



การเปรียบเทียบการแยกส่วนภาพและไม่แยกส่วนภาพเพื่อจำแนกน้ำหนักเฉลี่ยของ ปลานิลแดงโดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง

A Comparison of Image Segmentation and Image Non-Segmentation to Classify Average Weight of Red Tilapia Using Machine Learning Techniques

พิมพ์ลภัส สุวรรณสิงห์, รุ่งพฤทธิ จงเจริญสุข, เรืองชาย ยूनพันธ์ และ วราห์ เทพาหุดี*

Pimlapat Suwannasing, Roongparit Jongjaraunsuk, Rueangchary Yoonpundh and Wara Taparhudee*

ภาควิชาเพาะเลี้ยงสัตว์น้ำ คณะประมง มหาวิทยาลัยเกษตรศาสตร์

Department of Aquaculture, Faculty of Fisheries, Kasetsart University

Received : 14 January 2022

Revised : 11 April 2022

Accepted : 20 July 2022

บทคัดย่อ

การศึกษาในครั้งนี้เปรียบเทียบการใช้ภาพที่แยกส่วนเฉพาะลำตัวปลาส่วนบนบริเวณใกล้ผิวน้ำ โดยมีการตัดครีบทอง และพื้นหลังออก (5 ตัวต่อภาพ) กับภาพที่ไม่แยกส่วน (ภาพดั้งเดิม) โดยใช้เทคนิคการเรียนรู้ด้วยเครื่องในการประเมินน้ำหนักปลานิลแดง โดยภาพที่ใช้ประกอบด้วยภาพปลาช่วงน้ำหนักเฉลี่ย 3 กลุ่ม กลุ่มละ 48 ภาพ ได้แก่ ช่วงน้ำหนักเฉลี่ย 300-500 กรัม/ตัว 501-700 กรัม/ตัว และ 701-900 กรัม/ตัว โดยใช้แบบจำลองต้นไม้ตัดสินใจ (Decision Tree) แบบจำลองเพื่อนบ้านใกล้ที่สุด (K-nearest Neighbor) แบบจำลองวิธีการเรียนรู้แบบเบย์ (Naïve Bayes) แบบจำลองข้อมูลด้วยเครื่องเวกเตอร์ค้ำยัน (Support Vector Machine) และแบบจำลองการเรียนรู้เชิงลึก (Deep Learning) ผลการศึกษาพบว่าการใช้ภาพดั้งเดิมให้ค่าเฉลี่ยความถูกต้อง ความแม่นยำ และความระลึกลับที่ดีกว่าและมีค่าแตกต่างทางสถิติ ($P < 0.05$) กับการใช้ภาพที่แยกส่วน โดยภาพดั้งเดิมให้ค่าเฉลี่ยความถูกต้อง ความแม่นยำ และความระลึกลับจากทุกแบบจำลองเท่ากับ 80.97 ± 3.35 , 81.23 ± 3.41 และ 82.17 ± 5.26 เปอร์เซ็นต์ ตามลำดับ ส่วนการใช้ภาพที่แยกส่วนเท่ากับ 59.85 ± 3.45 , 61.03 ± 4.49 และ 59.58 ± 3.45 เปอร์เซ็นต์ ตามลำดับ ในกรณีของแบบจำลองที่ใช้พบว่าแบบจำลองการเรียนรู้เชิงลึกให้ค่าเฉลี่ยความถูกต้องสูงที่สุด เนื่องจากเป็นแบบจำลองที่มีประสิทธิภาพสูงในการจัดการกับชุดข้อมูลที่มีความซับซ้อน จากผลการศึกษาในครั้งนี้แสดงให้เห็นว่าการประเมินน้ำหนักเฉลี่ยปลานิลแดงจากภาพถ่ายโดยการใช้เทคนิคการเรียนรู้ด้วยเครื่องสามารถใช้ภาพแบบดั้งเดิมได้ โดยมีความถูกต้องสูงและทำงานได้รวดเร็วเมื่อเทียบกับการใช้ภาพที่แยกส่วนเฉพาะลำตัวปลาส่วนบนบริเวณใกล้ผิวน้ำ โดยมีการตัดครีบทอง และพื้นหลังออก

คำสำคัญ : การประเมินน้ำหนัก ; การเรียนรู้ด้วยเครื่อง ; การจำแนกรูปภาพ ; ปลานิลแดง



Abstract

In this study, the segmented images of the upper body of fish near the water surface in which the fins, tail, and background were removed (5 fish per image) were compared with non-segmented images (original images) using machine learning techniques for weight estimation of red tilapia. The images used consisted of 3 groups of fish with an average weight of 300–500, 501-700, and 701–900 g/fish, with 48 images in each group. Decision Tree, K-nearest Neighbor, Naïve Bayes, Support Vector Machine, and Deep Learning models were applied to predict the average weight of the fish in images. The results showed that using the original images had better average results of accuracy, precision, and recall than using the segmented images, and there was a statistical difference ($P < 0.05$). The average accuracy, precision, and recall for the original images were 80.97 ± 3.35 , 81.23 ± 3.41 , and 82.17 ± 5.26 percent, respectively. While the results of the segmented images were 59.85 ± 3.45 , 61.03 ± 4.49 , and 59.58 ± 3.45 percent, respectively. In the case of the model used, the deep learning model was found to provide the highest accuracy average because it is a highly effective model to deal with complex data sets. The results of this study showed that the original images could be used for red tilapia weight estimation with high accuracy and faster processing than the segmented images.

Keywords : weight estimation ; machine learning ; image classification ; red tilapia



บทนำ

หลักการเลี้ยงสัตว์น้ำที่ดีในระหว่างการเลี้ยงควรมีการประเมินน้ำหนักเพื่อทราบการเจริญเติบโต และใช้ในการประเมินปริมาณอาหารที่จะให้ได้อย่างถูกต้องเหมาะสมและลดปัญหาคุณภาพน้ำจากอาหารที่เหลือ ทำให้สัตว์น้ำเจริญเติบโตได้ดี และยังช่วยควบคุมต้นทุนค่าอาหารได้อีกด้วย (Ridha, 2006) ซึ่งวิธีการที่ใช้กันทั่วไปคือสุ่มจับปลาขึ้นมาจำนวนหนึ่งแล้วทำการชั่งน้ำหนักและวัดความยาว แต่ปัญหาที่พบคือการทำปลาขึ้นมาอาจจะทำให้เกิดการบอบช้ำหรือเป็นการรบกวน ทำให้เกิดความเครียด ส่งผลเสียต่อการกินอาหารและประสิทธิภาพการเจริญเติบโต อีกทั้งยังใช้แรงงานคนจำนวนมากและใช้เวลานานในการปฏิบัติงาน (Silva *et al.*, 2015) จากปัญหาดังกล่าวจึงมีนักวิจัยหลายคนได้ใช้เทคนิคการประมวลผลภาพ (Image processing) เพื่อประเมินน้ำหนักปลาจากภาพถ่าย เช่น Balaban *et al.* (2010) ประยุกต์ใช้เทคนิคการประมวลผลภาพแบบพื้นที ในการทำนายน้ำหนักปลาเซลมอนแต่ละสายพันธุ์ Viazzi *et al.* (2015) พัฒนาการประเมินน้ำหนักปลากะพงขาวที่ว่ายอยู่อิสระในถังที่เลี้ยงในระบบน้ำหมุนเวียน Konovalov *et al.* (2018) และ Jongjaraunsuk & Taparhudee (2021) ใช้เทคนิคการประมวลผลภาพแบบพื้นทีในการประเมินน้ำหนักปลากะพงขาวแบบใช้ภาพถ่ายจากด้านข้าง (Side views) และแบบใช้ภาพถ่ายจากมุมสูง (Top views) ตามลำดับ

การใช้เทคนิคการประมวลผลภาพยังคงมีข้อจำกัดในเรื่องของวิธีการก่อนการประมวลผล (Preprocessing) ซึ่งยังมีความจำเป็นต้องมีการจัดทำ หรือดัดแปลงภาพจากภาพดั้งเดิม เช่น การตัด (Cutting or Cropping) การแยกส่วน (Segmentation) หรือการปรับปรุงคุณภาพของภาพ (Image Enhancement) เช่น การทำภาพเป็นขาวดำ (Binary image) จากภาพบางส่วนหรือทั้งหมด เป็นต้น รวมทั้งหากคุณภาพของภาพถ่ายไม่ดี ก็จะส่งผลต่อความถูกต้องในการประมวลผลได้จากข้อด้อยของการประมวลผลภาพดังกล่าวจึงเป็นที่มาของการประยุกต์ใช้เทคนิคการเรียนรู้ด้วยเครื่อง (Machine learning) เพื่อลดขั้นตอนการทำงานดังกล่าว ซึ่งการประยุกต์ใช้เทคนิคการเรียนรู้ด้วยเครื่องจะเป็นการนำการจำแนกรูปภาพ (Image classification) มาใช้เพื่อประเมินน้ำหนักปลาจากภาพถ่าย โดยแบบจำลองการจำแนกประเภทที่ใช้กันทั่วไป เช่น Odone *et al.* (2001) คัดคุณภาพปลาเทราต์ โดยใช้แบบจำลองข้อมูลด้วยเครื่องเวกเตอร์ค้ำยัน (Support Vector Machine; SVM) ร่วมกับคอมพิวเตอร์วิทัศน์ (Computer Vision) พบว่ามีความถูกต้องประมาณ 97 เปอร์เซ็นต์ Saberioon & Cisař (2018) ประเมินน้ำหนักปลากะพงขาว โดยใช้แบบจำลองป่าสุ่ม (Random Forest) และแบบจำลองข้อมูลด้วยเครื่องเวกเตอร์ค้ำยัน พบว่าแบบจำลองทั้งสองมีค่าความถูกต้องมากกว่า 86 เปอร์เซ็นต์ และ Fernandes *et al.* (2020) ทำนายน้ำหนักปลานิล โดยใช้แบบจำลองการเรียนรู้เชิงลึก (Deep Learning) โครงข่ายประสาทแบบคอนโวลูชัน (Convolution Neutral Network; CNN) ร่วมกับคอมพิวเตอร์วิทัศน์ พบว่ามีความถูกต้องเท่ากับ 90 เปอร์เซ็นต์ เป็นต้น อย่างไรก็ตามการได้มาซึ่งภาพเพื่อประเมินน้ำหนักปลาส่วนใหญ่ยังต้องนำปลาขึ้นมาจากน้ำ ซึ่งจะทำให้ปลาที่จับขึ้นมาเกิดความเครียด บาดเจ็บ หยุดการกินอาหาร อีกทั้งปลาที่อยู่ในบ่อเดียวกันยังถูกรบกวนอาจจะส่งผลกระทบต่อการกินอาหารได้เช่นกัน (Jongjaraunsuk & Taparhudee, 2022) นอกจากนี้การใช้เทคนิคการเรียนรู้ด้วยเครื่องเพื่อประเมินน้ำหนักปลาจากภาพถ่ายโดยส่วนมากยังคงมีความจำเป็นต้องนำภาพถ่ายที่ได้ เข้าสู่กระบวนการก่อนการประมวลผลภาพ หรือใช้ภาพถ่ายจากด้านข้าง ซึ่งในทางปฏิบัติสำหรับการเพาะเลี้ยงสัตว์น้ำในประเทศไทยถ้าสามารถประเมินน้ำหนักปลาจากภาพถ่ายด้านบนได้จะช่วยให้การทำงานสะดวกขึ้น แต่การประเมินผลจากภาพถ่ายปลาด้านบนมี 2 วิธีคือ เลือกเฉพาะภาพปลาที่อยู่ที่มีน้ำหนักกับเลือกภาพปลาทั้งหมด



ซึ่งส่วนนี้ยังไม่ได้มีการศึกษาการเปรียบเทียบมาก่อน ดังนั้นจึงเป็นที่มาของการศึกษาในครั้งนี้คือ การประเมินน้ำหนักโดยใช้ภาพที่แยกส่วนเฉพาะลำตัวปลาส่วนบนบริเวณใกล้ผิวน้ำ โดยมีการตัดครีบ หาง และพื้นหลังออกกับภาพที่ไม่แยกส่วน โดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง ซึ่งจากตัวอย่างข้างต้นจะเห็นได้ว่ามีการใช้แบบจำลองการจำแนกประเภทอยู่หลายแบบ แต่ยากที่จะเข้าใจว่าแบบจำลองใดให้ผลลัพธ์ในการจำแนกรูปภาพที่ดีกว่า (Chugh *et al.*, 2020) การศึกษาครั้งนี้จึงเลือกใช้แบบจำลองต้นไม้ตัดสินใจ (Decision Tree), แบบจำลองวิธีการเรียนรู้แบบเบย์ (Naive Bayes), แบบจำลองเพื่อนบ้านที่ใกล้ที่สุด (K-Nearest Neighbors; K-NN), แบบจำลองข้อมูลด้วยเครื่องเวกเตอร์ค้ำยัน (SVM) และแบบจำลองการเรียนรู้เชิงลึกโครงข่ายประสาทแบบคอนโวลูชัน (CNN) และในการศึกษาครั้งนี้เลือกปลาชนิดแดงเพราะมีจุดเด่นคือเรื่องสีที่มีความแตกต่างอย่างชัดเจนกับสีของน้ำจึงง่ายต่อการทำการแยกตัวปลาออกจากน้ำ และปลานิลแดงถือเป็นปลาที่ได้รับความนิยมในการเลี้ยงเพิ่มมากขึ้น เนื่องด้วยมีสีแดงคล้ายกับพันธุ์ปลาทะเลที่ราคาแพง ทำให้มีราคาขายที่สูงขึ้น ส่งผลให้ความต้องการในตลาดทั้งในและต่างประเทศเพิ่มขึ้น (Watanabe *et al.*, 2010)

วิธีดำเนินการวิจัย

สถานที่เก็บข้อมูลและข้อมูลการเลี้ยงโดยทั่วไป

การศึกษานี้ใช้ข้อมูลรูปภาพจากฟาร์มเลี้ยงปลานิลแดงเอกชน จังหวัดบุรีรัมย์ เก็บข้อมูลโดยใช้บ่อขนาด 0.16 เฮกตาร์ (1 ไร่ หรือ 1,600 ตารางเมตร) จำนวน 3 บ่อ ซึ่งมีการจัดการที่เหมือนกัน มีการให้อากาศโดยใช้เครื่องตีน้ำ ขนาดเครื่อง 3 แรงม้า จำนวน 4 เครื่อง/บ่อ โดยเปิดเครื่องตีน้ำตลอด 24 ชั่วโมง ให้อาหารเม็ดสำเร็จรูปแบบเม็ดลอยที่มีโปรตีนอย่างน้อย 30 เปอร์เซ็นต์ วันละ 3 ครั้ง (08.00 น., 11.30 น. และ 16.30 น.) โดยใช้เครื่องให้อาหารอัตโนมัติ น้ำหนักปลาเริ่มต้นเฉลี่ยที่ทำการเลี้ยงคือประมาณ 200 กรัม/ตัว จำนวนที่ปล่อยเฉลี่ยคือ 19,000 ตัว/บ่อ (ประมาณ 12 ตัว/ตารางเมตร) การประเมินน้ำหนักจะสุ่มปลาขึ้นมาจำนวน 45-50 ตัว/บ่อ ทุก 2 สัปดาห์ (วันที่ 1 และ 16 ของทุกเดือน) เพื่อชั่งน้ำหนักและวัดความยาวโดยใช้วิธีการชั่งวัดด้วยมือ และมีการคำนวณค่าร้อยละสัมประสิทธิ์ของความแปรปรวนของน้ำหนักตัวปลา หรือร้อยละการแตกขนาดของปลา (The Percentage of Coefficient of Variation; %CV) โดยคำนวณดังสมการที่ 1 ซึ่งน้ำหนักเฉลี่ย ณ วันที่ทำการจับประมาณ 1,000 กรัม/ตัว อัตรารอดเฉลี่ย 95 เปอร์เซ็นต์ ระยะเวลาในการเลี้ยงต่อ 1 รุ่น คือ 120 วัน

$$\%CV = \frac{SD}{\bar{x}} \times 100 \quad (1)$$

โดยที่ SD คือ ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation)

\bar{x} คือ ค่าเฉลี่ยของน้ำหนัก (Mean)

โดยระหว่างการเลี้ยงมีการวัดคุณภาพน้ำทุกวันและมีการจัดการคุณภาพน้ำให้อยู่ในเกณฑ์ที่เหมาะสมคือ ปริมาณออกซิเจนที่ละลายในน้ำ (Dissolved oxygen; DO), อุณหภูมิ (Water temperature), ความเป็นกรดเป็นด่าง (pH), ความโปร่งใส (Transparency), แอมโมเนียรวม (Total ammonia-nitrogen; TAN), ไนไตรท์-ไนโตรเจน (Nitrite-nitrogen; NO₂⁻-N)

ที่ระดับมากกว่า 4 มิลลิกรัม/ลิตร, 25-32°C, 7.5-8.5, 30-60 เซนติเมตร, น้อยกว่า 1 มิลลิกรัม/ลิตร และน้อยกว่า 0.25 มิลลิกรัม/ลิตร ตามลำดับ (Azaza *et al.*, 2008; Kolding *et al.*, 2008; Wang *et al.*, 2009; Tran-Duy *et al.*, 2012; Lusiana *et al.*, 2021) โดยปริมาณออกซิเจนที่ละลายน้ำและอุณหภูมิน้ำตรวจวัดโดยใช้เครื่อง YSI Pro20 ความเป็นกรดเป็นด่างใช้ YSI Pro10 ความโปร่งใส วัดโดยใช้จาน 2 สี สำหรับวัดความโปร่งใส (Secchi disc) ในส่วนของแอมโมเนียรวมและไนโตรท-ไนโตรเจนจะทำการตรวจสอบในห้องปฏิบัติการโดยใช้วิธีของ APHA (2005)

การวางแผนการทดลอง

ในการทดลองจะวางแผนการทดลองแบบเปรียบเทียบค่าเฉลี่ยของสองกลุ่มประชากร กรณีที่กลุ่มประชากรทั้งสองเป็นอิสระต่อกัน (Two Independent Samples) โดยในแต่ละชุดการทดลองมีรายละเอียดดังต่อไปนี้

ชุดการทดลองที่ 1 ภาพที่แยกส่วนเฉพาะลำตัวปลาส่วนบนบริเวณใกล้ผิวน้ำ โดยมีการตัดครีบ หาง และพื้นหลังออก

ชุดการทดลองที่ 2 ภาพที่ไม่แยกส่วนหรือภาพดั้งเดิม




Figure 1 The segmented image of fish near the water surface without fins, tail, and background (left), and non-segmented or original image (right).

การได้มาซึ่งภาพ

ปลานิลแดงที่อยู่ในบ่อ 3 บ่อ จะถูกถ่ายภาพช่วงก่อนให้อาหารครั้งแรกของวัน (08.00 น.) ซึ่งถือว่าเป็นช่วงเวลาที่เหมาะสมเนื่องจากโดยปกติปลานิลจะมีระยะเวลาการย่อยอาหารโดยเฉลี่ยอยู่ที่ 4-5 ชั่วโมง ก่อนเข้าสู่สภาวะที่กระเพาะอาหารว่าง (Empty stomach) (Riche *et al.*, 2004) ซึ่งสภาวะดังกล่าวปลาจะมีความพร้อมในการกินอาหารทำให้มีพฤติกรรมว่ายน้ำขึ้นมาอยู่บนผิวน้ำ และในวันเก็บข้อมูลภาพจริงไม่มีการให้อาหารในเวลาดังกล่าว อีกทั้งยังเป็นช่วงที่ไม่มีแสงสะท้อนจากดวงอาทิตย์ (Sun glare) อีกด้วย ซึ่งแสงสะท้อนจากดวงอาทิตย์ถือเป็นปัจจัยที่สำคัญที่ทำให้การประมวลผลภาพได้รับผลกระทบ (เสียพื้นที่ในการประมวลผล) การถ่ายภาพจะทำการถ่ายครั้งละ 15 ภาพ/บ่อ โดยกล้องจะถูกติดตั้งบริเวณเหนือจุดที่ให้อาหาร โดยเลนส์กล้องสูงจากผิวน้ำ 70 เซนติเมตร กล้องที่ใช้คือกล้องเว็บแคมยี่ห้อ Oker HD629 ความละเอียดของกล้องคือ 1920 x 1080 พิกเซล เลนส์ที่ใช้ในการถ่ายภาพคือ เลนส์ Five-layer Glass และเซ็นเซอร์ในการถ่ายภาพเป็นแบบ CMOS ซึ่งการเก็บภาพปลาจะทำการเก็บภาพเดือนละ 2 ครั้ง โดยถ่ายทุก 2 สัปดาห์ (วันเดียวกันกับการสูบน้ำหน้าหนักด้วยมือ)

การแยกส่วนภาพ

การแยกส่วนภาพจะใช้รูปภาพปลา 3 ช่วงน้ำหนักคือ 1. ช่วงน้ำหนักเฉลี่ย 300-500 กรัม/ตัว 2. ช่วงน้ำหนักเฉลี่ย 501-700 กรัม/ตัว และ 3. ช่วงน้ำหนักเฉลี่ย 701-900 กรัม/ตัว นำภาพไปแยกส่วนเฉพาะลำตัวปลาส่วนที่อยู่บริเวณผิวน้ำที่มีการตัดครีบหาง และพื้นหลังออก เนื่องจากครีบและหางปลาส่งผลต่อผลลัพธ์ (Hao *et al.*, 2016) โดยใช้โปรแกรม ImageJ คอมพิวเตอร์ที่ใช้ในการวิเคราะห์ข้อมูลใช้คอมพิวเตอร์ยี่ห้อ HP Pavilion Gaming Laptop 15-ec1xxx (ระบบปฏิบัติการ Windows 10 Home หน่วยความจำ (RAM) 8 GB; ประเภทของระบบปฏิบัติการเป็นแบบ 64-Bit) โดยขั้นตอนจะเริ่มจากการเลือกรูปภาพที่จะทำการแยกส่วน (Select file photo) จากนั้นใช้ Polygon selections และเลือกเฉพาะบริเวณส่วนลำตัวของปลา ซึ่งไม่รวมครีบและหาง ตามวิธีของ Jongjaraunsuk & Taparhudee (2021) จากนั้นทำการดึงวัตถุพื้นน้ำออกจากพื้นหลัง (Clear outside) (ภาพที่ 2) ทำให้ได้ภาพเฉพาะส่วนลำตัวปลากับพื้นหลังสีดำ ซึ่งจำนวนปลาที่ได้จากการแยกส่วนเฉพาะลำตัวปลาส่วนบนบริเวณใกล้ผิวน้ำที่มีการตัดครีบหาง และพื้นหลังออกโดยเฉลี่ย 5 ตัว/ภาพ

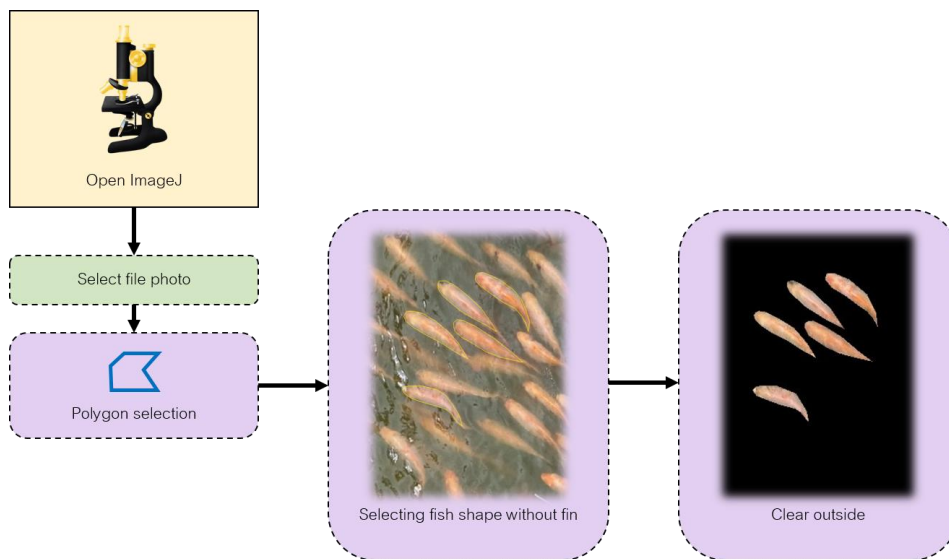


Figure 2 The process of segmenting of fish without fins, tail, and background using ImageJ (The image on the left is an original image and the image on the right is a segmented image).

การเปรียบเทียบผลการประเมินน้ำหนักเฉลี่ยระหว่างการใช้วิธีแยกภาพปลากับวิธีการไม่แยกภาพโดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง

ภาพที่แยกส่วนเฉพาะลำตัวปลาส่วนบนบริเวณใกล้ผิวน้ำ โดยมีการตัดครีบหาง และพื้นหลังออกและภาพดั้งเดิม จะถูกนำมาประมวลผลเพื่อแยกข้อมูลจุดภาพทั้งหมดที่ประกอบด้วยพื้นที่ศึกษาออกเป็นกลุ่มย่อย โดยใช้ ค่าสถิติเป็น



ตัวกำหนดความแตกต่างระหว่างจุดภาพ โดยใช้โปรแกรม RapidMiner Studio Version 9.8 ร่วมกับส่วนขยาย (Image Mining; IMMI) ที่ใช้ในการทำเหมืองรูปภาพสำหรับโปรแกรม RapidMiner ทั้งนี้แบบจำลองที่ใช้เพื่อการทำนายผลในการศึกษาครั้งนี้ คือ แบบจำลองต้นไม้ตัดสินใจ (Decision Tree) กำหนดพารามิเตอร์ Criterion เป็น Gain_ratio, Maximal depth มีค่าเท่ากับ 5, Confidence เท่ากับ 0.1, Minimal gain เท่ากับ 0.01, Minimal leaf size เท่ากับ 2, Minimal size for split เท่ากับ 4 และ Number of pre-pruning alternatives มีค่าเท่ากับ 3 แบบจำลองวิธีการเรียนรู้แบบเบย์ (Naive Bayes) แบบจำลองเพื่อนบ้านที่ใกล้ที่สุด (K-Nearest Neighbors; K-NN) กำหนด K เท่ากับ 5 แบบจำลองข้อมูลด้วยเครื่องเวกเตอร์ค้ำยัน (Support Vector Machine; SVM) กำหนด Kernel type เป็น Radial Basis Function (RBF) และแบบจำลองการเรียนรู้เชิงลึก (Deep Learning) โดยใช้โครงข่ายประสาทแบบคอนโวลูชัน (Convolution Neutral Network; CNN) กำหนด Activation function เป็น Rectified Linear Unit (RELU), Optimization algorithm เป็น Stochastic Gradient Descent (SGD), จำนวน Hidden layer 2 ชั้น Hidden layer ชั้นแรกประกอบด้วย Hidden node จำนวน 50 node และ Hidden layer ชั้นที่สองประกอบด้วย Hidden node จำนวน 50 node และ Epsilon เท่ากับ 1.0E-8 โดยขั้นตอนเริ่มจากตัวดำเนินการ (Operator) ใช้ Multiple Color Image Opener (MCIO) เพื่อเปิดรูปภาพทั้งหมดจากโฟลเดอร์ (Folder) จากนั้นกำหนดกลุ่มเป็น 3 กลุ่มและกำหนดป้ายกำกับให้กับกลุ่ม โดยกลุ่มแรกคือ ชวงน้ำหนักเฉลี่ย 300-500 กรัม/ตัว กลุ่มสองคือ ชวงน้ำหนักเฉลี่ย 501-700 กรัม/ตัว และกลุ่มสามคือ ชวงน้ำหนักเฉลี่ย 701-900 กรัม/ตัว ใช้รูปภาพชวงน้ำหนักเฉลี่ยละ 48 รูป (จำนวนภาพที่แยกส่วนเฉพาะลำตัวปลาส่วนบนที่มีการตัดครีบ หาง และพื้นหลังออกและภาพดั้งเดิมอย่างละ 144 ภาพ) จากนั้นเพิ่มตัวดำเนินการย่อยใน MCIO โดยเพิ่ม Global Feature Extractor from a Single Image เพื่อแยกคุณลักษณะทั้งหมดจากแต่ละรูปภาพ ซึ่งในส่วนนี้มีการเพิ่มตัวดำเนินการ Global statistics เพื่อวิเคราะห์ค่าสถิติคือ Mean, Median, Standard Deviation, Skewness, Kurtosis, Peak, Min gray value, Max gray value, Normalized center of mass, Area fraction และ Edginess สำหรับการทวนสอบ (Validation) จะทำการตรวจสอบแบบไขว้ (Cross validation) เพื่อใช้วัดประสิทธิภาพของแบบจำลอง โดยในการศึกษานี้ค่า k ถูกกำหนดเป็น 10 คือ การแบ่งข้อมูลออกเป็น 10 ส่วน โดยที่แต่ละส่วนมีจำนวนข้อมูลเท่ากัน หลังจากนั้นข้อมูลหนึ่งส่วนจะใช้เป็นตัวทดสอบประสิทธิภาพของแบบจำลอง โดยทำวนไปเช่นนี้จนครบจำนวนที่แบ่งไว้ (ภาพที่ 3) และตัววัดประสิทธิภาพที่ใช้ในการวัดประสิทธิภาพของแบบจำลองคือ ค่าความถูกต้อง (Accuracy) เป็นการวัดความถูกต้องของแบบจำลองที่พิจารณารวมทุกกลุ่ม ความแม่นยำ (Precision) เป็นการวัดความแม่นยำของข้อมูล โดยพิจารณาแยกทีละกลุ่ม และความระลึก (Recall) เป็นการวัดความถูกต้องของแบบจำลอง โดยพิจารณาแยกทีละกลุ่ม โดยคำนวณดังสมการที่ 2-4

$$\text{Accuracy} = \left(\frac{TP+TN}{TP+TN+FP+FN} \right) \times 100 \quad (2)$$

$$\text{Precision} = \left(\frac{TP}{TP+FP} \right) \times 100 \quad (3)$$

$$\text{Recall} = \left(\frac{TP}{TP+FN} \right) \times 100 \quad (4)$$

โดยที่ True Positive (TP) คือ ค่าที่ทำนายถูกต้องในกลุ่มที่สนใจ
True Negative (TN) คือ ค่าที่ทำนายถูกต้องในกลุ่มอื่น ๆ
False Positive (FP) คือ ค่าที่ทำนายผิดในกลุ่มที่สนใจ
False Negative (FN) คือ ค่าที่ทำนายผิดในกลุ่มอื่น ๆ

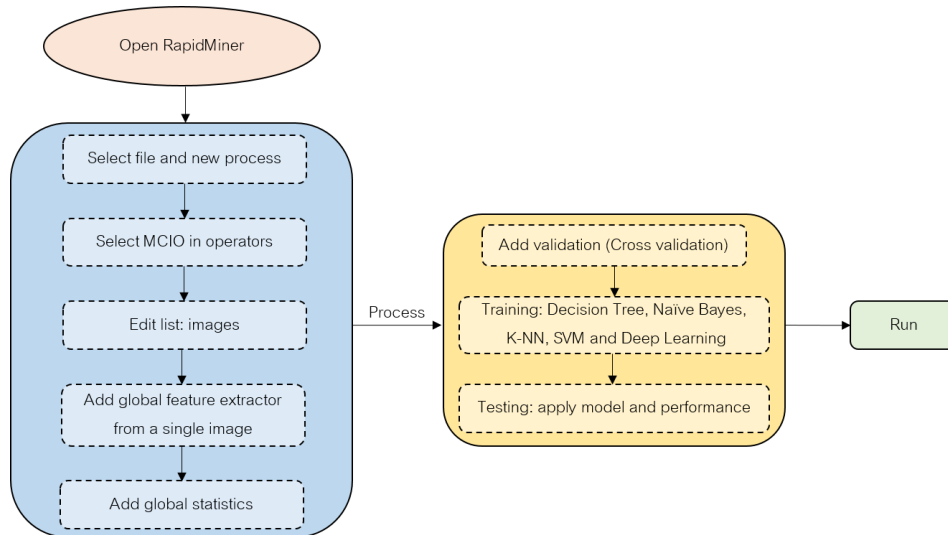


Figure 3 The process of image classification using RapidMiner.

การวิเคราะห์ข้อมูล

นำค่าเฉลี่ยความถูกต้อง ความแม่นยำ และความระลึจากทุกแบบจำลองข้างต้นของการใช้ภาพที่แยกส่วนเฉพาะลำตัวปลาส่วนบนบริเวณใกล้ผิวน้ำ โดยมีการตัดครีบ หาง และพื้นหลังออกกับภาพดั้งเดิม มาวิเคราะห์ค่าทางสถิติเพื่อเปรียบเทียบความแตกต่างค่าเฉลี่ยของสองกลุ่มประชากรที่เป็นอิสระต่อกัน (Independent Samples T-test) ที่ระดับความเชื่อมั่น 95 เปอร์เซ็นต์ โดยใช้โปรแกรม Statistics Package for the Social Science for Windows (SPSS) version 26.0

ผลการวิจัย

น้ำหนักเฉลี่ยและการแตกขนาดของปลาทดลอง

ขนาดปลาที่นำมาศึกษาในครั้งนี้แบ่งออกเป็น 3 กลุ่ม พบว่ากลุ่มแรกช่วงน้ำหนักเฉลี่ย 300-500 กรัม/ตัว มีค่าเฉลี่ยน้ำหนักอยู่ที่ 391.03±76.16 กรัม/ตัว และมีการแตกขนาด 19.48 เปอร์เซ็นต์ กลุ่มที่สองช่วงน้ำหนักเฉลี่ย 501-700 กรัม/ตัว มีค่าเฉลี่ยน้ำหนักอยู่ที่ 512.98±69.01 กรัม/ตัว และมีการแตกขนาด 13.45 เปอร์เซ็นต์ และกลุ่มที่สามช่วงน้ำหนักเฉลี่ย 701-900 กรัม/ตัว มีค่าเฉลี่ยน้ำหนักอยู่ที่ 710.14±92.03 กรัม/ตัว และมีการแตกขนาด 12.96 เปอร์เซ็นต์ (ตารางที่ 1)

**Table 1** Average weight and Percentage of Coefficient of Variation (%CV) of 3 average weight ranges.

Group	Weight range (g/fish)	Average weight (g/fish)	CV (%)
1	300-500	391.03±76.16	19.48
2	501-700	512.98±69.01	13.45
3	701-900	710.14±92.03	12.96

การศึกษาเปรียบเทียบผลการประเมินน้ำหนักเฉลี่ยระหว่างการใช้ภาพปลาแบบแยกส่วนเฉพาะลำตัวปลาส่วนบนที่มีการตัดครีบ หาง และพื้นหลังออกกับการใช้ภาพปลาดั้งเดิมโดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง

ผลการศึกษาพบว่า การใช้ภาพดั้งเดิมให้ค่าเฉลี่ยความถูกต้อง ความแม่นยำ และความระลึกลึกดีกว่าและมีค่าแตกต่างกันทางสถิติ ($P < 0.05$) กับการใช้ภาพที่แยกส่วนเฉพาะลำตัวปลาส่วนบนบริเวณใกล้ผิวน้ำ โดยมีการตัดครีบ หาง และพื้นหลังออก โดยที่การใช้ภาพดั้งเดิมให้ค่าเฉลี่ยความถูกต้อง ความแม่นยำ และความระลึกลึกจากทุกแบบจำลองเท่ากับ 80.97 ± 3.35 , 81.23 ± 3.41 และ 82.17 ± 5.26 เปอร์เซ็นต์ ตามลำดับ ในขณะที่การใช้ภาพที่แยกส่วนเท่ากับ 59.85 ± 3.45 , 61.03 ± 4.49 และ 59.58 ± 3.45 เปอร์เซ็นต์ ตามลำดับ ซึ่งแบบจำลองการเรียนรู้เชิงลึกโดยใช้โครงข่ายประสาทแบบคอนโวลูชันให้ค่าความถูกต้อง ความแม่นยำ และความระลึกลึกสูงสุด รองลงมาเป็นแบบจำลองข้อมูลด้วยเครื่องเวกเตอร์ค้ำยัน แบบจำลองเพื่อนบ้านใกล้ที่สุด แบบจำลองต้นไม้ตัดสินใจและแบบจำลองวิธีการเรียนรู้แบบเบย์ ตามลำดับ แสดงไว้ดังตารางที่ 2

Table 2 Comparison of accuracy, precision and recall between the segmented images of fish near the water surface without fins, tail, and background and original images.

Treatments	Models	Accuracy (%)	Precision (%)	Recall (%)
The segmented images	Decision Tree	59.03	63.55	59.03
	Naïve Bayes	54.17	53.25	54.17
	KNN	59.72	61.03	59.72
	SVM	61.81	63.52	61.80
	Deep learning (CNN)	63.19	63.80	63.19
	Mean±SD	59.85±3.45	61.03±4.49	59.58±3.45
Non-segmented images	Decision Tree	78.47	78.45	78.47
	Naïve Bayes	77.08	77.79	77.08
	KNN	80.56	80.38	80.56
	SVM	84.03	84.03	90.03
	Deep learning (CNN)	84.72	85.51	84.72
	Mean±SD	80.97±3.35	81.23±3.41	82.17±5.26
P-value		< 0.05	< 0.05	< 0.05

จากผลการศึกษาจะเห็นได้ว่าแบบจำลองการเรียนรู้เชิงลึกโดยใช้โครงข่ายประสาทแบบคอนโวลูชันมีความถูกต้องในการทำนายสูงสุด แต่ยังคงมีความผิดพลาดประมาณ 15 เปอร์เซ็นต์ ซึ่งอาจจะเกิดจากภาพที่มีลักษณะที่แตกต่างกัน โดยเมื่อนำภาพจากบ่อเดียวกันและวันเดียวกันมาเปรียบเทียบกัน พบว่าภาพที่ทำนายถูกจะมีจำนวนปลาที่ผิวน้ำมากกว่าเมื่อเปรียบเทียบกับภาพที่ทำนายผิด (ภาพที่ 4)




Figure 4 Examples of original images were correctly predicted (a) and incorrectly predicted (b).

วิจารณ์ผลการวิจัย

การศึกษาในครั้งนี้พบว่าการใช้ภาพดั้งเดิมให้ผลการทำนายค่าน้ำหนักเฉลี่ยทั้งความถูกต้อง ความแม่นยำ และความระมัดระวังกว่าการใช้ภาพที่แยกส่วน ซึ่งโดยปกติการแยกส่วนภาพ เช่น การใช้คุณลักษณะของสี (Color feature) การใช้คุณลักษณะของพื้นผิว (Texture feature) และการใช้รูปร่าง (Shape feature) เป็นต้น จะช่วยให้การทำนายมีความแม่นยำเพิ่มขึ้น (Medjahed, 2015) อย่างไรก็ตามในขั้นตอนการแยกส่วนภาพยังคงเป็นขั้นตอนที่เพิ่มระยะเวลาในการทำงาน และในบางกรณีอาจจะมีข้อผิดพลาดเกิดขึ้นในกระบวนการดังกล่าวได้ โดยเฉพาะอย่างยิ่งในกรณีของการแยกส่วนเพื่อสกัดภาพของสิ่งมีชีวิต เนื่องจากจะมีการขยับ หรือเคลื่อนไหวที่อวัยวะต่าง ๆ (Viazzi *et al.*, 2015) โดยตัวอย่างงานวิจัยที่ผ่านมาที่ได้ทำการประเมินน้ำหนักปลาจากภาพที่ทำการแยกส่วนเพื่อสกัดคุณลักษณะต่าง ๆ เช่น Viazzi *et al.* (2015) ศึกษาการประเมินน้ำหนักของปลาเก๋ายก (Jade Perch; *Scortum barcoo*) โดยใช้ภาพที่ทำการแยกส่วนเฉพาะพื้นที่ส่วนลำตัว ผลการศึกษาพบว่ามีความถูกต้อง 99 เปอร์เซ็นต์ Fernandes *et al.* (2020) ทำการแยกส่วนพื้นที่ภาพถ่ายของตัวปลา เพื่อใช้ในการประเมิน



น้ำหนัปลาไนล์ (Nile tilapia; *Oreochromis niloticus*) พบว่ามีความถูกต้องอยู่ที่ 96 เปอร์เซ็นต์ และ Jongjaraunsuk & Taparhudee (2021) ประเมินน้ำหนัปลาตะเพียนขาว (Asian Seabass; *Lates calcarifer*) โดยใช้ภาพที่ทำการแยกส่วนเฉพาะส่วนลำตัว ไม่รวมครีบและหาง ผลการศึกษาพบว่ามีความถูกต้อง 96 เปอร์เซ็นต์ เป็นต้น แต่จากผลการศึกษาในครั้งนี้พบว่า การใช้ภาพปลาที่ทำการแยกส่วนเฉพาะส่วนบนในการประเมินน้ำหนัปลาให้ค่าเฉลี่ยความถูกต้องจากทุกแบบจำลองเท่ากับ 59.85 ± 3.45 เปอร์เซ็นต์ ส่วนการใช้ภาพดั้งเดิมเท่ากับ 80.97 ± 3.35 เปอร์เซ็นต์ ซึ่งการใช้ภาพดั้งเดิมมีความถูกต้องมากกว่าการใช้ภาพปลาที่ทำการแยกส่วน เนื่องจากปลามีการแตกขนาดระหว่างการเลี้ยง เมื่อถ่ายภาพก่อนเวลาให้อาหารครั้งแรกของวัน ปลาที่มีขนาดใหญ่จะว่ายน้ำขึ้นมาบริเวณผิวน้ำก่อน ทำให้การแยกส่วนอาจได้เฉพาะปลาที่มีขนาดใหญ่และตัวปลาที่แยกได้มีจำนวนน้อย จึงอาจจะไม่ใช่ตัวแทนที่แท้จริงของปลาทั้งหมด ในขณะที่การใช้ภาพดั้งเดิมจะมีจำนวนปลา (วัตถุ) มากกว่าภาพที่ทำการแยกส่วน โดยทั่วไปแล้วหากมีจำนวนวัตถุให้เรียนรู้มาก จะทำให้ประสิทธิภาพในการทำนายสูง

นอกจากนั้นในการศึกษาครั้งนี้พบว่าแบบจำลองที่มีค่าความถูกต้องมากที่สุดคือ แบบจำลองการเรียนรู้เชิงลึก (Deep learning) ซึ่งในการศึกษาครั้งนี้ใช้แบบจำลองการเรียนรู้เชิงลึกโครงข่ายประสาทแบบคอนโวลูชัน (Convolution Neutral network; CNN) โดยมีค่าความถูกต้องเท่ากับ 84.72 เปอร์เซ็นต์ เนื่องจากเป็นแบบจำลองที่มีวิธีการทำงานเหมือนระบบประสาทในสมองมนุษย์ มีการประมวลผลแบบขนาน (Parallel processing) ใช้โครงข่ายประสาทแบบไปข้างหน้าหลายชั้น (Multi-layer feed forward neural network) ซึ่งเป็นการเรียนรู้แบบมีผู้สอน (Supervised learning) ทำให้แบบจำลองนี้มีประสิทธิภาพสูง นิยมใช้ในการจัดการกับชุดข้อมูลที่ซับซ้อน หรือใช้เพื่อการสกัดคุณลักษณะจากข้อมูลที่ไม่ค่อยเป็นระเบียบหรือไม่มีโครงสร้างที่ชัดเจน (Unstructured data) โดยสามารถเรียนรู้และดึงคุณลักษณะที่จำเป็นออกจากรูปภาพได้โดยอัตโนมัติ อีกทั้งยังมีประสิทธิภาพในการจำแนกประเภทหลายกลุ่ม (Multi-class classification) จึงทำให้เป็นแบบจำลองที่นิยมใช้ในกลุ่มการเรียนรู้ด้วยเครื่อง (Goodfellow *et al.*, 2016; Chugh *et al.*, 2020) และปัจจุบันเป็นวิธีที่ดีที่สุดสำหรับคอมพิวเตอร์วิทัศน์ในการระบุภาพ (Image identification) และจำแนกรูปภาพ (Cifuentes-Alcobendas & Domínguez-Rodrigo, 2019) ซึ่งสอดคล้องกับงานวิจัยที่ใช้การเรียนรู้เชิงลึกในการประมวลผล เช่น Iqbal *et al.* (2019) ใช้ในการจำแนกปลา 6 ชนิดที่แตกต่างกัน ได้แก่ สกุล *Cirrhilabrus*, *Lethrinus*, *Thunnus*, *Epinephelus*, *Scomberoides* และ *Lutjanus* พบว่ามีความถูกต้องประมาณ 91 เปอร์เซ็นต์ Álvarez-Ellacuría *et al.* (2020) ใช้ในการประเมินขนาดปลาแฮคยูโรป (*Merluccius merluccius*) พบว่ามีความถูกต้องมากกว่า 90 เปอร์เซ็นต์ Fernandes *et al.* (2020) ประเมินน้ำหนัปลาไนล์ พบว่ามีความถูกต้องเท่ากับ 90 เปอร์เซ็นต์ และ Tseng *et al.* (2020) ใช้ในการประเมินขนาดปลาทะเลน้ำลึกหลายชนิด เช่น *Thunnus obesus*, *Makaira nigricans*, *Prionace glauca* เป็นต้น พบว่ามีความถูกต้องมากกว่า 97 เปอร์เซ็นต์ อย่างไรก็ตาม การใช้แบบจำลองการเรียนรู้เชิงลึกก็ยังคงมีข้อเสียคือ กลไกการทำงานที่ไม่สามารถอธิบายได้เนื่องจากความซับซ้อนของการประมวลผลในแบบจำลอง มีต้นทุนและความต้องการกำลังการประมวลผลในระดับสูง (Yang *et al.*, 2020) นอกจากนี้ผลการทดลองพบว่าแบบจำลองข้อมูลด้วยเครื่องเวกเตอร์ค่าอันมีความถูกต้องใกล้เคียงกับแบบจำลองการเรียนรู้เชิงลึก ทั้งนี้เพราะข้อดีของแบบจำลองแบบนี้คือใช้ได้กับข้อมูลที่ไม่มากนัก แต่ถ้าข้อมูลที่มีสัญญาณรบกวน (Noise) เช่น กลุ่มเป้าหมายที่ซ้อนทับกัน จะทำให้ประสิทธิภาพของแบบจำลองลดลง (Almasi & Rouhani, 2016)



สำหรับการศึกษาในครั้งนี้ได้ค่าความถูกต้องต่ำกว่าตัวอย่างงานวิจัยข้างต้น เนื่องจากระยะความลึกของตัวปลาจากผิวน้ำอาจมีผลต่อความถูกต้องในการทำนาย และอาจมีปัจจัยอื่นร่วมด้วย เช่น ความขุ่นของน้ำที่ทำให้ปริมาณแสงทะลุผ่านน้ำลดลง ส่งผลต่อคุณภาพของภาพ และการทับซ้อนของตัวปลา เมื่อวัตถุทับซ้อนกัน พื้นที่พิกเซลจะมากกว่าปกติและอาจนับเป็นหนึ่งในวัตถุที่มีขนาดใหญ่ (Jongjaraunsuk *et al.*, 2019; Xu *et al.*, 2021) เป็นต้น แต่การศึกษาก่อนหน้านี้ส่วนใหญ่ยังคงทำในห้องปฏิบัติการ หรือสถานที่ที่มีการควบคุมสภาพแวดล้อมต่าง ๆ และการได้มาซึ่งภาพยังต้องอาศัยการจับปลาขึ้นมาจากน้ำ ทำให้ปลาเกิดความเครียด (Pickering & Christie, 1981; Fernandes *et al.*, 2020) ดังนั้นการศึกษานี้ครั้งนี้แสดงให้เห็นว่าสามารถใช้ภาพดั้งเดิมในการประเมินน้ำหนักของปลานิลแดงได้ โดยที่ไม่ต้องจับปลาขึ้นมาจากน้ำ ซึ่งจะไม่รบกวนและไม่ทำให้สัตว์น้ำเกิดความเครียด จึงเป็นวิธีที่มีประสิทธิภาพ รวดเร็ว และให้ค่าความถูกต้องในการทำนายสูง ซึ่งในการศึกษาต่อไปควรหาวิธีการในการลดอิทธิพลของปัจจัยที่มีผลต่อคุณภาพภาพลง และเพิ่มจำนวนข้อมูลให้มากขึ้นเพื่อให้มีความถูกต้องเพิ่มขึ้นต่อไป

สรุปผลการวิจัย

การประเมินน้ำหนักเฉลี่ยของปลานิลแดงโดยการใช้เทคนิคการเรียนรู้ด้วยเครื่องสามารถดำเนินการได้โดยใช้ภาพปลาที่ไม่แยกส่วนหรือภาพดั้งเดิมได้ โดยการใช้แบบจำลองการเรียนรู้เชิงลึก (Deep Learning) แบบโครงข่ายแบบคอนโวลูชัน (Convolution Neural Network; CNN) ได้ค่าเฉลี่ยความถูกต้องสูงที่สุดเท่ากับ 84.72 เปอร์เซ็นต์ อย่างไรก็ตามการศึกษานี้เป็นเพียงการเสนอแนวทางในการประเมินน้ำหนักปลาจากภาพถ่าย และควรมีการศึกษาและพัฒนาเพื่อให้ได้ค่าที่มีความถูกต้องเพิ่มขึ้นต่อไป

กิตติกรรมประกาศ

ขอขอบคุณปัทมราชฟาร์ม จ. บุรีรัมย์ สำหรับสถานที่และข้อมูลทำวิจัย ห้องปฏิบัติการวิศวกรรมเพาะเลี้ยงสัตว์น้ำ ภาควิชาเพาะเลี้ยงสัตว์น้ำ คณะประมง มหาวิทยาลัยเกษตรศาสตร์ในการช่วยสนับสนุนและให้คำปรึกษา และทุนสนับสนุนส่งเสริมการศึกษาค้นคว้าวิจัย คณะประมง ภายใต้โครงการ ระบบสนับสนุนการตัดสินใจโดยใช้เทคนิคการเรียนรู้จากเครื่องเพื่อค้นหาแนวทางปฏิบัติที่ดีที่สุดของปลานิลแดงที่เลี้ยงในระบบเพาะเลี้ยงสัตว์น้ำหมุนเวียนแบบหมุนเวียนกลางแจ้ง

เอกสารอ้างอิง

Almasi, O.N., & Rouhani, M. (2016). Fast and de-noise support vector machine training method based on fuzzy clustering method for large real world datasets. *Turkish Journal of Electrical Engineering and Computer Sciences*, 24(1), 219-233. <https://doi.org/10.3906/elk-1304-139>

Álvarez-Ellacuría, A., Palmer, M., Catalán, I.A., & Lisani, J-L. (2020). Image-based, unsupervised estimation of fish size from commercial landings using deep learning. *ICES Journal of Marine Science*, 77(4), 1330-1339.



- American Public Health Association, American Water Works Association and Water Pollution Control Federation (APHA). (2005). *Standard Methods of the Examination of Water and Wastewater*. Maryland, U.S.A.: United Book Press.
- Azaza, M.S., Dhraïef, M.N., & Kraïem, M.M. (2008). Effects of water temperature on growth and sex ratio of juvenile Nile tilapia *Oreochromis niloticus* (Linnaeus) reared in geothermal waters in southern Tunisia. *Journal of Thermal Biology*, 33(2), 98-105.
- Balaban, M.O., Sengor, G.F.U., Soriano, M.G., & Ruiz, E.G. (2010). Using image analysis to predict the weight of Alaskan salmon of different species. *Journal of Food Science Food Sci*, 75(3), 157-162.
- Chugh, R.S., Bhatia, V., Khanna, K., & Bhatia, V. (2020). A Comparative Analysis of Classifiers for Image Classification. *2020 10th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*, 248-253.
- Cifuentes-Alcobendas, G., & Domínguez-Rodrigo, M. (2019). Deep learning and taphonomy: high accuracy in the classification of cut marks made on fleshed and defleshed bones using convolutional neural networks. *Scientific Reports*, 9(1), 18933.
- Fernandes, A.F.A., Turra, E.M., Alvarenga, É.R.d., Passafaro, T.L., Lopes, F.B., Alves, G.F.O., Singh, V., & Rosa, G.J.M. (2020). Deep Learning image segmentation for extraction of fish body measurements and prediction of body weight and carcass traits in Nile tilapia. *Computers and Electronics in Agriculture*, 170.
- Goodfellow, I., Bengio, Y., Courville, A. (2016). *Deep Learning*. Cambridge: The MIT Press.
- Hao, M., Yu, H., & Li, D. (2016). The Measurement of Fish Size by Machine Vision - A Review. In *Computer and Computing Technologies in Agriculture IX*, 15-32.
- Iqbal, M.A., Wang, Z., Ali, Z.A., & Riaz, S. (2019). Automatic Fish Species Classification Using Deep Convolutional Neural Networks. *Wireless Personal Communications*, 116(2), 1043-1053.
- Jongjaraunsuk, R., & Taparhudee, W. (2021). Weight Estimation of Asian Sea Bass (*Lates calcarifer*) Comparing Whole Body with and without Fins using Computer Vision Technique. *Walailak Journal of Science and Technology (WJST)*, 18(10).



- Jongjaraunsuk, R., Taparhudee, W., & Nimitkul, S. (2019). Feasibility Study Application of Aerial Photographic Using Unmanned Aerial Vehicle for Weight Estimation in River-Based Hybrid Red Tilapia Cage Culture. *In Conference Proceeding: The 6 Annual Conference – Conference on Engineering and Information Technology*. (pp. 45-56). Kyoto: Japan.
- Kolding, J., Haug, L., & Stefansson, S. (2008). Effect of ambient oxygen on growth and reproduction in Nile tilapia (*Oreochromis niloticus*). *Canadian Journal of Fisheries and Aquatic Sciences*, 65(7), 1413-1424.
- Lusiana, E.D., Musa, M., & Ramadhan, S. (2021). Determinants of Nile tilapia's (*Oreochromis niloticus*) growth in aquaculture pond in Batu, Indonesia. *Biodiversitas Journal of Biological Diversity*, 22(2), 999-1005.
- Medjahed, S. A. (2015). A Comparative Study of Feature Extraction Methods in Images Classification. *International Journal of Image, Graphics and Signal Processing*, 7(3), 16-23.
- Odone, F., Trucco, E., & Verri, A. (2001). A trainable system for grading fish from images. *Applied Artificial Intelligence*, 15(8), 735-745.
- Pickering, A.D. & Christie, P. (1981). Changes in the concentrations of plasma cortisol and thyroxine during sexual maturation of the hatchery-reared brown trout, *Salmo trutta* L. *General and Comparative Endocrinology Comp Endocrinol*, 44(4), 487-96.
- Riche, M., Haley, D.I., Oetker, M., Garbrecht, S., & Garling, D.L. (2004). Effect of feeding frequency on gastric evacuation and the return of appetite in tilapia *Oreochromis niloticus* (L.). *Aquaculture*, 234(1-4), 657-673.
- Ridha, M.T. (2006). Comparative study of growth performance of three strains of Nile tilapia, *Oreochromis niloticus*, L. at two stocking densities. *Aquaculture Research*, 37(2), 172-179.
- Saberioon, M., & Cisař, P. (2018). Automated within tank fish mass estimation using infrared reflection system. *Computers and Electronics in Agriculture*, 150, 484-492.
- Silva, T.S.d.C., Santos, L.D.d., Silva, L.C.R.d., Michelato, M., Furuya, V.R.B., & Furuya, W.M. (2015). Length-weight relationship and prediction equations of body composition for growing-finishing cage-farmed Nile tilapia. *Revista Brasileira de Zootecnia*, 44(4), 133-137.



- Tran-Duy, A., Van Dam, A.A., & Schrama, J.W. (2012). Feed intake, growth and metabolism of Nile tilapia (*Oreochromis niloticus*) in relation to dissolved oxygen concentration. *Aquaculture Research*, 43(5), 730-744.
- Tseng, C-H., Hsieh, C-L., & Kuo, Y-F. (2020). Automatic measurement of the body length of harvested fish using convolutional neural networks. *Biosystems Engineering*, 189, 36-47.
- Viazzi, S., Hoestenbergh, S.V., Goddeeris, B.M., & Berckmans, D. (2015). Automatic mass estimation of Jade perch *Scortum barcoo* by computer vision. *Aquacultural Engineering*, 64, 42-48.
- Wang, T., Lefevre, S., Huong, D.T.T., Cong, N.V. & Bayley, M. (2009). Chapter 8 The Effects of Hypoxia On Growth and Digestion. In J.G. Richards, A.P. Farrell, & C.J. Brauner. (Eds.), *Fish Physiology*. (pp. 362-396) Burlington: Academic Press.
- Watanabe, W. O., Losordo, T. M., Fitzsimmons, K., & Hanley, F. (2010). Tilapia Production Systems in the Americas: Technological Advances, Trends, and Challenges. *Reviews in Fisheries Science*, 10(3-4), 465-498.
- Xu, H.-h., Wang, X.-q., Wang, D., Duan, B.-g., & Rui, T. (2021). Object detection in crowded scenes via joint prediction. *Defence Technology*.
- Yang, X., Zhang, S., Liu, J., Gao, Q., Dong, S., & Zhou, C. (2020). Deep learning for smart fish farming: applications, opportunities and challenges. *Reviews in Aquaculture*, 13(1), 66-90.