

Apply of Deep Learning Techniques to Classify Poisonous Squid and Non-Venomous Squid

Kritsakorn Ruamsamak^{1,*} Benchaphol Phetliam¹ Arisa Thongkhumkrom¹ Janista Nonsraket¹ and Napat Dechsatien¹

ABSTRACT

This research presents the development model for image detection of blue ringed octopus and non-venomous squid based on supervised learning deep learning technique. The image dataset to train model contains 200 images. There are 100 images per class and set up epoch equal to 10. We experimentally compare the performance of three algorithms, which are Feedforward Neural Network Convolutional Neural Network and Support Vector Machine. The experiment results show that the detection performance of Convolutional Neural Network is better than Feedforward Neural Network and Support Vector Machine in all measures. The model gives 92.50% Accuracy, 100.00% Precision, 85.00% Recall, and 91.89% F1-score. The performance test results come from the dataset used in model testing

Keywords: blue ringed octopus, non-venomous squid, non-venomous octopus, image classification, deep learning, convolutional neural network

Published Online: 5 June 2024

ISSN: 2730-3829

Kritsakorn Ruamsamak^{1,*}

¹Faculty of Industrial Technology and Management, King Mongkut's University of Technology North Bangkok, Prachinburi
(s6306021620115@email.kmutnb.ac.th)

Benchaphol Phetliam¹

¹Faculty of Industrial Technology and Management, King Mongkut's University of Technology North Bangkok, Prachinburi
(s6306021620085@email.kmutnb.ac.th)

Arisa Thongkhumkrom¹

¹Faculty of Industrial Technology and Management, King Mongkut's University of Technology North Bangkok, Prachinburi
(s6306021622096@email.kmutnb.ac.th)

Janista Nonsraket¹

¹Faculty of Industrial Technology and Management, King Mongkut's University of Technology North Bangkok, Prachinburi
(s6306021611035@email.kmutnb.ac.th)

Napat Dechsatien¹

¹Faculty of Industrial Technology and Management, King Mongkut's University of Technology North Bangkok, Prachinburi
(s6306021612074@email.kmutnb.ac.th)

*Corresponding Author

Received date: 23 March 2023

Revised date: 2 May 2024

Accepted date: 1 June 2024

การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกเพื่อจำแนกหมึกมีพิษและไม่มีพิษ

กฤษกร ร่วมสมัคร^{1,*} เบญจพล เพชรเหลี่ยม¹ อริษา ทองคำกรม¹ จนิस्ता นนท์สระเกตุ¹ และณภัทร เดชเสถียร¹

บทคัดย่อ

งานวิจัยนี้นำเสนอการพัฒนาโมเดลที่ช่วยตรวจสอบระหว่างหมึกมีพิษบลูริงกับหมึกไม่มีพิษโดยประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกด้วยวิธีการเรียนรู้แบบมีผู้สอน ข้อมูลรูปภาพที่นำมาใช้ในการทดลองโมเดลมีจำนวนทั้งสิ้น 200 ภาพ แบ่งเป็นคลาสละ 100 ภาพและตั้งค่าการฝึกสอนจำนวน 10 รอบ ผู้วิจัยได้ทำการทดลองโดยการเปรียบเทียบประสิทธิภาพของอัลกอริทึม 3 อัลกอริทึมคือ โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า โครงข่ายประสาทคอนโวลูชัน และ เครื่องเวกเตอร์ค้ำยัน ผลการทดสอบประสิทธิภาพพบว่า โครงข่ายประสาทคอนโวลูชันให้ค่าประสิทธิภาพที่ดีกว่าโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าและเครื่องเวกเตอร์ค้ำยันในทุกมาตรวัดประสิทธิภาพ โดยตัวโมเดลให้ค่าความถูกต้อง (Accuracy) ร้อยละ 92.50 ค่าความเที่ยงตรง (Precision) ร้อยละ 100.00 ค่าระลึก (Recall) ร้อยละ 85.00 และ ค่าความถ่วงดุล (F1-score) ร้อยละ 91.89 โดยผลทดสอบประสิทธิภาพที่ได้มาจากชุดข้อมูลที่ใช้ในการทดสอบตัวโมเดล

คำสำคัญ: หมึกมีพิษบลูริง หมึกไม่มีพิษ การจำแนกรูปภาพ การเรียนรู้เชิงลึก โครงข่ายประสาทเทียมแบบคอนโวลูชัน

Published Online: 5 มิถุนายน 2567

ISSN: 2730-3829

กฤษกร ร่วมสมัคร^{1,*}

¹คณะเทคโนโลยีและการจัดการอุตสาหกรรม
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนคร
เหนือ ปรานีนบุรี

(s6306021620115@email.kmutnb.ac.th)

เบญจพล เพชรเหลี่ยม¹

¹คณะเทคโนโลยีและการจัดการอุตสาหกรรม
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนคร
เหนือ ปรานีนบุรี

(s6306021620085@email.kmutnb.ac.th)

อริษา ทองคำกรม¹

¹คณะเทคโนโลยีและการจัดการอุตสาหกรรม
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนคร
เหนือ ปรานีนบุรี

(s6306021622096@email.kmutnb.ac.th)

จนิस्ता นนท์สระเกตุ¹

¹คณะเทคโนโลยีและการจัดการอุตสาหกรรม
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนคร
เหนือ ปรานีนบุรี

(s6306021611035@email.kmutnb.ac.th)

ณภัทร เดชเสถียร¹

¹คณะเทคโนโลยีและการจัดการอุตสาหกรรม
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนคร
เหนือ ปรานีนบุรี

(s6306021612074@email.kmutnb.ac.th)

**Corresponding Author*

Received date: 23 มีนาคม 2566

Revised date: 2 พฤษภาคม 2567

Accepted date: 1 มิถุนายน 2567

1. บทนำ

ในประเทศไทยนั้นหมึกเป็นอาหารทะเลที่ผู้คนนิยมบริโภคกันโดยทั่วไป แต่ว่าหมึก หรือ ปลาหมึกนั้นไม่ได้สามารถบริโภคได้ทั้งหมด เนื่องจากหมึกเป็นสัตว์ทะเลที่มีทั้งชนิดที่มีพิษและไม่มีพิษปะปนกันอยู่ จึงอาจจะทำให้เกิดอันตรายจากการที่บริโภคหมึกที่มีพิษเข้าไปโดยที่ผู้ไม่รู้และไม่ทันได้สังเกตได้ เมื่อวันที่ 1 มีนาคม พ.ศ.2559 ได้มีการพบหมึกมีพิษที่จังหวัดระนองวางจำหน่ายอยู่ ซึ่งหมึกมีพิษชนิดนั้นคือ หมึกบลูริง (Blue ringed octopus)

เมื่อวันที่ 1 ธันวาคม พ.ศ. 2563 และวัน 12 มีนาคม พ.ศ. 2564 ก็ได้มีข่าวเกี่ยวกับการพบเจอหมึกบลูริงถูกวางจำหน่ายอยู่ในท้องตลาด โดยที่ตัวชาวประมงและแม่ค้าเองก็ไม่ทราบว่าหมึกชนิดนี้มีพิษไม่สามารถรับประทานได้ ผู้วิจัยจึงได้เกิดแนวคิดเพื่อตรวจสอบรูปภาพระหว่างหมึกมีพิษบลูริงและหมึกไม่มีพิษโดยประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องในการตรวจสอบรูปภาพดังกล่าว วัตถุประสงค์ของงานวิจัย คือ เพื่อสร้างโมเดลตรวจสอบหมึกมีพิษบลูริงกับหมึกไม่มีพิษในประเทศไทยโดยประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกด้วยวิธีการเรียนรู้แบบมีผู้สอน ซึ่งประโยชน์ที่ได้รับจากงานวิจัยนอกจากได้โมเดลที่สามารถจำแนกข้อมูลรูปภาพที่มีประสิทธิภาพแล้ว ยังสามารถช่วยให้ผู้วิจัยหรือผู้ใช้ระบบสามารถจำแนกความแตกต่างระหว่าง หมึกมีพิษบลูริงกับหมึกไม่มีพิษได้ถูกต้อง

วัตถุประสงค์

1. เพื่อสร้างโมเดลจำแนกรูปภาพหมึกมีพิษกับหมึกไม่มีพิษในประเทศไทย โดยประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกด้วยวิธีการเรียนรู้แบบมีผู้สอน
2. เพื่อให้โมเดลสามารถจำแนกความแตกต่างระหว่างหมึกมีพิษบลูริงกับหมึกไม่มีพิษได้ถูกต้อง

2. วิธีการวิจัย

การจำแนกหมึกมีพิษกับหมึกไม่มีพิษด้วยรูปภาพโดยใช้เทคนิคการเรียนรู้เชิงลึกด้วยวิธีการเรียนรู้แบบมีผู้สอนมีการดำเนินงาน 3 ขั้นตอนด้วยกัน ได้แก่ 1) การรวบรวมและเตรียมข้อมูล 2) การสร้างโมเดลจำแนกภาพ 3) การวัดประสิทธิภาพโมเดล

ขั้นตอนที่ 1 การเก็บรวบรวมและเตรียมข้อมูล ในขั้นตอนนี้ใช้ภาพหมึก 200 ตัว แบ่งข้อมูลรูปภาพออกเป็น 2 คลาส ได้แก่ 1) หมึกไม่มีพิษ แบ่งออกเป็น หมึกกล้วย 35 รูป หมึกกระดอง 35 รูป และหมึกสาย 30 รูป 2) หมึกมีพิษบลูริง คลาสละ 100 รูป รวมทั้งหมด 200 รูป โดยหาภาพจากอินเทอร์เน็ตทั่ว ๆ ไป กำหนดขนาดรูปภาพทุกรูปให้มีขนาด 200x200 pixel จากนั้นจึงดำเนินการแบ่งข้อมูลภาพ 200 ตัวอย่างแบ่งเป็น 2 ส่วน คือ ข้อมูลส่วนที่หนึ่งแบ่งออกเป็นร้อยละ 80 ของจำนวนทั้งหมดจะได้จำนวน 160 ตัวอย่างนำมาใช้ในการฝึกสอนตัวโมเดล ข้อมูลส่วนที่สองแบ่งออกเป็นร้อยละ 20 ของจำนวนข้อมูลทั้งหมดจะได้จำนวน 40 ตัวอย่าง นำมาใช้ในการทดสอบตัวโมเดล โดยข้อมูลตัวอย่างภาพทั้งหมดนี้นำมาใช้เป็นข้อมูลในการฝึกสอนของโครงข่ายประสาทคอนโวลูชัน (CNN) โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (Feedforward NN) และเครื่องเวกเตอร์ค้ำยัน (SVM) ตัวอย่างภาพแสดงรายละเอียดดัง Table 1

Table 1 Number of octopus and squid images used to detect blue ring octopus

					
Type of	Pharaoh	Octopus	Soft	blue-ringed	
Octopus and	cuttlefish	membranaceous	cuttlefish	octopus	Total
Squid	(Squid)	(Octopus)	(Squid)	(Octopus)	
	Sepia	Octopus	Sepioteuthis	Hapalochlaena	
	pharaonis	membranaceus	lessoniana	maculosa	
	Ehrenberg,	Quoy and	Lesson, 1830	Hoyle, 1883	
	1831	Gaimard, 1832			
Total	35	30	35	100	200
(Images)					
Training					
Dataset		80		80	160
(Images)					
Testing					
Dataset		20		20	40
(Images)					

Table 1 เป็นตารางแสดงการแบ่งชุดข้อมูลสำหรับฝึกสอนโมเดล โดยแบ่งเป็นชุดข้อมูลของหมึกไม่มีพิษจำนวน 100 รูป จำแนกเป็นรูปภาพหมึกกล้วยจำนวน 35 รูป หมึกสายจำนวน 30 รูป หมึกกระดอง 35 รูป ชุดข้อมูลของหมึกมีพิษจำนวน 100 รูป เป็นรูปภาพของหมึกมีพิษบลูริงเพียงอย่างเดียว จากนั้นจึงมาทำการแบ่งเป็นชุดข้อมูลสำหรับฝึกสอน และชุดข้อมูลสำหรับทดสอบ แบ่งเป็นอัตราส่วนร้อยละ 80 สำหรับชุดข้อมูลฝึกสอน และร้อยละ 20 สำหรับชุดข้อมูลทดสอบ สำหรับรูปภาพในตารางจะประกอบไปรูปภาพตัวอย่างสำหรับหมึกแต่ละชนิด

ขั้นตอนที่ 2 การสร้างโมเดลตรวจสอบหมึกมีพิษบลูริง มีกระบวนการดังนี้ การสร้างโมเดลเริ่มจากนำข้อมูลรูปภาพที่ได้จัดเตรียมไว้มาทำการฝึก และสร้างโมเดลขึ้นมาด้วยภาษา Python ควบคู่กับไลบรารี TensorFlow โดยสร้างโมเดลทั้งหมด 3 ตัวด้วยกัน โมเดลตัวแรกสร้างด้วยเทคนิคแบบโครงข่ายประสาทแบบคอนโวลูชัน โดยโครงสร้างของตัวโมเดลได้มีการออกแบบให้มีจำนวนของชั้น Conv2D ทั้งสิ้น 3 ชั้น (ชั้นของ Conv2D คือชั้นสี่เหลี่ยม) รายละเอียดในการออกแบบโมเดล มีดังนี้ (ดู Figure 1 ประกอบ)

ชั้นที่ 1 มีจำนวน Filter 128 layers (ชั้นสี่เหลี่ยมชั้นแรกเริ่มจากฝั่งซ้าย)

kernel size 3*3 กำหนด padding ให้ส่งออกกรุปด้วยขนาดเท่าเดิม กำหนด Activation Function เป็น relu และมี MaxPooling2D (ชั้นสี่เหลี่ยมชั้นแรกเริ่มจากฝั่งซ้าย) ขนาด 3*3

ชั้นที่ 2 มีจำนวน Filter 64 layers (ชั้นสี่เหลี่ยมชั้นที่สองเริ่มจากฝั่งซ้าย)

kernel size 3*3 กำหนด padding ให้ส่งออกกรุปด้วยขนาดเท่าเดิม กำหนด Activation Function เป็น relu และมี MaxPooling2D (ชั้นสี่เหลี่ยมชั้นที่สองเริ่มจากฝั่งซ้าย) ขนาด 3*3

ชั้นที่ 3 มีจำนวน Filter 32 layers (ชั้นสี่เหลี่ยมชั้นที่สามเริ่มจากฝั่งซ้าย)

kernel size 3*3 กำหนด padding ให้ส่งออกรูปด้วยขนาดเท่าเดิม กำหนด Activation Function เป็น relu และมี MaxPooling2D (ชั้นสี่เหลี่ยมชั้นที่สามเริ่มจากฝั่งซ้าย) ขนาด 3*3

ส่วนการกำหนด Hidden Layer นั้น ผู้วิจัยให้มี Hidden layer 1 layer มี 16 โหนด ใช้ Activation Function เป็น relu กำหนดให้มี Dropout 1 ครั้ง ส่วน Output layer ใช้ Activation Function เป็น sigmoid

สาเหตุที่ทางผู้วิจัยได้ทำการออกแบบโครงสร้างของตัวโมเดลโครงข่ายประสาทแบบคอนโวลูชัน ตามรายละเอียดที่ระบุไว้แทนที่จะใช้โครงสร้างที่มีอยู่ หรือโครงสร้างที่ได้รับความนิยมเพราะว่า ทางผู้วิจัยได้ลองนำโครงสร้างเหล่านั้นมาทดลองใช้กับชุดข้อมูลที่จัดเตรียมไว้ แต่ตัวโมเดลได้ให้ค่าประสิทธิภาพออกมาไม่เป็นที่พึงพอใจ อาจจะเป็นเพราะจำนวนของข้อมูลที่น้อย ทางผู้วิจัยจึงได้ออกแบบโครงสร้างของตัวโมเดลที่สอดคล้องกับจำนวนของข้อมูลเพื่อให้ได้ประสิทธิภาพที่เป็นที่พึงพอใจ จึงได้เป็นโครงสร้างของตัวโมเดลตามรายละเอียดที่ระบุไว้ในเบื้องต้น




Figure 1 Model structure (CNN)

จาก Figure 1 เป็นภาพแสดงรายละเอียดของโครงสร้างตัวโมเดลโครงข่ายประสาทคอนโวลูชัน (CNN) ที่ได้ ออกแบบไว้ตามรายละเอียดที่ได้ระบุไว้โดยชั้นสี่เหลี่ยมเป็นชั้นของ Conv2D สี่เหลี่ยมเป็นชั้นของ Maxpooling2D สี่เหลี่ยม เป็นชั้น Flatten สีฟ้าเป็น Dense และสีน้ำเงินคือ Dropout ภาพนี้ถูกวาดขึ้นจากไลบรารี visualkeras

โมเดลตัวที่สองสร้างด้วยเทคนิคแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า โดยโครงสร้างของตัวโมเดลได้มีการออกแบบให้มีชั้น Input Layer จำนวน 1 layer มี 16 โหนด ใช้ Activation Function เป็น relu และมี Dropout 1 ครั้ง กำหนดให้มี Hidden Layer 1 Layer มี 16 โหนด Activation Function เป็น relu มี Dropout 1 ครั้ง ส่วนของ Output Layer กำหนดให้ใช้ Activation Function เป็น sigmoid

โมเดลตัวที่สามสร้างด้วยเทคนิคแบบเครื่องเวกเตอร์ค้ำยัน โดยตัวโครงสร้างของตัวโมเดลได้มีการออกแบบค่าพารามิเตอร์โดยใช้ฟังก์ชัน GridSearchCV ของไลบรารี sklearn.model_selection โดยฟังก์ชันนี้จะหาค่าพารามิเตอร์ที่ดีที่สุดสำหรับตัวโมเดลเครื่องเวกเตอร์ค้ำยันออกมา โดยค่าพารามิเตอร์ที่ดีที่สุดที่ได้ คือ

ค่าพารามิเตอร์ C ค่าที่ดีที่สุดมีค่าเท่ากับ 1 ค่าพารามิเตอร์ gamma ค่าที่ดีที่สุดที่ได้ คือ 0.001 และค่าพารามิเตอร์ kernel ที่ดีที่สุดที่ได้คือ poly

ในการฝึกสอนและทดสอบตัวโมเดลโครงข่ายประสาทแบบคอนโวลูชัน กับโมเดลโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า ได้มีการกำหนดให้มีจำนวนรอบในการฝึกสอนและทดสอบทั้งสิ้น 10 รอบ (epoch) และมีขนาด Batch Size เท่ากับ 20 ในการฝึกสอนและทดสอบโมเดลทั้ง 10 รอบด้วยภาษาไพธอนแสดงให้เห็นใน Figure 2 และ Figure 3 หลังจากที่ได้ฝึกสอนโมเดลและทดสอบประสิทธิภาพจนได้ค่าที่เหมาะสมแล้ว ผู้วิจัยจะนำโมเดลที่ได้ไปพัฒนาเป็นโปรแกรมเพื่อการประยุกต์ใช้ต่อไป

```
[121] history = model.fit(X_train, y_train, batch_size=20, epochs=10, validation_data=(X_test, y_test))

Epoch 1/10
8/8 [=====] - 11s 79ms/step - loss: 0.6703 - accuracy: 0.6375 - val_loss: 0.6098 - val_accuracy: 0.7250
Epoch 2/10
8/8 [=====] - 0s 45ms/step - loss: 0.6262 - accuracy: 0.7063 - val_loss: 0.4820 - val_accuracy: 0.7500
Epoch 3/10
8/8 [=====] - 0s 49ms/step - loss: 0.4850 - accuracy: 0.7812 - val_loss: 0.4191 - val_accuracy: 0.8250
Epoch 4/10
8/8 [=====] - 0s 49ms/step - loss: 0.4311 - accuracy: 0.8125 - val_loss: 0.3739 - val_accuracy: 0.8250
Epoch 5/10
8/8 [=====] - 0s 50ms/step - loss: 0.4206 - accuracy: 0.8125 - val_loss: 0.3240 - val_accuracy: 0.8750
Epoch 6/10
8/8 [=====] - 0s 45ms/step - loss: 0.2802 - accuracy: 0.8750 - val_loss: 0.2593 - val_accuracy: 0.8500
Epoch 7/10
8/8 [=====] - 0s 49ms/step - loss: 0.2691 - accuracy: 0.8667 - val_loss: 0.3247 - val_accuracy: 0.8750
Epoch 8/10
8/8 [=====] - 0s 46ms/step - loss: 0.2471 - accuracy: 0.8875 - val_loss: 0.2234 - val_accuracy: 0.8750
Epoch 9/10
8/8 [=====] - 0s 50ms/step - loss: 0.1900 - accuracy: 0.9375 - val_loss: 0.2249 - val_accuracy: 0.9000
Epoch 10/10
8/8 [=====] - 0s 46ms/step - loss: 0.2236 - accuracy: 0.9187 - val_loss: 0.1834 - val_accuracy: 0.9250
```

Figure 2 Model training and testing in python (CNN)

```
History = model.fit(X_train, y_train, batch_size=20, epochs=10, validation_data=(X_test, y_test))

Epoch 1/10
8/8 [=====] - 1s 58ms/step - loss: 13.7660 - accuracy: 0.5813 - val_loss: 2.6687 - val_accuracy: 0.7750
Epoch 2/10
8/8 [=====] - 0s 17ms/step - loss: 5.2790 - accuracy: 0.5000 - val_loss: 3.3293 - val_accuracy: 0.5250
Epoch 3/10
8/8 [=====] - 0s 26ms/step - loss: 1.5932 - accuracy: 0.5625 - val_loss: 2.2619 - val_accuracy: 0.5250
Epoch 4/10
8/8 [=====] - 0s 34ms/step - loss: 1.5601 - accuracy: 0.5625 - val_loss: 1.7580 - val_accuracy: 0.5500
Epoch 5/10
8/8 [=====] - 0s 36ms/step - loss: 2.5222 - accuracy: 0.5375 - val_loss: 0.7797 - val_accuracy: 0.6000
Epoch 6/10
8/8 [=====] - 0s 26ms/step - loss: 1.7210 - accuracy: 0.5188 - val_loss: 0.6800 - val_accuracy: 0.6250
Epoch 7/10
8/8 [=====] - 0s 37ms/step - loss: 1.5375 - accuracy: 0.5375 - val_loss: 0.5837 - val_accuracy: 0.7000
Epoch 8/10
8/8 [=====] - 0s 36ms/step - loss: 0.8994 - accuracy: 0.6875 - val_loss: 0.6099 - val_accuracy: 0.6750
Epoch 9/10
8/8 [=====] - 0s 35ms/step - loss: 1.0657 - accuracy: 0.5813 - val_loss: 0.8670 - val_accuracy: 0.7500
Epoch 10/10
8/8 [=====] - 0s 40ms/step - loss: 1.0078 - accuracy: 0.5437 - val_loss: 0.5846 - val_accuracy: 0.4500
```

Figure 3 Model training and testing in python (Feedforward NN)

ใน Figure 2 และ Figure 3 เป็นภาพที่แสดงจำนวนรอบในการฝึกและทดสอบโมเดล CNN และ Feedforward NN และแสดงค่าความแม่นยำในแต่ละรอบใน Google Colab ที่ใช้ในการฝึกสอนตัวโมเดล

ส่วนในการฝึกสอนตัวโมเดลเครื่องเวกเตอร์ค้ำยัน (SVM) จะไม่ได้มีการกำหนดรอบการฝึกสอนโดยตรง แต่จะเป็นทดลองหาค่าพารามิเตอร์ที่ดีที่สุดแล้วนำมาใช้ในการฝึกสอนตัวโมเดลแค่เพียงครั้งเดียวเท่านั้น

ขั้นตอนที่ 3 การวัดประสิทธิภาพโมเดลทั้ง 3 โมเดล ในงานวิจัยนี้ใช้มาวัดวัดประสิทธิภาพทั้งหมด 4 ตัว คือค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) และค่าความถ่วงดุล (F1-score) ซึ่งแต่ละค่ามีวิธีการคำนวณดังสมการที่ (1) ถึงสมการที่ (4) ตามลำดับ

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

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

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

$$\text{F1-score} = \frac{2*(\text{Precision}*\text{Recall})}{(\text{Precision} + \text{Recall})} \quad (4)$$

โดยที่ TP (True Positive) คือ จำนวนข้อมูลที่ไม่เคยจำแนกได้ถูกต้องและมีผลลัพธ์จริงที่ถูกต้อง
 TN (True Negative) คือ จำนวนข้อมูลที่ไม่เคยจำแนกไม่ถูกต้องและมีผลลัพธ์จริงที่ไม่ถูกต้อง
 FP (False Positive) คือ จำนวนข้อมูลที่ไม่เคยจำแนกได้ถูกต้องแต่ผลลัพธ์จริงไม่ถูกต้อง
 FN (False Negative) คือ จำนวนข้อมูลที่ไม่เคยจำแนกไม่ถูกต้องแต่ผลลัพธ์จริงถูกต้อง

1) การศึกษาทฤษฎีที่เกี่ยวข้องกับงานวิจัย

งานวิจัยนี้ทางผู้จัดทำได้เลือกศึกษาหมึกมีพิษและหมึกไม่มีพิษที่พบในประเทศไทย หมึกไม่มีพิษ ได้แก่

1.1 หมึกกล้วย มีรูปร่างยาวเรียว ในลำตัวมีกระดองใสเหมือนแผ่นพลาสติก รูปร่างคล้ายขนนกหนึ่งอัน ลำตัวกลม คลีบเป็นรูปสามเหลี่ยมอยู่ด้านท้าย คลีบด้านขวาและซ้ายเชื่อมต่อกันทางด้านหลัง ในปากมีเขี้ยวคล้ายปากนกแก้ว มีหนวดยาว 1 คู่และมีหนวดสั้น 4 คู่ และ นัยน์ตามีขนาดใหญ่



Figure 4 Soft cuttlefish (Squid)

(Retrieved from <https://th.wikipedia.org/wiki/หมึกกล้วย>)

Figure 4 เป็นภาพที่แสดงถึงลักษณะของหมึกกล้วยตามทฤษฎีที่ได้มีการกล่าวถึงไปในข้างต้น

1.2 หมึกกระดอง มีลักษณะคล้ายหมึกกล้วย แต่มีรูปร่างที่กลมป้อมกว่า มีหนวดทั้งสั้น 10 หนวดเหมือนกับหมึกกล้วย แต่มีหนวดยาว 2 เส้น ภายในโครงร่างภายในเป็นแผ่นหินปูนรูปกระสวย สอดอยู่กลางหลัง



Figure 5 Pharaoh cuttlefish (Squid)

(Retrieved from https://tuttjaquatics.blogspot.com/2013_11_01_archive.html)

Figure 5 เป็นภาพที่แสดงถึงลักษณะของหมึกกระดองตามทฤษฎีที่ได้มีการกล่าวถึงไปในข้างต้น

1.3 หมึกสาย หรือ หมึกยักษ์ มีขนาด 8 เส้น เขี้ยวคล้ายปากนกแก้ว คม มีสีดำ มีลักษณะลำตัวอ่อนนุ่มไม่มีกระดูก



Figure 6 Octopus membranaceus (Octopus)

(Retrieved from <https://www.taludiving.com/สัตว์ทะเลที่มีพิษ/ปลาหมึกยักษ์.html>)

Figure 6 เป็นภาพที่แสดงถึงลักษณะของหมึกสายตามทฤษฎีที่ได้มีการกล่าวถึงไปในข้างต้น

หมึกมีพิษ ได้แก่ หมึกบลูริง หรือ หมึกสายวงน้ำเงิน มีลักษณะลำตัวขนาดเล็ก โดยตัวโตเต็มวัยมีขนาดอยู่ที่ 4-5 เซนติเมตร มีสายวงแหวนสีฟ้าสะท้อนแสงเล็กๆ กระจายอยู่ตามลำตัว และหนวดยาวประมาณ 15 เซนติเมตร พิษของหมึกบลูริง มีลักษณะคล้ายกับพิษของปลาปักเป้าที่มีชื่อว่า Tetrodotoxin พบพิษได้ในต่อมน้ำลาย หนวด ลำไส้ ปาก และต่อมหมึก พิษชนิดนี้จะทำลายระบบประสาททำให้ไม่สามารถเคลื่อนไหวได้ และทำให้เหยื่อตายหรือเป็นอัมพาต โดยพิษชนิดนี้จะออกฤทธิ์อย่างรวดเร็ว



Figure 7 Bue-ringed octopus (Octopus)

(Retrieved from <http://www.pobpad.com/หมึกบลูริง-พิษร้ายที่มา>)

Figure 7 เป็นภาพที่แสดงถึงลักษณะของหมึกมีพิษบลูริงตามทฤษฎีที่ได้มีการกล่าวถึงไปในข้างต้น

ในส่วนของการศึกษาทฤษฎีที่เกี่ยวข้องกับการงานวิจัยทางผู้วิจัยได้ศึกษาเกี่ยวกับการเรียนรู้เชิงลึก ซึ่งมีรายละเอียดดังนี้

การเรียนรู้เชิงลึก (Deep Learning) คือ เป็นอัลกอริทึมที่เรียนรู้โดยอัตโนมัติใช้โครงข่ายประสาทหลายๆ ชั้น (Layer) เหมือนแบบจำลองโครงข่ายประสาทของมนุษย์ (Neurons) และทำการเรียนรู้ข้อมูล โดยใส่ข้อมูลเข้าไปและทำงานเป็นลำดับชั้น ชั้นแรกคือชั้นรับข้อมูล (Input Layer) เป็นชั้นที่รับข้อมูลหรือฟีเจอร์ จากนั้นเครื่องจักรจะนำข้อมูลไปประมวลผลในชั้นที่สองคือชั้นซ่อน (Hidden Layer) เพื่อปรับค่าน้ำหนักแล้วเมื่อคำนวณค่าน้ำหนักกับข้อมูลและปรับค่าผลลัพธ์ด้วยฟังก์ชันกระตุ้นแล้วจะนำเสนอข้อมูลผลลัพธ์ไปยังชั้นแสดงผล (Output Layer) ข้อดีของการเรียนรู้เชิงลึก คือ ผู้พัฒนาไม่จำเป็นต้องให้ความรู้พื้นฐานกับระบบล่วงหน้าตัวอัลกอริทึมก็สามารถสร้างแบบจำลองและแก้ไขปัญหาที่ซับซ้อนได้หลากหลายอีกทั้งมีความยืดหยุ่นสูง สำหรับอัลกอริทึมที่ได้รับความนิยมในการจำแนกรูปภาพในปัจจุบัน คือ โครงข่ายประสาทคอนโวลูชัน (Convolution Neural Network: CNN)




Figure 8 Deep Learning Structure

(Retrieved from https://www.researchgate.net/figure/Example-of-a-Deep-Neural-Network_fig24_355037927)

Figure 8 เป็นภาพที่แสดงให้เห็นถึงลักษณะโครงสร้างของเทคนิคการเรียนรู้เชิงลึก (Deep Learning) โดยจะมี Layers 3 Layers ด้วยกันประกอบไปด้วย Input Layers เป็นชั้นของการนำเข้าข้อมูล Hidden Layers เป็นชั้นสำหรับการประมวลผลข้อมูล และ Output Layers เป็นชั้นสำหรับส่งออกผลลัพธ์ที่ได้จาก Deep Learning

ในส่วนของการศึกษาทฤษฎีที่เกี่ยวข้องกับการงานวิจัยทางผู้วิจัยได้ศึกษาเกี่ยวกับโครงข่ายประสาทคอนโวลูชัน ซึ่งรายละเอียดดังนี้

โครงข่ายประสาทคอนโวลูชัน (Convolution Neural Networks: CNN) เป็นการเรียนรู้ของเครื่องอีกประเภทหนึ่ง (Machine Learning) ที่ได้จำลองรูปแบบประเภทโครงข่ายประสาทเทียมในรูปแบบการเรียนรู้เชิงลึก (Deep Learning) โดยเริ่มจากกระบวนการสกัดคุณลักษณะที่สำคัญของรูปภาพออกมาโดยใช้ Convolutional Layer ผ่านฟิลเตอร์ในแต่ละ Convolutional Layer ตามด้วยการลดขนาดของภาพด้วยขั้นตอนการ Pooling หลังจากนั้นจึงทำการแปลงโครงสร้างของข้อมูลที่ต้องการเรียนรู้ด้วยการ Flatten และเข้าสู่กระบวนการจำแนกด้วยโครงข่ายประสาทเพื่อหาผลลัพธ์ที่ต้องการ ซึ่งตัวโมเดลจะมีความยืดหยุ่นและสามารถสร้างรูปแบบการเรียนรู้ขึ้นมาได้เองโดยที่ผู้ใช้ไม่จำเป็นต้องกำหนดรูปแบบในการเรียนรู้ให้กับตัวโมเดล




Figure 9 CNN Structure

(Retrieved from <https://images.app.goo.gl/UB3xMP5WQyvxrMLh7>)

Figure 9 เป็นภาพที่แสดงให้เห็นถึงลักษณะโครงสร้างของโครงข่ายประสาทคอนโวลูชัน (Convolution Neural Networks: CNN) ที่ประกอบไปด้วยชั้นการป้อนข้อมูล (Input Layers) เป็นชั้นรับข้อมูลรูปภาพเข้าสู่โครงข่ายประสาทคอนโวลูชัน ชั้นการแปลงข้อมูล (Convolution Layers) เป็นชั้นของการแปลงข้อมูลรูปภาพโดยใช้ฟิลเตอร์เป็นเมทริกซ์ขนาดเล็กจะแปลงข้อมูลรูปภาพและคำนวณผลคูณระหว่างฟิลเตอร์กับข้อมูลภาพ ผลลัพธ์ที่ได้จะถูกบวกเข้าด้วยกัน ผ่านฟังก์ชันกระตุ้น ชั้นการลดขนาด (Pooling Layers) เป็นชั้นของการลดขนาดของรูปภาพโดยใช้ฟังก์ชันการลดขนาด (Pooling Function) ฟังก์ชันการลดขนาดที่ใช้ทั่วไป ได้แก่ ฟังก์ชันการลดขนาดสูงสุด (Max Pooling) ฟังก์ชันการลดขนาดเฉลี่ย (Average Pooling) ชั้นการเชื่อมต่อเต็มรูปแบบ (Fully Connected Layers) เป็นชั้นการเชื่อมต่อที่จะทำการแปลงข้อมูลภาพที่ผ่านการแปลงข้อมูลและลดขนาดแล้ว ให้เป็นรูปแบบเวกเตอร์

ในส่วนของการศึกษาทฤษฎีที่เกี่ยวข้องกับการงานวิจัยทางผู้วิจัยได้ศึกษาเกี่ยวกับ Artificial Neural Network ซึ่งมีรายละเอียดดังนี้

โครงข่ายประสาทเทียม เป็นแบบจำลองทางคณิตศาสตร์ที่พัฒนาเพื่อจำลองการทำงานของโครงข่ายประสาทในสมองของมนุษย์ โมเดลจะให้ค่าน้ำหนักซึ่งจะถูกปรับเปลี่ยนค่าเมื่อมีการเรียนรู้ใหม่ๆ เกิดขึ้น ค่าน้ำหนักเปรียบเสมือนความรู้ที่ถูกรวบรวมขึ้น เพื่อใช้ในการแก้ไขปัญหาในสมองของมนุษย์ เหมือนในระบบประสาทของมนุษย์ภายในโหนดจะมีฟังก์ชันกระตุ้น หรือ Activation Function ซึ่งเป็นฟังก์ชันสำหรับส่งสัญญาณส่งออกหรือผลลัพธ์




Figure 10 ANN Structure

(Retrieved from <https://towardsdatascience.com/the-concept-of-artificial-neurons-perceptrons-in-neural-networks-fab22249cbfc>)

Figure 10 เป็นภาพที่แสดงให้เห็นถึงลักษณะโครงสร้างของโครงข่ายประสาทเทียม (Artificial Neural Network) ที่เปรียบเทียบลักษณะการทำงานที่คล้ายคลึงกันระหว่างโครงข่ายประสาทเทียมและระบบประสาทของมนุษย์

ในส่วนของการศึกษาทฤษฎีที่เกี่ยวข้องกับการงานวิจัยทางผู้วิจัยได้ศึกษาเกี่ยวกับ Support Vector Machine ซึ่งมีรายละเอียดดังนี้

Support Vector Machine เป็น Algorithm แบบ Supervised Learning ที่ใช้ในการแก้ปัญหาการจัดกลุ่มของข้อมูล Classification และการวิเคราะห์การถดถอย Regression มีความคล้ายกับ Logistic regression ซึ่งตัวของ Support Vector Machine จะเป็นการจัดกลุ่มข้อมูล โดยการแบ่ง class ของข้อมูลออกจากกัน ซึ่งสามารถใช้การแบ่งด้วยสมการเชิงเส้นได้ทั้ง Linear และ Non-Linear

ในส่วนของการศึกษาทฤษฎีที่เกี่ยวข้องกับการงานวิจัยทางผู้วิจัยได้ศึกษาเกี่ยวกับ TensorFlow ซึ่งมีรายละเอียดดังนี้

TensorFlow คือ ไลบรารี Deep learning ของ บริษัท Google ซึ่งบริษัท Google ได้ใช้เป็นเครื่องมือในงานหลายๆ ด้าน เช่น เครื่องมือค้นหา (Search engine), คำบรรยายภาพ (Image captioning) , การแปลภาษา (Translation) และเครื่องมือช่วยการเสนอแนะ (Recommendations) สามารถใช้งานได้ดีกับภาษาไพธอน แต่อย่างไรก็ตามสามารถใช้ภาษาอื่น ๆ ได้ เช่น ภาษา C ภาษา Java หรือ Go ซึ่ง TensorFlow เมื่อถูกนำใช้แล้วจะช่วยให้โปรแกรมต่าง ๆ ให้ผลลัพธ์ได้อย่างรวดเร็ว และมีความถูกต้องแม่นยำมากขึ้น ที่สำคัญไลบรารีเหล่านี้สามารถใช้งานได้ง่ายเป็น Open Source และทำงานได้บนอุปกรณ์หลากหลายแพลตฟอร์มทั้งเครื่องคอมพิวเตอร์และบนอุปกรณ์เคลื่อนที่

ในส่วนของการศึกษาทฤษฎีที่เกี่ยวข้องกับการงานวิจัยทางผู้วิจัยได้ศึกษาเกี่ยวกับงานวิจัยที่เกี่ยวข้อง 2 เรื่อง ดังนี้

คุณศิริเรือง พัฒน์ช่วย และ อาทิตย์ อยู่เย็น ได้พัฒนาระบบต้นแบบการคัดแยกเกรดปลาหมึก เพื่อช่วยเพิ่มมูลค่าการขายปลาหมึกแห้งให้แก่ชาวประมงกลุ่มน้ำชายฝั่งทะเลประจวบคีรีขันธ์ ด้วยอัลกอริทึมของการประมวลผลภาพแบบเทคนิคการเรียนรู้แบบเชิงลึก โดยตัวอย่างรูปภาพที่มีความเกี่ยวข้องทั้งหมด 500 ภาพ โดยชนิดของปลาหมึกมีอยู่ 2 ประเภท คือ ปลาหมึกแบบผ่า และปลาหมึกแบบไม่ผ่า และเกรดของปลาหมึกประกอบด้วย 3 เกรด คือ เกรด A เกรด B และเกรด C ซึ่งให้ผลค่าความถูกต้องแม่นยำอยู่ในระดับดี คิดเป็นร้อยละ 85.00

สำหรับงานวิจัยของภูมิภักดี พรหมรังกาและคณะ ได้นำเสนอการตัวแบบสำหรับการจำแนกสายพันธุ์นกทั้งหมด 10 สายพันธุ์ ด้วยการใช้แบบจำลองการเรียนรู้เชิงลึก ซึ่งถูกสร้างผ่านไลบรารี TFLite Model Maker จากการทดลองพบว่า แบบจำลอง EfficientDet Lite 0 ซึ่งเป็นรุ่นของแบบจำลอง EfficientDet Lite ที่มีขนาดเล็กที่สุด ให้ผลลัพธ์ที่เหมาะสมกับการใช้งานมากที่สุด โดยใช้เวลาแปรผลภาพที่ . ms และมีค่า Precision เท่ากับ 0.94 , Recall เท่ากับ 0.94, Accuracy เท่ากับ 0.99 และ F1-score เท่ากับ 0.94

3. ผลการวิจัย

ผลการวิจัยได้นำเสนอผลการวัดประสิทธิภาพโมเดล มีรายละเอียดดังต่อไปนี้ ผลการวัดประสิทธิภาพโมเดลการวิจัยนี้ได้ทดลองสร้างโมเดลจำแนกภาพด้วยเทคนิค CNN, Feedforward NN และ SVM ดัง Table 2

Table 2 Performance comparison of models with test set data

Algorithms Measures	CNN	Feedforward NN	SVM
Precision	1.0000	0.4400	55.0000
Recall	0.8500	0.5789	73.3333
F1-Score	0.9189	0.5000	62.8600
Accuracy	92.55%	45.00%	67.50%
Model Size	1.43 MB	274 MB	29.78 MB

จากผลการทดลองที่ได้นำรูปทั้งหมด 200 ภาพ มาทำการเรียนรู้กับโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (Feedforward NN) โครงข่ายประสาทคอนโวลูชัน (CNN) และเครื่องเวกเตอร์ค้ำยัน (SVM) เพื่อนำมาเปรียบเทียบประสิทธิภาพในการตรวจสอบหมีก็มีพิษลูริง มีการแบ่งข้อมูลออกมาเป็นข้อมูลฝึกสอนจำนวนร้อยละ 80 และข้อมูลทดสอบจำนวนร้อยละ 20 ของข้อมูลทั้งหมด พบว่าความถูกต้องในการตรวจสอบหมีก็มีพิษลูริงโมเดลที่ได้จากอัลกอริทึม CNN มีค่าประสิทธิภาพในทุกมาตรวัดประสิทธิภาพสูงกว่าอัลกอริทึม Feedforward NN และ SVM และมีขนาดของไฟล์โมเดลที่เล็กกว่า และมีความเหมาะสมในนำไปใช้เพื่อพัฒนาโปรแกรมประยุกต์ต่อไป

เมื่อข้อมูลที่ได้จากการวัดประสิทธิภาพตัวโมเดลมาวาดเป็นกราฟตามFigure 11 จะพบว่าเมื่อมีการฝึกสอนโมเดลมากขึ้นตามจำนวน epoch ค่า Loss มีแนวโน้มลดลง ในขณะที่ค่า Accuracy มีแนวโน้มเพิ่มมากขึ้น อย่างไรก็ตามจากกราฟที่ได้จะพบว่ามี Gap เกิดขึ้นระหว่างค่า Training กับ Validation ทั้งในแง่ของค่า Loss และค่า Accuracy พอสมควร ซึ่งอาจจะเกิดจากจำนวนของชุดข้อมูลที่มีจำนวนไม่มากนักมีเพียง 200 ภาพ ซึ่งหากมีการเพิ่มจำนวนข้อมูลตัวอย่างให้มากขึ้น อาจจะทำให้ได้โมเดลที่มีการเรียนรู้ที่ดีและสามารถนำไปจำแนกข้อมูลหมีที่มีไม่เคยพบเห็นมาก่อนได้อย่างแม่นยำมากยิ่งขึ้น




Figure 11 CNN classification performance measurement results

ใน Figure 11 เป็นภาพกราฟแสดงให้เห็นถึงประสิทธิภาพของโมเดลว่าในแต่ละรอบค่า Accuracy และ Loss ของโมเดลมีการเปลี่ยนแปลงไปอย่างไร โดยเส้นสีฟ้าเป็นการแทนค่า loss ของการฝึกสอน เส้นสีส้มแทนค่า accuracy ของการฝึกสอน เส้นสีเขียวเป็นการแทนค่า loss ของการทดสอบ และเส้นสีแดงเป็นการแทนค่า accuracy ของการทดสอบโมเดล

จากนั้นผู้วิจัยได้นำตัวโมเดลที่ไปทดสอบกับชุดข้อมูลใหม่ที่ไม่เคยพบมาก่อน (unseen data) จำนวนทั้งหมด 20 ภาพ แบ่งเป็นภาพหมึกมีพิษบลูริง 10 ภาพและหมึกไม่มีพิษ 10 ภาพ ได้ผลการทดสอบออกมาว่า โมเดลสามารถตรวจสอบได้ถูกต้องเฉลี่ยร้อยละ 70 ของข้อมูลทั้งหมด โดยคลาสที่โมเดลตอบได้ถูกต้องเยอะที่สุด คือ คลาสของหมึกไม่มีพิษ สามารถตอบได้ถูก 8 ภาพ จาก 10 ภาพ ส่วนคลาสหมึกมีพิษบลูริง ตอบได้ถูกต้องเพียง 6 ภาพจาก 10 ภาพ ข้อจำกัดของโมเดลที่พบ คือ แสงและมุมของภาพนั้นส่งผลต่อการเรียนรู้ของอัลกอริทึม

หลังจากที่ผู้วิจัยได้ทำการฝึกสอนและทดสอบโมเดลจึงได้ข้อเสนอแนะสำหรับการนำไปปรับปรุงในอนาคต ดังนี้

1. การตรวจสอบหมึกที่สามารถบอกได้ว่าเป็นหมึกชนิดอะไรโดยครอบคลุมเฉพาะหมึกที่พบในประเทศไทย เท่านั้น
2. เมื่อนำงานวิจัยนี้ไปพัฒนาต่อในอนาคต ควรให้ตัวโมเดลสามารถตรวจสอบหมึกมีพิษบลูริงได้ถูกต้องและแม่นยำมากยิ่งขึ้น

4. สรุปผลการวิจัย

การศึกษานี้นำเสนอการตรวจสอบหมึกมีพิษบลูริง โดยประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกด้วยวิธีการเรียนรู้แบบมีผู้สอน การดำเนินงานเริ่มจากการรวบรวมรูปภาพกลุ่มตัวอย่างสำหรับทดลอง โดยแบ่งคลาสการจำแนกเป็น 2 คลาส ได้แก่ หมึกมีพิษบลูริง และหมึกไม่มีพิษ คลาสละ 100 ภาพ รวมทั้งหมด 200 ภาพ จากนั้นนำภาพตัวอย่างไปดำเนินการฝึกสอนและสร้างโมเดลการจำแนกภาพโดยการเปรียบเทียบประสิทธิภาพระหว่างสองอัลกอริทึม คือ โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า โครงข่ายประสาทเทียมแบบคอนโวลูชัน และเครื่องเวกเตอร์ค้ำยัน ภายใต้ไลบรารี TensorFlow ด้วยจำนวนรอบการฝึกสอนทั้งสิ้น 10 รอบ และวัดประสิทธิภาพโมเดลด้วยค่าความถูกต้อง ค่าความระลึก ค่าความแม่นยำ และค่าความถ่วงดุล

ผลการทดสอบประสิทธิภาพในการตรวจสอบหมึกมีพิษบลูริง พบว่า อัลกอริทึมโครงข่ายประสาทคอนโวลูชันให้ค่าประสิทธิภาพที่ดีกว่าทั้ง 4 มาตรวัด โดยให้ค่าความถูกต้องเท่ากับ ร้อยละ 92.55 ค่าความแม่นยำเท่ากับ 1.0000 ค่าความระลึกเท่ากับ 0.85 และค่าความถ่วงดุลเท่ากับ 0.9189

เมื่อนำโมเดลมาทดสอบกับข้อมูลใหม่ที่ไม่เคยพบมาก่อน (unseen data) จำนวน 20 ภาพแบ่งเป็นหมึกมีพิษ 10 ภาพและไม่มีพิษ 10 ภาพ พบว่า โมเดลสามารถตรวจสอบได้ถูกต้องเฉลี่ย ร้อยละ 70 โดยคลาสที่ตรวจสอบได้ถูกต้องมากที่สุด คือ คลาสหมึกไม่มีพิษ จำแนกได้ถูก 8 ภาพจาก 10 ภาพ ส่วนคลาสหมึกมีพิษ จำแนกถูกต้องได้เพียง 6 ภาพจาก 10 ภาพ สาเหตุอาจเนื่องมาจากการจัดเตรียมชุดข้อมูลรูปภาพสำหรับการฝึกสอนอาจจะยังไม่ครอบคลุม เพราะในบางกรณีหมึกไม่มีพิษที่พบตามท้องตลาดหรือสถานที่ต่าง ๆ อาจจะมีสีที่ไม่เหมือนกับตอนที่หมึกยังมีชีวิตอยู่ จึงทำให้เกิดความคลาดเคลื่อนได้

5. กิตติกรรมประกาศ

งานวิจัยการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกเพื่อตรวจสอบหมึกมีพิษบลูริง สามารถสำเร็จลุล่วงไปด้วยดี ได้ โดยได้รับความอนุเคราะห์และการสนับสนุนจากผู้ช่วยศาสตราจารย์ ดร. วันทนีย์ ประจวบศุภกิจ ที่ได้กรุณาให้คำแนะนำ ความรู้ ข้อคิดเห็น ข้อเสนอแนะ และปรับปรุงข้อบกพร่องต่างๆ จนกระทั่งรายงานการวิจัยนี้เสร็จสิ้น ผู้วิจัยขอแสดงความขอบคุณไว้ ณ ที่นี้สุดท้ายนี้ ผู้วิจัยหวังว่ารายงานการวิจัยนี้ยังคงเป็นประโยชน์ต่อหน่วยงานที่เกี่ยวข้องและผู้สนใจรายงานวิจัยต่อไป

ผลประโยชน์ทับซ้อน

ผู้เขียนขอยืนยันว่างานวิจัยนี้ไม่มีความขัดแย้งทางผลประโยชน์ที่เกี่ยวข้องกับบทความนี้กับบทความอื่น ๆ

REFERENCES

- Alom, M. Z., & Taha, T. M., & Yakopcic, C., & Westberg, S., & Sidike, P, & Nasrin, M. S., & Hasan, M., & Van Essen, B. C., & Awwal, A. A. S., & Asari, V. K. (2019). A State-of-the-Art Survey on Deep Learning Theory and Architectures. *Electronics*, 8, 292. <https://doi.org/10.3390/electronics8030292>.
- Divya, S. (2022). What is Deep Learning?. Retrieved October 27, 2022, from <http://new.abb.com/news/detail/58004/deep-learning>.
- F. Bre, J. M. Gimenez, and V. D. Fachinotti, "Prediction of wind pressure coefficients on building surfaces using artificial neural networks," *Energy and Buildings*. (2018). vol. 158, pp. 1429-1441, Jan 2018, <https://doi.org/10.1016/j.enbuild.2017.11.045>.
- FASCINO. (2022). Blue ring squid, poisonous 20 times stronger than a cobra, accidentally eaten to death. Retrieved October 26, 2022, from <http://www.fascino.co.th/article/post/blue-ringed-octopus>.
- Gurney, K. (1997). *An Introduction to Neural Networks*. London: Routledge. 1-85728-673-1 (hardback) or ISBN 1-85728-503-4 (paperback).
- Natthasath Saksupanara. (2023). Support Vector Machine. Retrieved December 8, 2018, from <https://codeinsane.wordpress.com/2018/12/08/support-vector-machine>.
- P. Chandran, B. Byju, R. Deepak, K. Nishakumari, P. Devanand and P. Sasi, (2018). Missing Child Identification System using Deep Learning and Multiclass SVM, in *Proceeding of 2018 IEEE Recent Advances in Intelligent Computational Systems (RAICS), Thiruvananthapuram, India, 2018*, pp. 113–116.
- Phuket AQUARIUM. (2022). Type of squid. Retrieved October 26, 2022, from <http://phuketaquarium.org/knowledge/splendid-squid/>.
- Phummiphak P., & Saharat W., & Choopan R. (2022). Mobile Application for Breeding Bird Classification using Deep Learning Technique. *Journal of Information Science and Technology* Volume 12, NO 1, JAN – JUN 2022 , 37-46 ISSN: 2651-1053 (Online).
- POBPAD. (2022). Blue ring squid, a deadly poison that comes with deliciousness. Retrieved October 26, 2022, from <http://www.pobpad.com/หมึกบลูริง-พิษร้ายที่มา>.
- Pramoditha, R. (2021). The Concept of Artificial Neurons (Perceptrons) in Neural Networks. Retrieved November 24, 2022, from <http://towardsdatascience.com/the-concept-of-artificial-neurons-perceptrons-in-neural-networks-fab22249cbfc>.
- Siriruang, P. and Arthit Y. (2562). A sorting dried squid system for fisher coastal basin Prachuap Khiri Khan by Deep Learning, Rajamangala University of Technology Rattanakosin, 2018.