยกรรม AlexNet ซึ่งการใช้โมดูล Inception ทำให้สามารถแก้ปัญหา Gradient Vanishing ที่เกิดขึ้นเมื่อโครงข่ายประสาทเทียมมีความลึกมากขึ้น ในงาน ILSVRC ปี 2014 GoogLeNet มีค่าความผิดพลาด (Error) ที่น้อยที่สุดจึงทำให้ได้รับรางวัลชนะเลิศในการ


แข่งขันครั้งนั้น โครงสร้างนี้ได้รับแรงบันดาลใจมาจากภาพยนตร์เรื่อง Inception ซึ่งแนวคิดของภาพยนตร์คือการลง  
 ไปในฝันชั้นที่ลึกขึ้นเรื่อย ๆ โครงสร้างแบบจำลองแสดงในรูปที่ 17



รูปที่ 17 โครงสร้างสถาปัตยกรรม GoogLeNet [13]

### 2.3.4 VGGNet


Karen Simonyan [14] ได้วิเคราะห์ความลึกของชั้นคอนโวลูชันโดยให้พารามิเตอร์อื่น ๆ นอกเหนือจากความลึกเป็นพารามิเตอร์ควบคุม และใช้ฟิลเตอร์คอนโวลูชันขนาด  $3 \times 3$  ทำให้ได้โครงข่ายประสาทเทียมแบบคอนโวลูชันที่มีความแม่นยำมากขึ้นและได้รับรางวัลรองชนะเลิศ ในงาน ILSVRC ปี 2014 โครงสร้างแบบจำลองแสดงในรูปที่ 18



รูปที่ 18 โครงสร้างสถาปัตยกรรม VGG-16 [15]

### 2.3.5 ResNet

Kaiming et al [16] ได้นำเสนอช่วยงานการเรียนรู้แบบ residual (Residual Learning Framework) ชั้นของโครงข่ายประสาทเทียมถูกฝึกด้วยการนำข้อมูลขาเข้าของชั้นก่อนหน้ามาเป็นข้อมูลขาเข้าร่วมกับผลลัพธ์ขาออกจากชั้นก่อนหน้าแทนการใช้ผลลัพธ์ขาออกจากชั้นก่อนหน้ามาเป็นข้อมูลขาเข้าเพียงอย่างเดียว ทำให้สามารถปรับแต่ง (Optimize) โครงข่ายประสาทเทียมที่มีความลึกได้ง่ายขึ้นและยังทำให้ได้ความแม่นยำสูงขึ้นและได้รับรางวัลชนะเลิศในงาน ILSVRC ปี 2015 โครงสร้างแบบจำลองแสดงในรูปที่ 19



รูปที่ 19 โครงสร้างสถาปัตยกรรม ResNet-12 [17]

## 2.4 สายพันธุ์ของยุงที่ปรากฏในงานวิจัย

ในส่วนแรกของงานวิจัยได้มีการใช้ชุดข้อมูลที่เป็น open access [8] เพื่อนำมาทดลองฝึกกับแบบจำลองโครงข่ายประสาทเทียม ชุดข้อมูลนี้ประกอบด้วยยุงทั้งหมด 8 สปีชีส์ มาใช้สำหรับการฝึกโดยมาจาก 3 จินัส ได้แก่ จินัส *Aedes* จินัส *Anopheles* และจินัส *Culex* ซึ่งเป็นจินัสหลักที่เป็นพาหะนำโรค โดยประกอบด้วย ยุง 5 สปีชีส์ ที่เป็นพาหะนำโรค ได้แก่

- 2.4.1 ยุงลาย *Aedes albopictus* หรือยุงลายสวน

ยุงลายสวน หรือ ยุงลาย *Aedes albopictus* เป็นพาหะสำคัญในการนำเชื้อไวรัสที่ก่อให้เกิดโรคต่าง ๆ เช่น ไวรัสไข้เหลือง (Yellow Fever Virus) ไวรัสไข้เลือดออก (Dengue Virus) ไวรัสชิคุนกุนยา (Chikungunya Virus) ไวรัสซิกา (Zika Virus) [18]

- 2.4.2 ยุงลาย *Aedes vexans*

ยุงลาย *Aedes vexans* มีความสามารถในการเป็นพาหะนำโรคได้หลายโรค เช่น ไวรัสเวสต์ไนล์ (West Nile Virus) ไวรัสไข้สมองอักเสบเซนต์หลุยส์ (St. Louis Encephalitis Virus) ไข้สมองอักเสบจากไวรัส EEE (Eastern Equine Encephalitis Virus) ไข้สมองอักเสบจากไวรัส WEE (Western Equine Encephalitis Virus) ไวรัสไข้ริฟต์แวลลีย์ (Rift Valley Fever Virus) [19]

- 2.4.3 ยุงก้นปล่อง *Anopheles sinensis*

ยุงก้นปล่อง *Anopheles* เป็นพาหะของเชื้อ *Plasmodium Vivax* ซึ่งก่อให้เกิดโรคมาลาเรีย [20]

- 2.4.4 ยุงรำคาญ *Culex pipiens*

ยุงรำคาญ *Culex pipiens* เป็นพาหะนำโรคต่าง ๆ เช่น ไวรัสเวสต์ไนล์ (West Nile Virus) [21]

- 2.4.5 ยุงรำคาญ *Culex tritaeniorhynchus*

ยุงรำคาญ *Culex tritaeniorhynchus* เป็นพาหะหลักของไวรัสไข้สมองอักเสบเจอี (Japanese Encephalitis Virus) [22]

- ยุงที่ไม่เป็นพาหะนำโรค 3 สปีชีส์ ได้แก่ ยุงลาย *Aedes dorsalis* ยุงลาย *Aedes koreikus* และ ยุงรำคาญ *Culex inatomii* [8]

หลังจากนั้นทำการเก็บยุงตัวเมียที่เลี้ยงไว้ในห้องทดลองประกอบไปด้วย ยุง *Aedes aegypti* *Aedes albopictus* *Culex quinquefasciatus* จำนวนชนิดละ 100 ตัว และ ได้ทำการเก็บยุงตัวเมียจากธรรมชาติในหลายจังหวัดประกอบด้วย ยุง *Aedes aegypti* จากจังหวัดเชียงใหม่ กรุงเทพมหานคร สมุทรปราการ และ นครศรีธรรมราช จำนวน 221 ตัว ยุง *Aedes albopictus* จากจังหวัดเชียงใหม่ กรุงเทพมหานคร ชัยนาท และ นครศรีธรรมราช จำนวน 223 ตัว ยุง *Aedes vexans* จากจังหวัดเชียงใหม่ จำนวน 197 ตัว ยุง *Anopheles tessellatus* จังหวัดเชียงใหม่ จำนวน 178 ตัว ยุง *Culex quinquefasciatus* จากจังหวัดเชียงใหม่ กรุงเทพมหานคร สมุทรปราการ และนครศรีธรรมราช จำนวน 160 ตัว ยุง *Culex vishnui* จากจังหวัดเชียงใหม่ จำนวน 269 ตัว และยุงอื่น ๆ จากจังหวัดปทุมธานี จำนวน 236 ตัว หลังจากนั้นสร้างชุดข้อมูลภาพโดยนำยุงมาทำการถ่ายภาพด้วยโทรศัพท์มือถือตัวละ 3 ถึง 5 ครั้ง โดยทำการเปลี่ยนแสงและท่าทางของยุงระหว่างการถ่าย ได้เป็นชุดข้อมูลที่มีจำนวน 7 กลุ่ม ประกอบด้วย *Aedes aegypti* *Aedes albopictus* *Aedes vexans* *Anopheles tessellatus* *Culex quinquefasciatus* *Culex vishnui* และ Others (ยุง *Culex brevipalpis*) มีจำนวนภาพแต่ละกลุ่มทั้งสิ้น 763, 666, 591, 533, 719, 610 และ 708 ภาพ ตามลำดับ มีจำนวนภาพรวมทั้งหมด 4,590 ภาพ แสดงในตารางที่ 1



Species (GenBank accession no.)	Collection sites	No. of females	No. of images
<i>Aedes aegypti</i> (OP477050-OP477052)	Laboratory Chiang Mai, Bangkok, Samut Prakan, Nakhon Si Thammarat	100 221	763
<i>Aedes albopictus</i> (OP477053-OP477055)	Laboratory Chiang Mai, Bangkok, Chai Nat, Nakhon Si Thammarat	100 223	666
<i>Aedes vexans</i> (OP477062-OP477064)	Chiang Mai	197	591
<i>Anopheles tessellatus</i> (OP477047-OP477049)	Chiang Mai	178	533
<i>Culex quinquefasciatus</i> (OP477056-OP477058)	Laboratory Chiang Mai, Bangkok, Samut Prakan, Nakhon Si Thammarat	100 160	719
<i>Culex vishnui</i> (OP477059-OP477061)	Chiang Mai	269	610
Other Mosquitoes	Pathum Thani	236	708
<b>Total</b>		<b>1,784</b>	<b>4,590</b>

ตารางที่ 1 ชนิดตัวอย่างยุงในประเทศไทย แหล่งที่เก็บตัวอย่าง และจำนวนภาพ

## 2.5 โรคที่เกิดจากยุงเป็นพาหะนำโรค (Mosquito-borne Diseases)

ทั่วทั้งโลกมียุงอยู่ประมาณ 3,500 สปีชีส์ ในยุงเกือบทุกสปีชีส์ยุงตัวเมียจะใช้เลือดของสัตว์มีกระดูกสันหลังเป็นแหล่งของโปรตีนเพื่อใช้ในการผลิตไข่สำหรับการสืบพันธุ์ การดูดเลือดของยุงสามารถที่จะส่งต่อเชื้อโรคที่ยุงเป็นพาหะไปสู่สิ่งมีชีวิตที่ถูกดูดเลือดได้ ถึงแม้ว่าทั่วโลกจะมียุงอยู่ถึง 3,500 สปีชีส์ แต่ยุงที่เป็นพาหะนำโรคสู่มนุษย์ส่วนใหญ่จะอยู่ในจิ้นัส *Aedes* จิ้นัส *Anopheles* และ จิ้นัส *Culex*

### 2.5.1 ไข้มาลาเรีย (Malaria)

ไข้มาลาเรียเป็นโรคที่เกิดจากติดเชื้อของเซลล์เม็ดเลือดแดง (Red Blood Cells) จากโปรโตซัว [23] การติดเชื้อในมนุษย์หลัก ๆ ที่พบจะเกิดจากโปรโตซัวจิ้นัส *Plasmodium* ซึ่งสายพันธุ์ที่พบได้บ่อยในมนุษย์ได้แก่ *Plasmodium falciparum* *Plasmodium vivax* *Plasmodium avale* *Plasmodium malariae* และ *Plasmodium knowlesi* โดยมียุงจิ้นัส *Anopheles* เพศเมียเป็นพาหะของโรค อาการของผู้ป่วยจากโรคมาลาเรียอาการจะเริ่มขึ้นหลังจากระยะเวลาเพาะตัวของเชื้อประมาณ 10-15 วัน โดยอาการช่วงแรกจะมีไข้ ปวดหัว หนาวสั่น บางรายอาจมีอาการไม่รุนแรงซึ่งทำให้วิเคราะห์ว่าเป็นมาลาเรียได้ยาก ถ้าไม่ได้รับการรักษาเชื้ออาจจะส่งผลให้ผู้ป่วยมีอาการรุนแรงได้ เด็กอายุต่ำกว่า 5 ปี และผู้ที่มีภูมิคุ้มกันต่ำจะมีความเสี่ยงมากกว่ากลุ่มอื่น ในปี 2019 เด็กอายุต่ำกว่า 5 ปี เสียชีวิตทั่วโลกรวมกันเป็นจำนวนถึง 274,000 ราย ซึ่งคิดเป็นร้อยละ 67 จากผู้เสียชีวิตทั้งหมด [24]

### 2.5.2 ไข้เหลือง (Yellow Fever)

เป็นโรคที่เกิดจากไวรัสในจิ้นัส *Flavivirus* โดยมียุงสปีชีส์ *Aedes aegypti* เป็นพาหะนำโรคสู่มนุษย์ [23] ไวรัสจะมีระยะเวลาฟักตัว 3-6 วัน ส่วนมากผู้ป่วยจะไม่มีอาการ อาการส่วนมากจะมีไข้ ปวดเมื่อยกล้ามเนื้อ โดยเฉพาะบริเวณหลัง ปวดหัว เบื่ออาหาร คลื่นไส้ อาเจียน ส่วนมากอาการป่วยข้างต้นจะหายไปภายใน 3 ถึง 4 วัน ในผู้ป่วยบางรายอาจมีอาการป่วยในระยะที่ 2 ซึ่งมีความรุนแรงมากผู้ป่วยจะมีไข้สูงอีกครั้ง มีอาการเหลืองที่

ผิวหนังและดวงตา อาจจะมีเลือดไหลจากปาก จมูก ดวงตา หรือกระเพาะอาหาร กว่าครึ่งหนึ่งของผู้ป่วยที่เข้าสู่ระยะที่ 2 เสียชีวิตภายใน 7 ถึง 10 วัน [25]

### 2.5.3 ไข้เลือดออก (Dengue)

ไข้เลือดออก (Dengue) เป็นโรคที่เกิดจากเชื้อไวรัสที่มีบรรพบุรุษเดียวกันกับไข้เหลือง ส่วนมากจะมียุงสปีชีส์ *Aedes aegypti* เป็นพาหะนำโรคสู่มนุษย์เนื่องจากยุงสายพันธุ์นี้มาการปรับตัวเข้ากับวิถีชีวิตของมนุษย์ [23] อาการป่วยของโรคไข้เลือดออกผู้ป่วยบางรายอาจจะไม่แสดงอาการป่วย บางรายอาจมีอาการป่วยที่รุนแรง อาการป่วยจะเริ่มแสดงอาการหลังจากถูกยุงที่เป็นพาหะนำเชื้อกัดประมาณ 4 ถึง 10 วัน อาการป่วยทั่วไปอาจจะคล้ายกับการป่วยจากไข้หวัด เช่น มีไข้ ปวดหัว ปวดตามข้อและกล้ามเนื้อ คลื่นไส้ อาเจียน อ่อนเพลีย มีผื่นที่ผิวหนัง ปวดบริเวณหลังดวงตา นอกจากนี้ผู้ป่วยอาจจะมีเลือดออกบริเวณจมูก และเหงือก มีความดันโลหิตต่ำแบบเฉียบพลันซึ่งอาจนำไปสู่ภาวะช็อค มีการประมาณการผู้ป่วยโรคไข้เลือดออกในแต่ละปีถึง 100 ล้านคน ที่แสดงอาการป่วย และ ผู้ป่วยที่ไม่มีการจำแนก 300 ล้านคน [4] โดยไวรัสไข้เลือดออกนั้นมีอยู่ 4 สายพันธุ์ด้วยกัน

### 2.5.4 โรคไข้มองอักเสบเจอี (Japanese Encephalitis Virus)

โรคไข้มองอักเสบเจอี (Japanese Encephalitis Virus) เกิดจากเชื้อไวรัส *Japanese encephalitis* ซึ่งอยู่ในกลุ่มเดียวกันกับ *Flavivirus* พาหะนำโรคหลักเป็นยุงในจินัส *Culex* [23] ส่วนมากผู้ป่วยโรคไข้มองอักเสบเจอีมักไม่แสดงอาการหรือมีอาการป่วยไม่รุนแรง โดยมีสัดส่วนอาการป่วยรุนแรงประมาณ 1 ใน 250 คน เชื่อจะมีระยะฟักตัว 4 ถึง 14 วัน ในเด็กอาการเริ่มต้นอาจจะมีกรปวดในทางเดินอาหาร รวมถึงอาเจียน ในผู้ป่วยที่มีอาการรุนแรงอาจจะมีไข้สูง ปวดหัว โคม่า ชัก และอาจเสียชีวิตได้ ผู้ป่วยที่รอดชีวิตประมาณร้อยละ 20 ถึง 30 อาจมีปัญหาทางด้านสติปัญญา รวมไปถึงเป็นอัมพาต การชัก หรือไม่สามารถพูดได้ [26]

### 2.5.5 โรคไข้มองอักเสบจากไวรัสเวสต์ไนล์ (West Nile Virus)

โรคไข้มองอักเสบจากไวรัสเวสต์ไนล์ (West Nile Virus) เกิดจากเชื้อไวรัสในกลุ่มจินัส *Flavivirus* มีพาหะนำโรคหลักโดยยุงจินัส *Culex* [23] โดยมีระยะฟักตัวของเชื้ออยู่ที่ 3 ถึง 14 วัน ผู้ป่วยร้อยละ 80 จะไม่แสดงอาการ ส่วนผู้ป่วยที่มีอาการป่วยจากโรคนี้อาจจะมีไข้ ปวดหัว ปวดตามร่างกาย คลื่นไส้ อาเจียน ผู้ป่วยประมาณ 1 ใน 150 จะมีอาการรุนแรง มีไข้สูง มีอาการซึม (stupor) สั่น ชัก โคม่า หรือเป็นอัมพาต [27]

### 2.5.6 โรคชิคุนกุนยา (Chikungunya)

โรคชิคุนกุนยา (Chikungunya) เกิดจากเชื้อไวรัสที่อยู่ในจินัส *Alphavirus* มีพาหะนำโรคหลักโดยยุงจินัส *Aedes Culex Mansonia* และ *Anopheles* โดยในภูมิภาคเอเชียยุงสปีชีส์ *Aedes aegypti* และ *Aedes albopictus* จะเป็นกลุ่มหลักที่เป็นพาหะนำโรคสู่มนุษย์ [23] โดยเชื่อมีระยะเวลาฟักตัว 4 ถึง 7 วัน ผู้ป่วยส่วนมากจะมีอาการไม่รุนแรงโดยมีไข้ ปวดตามข้อ ปวดกล้ามเนื้อ ปวดหัว คลื่นไส้ มีผื่นตามผิวหนัง อาการส่วนมากจะหายไปภายใน 2 ถึง 3 วัน แต่อาการปวดตามข้ออาจจะมีอาการอยู่ถึงหลายสัปดาห์ในบางรายอาการปวดตามข้ออาจคงอยู่เป็นเวลานานหลายเดือนหรือเป็นปี [28]

### 2.5.7 โรคเท้าช้าง (Filariasis)

โรคเท้าช้าง (Filariasis) เป็นโรคที่เกิดจากพยาธิหนอนตัวกลม (Round Worm) โดยมีพยาธิ 3 ชนิด เป็นตัวกำเนิดโรคได้แก่ *Wuchereria bancrofti* *Brugia malayi* และ *Brugia timori* [23] พบว่า *Wuchereria bancrofti* เป็นสาเหตุของโรคถึงร้อยละ 90 แต่มียุงหลากหลายชนิดเป็นพาหะนำโรค หนอนจะอาศัยอยู่ในระบบต่อมน้ำเหลืองและมีอายุยืน 6 ถึง 8 ปี ผู้ป่วยส่วนมากไม่แสดงอาการแต่อย่างไรก็ตามหนอนก็ยังคงก่อให้เกิดความเสียหายต่อระบบน้ำเหลืองรวมไปถึงไตและส่งผลถึงระบบภูมิคุ้มกัน เมื่อโรคเท้าช้างอยู่ในช่วงเรื้อรังจะก่อให้เกิดการบวมของผิวหนังและเนื้อเยื่อ [29]

### 2.6 การจำแนกสายพันธุ์ยุง (Mosquito Classification)

Park et al [8] นำเสนอการจำแนกยุงที่มีความเสี่ยงในการเป็นพาหะนำโรคจำนวน 5 สายพันธุ์ได้อย่างแม่นยำรวมทั้ง อีกทั้งยังชี้ให้เห็นถึงผลของการเพิ่มจำนวนข้อมูล (Data Augmentation) ว่าสามารถช่วยให้โครงข่ายประสาทเทียมทำงานได้อย่างถูกต้องแม่นยำมากกว่าโครงข่ายประสาทเทียมที่ไม่ได้ใช้การเพิ่มจำนวนข้อมูลร่วมด้วย ผลลัพธ์ที่ได้จากโครงข่ายประสาทเทียมยังแสดงให้เห็นว่าโครงข่ายประสาทเทียมมีวิธีการในการจำแนกสายพันธุ์ของยุงคล้ายกับการใช้คนจำแนกโดยใช้คุณลักษณะเด่นของยุง เช่น ลักษณะของปีก ลักษณะของลำตัว

Okayasu et al [30] นำเสนอการเปรียบเทียบการจำแนกสายพันธุ์ยุงด้วยวิธีแบบดั้งเดิมด้วยวิธีการแยกคุณลักษณะของข้อมูล (feature extraction) จำนวน 12 วิธี โดยใช้ รูปร่าง สี พื้นผิว และความถี่ หลังจากนั้นใช้ SVM (Support Vector Machine) ในการจำแนกชนิดของยุง และ การจำแนกสายพันธุ์ยุงด้วยโครงข่ายประสาทเทียม 3 โครงข่าย ได้แก่ AlexNet VGGNet และ ResNet ผลที่ได้พบว่าการจำแนกสายพันธุ์ยุงด้วยโครงข่ายประสาทเทียมให้ความถูกต้องสูงกว่าการจำแนกสายพันธุ์ยุงด้วยวิธีแบบดั้งเดิมรวมถึงการเพิ่มจำนวนข้อมูลสามารถเพิ่มความถูกต้องในการทำงานของโครงข่ายประสาทเทียม

Motta et al [31] นำเสนอการเปรียบเทียบการจำแนกสายพันธุ์และเพศของยุง ด้วยโครงข่ายประสาทเทียม 3 โครงข่ายคือ Alex Net LeNet และ GoogLeNet โดยพบว่าโครงข่ายที่มีความซับซ้อนมากกว่าโดยมีจำนวนชั้นมากกว่า สามารถเพิ่มความถูกต้องของโครงข่ายประสาทเทียมได้

Ortiz et al [32] นำเสนอการจำแนกสายพันธุ์ยุงจากภาพลูกน้ำด้วยวิธีดั้งเดิม โดยใช้ K-means และ SVM เปรียบเทียบกับโครงข่ายประสาทเทียม และพบว่าการใช้โครงข่ายประสาทเทียมพร้อมทั้งการเพิ่มจำนวนข้อมูลและการใช้การเรียนรู้แบบถ่ายโอน มีความถูกต้องสูงกว่าการจำแนกด้วยวิธีแบบดั้งเดิม

Fanioudakis et al [6] นำเสนอการจำแนกสายพันธุ์ของยุงจากข้อมูลที่ตรวจวัดทางแสงของการบินของยุงด้วยแบบจำลองการเรียนรู้เชิงลึก ของยุง 6 สายพันธุ์ ได้แก่ *Aedes aegypti* *Aedes albopictus* *Anopheles arabiensis* *Anopheles gambiae* *Culex pipiens* และ *Culex quinquefasciatus* พบว่าเมื่อใช้สถาปัตยกรรมการเรียนรู้เชิงลึก DenseNet121 โดยใช้ข้อมูลสเปกโทรแกรม (Spectrogram) ในการฝึก พบว่าได้ความแม่นยำมากถึงร้อยละ 96

Ouyang et al [33] นำเสนอการจำแนกสายพันธุ์และเพศของยุงจากข้อมูลที่เก็บบันทึกจากอุปกรณ์อินฟราเรดของการบินของยุงด้วยกลวิธีการเรียนรู้ของเครื่อง ของยุงสายพันธุ์ *Aedes albopictus* *Aedes aegypti* และ *Culex quinquefasciatus* โดยใช้แบบจำลองส่วนผสมแบบเกาส์เซียน (Gaussian Mixture Model) ผ่านการฝึกด้วยอัลกอริทึมหาค่าคาดหวังสูงสุด (Expectation Maximization) โดยได้ค่าความแม่นยำในการจำแนกสูงกว่าร้อยละ 80 และพบว่ายุงบางสายพันธุ์มีลักษณะเฉพาะ (Characteristic) บางอย่างที่มีความคล้ายกัน

Lorenz et al [34] ได้นำเสนอเทคนิคการจำแนกและระบุสายพันธุ์ของยุงด้วย โครงข่ายประสาทเทียม (ANN) จากชุดข้อมูลยุง 17 สายพันธุ์ ในจันีส *Anopheles* *Aedes* และ *Culex* โดยใช้คุณลักษณะของลักษณะปีกเป็นตัวจำแนกและได้ความแม่นยำอยู่ในช่วงร้อยละ 85.7 ถึง 100



### บทที่ 3 การเพิ่มความแม่นยำของโครงข่ายประสาทเทียม

#### 3.1 การเรียนรู้แบบถ่ายโอน (Transfer Learning)

การเรียนรู้แบบถ่ายโอนเป็นวิธีการเรียนรู้ของโครงข่ายประสาทเทียมแบบหนึ่ง โดยการนำความรู้ที่ได้จากการเรียนรู้ก่อนหน้ามาเป็นพื้นฐานของแบบจำลองก่อนที่จะเริ่มทำการฝึก การใช้วิธีการเรียนรู้แบบถ่ายโอนในโครงข่ายประสาทเทียมจะทำได้โดยการใช้ค่าน้ำหนักที่ถูกฝึกเรียบร้อยแล้วของสถาปัตยกรรมเดียวกันกับแบบจำลองที่จะนำมาใช้ในการฝึก ตัวอย่างเช่น ผู้วิจัยต้องการฝึกแบบจำลองโครงข่ายประสาทเทียม VGG-16 ผู้วิจัยต้องใช้ค่าน้ำหนักจากแบบจำลองโครงข่ายประสาทเทียม VGG-16 ที่ถูกฝึกเสร็จสิ้นเรียบร้อยแล้วมาเป็นค่าน้ำหนักเริ่มต้นของการฝึก โดยภายในชุดคำสั่ง Keras จะมีค่าน้ำหนักของแบบจำลองที่ได้รับการฝึกบนชุดข้อมูลของ ImageNet ซึ่งเป็นชุดข้อมูลที่มีจำนวนรูปภาพที่ใช้สำหรับการฝึกมากกว่า 1.2 ล้านรูป จากรูปทั้งหมด 1000 ชนิด ซึ่งการใช้วิธีการเรียนรู้แบบถ่ายโอนนั้นสามารถช่วยแก้ปัญหาชุดข้อมูลที่มีขนาดเล็กได้เมื่อต้องการฝึกแบบจำลองที่มีความลึก

#### 3.2 การเพิ่มปริมาณข้อมูล (Data Augmentation)

เนื่องจากรูปที่มีอยู่นั้นมีจำนวนจำกัดจึงจำเป็นต้องมีการเพิ่มจำนวนชุดข้อมูลขึ้นเพื่อให้โครงข่ายประสาทเทียมสามารถเรียนรู้ที่จะแยกแยะคุณลักษณะของยุงได้ดีขึ้น โดยการใช้คลังชุดคำสั่ง (Library) imgaug ในการเพิ่มปริมาณข้อมูลภาพโดยการดัดแปลงจากรูปภาพเดิมที่มีอยู่



รูปที่ 20 ภาพถ่ายยุง *Aedes albopictus* ที่ผ่านการเพิ่มปริมาณข้อมูลภาพด้วยฟังก์ชัน Rotate



รูปที่ 21 ภาพถ่ายยุง *Aedes albopictus* ที่ผ่านการเพิ่มปริมาณข้อมูลภาพด้วยฟังก์ชัน MultiplyHue



รูปที่ 22 ภาพถ่ายยุง *Aedes albopictus* ที่ผ่านการเพิ่มปริมาณข้อมูลภาพด้วยฟังก์ชัน MultiplyBrightness



รูปที่ 23 ภาพถ่ายยุง *Aedes albopictus* ที่ผ่านการเพิ่มปริมาณข้อมูลภาพด้วยฟังก์ชัน Scale



รูปที่ 24 ภาพถ่ายยุง *Aedes albopictus* ที่ผ่านการเพิ่มปริมาณข้อมูลภาพด้วยฟังก์ชัน LinearContrast



รูปที่ 25 ภาพถ่ายยุง *Aedes albopictus* ที่ผ่านการเพิ่มปริมาณข้อมูลภาพด้วยฟังก์ชัน CenterCropToFixedSize

### 3.3 การสร้างชุดข้อมูล (Dataset) และการติดป้าย (Labeling)

1. ข้อมูลรูปภาพได้นำมาจาก [8] ประกอบไปด้วยชุดข้อมูลที่ไว้สำหรับฝึก (Training) จำนวนทั้งสิ้น 2980 รูป และข้อมูลสำหรับทดสอบ (Test) จำนวน 2960 รูป และทำการติดป้าย (Labeling) โดยการแบ่งเป็นกลุ่มทั้งหมด 6 กลุ่ม ประกอบด้วย *Aedes albopictus* *Aedes vexans* *Anopheles sinensis* *Culex pipiens* *Culex tritaeniorhynchus* และ Non vectors โดยกลุ่ม Non vectors นั้นจะประกอบไปด้วยยุงจำนวน 3 สายพันธุ์ที่ไม่เป็นพาหะนำโรค ได้แก่ *Aedes dorsalis* *Aedes koreikus* และ *Culex inatomii* โดยมีการเก็บตัวอย่างยุงแต่ละสายพันธุ์ประมาณ 120 ตัวอย่าง หลังจากนั้นนำตัวอย่างที่ได้มาทำการถ่ายรูปโดยเปลี่ยนลักษณะท่าทาง มุม และความเข้มแสง เป็นจำนวน 3 ถึง 5 ครั้ง ต่อหนึ่งตัวอย่าง โดยทำการบันทึกภาพที่ความละเอียด 2952 x 1944 พิกเซล จนได้รูปภาพของยุงแต่ละกลุ่มประมาณ 600 รูป หลังจากนั้นทำการลดขนาดของภาพโดยการลดความละเอียดลงให้มีความละเอียด 420 x 314 พิกเซล และทำการแบ่งรูปภาพจากแต่ละกลุ่มมาประมาณ 100 รูป จากนั้นทำการเพิ่มปริมาณข้อมูล (Data Augmentation) ของรูปภาพจนได้จำนวนรวมทั้งหมด 500 รูป โดยมีความละเอียด 224 x 224 พิกเซล เพื่อใช้สำหรับเป็นชุดทดสอบส่วนรูปภาพที่เหลือจะใช้เป็นข้อมูลสำหรับชุดฝึกแต่เนื่องจากจำนวนรูปภาพมีจำนวนเพียง 3000 รูป จึงมีความจำเป็นที่จะต้องทำการเพิ่มปริมาณข้อมูลเพื่อให้โครงข่ายประสาทเทียมสามารถเรียนรู้ได้ดีมากขึ้น



รูปที่ 26 ตัวอย่างยุงสายพันธุ์ *Aedes albopictus*



รูปที่ 27 ตัวอย่างยุงสายพันธุ์ *Aedes vexans*



รูปที่ 28 ตัวอย่างยุงสายพันธุ์ *Anopheles sinensis*






รูปที่ 29 ตัวอย่างยุงสายพันธุ์ *Culex pipiens*



รูปที่ 30 ตัวอย่างยุงสายพันธุ์ *Culex tritaeniorhynchus*



รูปที่ 31 ตัวอย่างยุงสายพันธุ์ *Aedes koreikus*



รูปที่ 32 ตัวอย่างยุงสายพันธุ์ *Aedes dorsalis*



รูปที่ 33 ตัวอย่างยุงสายพันธุ์ *Culex inatomii*

2.ชุดข้อมูลภาพยุงในประเทศไทยประกอบด้วยยุงจาก 2 แหล่ง 1.) ยุงที่มีการเพาะเลี้ยงรักษาสายพันธุ์มาอย่างต่อเนื่องในห้องเพาะเลี้ยงที่ภาควิชาปรสิตวิทยา คณะแพทยศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ได้แก่ ยุง *Aedes aegypti*, *Aedes albopictus* และ *Culex quinquefasciatus* โดยยุงจำนวนหนึ่งจะถูกนำมาใช้ในงานวิจัยฉบับนี้ 2.) ยุงตัวเมียที่ได้ทำการดัดเลือดจนเต็มทีประกอบด้วย ยุง *Aedes aegypti*, *Aedes albopictus*, *Aedes vexans*, *Anopheles tessellatus*, *Culex aculaetus*, *Culex quinquefasciatus* และ *Culex vishnui* ถูกเก็บรวบรวมมาจาก 6 จังหวัดในประเทศไทย ได้แก่ จังหวัดกรุงเทพมหานคร, จังหวัดชัยนาท, จังหวัดเชียงใหม่, จังหวัดนครศรีธรรมราช, จังหวัดปทุมธานี และจังหวัดสมุทรปราการ และจัดให้ยุงแต่ละตัวอยู่ในภาชนะสำหรับการวางไข่ โดยจะมียุงหนึ่งตัวต่อหนึ่งภาชนะเพื่อให้ได้ยุงที่เกิดจากยุงตัวเมียตัวเดียวกันอยู่ภายในภาชนะที่ได้จัดไว้แล้ว หลังจากนั้นนำรุ่นลูกจำนวน 1 ตัว จากภาชนะที่เลี้ยงแต่ละภาชนะมาทำการยึนย่นสายพันธุ์ หลังจากนั้นทำการนำตัวอย่างของยุงที่เป็นรุ่นลูกของยุงที่เก็บมาจากหลาย ๆ จังหวัดประมาณสายพันธุ์ละ 200 ตัว และตัวอย่างของยุงที่มีการรักษาสายพันธุ์ในห้องทดลองมาอีก 100 ตัว ต่อสายพันธุ์เพื่อใช้ในการสร้างชุดข้อมูลภาพ

หลังจากนั้นสร้างชุดข้อมูลภาพโดยนำยุงมาทำการถ่ายภาพด้วยโทรศัพท์มือถือตัวละ 3 ถึง 5 ครั้ง โดยทำการเปลี่ยนแสงและท่าทางของยุงระหว่างการถ่าย ได้เป็นชุดข้อมูลที่มีจำนวน 7 กลุ่ม ประกอบด้วย *Aedes aegypti*, *Aedes albopictus*, *Aedes vexans*, *Anopheles tessellatus*, *Culex quinquefasciatus*, *Culex vishnui* และ


Others (ยุง *Culex aculeatus*) มีจำนวนภาพแต่ละกลุ่มทั้งสิ้น 763, 666, 591, 533, 719, 610 และ 708 ภาพตามลำดับ โดยมีจำนวนภาพรวมทั้งหมด 4,590 ภาพ




รูปที่ 34 ชุดอุปกรณ์ถ่ายภาพยุง



รูปที่ 35 ตัวอย่างภาพยุงจากกล้องโทรศัพท์มือถือ




รูปที่ 36 ตัวอย่างยุงสายพันธุ์ *Aedes aegypti*



รูปที่ 37 ตัวอย่างยุงสายพันธุ์ *Aedes albopictus*




รูปที่ 38 ตัวอย่างยุงสายพันธุ์ *Aedes vexans*




รูปที่ 39 ตัวอย่างยุงสายพันธุ์ *Anopheles tessellatus*



รูปที่ 40 ตัวอย่างยุงสายพันธุ์ *Culex quinquefasciatus*



รูปที่ 41 ตัวอย่างยุงสายพันธุ์ *Culex vishnui*



รูปที่ 42 ตัวอย่างยุงอื่น ๆ

### 3.4 กรรรมวิธีพัฒนาโครงข่ายประสาทเทียมสำหรับการจำแนกประเภทสายพันธุ์ยุง


การจำแนกวัตถุด้วยโครงข่ายประสาทเทียมเป็นการทำให้คอมพิวเตอร์สามารถรับรู้และประมวลผลสิ่งที่ได้รับว่าเป็นอะไร โดยหลักการทำงานของโครงข่ายประสาทเทียมแบบคอนโวลูชันมีหลักการทำงานคล้ายกับการมองเห็นของมนุษย์และหาคุณลักษณะของวัตถุนั้น ๆ เพื่อที่จะบอกว่าวัตถุนั้นคืออะไรโดยมีพื้นฐานมาจากความรู้เดิมที่เคยเรียนรู้มา ในปี 2012 ในการแข่งขัน Large Scale Visual Recognition Challenge 2012 (ILSVRC 2012) เป็นการแข่งชันการจำแนกวัตถุโดยมีข้อมูลชุดภาพ (Image Dataset) มากกว่า 1.4 ล้านภาพ และวัตถุมีจำนวนชนิดถึง 1000 ชนิด เพื่อที่จะหาแบบจำลองที่มีประสิทธิภาพสูงสุด โดยโครงข่ายประสาทเทียมแบบคอนโวลูชันได้ถูกพัฒนาขึ้นและได้รับรางวัลชนะเลิศในการแข่งขันจำแนกวัตถุ โครงข่ายประสาทเทียมแบบคอนโวลูชันจึงได้รับความนิยมและถูกนำมาใช้ในงานด้านจำแนกวัตถุมากขึ้นแทนที่แบบจำลองที่ใช้การหาคุณลักษณะแบบดั้งเดิม โดยใช้โครงข่ายประสาทเทียมที่มีประสิทธิภาพสูงจากการแข่งขันในงาน ILSVRC มาเป็น backbone ในการฝึก โดยการฝึกโครงข่ายประสาทเทียมนั้นต้องมีการเตรียมความพร้อมของระบบปฏิบัติการให้พร้อมใช้งาน และติดตั้งองค์ประกอบพื้นฐานที่เกี่ยวข้องกับการใช้งาน GPU ได้แก่ชุดคำสั่ง CUDA TOOLKIT CUDNN และ TENSORFLOW 2.4

การฝึกของผู้วิจัยจะทำการฝึกโครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้ชุดคำสั่ง Keras ซึ่งเป็นชุดคำสั่งที่อยู่ภายใน TENSORFLOW 2.4 โดยชุดคำสั่ง Keras สามารถสร้างโครงข่ายประสาทเทียมขึ้นมาใหม่ด้วย



คำสั่งต่าง ๆ เช่น Dense Conv2D Dropout Flatten โดยสามารถกำหนดค่าพารามิเตอร์ในอากิวเมนต์ (Arguments) ต่าง ๆ ของคำสั่งได้ตามต้องการ แต่ข้อมูลที่ใช้ในการฝึกสำหรับงานวิจัยนี้มีขนาดเล็ก ผู้วิจัยจึงเลือกใช้โครงข่ายประสาทเทียมที่มีอยู่ภายในชุดคำสั่ง Keras เช่น VGG16 VGG19 ResNet50 นอกจากนี้ยังสามารถใช้วิธีการเรียนรู้แบบถ่ายโอนโดยใช้น้ำหนักเริ่มต้นของโครงข่ายประสาทเทียมที่ถูกฝึกบนชุดข้อมูล ImageNet ซึ่งเป็นชุดข้อมูลฝึกที่มีขนาดใหญ่ (ประมาณ 1.4 ล้านภาพ) มาเป็นน้ำหนักเริ่มต้นก่อนการฝึกได้ เพื่อช่วยในการเรียนรู้คุณลักษณะระดับต่ำ เช่น ขอบ มุม ของโครงข่ายประสาทเทียมได้ดียิ่งขึ้น โดยผู้วิจัยได้ทำการเลือกใช้โครงข่ายประสาทเทียมที่ได้รับการฝึกบนชุดข้อมูล ImageNet มาเป็น backbone สำหรับการฝึกบนข้อมูลที่ใช้ในงานวิจัย โดยหลังจากตั้งค่าให้โครงข่ายประสาทเทียมมีน้ำหนักเริ่มต้นจากการเรียนรู้แบบถ่ายโอนแล้ว จะทำการปรับแต่ง (Fine-tuning) โครงข่ายประสาทเทียมเพื่อให้ได้ประสิทธิภาพในการจำแนกสายพันธุ์ยุงที่สูงขึ้น

ขั้นตอนสำหรับการฝึกโครงข่ายประสาทเทียม จะนำข้อมูลภาพถ่ายยุงที่ผ่านการเพิ่มปริมาณชุดข้อมูล และติดป้ายบ่งบอกคลาสของยุง จำนวน 6 คลาส ประกอบด้วยชื่อคลาส *Aedes albopictus* ชื่อคลาส *Aedes vexans* ชื่อคลาส *Anopheles sinensis* ชื่อคลาส *Culex pipiens* ชื่อคลาส *Culex tritaeniorhynchus* และชื่อคลาส Non vectors โดยแบ่งเป็นชุดสำหรับการฝึก (Training Set) ร้อยละ 75 ชุดตรวจสอบความถูกต้อง (Validation Set) ร้อยละ 25 และชุดสำหรับทดสอบ (Test Set) โดยฝึกโครงข่ายประสาทเทียมผ่าน Tensorflow ด้วย GPU และใช้ชุดสำหรับการฝึกและชุดตรวจสอบความถูกต้องในการฝึก โดยชุดตรวจสอบความถูกต้องจะเป็นชุดที่ประเมินผลสำหรับการฝึกในแต่ละ epoch หลังจากการฝึกเสร็จสิ้นจะใช้ชุดทดสอบในการทดสอบความแม่นยำของโครงข่ายประสาทเทียมที่ได้รับการฝึกเสร็จสิ้นแล้ว




รูปที่ 43 ตัวอย่างการติดป้ายข้อมูลตามคลาส


คอมพิวเตอร์ที่ใช้ประกอบด้วยระบบปฏิบัติการ : Ubuntu 20.04 LTS และ Microsoft Windows 10  
หน่วยประมวลผลกลาง CPU AMD Ryzen 7 Series 1700x 3.4GHz 8 cores 16 threads หน่วยประมวลผล  
กราฟิก GPU NVIDIA GeForce RTX 2080Ti 11GB บอร์ดหลัก Motherboard AM4 Asus X370 ROG

Crosshair VI Hero หน่วยความจำหลัก RAM Corsair Vengeance DDR4 3000MHz ความจุ 16 GB  
หน่วยความจำสำรอง ฮาร์ดดิสก์ WD Black ความจุ 1 TB


ทำการปรับปรุงพัฒนาแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน VGG-16 แสดงในรูปที่ 44 โดยการเพิ่มชั้น spatial dropout เข้าไปข้างหลังชั้น max-pooling ของแต่ละบล็อกคอนโวลูชัน แสดงในรูปที่ 45 ซึ่งชั้น spatial dropout จะมีความแตกต่างจากชั้น dropout ทั่วไป คือ ชั้น dropout ทั่วไปจะทำการหาค่าพารามิเตอร์ของแผนที่คุณลักษณะให้เป็นศูนย์ชั่วคราวแบบสุ่ม แต่ชั้น spatial dropout จะทำการหาค่าพารามิเตอร์ของแผนที่คุณลักษณะชั่วคราวของช่องให้เป็นศูนย์แบบสุ่มทั้งช่อง แสดงใน รูปที่ 46 และใช้เทคนิคการเรียนรู้แบบถ่ายโอนโดยใช้ค่าน้ำหนักที่เรียนรู้จากชุดข้อมูล ImageNet ซึ่งเป็นชุดข้อมูลขนาดใหญ่ซึ่งช่วยให้แบบจำลองสามารถเรียนรู้คุณลักษณะระดับกลางเช่น มุม ขอบ โค้ง ได้ดีขึ้น และทำการปรับปรุงพัฒนาแบบจำลอง VGG-16 ให้สามารถรับข้อมูลขาพร้อมกันทีละ 2 เพื่อให้แบบจำลองมีความทนทานในการใช้งานมากยิ่งขึ้น สร้างขึ้นจากโครงสร้างของแบบจำลอง VGG-16 ฝั่งหนึ่งส่วนอีกจะเป็นโครงสร้างของแบบจำลอง VGG-16 ตั้งแต่ชั้นข้อมูลขาเข้าจนถึงชั้นที่จะนำข้อมูลไปรวมกัน โดยการรวมกันได้รับแนวคิดจากวิธี spatial dropout โดยทำการหาค่าของช่องคู่ของฝั่งหนึ่ง และค่าของช่องคู่ของอีกฝั่งหนึ่งก่อนที่จะนำทั้งสองฝั่งมารวมเข้าด้วยกัน แสดงในรูปที่ 47 และทำการสร้างแบบจำลองที่มีการรวมข้อมูลกันทั้งสิ้น 3 แบบ ได้แก่ 1) early-combined VGG-16 แสดงในรูปที่ 48 จะเป็นการรวมข้อมูลทั้งสองฝั่งเข้าด้วยกันที่ชั้นถัดจากบล็อกคอนโวลูชันที่ 1 2) middle-combined VGG-16 แสดงในรูปที่ 49 จะเป็นการรวมข้อมูลทั้งสองฝั่งเข้าด้วยกันที่ชั้นถัดจากบล็อกคอนโวลูชันที่ 3 3) late-combined VGG-16 แสดงในรูปที่ 50 จะเป็นการรวมข้อมูลทั้งสองฝั่งเข้าด้วยกันที่ชั้นถัดจากบล็อกคอนโวลูชันที่ 5 นอกจากนี้ ยังได้นำผลลัพธ์ของแบบจำลองทั้ง 3 แบบ มาทำการสร้างแบบจำลอง ensemble ซึ่งเกิดจากการใช้ผลการทำนายร่วมกัน โดยใช้แบบจำลองโครงข่ายประสาทเทียม (ANN) เพื่อเพิ่มประสิทธิภาพความแม่นยำในการทำนายผล ดังรูปที่ 51



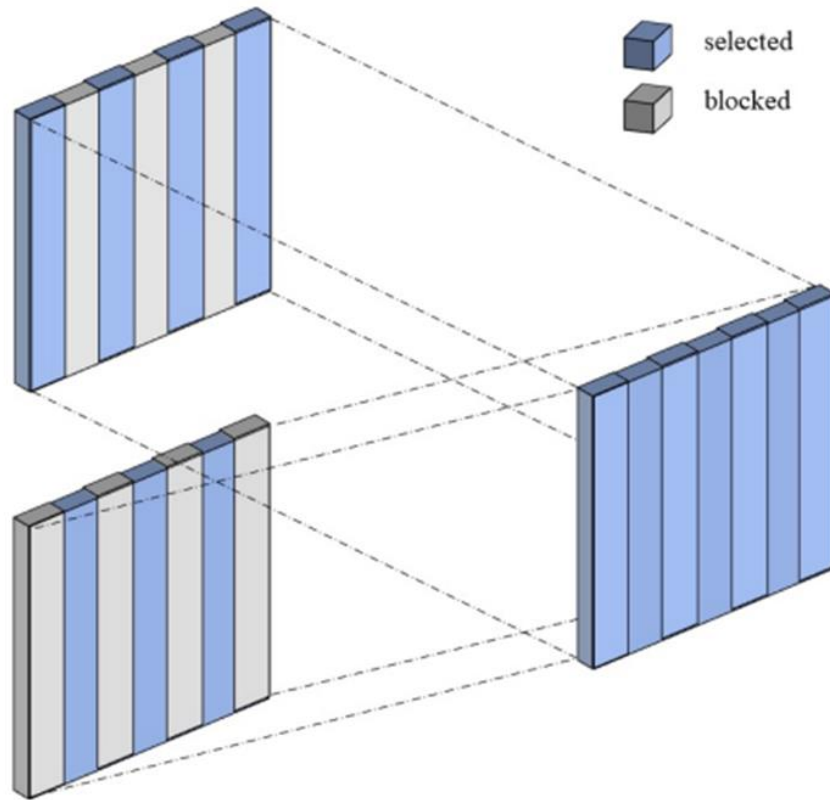
รูปที่ 44 แบบจำลอง VGG-16




รูปที่ 45 แบบจำลอง VGG-16 ที่มีการเพิ่มขึ้น spatial dropout




รูปที่ 46 (ซ้าย) dropout แบบทั่วไปของแผนที่คุณลักษณะ 3 มิติ (ขวา) spatial dropout ของแผนที่คุณลักษณะ 3 มิติ




รูปที่ 47 การรวมข้อมูลเข้าด้วยกันโดยมีแนวความคิดจาก spatial dropout




รูปที่ 48 แบบจำลอง early-combined VGG-16



รูปที่ 49 แบบจำลอง middle-combined VGG-16



รูปที่ 50 แบบจำลอง late-combined VGG-16



รูปที่ 51 การบวนการทำนายผลซึ่งประกอบไปด้วยแบบจำลอง VGG-16 ทั้ง 3 แบบจำลอง และนำผลลัพธ์ที่ได้ไปทำนายร่วมกันโดยใช้แบบจำลอง ensemble




## บทที่ 4 ผลการทำงานของระบบ

### 4.1 ผลลัพธ์การทำงานของแบบจำลอง VGG-16 และ VGG-19 บนชุดข้อมูลยุงจากประเทศเกาหลีใต้


ทำการฝึกแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน VGG-16 และ VGG-19 โดยใช้ชุดข้อมูลยุงจากประเทศเกาหลีใต้ที่ได้ทำการเพิ่มปริมาณข้อมูลภาพด้วยชุดคำสั่ง `imgaug` โดยทำการกำหนดแพ้มที่เก็บไฟล์ภาพต้นฉบับและแพ้มสำหรับผลลัพธ์ที่ได้จากการเพิ่มปริมาณข้อมูล จากนั้นทำการกำหนดจำนวนรอบสำหรับการเพิ่มปริมาณข้อมูลภาพแต่ละภาพ โดยภาพ 1 ภาพ จะทำการเพิ่มปริมาณข้อมูลเท่ากับจำนวนรอบที่ได้กำหนดไว้ และทำการเพิ่มปริมาณข้อมูลภาพแต่ละภาพจะถูกดำเนินการทุกฟังก์ชันแบบเป็นลำดับขั้น โดยแบบจำลอง VGG-16 และ VGG-19 ที่นำมาใช้ในการฝึกจะถูกปรับปรุงโดยการเพิ่มขึ้น `spatial dropout` ต่อจากชั้นคอนโวลูชันสุดท้ายของแต่ละบล็อกคอนโวลูชันก่อนที่จะเข้าชั้น `max pooling`

#### 4.1.1 การเพิ่มปริมาณข้อมูลภาพ (Data Augmentation) ชุดข้อมูลยุงจากประเทศเกาหลีใต้

ชุดข้อมูลยุงจากประเทศเกาหลีใต้ประกอบไปด้วยกลุ่ม *Aedes albopictus* *Aedes vexans* *Anopheles sinensis* *Culex pipiens* *Culex tritaeniorhynchus* และ Non vectors ชุดข้อมูลภาพทั้ง 6 กลุ่ม นี้ จะถูกนำมาทำการเพิ่มปริมาณข้อมูลภาพใช้ชุดคำสั่ง `imgaug` โดยทำการกำหนดแพ้มที่เก็บไฟล์ภาพต้นฉบับและแพ้มสำหรับผลลัพธ์ที่ได้จากการเพิ่มปริมาณข้อมูล จากนั้นทำการกำหนดจำนวนรอบสำหรับการเพิ่มปริมาณข้อมูลภาพแต่ละภาพ โดยภาพ 1 ภาพ จะทำการเพิ่มปริมาณข้อมูลเท่ากับจำนวนรอบที่ได้กำหนดไว้ และทำการเพิ่มปริมาณข้อมูลภาพแต่ละภาพจะถูกดำเนินการทุกฟังก์ชันแบบเป็นลำดับขั้น



รูปที่ 52 ตัวอย่างชุดข้อมูลภาพ *Aedes albopictus* ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ




รูปที่ 53 ตัวอย่างชุดข้อมูลภาพ *Aedes albopictus* หลังได้รับการเพิ่มปริมาณข้อมูลภาพ



รูปที่ 54 ตัวอย่างชุดข้อมูลภาพ *Aedes vexans* ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ







รูปที่ 55 ตัวอย่างชุดข้อมูลภาพ *Aedes vexans* หลังได้รับการเพิ่มปริมาณข้อมูลภาพ




รูปที่ 56 ตัวอย่างชุดข้อมูลภาพ *Anopheles sinensis* ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ




รูปที่ 57 ตัวอย่างชุดข้อมูลภาพ *Anopheles sinensis* หลังได้รับการเพิ่มปริมาณข้อมูลภาพ




รูปที่ 58 ตัวอย่างชุดข้อมูลภาพ *Culex pipiens* ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ




รูปที่ 59 ตัวอย่างชุดข้อมูลภาพ *Culex pipiens* หลังได้รับการเพิ่มปริมาณข้อมูลภาพ



รูปที่ 60 ตัวอย่างชุดข้อมูลภาพ *Culex tritaeniorhynchus* ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ



รูปที่ 61 ตัวอย่างชุดข้อมูลภาพ *Culex tritaeniorhynchus* หลังได้รับการเพิ่มปริมาณข้อมูลภาพ



รูปที่ 62 ตัวอย่างชุดข้อมูลภาพ Non vectors ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ




รูปที่ 63 ตัวอย่างชุดข้อมูลภาพ Non vectors หลังได้รับการเพิ่มปริมาณข้อมูลภาพ

#### 4.1.2 แบบจำลอง VGG-16

การฝึกแบบจำลอง VGG-16 จะทำการฝึกทั้งสิ้น 4 แบบ ได้แก่ 1.) การฝึกแบบจำลอง VGG-16 โดยไม่ได้ใช้เทคนิคการเรียนรู้แบบถ่ายโอน ไม่มีการปรับแต่งโครงสร้างของแบบจำลอง และ ไม่มีการทำการเพิ่มขนาดชุดข้อมูลภาพ 2.) การฝึกแบบจำลอง VGG-16 โดยใช้เพียงเทคนิคการเรียนรู้แบบถ่ายโอน แต่ไม่มีการปรับแต่งโครงสร้างของแบบจำลอง และ การเพิ่มขนาดของชุดข้อมูลภาพ 3.) การฝึกแบบจำลอง VGG-16 โดยใช้เทคนิคการเรียนรู้แบบถ่ายโอน และ การเพิ่มขนาดของชุดข้อมูลภาพ โดยไม่ได้มีการปรับแต่งโครงสร้างแบบจำลอง 4.) การฝึกแบบจำลอง VGG-16 โดยใช้เทคนิคการเรียนรู้แบบถ่ายโอน การปรับแต่งโครงสร้างแบบจำลอง และ การเพิ่มขนาดของชุดข้อมูลภาพ


1.) การฝึกแบบจำลอง VGG-16 โดยไม่ได้ใช้เทคนิคการเรียนรู้แบบถ่ายโอน ไม่มีการปรับแต่งโครงสร้างของแบบจำลอง และ ไม่มีการทำการเพิ่มขนาดชุดข้อมูลภาพ มีความแม่นยำของแบบจำลองบนชุดทดสอบอยู่ที่ร้อยละ 43.85



รูปที่ 64 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 1


2.) การฝึกแบบจำลอง VGG-16 โดยใช้เพียงเทคนิคการเรียนรู้แบบถ่ายโอน แต่ไม่มีการปรับแต่งโครงสร้างของแบบจำลอง และ การเพิ่มขนาดของชุดข้อมูลภาพ มีความแม่นยำของแบบจำลองบนชุดทดสอบอยู่ที่ร้อยละ

58.44



รูปที่ 65 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 2


3.) การฝึกแบบจำลอง VGG-16 โดยใช้เทคนิคการเรียนรู้แบบถ่ายโอน และการเพิ่มขนาดของชุดข้อมูลภาพ โดยไม่ได้มีการปรับแต่งโครงสร้างแบบจำลอง มีความแม่นยำของแบบจำลองบนชุดทดสอบอยู่ที่ร้อยละ 89.22



รูปที่ 66 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 3



4.) การฝึกแบบจำลอง VGG-16 โดยใช้เทคนิคการเรียนรู้แบบถ่ายโอน การปรับแต่งโครงสร้างแบบจำลอง และ การเพิ่มขนาดของชุดข้อมูลภาพ มีความแม่นยำของแบบจำลองบนชุดทดสอบอยู่ที่ร้อยละ 96.35




รูปที่ 67 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 4

#### 4.1.3 แบบจำลอง VGG-19

การฝึกแบบจำลอง VGG-19 จะทำการฝึกทั้งสิ้น 4 แบบ ได้แก่ 1.) การฝึกแบบจำลอง VGG-19 โดยไม่ได้ใช้เทคนิคการเรียนรู้แบบถ่ายโอน ไม่มีการปรับแต่งโครงสร้างของแบบจำลอง และ ไม่มีการทำการเพิ่มขนาดชุดข้อมูลภาพ 2.) การฝึกแบบจำลอง VGG-19 โดยใช้เพียงเทคนิคการเรียนรู้แบบถ่ายโอน แต่ไม่มีการปรับแต่งโครงสร้างของแบบจำลอง และ การเพิ่มขนาดของชุดข้อมูลภาพ 3.) การฝึกแบบจำลอง VGG-19 โดยใช้เทคนิคการเรียนรู้แบบถ่ายโอน และ การเพิ่มขนาดของชุดข้อมูลภาพ โดยไม่ได้มีการปรับแต่งโครงสร้างแบบจำลอง 4.) การฝึก


แบบจำลอง VGG-19 โดยใช้เทคนิคการเรียนรู้แบบถ่ายโอน การปรับแต่งโครงสร้างแบบจำลอง และการเพิ่มขนาดของชุดข้อมูลภาพ

1.) การฝึกแบบจำลอง VGG-19 โดยไม่ได้ใช้เทคนิคการเรียนรู้แบบถ่ายโอน ไม่มีการปรับแต่งโครงสร้างของแบบจำลอง และ ไม่มีการทำการเพิ่มขนาดชุดข้อมูลภาพ มีความแม่นยำของแบบจำลองบนชุดทดสอบอยู่ที่ร้อยละ 40.98




รูปที่ 68 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 1

2.) การฝึกแบบจำลอง VGG-19 โดยใช้เพียงเทคนิคการเรียนรู้แบบถ่ายโอน แต่ไม่มีการปรับแต่งโครงสร้างของแบบจำลอง และ การเพิ่มขนาดของชุดข้อมูลภาพ มีความแม่นยำของแบบจำลองบนชุดทดสอบอยู่ที่ร้อยละ 61.93




รูปที่ 69 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 2

3.) การฝึกแบบจำลอง VGG-19 โดยใช้เทคนิคการเรียนรู้แบบถ่ายโอน และการเพิ่มขนาดของชุดข้อมูลภาพ โดยไม่ได้มีการปรับแต่งโครงสร้างแบบจำลอง มีความแม่นยำของแบบจำลองบนชุดทดสอบอยู่ที่ร้อยละ 93.01



รูปที่ 70 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 3

4.) การฝึกแบบจำลอง VGG-19 โดยใช้เทคนิคการเรียนรู้แบบถ่ายโอน การปรับแต่งโครงสร้างแบบจำลอง และ การเพิ่มขนาดของชุดข้อมูลภาพ มีความแม่นยำของแบบจำลองบนชุดทดสอบอยู่ที่ร้อยละ 95.64



รูปที่ 71 ผลลัพธ์ค่าความสูญเสีย และความแม่นยำระหว่างการฝึกของแบบจำลองแบบที่ 4

#### 4.2 ผลลัพธ์การทำงานของแบบจำลอง VGG-16 บนชุดข้อมูลของยุงในประเทศไทย

ทำการเตรียมชุดข้อมูลภาพยุงในประเทศไทยที่ได้ทำการเก็บภาพจากยุงตัวเมียที่เลี้ยงไว้ในห้องทดลอง และยุงที่ได้ทำการเก็บมาจากพื้นที่ต่าง ๆ ในประเทศไทยประกอบด้วยยุง 7 กลุ่ม ได้แก่ *Aedes aegypti* *Aedes albopictus* *Aedes vexans* *Culex Anopheles tessellatus* *quinquefasciatus* *Culex vishnui* และ *Culex brevipalis* โดยยุง *Culex aculaetus* เป็นยุงที่ไม่เป็นพาหะนำโรคจึงถูกจัดไว้ในกลุ่ม Others หลังจากทำการถ่ายภาพยุงจนได้ภาพทั้งหมด 4,590 ภาพ หลังจากนั้นนำชุดข้อมูลภาพที่ได้มาทำการตัดบริเวณรอบ ๆ ตัวยุง และทำการปรับขนาดภาพให้มีขนาด 512 x 512 พิกเซล และ นำชุดข้อมูลภาพที่ได้มาใช้เทคนิคการเพิ่มข้อมูลภาพ โดย

มีการใช้ฟังก์ชันซูม การหมุน การกลับด้าน การย่อ-ขยาย การเลื่อน การปรับค่าความสว่างและความคมชัด การเพิ่มสัญญาณรบกวนเกาส์ การปรับค่าสี การปรับค่าความอ้อมตัวของสี การปรับค่าความสว่างของสี และการปรับค่าแกมมา แสดงความเป็นเชิงเส้นและไม่เป็นเชิงเส้นของแต่ละฟังก์ชันดังตารางที่ 2 โดยกำหนดให้การทำงานของแต่ละฟังก์ชันมีความน่าจะเป็น 0.5 และทำการเพิ่มข้อมูลภาพเป็นจำนวนทั้งสิ้น 10 ครั้ง จากนั้นทำการรวมเข้ากับชุดข้อมูลภาพก่อนที่จะมาใช้เทคนิคเพิ่มข้อมูลภาพ จนได้ชุดข้อมูลที่มี 7 กลุ่ม มีขนาดของชุดข้อมูล 50,490 ภาพ




รูปที่ 72 ตัวอย่างชุดข้อมูลภาพ *Aedes aegypti* ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ



รูปที่ 73 ตัวอย่างชุดข้อมูลภาพ *Aedes aegypti* หลังได้รับการเพิ่มปริมาณข้อมูลภาพ



รูปที่ 74 ตัวอย่างชุดข้อมูลภาพ *Aedes albopictus* ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ



รูปที่ 75 ตัวอย่างชุดข้อมูลภาพ *Aedes albopictus* หลังได้รับการเพิ่มปริมาณข้อมูลภาพ




รูปที่ 76 ตัวอย่างชุดข้อมูลภาพ *Aedes vexans* ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ



รูปที่ 77 ตัวอย่างชุดข้อมูลภาพ *Aedes vexans* หลังได้รับการเพิ่มปริมาณข้อมูลภาพ





รูปที่ 78 ตัวอย่างชุดข้อมูลภาพ *Anopheles tessellatus* ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ




รูปที่ 79 ตัวอย่างชุดข้อมูลภาพ *Anopheles tessellatus* หลังได้รับการเพิ่มปริมาณข้อมูลภาพ



รูปที่ 80 ตัวอย่างชุดข้อมูลภาพ *Culex quinquefasciatus* ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ



รูปที่ 81 ตัวอย่างชุดข้อมูลภาพ *Culex quinquefasciatus* หลังได้รับการเพิ่มปริมาณข้อมูลภาพ




รูปที่ 82 ตัวอย่างชุดข้อมูลภาพ *Culex vishnui* ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ



รูปที่ 83 ตัวอย่างชุดข้อมูลภาพ *Culex vishnui* หลังได้รับการเพิ่มปริมาณข้อมูลภาพ



รูปที่ 84 ตัวอย่างชุดข้อมูลภาพ Others ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ



รูปที่ 85 ตัวอย่างชุดข้อมูลภาพ Others หลังได้รับการเพิ่มปริมาณข้อมูลภาพ

ฟังก์ชันที่ใช้ในการเพิ่มขนาดชุดข้อมูล	ความเป็นเชิงเส้น-ไม่เป็นเชิงเส้น
การหมุน	เชิงเส้น
การกลับด้าน	เชิงเส้น
การย่อ-ขยาย	เชิงเส้น
การเลื่อน	เชิงเส้น
การปรับค่าความสว่าง	ไม่เป็นเชิงเส้น
การปรับค่าความคมชัด	ไม่เป็นเชิงเส้น
การปรับค่าสี	ไม่เป็นเชิงเส้น
การปรับค่าความอึมตัวของสี	ไม่เป็นเชิงเส้น
การปรับค่าความสว่างของสี	ไม่เป็นเชิงเส้น
การปรับค่าแกมมา	ไม่เป็นเชิงเส้น
การเพิ่มสัญญาณรบกวนเกาส์	ไม่เป็นเชิงเส้น


ตารางที่ 2 ความเป็นเชิงเส้น-ไม่เป็นเชิงเส้นของฟังก์ชันที่ใช้เพิ่มขนาดชุดข้อมูลภาพ

นำชุดข้อมูลจากประเทศไทยที่ได้ทำการเพิ่มข้อมูลภาพมาทำการแบ่งเป็นชุดฝึกและทดสอบด้วยอัตราส่วน 0.8:0.2 มาทำการฝึกกับแบบจำลอง แบบจำลอง early-combined VGG-16, middle-combined VGG-16 และ late-combined VGG-16 ที่รับข้อมูลขาเข้า 2 ข้าง และ แบบจำลอง ensemble ซึ่งได้จากการนำผลลัพธ์ที่ได้จาก 3 แบบจำลอง ข้างต้นมาทำนายร่วมกันโดยเป็นแบบจำลองโครงข่ายประสาทเทียม ANN เป็นจำนวน 10 รอบ พบว่าได้ค่าความแม่นยำบนชุดทดสอบโดยเฉลี่ยร้อยละ 95.76 (1.462), 97.08 (1.242), 96.76 (1.684) และ 99.44 (0.324) ตามลำดับ แสดงในตารางที่ 3

Run	Accuracy (%)			
	Early	Middle	Late	Ensemble
1	94.86	96.00	93.82	99.25
2	95.17	95.79	96.68	99.78
3	96.53	98.19	98.19	99.51
4	96.31	97.50	93.97	99.03
5	92.69	96.11	97.09	99.51
6	97.30	97.96	97.71	99.33
7	94.75	94.89	95.57	99.36
8	95.96	98.06	97.70	99.88
9	95.73	97.32	97.80	98.88
10	98.30	98.99	99.10	99.88
Mean	95.76	97.08	96.76	99.44
SD	1.462	1.242	1.684	0.324


ตารางที่ 3 ค่าความแม่นยำของแบบจำลอง early-combined VGG-16 middle-combined VGG-16 late-combined VGG-16 และ แบบจำลอง ensemble บนชุดข้อมูลลงในประเทศไทย

1.) แบบจำลอง early-combined VGG-16 เป็นแบบจำลองโครงข่ายประสาทเทียม VGG-16 ที่มีการปรับแต่งให้รับข้อมูลขาเข้าได้ครั้งละ 2 โดยทำการรวมกันที่ด้านหลังบล็อกคอนโวลูชันที่ 1 ดังรูปที่ 86



รูปที่ 86 โครงสร้างแบบจำลอง early-combined VGG-16

การฝึกแบบจำลอง early-combined VGG-16 จะมีการใช้ชุดข้อมูลลงในประเทศไทยที่มีการทำการเพิ่มขนาดข้อมูลภาพไว้แล้วมาใช้ในการฝึก โดยในชั้น spatial dropout จะมีการสุ่มดรอปที่ค่าความน่าจะเป็น 0.2 และใช้ optimizer ADAM ในการปรับค่าพารามิเตอร์ระหว่างฝึก โดยกำหนด learning rate เริ่มต้นของการฝึกที่  $2e-5$  ลดลงด้วยอัตราคูณ 0.5 ทุก ๆ 10 epoch ของการฝึก โดยทำการฝึกทั้งสิ้น 40 epoch ได้ตัวอย่างผลลัพธ์ของการฝึก ตารางแสดงค่า confusion matrix ได้ค่าความแม่นยำบนชุดทดสอบที่ร้อยละ 96.73 และ ค่าความเที่ยงตรง (Precision) ค่าการเรียกคืน (Recall) และค่า F1 ของแต่ละคลาส ดังรูปที่ 87 88 และ 89 ตามลำดับ



รูปที่ 87 ผลลัพธ์การฝึกของแบบจำลอง early-combined VGG-16



#### Confusion Matrix

```

[[776 15 1 0 0 0 0]
 [ 6 687 0 0 0 0 0]
 [ 0 0 603 0 0 2 0]
 [ 2 0 2 556 0 1 0]
 [ 0 0 4 0 659 4 92]
 [ 0 0 6 1 0 652 1]
 [ 0 0 0 2 18 0 717]]


```

รูปที่ 88 confusion matrix ของแบบจำลอง early-combined VGG-16 บนชุดข้อมูลทดสอบ

Classification Report				
	precision	recall	f1-score	support
Aedes aegypti	0.99	0.98	0.98	792
Aedes albopictus	0.98	0.99	0.98	693
Aedes vexans	0.98	1.00	0.99	605
An tessellatus	0.99	0.99	0.99	561
Culex quinquefasciatus	0.97	0.87	0.92	759
Culex vishnui	0.99	0.99	0.99	660
Others	0.89	0.97	0.93	737
accuracy			0.97	4807
macro avg	0.97	0.97	0.97	4807
weighted avg	0.97	0.97	0.97	4807

รูปที่ 89 ค่าความเที่ยงตรง (Precision) ค่าการเรียกคืน (Recall) และค่า F1 ของแต่ละคลาสของชุดข้อมูลทดสอบ

2.) แบบจำลอง middle-combined VGG-16 เป็นแบบจำลองโครงข่ายประสาทเทียม VGG-16 ที่มีการปรับแต่งให้รับข้อมูลขาเข้าได้ครั้งละ 2 โดยทำการรวมกันที่ด้านหลังบล็อกคอนโวลูชันที่ 3 ดังรูปที่ 90

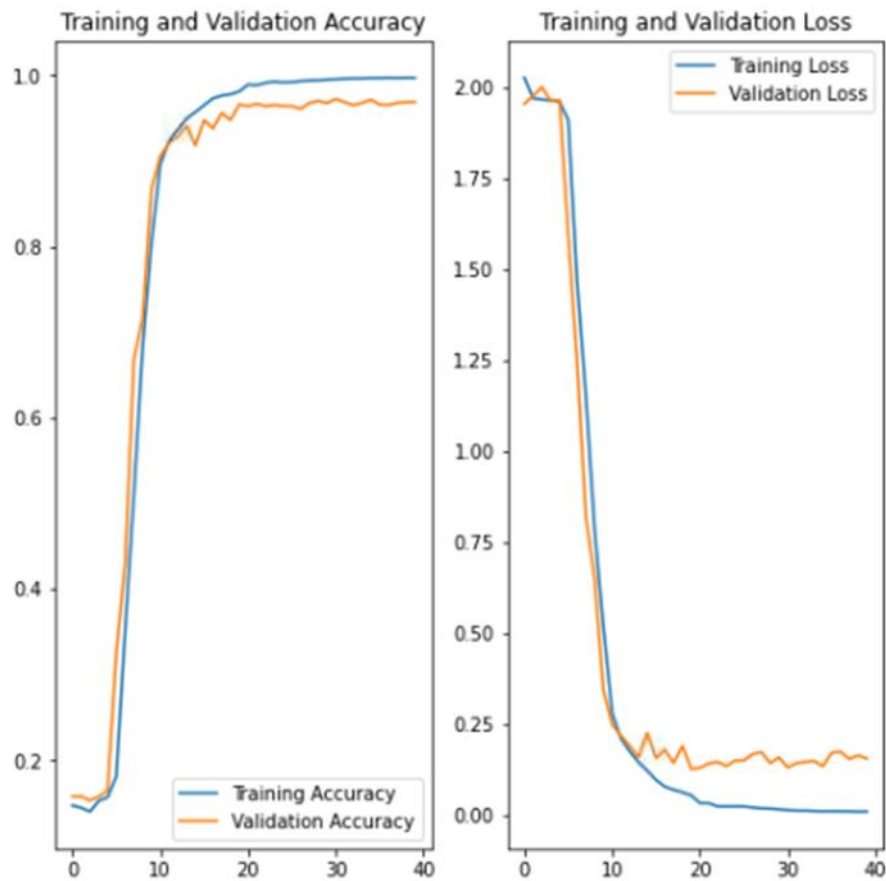


รูปที่ 90 โครงสร้างแบบจำลอง middle-combined VGG-16

การฝึกแบบจำลอง middle-combined VGG-16 จะมีการใช้ชุดข้อมูลลงในประเทศไทยที่มีการทำการเพิ่มขนาดข้อมูลภาพไว้แล้วมาใช้ในการฝึก โดยในชั้น spatial dropout จะมีการสุ่มดรอปที่ค่าความน่าจะเป็น 0.2 และใช้ optimizer ADAM ในการปรับค่าพารามิเตอร์ระหว่างฝึก โดยกำหนด learning rate เริ่มต้นของการฝึกที่  $2e-5$  ลดลงด้วยอัตราคูณ 0.5 ทุก ๆ 10 epoch ของการฝึก โดยทำการฝึกทั้งสิ้น 40 epoch ได้ตัวอย่างผลลัพธ์ของ



การฝึก ตารางแสดงค่า confusion matrix ได้ค่าความแม่นยำบนชุดทดสอบที่ร้อยละ 96.90 และ ค่าความเที่ยงตรง (Precision) ค่าการเรียกคืน (Recall) และค่า F1 ของแต่ละคลาส ดังรูปที่ 91 92 และ 93 ตามลำดับ



รูปที่ 91 ผลลัพธ์การฝึกของแบบจำลอง middle-combined VGG-16

CHULALONGKORN UNIVERSITY

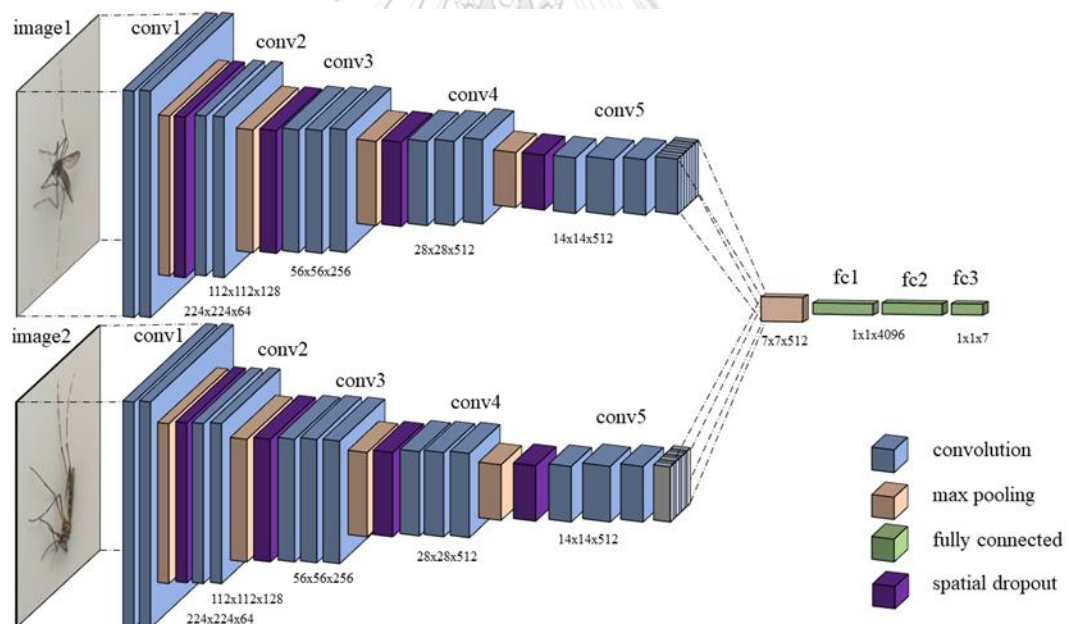
Confusion Matrix  
[[788 1 1 0 1 1 0]  
[ 17 676 0 0 0 0 0]  
[ 0 0 603 0 0 2 0]  
[ 0 0 0 561 0 0 0]  
[ 0 0 0 0 654 5 100]  
[ 1 0 7 2 1 649 0]  
[ 0 0 0 1 9 0 727]]

รูปที่ 92 confusion matrix ของแบบจำลอง middle-combined VGG-16 บนชุดข้อมูลทดสอบ

Classification Report				
	precision	recall	f1-score	support
Aedes aegypti	0.98	0.99	0.99	792
Aedes albopictus	1.00	0.98	0.99	693
Aedes vexans	0.99	1.00	0.99	605
An tessellatus	0.99	1.00	1.00	561
Culex quinquefasciatus	0.98	0.86	0.92	759
Culex vishnui	0.99	0.98	0.99	660
Others	0.88	0.99	0.93	737
accuracy			0.97	4807
macro avg	0.97	0.97	0.97	4807
weighted avg	0.97	0.97	0.97	4807

รูปที่ 93 ค่าความเที่ยงตรง (Precision) ค่าการเรียกคืน (Recall) และค่า F1 ของแต่ละคลาสของชุดข้อมูลทดสอบ


3.) แบบจำลอง late-combined VGG-16 เป็นแบบจำลองโครงข่ายประสาทเทียม VGG-16 ที่มีการปรับแต่งให้รับข้อมูลขาเข้าได้ครั้งละ 2 โดยทำการรวมกันที่ด้านหลังบล็อกคอนโวลูชันที่ 5 ดังรูปที่ 94



รูปที่ 94 โครงสร้างแบบจำลอง late-combined VGG-16

การฝึกแบบจำลอง late-combined VGG-16 จะมีการใช้ชุดข้อมูลลงในประเทศไทยที่มีการทำการเพิ่มขนาดข้อมูลภาพไว้แล้วมาในใช้การฝึก โดยในชั้น spatial dropout จะมีการสุ่มดรอปที่ค่าความน่าจะเป็น 0.2 และใช้ optimizer ADAM ในการปรับค่าพารามิเตอร์ระหว่างฝึก โดยกำหนด learning rate เริ่มต้นของการฝึกที่  $2e-5$  ลดลงด้วยอัตราคูณ 0.5 ทุก ๆ 10 epoch ของการฝึก โดยทำการฝึกทั้งสิ้น 40 epoch ได้ตัวอย่างผลลัพธ์ของการ

ฝึก ตารางแสดงค่า confusion matrix ได้ค่าความแม่นยำบนชุดทดสอบที่ร้อยละ 97.69 และ ค่าความเที่ยงตรง (Precision) ค่าการเรียกคืน (Recall) และค่า F1 ของแต่ละคลาส ดังรูปที่ 95 96 และ 97 ตามลำดับ



รูปที่ 95 ผลลัพธ์การฝึกของแบบจำลอง late-combined VGG-16

CHULALONGKORN UNIVERSITY

Confusion Matrix

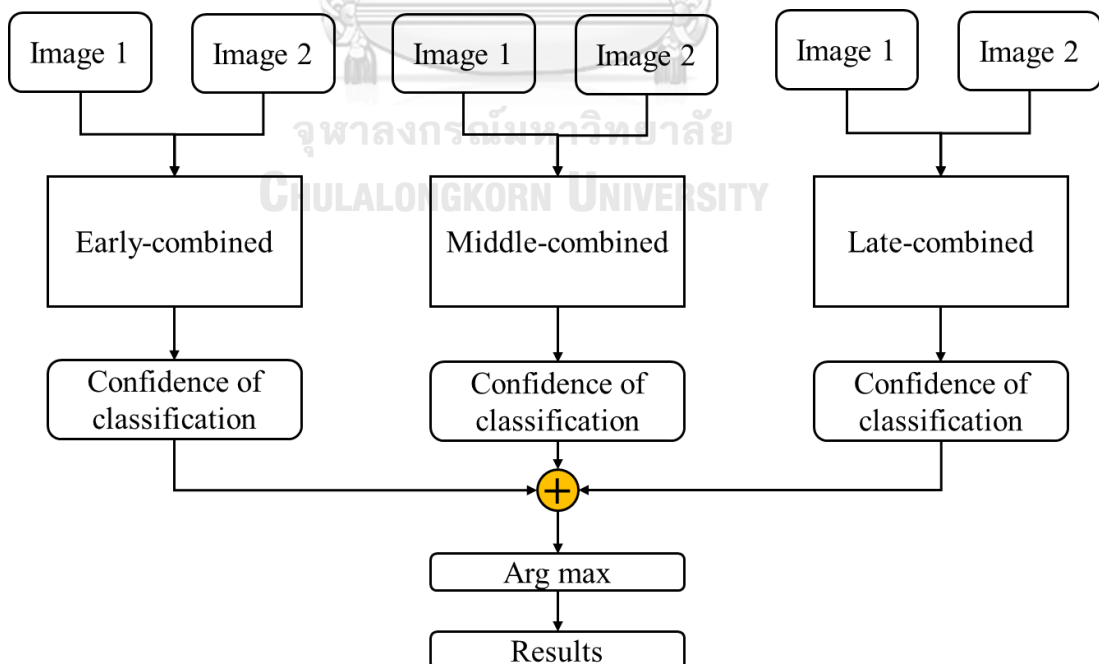
```
[[787  5  0  0  0  0  0]
 [  5 688  0  0  0  0  0]
 [  0  0 605  0  0  0  0]
 [  1  0  0 559  0  1  0]
 [  0  0  2  0 664  0 93]
 [  0  0  3  0  0 657  0]
 [  0  0  0  0  1  0 736]]
```

รูปที่ 96 confusion matrix ของแบบจำลอง late-combined VGG-16 บนชุดข้อมูลทดสอบ

Classification Report				
	precision	recall	f1-score	support
Aedes aegypti	0.99	0.99	0.99	792
Aedes albopictus	0.99	0.99	0.99	693
Aedes vexans	0.99	1.00	1.00	605
An tessellatus	1.00	1.00	1.00	561
Culex quinquefasciatus	1.00	0.87	0.93	759
Culex vishnui	1.00	1.00	1.00	660
Others	0.89	1.00	0.94	737
accuracy			0.98	4807
macro avg	0.98	0.98	0.98	4807
weighted avg	0.98	0.98	0.98	4807

รูปที่ 97 ค่าความเที่ยงตรง (Precision) ค่าการเรียกคืน (Recall) และค่า F1 ของแต่ละคลาสของชุดข้อมูลทดสอบ

4.) การทำนายผลโดยใช้แบบจำลองทั้ง 3 แบบจำลองในการร่วมกันทำนายผล ใช้หลักการนำผลลัพธ์ความมั่นใจของยุงแต่ละชนิดที่ได้จากแบบจำลองทั้งสาม มาทำการบวกเข้าด้วยกันและทำการเลือกค่าความมั่นใจของชนิดยุงที่มีความมากที่สุดมาเป็นคำตอบของการทำนาย กระบวนการการทำงานของการทำนายผลโดยใช้การบวกค่าผลลัพธ์ความมั่นใจของแบบจำลองทั้งสาม ตารางแสดงค่า confusion matrix ได้ค่าความแม่นยำบนชุดทดสอบที่ร้อยละ 97.84 และ ค่าความเที่ยงตรง (Precision) ค่าการเรียกคืน (Recall) และค่า F1 ของแต่ละคลาส ดังรูปที่ 98 และ 100 ตามลำดับ



รูปที่ 98 กระบวนการการทำงานของการทำนายผลโดยใช้การบวกผลลัพธ์ค่าความมั่นใจของแบบจำลองทั้งสามแบบ

```

Confusion Matrix
[[790  2  0  0  0  0  0]
 [  4 689  0  0  0  0  0]
 [  0  0 604  0  0  1  0]
 [  1  0  0 560  0  0  0]
 [  0  0  0  0 667  0 92]
 [  0  0  1  0  0 659  0]
 [  0  0  0  0  3  0 734]]

```

รูปที่ 99 confusion matrix ของการทำนายผลโดยใช้แบบจำลองทั้งสามแบบในการร่วมกันทำนายผล

```

Classification Report
              precision    recall  f1-score   support


 Aedes aegypti         0.99      1.00      1.00       792
 Aedes albopictus       1.00      0.99      1.00       693
 Aedes vexans           1.00      1.00      1.00       605
 An tessellatus         1.00      1.00      1.00       561
 Culex quinquefasciatus 1.00      0.88      0.93       759
 Culex vishnui          1.00      1.00      1.00       660
 Others                 0.89      1.00      0.94       737

 accuracy              0.98
 macro avg             0.98
 weighted avg          0.98

```

รูปที่ 100 ค่าความเที่ยงตรง (Precision) ค่าการเรียกคืน (Recall) และค่า F1 ของแต่ละคลาสของชุดข้อมูลทดสอบ


5.) การทำนายผลโดยใช้แบบจำลอง ANN ในการทำนายผลที่ใช้ชุดความมั่นใจที่เป็นผลลัพธ์ของแบบจำลองทั้งสามเป็นข้อมูลขาเข้าของแบบจำลอง โดยมีค่าความแม่นยำของแบบจำลองอยู่ที่ร้อยละ 99.88 ตัวอย่างผลการทำงานการทำนายผลโดยใช้แบบจำลอง ANN แสดงดังรูปที่ 101



รูปที่ 101 ตัวอย่างผลการทำงานการทำนายผลร่วมกันโดยใช้แบบจำลอง ANN

#### 4.3 การจำแนกยูงจากภาพอัตโนมัติผ่าน LINE API

นำแบบจำลองที่ได้ปรับปรุงให้มีการรับภาพได้พร้อมกันทีละ 2 ภาพ พร้อมทั้งแบบจำลอง ANN ที่ใช้ผลลัพธ์จากแบบจำลองทั้ง 3 ได้แก่ early-combined middle-combined และ late-combined VGG-16 มาใช้เป็นตัวทำนายผลภาพยูงที่ได้รับมาจากผู้ใช้ที่ทำการส่งเข้ามาในระบบผ่านทางแอปพลิเคชัน LINE โดยให้ผู้ใช้งานได้ส่งภาพยูงเข้ามา 3 ภาพ พร้อมทั้งส่งโลเคชันเข้ามาด้วย และจำได้รับผลลัพธ์ตอบกลับผ่านทางแอปพลิเคชันไลน์ เป็นชนิดของยูง กระบวนการทำงานของระบบจำแนกยูงจากภาพผ่านทางมีการบวนการแสดงดังรูปที่ 102




รูปที่ 102 กระบวนการทำงานของระบบจำแนกยูงอัตโนมัติผ่าน LINE API

การทำงานจะเริ่มต้นให้ผู้ใช้ทำการเป็นเพื่อนกับบอทผ่านทางแอปพลิเคชันไลน์ หลังจากนั้นเมื่อผู้ใช้ส่งภาพเข้ามา ระบบจะทำการล๊อคไม่รับภาพจากผู้ใช้คนอื่น เพื่อรอให้ผู้ใช้คนปัจจุบันทำการส่งภาพยุงจำนวนทั้งสิ้น 3 ภาพ พร้อมทั้งโลเคชันของผู้ใช้จนกระทั่งได้รับผลตอบกลับหลังจากนั้นจึงทำการปลดล๊อคเพื่อให้สามารถรับภาพจากผู้ใช้คนอื่นเข้าสู่ระบบได้


เมื่อระบบได้รับภาพที่ถูกส่งโดยผู้ใช้งานผ่านทาง LINE API จะทำการล๊อคการรับภาพสำหรับผู้ใช้งานคนปัจจุบันที่ได้ส่งภาพเข้ามา หลังจากนั้นภาพที่รับเข้ามาจะถูกนำเข้าไปที่แบบจำลอง YOLO v5 ซึ่งแบบจำลอง YOLO v5 นี้ได้ถูกฝึกขึ้นบนชุดข้อมูลบางส่วนจากข้อมูลที่ใช้ในการฝึกแบบจำลอง VGG-16 แต่จะเป็นการฝึกแยกกระหว่างกลุ่มที่เป็นยุงนำโรคและยุงที่ไม่เป็นพาหะเพื่อนำมาใช้ในการหาขุมที่อยู่ในภาพในขั้นเบื้องต้น และทำการครอบตัดบริเวณรอบ ๆ ตัวยุงให้มีขนาด 512x512 พิกเซล ในกรณีที่แบบจำลองไม่สามารถหาตัวยุงในภาพได้จะทำการส่งข้อความเพื่อให้ผู้ใช้งานคนปัจจุบันทำการส่งภาพเข้ามาใหม่อีกครั้ง หลังจากที่แบบจำลอง YOLO v5 หาตัวยุงเจอและทำการครอบตัดรอบ ๆ ตัวยุง จะทำการตรวจสอบความคมชัดของภาพ ถ้าภาพที่ได้มีความคมชัดต่ำจนเกินไปจะส่งข้อความตอบกลับให้ผู้ใช้งานส่งภาพเข้ามาใหม่อีกครั้ง เมื่อภาพผ่านการตรวจสอบความคมชัดแล้วจะทำการบันทึกภาพและให้ผู้ใช้งานทำการส่งภาพจนครบ 3 ภาพ เมื่อระบบได้ภาพทั้ง 3 ภาพ เป็นที่เรียบร้อยแล้วจะทำการส่งข้อความไปถึงผู้ใช้เพื่อให้ผู้ใช้ทำการส่งโลเคชันปัจจุบันของผู้ใช้งานเข้ามาในระบบผ่านทางไลน์ หลังจากนั้นจะทำการนำภาพทั้ง 3 ภาพ ไปเข้าสู่แบบจำลอง VGG-16 ทั้งสามแบบจำลองซึ่งรับได้ครั้งละ 2 ภาพ ซึ่งภาพที่ได้รับจากผู้ใช้งานทั้ง 3 ภาพ จะถูกนำมาจับคู่ด้วยการเรียงสับเปลี่ยน (Permutation) จนได้ทั้งหมด 6 รูปแบบ ส่งผลให้แต่ละแบบจำลองจะมีการรับข้อมูลที่สิ้น 6 คู่ ได้เป็นผลลัพธ์ชุดความมั่นใจทั้งสิ้น 18 ชุด ก่อนที่จะส่งต่อไปให้แบบจำลอง ANN เพื่อใช้ในการทำนายผลขั้นตอนสุดท้าย เมื่อได้ผลลัพธ์จากแบบจำลอง ANN จะทำการส่งผลลัพธ์เป็นชนิดของยุงที่ได้กลับไปยังผู้ใช้งานคนปัจจุบัน และทำการบันทึกภาพทั้งสามเก็บไว้ในฐานข้อมูลสำหรับการนำไปใช้ต่อไปในอนาคต

#### 4.4 การใช้งานผ่านแอปพลิเคชันไลน์

ผู้ใช้งานสามารถเพิ่มเพื่อนไลน์ Official Account ที่มีชื่อว่า Mosquito Species แสดงดังรูปที่ 103 เมื่อทำการเพิ่มเพื่อนแล้วจะทำการส่งข้อความผ่านทางไลน์ Mosquito Species ได้ ถ้าผู้ใช้ทำการส่งข้อความที่ไม่ใช่รูปภาพจะมีข้อความเตือนขึ้นมาว่าให้ส่งรูปภาพเข้ามาแสดงดังรูปที่ 104 ในกรณีที่ผู้ใช้งานทำการส่งรูปภาพที่ไม่ใช่ยุงระบบจะทำการตอบกลับว่าไม่พบยุงในภาพและให้ทำการส่งรูปภาพเข้ามาใหม่อีกครั้งดังรูปที่ 105 ถ้าหากผู้ใช้ทำการส่งรูปภาพที่แบบจำลองพบว่ามียุงแต่มีค่าความคมชัดที่ไม่มากเพียงพอจะทำการส่งข้อความตอบกลับมาให้ผู้ใช้งานว่ารูปภาพไม่คมชัดและให้ทำการถ่ายใหม่อีกครั้งดังรูปที่ 106 เมื่อผู้ใช้ทำการส่งรูปยุงที่ผ่านการตรวจสอบค่าความคมชัดจะทำการส่งข้อความให้ผู้ใช้งานส่งรูปภาพเพิ่มจนครบ 3 ภาพ เมื่อได้ภาพครบ 3 ภาพ ระบบจำให้ผู้ใช้ทำการส่งสถานที่ ณ ปัจจุบันของผู้ใช้งานเข้ามา หลังจากนั้นระบบจะทำการส่งข้อความตอบกลับเป็นชนิดของยุงที่ระบบจำแนกได้ดังรูปที่ 107 108 และ 109



CU Mosquito Classification



Country or region: Thailand

รูปที่ 103 ไลน์ Official Account สำหรับการจำแนกยุง




Read  
1:43 PM hi



Please submit only three jpeg photos of a mosquito subject, one-by-one; and share your location. Each photo should contain a mosquito image on a white or plain background.


1:43 PM



1:43 PM

Save | Save as... | Share | Keep

รูปที่ 104 ข้อความตอบกลับเมื่อผู้ใช้ทำการส่งข้อความที่ไม่ใช่รูปภาพ



Read  
2:24 PM

Save | Save as... | Share | Keep




No mosquito is found in your photo, retake once more.

2:24 PM


รูปที่ 105 ข้อความตอบกลับเมื่อผู้ใช้ทำการส่งข้อความที่เป็นรูปภาพที่ไม่ใช่ยุง




 This photo appears to be blurry, retake once more. 2:28 PM

รูปที่ 106 ข้อความตอบกลับเมื่อผู้ใช้ทำการส่งภาพยุงเข้ามาแต่ไม่ผ่านเกณฑ์การตรวจสอบค่าความคมชัด



 First photo is well received. Please send the second photo within 2 minutes. 1:52 PM

รูปที่ 107 ข้อความตอบกลับเมื่อผู้ใช้ทำการส่งภาพยุงภาพที่ 1



Read  
1:52 PM

Save | Save as... | Share | Keep



Second photo is well received. Please send the last photo within 2 minutes.

1:52 PM

รูปที่ 108 ข้อความตอบกลับเมื่อผู้ใช้ทำการส่งภาพที่ 2



Read  
1:52 PM

Save | Save as... | Share | Keep



Third and last photo is well received. Please share your location within 2 minutes.

1:52 PM

Read  
1:53 PM

▶ 5, 83 Soi Baring 58, Tambon Sam Rong Nua, Amphoe Mueang Samut Prakan, Chang Wat Samut Prakan 10270, Thailand

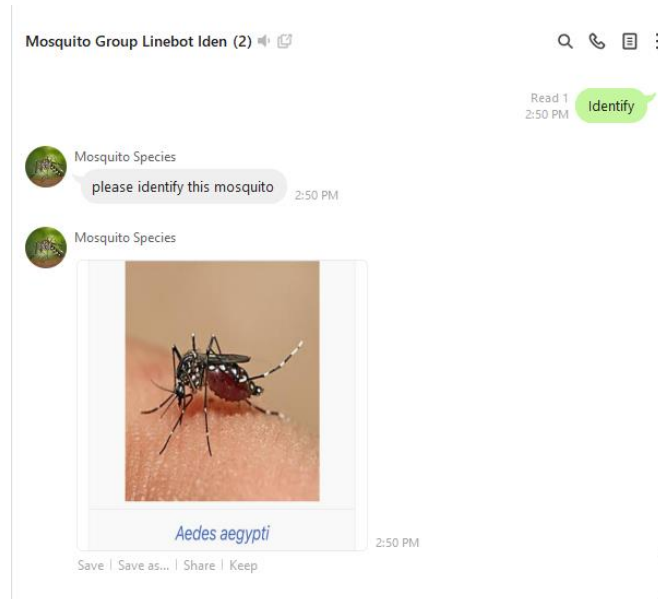


Result: species of your mosquito is *Ae-albopictus*.


1:53 PM

รูปที่ 109 ข้อความตอบกลับเมื่อผู้ใช้ทำการส่งภาพที่ 3 และสถานที่เข้าสู่ระบบ และข้อความตอบกลับเป็นชนิดยุง

นอกจากนี้ผู้เชี่ยวชาญสามารถทำนายผลโดยการส่งข้อความตัวอักษร “Identify” ผ่านทางไลน์กลุ่มที่ได้มีการกำหนดไว้ เมื่อผู้เชี่ยวชาญทำการส่งข้อความตัวอักษร “Identify” ระบบจะทำการตอบกลับโดยส่งข้อความตัวอักษรและข้อความภาพเพื่อให้ผู้เชี่ยวชาญได้ทำการส่งข้อความผลลัพธ์ตอบกลับไประบบ และเมื่อระบบได้รับผลลัพธ์ที่ส่งกลับเข้ามาโดยผู้เชี่ยวชาญจะทำการส่งข้อความกลับไปหาผู้เชี่ยวชาญให้ทราบว่าได้ทำการบันทึกผลลัพธ์เรียบร้อยแล้ว แสดงตัวอย่างดังรูปที่ 110 และ 111 ตามลำดับ



รูปที่ 110 ผู้เชี่ยวชาญส่งคีย์เวิร์ด ‘Identify’ ผ่านไลน์



รูปที่ 111 ผู้เชี่ยวชาญส่งข้อความตัวอักษรชนิดของยุง

## บทที่ 5 บทสรุปงานวิจัย

### 5.1 สรุปผลงานวิจัย

จากผลลัพธ์ของแบบจำลอง VGG-16 และ VGG-19 ในบทที่ 4 จะเห็นได้ว่าเมื่อไม่มีการใช้กลวิธีการเรียนรู้แบบถ่ายโอน และการเพิ่มปริมาณชุดข้อมูล ดังรูปที่ 64 และ รูปที่ 68 จะเห็นได้ว่าแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ได้รับการฝึกแล้วมีค่าความแม่นยำบนชุดทดสอบอยู่ที่ร้อยละ 43.85 และ 40.98 ตามลำดับ นอกจากนี้ค่าความสูญเสียที่ลดลงและเพิ่มสูงขึ้นอีกครั้งเมื่อจำนวน epoch เพิ่มขึ้น และความแม่นยำบนชุดตรวจสอบมีค่าที่แตกต่างจากความแม่นยำบนชุดฝึกมาก เพราะแบบจำลองโครงข่ายประสาทเทียมได้เรียนรู้จากข้อมูลฝึกมากเกินไป (Overfitting) จนทำให้เมื่อเจอสิ่งต่างจากที่เรียนรู้มาแม้จะเพียงไม่มากก็ไม่สามารถจำแนกได้ดี อีกทั้งจำนวนข้อมูลที่ใช้ฝึกมีจำนวนไม่มากพอสำหรับแบบจำลองที่มีจำนวนชั้นหลายชั้น อีกทั้งยังไม่มีการเรียนรู้แบบถ่ายโอนที่จึงทำให้แบบจำลองที่มีจำนวนชุดข้อมูลสำหรับการฝึกน้อยไม่มีเสถียรภาพในการทำงาน เพราะการเรียนรู้แบบถ่ายโอนสามารถช่วยให้แบบจำลองเรียนรู้คุณลักษณะเฉพาะระดับต่ำ เช่น มุม ขอบ โค้ง เป็นต้น

การเพิ่มขนาดของชุดข้อมูลภาพได้มีการใช้ฟังก์ชันที่มีความเป็นเชิงเส้นและไม่เป็นเชิงเส้นดังตารางที่ 2 เข้าร่วมกันเพราะการใช้ฟังก์ชันที่มีความเป็นเชิงเส้นและไม่เป็นเชิงเส้นร่วมกันจะทำให้ได้ชุดข้อมูลใหม่ถูกสร้างขึ้นมา มีความสัมพันธ์กันกับรูปต้นฉบับน้อยกว่าการใช้ฟังก์ชันที่มีความเป็นเชิงเส้นหรือไม่เป็นเชิงเส้นเพียงชนิดเดียว ทำให้เสมือนว่าได้ภาพที่เพิ่มขึ้นมาใหม่จริง ๆ ทำให้แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันเรียนรู้ปรับค่าพารามิเตอร์ในระหว่างการฝึกได้ดียิ่งขึ้น และสามารถทำนายผลของภาพที่อาจจะได้รับเข้ามาใหม่ดีขึ้นกว่าการชุดข้อมูลที่มีการเพิ่มขนาดของชุดข้อมูลภาพด้วยฟังก์ชันที่มีความเป็นเชิงเส้นหรือไม่เป็นเชิงเส้นอย่างใดอย่างหนึ่งเพียงอย่างเดียว

จากผลลัพธ์การทำงานของแบบจำลอง VGG-16 และ VGG-19 ในบทที่ 4 เมื่อใช้กลวิธีการเรียนรู้แบบถ่ายโอนร่วมกับสัญญาณตกหายเชิงพื้นที่ ส่งผลให้แบบจำลองโครงข่ายประสาทเทียมไม่เรียนรู้เฉพาะข้อมูลบนชุดฝึกมากเกินไป (Overfitting) รวมไปถึงมีการถ่ายโอนความรู้ของคุณลักษณะระดับต่ำที่ได้จาก ImageNet และความหลากหลายของข้อมูลฝึกที่ได้จากการเพิ่มจำนวนข้อมูล ทำให้ค่าความสูญเสียมีค่าลดลงและเมื่อทดสอบประสิทธิภาพการทำงานบนชุดทดสอบ สามารถประเมินค่าความแม่นยำได้มากถึงร้อยละ 96.35 สำหรับแบบจำลอง VGG-16 และ ร้อยละ 95.64 สำหรับแบบจำลอง VGG-19

แบบจำลอง VGG-16 ที่ได้มาการปรับปรุงให้มีการรับภาพได้สองภาพ 3 แบบจำลองได้แก่ early-combined VGG-16 middle-combined VGG-16 และ late-combined VGG-16 และนำมาฝึกบนชุดข้อมูลใหม่ ซึ่งเป็นยู่งในประเทศไทยที่ถ่ายด้วยโทรศัพท์มือถือ พบว่าได้ค่าความแม่นยำบนชุดทดสอบโดยเฉลี่ยร้อยละ 95.76 (1.462) 97.08 (1.242) และ 96.76 (1.684) ตามลำดับ เห็นได้ว่าถึงแม้ชุดข้อมูลใหม่ที่มีจำนวนคลาสมากกว่าชุดข้อมูลยู่งในประเทศเกาหลี และ ถ่ายโดยกล้องโทรศัพท์มือถือ แบบจำลองยังสามารถจำแนกประเภทของยู่งได้มีความถูกต้องโดยเฉลี่ย ไม่ต่ำกว่าร้อยละ 95.76 ซึ่งถือว่ามีประสิทธิภาพการทำงานที่สูงบนชุดข้อมูลทดสอบ จากผลทดสอบการทำงานบนชุดข้อมูลทดสอบนี้จะเห็นได้ว่าแบบจำลองแบบจำลองเหล่านี้มีความสามารถมากพอที่จะ

นำไปประยุกต์ใช้สำหรับการจำแนกสายพันธุ์งูในไทยแบบอัตโนมัติได้ ยิ่งไปกว่านั้นการนำแบบจำลองทั้งสามมาทำการร่วมกันทำนายผลโดยใช้แบบจำลอง ANN สามารถเพิ่มความแม่นยำบนชุดทดสอบให้มีความแม่นยำได้สูงถึงร้อยละ 99.44 (0.324) โดยเฉลี่ย แต่การใช้งานแบบจำลองทั้งสามแบบมาทำงานร่วมกันพร้อมทั้งใช้แบบจำลอง ANN เป็นตัวจำแนกสุดท้ายมีการใช้ทรัพยากรที่สูงดังนั้นการนำไปประยุกต์ใช้ต้องมีการเลือกฮาร์ดแวร์สำหรับการประมวลผลให้เหมาะสมระบบจึงจะมีการทำงานได้อย่างมีประสิทธิภาพและไม่เกิดปัญหาในช่วงการประมวลผลข้อมูล

การประยุกต์ใช้แบบจำลองที่ได้ทำการพัฒนาสำหรับการจำแนกงูโดยให้ผู้ใช้ส่งภาพและสถานที่ของผู้ใช้ผ่านทางไลน์แอปพลิเคชันทำให้ผู้ใช้งานสามารถใช้บริการจำแนกงูได้อย่างสะดวกโดยสามารถส่งรูปเข้ามาทางมือถือ แท็บเล็ต และคอมพิวเตอร์ แต่ว่าการส่งสถานที่ของผู้ใช้จะไม่สามารถส่งจากคอมพิวเตอร์ได้ถ้าผู้ใช้มีความต้องการที่จะส่งรูปจากคอมพิวเตอร์เข้ามาที่ระบบผ่านทางแอปพลิเคชันไลน์จำเป็นต้องมีการใช้อุปกรณ์อื่นที่เป็นแอดเดคท์เดียวกันที่สามารถส่งสถานที่ได้ เช่น โทรศัพท์มือถือ หรือแท็บเล็ต

ถึงแม้แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันจะมีความแม่นยำสูงบนชุดข้อมูลทดสอบ แต่ยังคงต้องการข้อมูลเพิ่มเติมเรื่อย ๆ เพื่อใช้ในการฝึกใหม่ (Retraining) เพื่อให้ได้แบบจำลองที่มีความคงทนต่อข้อมูลขาเข้าที่อาจมีความแตกต่างไปจากสิ่งที่แบบจำลองได้เคยเรียนรู้มา เช่น ข้อมูลใหม่มีการค่าความสว่าง สีของพื้นหลัง รวมถึงสัญญาณรบกวนที่ต่างไปจากสิ่งที่เคยเรียนรู้มามากอาจส่งผลให้แบบจำลองทำนายผลคลาดเคลื่อนผิดไปจากที่ควรจะเป็น

## 5.2 แนวทางการพัฒนางานวิจัย

แบบจำลอง VGG-16 ที่มีการนำไปใช้งานต้องมีการเก็บข้อมูลเพิ่มเติมเพื่อนำมาใช้ในการฝึกใหม่ (Retraining) อยู่เรื่อย ๆ เพื่อให้แบบจำลองได้เรียนรู้รูปที่ไม่เคยเห็นมาก่อน เพื่อให้แบบจำลองทำงานได้ถูกต้องแม่นยำมากขึ้น เนื่องจากในการใช้งานจริงรูปถ่ายที่ได้รับมาอาจจะมีลักษณะท่าทางของงู รวมถึงลักษณะตัวงูที่อาจมีความแตกต่างกันไปในแต่ละถิ่นที่อยู่อาศัย

แบบจำลอง YOLO v5 ที่นำมาใช้เป็นตัวตรวจจับงูในรูปก่อนที่จะนำไปให้แบบจำลอง VGG-16 ทำนายผลจำเป็นต้องมีการนำข้อมูลที่มากขึ้นเพื่อนำมาฝึกเพิ่ม เช่น ชุดข้อมูลภาพงูที่หลากหลายขึ้น ชุดข้อมูลของแมลงชนิดอื่น ๆ ที่มีลักษณะที่มีความคล้ายเคียงกับงู เพื่อที่จะให้แบบจำลองสามารถค้นหางูในภาพได้อย่างถูกต้องแม่นยำมากขึ้น



จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**



จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**



## บรรณานุกรม

- [1] Department of Disease Control. "สถานการณ์โรคไข้เลือดออก สัปดาห์ที่ 50 ปี 2562." <http://odpc3.ddc.moph.go.th/> (accessed April 28, 2021).
- [2] Department of Disease Control. "Thailand Malaria Elimination Program." [http://malaria.ddc.moph.go.th/malariaR10/index\\_newversion.php#](http://malaria.ddc.moph.go.th/malariaR10/index_newversion.php#) (accessed April 28, 2021).
- [3] สุวรรณชัย วัฒนายิ่งเจริญชัย. "พยากรณ์โรคและภัยสุขภาพรายสัปดาห์ ฉบับที่ 274 ประจำสัปดาห์ที่ 32 (วันที่ 9 - 15 ส.ค. 63)." [https://ddc.moph.go.th/brc/news.php?news=14160&deptcode=brc&news\\_views=3332](https://ddc.moph.go.th/brc/news.php?news=14160&deptcode=brc&news_views=3332) (accessed April 28, 2021).
- [4] World Health Organization. "Dengue and severe dengue." <https://www.who.int/news-room/fact-sheets/detail/dengue-and-severe-dengue> (accessed April 28, 2021).
- [5] World Health Organization. "Malaria." <https://www.who.int/news-room/fact-sheets/detail/malaria> (accessed April 28, 2021).
- [6] E. Fanioudakis, M. Geismar, and I. Potamitis, "Mosquito wingbeat analysis and classification using deep learning," in *2018 26th European Signal Processing Conference (EUSIPCO)*, 2018: IEEE, pp. 2410-2414.
- [7] G. Wang *et al.*, "Identifying the main mosquito species in China based on DNA barcoding," *PLoS one*, vol. 7, no. 10, p. e47051, 2012.
- [8] J. Park, D. I. Kim, B. Choi, W. Kang, and H. W. Kwon, "Classification and morphological analysis of vector mosquitoes using deep convolutional neural networks," *Scientific reports*, vol. 10, no. 1, pp. 1-12, 2020.
- [9] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, pp. 1097-1105, 2012.
- [10] X. Kang, B. Song, and F. Sun, "A deep similarity metric method based on incomplete data for traffic anomaly detection in IoT," *Applied Sciences*, vol. 9, no. 1, p. 135, 2019.
- [11] Y. LeCun, "LeNet-5, convolutional neural networks," URL: <http://yann.lecun>.

- com/exdb/lenet*, vol. 20, no. 5, p. 14, 2015.
- [12] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, 1998, doi: 10.1109/5.726791.
- [13] C. Szegedy *et al.*, "Going deeper with convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1-9.
- [14] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [15] M. Loukadakis, J. Cano, and M. O'Boyle, "Accelerating deep neural networks on low power heterogeneous architectures," 2018.
- [16] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770-778.
- [17] H. Choi, S. Ryu, and H. Kim, "Short-term load forecasting based on ResNet and LSTM," in *2018 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm)*, 2018: IEEE, pp. 1-6.
- [18] N. Gratz, "Critical review of the vector status of *Aedes albopictus*," *Medical and veterinary entomology*, vol. 18, no. 3, pp. 215-227, 2004.
- [19] A. Gendernalik *et al.*, "American *Aedes vexans* mosquitoes are competent vectors of Zika virus," *The American journal of tropical medicine and hygiene*, vol. 96, no. 6, pp. 1338-1340, 2017.
- [20] H.-I. Ree, "Studies on *Anopheles sinensis*, the vector species of vivax malaria in Korea," *The Korean Journal of Parasitology*, vol. 43, no. 3, p. 75, 2005.
- [21] D. M. Fonseca *et al.*, "Emerging vectors in the *Culex pipiens* complex," *Science*, vol. 303, no. 5663, pp. 1535-1538, 2004.
- [22] L. Self, H. Shin, K. Kim, K. Lee, C. Chow, and H. Hong, "Ecological studies on *Culex tritaeniorhynchus* as a vector of Japanese encephalitis," *Bulletin of the World Health Organization*, vol. 49, no. 1, p. 41, 1973.
- [23] M. A. Tolle, "Mosquito-borne diseases," *Current problems in pediatric and adolescent health care*, vol. 39, no. 4, pp. 97-140, 2009.
- [24] P. Reiter, "Climate change and mosquito-borne disease," *Environmental health*

- perspectives*, vol. 109, no. suppl 1, pp. 141-161, 2001.
- [25] World Health Organization. "Yellow fever." <https://www.who.int/news-room/fact-sheets/detail/yellow-fever> (accessed April 28, 2021).
- [26] World Health Organization. "Japanese encephalitis." <https://www.who.int/news-room/fact-sheets/detail/japanese-encephalitis> (accessed April 28, 2021).
- [27] World Health Organization. "West Nile virus." <https://www.who.int/news-room/fact-sheets/detail/west-nile-virus> (accessed April 28, 2021).
- [28] World Health Organization. "Chikungunya." [https://www.who.int/health-topics/chikungunya#tab=tab\\_1](https://www.who.int/health-topics/chikungunya#tab=tab_1) (accessed April 28, 2021).
- [29] World Health Organization. "Lymphatic filariasis." <https://www.who.int/news-room/fact-sheets/detail/lymphatic-filariasis> (accessed April 28, 2021).
- [30] K. Okayasu, K. Yoshida, M. Fuchida, and A. Nakamura, "Vision-Based Classification of Mosquito Species: Comparison of Conventional and Deep Learning Methods," *Applied Sciences*, vol. 9, no. 18, p. 3935, 2019.
- [31] D. Motta *et al.*, "Application of convolutional neural networks for classification of adult mosquitoes in the field," *PloS one*, vol. 14, no. 1, p. e0210829, 2019.
- [32] A. S. Ortiz, M. N. Miyatake, H. Tünnermann, T. Teramoto, and H. Shouno, "Mosquito Larva Classification based on a Convolution Neural Network," in *Proceedings of the International Conference on Parallel and Distributed Processing Techniques and Applications (PDPTA)*, 2018: The Steering Committee of The World Congress in Computer Science, Computer ..., pp. 320-325.
- [33] T.-H. Ouyang, E.-C. Yang, J.-A. Jiang, and T.-T. Lin, "Mosquito vector monitoring system based on optical wingbeat classification," *Computers and Electronics in Agriculture*, vol. 118, pp. 47-55, 2015.
- [34] C. Lorenz, A. S. Ferraudo, and L. Suesdek, "Artificial Neural Network applied as a methodology of mosquito species identification," *Acta Tropica*, vol. 152, pp. 165-169, 2015.



จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**

## ประวัติผู้เขียน

ชื่อ-สกุล	กัตัญญ ธาราวชิรศาสตร์
วัน เดือน ปี เกิด	3 สิงหาคม 2539
สถานที่เกิด	ชัยนาท
วุฒิการศึกษา	ปริญญาตรี ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ที่อยู่ปัจจุบัน	58/16 ถ.พหลโยธิน ต.บ้านกล้วย อ.เมือง จ.ชัยนาท 17000



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY