

บทความวิจัย (Research Article)

การคัดแยกคุณภาพของปลาตะเพียนขาวด้วยวิธีการเรียนรู้เชิงลึกและแชทบอทสำหรับการวิเคราะห์ภาพถ่าย

อัจฉรา ชุมพล^{1*}, สรายุทธ กรวิรัตน์¹, รณชัย สังหมั่นเม้า¹, นรงค์ วิชาผา², ปรีชาดิ เบอร์ขุนทด¹, แพรวา สีกาลุน¹
และ ภัทรพล เกواهرิต³

¹ สาขาวิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์และเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยกาฬสินธุ์

² สาขาวิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์และเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยกาฬสินธุ์

³ สาขาวิชาเทคโนโลยีสารสนเทศ คณะวิทยาศาสตร์ มหาวิทยาลัยอุบลราชธานี

*ผู้ประสานงานบทความฉบับนี้: atchara.ch@ksu.ac.th

(รับบทความ: 8 ตุลาคม 2567; แก้ไขบทความ: 24 ตุลาคม 2567; ตอรับบทความ: 29 ตุลาคม 2567)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อ แก้ไขข้อจำกัดของการคัดแยกคุณภาพปลาตะเพียนขาวด้วยสายตาตามมนุษย์ ซึ่งมีความแม่นยำจำกัดและไม่สม่ำเสมอ โดยพัฒนาโมเดลการเรียนรู้เชิงลึกเพื่อเพิ่มประสิทธิภาพในการคัดแยกคุณภาพปลา โดยอาศัยการวิเคราะห์ภาพถ่าย โมเดลที่ใช้คือโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ที่ถูกฝึกด้วยชุดข้อมูลภาพถ่ายจำนวน 700 ภาพที่เก็บรวบรวมในระยะเวลา 7 วัน โดยมีการใช้ตัวเพิ่มประสิทธิภาพ ADAM ในการปรับพารามิเตอร์ระหว่างการฝึก เพื่อเพิ่มความแม่นยำในการจำแนกภาพ นอกจากนี้ยังได้พัฒนาแชทบอทผ่านแอปพลิเคชัน Line เพื่ออำนวยความสะดวกในการตรวจสอบคุณภาพปลาแบบเรียลไทม์ ผลการวิจัยแสดงให้เห็นว่า โมเดลที่พัฒนาสามารถจำแนกคุณภาพปลาได้ด้วยความแม่นยำสูงถึงร้อยละ 98.12 ซึ่งแสดงถึงศักยภาพในการนำไปประยุกต์ใช้ในอุตสาหกรรมการประมงได้อย่างมีประสิทธิภาพ

คำสำคัญ: การคัดแยกคุณภาพปลา การเรียนรู้เชิงลึก การประมวลผลภาพ แชทบอท

การอ้างอิงบทความ: อัจฉรา ชุมพล, สรายุทธ กรวิรัตน์, รณชัย สังหมั่นเม้า, นรงค์ วิชาผา, ปรีชาดิ เบอร์ขุนทด, แพรวา สีกาลุน และ ภัทรพล เกواهرิต, "การคัดแยกคุณภาพของปลาตะเพียนขาวด้วยวิธีการเรียนรู้เชิงลึกและแชทบอทสำหรับการวิเคราะห์ภาพถ่าย," วารสารวิศวกรรมและเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยกาฬสินธุ์, ปีที่ 2, ฉบับที่ 5, หน้า 44-51, 2567.

บทความวิจัย (Research Article)

Quality Sorting of Silver Barb Fish Using Deep Learning and Chatbot-Based Image Analysis

Atchara Choompol^{1,*}, Sarayut Gonwirat¹, Ronnachai Sangmuenmao¹, Narong Wichapa²,
Parichat Berkhuntod¹, Phaewa Sikalun¹ and Phattarapol Phaowarit³

¹ Department of Computer Engineering, Faculty of Engineering and Industrial Technology, Kalasin University

² Department of Industrial Engineering, Faculty of Engineering and Industrial Technology, Kalasin University

³ Department of Information Technology, Faculty of Science, Ubon Ratchathani University

* Corresponding Author: atchara.ch@ksu.ac.th

(Received: October 8, 2024; Revised: October 24, 2024; Accepted: October 29, 2024)

Abstract

This research aimed to address the limitations of manual quality sorting of silver barb fish, which suffered from limited accuracy and inconsistency. A deep learning model was developed to enhance the efficiency of fish quality classification based on image analysis. The model employed a Convolutional Neural Network (CNN), which was trained using a dataset of 700 images collected over a period of seven days. The ADAM optimizer was utilized to adjust the model's parameters during training, improving the accuracy of image classification. Additionally, a chatbot was developed through the Line Application to facilitate real-time fish quality inspection. The research findings demonstrated that the developed model classified fish quality with an accuracy of 98.12%, highlighting its potential for effective application in the fishing industry.

Keywords: Fish quality classification, Deep learning, Image classification, Chatbot

Please cite this article as: A. Choompol, S. Gonwirat, R. Sangmuenmao, N. Wichapa, P. Berkhuntod, P. Sikalun and P. Phaowarit, "Quality Sorting of Silver Barb Fish Using Deep Learning and Chatbot-Based Image Analysis," *The Journal of Engineering and Industrial Technology, Kalasin University*, vol. 2, no. 5, pp. 44-51, 2024.

บทความวิจัย (Research Article)

1. บทนำ

ในปัจจุบันอุตสาหกรรมการประมงของประเทศไทยมีบทบาทสำคัญอย่างยิ่งต่อเศรษฐกิจของประเทศ โดยเฉพาะในกลุ่มปลาน้ำจืด เช่น ปลาดุกเพียนและปลากะมัง ซึ่งถือเป็นวัตถุดิบหลักในกระบวนการผลิตอาหารแปรรูปต่าง ๆ ไม่ว่าจะเป็นปลาดุกแห้ง ปลาส้ม และผลิตภัณฑ์จากไขปลา สินค้าเหล่านี้มีความต้องการสูงทั้งในตลาดภายในประเทศและตลาดต่างประเทศ ความสำเร็จของอุตสาหกรรมนี้พึ่งพาคุณภาพของวัตถุดิบปลาอย่างมาก ซึ่งส่งผลต่อมูลค่าและความสามารถในการแข่งขันของผลิตภัณฑ์ในตลาด [1]

อย่างไรก็ตาม กระบวนการคัดแยกคุณภาพปลาที่ใช้อยู่ในปัจจุบันยังคงอาศัยการประเมินด้วยสายตามนุษย์ ซึ่งมีข้อจำกัดทั้งในด้านเวลา ความแม่นยำ และความสม่ำเสมอ การพึ่งพาแรงงานมนุษย์ในการคัดแยกปลาไม่เพียงทำให้เกิดข้อผิดพลาด แต่ยังทำให้กระบวนการมีต้นทุนสูง [2] การนำเทคโนโลยีใหม่ ๆ เช่น ปัญญาประดิษฐ์ (AI) และการเรียนรู้เชิงลึก (Deep Learning) เข้ามาช่วยในการคัดแยกคุณภาพปลาจึงเป็นสิ่งที่จำเป็นอย่างยิ่ง [3]

การประยุกต์ใช้เทคโนโลยี Deep Learning ในการคัดแยกคุณภาพปลานั้นเป็นแนวทางที่มีศักยภาพสูง เนื่องจากเทคโนโลยีนี้สามารถช่วยลดข้อผิดพลาดที่เกิดจากมนุษย์ได้ งานวิจัยที่ผ่านมาแสดงให้เห็นถึงศักยภาพของการใช้ Deep Learning ในการประมวลผลภาพสำหรับการจำแนกประเภทต่าง ๆ เช่น งานวิจัยของ Krizhevsky และคณะ (2012) ที่ได้พัฒนาโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) เพื่อใช้ในการจำแนกภาพจากชุดข้อมูล ImageNet [4] นอกจากนี้ งานวิจัยของ Chollet (2018) และ Li & Zhang (2022) ยังแสดงให้เห็นถึงความสำเร็จในการนำ CNN มาใช้ในการจำแนกคุณภาพปลาจากภาพถ่ายเช่นกัน [5][6] อย่างไรก็ตาม การพัฒนาโมเดลที่สามารถวิเคราะห์และจำแนกปลาจากข้อมูลภาพถ่ายได้อย่างแม่นยำนั้น จำเป็นต้องมี

การจัดการกับข้อจำกัดที่อาจเกิดขึ้นจากคุณภาพของภาพถ่าย เช่น แสงเงาที่แตกต่างกัน ความไม่สม่ำเสมอของระยะห่างในการถ่ายภาพ และการเก็บข้อมูลภาพถ่ายที่มีความหลากหลายเพียงพอ นอกจากนี้ ความท้าทายในการพัฒนาโมเดลที่สามารถใช้งานได้จริงในอุตสาหกรรมประมง เช่น การตรวจสอบความสดของปลาตามเวลาจริง และการตอบสนองที่รวดเร็วต่อการคัดแยกคุณภาพปลาจากภาพถ่าย ยังคงเป็นประเด็นที่ต้องพิจารณาในการพัฒนาเทคโนโลยีนี้

งานวิจัยนี้จึงมุ่งเน้นไปที่การนำเทคโนโลยีการเรียนรู้เชิงลึกมาใช้ในการคัดแยกคุณภาพปลาดุกเพียนขาวจากภาพถ่าย โดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) เพื่อวิเคราะห์และจำแนกปลาดุกเพียนขาวว่าสดหรือไม่สด อีกทั้งยังได้พัฒนาแอปพลิเคชัน Application Line เพื่ออำนวยความสะดวกให้กับผู้ใช้งานในการอัปโหลดภาพและรับผลการวิเคราะห์ในเวลาจริง ซึ่งการใช้งานเทคโนโลยีนี้จะช่วยลดข้อผิดพลาดจากมนุษย์ เพิ่มความแม่นยำในการคัดแยก และเพิ่มประสิทธิภาพการทำงานในอุตสาหกรรมประมงของไทย

2. แนวคิด ทฤษฎี และงานวิจัยที่เกี่ยวข้อง

การเรียนรู้เชิงลึก (Deep Learning) คือส่วนหนึ่งของปัญญาประดิษฐ์ (Artificial Intelligence: AI) ซึ่งเป็นวิธีการที่ให้ระบบคอมพิวเตอร์เรียนรู้และประมวลผลข้อมูลอย่างอัตโนมัติ โดยไม่ต้องมีการตั้งค่ากฎเกณฑ์ล่วงหน้า [4] แนวคิดนี้เกิดขึ้นจากการพัฒนาของการเรียนรู้ของเครื่อง (Machine Learning) ซึ่งมีความสามารถในการวิเคราะห์ข้อมูลเชิงซับซ้อน เช่น การประมวลผลภาพ การแยกแยะวัตถุ และการรู้จำคำพูด การเรียนรู้เชิงลึกทำงานโดยใช้โครงข่ายประสาทเทียม (Neural Network) ที่มีโครงสร้างหลายชั้น (Layered Structure) ซึ่งชั้นเหล่านี้จะช่วยให้โมเดลสามารถเรียนรู้และดึงคุณลักษณะสำคัญออกจากข้อมูลที่ป้อนเข้าไป

บทความวิจัย (Research Article)

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) เป็นหนึ่งในสถาปัตยกรรมที่นิยมใช้ในการประมวลผลภาพ ด้วยการสกัดคุณลักษณะเฉพาะจากภาพแล้วนำไปประมวลผลเพื่อจำแนกวัตถุในภาพ [7] CNN ถูกนำมาใช้ในหลายด้าน เช่น การวิเคราะห์ภาพทางการแพทย์ การรู้จำใบหน้า และการตรวจจับวัตถุจากภาพถ่ายหรือวิดีโอ

การประมวลผลภาพด้วยคอมพิวเตอร์ (Computer Vision) คือกระบวนการที่ทำให้คอมพิวเตอร์สามารถ "มองเห็น" และเข้าใจภาพดิจิทัลได้ เช่น การจำแนกประเภทของวัตถุในภาพ การตรวจจับวัตถุ และการแยกแยะลักษณะต่าง ๆ ของวัตถุ การประมวลผลภาพที่ใช้ในงานวิจัยนี้เป็นการจำแนกภาพ (Image Classification) โดยใช้ CNN ซึ่งเป็นวิธีที่ได้รับการพิสูจน์แล้วว่ามีความแม่นยำสูงในการประมวลผลภาพและการตรวจจับวัตถุที่อยู่ในภาพ [7] การประมวลผลภาพได้รับการพัฒนาอย่างต่อเนื่องและมีการนำไปใช้อย่างแพร่หลายในอุตสาหกรรม เช่น การวิเคราะห์ทางการแพทย์และระบบขับเคลื่อนอัตโนมัติ


จากการสำรวจงานวิจัยก่อนหน้านี้ซึ่งนำ Deep Learning มาใช้ในงานจำแนกภาพ ตัวอย่างเช่น งานวิจัยของ Chollet ที่ได้พัฒนาโมเดล CNN สำหรับจำแนกภาพและการประมวลผลข้อมูลภาพถ่ายที่มีคุณลักษณะแตกต่างกัน [8] และ Li และ Zhang ได้ทำการทดลองใช้ Deep Learning ในการจำแนกสายพันธุ์ปลาจากภาพถ่าย โดยใช้เทคนิค CNN เช่นกัน ผลลัพธ์จากงานวิจัยดังกล่าวได้แสดงให้เห็นถึงความแม่นยำที่สูงในการจำแนกสายพันธุ์ปลาผ่านการประมวลผลภาพถ่าย [9] อย่างไรก็ตาม งานวิจัยเหล่านี้ยังมีข้อจำกัดที่ควรพิจารณา เช่น การประเมินผลลัพธ์ในสถานะที่หลากหลาย งานวิจัยนี้ ผู้วิจัยได้พัฒนาและทดสอบโมเดลในสภาพแวดล้อมที่ใกล้เคียงกับสถานการณ์การใช้งานจริง เพื่อเพิ่มประสิทธิภาพในการคัดแยกคุณภาพปลา นอกจากนี้ ยังมีการพัฒนาแชทบอทที่เชื่อมต่อกับโมเดลเพื่อให้ผู้ใช้งานสามารถ

ประเมินคุณภาพปลาได้แบบเรียลไทม์ ซึ่งเป็นการเพิ่มมูลค่าในการประยุกต์ใช้เทคโนโลยีนี้ในอุตสาหกรรม

3. วิธีการดำเนินการวิจัย

ผู้วิจัยได้ดำเนินการเก็บรวบรวมข้อมูลโดยถ่ายภาพปลาตะเพียนขาวที่ถูกจัดเก็บในสถานะการแช่เย็นเพื่อตรวจสอบความสดของปลา ภาพถ่ายเหล่านี้ได้ถูกเก็บรวบรวมทุกวันเป็นระยะเวลา 7 วัน เพื่อสังเกตการเปลี่ยนแปลงของปลาตามช่วงเวลา โดยมีการควบคุมระยะห่างจากกล้องถ่ายภาพและความสูงที่เท่ากัน (50 เซนติเมตร) เพื่อให้ได้ภาพที่มีคุณภาพและความสม่ำเสมอในการประมวลผล จากนั้นข้อมูลภาพที่ได้จะถูกนำมาใช้ในการพัฒนาโมเดลการเรียนรู้เชิงลึก (Deep Learning) โดยใช้สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ซึ่งโมเดลจะถูกฝึกด้วยข้อมูลภาพถ่ายเหล่านี้เพื่อเรียนรู้คุณลักษณะที่บ่งบอกถึงความสดของปลา และสามารถจำแนกได้ว่าปลานั้นสดหรือไม่สด นอกจากนี้ยังมีการใช้ตัวเพิ่มประสิทธิภาพ ADAM เพื่อปรับพารามิเตอร์ของโมเดลในระหว่างการฝึก เพื่อเพิ่มความแม่นยำของการจำแนก ทั้งนี้โมเดลที่พัฒนาขึ้นได้ถูกเชื่อมต่อกับแชทบอทที่สร้างขึ้นผ่าน Line Messaging API โดยแชทบอทที่พัฒนาขึ้นสามารถรับภาพถ่ายจากผู้ใช้งานผ่านแอปพลิเคชันไลน์ และส่งผลการวิเคราะห์คุณภาพปลาให้ผู้ใช้งานแบบเรียลไทม์ ซึ่งช่วยให้ผู้ใช้งานสามารถตรวจสอบคุณภาพของปลาได้อย่างสะดวกและรวดเร็ว รายละเอียดขั้นตอนวิธีการดำเนินงานวิจัย แสดงดังรูปที่ 1

บทความวิจัย (Research Article)



รูปที่ 1 ขั้นตอนการดำเนินงานวิจัย

3.1 การเก็บรวบรวมข้อมูล

ผู้จัดทำได้ทำการศึกษาข้อมูลเกณฑ์การคัดแยกคุณภาพความสดของปลา จากการสัมภาษณ์ผู้ประกอบการผลิตภัณฑ์แปรรูปปลา ซึ่งได้คัดเลือกปลาสำหรับใช้ในกระบวนการแปรรูปผลิตภัณฑ์ตามความสดของปลา โดยที่ปลาที่มีการแช่เย็นไว้ไม่เกิน 2 วัน จัดเป็นปลาสด จะถูกนำไปแปรรูปเป็นผลิตภัณฑ์ปลาต้ม หากเลยระยะเวลาดังกล่าว จะถูกนำไปทำเป็นผลิตภัณฑ์ปลาร้า โครงการนี้จะทำการคัดแยกคุณภาพความสดของปลา โดยใช้ภาพถ่าย ซึ่งได้เก็บรวบรวมข้อมูลภาพถ่ายปลาในแต่ละวัน โดยการทดลองได้ทำการจัดเก็บภาพถ่ายเพื่อดูการเปลี่ยนแปลงของสภาพปลา เป็นเวลา 7 วัน และได้มีการออกแบบอุปกรณ์เก็บข้อมูลเพื่อให้เกิดสภาวะที่เหมาะสมในการเก็บข้อมูลภาพ ลดปัญหาสัญญาณรบกวนและเพื่อคงระยะการถ่ายภาพให้สม่ำเสมอเพื่อให้ง่ายต่อการประมวลผล โดยที่อุปกรณ์จัดเก็บ

ข้อมูลประกอบด้วย โทรศัพท์มือถือสำหรับถ่ายภาพ อุปกรณ์ถ่ายภาพซึ่งผู้จัดทำโครงการได้จัดให้มีระยะความสูง เท่ากับ 50 เซนติเมตร ดังแสดงในรูปที่ 2



รูปที่ 2 อุปกรณ์ถ่ายภาพ

ผู้วิจัยได้ทำการถ่ายภาพปลาในแต่ละวัน จำนวนภาพทั้งหมด 700 ภาพ แบ่งเป็น 2 กลุ่ม ได้แก่ กลุ่มปลาสด (อายุการจัดเก็บไม่เกิน 2 วัน) จำนวน 200 ภาพ และกลุ่มปลาไม่สด (อายุการจัดเก็บ 3 วันขึ้นไป) จำนวน 500 ภาพ ตัวอย่างชุดข้อมูลที่รวบรวม ดังแสดงในตารางที่ 1 ดังนี้

ตารางที่ 1 ภาพตัวอย่างชุดข้อมูล

วันที่	ภาพตัวอย่าง
วันที่ 1	
วันที่ 2	
วันที่ 3	

บทความวิจัย (Research Article)

วันที่	ภาพตัวอย่าง
วันที่ 4	
วันที่ 5	
วันที่ 6	
วันที่ 7	

3.2 วิธีการเตรียมข้อมูล

ในการเตรียมข้อมูล ผู้วิจัยได้นำภาพถ่ายที่รวบรวมมาปรับขนาดให้มีความละเอียด 224x224 พิกเซล เพื่อให้ได้มาตรฐานที่สอดคล้องกับความต้องการของการฝึกโมเดล และทำการกำจัดข้อมูลที่มีปัญหา เช่น ภาพที่ไม่ชัดเจนหรือภาพที่ไม่สมบูรณ์ ออกจากชุดข้อมูล เพื่อรักษาคุณภาพของข้อมูลที่ใช้ในการฝึกโมเดล จากนั้นใช้เทคนิคการเพิ่มข้อมูล (Data Augmentation) ซึ่งประกอบด้วย การพลิกภาพในแนวนอน การหมุนภาพในมุมต่าง ๆ และการปรับระดับแสงสว่าง เพื่อเพิ่มความหลากหลายของชุดข้อมูลและลดความเสี่ยงจากการเกิด overfitting

3.3 การพัฒนาโมเดล

โมเดลการเรียนรู้เชิงลึกที่ใช้ในการคัดแยกคุณภาพปลาน้ำจืดถูกพัฒนาขึ้นโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) โครงสร้างของ CNN ประกอบด้วย ชั้นคอนโวลูชัน (Convolutional Layer) ที่ทำหน้าที่

สกัดคุณลักษณะจากภาพ ชั้นพูลลิง (Pooling Layer) ที่ช่วยลดขนาดข้อมูล และชั้นเชื่อมต่อทั้งหมด (Fully Connected Layer) เพื่อจำแนกภาพ โมเดลนี้ใช้ตัวเพิ่มประสิทธิภาพ ADAM เพื่อปรับพารามิเตอร์ในระหว่างการฝึกโมเดล [11]

3.4 การพัฒนาแชทบอท


ในส่วนของการพัฒนา Chatbot เพื่อช่วยในการตรวจสอบคุณภาพปลาตะเพียนขาวแบบเรียลไทม์ ใช้ Python เวอร์ชัน 3.9.0 ร่วมกับ Flask ซึ่งเป็นเฟรมเวิร์กสำหรับสร้าง API และจัดการการเชื่อมต่อกับเซิร์ฟเวอร์ โดยใช้ Line Messaging API สำหรับการส่งและรับข้อมูลระหว่างผู้ใช้งานและเซิร์ฟเวอร์ เมื่อผู้ใช้งานอัปโหลดภาพปลาผ่านแอปพลิเคชัน Line ภาพจะถูกส่งไปยังเซิร์ฟเวอร์ที่รันโมเดล CNN ที่พัฒนาขึ้น กระบวนการนี้ใช้ TensorFlow และ Keras เวอร์ชัน 2.9.0 ในการประมวลผลภาพ โมเดล CNN จะทำการวิเคราะห์ภาพเพื่อจำแนกคุณภาพของปลาเป็น "สด" หรือ "ไม่สด" ผลการวิเคราะห์จะถูกส่งกลับผ่าน Line Messaging API เพื่อแจ้งผู้ใช้งานแบบเรียลไทม์ จากนั้นผู้วิจัยได้ทำการทดสอบระบบ Chatbot กับชุดข้อมูลทดสอบ เพื่อทำการประเมินประสิทธิภาพและตรวจสอบความแม่นยำในการวิเคราะห์ หลังจากนั้นได้ทำการปรับแต่งเพื่อให้การตอบสนองมีความถูกต้องและรวดเร็วมากยิ่งขึ้น ซึ่งการพัฒนา Chatbot นี้ช่วยให้การใช้งานเทคโนโลยี Deep Learning มีความสะดวกและสามารถนำไปประยุกต์ใช้ในอุตสาหกรรมการประมงได้อย่างมีประสิทธิภาพ โดยทำให้ผู้ใช้งานสามารถตรวจสอบคุณภาพปลาได้ทุกที่ทุกเวลาในรูปแบบเรียลไทม์ [12]

4. ผลการทดลอง

โมเดลที่พัฒนาขึ้นถูกทดสอบกับชุดข้อมูลที่ถูกแยกไว้สำหรับการทดสอบ โดยกำหนดข้อมูลสำหรับการฝึกโมเดลและข้อมูลสำหรับการทดสอบ 80:20 ผลการทดลองแสดงให้เห็นว่าโมเดล CNN ที่พัฒนา

บทความวิจัย (Research Article)

สามารถจำแนกคุณภาพของปลาตะเพียนได้อย่างมีประสิทธิภาพ โดยวัดจากค่าความถูกต้อง (Accuracy) เท่ากับ 98.12% โดยผลการวัดจากค่าความถูกต้อง (Accuracy) ด้วยการคำนวณ Confusion Matrix ที่บ่งบอกถึงการจำแนกที่ถูกต้องและผิดพลาด [13] ผลประสิทธิภาพโมเดลแสดงดังในรูปที่ 3 และรูปที่ 4



รูปที่ 3 ประสิทธิภาพความถูกต้องของโมเดลที่พัฒนา



รูปที่ 4 ค่าความผิดพลาดของโมเดล

นอกจากนี้ ผู้วิจัยได้ทดสอบการใช้งานแพลตฟอร์มที่พัฒนาขึ้น โดยส่งภาพปลาไปที่ไลน์แชทบอท จำนวน 50 รูป ประกอบด้วย ปลาสด 25 รูป และปลาไม่สด 24 รูป พบว่า สามารถระบุความสดของปลาได้ถูกต้อง 100%

5. สรุปผล

การวิจัยนี้ได้แสดงให้เห็นถึงศักยภาพของการใช้ Deep Learning ในการคัดแยกคุณภาพของปลา โดยโมเดลที่พัฒนาสามารถจำแนกความสดของปลาด้วยความแม่นยำสูง การพัฒนาแชทบอทช่วยเพิ่มความสะดวกในการนำไปใช้งานจริงในภาคอุตสาหกรรม ประมุง โดยเฉพาะในด้านการเพิ่มประสิทธิภาพและลดต้นทุนในการคัดแยกคุณภาพปลาตะเพียนขาว ด้วยการประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์และการเรียนรู้เชิงลึกผ่านโมเดล CNN ทำให้สามารถจำแนกคุณภาพปลาได้อย่างรวดเร็วและแม่นยำ ซึ่งช่วยลดการพึ่งพาแรงงานมนุษย์ที่อาจเกิดความผิดพลาด และทำให้กระบวนการคัดแยกมีความแม่นยำและสม่ำเสมอมากขึ้น นอกจากนี้ การพัฒนาแชทบอทที่เชื่อมต่อกับระบบยังช่วยให้สามารถตรวจสอบคุณภาพปลาได้ในรูปแบบเรียลไทม์ ส่งผลให้การจัดการคุณภาพปลาทำได้ง่ายและสะดวกขึ้น

การวิจัยในอนาคตอาจมุ่งเน้นไปที่การปรับปรุงความแม่นยำของโมเดลเพิ่มเติมด้วยการเพิ่มชุดข้อมูลและเพิ่มความหลากหลายของข้อมูลโดยขยายขอบเขตการจำแนกปลาสายพันธุ์อื่น ๆ [14]

6. เอกสารอ้างอิง

- [1] กรมประมง, "รายงานสถานการณ์การผลิตสัตว์น้ำในประเทศไทย ปี 2563," กรมประมง, กรุงเทพฯ, 2563.
- [2] สุทธิวัฒน์ เบญจกุล, "การตรวจสอบคุณภาพสัตว์น้ำ," มหาวิทยาลัยสงขลานครินทร์, สงขลา, 2548.
- [3] A. Krizhevsky, I. Sutskever, and G. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Proceedings of the Neural Information Processing Systems (NIPS)*, 2012.

บทความวิจัย (Research Article)

- [4] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-Based Learning Applied to Document Recognition," *Proceedings of the IEEE*, 1998.
- [5] F. Chollet, *Deep Learning with Python*, O'Reilly Media, United States, 2018.
- [6] T. Li and X. Zhang, "Deep Learning for Fish Species Classification," *Marine Technology Journal*, 2022.
- [7] A. Jain and B. Kamath, "Applications of Computer Vision in Object Detection," *International Journal of Computer Science*, 2020.
- [8] P. He and S. Li, "Convolutional Neural Network for Image Classification," Location not specified, 2019.
- [9] D. Kingma and J. Ba, "ADAM: A Method for Stochastic Optimization," *International Conference on Learning Representations (ICLR)*, 2015.
- [10] Line Corporation, "Line Messaging API documentation," Line Corporation, Japan, 2023.
- [11] X. Wang, "Applications of Deep Learning in Aquaculture," *Aquatic Science Review*, 2023.
- [12] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely Connected Convolutional Networks," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017.
- [13] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *International Conference on Learning Representations (ICLR)*, 2015.
- [14] R. Girshick, "Fast R-CNN," *International Conference on Computer Vision (ICCV)*, 2015.
- [15] O. Russakovsky et al., "ImageNet Large Scale Visual Recognition Challenge," *International Journal of Computer Vision (IJCV)*, 2015.