

การวินิจฉัยโรคในปลานิลด้วยปัญญาประดิษฐ์โดยใช้การเรียนรู้ของเครื่อง

ชนะชัย คำนาโฮม^{*1}, สุรเจษฎ์ ก้อนจันทร์² และ ถนัดกิจ ศรีโชค³

สาขาวิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยอุบลราชธานี 34190

Received: 25 April 2025; Revised: 27 July 2025; Accepted: 4 August 2025

บทคัดย่อ

โรคในปลานิล (*Oreochromis niloticus*) ส่งผลกระทบอย่างรุนแรงต่ออุตสาหกรรมการเพาะเลี้ยงสัตว์น้ำ ทำให้อัตราการตายของปลาสูงและก่อให้เกิดความสูญเสียทางเศรษฐกิจอย่างมีนัยสำคัญ วิธีการวินิจฉัยโรคแบบดั้งเดิมมักต้องอาศัยผู้เชี่ยวชาญเฉพาะทาง ซึ่งมีค่าใช้จ่ายสูง ใช้เวลานาน และอาจไม่สามารถเข้าถึงได้สำหรับเกษตรกรรายย่อย งานวิจัยนี้นำเสนอแนวทางการวินิจฉัยโรคในปลานิลโดยใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) โดยพัฒนาแบบจำลอง DFYOLO ซึ่งเป็นการปรับปรุง YOLOv5 ให้มีความแม่นยำและประสิทธิภาพสูงขึ้นสำหรับการตรวจจับโรคแบบเรียลไทม์ งานวิจัยนี้รวบรวมข้อมูลภาพถ่ายปลานิลที่มีสุขภาพดีและติดโรคจำนวน 1,795 ภาพ ซึ่งได้รับการติดป้ายกำกับโดยสัตวแพทย์เฉพาะทาง ก่อนนำมาใช้ในการฝึกและทดสอบแบบจำลอง การประเมินผลลัพธ์โดยใช้ค่าความแม่นยำ (Precision) ค่าการเรียกคืน (Recall) และค่าความแม่นยำเฉลี่ย (mAP50) พบว่า DFYOLO มีประสิทธิภาพสูงกว่าวิธีการแบบดั้งเดิม โดยให้ค่า Precision ร้อยละ 99.75, Recall ร้อยละ 99.31 และ mAP50 ร้อยละ 99.38 พร้อมความสามารถในการประมวลผลแบบเรียลไทม์ที่ 93.21 FPS ผลการศึกษานี้ชี้ให้เห็นถึงศักยภาพของปัญญาประดิษฐ์ในการเพิ่มประสิทธิภาพการวินิจฉัยโรคในอุตสาหกรรมเพาะเลี้ยงสัตว์น้ำ เพื่อความยั่งยืนในระยะยาว ทั้งนี้ งานวิจัยในอนาคตจะมุ่งเน้นการปรับปรุงความสามารถของแบบจำลองให้รองรับโรคในสัตว์น้ำชนิดอื่น รวมถึงการบูรณาการร่วมกับระบบเฝ้าระวังสิ่งแวดล้อม

คำสำคัญ: ปลานิล, การวินิจฉัยโรค, การประมวลผลภาพ, ระบบอัจฉริยะ, การเรียนรู้ของเครื่อง

* Corresponding author. E-mail: chanachai.kha.67@ubu.ac.th

¹ นักศึกษา ภาควิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยอุบลราชธานี

^{2,3} ผู้ช่วยศาสตราจารย์ ภาควิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยอุบลราชธานี

AI-Driven Disease Diagnosis in Nile Tilapia Using Machine Learning

Chanachai Khamnahom^{*1}, Surajet Khonjun² and Thanatkit Srichok³

Department of Industrial Engineering, Faculty of Engineering, Ubon Ratchathani University 34190

Received: 25 April 2025; Revised: 27 July 2025; Accepted: 4 August 2025

Abstract

Nile tilapia (*Oreochromis niloticus*) is a crucial species in aquaculture, but disease outbreaks pose significant threats to its production, leading to high mortality rates and severe economic losses. Traditional disease diagnosis methods rely on expert assessments, which are costly, time-consuming, and often inaccessible to small-scale farmers. This study proposes an advanced machine learning approach for disease diagnosis in Nile tilapia using DFYOLO, an optimized version of YOLOv5 designed for real-time and high-accuracy detection. A dataset of 1,795 images of healthy and diseased fish was collected and labeled by aquatic veterinary experts. The model was trained and evaluated using standard performance metrics, achieving an outstanding Precision of 99.75%, Recall of 99.31%, and mean Average Precision (mAP50) of 99.38%, while maintaining real-time processing capability at 93.21 FPS. The findings demonstrate that DFYOLO outperforms conventional models, providing a scalable and cost-effective solution for disease monitoring in aquaculture. Future research will explore its applicability to other aquatic species and integration with environmental monitoring systems for enhanced predictive disease management.

Keywords: Nile tilapia, disease diagnosis, image processing, intelligent system, machine learning

* Corresponding author. E-mail: chanachai.kha.67@ubu.ac.th

¹ Student from the Department of Industrial Engineering, Faculty of Engineering, Ubon Ratchathani University

^{2,3} Assistant Professor, Department of Industrial Engineering, Faculty of Engineering, Ubon Ratchathani University

1. บทนำ

1.1 หลักการและเหตุผล

การเพาะเลี้ยงปลานิลเป็นอุตสาหกรรมเกษตรน้ำที่มีความสำคัญ โดยเฉพาะในภูมิภาคเอเชียตะวันออกเฉียงใต้ ซึ่งมีสัดส่วนผลผลิตมากกว่าร้อยละ 70 ของผลผลิตปลานิลทั่วโลก [1] ในปี พ.ศ. 2562 ประเทศไทยเป็นผู้ผลิตปลานิลอันดับที่ 8 ของโลก โดยมีผลผลิตรวม 218,329 ตัน คิดเป็นมูลค่าทางเศรษฐกิจกว่า 11,036 ล้านบาท [2] อย่างไรก็ตาม อุตสาหกรรมนี้กำลังเผชิญกับปัญหาการระบาดของโรคที่ส่งผลกระทบต่อเกษตรกรและเศรษฐกิจโดยโรคที่พบ ได้แก่ Tilapia Lake Virus, Aeromonas Hydrophila และ Streptococcus Iniae ซึ่งสามารถทำให้อัตราการตายของปลานิลสูงถึงร้อยละ 80 ในบางฟาร์ม และสร้างความเสียหายทั่วโลกกว่า 3 พันล้านดอลลาร์สหรัฐต่อปี สำหรับประเทศไทยเพียงประเทศเดียว ความสูญเสียจากการระบาดของเชื้อแบคทีเรียระหว่างปี พ.ศ. 2561 - 2566 คิดเป็นมูลค่ากว่า 2 พันล้านบาท [3,4] นอกจากนี้ ในช่วงปี พ.ศ. 2562 - 2564 ประเทศฟิลิปปินส์ได้รับผลกระทบจากการระบาดของ Streptococcus Iniae ส่งผลให้ผลผลิตลดลงมากกว่าร้อยละ 50 คิดเป็นมูลค่าความเสียหายกว่า 1 ล้านดอลลาร์สหรัฐ ซึ่งกระทบต่อเกษตรกรรายย่อยที่ต้องพึ่งพาการเพาะเลี้ยงปลานิลเป็นแหล่งรายได้หลัก [5]

ฟาร์มปลานิลทั่วไปยังคงใช้วิธีการวินิจฉัยโรคแบบดั้งเดิม เช่น การสังเกตอาการภายนอกหรือการขอความเห็นจากชุมชนออนไลน์ (เช่น โพสต์รูปปลาในกลุ่มเกษตรบน Facebook) เพื่อระบุโรค ซึ่งวิธีเหล่านี้มีความเสี่ยงต่อความผิดพลาดสูง ตัวอย่างเช่น อาการภายนอกอย่างจุดแดงหรือแผลที่ผิวหนังอาจเกิดได้จากหลายโรค การประเมินด้วยตาเปล่าโดยไม่มีการทดสอบในห้องปฏิบัติการจึงอาจนำไปสู่วินิจฉัยผิดพลาดและการใช้ยาที่ไม่ถูกต้อง นอกจากนี้ การรอผู้เชี่ยวชาญมาตรวจหน้างานใช้เวลานาน ทำให้โรคลุกลามโดยไม่ทันรับมือทันเวลา ระบบวินิจฉัยโรคอัจฉริยะที่ใช้การประมวลผลภาพและปัญญาประดิษฐ์สามารถช่วยแก้ปัญหานี้ได้ โดยสามารถวิเคราะห์ภาพถ่ายปลาเพื่อระบุโรคอย่างรวดเร็วและแม่นยำ ลดการพึ่งพาผู้เชี่ยวชาญเฉพาะ

ทางและให้ผลลัพธ์ทันทีในฟาร์ม ช่วยให้เกษตรกรตัดสินใจรักษาได้ทันเวลาที่ ลดความสูญเสียจากการระบาดของโรค [6] อย่างไรก็ตาม การวินิจฉัยโรคโดยอาศัยเพียงการสังเกตอาการทางกายภาพอาจนำไปสู่การวินิจฉัยที่ผิดพลาด ส่งผลให้เกิดการใช้ยาที่ไม่เหมาะสม ซึ่งอาจเพิ่มความเสี่ยงของการดื้อยาและการแพร่ระบาดของโรคมมากขึ้น งานวิจัยนี้จึงมุ่งพัฒนาเทคโนโลยี Machine Learning เพื่อนำมาใช้ในการสร้างระบบวินิจฉัยโรคปลานิลที่มีความแม่นยำและรวดเร็ว อีกทั้งยังมีการพัฒนาแอปพลิเคชันที่ช่วยให้เกษตรกรสามารถวิเคราะห์อาการของปลาได้ด้วยตนเอง โดยใช้การประมวลผลภาพถ่ายและข้อมูลพฤติกรรมของปลาแบบอัตโนมัติ ซึ่งจะช่วยให้สามารถรักษาและป้องกันโรคได้ตั้งแต่ระยะเริ่มต้น ลดอัตราการตายของปลา และลดต้นทุนการเพาะเลี้ยงในระยะยาว [7]

ในประเทศไทย การวินิจฉัยโรคในปลานิลด้วยวิธีดั้งเดิมที่อาศัยการสังเกตอาการภายนอกและการตรวจสอบเบื้องต้น มักประสบปัญหาความไม่แม่นยำ เนื่องจากโรคต่างๆ อาจแสดงอาการคล้ายคลึงกัน ตัวอย่างเช่น โรคที่เกิดจากเชื้อแบคทีเรีย *Flavobacterium columnare* และ *Streptococcus spp.* ปลาที่ติดเชื้อ *F. columnare* มักแสดงอาการลอยหัวขึ้นบริเวณผิวน้ำหรือบริเวณที่มีการเติมอากาศ เหงือกเน่าโดยมีลักษณะคล้ายดินตะกอนเกาะบริเวณเหงือก ในขณะที่ปลาที่ติดเชื้อ *Streptococcus spp.* จะมีตาขุ่นขาวและโปน ไม่ค่อยว่ายน้ำ ลอยนิ่ง บางตัวว่ายน้ำคางส่วน [8]

แม้ว่าจะมีการศึกษาหลายฉบับที่นำ Machine Learning มาใช้ในการวินิจฉัยโรคในสัตว์น้ำ แต่การประยุกต์ใช้ในปลานิลยังคงมีข้อจำกัดหลายประการ โดยงานวิจัยที่ผ่านมาเน้นไปที่การตรวจจบบโรคในมนุษย์หรือสัตว์น้ำสายพันธุ์อื่น ทำให้ยังคงมีช่องว่างทางองค์ความรู้ (Research Gap) ที่ต้องได้รับการศึกษาเพิ่มเติม นอกจากนี้ การวินิจฉัยโรคในปลานิลมีความซับซ้อน เนื่องจากปลาสามารถติดเชื้อจากหลายปัจจัยพร้อมกัน หรือที่เรียกว่า co-infections ซึ่งยังไม่ได้มีการศึกษาอย่างครอบคลุม [9,10] อีกทั้งปัญหาด้านข้อมูล เช่น ความไม่สมบูรณ์ของชุดข้อมูลภาพถ่าย หรือความหลากหลายของสายพันธุ์ปลานิลในแต่ละพื้นที่ อาจทำให้การฝึกฝนแบบจำลอง Machine

Learning Model ไม่ครอบคลุมทุกกรณี ดังนั้น งานวิจัยนี้จึงมุ่งเน้นการสร้างชุดข้อมูลที่มีความครอบคลุมและผ่านการตรวจสอบจากผู้เชี่ยวชาญ เพื่อเพิ่มความแม่นยำของแบบจำลอง ตลอดจนออกแบบระบบที่สามารถใช้งานได้จริงในสภาพแวดล้อมของเกษตรกร โดยรองรับการทำงานแบบเรียลไทม์ และพัฒนาองค์ประกอบที่สามารถแจ้งเตือนเกษตรกรเกี่ยวกับภาวะโรคระบาดที่อาจเกิดขึ้น [11,12]

งานวิจัยนี้ใช้วิธีการที่ครอบคลุมทั้งการเก็บข้อมูล การพัฒนาโมเดล และการออกแบบระบบให้เหมาะสมกับการใช้งานจริง ในเบื้องต้น มีการรวบรวมข้อมูลภาพถ่ายปลานิลที่ติดเชื้อจากแหล่งต่าง ๆ รวมถึงข้อมูลพฤติกรรมของปลาที่แสดงอาการของโรค ระบบนี้ใช้เทคนิค Machine Learning โดยเน้นอัลกอริธึมที่ได้รับการพิสูจน์ว่ามีประสิทธิภาพสูงในงานด้านการวินิจฉัยโรค เช่น Convolutional Neural Networks (CNNs), Support Vector Machines (SVMs) และ Random Forests ข้อมูลทั้งหมดจะถูกนำมาผ่านกระบวนการประมวลผลและการฝึกโมเดลเพื่อให้สามารถจำแนกโรคที่พบบ่อยได้อย่างแม่นยำ งานวิจัยนี้คาดหวังว่าจะสามารถช่วยลดอัตราการเสียชีวิตของปลานิล ลดต้นทุนของเกษตรกร และส่งเสริมความยั่งยืนในอุตสาหกรรมเพาะเลี้ยงสัตว์น้ำในระยะยาว [13,14]

2. ทฤษฎีและการทบทวนวรรณกรรม

2.1 พื้นฐานโมเดล YOLO และความหมายของ DFYOLO

YOLO (You Only Look Once) สถาปัตยกรรมโครงข่ายประสาทเทียมเชิงลึกสำหรับงานตรวจจับวัตถุ (object detection) ที่มีแนวคิดสำคัญคือทำการทำนายพิกัดกรอบวัตถุและชนิดของวัตถุพร้อมกันในขั้นตอนเดียวของการประมวลผลภาพ แตกต่างจากวิธีแบบสองขั้นตอนที่ต้องสร้างภูมิประเทศวัตถุก่อนแล้วค่อยจำแนกชนิด (เช่น Faster R-CNN) วิธีการ YOLO แบ่งภาพออกเป็นกริดย่อย แล้วใช้โครงข่าย CNN ในการคาดการณ์ทั้งกรอบและคลาสของวัตถุสำหรับแต่ละส่วนกริดพร้อมกัน ทำให้การตรวจจับทำได้แบบ end-to-end ที่เรียนรู้ได้ ด้วยโครงสร้างนี้ YOLO จึงมีความรวดเร็วกว่าอัลกอริธึมตรวจจับวัตถุรุ่นก่อน ๆ ที่ต้องสแกนภาพหลายครั้ง โดย YOLO ได้รับการพัฒนาอย่างต่อเนื่องหลายรุ่น

แต่ละรุ่นมุ่งปรับปรุงทั้งความแม่นยำ ความเร็ว และประสิทธิภาพการใช้ทรัพยากร ดังนี้

YOLOv1 (2016) รุ่นแรกสุดที่นำเสนอแนวคิดการรวมการตรวจจับวัตถุเข้ากับการทำนายคลาสในโครงข่ายเดียว ผลที่ได้คือความเร็วในการตรวจจับสูง แต่มีข้อจำกัด เช่น การตรวจจับวัตถุขนาดเล็กในภาพยังทำได้ไม่ดีนัก และมีข้อผิดพลาดด้านตำแหน่งกรอบวัตถุเนื่องจากฟังก์ชันความสูญเสียที่ใช้อาจไม่เหมาะกับวัตถุหลายขนาด

YOLOv2 (YOLO9000, 2016) เพิ่มประสิทธิภาพขึ้นด้วยการใช้สถาปัตยกรรม Darknet-19 เป็นโครงข่ายหลัก และเสนอการฝึกแบบรวมข้อมูลตรวจจับและจำแนกร่วมกัน ทำให้รองรับชนิดวัตถุได้มากขึ้นถึง ~9000 ชนิด (จึงชื่อ YOLO9000) มีการเพิ่ม Batch Normalization เพื่อการฝึกที่เสถียร และเพิ่ม anchor boxes เพื่อให้จัดการวัตถุต่างขนาดได้ดีขึ้น รวมถึงปรับปรุงฟังก์ชันความสูญเสีย

YOLOv3 (2018) ปรับปรุงโครงข่ายหลักเป็น Darknet-53 ที่ลึกขึ้นและมี residual connections ทำให้เรียนรู้คุณลักษณะได้ดีขึ้น YOLOv3 ยังเพิ่มการทำนายหลายสเกล (multi-scale predictions) ที่สามารถจับคุณลักษณะทำให้ตรวจจับวัตถุขนาดเล็กได้มีประสิทธิภาพขึ้นอีกทั้งเปลี่ยนมาใช้ logistic classifier แทน softmax เพื่อรองรับการทำนายหลายป้ายกำกับ

YOLOv4 (2020) พัฒนาโดยนำเทคนิคหลายอย่างมารวมกัน มีการใช้โครงข่ายหลัก CSPDarknet53 (Cross-Stage Partial Darknet-53) ซึ่งผสม CSPNet เพื่อลดการซ้ำซ้อนของการคำนวณและเพิ่มความแม่นยำในการดึงคุณลักษณะ นอกจากนี้ YOLOv4 ยังเพิ่มโมดูล SPP (Spatial Pyramid Pooling) และ PANet ในส่วนคอข่าย (neck) เพื่อรวมคุณลักษณะหลายระดับอย่างมีประสิทธิภาพ และใช้ฟังก์ชันความสูญเสียแบบ CloU (Complete IoU) เพื่อปรับปรุงการจัดกรอบวัตถุ

YOLOv5 (2020) พัฒนาโดย Ultralytics (ไม่มีงานวิจัยตีพิมพ์อย่างเป็นทางการ) โดยปรับปรุงให้ใช้งานง่ายบน PyTorch และรองรับการฝึกโมเดลบนชุดข้อมูลใหม่ได้สะดวก YOLOv5 มีขนาดโมเดลย่อยให้เลือก (s, m, l, x) ตามความต้องการความเร็ว/ความแม่นยำ และมีการเพิ่มเทคนิค augmentation เช่น Mosaic augmentation ในการฝึกเพื่อ

แก้ปัญหาวัดขนาดเล็ก[นอกจากนี้ YOLOv5 ยังแนะนำการเลือก anchor อัตโนมัติตามข้อมูลชุดฝึก (auto-anchor) และรองรับการส่งออกโมเดลหลายรูปแบบเพื่อความสะดวกในการใช้งานจริง YOLOv5 ถูกออกแบบให้มีความเร็วสูงมาก โดยรายงานว่าสามารถประมวลผลได้ถึง ~140 FPS บน GPU ตัวเดียว ทั้งที่ ยังรักษาความแม่นยำใกล้เคียง YOLOv4 (สถาปัตยกรรม YOLOv5 นั้นคล้าย YOLOv4 มาก แต่ปรับปรุงขั้นตอนการฝึกและโค้ดให้มีประสิทธิภาพ) ในกรณี YOLOv5 ใช้โครงข่าย backbone ที่เรียกว่า CSPNet ที่มีโมดูลแบบ C3 ซึ่งช่วยลดจำนวนพารามิเตอร์และเพิ่มประสิทธิภาพการเรียนรู้คุณลักษณะ

DFYOLO (Deep Feature YOLO) เป็นโมเดลที่ผู้วิจัยพัฒนาขึ้นบนพื้นฐานของ YOLOv5 โดยมุ่งปรับปรุงให้เหมาะสมกับงานวินิจฉัยโรคปลาน้ำจืดมากขึ้นทั้งด้านความแม่นยำและความเร็วในการประมวลผล โมเดล DFYOLO นี้มีการแก้ไขสถาปัตยกรรมสำคัญหลายส่วนเมื่อเทียบกับ YOLOv5 ดั้งเดิม ได้แก่ โครงข่ายหลัก (Backbone) เปลี่ยนจากโครงข่ายแบบ CSPNet ของ YOLOv5 มาใช้ โมดูล C3 (Cross-Stage Partial Networks version3) อย่างเต็มรูปแบบในทุกส่วนที่เป็นคอขวด (bottleneck) เพื่อช่วยลดจำนวนพารามิเตอร์ลงโดยที่ยังรักษาความสามารถในการเรียนรู้คุณลักษณะสำคัญได้

การสกัดคุณลักษณะหลายขนาด เพิ่ม Convolution Kernel Group (Conv KG) ซึ่งคือชุดของคอนโวลูชันหลายขนาด (เช่น kernel 1×1, 3×3, 5×5, 7×7) ทำงานขนานกันภายในโมดูล เพื่อให้โมเดลสามารถสกัดคุณลักษณะของโรคได้หลากหลายระดับในชั้นเดียวกัน ช่วยในการดึงรายละเอียดของลักษณะโรคทั้งจุดเล็กและบริเวณกว้างพร้อมกัน (แนวคิดคล้ายการประมวลผล multiscale ที่แต่ละกลุ่มช่องสัญญาณใช้ kernel ขนาดต่างกันแล้วรวมผลลัพธ์เข้าด้วยกัน) เทคนิคนี้เพิ่มขอบเขตการรับรู้ (receptive field) ของโมเดลและเพิ่มความละเอียดในการตรวจจับลักษณะเฉพาะของโรค

กลไก Attention เสริมโมเดลด้วยโมดูล CBAM (Convolutional Block Attention Module) ซึ่งเป็นกลไก Attention ที่ผนวกเข้ากับสถาปัตยกรรม เพื่อให้เครือข่ายสามารถให้ความสนใจ (focus) กับบริเวณที่มีความสำคัญต่อการวินิจฉัยโรคมากขึ้น โดย CBAM จะเรียนรู้ปรับน้ำหนัก

ความสำคัญทั้งเชิงช่องสัญญาณ (Channel Attention) และเชิงพื้นที่ (Spatial Attention) ในแต่ละ Feature Map ผลคือโมเดลสามารถเน้นบริเวณรอยโรคหรือคุณลักษณะเด่นที่บ่งบอกโรคได้ดีขึ้น และมองข้ามฉากหลังหรือสัญญาณรบกวนที่ไม่เกี่ยวข้อง

การปรับปรุงทั้งสามส่วนนี้ทำให้ DFYOLO มีความสามารถสูงกว่า YOLOv5 ดั้งเดิมอย่างชัดเจน ทั้งด้านความแม่นยำในการจำแนกโรคและประสิทธิภาพการประมวลผลที่รองรับงานแบบเรียลไทม์ ในขณะที่ใช้ทรัพยากรน้อยกว่าจากจำนวนพารามิเตอร์ที่ลดลง ส่งผลให้ DFYOLO เหมาะสมอย่างยิ่งต่อการนำไปใช้จริงในฟาร์มปลาที่อาจมีข้อจำกัดด้านฮาร์ดแวร์ (เช่น อุปกรณ์ Edge ราคาประหยัด)

ตารางที่ 1 โครงสร้างและประสิทธิภาพเปรียบเทียบระหว่าง YOLOv5 และ DFYOLO

คุณลักษณะ/ ตัวชี้วัด	YOLOv5	DFYOLO
Backbone (โครงข่ายหลัก)	CSPNet (CSPDarknet 53) พร้อมโมดูล C3 บางส่วน	C3 Module แทนที่ CSPNet ตลอดเครือข่าย ลดพารามิเตอร์
Multi-scale features (คุณลักษณะหลายขนาด)	Conv มาตรฐาน (ขนาด 3×3 เป็นหลัก)	เพิ่ม Convolution Kernel Group (เช่น 1×1, 3×3, 5×5, 7×7) เพื่อสกัดคุณลักษณะหลายสเกล
Attention (กลไกเน้นจุดสำคัญ)	ไม่มี	เพิ่ม CBAM (Channel & Spatial Attention)
Head (ส่วนทำนายผล)	ชั้นทำนาย 3 สเกล (เหมือน YOLOv4)	ชั้นทำนาย 3 สเกล (เหมือนเดิม)
จำนวนพารามิเตอร์ (ล้าน)	7.2 (ขนาดรุ่นเล็ก โดยประมาณ 14.5 MB)	6.8 (ลดลง 5-10%, ตามการใช้หน่วยความจำ 13.6 MB)

คุณลักษณะ/ ตัวชี้วัด	YOLOv5	DFYOLO
ความเร็ว (FPS ที่ ความละเอียด เท่ากัน)	96.43 FPS	93.21 FPS
Precision (ความ แม่นยำเชิงบวก)	94.36%	94.36%
Recall (อัตราการ ตรวจพบ)	93.76%	93.76%
mAP50 (ค่าเฉลี่ย ความแม่นยำ)	94.52%	94.52%
ขนาดหน่วยความจำ โมเดล	14.5 MB	14.5 MB

หมายเหตุ: แพลตฟอร์มฮาร์ดแวร์ในการทดสอบคือ RTX 3080 Ti ค่าประสิทธิภาพของ YOLOv5 และ DFYOLO ข้างต้นมาจากการทดสอบชุดข้อมูลเดียวกันเพื่อความเที่ยงตรงในการเปรียบเทียบ

จากตารางข้างต้นจะเห็นว่า DFYOLO เหนือกว่า YOLOv5 ในทุกตัวชี้วัดด้านความแม่นยำ โดยมี Precision, Recall และ mAP50 สูงขึ้นอย่างชัดเจน นอกจากนี้การใช้ Convolution Kernel Group และ CBAM ทำให้โมเดล DFYOLO มีขนาดเล็กลงเล็กน้อยและโฟกัสไปที่ลักษณะสำคัญของโรคได้ดี ส่งผลให้อัตราการตรวจจับวัตถุผิดพลาดลดลง แม้ความเร็วของ DFYOLO จะลดลงเล็กน้อย (~3 FPS ต่ำกว่า YOLOv5) เนื่องจากขั้นตอนการคำนวณที่เพิ่มจากโมดูล attention แต่ยังคงอยู่ในระดับเรียลไทม์ (มากกว่า 90 FPS) ซึ่งเพียงพอสำหรับงานวินิจฉัยโรคจากภาพในสถานการณ์จริง

2.2 ทฤษฎีพื้นฐาน Convolutional Neural Network และ Attention Mechanism

Convolutional Neural Network (CNN) เป็นโครงข่ายประสาทเทียมแบบลึกที่มีความสามารถในการดึงคุณลักษณะจากข้อมูลภาพโดยอัตโนมัติ แต่ละชั้นคอนโวลูชันจะทำหน้าที่เป็นตัวกรองที่สกัดรูปแบบเฉพาะ (เช่น ขอบ รูปทรง พื้นผิว) จากภาพ ชั้นต้นของ CNN จะเรียนรู้คุณลักษณะระดับต่ำ (เช่น เส้นขอบหรือสี) ส่วนชั้นลึกจะผสานคุณลักษณะให้เกิดเป็นรูปแบบที่ซับซ้อนยิ่งขึ้นเพื่อนำไปใช้ในการจำแนก

หรือระบุตำแหน่งวัตถุ ในบริบทของงานวิจัยนี้ CNN คือหัวใจสำคัญของโมเดล YOLO/DFYOLO ที่ช่วยให้โมเดลเรียนรู้ลักษณะทางกายภาพของโรคปลา เช่น สีของแผลหรือความขุ่นของดวงตา โดยไม่ต้องระบุคุณลักษณะด้วยมนุษย์ล่วงหน้า

Attention Mechanism คือแนวคิดในการให้โมเดลเรียนรู้ว่าจะสนใจ ส่วนใดของข้อมูลมากเป็นพิเศษ กลไก Attention ถูกใช้แพร่หลายในงานด้านวิสัยทัศน์และภาษาธรรมชาติ เพื่อปรับปรุงประสิทธิภาพของโมเดลโดยการให้น้ำหนักกับข้อมูลสำคัญ ในกรณีของงานวินิจฉัยโรคปลา การใช้ Attention (เช่น CBAM ใน DFYOLO) จะช่วยให้โมเดลสามารถระบุบริเวณของภาพปลาที่มีสัญญาณของโรคและเน้นการวิเคราะห์บริเวณนั้นมากขึ้น [15]

ตัวอย่างเช่น CBAM จะคำนวณ Channel Attention เพื่อตรวจว่าช่องคุณลักษณะใดมีความหมายต่อการทำนายโรค (เช่น ช่องที่อาจแทนสีแดงของแผล หรือความขุ่นของดวงตา) และ Spatial Attention เพื่อตรวจหาตำแหน่งบนภาพที่เด่นชัด (เช่น ตำแหน่งของแผลบนตัวปลา) จากนั้นปรับเพิ่มหรือลดค่าน้ำหนักของคุณลักษณะตามความสำคัญ ผลลัพธ์คือโมเดลจะเน้นข้อมูลบริเวณรอยโรคหรืออาการผิดปกติ และลดความสนใจต่อฉากหลังหรือตำแหน่งที่ไม่เกี่ยวข้อง ทำให้ประสิทธิภาพการจำแนกดีขึ้น การผนวก Attention Mechanism เช่นนี้สอดคล้องกับหลักการในงานวิจัยสมัยใหม่ ที่พบว่าการรวม Attention เข้ากับ CNN ช่วยเพิ่มทั้งความแม่นยำและความสามารถในการอธิบายการตัดสินใจของโมเดลได้ดียิ่งขึ้น เช่น เราสามารถสร้างแผนที่ความสนใจเพื่ออธิบายว่าระบบให้ความสำคัญกับบริเวณใดของปลาในการวินิจฉัย

2.3 การเปรียบเทียบกับงานวิจัย

งานที่ใช้โมเดล YOLO รุ่นต่าง ๆ ได้แก่ YOLOv3, YOLOv4, และ YOLOv5 ซึ่งมีจุดเด่นแตกต่างกันไป เช่น YOLOv3 ที่ปรับปรุงประสิทธิภาพในการตรวจจับวัตถุขนาดเล็ก, YOLOv4 ที่ใช้โครงข่าย CSPDarknet53 เพื่อเพิ่มความแม่นยำ และ YOLOv5 ที่ออกแบบเพื่อรองรับการทำงานแบบเรียลไทม์และการใช้งานบนอุปกรณ์ขนาดเล็ก (Edge Devices) อย่างไรก็ตาม โมเดล DFYOLO ในงานวิจัยนี้ได้มีการปรับปรุงเพิ่มเติมจาก YOLOv5 โดยเฉพาะส่วนของการแทนที่ CSPNet ด้วย C3 Module เพื่อลดจำนวน

พารามิเตอร์ การเพิ่ม Conv Kernel Group (Conv KG) เพื่อช่วยให้โมเดลสกัดลักษณะเฉพาะของโรคได้ละเอียดขึ้น และการเสริม CBAM (Convolutional Block Attention Module) เพื่อเพิ่มประสิทธิภาพในการตรวจจับจุดสำคัญ ส่งผลให้ DFYOLO มีความแม่นยำและความเร็วในการประมวลผลสูงขึ้นกว่าโมเดลที่กล่าวมาข้างต้น พร้อมกับใช้ทรัพยากรต่ำลงอย่างชัดเจน ส่งผลให้ DFYOLO มีศักยภาพและความเหมาะสมสูงในการนำไปใช้งานจริงในฟาร์มเพาะเลี้ยงสัตว์น้ำ

2.4 งานวิจัยที่เกี่ยวข้อง

การศึกษาหลายฉบับได้เน้นถึงความก้าวหน้าทางเทคโนโลยีในการวินิจฉัยโรคปลานิล โดย Bohara et al. (2024) ศึกษาไวรัส Tilapia Lake Virus (TiLV) ซึ่งเป็นเชื้ออุบัติใหม่ที่ทำให้ปลานิลตายสูงถึงร้อยละ 90 โดยพบว่าเทคนิค Nested RT-PCR และ Oxford Nanopore Technologies (ONT) สามารถตรวจจับและจำแนกสายพันธุ์ของ TiLV ได้ภายใน 24 ชั่วโมง ช่วยให้สามารถควบคุมการระบาดของโรคได้อย่างรวดเร็ว [16] ขณะที่ Yamkasem et al. (2021) ศึกษา Parvovirus ในปลานิล (TiPV) ซึ่งทำให้เกิดอาการรุนแรง เช่น ตาโปน โลหิตจาง และมีเลือดออกที่ผิวหนัง การตรวจทางจุลพยาธิวิทยาพบการแทรกซึมของเม็ดเลือดขาวในเนื้อเยื่อที่ได้รับผลกระทบ แสดงให้เห็นถึงความรุนแรงของการติดเชื้อและความจำเป็นในการเฝ้าระวังโรคแบบเข้มข้น [17] ในขณะที่ Delamare-Deboutteville et al. (2023) ได้เปรียบเทียบเทคนิคทางชีวโมเลกุลสำหรับการตรวจหา TiLV พบว่า Nested RT-PCR มีความไวและความจำเพาะสูงสุด และเทคนิค ONT สามารถตรวจจับไวรัสได้อย่างรวดเร็ว ซึ่งเป็นโซลูชันที่มีศักยภาพในการพัฒนา Portable Diagnostic Systems สำหรับฟาร์มเพาะเลี้ยง [18]

นอกเหนือจากการตรวจวินิจฉัยโรคแล้ว ยังมีการใช้ Machine Learning (ML) เพื่อช่วยในการบริหารจัดการฟาร์มเพาะเลี้ยงปลานิล งานวิจัยโดยนักวิจัยยังได้วิเคราะห์เทคนิค Deep Learning ที่ใช้ในระบบเพาะเลี้ยงปลาอัจฉริยะ โดยพิจารณาประเภทข้อมูล อัลกอริทึมที่ใช้ และประสิทธิภาพของโมเดล เพื่อช่วยให้ผู้ปฏิบัติงานสามารถนำ

AI มาใช้ในฟาร์มเพาะเลี้ยงได้อย่างมีประสิทธิภาพ [19] ด้านการประยุกต์ใช้ ML ในการวิเคราะห์ภาพ Ahmed et al. (2022) ได้พัฒนา Convolutional Neural Networks (CNNs) เพื่อตรวจจับอาการผิดปกติของปลานิล เช่น แผลพุพอง จุดเลือดออก และการเปลี่ยนสีของผิวหนัง โดยมีความแม่นยำร้อยละ 92.7 ซึ่งสูงกว่าวิธีการตรวจด้วยสายตาของผู้เชี่ยวชาญ อย่างไรก็ตาม คุณภาพของภาพถ่าย เช่น แสงและมุมกล้อง ยังคงเป็นปัจจัยที่อาจส่งผลต่อความแม่นยำของโมเดล [20]

สำหรับแนวทางการพัฒนาระบบวินิจฉัยโรคที่มีประสิทธิภาพ Çakir et al. (2023) ได้ศึกษาการเปรียบเทียบประสิทธิภาพของอัลกอริทึม ML หลายรูปแบบ พบว่า SVM มีความแม่นยำสูงสุดในการจำแนกโรคที่เกิดจากเชื้อแบคทีเรีย เช่น *Streptococcus iniae* และ *Aeromonas hydrophila* โดยแนะนำให้ใช้ Ensemble Learning ซึ่งรวมอัลกอริทึมหลายตัวเข้าด้วยกันเพื่อเพิ่มความแม่นยำในการวินิจฉัย [21] ขณะที่ Palaiokostas (2021) ศึกษาการใช้ ML ในการพยากรณ์ความสามารถในการต้านทานโรคของปลานิล โดยใช้ข้อมูลพันธุกรรมและลักษณะทางฟีโนไทป์ พบว่าโมเดล Random Forest และ Gradient Boosting สามารถทำนายระดับความต้านทานโรคของปลาได้แม่นยำร้อยละ 89.4 ซึ่งช่วยให้สามารถคัดเลือกพ่อแม่พันธุ์ที่มีภูมิคุ้มกันสูงเพื่อนำไปเพาะเลี้ยงต่อไปได้อย่างแม่นยำมากขึ้น งานวิจัยเหล่านี้แสดงให้เห็นถึงศักยภาพของ AI และเทคโนโลยีชีวโมเลกุล ในการเพิ่มประสิทธิภาพของการวินิจฉัยและควบคุมโรคปลานิล ซึ่งจะช่วยลดความสูญเสียและเพิ่มผลผลิตในอุตสาหกรรมเพาะเลี้ยงสัตว์น้ำ [22]


3. วิธีการดำเนินการวิจัย

งานวิจัยนี้พัฒนาแบบจำลองการเรียนรู้ของเครื่องเพื่อวินิจฉัยโรคในปลานิล โดยออกแบบกระบวนการตั้งแต่การเก็บข้อมูล ประมวลผล ไปจนถึงการฝึกและทดสอบโมเดล ชุดข้อมูลภาพปลานิลที่ติดเชื้อและไม่ติดเชื้อถูกเตรียมพร้อมด้วย Data Augmentation ก่อนนำไปฝึกโมเดลและแบ่งเป็นชุดฝึก-ทดสอบ ประสิทธิภาพของโมเดล

ถูกประเมินด้วย Accuracy, Precision, Recall และ F1-Score เมื่อได้โมเดลที่แม่นยำที่สุด ระบบจะถูกทดสอบกับข้อมูลจริงจากฟาร์มเพาะเลี้ยงเพื่อยืนยันการทำงานในสภาพแวดล้อมจริง

3.1 การเก็บข้อมูล

ข้อมูลที่ใช้ในการวิจัยนี้ถูกเก็บจากฟาร์มเพาะเลี้ยงปลานิลในพื้นที่ลุ่มแม่น้ำโขง ซึ่งเป็นแหล่งเพาะเลี้ยงปลานิลที่สำคัญของประเทศไทย ข้อมูลภาพถูกถ่ายจากปลานิลที่แสดงอาการของโรคและปลาปกติ โดยใช้กล้องถ่ายภาพนิ่งคุณภาพสูงและกล้องใต้น้ำเพื่อบันทึกพฤติกรรมของปลา ข้อมูลถูกแบ่งออกเป็น 5 กลุ่ม ได้แก่ ปลาปกติ (Normal), โรคสเตรปโตคอคโคซิส (Streptococcosis), โรคไวรัส Tilapia Lake Virus (TiLV), โรคพยาธิ (Parasitic diseases), และโรคแบคทีเรีย Aeromonas hydrophila รวมทั้งรวม 1,795 ภาพ ดังตารางที่ 1



รูปที่ 1 กระบวนการตรวจสอบและวิเคราะห์โรคในปลานิล

ข้อมูลภาพภายใต้การตรวจสอบและติดป้ายกำกับ (Labeling) โดยผู้เชี่ยวชาญด้านสัตวแพทย์สัตว์น้ำ เพื่อลดความผิดพลาดของข้อมูลที่ใช้ฝึกโมเดล นอกจากนี้ยังมีการรวบรวมข้อมูลคุณภาพน้ำ เช่น ค่า pH, อุณหภูมิ และระดับออกซิเจน ซึ่งอาจมีผลต่อสุขภาพของปลา ข้อมูลทั้งหมดถูกจัดเก็บในรูปแบบฐานข้อมูลดิจิทัลเพื่อให้สามารถเข้าถึงและใช้งานได้สะดวกในการฝึกโมเดล Machine Learning

รูปที่ 1 แสดงกระบวนการตรวจสอบและวิเคราะห์โรคในปลานิลโดยใช้เทคโนโลยี Machine Learning โดยเริ่มจากการถ่ายภาพปลานิลที่อาจมีความผิดปกติภายในฟาร์มเลี้ยง จากนั้นภาพถูกส่งให้ผู้เชี่ยวชาญทำการ

ตรวจสอบและระบุประเภทของโรค เช่น โรคแบคทีเรียไวรัส หรือปรสิต ข้อมูลภาพถูกนำเข้าสู่ Vision Layer เพื่อผ่านกระบวนการเรียนรู้แบบมีผู้สอน (Supervised Learning) ซึ่งใช้ Deep Learning Models เช่น VGGNet, GoogLeNet และ ResNet ในการวิเคราะห์โครงสร้างภาพ การดึงคุณลักษณะสำคัญ และการแบ่งส่วนเป้าหมาย เมื่อตรวจสอบเสร็จสิ้น ระบบจะทำการตัดสินใจ หากปลาไม่สุขภาพดี ระบบจะอนุญาตให้ดำเนินการเลี้ยงต่อไป (Tilapia Farming Operation) แต่หากพบความผิดปกติ ระบบจะส่งสัญญาณแจ้งเตือนเพื่อให้เกษตรกรดำเนินการแก้ไขปัญหา

3.2 อุปกรณ์และเครื่องมือที่ใช้ในการเก็บข้อมูล (Data Collection Tools)

3.2.1 กล้องถ่ายรูป

กล้อง Mirrorless ที่ใช้ในการถ่ายภาพปลานิลมีความละเอียดสูงและสามารถจับรายละเอียดได้อย่างแม่นยำด้วยเซนเซอร์รับภาพขนาดใหญ่และระบบบอดี้โฟกัสที่รวดเร็ว การถ่ายภาพปลานิลบ่งชี้การดำเนินการภายใต้สภาพแสงที่เหมาะสม โดยใช้ฉากหลังที่มีความคมชัดและแสงไฟเสริมเพื่อลดเงาสะท้อน พร้อมทั้งใช้ขาตั้งกล้องเพื่อลดการสั่นไหว

3.2.2 กล้องใต้น้ำ

กล้องใต้น้ำ เช่น กล้อง CCTV Digital IP Network ความละเอียดสูง และกล้องใต้น้ำเพื่อให้แน่ใจว่าได้ข้อมูลภาพที่ละเอียดและหลากหลาย ซึ่งแสดงถึงลักษณะและพฤติกรรมของปลาในสภาวะต่างๆ รวมถึงข้อมูลเพิ่มเติมเกี่ยวกับลักษณะของโรค เช่น การแสดงบนผิวหนัง สาเหตุและอาการ ดังรูปที่ 2



รูปที่ 2 อุปกรณ์ถ่ายรูปปลานิลแบบบนน้ำและใต้น้ำ

ตารางที่ 2 จำนวนรูปภาพชุดข้อมูลสำหรับการสอน (Training set) และชุดข้อมูลสำหรับทดสอบ (Test set)

ชนิดโรคของปลานิล	จำนวนข้อมูลภาพ		
	ชุดเรียนรู้ (Training set)	ชุดทดสอบ (Test set)	รวมทั้งหมด (Total)
โรคสเตรปโตคอคคัส (Streptococcosis)	227	98	325
โรคไวรัสทิลapiaเปื้อนเลือด (Tilapia Lake Virus Disease)	247	106	353
โรคพยาธิ (Parasitic diseases)	237	102	339
โรคแบคทีเรียแอโรโมนาส เซ็ปติซีเมีย (Motile Aeromonas Septicaemia)	268	115	383
ปลานิลปกติ (Normal Nile Tilapia)	276	119	395
รวม	1,255	540	1,795

3.3 Machine Learning Model Development

3.3.1 โมเดลพื้นฐาน YOLOV5

1. C3 Module (Concentrated-Comprehensive Convolution Block) การพัฒนา DFYOLO ได้เลือกใช้ C3 Module เข้ามาแทนที่โครงสร้าง Bottleneck CSPNet (Cross Stage Partial Networks) แบบดั้งเดิมใน YOLOv5 โดยมีวัตถุประสงค์หลักเพื่อเพิ่มประสิทธิภาพการไหลเวียนของ Gradient ในระหว่างการทำ Backpropagation และลดความซ้ำซ้อนของข้อมูล (Redundant Gradient Information)

หลักการทำงานของ C3 Module ทำงานโดยแยก Feature Map ออกเป็นสองส่วน ส่วนหนึ่งผ่านกระบวนการ Convolution ย่อย และอีกส่วนหนึ่งจะถูกส่งข้าม (Skip connection) ไปรวมกับผลลัพธ์สุดท้ายโดยตรง เทคนิคนี้ช่วยลดจำนวนพารามิเตอร์ (Parameters) และ Floating Point Operations (FLOPs) ลงได้ประมาณ 10-20% เมื่อเทียบกับ CSPBottleneck เดิม

ผลลัพธ์ การปรับเปลี่ยนนี้ส่งผลให้โมเดลมีน้ำหนักเบาขึ้น (Lightweight) เพิ่มความเร็วในการประมวลผล (Inference Speed) บนอุปกรณ์ Edge Device โดยไม่สูญเสียความแม่นยำในการตรวจจับลักษณะสำคัญ [23]

2. Convolution Kernel Group (Conv KG) เพื่อให้โมเดลสามารถตรวจจับลักษณะโรคที่มีความหลากหลายของขนาด (Scale Variation) ได้ดียิ่งขึ้น งานวิจัยนี้ได้ประยุกต์ใช้ Convolution Kernel Group (Conv KG) ซึ่งเป็นเทคนิคการใช้ Kernel หลายขนาดทำงานขนานกัน (Multi-branch Architecture) คล้ายกับโครงสร้าง Inception Module

หลักการทำงาน แทนที่จะใช้ Kernel ขนาด 3×3 เพียงอย่างเดียว Conv KG จะใช้ชุดของ Kernel ขนาด 1×1 , 3×3 , 5×5 , และ 7×7 ทำงานร่วมกันใน Layer เดียวกัน

Kernel ขนาดเล็ก (1×1 , 3×3) ทำหน้าที่สกัดรายละเอียดพื้นผิว (Texture) ที่ละเอียดอ่อน เช่น จุดเลือดออกเล็กๆ หรือรอยปรุสีเทาผิว

Kernel ขนาดใหญ่ (5×5 , 7×7) ทำหน้าที่ขยาย Receptive Field เพื่อมองเห็นโครงสร้างโดยรวม เช่น รูปทรงที่บิดเบี้ยวของปลา หรืออาการตาโปน

ผลลัพธ์ การรวมผลลัพธ์ (Concatenation) จากหลาย Kernel ช่วยให้ DFYOLO สามารถมองเห็น ทั้งจุดเล็กๆ และอาการภาพรวมได้พร้อมกัน เพิ่มค่า Recall ในการตรวจจับโรคที่มีอาการแสดงขนาดเล็กได้อย่างมีนัยสำคัญ

3. Convolutional Block Attention Module (CBAM) ปัญหาความซับซ้อนของฉากหลัง (เช่น น้ำขุ่น หรือเงาสะท้อน) มักทำให้โมเดลเกิดความผิดพลาด งานวิจัยนี้จึงติดตั้ง CBAM ซึ่งเป็นกลไก Attention Mechanism ที่ทำงาน 2 ขั้นตอนต่อเนื่องกัน

Channel Attention Module (CAM) พิจารณาว่าฟีเจอร์ใดสำคัญ โดยการใช้ Global Average Pooling และ Max Pooling เพื่อหาความสัมพันธ์ระหว่าง Channel ของภาพ ทำให้โมเดลเรียนรู้ที่จะโฟกัสที่ "สีของแผล" หรือ ความขุ่นของตา มากกว่าสีของน้ำ

Spatial Attention Module (SAM) พิจารณาว่าตำแหน่งใดสำคัญ โดยการสร้าง Spatial Map เพื่อระบุพิกัดของรอยโรคบนตัวปลา

ผลลัพธ์ การใช้ CBAM เปรียบเสมือนการชี้นำสายตาของโมเดลให้โฟกัสเฉพาะบริเวณที่ผิดปกติ (Region of Interest) ช่วยลดค่า False Positive ที่เกิดจากสิ่งรบกวนในน้ำ และเพิ่มความแม่นยำ (Precision) ในสภาพแวดล้อมที่ไม่เอื้ออำนวย [24]


4. Enhanced Loss Function (CloU Loss) เพื่อให้กรอบการตรวจจับ (Bounding Box) มีความแม่นยำสูงสุด งานวิจัยนี้ได้ปรับปรุง Loss Function จากเดิมที่เป็น GloU (Generalized IoU) มาใช้ CloU (Complete IoU) [25] หลักการทำงานของ CloU ไม่เพียงแต่คำนวณพื้นที่ทับซ้อน (Overlap Area) แต่ยังคำนึงถึงปัจจัยทางเรขาคณิตอีก 2 ประการ คือ ระยะห่างระหว่างจุดศูนย์กลาง (Central Point Distance) และ อัตราส่วนกว้างยาว (Aspect Ratio) ของกล่องทำนายเทียบกับกล่องจริง

ผลลัพธ์ ช่วยให้การตีกรอบตำแหน่งโรคกระชับและตรงจุดมากขึ้น ลดปัญหาการตรวจจับที่กรอบลอยหรือไม่ครอบคลุมรอยโรคทั้งหมด (Misalignment) และช่วยให้โมเดลเข้าสู่ค่าที่ถูกต้อง (Convergence) ได้เร็วกว่าเดิมในระหว่างการฝึกสอน

3.3.2 การเปรียบเทียบโมเดล

DFYOLO (Deep Feature YOLO) เป็นโมเดลที่พัฒนาต่อยอดจาก YOLOv5 โดยปรับปรุงให้สามารถตรวจจับโรคในปลานิลได้แม่นยำยิ่งขึ้น พร้อมทั้งลดภาระการคำนวณเพื่อรองรับการทำงานแบบเรียลไทม์ การพัฒนาโครงสร้างของ DFYOLO รวมถึง การแทนที่ CSPNet ด้วย C3 Module เพื่อลดภาระการคำนวณและเพิ่มประสิทธิภาพในการดึงคุณลักษณะของโรค การใช้ Convolution Kernel Group (Conv KG) เพื่อช่วยให้โมเดลสามารถดึงข้อมูลพื้นผิวของปลาได้ละเอียดขึ้น การเพิ่ม Convolutional Block Attention Module (CBAM) ซึ่งช่วยให้โมเดลสามารถโฟกัสบริเวณที่เป็นโรคได้แม่นยำขึ้นผ่านกลไก Spatial และ Channel Attention และ การปรับปรุง Loss

Function เพื่อช่วยลด False Positive และ False Negative ดังรูปที่ 3



รูปที่ 3 โครงสร้างและประสิทธิภาพของ DFYOLO Model ประสิทธิภาพของ DFYOLO ถูกเปรียบเทียบกับ

1. Faster R-CNN โมเดลตรวจจับแบบสองขั้นตอนที่มีความแม่นยำสูงแต่ประมวลผลช้ากว่า
2. YOLOv3 เวอร์ชันเก่าของ YOLO ที่ใช้เลเยอร์คอนโวลูชันมาตรฐาน
3. YOLOv4 เวอร์ชันที่ได้รับการปรับแต่งโดยใช้ CSPDarknet53 สำหรับการดึงคุณลักษณะ

3.4 การประเมินผลการทำงาน

3.4.1 เมตริกการประเมินผล

การประเมินผลประสิทธิภาพของโมเดลใช้ค่าความแม่นยำ (Accuracy) โดยคำนวณจากจำนวนข้อมูลที่ทำนายถูกต้องเปรียบเทียบกับข้อมูลจริง [26] แสดงดังสมการที่ 1

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \times 100 \quad (1)$$

เมื่อ

TP (True Positive) หมายถึง ข้อมูลที่ทำนายถูกต้องเชิงบวก

TN (True Negative) หมายถึง ข้อมูลที่ทำนายถูกต้องเชิงลบ

FP (False Positive) หมายถึง ข้อมูลที่ทำนายผิดเป็นเชิงบวก

FN (False Negative) หมายถึง ข้อมูลที่ทำนายผิดเป็นเชิงลบ

นอกจากนี้ โมเดลยังถูกทดสอบซ้ำ 3 ครั้งในแต่ละการตั้งค่าพารามิเตอร์ เพื่อหาค่าเฉลี่ยที่ดีที่สุดสำหรับการพัฒนาโมเดลที่มีความแม่นยำสูงสุด

3.4.2 การตั้งค่าการทดลอง

1. ฮาร์ดแวร์ Intel Core i7-9700K CPU, NVIDIA GeForce RTX 3080 Ti GPU

2. ซอฟต์แวร์ Python พร้อม PyTorch, OpenCV สำหรับการประมวลผลภาพ

3. การตั้งค่าการฝึกอบรม Batch size = 16, Learning rate = 0.01, Epochs = 475

อธิบายเพิ่มเติม Batch size = 16 ถูกเลือกเนื่องจากเป็นค่าที่สมดุลระหว่างประสิทธิภาพการเรียนรู้และข้อจำกัดด้านหน่วยความจำ GPU

Learning rate = 0.01 เป็นค่าที่ให้ผลดีที่สุดในการลด Loss อย่างมีเสถียรภาพ จากการทดลองค่าต่าง ๆ (เช่น 0.001, 0.005, 0.01, 0.02)

Epochs = 475 มาจากการทดสอบช่วง 300-500 Epochs โดยพบว่าโมเดลมีความแม่นยำสูงสุดและไม่มี Overfitting ที่จุดนี้ นอกจากนี้ มีการใช้ Grid Search ในการทดลองค่าต่าง ๆ ของ Batch size และ Learning rate เพื่อหาค่าที่เหมาะสมที่สุด

3.5 การเปรียบเทียบผลลัพธ์

DFYOLO เป็นโมเดลที่ได้รับการปรับแต่งจาก YOLOv5 เพื่อเพิ่มประสิทธิภาพในการวินิจฉัยโรคในปาลานิล โดยเสริมความสามารถในการตรวจจับด้วย C3 Module, Convolution Kernel Group (Conv KG) และ CBAM ซึ่งช่วยให้สามารถโฟกัสไปที่จุดที่มีลักษณะเฉพาะของโรคได้แม่นยำขึ้น นอกจากนี้ ยังมีการเปรียบเทียบกับ Faster R-CNN ซึ่งเป็นโมเดลที่มีความแม่นยำสูงแต่ใช้เวลาประมวลผลนานกว่า, YOLOv3 ที่เป็นเวอร์ชันเก่าของ YOLO และ YOLOv4 ที่ได้รับการพัฒนาให้ดึงคุณลักษณะได้ดียิ่งขึ้นจาก CSPDarknet53 การเปรียบเทียบผลลัพธ์ของโมเดลแสดงในตารางที่ 3

ตารางที่ 3 การเปรียบเทียบประสิทธิภาพของโมเดล

โมเดล	Precision (%)	Recall (%)	mAP50 (%)	FPS	หน่วยความจำที่ใช้ (MB)
Faster R-CNN	86.18	83.28	79.87	57.97	77.8
YOLOv3	82.38	86.12	90.99	69.44	62.1
YOLOv4	93.58	93.84	93.39	78.24	226
YOLOv5	94.36	93.76	94.52	96.43	14.5
DFYOLO	99.75	99.31	99.38	93.21	13.6

โมเดล DFYOLO ที่เสนอช่วยเพิ่มประสิทธิภาพในการวินิจฉัยโรคในปาลานิลได้อย่างมีนัยสำคัญ โดยมี ความแม่นยำ (accuracy), ค่ารีคอล (recall) และค่าความแม่นยำเฉลี่ย (precision) ที่สูงกว่าโมเดลที่มีอยู่ โมเดลนี้ยังคงประสิทธิภาพการทำงานแบบเรียลไทม์ที่ 93.21 FPS พร้อมทั้งใช้หน่วยความจำที่ต่ำกว่า ผลลัพธ์เหล่านี้แสดงให้เห็นถึงศักยภาพของระบบอัตโนมัติที่ขับเคลื่อนด้วย AI ในอุตสาหกรรมการเพาะเลี้ยงสัตว์น้ำ เพื่อป้องกันโรคและปรับปรุงสุขภาพของปลาให้ดีขึ้น

4. ผลการวิจัย

4.1 การประเมินประสิทธิภาพของโมเดล

โมเดล DFYOLO ได้รับการประเมินโดยใช้ตัวชี้วัด Precision, Recall, Mean Average Precision (mAP50), Frames Per Second (FPS) และหน่วยความจำที่ใช้ โดยเปรียบเทียบกับโมเดลอื่น ๆ เช่น Faster R-CNN, YOLOv3, YOLOv4 และ YOLOv5

ผลการเปรียบเทียบในตารางที่ 3 แสดงให้เห็นว่า DFYOLO มีประสิทธิภาพสูงสุด โดยสามารถทำได้ Precision ร้อยละ 99.75, Recall ร้อยละ 99.31 และ mAP50 ร้อยละ 99.38 พร้อมทั้งยังสามารถทำงานได้แบบเรียลไทม์ และใช้ทรัพยากรหน่วยความจำน้อยที่สุด


4.2 การวิเคราะห์ Feature Importance

จากการวิเคราะห์ด้วยเทคนิค Grad-CAM (Gradient-weighted Class Activation Mapping) และ Feature Map Visualization พบว่าโมเดลให้ความสำคัญ

กับพีเจอร์หลัก ได้แก่ (1) บริเวณรอบดวงตา ซึ่งช่วยระบุอาการของโรคติดเชื้อสเตรปโตคอคคัสที่ทำให้เกิดตาขุนขาวหรือโปน (2) สีและพื้นผิวของผิวหนัง ซึ่งสำคัญต่อการตรวจจับโรคแบคทีเรียและปรสิตที่ทำให้เกิดแผลพุพอง (3) รูปแบบพฤติกรรมของปลา เช่น การเอียงตัวหรือว่ายน้ำผิดปกติ ซึ่งเป็นอาการของโรคไวรัส Tilapia Lake Virus (TiLV)

4.3 การวิเคราะห์ Confusion Matrix

เพื่อประเมินความสามารถของโมเดลในการจำแนกโรคของปลานิล Confusion Matrix ถูกสร้างขึ้นจากชุดทดสอบ 540 ภาพ ใน 5 กลุ่มโรค ผลลัพธ์แสดงให้เห็นว่าโมเดลสามารถจำแนกโรคได้อย่างแม่นยำ โดยมีข้อผิดพลาดเล็กน้อยในการจำแนกโรคที่มีลักษณะใกล้เคียงกัน เช่น โรคพยาธิและโรคเมทิลแอโรโมนาสเซ็ปติซีเมีย



รูปที่ 4 Confusion Matrix

ค่าบนเส้นทแยงมุมของเมทริกซ์ แสดงให้เห็นว่าโมเดลสามารถจำแนกโรคได้อย่างถูกต้องสูงมาก ในขณะที่ค่าที่อยู่นอกเส้นทแยงมุมมีจำนวนน้อย ซึ่งหมายความว่าโมเดลมีอัตราการคาดการณ์ที่ผิดพลาดต่ำ และสามารถใช้งานได้อย่างมีประสิทธิภาพ อธิบายเพิ่มเติมคือ

True Positive (TP) จำนวนครั้งที่โมเดลทำนายว่ามีโรคและเป็นโรคจริง

True Negative (TN) จำนวนครั้งที่โมเดลทำนายว่าไม่มีโรคและไม่มีโรคจริง

False Positive (FP) จำนวนครั้งที่โมเดลทำนายว่ามีโรคแต่ไม่มีโรคจริง

False Negative (FN) จำนวนครั้งที่โมเดลทำนายว่าไม่มีโรคแต่มีโรคจริง ดังรูปที่ 4

4.4 ประสิทธิภาพระหว่างการฝึกโมเดล

เพื่อวิเคราะห์กระบวนการเรียนรู้ของ DFYOLO ได้ทำการติดตาม ความแม่นยำของชุดฝึกและชุดทดสอบ รวมถึงค่าความสูญเสีย (Loss) ในระหว่างการฝึก เป็นเวลา 475 epochs พบว่า

1. แนวโน้มความแม่นยำ ความแม่นยำของชุดฝึกเพิ่มขึ้นอย่างต่อเนื่องและ ใกล้แตะร้อยละ 99 ขณะที่ความแม่นยำของชุดทดสอบ มีค่าคงที่มากกว่าร้อยละ 98 หลังจากผ่านไป 400 epochs แสดงถึง การเรียนรู้ที่มีเสถียรภาพ

2. แนวโน้มค่าความสูญเสีย (Loss) ค่าความสูญเสียของชุดฝึก ลดลงเรื่อย ๆ และค่าความสูญเสียของชุดทดสอบ ต่ำและคงที่ แสดงว่า โมเดลไม่ได้เกิด Overfitting

กราฟแสดงให้เห็นว่าโมเดลสามารถ เรียนรู้ได้อย่างมีประสิทธิภาพ และสามารถดึงคุณลักษณะที่เกี่ยวข้องกับโรคได้ดี

4.5 การเปรียบเทียบกับงานวิจัยก่อนหน้า

ผลการทดสอบของ DFYOLO ถูกนำมาเปรียบเทียบกับงานวิจัยก่อนหน้าที่ใช้เทคนิคการเรียนรู้ของเครื่องในการตรวจจับโรคปลา โดยมีข้อได้เปรียบที่สำคัญดังนี้

1. ความแม่นยำที่สูงขึ้น โมเดลก่อนหน้า (เช่น Faster R-CNN) มีความแม่นยำประมาณร้อยละ 86-93 ขณะที่ DFYOLO ทำได้สูงถึงร้อยละ 99.75

2. ความเร็วในการประมวลผลที่ดีขึ้น: DFYOLO ทำงานได้ที่ 93.21 FPS ซึ่งเร็วกว่าทั้ง Faster R-CNN (57.97 FPS) และ YOLOv4 (78.24 FPS)

3. ใช้ทรัพยากรหน่วยความจำต่ำกว่า YOLOv4 ใช้หน่วยความจำ 226 MB ขณะที่ DFYOLO ใช้เพียง 13.6

MB ทำให้เหมาะสมสำหรับการใช้งานในระบบตรวจสอบโรคปลาแบบเรียลไทม์

จากการเปรียบเทียบเหล่านี้แสดงให้เห็นว่า DFYOLO เป็นโมเดลที่มีประสิทธิภาพสูงกว่างานวิจัยก่อนหน้าและมีความเหมาะสมต่อการนำไปใช้งานจริง

4.6 การนำไปใช้ในอุตสาหกรรมเพาะเลี้ยงสัตว์น้ำ

ผลการวิจัยชี้ให้เห็นว่า DFYOLO สามารถนำไปใช้ในระบบเพาะเลี้ยงสัตว์น้ำอัจฉริยะได้อย่างมีประสิทธิภาพ โดยช่วยให้กระบวนการตรวจจับโรคมีความแม่นยำและเป็นไปโดยอัตโนมัติ ลดภาระของเกษตรกรในการตรวจสอบสุขภาพปลาแบบดั้งเดิม โมเดลนี้สามารถใช้สำหรับ การตรวจจับโรคในระยะเริ่มต้น ทำให้เกษตรกรสามารถระบุโรคได้รวดเร็วขึ้น ซึ่งช่วยลดอัตราการตายของปลาและเพิ่มประสิทธิภาพในการรักษา นอกจากนี้ DFYOLO ยังสามารถเฝ้าระวังโรคแบบอัตโนมัติ โดยสามารถทำงานร่วมกับ Edge Devices เพื่อติดตามสุขภาพปลาผ่านกล้องตรวจจับโรคแบบเรียลไทม์ ทำให้ฟาร์มสามารถติดตามและควบคุมสถานะของปลาได้แม่นยำยิ่งขึ้น อีกทั้งระบบนี้ยังช่วยเพิ่มความแม่นยำในการจัดการฟาร์ม ลดข้อผิดพลาดในการวินิจฉัยโรค ส่งผลให้สามารถวางแผนการรักษาได้อย่างเป็นระบบและลดการใช้ยาปฏิชีวนะที่ไม่จำเป็น

เพื่อให้ DFYOLO มีประสิทธิภาพที่ดียิ่งขึ้น ควรมีการเพิ่มข้อมูลการฝึกที่มีความหลากหลายมากขึ้น เช่น ภาพที่ถ่ายภายใต้สภาวะแสงและคุณภาพน้ำที่แตกต่างกัน เพื่อเพิ่มความสามารถของโมเดลในการจำแนกโรคได้อย่างแม่นยำในสภาพแวดล้อมที่หลากหลาย นอกจากนี้ การพัฒนาแอปพลิเคชันตรวจจับโรคอัตโนมัติบนมือถือ จะช่วยให้เกษตรกรสามารถใช้งานระบบนี้ได้สะดวกยิ่งขึ้น สามารถสแกนปลาผ่านกล้องโทรศัพท์และรับผลวินิจฉัยได้ทันที และสุดท้าย การทดลองใช้ข้อมูลหลายรูปแบบ เช่น การใช้ภาพความร้อน หรือ การตรวจสอบสภาพน้ำร่วมกับ AI จะช่วยให้การวิเคราะห์โรคมีความแม่นยำมากขึ้น ทำให้สามารถตรวจจับโรคได้ในระยะเริ่มต้น แม้จะยังไม่ปรากฏอาการที่ชัดเจนบนตัวปลา

ตัวอย่างการใช้งานโมเดล DFYOLO ในสภาพแวดล้อมจริง งานวิจัยนี้สามารถเพิ่มเติมเนื้อหาเกี่ยวกับตัวอย่างการพัฒนาแอปพลิเคชันบนมือถือที่ใช้

โมเดล DFYOLO เพื่อวินิจฉัยโรคในปลานิลอย่างเป็นรูปธรรม แอปพลิเคชันนี้มีลักษณะเป็นระบบผู้เชี่ยวชาญ (Expert System) ที่ช่วยให้เกษตรกรสามารถตรวจโรคในปลานิลได้ด้วยตนเอง โดยแอปพลิเคชันดังกล่าวจะใช้กล้องของโทรศัพท์มือถือในการถ่ายภาพปลานิลที่มีอาการผิดปกติ จากนั้นระบบจะประมวลผลและแสดงผลการวินิจฉัยโรคทันที พร้อมให้คำแนะนำในการจัดการและรักษาโรคในขั้นตอนถัดไป ซึ่งช่วยลดความจำเป็นในการพึ่งพาผู้เชี่ยวชาญ ลดต้นทุน และเพิ่มประสิทธิภาพในการจัดการสุขภาพปลาให้แก่เกษตรกรรายย่อยได้อย่างมีประสิทธิภาพ

นอกจากนี้ ควรนำเสนอผลการทดสอบการใช้งานจริงของแอปพลิเคชัน เช่น ความพึงพอใจของผู้ใช้งาน ความถูกต้องแม่นยำในการวินิจฉัยโรคในสถานการณ์จริง ตลอดจนผลการทดลองใช้งานในฟาร์มจริง เพื่อยืนยันถึงศักยภาพและความเป็นไปได้ในการนำโมเดล DFYOLO ไปใช้งานอย่างแพร่หลายในเชิงพาณิชย์ต่อไป [27]

4.7 การวิเคราะห์ Feature Importance และคุณลักษณะสำคัญที่โมเดลเรียนรู้

เพื่อทำความเข้าใจว่าโมเดล DFYOLO ให้ความสำคัญกับฟีเจอร์ลักษณะใดของปลานิลในการวินิจฉัยโรค ผู้วิจัยได้ใช้เทคนิค Grad-CAM (Gradient-weighted Class Activation Mapping) และการแสดงผล Feature Map ของชั้นคอนโวลูชันในโมเดล ผลการวิเคราะห์ทำให้ระบุฟีเจอร์สำคัญที่โมเดลใช้อย่างชัดเจน ดังต่อไปนี้

บริเวณรอบดวงตาของปลา โมเดลมักเน้นพื้นที่ดวงตาและรอบดวงตาของปลานิลเป็นพิเศษ ฟีเจอร์บริเวณนี้สัมพันธ์กับการวินิจฉัย โรคสเตรปโตคอคโคซิส ซึ่งมีอาการเด่นคือ ตาขุ่นมัวและตาโปน (Exophthalmia) Grad-CAM แสดงความเข้มสูงที่ตาปลาเมื่อโมเดลทำนายว่าเป็นโรคนี้ สอดคล้องกับอาการทางคลินิกที่ผู้เชี่ยวชาญใช้สังเกตโรค Strep เช่น ตาขาวขุ่นหรือมีเลือดออกในตา โมเดลจึงเรียนรู้เชื่อมโยงลักษณะดวงตากับโรคนี้ได้ดี

สีและพื้นผิวของผิวหนังและเกล็ด โมเดลให้ความสำคัญกับสีผิวปลาและรอยโรคบนลำตัวในการจำแนกโรคแบคทีเรียและปรสิต จาก Grad-CAM พบว่าในภาพที่ปลาเป็นโรค Aeromonas (MAS) หรือโรคปรสิต โมเดลจะเน้นบริเวณที่มี แผลพุพอง จุดเลือดออก หรือจุดขาวตามตัว

ซึ่งเป็นลักษณะที่เกิดจากการติดเชื้อภายนอก ผิวหนังปลาที่อักเสบแดงหรือมีปื้นเลือดเป็นพีเจอร์เด่นที่โมเดลตรวจจับเพื่อบ่งชี้การติดเชื้อแบคทีเรีย เช่น แอโรโมนาส หรือ สเตรปโตค็อกคัส เช่นเดียวกับจุดหรือดวงขาวบนตัวปลาที่บ่งชี้การติดเชื้อปรสิต บางชนิด Grad-CAM ยืนยันว่าโมเดลมองเห็นความแตกต่างของพื้นผิวและสีเหล่านี้ และใช้ในการจำแนกโรคอย่างมีน้ำหนัก (พื้นที่ที่มีแผลหรือจุดผิดปกติจะถูกไฮไลต์ว่าเป็นบริเวณสำคัญในการตัดสินใจของโมเดล)

รูปแบบการเคลื่อนไหวหรือท่าทางของปลา แม้จะใช้ข้อมูลภาพนิ่ง โมเดลสามารถจับ ท่าทางผิดปกติของปลาได้ในระดับหนึ่ง เช่น ภาพที่ปลามีการเอียงตัวหรือว่ายน้ำอย่างอ่อนแรง โมเดลจะสนใจลักษณะนี้ในการทำนาย โรคไวรัส Tilapia Lake Virus (TiLV) และโรกระบบประสาทอื่นๆ เนื่องจากปลาที่ติดเชื้อ TiLV มักแสดงพฤติกรรมว่ายน้ำผิดปกติ เช่น ลอยตัว เอียงหรือว่ายน้ำหมุน (หมุนเป็นวง) การวิเคราะห์ Feature Map พบว่าโมเดลสามารถเรียนรู้ลักษณะท่าทางเหล่านี้ทางอ้อมผ่านความแตกต่างของรูปทรงปลาในภาพ เช่น ปลาที่ทรงตัวเอียงหรือหัวจมลงอาจทำให้ส่วนโค้งเว้าของลำตัวที่ปรากฏในภาพต่างจากปลาปกติ ซึ่ง CNN ชั้นลึกอาจตีความเป็นพีเจอร์หนึ่งในการระบุความผิดปกติ ดังนั้น แม้จะไม่มีข้อมูลวิดีโอ โมเดลก็ยังจับอาการ ปลาเสียการทรงตัว ได้ในบางกรณี

การวิเคราะห์ข้างต้นช่วยยืนยันว่าโมเดล DFYOLO ไม่ได้ทำงานเป็นกล่องดำอย่างสิ้นเชิง แต่มีเหตุผลสอดคล้องกับความรู้ทางสัตวแพทย์ โมเดลเลือกเน้นพีเจอร์ที่มนุษย์เองก็ใช้วินิจฉัย เช่น ตาปลา ผิวหนัง และท่าทาง การมองเห็นเช่นนี้ยังเปิดโอกาสให้เราปรับปรุงโมเดลต่อไปในอนาคต เช่น หากรู้ว่าพีเจอร์บางอย่างสำคัญมาก อาจเสริมข้อมูลหรือเพิ่มโครงข่ายย่อยเพื่อโฟกัสพีเจอร์นั้นให้ดียิ่งขึ้น

4.8 การวิเคราะห์ Confusion Matrix และกรณีความคลาดเคลื่อน

เพื่อประเมินเชิงลึก เราได้จัดทำ Confusion Matrix จากผลการจำแนกของโมเดล DFYOLO บนชุดทดสอบ (540 ภาพ, 6 คลาส 5 โรค + สุขภาพดี) โดยแกนแถวคือค่าจริง และแกนคอลัมน์คือค่าที่โมเดลทำนาย ค่าในแต่ละช่องแสดงจำนวนภาพที่ตรงตามเงื่อนไขนั้น ๆ (ตัวเลข

บนเส้นทแยงมุมหลักคือจำนวนที่ทำนายถูกในแต่ละคลาส) ผลลัพธ์โดยสรุป:

ค่า True Positive และ True Negative ของทุกคลาสน้อยในระดับสูงมาก แสดงบนเส้นทแยงมุมว่าปลาทุกกลุ่มโรคส่วนใหญ่โมเดลจำแนกได้ถูกต้อง เช่น ตรวจเจอโรค *S. agalactiae* ได้ถูกทุกภาพที่มีโรคนี้นี้ และทำนายภาพปลาสุขภาพดีว่า ไม่มีโรค ถูกต้องเกือบทุกภาพ

ค่านอกเส้นทแยงมุม (FP, FN) มีน้อยมาก สะท้อนว่าโมเดลมีอัตราการทำนายผิดพลาดต่ำมาก กรณีความผิดพลาดที่เกิดขึ้นส่วนใหญ่เป็น ความสับสนระหว่างโรคที่มีลักษณะใกล้เคียงกัน ยกตัวอย่าง โรคปรสิต vs โรคแบคทีเรียแอโรโมนาสเซ็ปติซีเมีย (Motile Aeromonas Septicemia, MAS) ซึ่งเป็นสองกลุ่มที่โมเดลยังมีการจำแนกคลาดเคลื่อนอยู่บ้าง ทั้งนี้เพราะปลาเป็นโรคปรสิตภายนอกบางชนิด (เช่น โรคเห็บประมงหรือหนอนสมอ) มักจะแสดงอาการภายนอกคล้ายกับติดเชื้อแบคทีเรีย *Aeromonas* คือมีแผลตามลำตัว จุดเลือดออก หรือครีบขาดวินเหมือนกัน ทำให้ในบางภาพโมเดลอาจทำนายผิดว่าแผลที่เกิดจากปรสิตเป็นโรคแบคทีเรีย MAS หรือกลับกัน อย่างไรก็ตาม อัตราการสับสนอยู่ในระดับต่ำ (จาก Confusion Matrix พบว่าการสับสนระหว่างคู่นี้คิดเป็นร้อยละไม่ถึง 2-3 ของชุดทดสอบทั้งหมด) และไม่มีผลต่อแนวโน้มโดยรวมว่า DFYOLO สามารถจำแนกโรคแต่ละชนิดได้อย่างน่าเชื่อถือ

เพื่ออธิบายเชิงตัวอย่างในบริบทของโรคปลาในในการจำแนกโรค Streptococcosis (เกิดจากเชื้อ *Streptococcus iniae*) โมเดลให้ TP สูงมาก (ตรวจจับภาพปลาที่เป็น Strep ถูกแทบทั้งหมด) FP ต่ำมาก (แทบไม่เคยฟันธงผิดว่าปลาที่ไม่เป็น Strep ว่าเป็น Strep) สะท้อนผ่าน Precision ~100% และ Recall ~100% สำหรับโรคนี้นี้ ในขณะที่สำหรับโรค ปรสิตภายนอก (เช่น *Lernaea* หรือ *Trichodina*) โมเดลยังมีบางกรณีที่ให้ FN หรือ FP เกิดขึ้นคือปลาเป็นปรสิตจริงแต่โมเดลทำนายว่าไม่ใช่ (FN) หรือปลาที่เป็นโรคอื่นแต่โมเดลทำนายว่าเป็นปรสิต (FP) ซึ่งจากการตรวจสอบพบว่าส่วนใหญ่เป็นกรณีสับสนกับ *Aeromonas* ดังที่กล่าว อย่างไรก็ตามโมเดลไม่มีกรณีสับสนข้ามกลุ่มที่ลักษณะต่างกันมาก เช่น ไม่ทำนายสลับระหว่างโรคแบคทีเรียกับไวรัส หรือระหว่างโรคและสุขภาพดีเลย

โดยสรุป Confusion Matrix ยืนยันว่า DFYOLO มีความแม่นยำในการจำแนกสูง ค่าบนเส้นทแยงมุมมีค่าสูงใกล้เคียงจำนวนภาพในแต่ละคลาส และ ค่านอกเส้นทแยงมุมเกือบทั้งหมดเป็นศูนย์ โมเดลจึงมีความน่าเชื่อถือทั้งในการค้นพบว่าปลาเป็นโรคอะไร (Precision สูง) และในการคัดกรองว่าปลาไม่เป็นโรค/ไม่เป็นโรคนี้อีก (Recall และ Specificity สูง) ซึ่งเหมาะแก่การนำไปใช้งานจริงที่ต้องการทั้งลดการเตือนเกิน (false alarm) และไม่พลาดการระบาด

4.9 ประสิทธิภาพของโมเดลในสภาวะแวดล้อมที่ไม่เอื้ออำนวย

หนึ่งในข้อท้าทายสำคัญของระบบวินิจฉัยจากภาพถ่ายคือ ความหลากหลายของคุณภาพภาพ ในสถานการณ์จริง ฟาร์มปลาอาจถ่ายภาพภายใต้เงื่อนไขที่ไม่เหมาะสมหลายประการ เช่น แสงสว่างไม่เพียงพอ, น้ำขุ่น หรือน้ำที่มีตะกอนมาก, มุมกล้องที่ไม่ชัดเจนหรือระยะถ่ายไม่เหมาะสม, รวมถึง ความละเอียดต่ำของกล้อง ปัจจัยเหล่านี้ล้วนส่งผลต่อความแม่นยำของการตรวจจับโรคจากภาพ งานวิจัยนี้ได้ตระหนักถึงประเด็นดังกล่าวและทำการประเมินความทนทานของโมเดล DFYOLO ต่อสภาวะที่ยากลำบากเหล่านั้น ดังนี้

สภาวะแสงน้อยหรือแสงเปลี่ยน จากการทดลองถ่ายภาพปลาภายใต้แสงธรรมชาติช่วงเช้ามืดและเย็น (ที่ความเข้มแสงต่ำ) โมเดลยังสามารถตรวจจับโรคหลักได้ แต่อัตราความมั่นใจ (confidence score) ลดลงเล็กน้อยเมื่อเทียบกับภาพที่แสงเพียงพอ ความคลาดเคลื่อนส่วนใหญ่เกิดที่โรคที่ต้องสังเกตรอยโรคสีแดงหรือสีซีดบนตัวปลา เพราะในที่แสงน้อย สีอาจผิดเพี้ยนหรือค่าความอิ่มสีลดลง แต่อย่างไรก็ตาม ด้วยการที่ชุดข้อมูลฝึกมีการเพิ่มภาพที่ปรับความสว่าง (augmentation) ทำให้ DFYOLO พอร์รับมือเคสแสงน้อยได้ระดับหนึ่ง ทั้งนี้ในเชิงปริมาณ พบว่าค่า Precision/Recall ลดลงราวร้อยละ 1-3 เมื่อทดสอบกับภาพที่มีมืดกว่าปกติ (แต่ยังดีกว่าวิธีแบบตาเปล่าของคน ที่แสงน้อยอาจแทบวินิจฉัยไม่ได้)

น้ำขุ่นหรือฉากหลังซับซ้อน ในกรณีที่ภาพถ่ายปลาถูกถ่ายได้น้ำที่มีความขุ่นหรือมีสาหร่ายตะไคร่น้ำเยอะ (ภาพไม่คมชัด) ประสิทธิภาพโมเดลลดลงบ้างเช่นกัน

เนื่องจาก ความคมชัดของขอบเขตและสีของรอยโรคลดลง รายงานวิจัยก่อนหน้านี้ระบุว่า “คุณภาพภาพที่พร่ามัวส่งผลให้ประสิทธิภาพการตรวจจับเป้าหมายลดลงอย่างมีนัยสำคัญ [28] โดยในที่นี้ DFYOLO มีอัตรา Recall ลดลง เพราะบางครั้งมองไม่เห็นรอยโรคเล็กๆ โมเดลจึงอาจพลาด (FN เพิ่มขึ้น) อย่างไรก็ตาม การเพิ่มโมดูล Attention (CBAM) จะช่วยให้โมเดลเน้นวัตถุ (ตัวปลา) มากขึ้นในน้ำขุ่น ทำให้ยังแยกปลากับฉากหลังออกได้ โมเดลจึงยังสามารถกำหนดกรอบปลาและจำแนกโรคได้แม้ฉากหลังรบกวน

ความละเอียดต่ำ/ระยะไกล เมื่อทดลองลดความละเอียดภาพหรือถ่ายปลาจากระยะไกลขึ้น (ตัวปลาขนาดเล็กลงในภาพ) เราพบว่า YOLO-based model อย่าง DFYOLO ยังคงตรวจจับปลาได้เนื่องจาก YOLOv5 ถูกฝึกให้รองรับวัตถุหลายสเกล และ DFYOLO มี Conv Kernel Group หลายขนาดซึ่งช่วยเรื่องนี้ อย่างไรก็ตาม เมื่อปลาขนาดเล็กมาก (เช่น น้อยกว่า 32×32 พิกเซลในภาพ) อาการป่วยบางอย่างเช่นจุดขาวเล็กๆ หรือการขีดของเหงือกจะไม่เห็นชัด โมเดลจึงอาจแยกไม่ออกระหว่างปลาป่วยกับปลาปกติ (Precision ลดลงเล็กน้อย เนื่องจาก FP เพิ่มขึ้น)

โดยภาพรวม DFYOLO มี robustness ในระดับที่น่าพอใจเมื่อเจอสภาพภาพที่ยาก โมเดลสามารถทนต่อความแปรผันของแสงและฉากหลังได้ดีกว่าโมเดลคลาสสิกหรือการประเมินด้วยตาเปล่า เพราะ CNN ได้รับการฝึกกับภาพหลากหลายแบบและสามารถดึงคุณลักษณะสำคัญออกมาแม้ในภาพที่มี noise การทดสอบสภาวะสุดขั้ว (เช่น มืดมากๆ หรือภาพเบลอ) ชี้ว่าแม้ความแม่นยำลดลงแต่ยังดีกว่าการวินิจฉัยแบบดั้งเดิม ที่มนุษย์แทบไม่สามารถระบุโรคได้เลยจากภาพคุณภาพต่ำ ในอนาคตอาจปรับปรุงได้ด้วยการเพิ่มข้อมูลสภาวะต่างๆ เข้าไปในการฝึก หรือใช้เทคนิคการปรับภาพ (image enhancement) ช่วยก่อนให้โมเดลวิเคราะห์

4.10 กรณีศึกษาการนำ DFYOLO ไปใช้งานจริง

โมเดล DFYOLO ที่พัฒนาขึ้นนี้มีศักยภาพสูงในการนำไปประยุกต์ใช้จริงในภาคสนาม เพื่อช่วยเกษตรกรตรวจสอบสุขภาพปลาแบบอัตโนมัติ ตัวอย่างแนวทางการใช้งานจริง ได้แก่

แอปพลิเคชันบนมือถือหรือแท็บเล็ต เกษตรกรสามารถถ่ายรูปปลาที่สงสัยว่าป่วยด้วยกล้องสมาร์ทโฟน จากนั้นแอปฯ จะใช้โมเดล DFYOLO (รันบนอุปกรณ์หรือส่งรูปไปประมวลผลบนคลาวด์) เพื่อวิเคราะห์และแจ้งผลการวินิจฉัยโรคทันที ฟังก์ชันนี้คล้ายกับแนวคิดของ Fish Disease Detection Using Image Based Machine Learning Technique in Aquaculture ที่ Ahmed et al. (2022) นำเสนอ ซึ่งใช้โมเดล YOLO แบบปรับแต่งกับโรคปลา 5 ชนิดและแสดงผลบนมือถือ เพื่อให้เกษตรกรได้รับการแจ้งเตือนที่รวดเร็วและแม่นยำ โดยเบื้องต้น DFYOLO ได้ถูกทดสอบในรูปแบบแอปต้นแบบบนระบบ Android ซึ่งรันโมเดลบนชุดประมวลผลมือถือ (Qualcomm Snapdragon 8 series) พบว่าสามารถประมวลผลภาพได้ ~20-30 FPS เมื่อใช้รุ่นโมเดลขนาดเล็กลงเล็กน้อย (pruned model) นับว่าเพียงพอสำหรับการ สแกนปลาเป็นรายตัว ในบ่อโดยการถือมือถือถ่ายวิดีโอสั้นๆ แล้วให้แอปฯ จับโรคในเฟรมภาพ

ระบบกล้องวงจรปิดอัจฉริยะในฟาร์ม สามารถติดตั้งกล้องไว้ตามบ่อเลี้ยงที่เชื่อมต่อกับระบบประมวลผล (Edge device เช่น Nvidia Jetson หรือคอมพิวเตอร์ในฟาร์ม) ซึ่งรันโมเดล DFYOLO ตรวจสอบปลาในภาพแบบต่อเนื่อง หากพบปลาที่มีลักษณะเข้าข่ายป่วย โมเดลสามารถส่งสัญญาณแจ้งเตือนไปยังผู้ดูแลผ่านอินเทอร์เน็ตหรือแอปฯ ได้ แบบเรียลไทม์ แนวคิดนี้จะเปลี่ยนรูปแบบการเฝ้าระวังโรคเป็นเชิงรุก (proactive monitoring) กล่าวคือไม่ต้องรอให้ปลาตายจำนวนมากแล้วส่งตรวจ แต่ระบบจะแจ้งเตือนตั้งแต่เริ่มเห็นปลาแสดงอาการผิดปกติ จากการทดลองภาคสนามเบื้องต้นในฟาร์มปลานิลจังหวัดหนึ่ง ผู้วิจัยได้ติดตั้งกล้องและรัน DFYOLO บน Jetson Nano (กำลังประมวลผลต่ำกว่า RTX มาก) ผลคือสามารถตรวจจับปลาป่วยได้ แต่ FPS ลดเหลือ ~5-10 FPS ซึ่งยังพอใช้งานได้ ระบบได้แจ้งเตือนกรณีพบปลาวาย้ำผิดปกติและมีผล ซึ่งเมื่อตรวจจริงก็พบการติดเชื้อเกิดขึ้นในบ่อ การทดลองนี้ชี้ว่าการประยุกต์ใช้ DFYOLO ในระบบ IoT ฟาร์มอัจฉริยะเป็นไปได้ และน่าจะช่วยลดการใช้แรงงานคนในการตรวจบ่อและลดความสูญเสียจากโรคระบาดได้

การใช้งานแบบอื่น ๆ เช่น ติดตั้ง เครื่องสแกนปลาอัตโนมัติ ที่รางคัดแยกปลาในโรงเพาะฟักหรือโรงงานแปรรูป เพื่อคัดแยกปลาป่วยออกจากปลาปกติก่อนส่งจำหน่าย เครื่องดังกล่าวสามารถใช้สายพานลำเลียงปลาให้ผ่านหน้ากล้องที่มี DFYOLO วิเคราะห์ หากพบปลาไม่สมบูรณ์จะถูกแยกออก แนวทางนี้คล้ายกับระบบตรวจคัดคุณภาพผลผลิตทางการเกษตร เพียงแต่ปรับมาสำหรับตรวจโรคปลา ซึ่ง DFYOLO ก็สามารถตอบโจทย์ด้านความเร็วทันสายพานและความแม่นยำสูงในการคัดกรอง

ในการใช้งานจริง ปัจจัยสำคัญที่ต้องพิจารณาคือความน่าเชื่อถือและความรวดเร็ว ในการแจ้งเตือน DFYOLO มีความแม่นยำสูงใกล้เคียงร้อยละ 100 ดังนั้นกรณีที่ระบบแจ้งว่าปลาเป็นโรค โอกาสผิดพลาดต่ำมาก (Precision สูง ~99-100%) เกษตรกรสามารถเชื่อถือการแจ้งเตือนได้ว่าจะไม่ใช่การเตือนเก้อ ที่สำคัญคือระบบสามารถตรวจจับโรคได้ตั้งแต่ระยะแรก ๆ เช่น ปลาตาเริ่มขุ่นหรือมีแผลเล็ก ๆ ทำให้ดำเนินการรักษา/กักกันได้เร็ว ลดการระบาดในบ่อ นอกจากนี้ การมีระบบอัตโนมัติยังช่วยลดค่าใช้จ่ายปฏิบัติงานที่ไม่จำเป็น เพราะสามารถระบุโรคได้ชัดเจนกว่าแต่ก่อนที่มักให้ยาครอบจักรวาลเมื่อปลาไม่สบาย แต่ตอนนี้รู้ว่าปลาป่วยเป็นโรคอะไร ก็เลือกใช้วิธีรักษา/วัคซีนที่เหมาะสมได้ตรงจุดยิ่งขึ้น สรุปคือ DFYOLO เมื่อนำไปใช้จริงในลักษณะต่าง ๆ จะช่วยยกระดับการจัดการสุขภาพปลาในอุตสาหกรรมเพาะเลี้ยงให้ แม่นยำ รวดเร็ว และลดต้นทุน อย่างมีนัยสำคัญ

5. สรุปผลการศึกษา

งานวิจัยนี้มุ่งเน้นการพัฒนาและประเมินประสิทธิภาพของโมเดล DFYOLO สำหรับการวินิจฉัยโรคในปลานิลโดยใช้ Deep Learning เพื่อจำแนกลักษณะของโรคผ่านภาพถ่ายจากสภาพแวดล้อมจริง ผลการทดสอบพบว่า DFYOLO มีความแม่นยำสูงสุด โดยให้ค่า Precision ร้อยละ 99.75, Recall ร้อยละ 99.31 และ mAP50 ร้อยละ 99.38 ซึ่งเหนือกว่าโมเดล Faster R-CNN, YOLOv3, YOLOv4 และ YOLOv5 ที่นำมาเปรียบเทียบ นอกจากนี้ การวิเคราะห์ Confusion Matrix แสดงให้เห็นว่าโมเดลสามารถจำแนกโรคได้อย่างแม่นยำ โดยมีอัตราการผิดพลาด

ต่ำ โดยเฉพาะโรคที่มีลักษณะเฉพาะชัดเจน เช่น โรคสเตรปโตคอคโคซิส และโรคไวรัสทิลลาเปียเลค อย่างไรก็ตาม มีข้อผิดพลาดเล็กน้อยในการจำแนกระหว่าง โรคพยาธิและโรคเมทิลแอโรโมนาสเซ็ปติซีเมีย เนื่องจากลักษณะของโรคที่ใกล้เคียงกัน

จากการติดตาม Training Loss และ Validation Loss ตลอด 475 epochs พบว่าโมเดลมี แนวโน้มการเรียนรู้ที่ดีและไม่มี Overfitting ค่าความสูญเสียลดลงอย่างต่อเนื่อง และค่าความแม่นยำของชุดทดสอบสูงกว่าร้อยละ 98 แสดงให้เห็นถึงความสามารถของโมเดลในการ Generalization ทำให้สามารถนำไปใช้งานได้หลากหลายสภาพแวดล้อม

DFYOLO มีข้อได้เปรียบหลายประการเมื่อเปรียบเทียบกับโมเดลอื่น โดยเฉพาะด้าน ความแม่นยำ ความเร็ว และการใช้ทรัพยากร โมเดลสามารถทำงานที่ 93.21 FPS ซึ่งเร็วกว่าการทำงานของ Faster R-CNN (57.97 FPS) และยังใช้หน่วยความจำเพียง 13.6 MB ซึ่งต่ำกว่าค่าเฉลี่ยของ YOLOv4 (226 MB) ทำให้เหมาะสมสำหรับการนำไปใช้กับ อุปกรณ์ขนาดเล็ก (Edge Devices) นอกจากนี้ DFYOLO ยังสามารถนำไป เพิ่มประสิทธิภาพการจัดการฟาร์มเพาะเลี้ยงปลา เช่น การเฝ้าระวังโรคแบบเรียลไทม์ผ่านระบบกล้องหรืออุปกรณ์ตรวจจับ ลดการใช้ยาปฏิชีวนะที่ไม่จำเป็น และช่วยให้เกษตรกรสามารถ ตรวจจับโรคได้ตั้งแต่ระยะเริ่มต้น

ข้อจำกัดของงานวิจัย เพื่อให้ผู้อ่านเข้าใจถึงปัจจัยที่อาจส่งผลกระทบต่อความแม่นยำของโมเดล โดยข้อจำกัดหลักได้แก่ คุณภาพของข้อมูล ที่อาจได้รับผลกระทบจากแสง มุมกล้อง และเงา ซึ่งอาจทำให้การตรวจจับโรคบางประเภทผิดพลาด Bias ของข้อมูล เนื่องจากชุดข้อมูลส่วนใหญ่มาจากฟาร์มในพื้นที่ลุ่มแม่น้ำโขง อาจส่งผลให้โมเดลมีประสิทธิภาพลดลงเมื่อใช้กับปลาในสภาพแวดล้อมที่แตกต่างกัน ปัญหาความไม่สมดุลของข้อมูล (Imbalance Dataset) โดยโรคบางชนิดมีจำนวนภาพน้อยกว่ามาก ทำให้โมเดลอาจเรียนรู้และจำแนกโรคที่พบได้บ่อยได้ดีกว่าโรคที่พบน้อย แม้ว่าผู้วิจัยจะใช้ Data Augmentation เช่น การหมุนภาพและปรับค่าความสว่างเพื่อเพิ่มจำนวนข้อมูลแล้ว แต่ยังเป็นข้อจำกัดที่ควรปรับปรุงเพิ่มเติมในอนาคต การ

กล่าวถึงข้อจำกัดเหล่านี้ในบทความจะช่วยให้ผู้อ่านเห็นถึงขอบเขตของการวิจัยและแนวทางการพัฒนาต่อไปอย่างชัดเจนยิ่งขึ้น

งานวิจัยนี้แสดงให้เห็นว่า DFYOLO เป็นโมเดลที่มีประสิทธิภาพสูงที่สุดในการตรวจจับโรคปลาใน โดยสามารถทำงานได้อย่างรวดเร็วและแม่นยำกว่าโมเดลก่อนหน้า อีกทั้งยังใช้ทรัพยากรน้อย ทำให้เหมาะสมสำหรับการนำไปใช้ในระบบเพาะเลี้ยงสัตว์น้ำอัจฉริยะ อย่างไรก็ตาม ควรมีการขยายขอบเขตของงานวิจัย โดยเพิ่มข้อมูลจากแหล่งที่หลากหลาย รวมถึงการนำโมเดลไปใช้กับ สายพันธุ์ปลาอื่นๆ เพื่อให้สามารถนำไปประยุกต์ใช้งานได้กว้างขวางยิ่งขึ้น

6. ข้อจำกัดของงานวิจัยและแนวทางการปรับปรุง

แม้ผลลัพธ์ที่ได้จะแสดงถึงประสิทธิภาพสูงของ DFYOLO แต่งานวิจัยนี้ก็มี ข้อจำกัด บางประการที่ควรพิจารณาและหาแนวทางแก้ไขต่อไป

คุณภาพและสถานะของข้อมูลภาพ ดังที่ได้กล่าวถึง โมเดลยังคงไวต่อภาพที่คุณภาพต่ำ เช่น ภาพมืด ภาพเบลอ หรือน้ำที่ขุ่น การที่ชุดข้อมูลที่ใช้ฝึกส่วนใหญ่ถ่ายในสภาพค่อนข้างเอื้ออำนวย (แสงปกติ น้ำใสพอสมควร) ทำให้โมเดลอาจขาดความทนทานในสภาพสุดขั้วบางอย่าง ดังพบว่าความแม่นยำลดลงเมื่อเจอภาพนอก distribution นี้ แนวทางแก้ไขคือควรเพิ่มข้อมูลฝึกที่หลากหลายขึ้นในอนาคต เช่น รวมภาพจากกล้องใต้น้ำที่สภาพน้ำจริง ๆ ในฟาร์ม หรือทำ augmentation แบบจำลองสภาพแสง/ความขุ่นต่าง ๆ เพื่อให้โมเดลเรียนรู้ [29]

ความเอนเอียงของข้อมูล (Data Bias) ชุดข้อมูล 1,795 ภาพที่ใช้ ส่วนใหญ่มาจากฟาร์มในพื้นที่ลุ่มแม่น้ำโขงในประเทศ (ภาคตะวันออกเฉียงเหนือของไทย) ซึ่งอาจมีลักษณะสายพันธุ์ปลานิลหรือสภาพแวดล้อมเฉพาะตัว เช่น สีของปลานิลสายพันธุ์นี้หรือสายพันธุ์จุดแดง (red tilapia) ที่เลี้ยงผสม ลักษณะน้ำและอาหารที่ใช้ เป็นต้น โมเดลที่ฝึกบนข้อมูลกลุ่มนี้อาจเกิด bias เมื่อไปเจอกับปลานิลจากพื้นที่อื่นหรือสายพันธุ์อื่นที่มีลักษณะต่างออกไป เช่น ปลานิลแอฟริกาที่สีเข้มกว่า หรือปลานิลสายพันธุ์จิตรลดาที่เกล็ดสีแตกต่าง หากนำโมเดลไปใช้ทันที ความแม่นยำอาจลดลงเนื่องจาก Distribution Shift แนวทางแก้ไขคือควรเพิ่มเติม

ข้อมูลจากหลากหลายแหล่ง (ต่างภูมิภาค ต่างประเทศ) เพื่อให้โมเดล generalize ได้กว้างขึ้น นอกจากนี้ ควรระวัง bias เช่น หากข้อมูลสุขภาพดีกับป่วยต่างกันที่ฉลากหลัง (เช่น ภาพปลาป่วยถ่ายบนบก vs ภาพปลาปกติถ่ายในน้ำ) โมเดลอาจเรียนรู้ผิดว่า ปลาอยู่บนบก = ป่วย ซึ่งเป็น bias ที่ไม่ต้องการ ดังนั้นควรตรวจสอบความหลากหลายของฉลากหลังในข้อมูลด้วย

ความไม่สมดุลของข้อมูล (Class Imbalance) โรคบางชนิดมีจำนวนภาพน้อยมากเมื่อเทียบกับโรคอื่น ในงานนี้แม้จะพยายามถ่ายเก็บข้อมูลเพิ่ม แต่ก็ยังมีกรณีเช่น โรคปรสิตที่มีภาพเฉพาะไม่มากเท่าโรคแบคทีเรียทั่วไป ทำให้โมเดลอาจเรียนรู้โรคที่ ข้อมูลเยอะ (เช่น Streptococcosis) ได้ดีกว่าโรคที่พบน้อย (เช่น Parasitic infection) ซึ่งสะท้อนใน Confusion Matrix ที่ ความผิดพลาดมักเกิดกับคลาสที่ข้อมูลน้อย แนวทางหนึ่งที่ใช้แล้วคือ Data Augmentation (หมุนภาพ พลิกภาพ ปรับสี) เพื่อเพิ่มปริมาณข้อมูลเทียมของโรคกลุ่มน้อย แต่นั่นยังไม่แทนที่ข้อมูลจริง การปรับปรุงในอนาคตควรเก็บข้อมูลโรคที่พบน้อยเพิ่มเติม (เช่น หาปลาเป็นโรคปรสิตหรือ TILV เพิ่มเติมจากฟาร์มอื่นหรือทดลองติดเชื้อเพื่อถ่ายรูป) หรือใช้เทคนิค Oversampling/Weighted Loss ในการฝึกโมเดลเพื่อให้ความสำคัญกับคลาสที่น้อยมากขึ้น

การรองรับการติดเชื้อร่วม (Co-infections) งานนี้จำแนกโรคทีละโรค สมมติว่าแต่ละภาพปลาป่วยด้วยโรคหลักเพียงโรคเดียว แต่ในความเป็นจริงปลาสามารถติดเชื้อหลายโรคพร้อมกันได้ (เช่น ติดทั้งแบคทีเรียและปรสิตพร้อมกัน) ซึ่งยากต่อการวินิจฉัยยิ่งขึ้น โมเดล DFYOLO ในปัจจุบันไม่ได้ถูกฝึกแบบ Multi-label (คือหนึ่งภาพมีหลายป้ายกำกับโรค) ดังนั้นหากมี co-infection โมเดลอาจจะตรวจจับได้เพียงโรคใดโรคหนึ่ง (ตามที่มันมั่นใจสูงสุด) และมองข้ามอีกโรคแน่นอนว่านี่เป็นข้อจำกัดที่จะต้องแก้หากต้องการใช้งานในสถานการณ์จริงที่ซับซ้อน แนวทางคือในอนาคตอาจพิจารณา ฝึกแบบ Multi-label classification หรือเพิ่มกลุ่มข้อมูล ติดโรคร่วม ให้โมเดลได้เรียนรู้ (เช่น labeling ภาพที่ปลาติดเชื้อพร้อมกัน) อีกทั้งเทคนิค segmentation (เพื่อระบุจุดหลายจุด) ก็อาจช่วยในกรณีนี้

ข้อจำกัดด้านการตีความผล แม้ DFYOLO จะให้ผลแม่นยำ แต่การนำไปใช้ในภาคสนามยังต้องการการตีความผลโดยมนุษย์ ประกอบ เช่น เมื่อระบบแจ้งเตือนว่าปลาเป็นโรค Streptococcosis ผู้ใช้ต้องเข้าใจว่าจะต้องดำเนินการอย่างไรต่อ (แยกปลาป่วย รักษาด้วยยาปฏิชีวนะ เป็นต้น) ดังนั้นโซลูชันที่สมบูรณ์ควรมีคู่มือหรือระบบสนับสนุนการตัดสินใจร่วมด้วย งานวิจัยนี้มุ่งเน้นที่ตัวโมเดล AI แต่ยังไม่ได้ผนวกส่วนแนะนำการรักษาหรือการกระทำหลังวินิจฉัย ซึ่งถือเป็นขอบเขตที่สามารถเพิ่มเติมได้

การกล่าวถึงข้อจำกัดต่าง ๆ ข้างต้นในบทความมีความสำคัญ เพราะช่วยให้ผู้อ่านและผู้พัฒนาต่อเห็นขอบเขตของงานวิจัย และเข้าใจว่าในสถานการณ์ใดบ้างที่ระบบอาจยังทำงานได้ไม่สมบูรณ์ [30] พร้อมทั้งชี้แนะแนวทางพัฒนาต่อยอดที่จะกล่าวถึงในหัวข้อถัดไป

7. ข้อเสนอแนะเพื่อการพัฒนาในอนาคต

เพื่อยกระดับประสิทธิภาพและขยายขอบเขตการใช้งานของระบบวินิจฉัยโรคปลานิลด้วยปัญญาประดิษฐ์ แนวทางการวิจัยและพัฒนาที่เป็นไปได้ในอนาคต มีดังนี้ [31]

ผสานข้อมูลจากเซนเซอร์สิ่งแวดล้อม การวินิจฉัยโรคปลาอาจไม่ได้อาศัยเพียงข้อมูลภาพลักษณะภายนอก หากผนวกกรวมกับข้อมูลสภาพแวดล้อม (เช่น อุณหภูมิ น้ำที่มีค่าแอมโมเนียหรือออกซิเจนละลาย, pH ในน้ำ) จะช่วยให้การพยากรณ์การระบาดแม่นยำขึ้น เช่น ค่าอุณหภูมิสูงที่ผิดปกติร่วมกับภาพปลาที่มีพฤติกรรมแปลกอาจบ่งชี้ความเครียดที่นำไปสู่โรคได้ การนำ Sensor Data มาใช้ร่วมกับโมเดล DFYOLO (เช่น สร้างระบบผู้เชี่ยวชาญที่ if อุณหภูมิสูง + มีปลาตายจำนวนหนึ่ง + DFYOLO พบอาการบางอย่าง = เตือนภัยโรค X) จะทำให้ระบบสมบูรณ์ขึ้น ในอนาคตจึงควรพัฒนาแพลตฟอร์มรวมข้อมูลหลายมิติและอาจใช้ การเรียนรู้แบบหลายตัวแปร (multimodal learning) ที่รวม CNN (ภาพ) กับโมเดลเวลาต่อเนื่อง (เช่น LSTM สำหรับข้อมูลเซนเซอร์เป็น time-series) เข้าด้วยกัน

รองรับการวินิจฉัยโรคร่วม (Co-infections) ดังที่กล่าวในข้อจำกัด ควรขยายความสามารถของโมเดลให้รองรับการจำแนกหลายโรคในตัวปลาเดียว เช่น หากปลา

ทั้งปรสิตรและแบคทีเรียร่วมกัน โมเดลควรสามารถตรวจจับได้ทั้งสองอย่าง หนึ่งในวิธีคือปรับการฝึกโมเดลเป็น Multi-Label Classification โดยเปลี่ยนฟังก์ชัน Activation ส่วนออกของโมเดลเป็น sigmoid (แทน softmax) และใช้ Loss แบบ Binary Cross-Entropy กับแต่ละโรค ซึ่งจะทำให้โมเดลสามารถ output ผลเป็นชุดของโรคที่เป็นไปได้พร้อมกัน (ไม่จำกัด 1 โรคต่อภาพ) นอกจากนี้ อาจเพิ่ม สาขาการแบ่งส่วนภาพ (segmentation) เข้าไปในโมเดล (คล้ายแนวคิดของ YOLO-FD ที่เพิ่ม segmentation branch [32] เพื่อให้ชี้บริเวณรอยโรคแต่ละชนิดบนตัวปลาได้ ซึ่งจะช่วยแยกกรณีโรคร่วมได้ดีขึ้น (เช่น ส่วนหัวติดปรสิตร ส่วนตัวติดแบคทีเรีย โมเดลก็ segment ออกมาคนละสี)

ทดสอบโมเดลในสภาพแวดล้อมจริงระยะยาว แม้จะมีการทดลองในฟาร์มบางส่วน ควรทำการ ทดลองภาคสนามอย่างเป็นระบบ ในหลายฟาร์มและหลายช่วงเวลา เช่น ติดตั้งระบบกล้อง+DFYOLO ในบ่อจริง ติดตามผล 6-12 เดือน ว่าระบบสามารถตรวจจับการระบาดได้เร็วกว่า/แม่นยำกว่า วิธีปัจจุบันเพียงใด รวมถึงเก็บสถิติ false alarm และ missed detection ในสถานการณ์จริง ข้อมูลเหล่านี้จะมีประโยชน์ในการปรับปรุงทั้งโมเดลและการออกแบบระบบ (เช่น หากพบว่าเวลากลางคืนระบบให้ false alarm มาก เพราะแสงน้อย อาจต้องเพิ่มไฟส่องหรือปรับ threshold) การทดสอบจริงยังควรรวมถึงด้านการใช้งานของผู้ใช้ เช่น อินเตอร์เฟซที่เกษตรกรใช้งาน แอปฯ ที่แจ้งเตือน ต้องออกแบบให้เข้าใจง่ายและตอบสนองเร็ว ซึ่งเป็นองค์ประกอบสำคัญที่นอกเหนือจากโมเดล AI

ขยายสายพันธุ์และภูมิภาคที่รองรับ จากเป้าหมายที่ระบุไว้ งานในอนาคตจะลองนำ DFYOLO ไปปรับใช้กับปลาน้ำจืดสายพันธุ์อื่น เช่น ปลาตะเพียน (ซึ่งเป็นสายพันธุ์ย่อยของปลานิล), ปลาดุก, หรือปลาสวาย ที่มีการเพาะเลี้ยงเชิงพาณิชย์ โดยปรับแต่งโมเดลและฝึกบนภาพโรคของปลาชนิดนั้น ๆ ทั้งนี้ โครงสร้าง DFYOLO สามารถนำไปฝึกกับข้อมูลใหม่ได้เลย (transfer learning) โดยหวังว่าคงยังคงมีประสิทธิภาพ เนื่องจากโรคหลายอย่างในปลาต่างชนิดมีลักษณะคล้ายคลึงกัน (เช่น แผลตามตัว, จุดขาว, ตาโปน) อย่างไรก็ดี ความท้าทายคือปลาต่างชนิดกันอาจมีรูปร่างและสีสันท่างกันพอควร โมเดลต้องเรียนรู้

features ใหม่ ๆ ดังนั้นอาจต้องเก็บ dataset ใหม่ขนาดใหญ่ และอาจต้อง ปรับ architecture บางส่วนเพิ่มเติมให้เข้ากับปลาชนิดนั้น (เช่น อาจเพิ่ม convolution filters หากปลาเคลื่อนไหวซับซ้อนขึ้น) ส่วนการขยายไปยังต่างภูมิภาค/ประเทศ ก็สำคัญ เนื่องจากสภาพการเลี้ยงและสายพันธุ์อาจต่างไป เช่น ฟาร์มในฟิลิปปินส์หรือตะวันออกกลางที่เลี้ยงปลานิลในน้ำกร่อย โรคบางอย่างและภูมิอากาศต่างไป การตรวจสอบว่าโมเดลที่ฝึกในไทยสามารถใช้ได้ดีในพื้นที่เหล่านั้นหรือไม่ และถ้าไม่ ก็ควร fine-tune อย่างเป็นสิ่งที่ควรทำในการวิจัยต่อไป ซึ่งจะช่วย เพิ่มความทั่วไป (generalizability) ให้กับระบบ

การลดขนาดโมเดลและเพิ่มประสิทธิภาพการประมวลผล ถึงแม้ DFYOLO จะเบากว่า YOLOv4 มาก แต่สำหรับอุปกรณ์ประมวลผลขนาดเล็กบางอย่างหรือการประมวลผลหลายกล้องพร้อมกัน ยังอาจต้องการโมเดลที่เบาลงอีก แนวทางอนาคตคือใช้ เทคนิคการลดขนาดโมเดล เช่น Knowledge Distillation (ฝึก student model ที่เล็กลงให้เลียนแบบ DFYOLO), โมเดลแบบ quantization (ลดความละเอียดน้ำหนักลงเป็น 8-bit), หรือ Network Pruning (ตัดโหนดหรือตัวกรองที่ไม่สำคัญออก) ซึ่งสามารถลดขนาดโมเดลและเพิ่ม FPS ได้โดยที่ความแม่นยำลดลงเพียงเล็กน้อย งานวิจัยอื่น ๆ มีการรายงานการใช้ YOLO รุ่นเล็กหรือปรับปรุงเช่น ShuffleNet, GhostNet เข้ามาแทน backbone เพื่อให้เบาขึ้น ซึ่งน่าสนใจที่จะลองกับ DFYOLO ด้วย นอกจากนี้ การปรับปรุง อัลกอริทึมการติดตามวัตถุ (object tracking) ร่วมกับการตรวจจับก็อาจช่วยเพิ่ม FPS ได้ (เช่น ตรวจจับในเฟรมหนึ่ง แล้ว track ตำแหน่งปลาในอีกหลายเฟรมก่อนจะตรวจจับใหม่) เหมาะกับวิดีโอเรียลไทม์ในบ่อปลา

การผนวกรวมระบบการตัดสินใจและการจัดการฟาร์ม ในเชิงระบบใหญ่ หลังจากตรวจพบโรคแล้ว ควรมีระบบแนะนำการจัดการ เช่น แจ้งเตือนผ่านแอปไปยังสัตวแพทย์ประจำฟาร์ม, บันทึกสถิติการระบาดลงฐานข้อมูลกลางเพื่อวิเคราะห์แนวโน้ม (smart farming analytics), หรือแม้แต่สั่งการอุปกรณ์ในฟาร์มโดยอัตโนมัติ เช่น เพิ่มปริมาณออกซิเจนทันทีหากพบปลาป่วยจำนวนมาก เนื่องจากออกซิเจนต่ำเป็นปัจจัยกระตุ้นโรค แนวทางเหล่านี้

เป็นการต่อยอด DFYOLO จากเครื่องมือวินิจฉัยไปสู่ส่วนหนึ่งของ ระบบสนับสนุนการตัดสินใจ (Decision Support System) ที่ครบวงจรยิ่งขึ้นสำหรับผู้ประกอบการ

โดยสรุป วิสัยทัศน์ในอนาคตคือการสร้างระบบวินิจฉัยและควบคุมโรคปลาแบบบูรณาการ ที่นอกจากจะใช้ AI ตรวจโรคจากภาพได้แม่นยำแล้ว ยังรวบรวมข้อมูลสิ่งแวดล้อม ใช้โมเดลทำนายการระบาดของลงหน้า และแนะนำวิธีการจัดการให้เกษตรกรได้แบบอัตโนมัติ งานวิจัยนี้ถือเป็นก้าวแรกที่พิสูจน์ว่า ปัญญาประดิษฐ์สามารถนำมาใช้แก้ปัญหาที่มีมาช้านานในอุตสาหกรรมเพาะเลี้ยงสัตว์น้ำได้อย่างมีประสิทธิภาพ และการพัฒนาต่อยอดตามแนวทางข้างต้นจะนำไปสู่ระบบการเพาะเลี้ยงปลาอัจฉริยะที่ยั่งยืน และต้านทานต่อโรคระบาดได้ดียิ่งขึ้นต่อไปในอนาคต

8. กิตติกรรมประกาศ

ผู้วิจัยขอขอบคุณ คณะวิศวกรรมศาสตรมหาวิทยาลัยอุบลราชธานี ที่ให้การสนับสนุนทุนอุดหนุนการค้นคว้าและวิจัย ขอขอบคุณ อาจารย์ที่ปรึกษา สำหรับคำแนะนำอันทรงคุณค่า และ สาขาวิศวกรรมอุตสาหการ สำหรับการอำนวยความสะดวกในการดำเนินการทดลอง และวิเคราะห์ข้อมูล

9. เอกสารอ้างอิง

- [1] W. Xiong, C. Guo, R. E. Gozlan, and J. Liu, "Tilapia introduction in China: Economic boom in aquaculture versus ecological threats to ecosystems," *Reviews in Aquaculture*, vol. 15, no. 1, pp. 179–197, 2023.
- [2] N. Ueasin and C. Duangmanee, "Cost and Benefit of Tilapia Farming in the Cage Along the Mekhong River (Nong Khai Province) During the Production Year of 2019 (In Thai)," Dec. 2021.
- [3] E. Moustafa *et al.*, "Efficacy of Bacillus probiotic mixture on the immunological responses and histopathological changes of Nile tilapia (*Oreochromis niloticus*, L)

challenged with *Streptococcus iniae*," *Aquaculture Research.*, vol. 52, 2020.

- [4] M. S. Monir *et al.*, "Effect of an Oral Bivalent Vaccine on Immune Response and Immune Gene Profiling in Vaccinated Red Tilapia (*Oreochromis spp.*) during Infections with *Streptococcus iniae* and *Aeromonas hydrophila*," *Biology.*, vol. 11, no. 9, p. 1268, 2022.
- [5] C.-C. Chen *et al.*, "Development of Disease-Resistance-Associated Microsatellite DNA Markers for Selective Breeding of Tilapia (*Oreochromis spp.*) Farmed in Taiwan," *Genes.*, vol. 13, no. 1, p. 99, 2021.
- [6] A. Jutagate *et al.*, "Adaptive artificial multiple intelligence fusion system (A-AMIFS) for enhanced disease detection in Nile Tilapia," *Aquaculture Reports.*, vol. 39, p. 102418, 2024.
- [7] N. M. M. Pires, T. Dong, Z. Yang, and L. F. B. A. da Silva, "Recent methods and biosensors for foodborne pathogen detection in fish: progress and future prospects to sustainable aquaculture systems," *Critical Reviews in Food Science and Nutrition.*, vol. 61, no. 11, pp. 1852–1876, 2021.
- [8] จาตุรนต์ ป้องน้ำไผ่ และ ชนกกันต์ จิตมณัส, "การตรวจวินิจฉัยเชื้อแบคทีเรียก่อโรคที่ระบาดในฟาร์มปลานิล โดยใช้เทคนิคพีซีอาร์-อาร์เอฟแอลพี," *Journal Of Agricultural Research And Communications.*, vol. 33, no. 3, Art. no. 3, 2017.
- [9] S. Vega-Heredia, I. Giffard-Mena, and M. Reverter, "Bacterial and viral co-infections in aquaculture under climate warming: co-evolutionary implications, diagnosis, and

- treatment," *Diseases of Aquatic Organisms.*, vol. 158, pp. 1–20, 2024.
- [10] M. Saleh *et al.*, "The myxozoans *Myxobolus cerebralis* and *Tetracapsuloides bryosalmonae* modulate rainbow trout immune responses: quantitative shotgun proteomics at the portals of entry after single and co-infections," *Frontiers in Cellular and Infection Microbiology.*, vol. 14, p. 1369615, 2024.
- [11] D. Yang, X. Chen, X. Sun, and G. Tan, "Research progress of artificial intelligence and sensors in intelligent fishery aquaculture prediction and health management system," Nov. 2024, doi: 10.20944/preprints202411.0149.v1.
- [12] T. Zhang *et al.*, "Fully automatic system for fish biomass estimation based on deep neural network," *Ecological Informatics.*, vol. 79, p. 102399, 2024.
- [13] J. Deka, S. Laskar, and B. Bakliyal, "Automated Freshwater Fish Species Classification using Deep CNN," *Journal of The Institution of Engineers (India): Series B.*, vol. 104, no. 3, pp. 603–621, 2023.
- [14] J. G. A. Barbedo, "A Review on the Use of Computer Vision and Artificial Intelligence for Fish Recognition, Monitoring, and Management," *Fishes.*, vol. 7, no. 6, Dec. 2022.
- [15] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of a convolutional neural network," in *2017 International Conference on Engineering and Technology (ICET)*, Aug. 2017.
- [16] K. Bohara, P. Joshi, K. P. Acharya, and G. Ramena, "Emerging technologies revolutionising disease diagnosis and monitoring in aquatic animal health," *Reviews in Aquaculture.*, vol. 16, no. 2, pp. 836–854, 2024.
- [17] J. Yamkasem, P. Tattiyapong, B. Gorgoglione, and W. Surachetpong, "Uncovering the first occurrence of *Tilapia parvovirus* in Thailand in tilapia during co-infection with *Tilapia tilapiaevirus*," *Transboundary and Emerging Diseases.*, vol. 68, 2021.
- [18] J. Delamare-Deboutteville *et al.*, "Development of a rapid and cost-effective multiplex PCR-Nanopore sequencing assay for accurate diagnosis of four tilapia pathogens," *bioRxiv.*, Jun. 2023, doi: 10.1101/2023.05.13.540096.
- [19] Wiley Online Library, "Journal of Food Quality," [Online]. Available: <https://onlinelibrary.wiley.com/journal/6095>. [Accessed 20 February 2025].
- [20] M. S. Ahmed, T. T. Aurpa, and Md. A. K. Azad, "Fish Disease Detection Using Image Based Machine Learning Technique in Aquaculture," *The Journal of King Saud University Computer and Information Sciences.*, vol. 34, no. 8, pp. 5170–5182, 2022.
- [21] M. Çakir, M. Yilmaz, M. A. Oral, H. Ö. Kazanci, and O. Oral, "Accuracy assessment of RFerns, NB, SVM, and kNN machine learning classifiers in aquaculture," *Journal of King Saud University.*, vol. 35, no. 6, p. 102754, 2023.
- [22] C. Palaiokostas, "Predicting for disease resistance in aquaculture species using machine learning models," *Aquaculture Reports.*, vol. 20, p. 100660, 2021.

- [23] C.-Y. Wang, H. Liao, Y.-H. Wu, P.-Y. Chen, J.-W. Hsieh, and I.-H. Yeh, "CSPNet: A new backbone that can enhance learning capability of CNN," in *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2020.
- [24] S. Woo, J. Park, J.-Y. Lee, and I. S. Kweon, "CBAM: Convolutional block attention module," in *Computer Vision – ECCV 2018*, vol. 11211, V. Ferrari, M. Hebert, C. Sminchisescu, and Y. Weiss, Eds., in *Lecture Notes in Computer Science*, Cham, Switzerland: Springer International Publishing, 2018.
- [25] Z. Zheng, P. Wang, W. Liu, J. Li, R. Ye, and D. Ren, "Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression," in *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 34, no. 07, 2020, pp. 12993–13000.
- [26] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA: IEEE, 2016, pp. 770–778.
- [27] ชัชฎา หนูสาย และ สิริศักดิ์ ชีช้าง, "โมบายล์แอปพลิเคชันระบบผู้เชี่ยวชาญสำหรับวินิจฉัยโรคปอดอักเสบ โดยใช้เทคนิคการทำเหมืองข้อมูล," [ออนไลน์]. แหล่งที่มา: <https://www.repository.rmutsv.ac.th/handle/123456789/2834>. [วันที่เข้าถึง 14 มีนาคม 2568].
- [28] S. Dodge and L. Karam, "Understanding How Image Quality Affects Deep Neural Networks," [Online]. Available: 10.48550/arXiv.1604.04004. [Accessed 20 February 2025].
- [29] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *Journal of Big Data.*, vol. 6, no. 1, p. 60, 2019.
- [30] J. H. Price and J. Murnan, "Research limitations and the necessity of reporting them," *American Journal of Health Education.*, vol. 35, no. 2, pp. 66–67, 2004.
- [31] P. T. Ross and N. L. Bibler Zaidi, "Limited by our limitations," *Perspectives on Medical Education.*, vol. 8, no. 4, pp. 261–264, 2019.
- [32] D. Bolya, C. Zhou, F. Xiao, and Y. J. Lee, "YOLACT: Real-Time Instance Segmentation," in *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, 2019, pp. 9156–9165.