



Intelligent Water Quality Forecasting and Monitoring System based on Water Quality Index using Machine Learning and IoT Techniques

Wanarase Sinhashthita¹, Tossaporn Alherbe¹, Kamol Chareonsri² and Chayaporn Kaensar^{1,*}

¹*Department of Mathematics and Digital Technology, Faculty of Science, Ubon Ratchathani University*

²*Data Science and Software Innovation Program, Faculty of Science, Ubon Ratchathani University*

*Email: chayaporn.k@ubu.ac.th

Received < 4 Jun. 2026>; Revised < 1 Sep. 2026 >; Accepted < 2 Sep. 2026 >

Abstract

This research utilizes Internet of Things (IoT) technology and Machine Learning (ML) to develop a prototype for a smart water quality forecasting and monitoring system. The study focuses on analyzing the Reduced Water Quality Index (rWQI) based on water temperature, pH, and Total Dissolved Solids (TDS). To forecast water quality 1 to 6 hours in advance, the performance of four predictive models was evaluated and compared: Extremely Randomized Trees (ET), Random Forest (RF), Simple Linear Regression (LR), and Multiple Linear Regression (MLR). The efficiency of these algorithms was validated using four key evaluation metrics: Coefficient of Determination (R^2), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), and Symmetric Mean Absolute Percentage Error (sMAPE). The experimental results indicated that the predictive performance of the models varied significantly depending on the forecasting horizon. In the short-term horizon (1–3 hours ahead), the RF model achieved the highest performance, with an R^2 of 0.566 and an MAE of 5.215 in the first hour. Conversely, for long-term forecasting (4–6 hours ahead), all models exhibited a significant drop in performance ($R^2 < 0$), yielding higher prediction errors than the Mean Baseline. This long-term limitation stems from high water quality volatility in real-world environments combined with error accumulation in multi-step ahead forecasting. In conclusion, these findings emphasize that aligning model selection with the specific forecasting horizon is critical for enhancing system efficiency and stability. The developed model demonstrates high accuracy and suitability for short-term early warnings within 3 hours. This knowledge enables operators to plan water quality management with precision and speed, thereby reducing operational costs and the risk of aquatic livestock loss. Furthermore, this system serves as a technological prototype in digital agriculture, elevating conventional water quality monitoring into proactive management through intelligent technology.

Keywords: Water quality forecasting; Machine learning; Internet of Things; Reduced Water Quality Index

ระบบพยากรณ์และเฝ้าระวังคุณภาพน้ำอัจฉริยะตามดัชนีคุณภาพน้ำ ด้วยเทคนิคการเรียนรู้ของเครื่องและอินเทอร์เน็ตของสรรพสิ่ง

วันนเรศวร์ สิงห์ขันธ์¹ ทศพร อเลิร์ป¹ กมล เจริญศรี² และ ชยาพร แก่นสาร^{1,*}

¹ภาควิชาคณิตศาสตร์และเทคโนโลยีดิจิทัล คณะวิทยาศาสตร์ มหาวิทยาลัยอุบลราชธานี

²สาขาวิทยาการข้อมูลและนวัตกรรมซอฟต์แวร์ คณะวิทยาศาสตร์ มหาวิทยาลัยอุบลราชธานี

*Email: chayaporn.k@ubu.ac.th

บทคัดย่อ

งานวิจัยนี้ใช้เทคโนโลยีอินเทอร์เน็ตของสรรพสิ่ง (IoT) ร่วมกับการเรียนรู้ของเครื่อง (Machine Learning) เพื่อพัฒนาต้นแบบระบบพยากรณ์และเฝ้าระวังคุณภาพน้ำอัจฉริยะ โดยมุ่งเน้นการวิเคราะห์ค่าดัชนีคุณภาพน้ำแบบลดรูป (Reduced Water Quality Index: rWQI) จากข้อมูลอุณหภูมิ น้ำ ค่าความเป็นกรด-ด่าง (pH) และปริมาณของแข็งละลายน้ำรวม (TDS) ผ่านการเปรียบเทียบประสิทธิภาพของ 4 โมเดล ได้แก่ Extremely Randomized Trees (ET), Random Forest (RF), Simple Linear Regression (LR) และ Multiple Linear Regression (MLR) ในการพยากรณ์ค่าคุณภาพน้ำล่วงหน้าระยะเวลา 1–6 ชั่วโมง โดยทำการทดสอบประสิทธิภาพของอัลกอริทึมผ่านตัวชี้วัด 4 ด้าน ได้แก่ สัมประสิทธิ์การตัดสินใจ (R^2) ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) ค่าความคลาดเคลื่อนเปอร์เซ็นต์สัมบูรณ์เฉลี่ย (MAPE) และค่าความคลาดเคลื่อนเปอร์เซ็นต์สัมบูรณ์เฉลี่ยแบบสมมาตร (sMAPE) โดยผลการทดลองพบว่าประสิทธิภาพของแบบจำลองมีความแปรผันตามระยะเวลาพยากรณ์ ซึ่งในระยะสั้น (1–3 ชั่วโมงล่วงหน้า) แบบจำลอง RF ให้ประสิทธิภาพการพยากรณ์ที่ดีที่สุด (โดยในชั่วโมงแรกมีค่า $R^2 = 0.566$ และ $MAE = 5.215$) ในขณะที่การพยากรณ์ระยะยาว (4–6 ชั่วโมงล่วงหน้า) พบว่าทุกแบบจำลองมีประสิทธิภาพลดลงอย่างมาก ($R^2 < 0$) ซึ่งมีความคลาดเคลื่อนสูงกว่าการใช้ค่าเฉลี่ยของข้อมูล (Mean Baseline) โดยข้อจำกัดนี้มีสาเหตุมาจากความผันผวนของคุณภาพน้ำที่สูงในสภาพแวดล้อมจริง ร่วมกับความคลาดเคลื่อนสะสมของการทำนายข้ามช่วงเวลาหลายก้าว (Multi-step Ahead Forecasting) ดังนั้นจากข้อค้นพบดังกล่าวจึงสรุปได้ว่าการใช้แบบจำลองให้สอดคล้องกับกรอบเวลาพยากรณ์เป็นปัจจัยสำคัญในการเพิ่มประสิทธิภาพและความเสถียรในการประเมินและพยากรณ์ดัชนีคุณภาพน้ำ ซึ่งพบว่าโมเดลที่พัฒนาขึ้นมีความแม่นยำและเหมาะสมสำหรับแจ้งเตือนล่วงหน้าในระยะสั้น ในระยะ 1-3 ชั่วโมง ซึ่งองค์ความรู้นี้จะช่วยให้ผู้ใช้สามารถวางแผนควบคุมคุณภาพน้ำได้อย่างแม่นยำและรวดเร็ว ช่วยลดต้นทุนและความเสี่ยงในการสูญเสียสัตว์น้ำ อีกทั้งยังเป็นต้นแบบทางเทคโนโลยีเกษตรดิจิทัลที่ช่วยยกระดับการเฝ้าระวังคุณภาพน้ำทั่วไปสู่การบริหารจัดการเชิงรุกด้วยเทคโนโลยีอัจฉริยะ

คำสำคัญ: การพยากรณ์คุณภาพน้ำ; การเรียนรู้ของเครื่อง; อินเทอร์เน็ตของสรรพสิ่ง; ดัชนีคุณภาพน้ำแบบลดรูป

บทนำ

การเพาะเลี้ยงสัตว์น้ำและการจัดการระบบนิเวศจำลองในระบบปิด นับว่ามีการเติบโตอย่างต่อเนื่อง ทั้งในแง่การเพาะเลี้ยงเชิงพาณิชย์และการเลี้ยงเพื่อความสวยงามในสังคมเมือง สอดคล้องกับรายงานของ Ornamental Fish Market โดย Straits Research (2024) ที่ระบุว่ามูลค่าตลาดปลาสวยงามและสัตว์น้ำจำลองทั่วโลกในปี 2024 สูงถึง 5.95 พันล้านดอลลาร์สหรัฐ และมีอัตราการเติบโตเฉลี่ยร้อยละ 7.80 ต่อปี ขณะที่ในบริบทของประเทศไทย ข้อมูลจาก Department of Fisheries (2024) ระบุว่ามูลค่าการส่งออกสัตว์น้ำสวยงามและเทคโนโลยีที่เกี่ยวข้องมีจำนวนมากกว่า 1,000 ล้านบาท โดยมีห่วงโซ่อุปทานครอบคลุมตั้งแต่ผู้เลี้ยงปลาสวยงามทั่วไป เกษตรกรผู้เพาะเลี้ยงรายย่อย ไปจนถึงผู้ประกอบการค้าปลีกจำนวนมาก

อย่างไรก็ตาม แม้การขยายตัวของอุตสาหกรรมจะสะท้อนถึงศักยภาพการเติบโตของการเพาะเลี้ยงสัตว์น้ำ แต่ในทางปฏิบัติการรักษาสมาคมของสภาพแวดล้อมทางน้ำกลับมีความซับซ้อนสูง เพราะการจัดการน้ำในระบบมีความไวต่อความแปรปรวนของปัจจัยแวดล้อมต่าง ๆ เป็นอย่างมาก ซึ่งเป็นผลมาจากการสะสมของเสียและค่าทางน้ำต่าง ๆ เช่น ค่าความเป็นกรด-ด่างที่ควบคุมระดับความเป็นพิษของของเสีย ปริมาณของแข็งละลายน้ำรวมทั้งสะท้อนความหนาแน่นของสารอินทรีย์สะสม และอุณหภูมิที่เป็นปัจจัยเร่งปฏิกิริยาทางเคมี รวมทั้งค่าการละลายของออกซิเจนในน้ำ เป็นต้น ซึ่งการเปลี่ยนแปลงของกลุ่มค่าต่าง ๆ เหล่านี้อาจส่งผลกระทบต่อดัชนีคุณภาพน้ำในภาพรวม (Water Quality Index: WQI) ตามแนวคิดของ Brown *et al.* (1970) ด้วยเหตุนี้การติดตามและตรวจสอบคุณภาพน้ำแบบเรียลไทม์จึงมีความสำคัญอย่างมาก

ด้วยเหตุผลดังกล่าว จึงมีการศึกษาวิจัยอย่างแพร่หลายในการนำเทคโนโลยีอินเทอร์เน็ตของสรรพสิ่ง (Internet of Things: IoT) เข้ามาช่วยบริหารจัดการและตรวจสอบค่าน้ำแบบเรียลไทม์ อย่างไรก็ตามแม้ว่าเทคโนโลยีดังกล่าวจะช่วยอำนวยความสะดวกในการจัดเก็บและประมวลผลข้อมูลในภาพรวมเป็นอย่างดี แต่ในทางปฏิบัติกลับพบว่าการใช้งานจริงนั้นยังพบข้อจำกัดอยู่ 3 ประเด็นหลักได้แก่ ประเด็นแรก คือ ขาดการประมวลผลข้อมูลร่วมกัน โดยระบบเดิมมักแสดงผลค่าข้อมูลของน้ำแยกส่วนกันและขาดการวิเคราะห์ข้อมูลในภาพรวม ดังเช่นในงานวิจัยของ Arthi *et al.* (2024) และ Dayaday and Namoco (2021) ซึ่งแม้จะรายงานค่าข้อมูลน้ำได้อย่างรวดเร็ว แต่ยังไม่สามารถนำค่าข้อมูลเหล่านั้นมาประมวลผลร่วมกันเพื่อระบุสถานะความปลอดภัยในภาพรวม ณ เวลานั้นได้ ส่งผลให้การแจ้งเตือนค่าในลำดับวิกฤตทำได้น้อยลง ประเด็นที่สอง คือ มีข้อจำกัดด้านต้นทุนและความซับซ้อนของอุปกรณ์ เช่นในงานวิจัยบนคลาวด์ของ Stojanovic and Chaudhary (2023) ที่แม้ว่าจะสามารถประมวลผลพารามิเตอร์ค่าน้ำแบบองค์รวมได้อย่างมีประสิทธิภาพ แต่กลับพบว่ามีงบประมาณและการบำรุงรักษาที่สูงเนื่องจากระบบจำเป็นต้องติดตั้งเซ็นเซอร์จำนวนมาก เช่น ความเข้มแสง ความชื้น ความเร็วลม และแอมโมเนียไนโตรเจน ซึ่งอาจไม่เหมาะกับการประยุกต์ใช้จริงในระบบที่มีทรัพยากรจำกัด และประเด็นสุดท้ายคือ ขาดการพยากรณ์แนวโน้มข้อมูลล่วงหน้า โดยงานวิจัยส่วนใหญ่มักมุ่งเน้นแค่การรายงานหรือแจ้งเตือนค่าในสถานการณ์ปัจจุบัน ดังจะเห็นได้จากงาน Forhad *et al.* (2024) ที่พัฒนาระบบตรวจวัดคุณภาพน้ำที่มีจุดเด่นคือประหยัดพลังงานและเก็บบันทึกสถิติในอดีตได้ (Historical Data Logging) แต่การแจ้งเตือนยังคงจำกัดอยู่เพียงการรายงานค่าที่เกิดขึ้น ณ ช่วงเวลานั้น ๆ เช่นเดียวกับงานของ Duangwongsa *et al.* (2022) ที่เน้นการส่งสัญญาณแจ้งเตือนผ่านแอปพลิเคชันบนมือถือเมื่อค่าพารามิเตอร์ไม่ตรงตามเกณฑ์ที่กำหนดไว้ ซึ่งการแจ้งเตือนในลักษณะนี้มักล่าช้าเกินกว่าจะป้องกันได้ทัน อีกทั้งยังขาดการประมวลผลข้อมูลในอดีตเพื่อพยากรณ์แนวโน้มล่วงหน้า รวมถึงขาดการประเมินประสิทธิภาพของแบบจำลองตามกรอบเวลาพยากรณ์ที่ต่างกัน (Horizon-Dependent Performance Evaluation) ซึ่งประเด็นนี้สอดคล้องกับแนวคิดของ Fandiño Pelayo *et al.* (2025) ที่เน้นว่าความปลอดภัยของระบบนิเวศทางน้ำจะต้องอาศัยทั้งข้อมูลปัจจุบัน และการประมวลผลเชิงพยากรณ์ผ่านแบบจำลองการทำนายผล (Predictive Model) ร่วมกัน จะช่วยเพิ่มประสิทธิภาพในการบริหารจัดการคุณภาพน้ำให้มากยิ่งขึ้น

ดังนั้นงานวิจัยนี้จึงเสนอระบบต้นแบบพยากรณ์คุณภาพน้ำอัจฉริยะที่สามารถแจ้งเตือนผู้ใช้งานได้อย่างแม่นยำภายใต้ต้นทุนที่เหมาะสม โดยใช้พารามิเตอร์หลัก 3 ตัวแปร ได้แก่ อุณหภูมิ (Temperature) ค่าความเป็นกรด-ด่าง (pH) และปริมาณของแข็งละลายน้ำรวม (Total Dissolved Solids: TDS) เพื่อคำนวณค่าดัชนีคุณภาพน้ำแบบลดรูป (Reduced WQI: rWQI) ซึ่งสอดคล้องกับแนวคิดของ De Oliveira *et al.* (2022) และ Siswanto *et al.* (2023) ที่ระบุว่าการใช้ข้อมูลดังกล่าวผ่านอุปกรณ์ IoT มีประสิทธิภาพเพียงพอในการบริหารจัดการและวิเคราะห์ค่าคุณภาพน้ำ นอกจากนี้งานวิจัยนี้ได้ประยุกต์ใช้เทคนิคการ

วิเคราะห์การถดถอย (Regression Analysis) ในการแก้ปัญหาการถดถอย (Regression Problem) สำหรับพยากรณ์ค่า rWQI ซึ่งเป็นค่าต่อเนื่องในช่วง 0–100 โดยเปรียบเทียบประสิทธิภาพของ 4 แบบจำลอง ได้แก่ Extremely Randomized Trees, Random Forest, Simple Linear Regression และ Multiple Linear Regression โดยพัฒนาแบบจำลองการเรียนรู้ของเครื่องทั้งหมดบนไลบรารี Scikit-learn อ้างอิงจาก Pedregosa et al., (2011) เพื่อประเมินประสิทธิภาพการพยากรณ์ค่า rWQI ในกรอบเวลา 1 ถึง 6 ชั่วโมงล่วงหน้าให้มีความแม่นยำ และเพิ่มประสิทธิภาพทั้งในการเฝ้าระวัง การวางแผน และการบริหารจัดการน้ำ โดยประกอบด้วยการทำงาน 3 ส่วนหลัก ได้แก่

1) ส่วนฮาร์ดแวร์ IoT (IoT Hardware) ทำหน้าที่ตรวจวัดคุณภาพน้ำแบบเรียลไทม์ ผ่านชุดเซนเซอร์วัดค่า pH TDS และอุณหภูมิ ก่อนจะจัดส่งข้อมูลผ่านเครือข่ายเข้าสู่ระบบส่วนกลาง

2) ส่วนประมวลผลและวิเคราะห์ (Backend System) พัฒนาด้วย Django Framework ร่วมกับฐานข้อมูล MySQL โดยนำข้อมูลย้อนหลังมาเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่อง 4 เทคนิค และคัดเลือกแบบจำลองที่มีประสิทธิภาพสูงสุด เพื่อนำไปเชื่อมต่อและใช้งานบนแอปพลิเคชัน

3) ส่วนการแสดงผล (Frontend System) เป็นส่วนที่ติดต่อกับผู้ใช้งาน โดยจะแสดงข้อมูลค่า น้ำ และผลการพยากรณ์คุณภาพน้ำล่วงหน้า โดยใช้เกณฑ์มาตรฐานในการจำแนกสถานะได้แก่ ระดับปกติ (Normal) ระดับเฝ้าระวัง (Caution) และระดับอันตราย (Danger)

โดยผลจากงานวิจัยนี้จะสร้างองค์ความรู้เชิงบูรณาการที่ผสมผสานเทคโนโลยี IoT การเรียนรู้ของเครื่อง และเว็บแอปพลิเคชันเข้าด้วยกัน เพื่อพัฒนาเป็นต้นแบบในการเฝ้าระวังและแจ้งเตือนค่า rWQI ที่มีต้นทุนที่ต่ำและมีความแม่นยำสูง ซึ่งจะสนับสนุนการตัดสินใจเชิงรุกในการบริหารจัดการน้ำ พร้อมทั้งสร้างองค์ความรู้ในการคัดเลือกแบบจำลองให้สอดคล้องกับกรอบเวลาพยากรณ์ (Horizon-Dependent Model Selection) เพื่อเป็นแนวทางให้ผู้ใช้สามารถเลือกใช้เทคโนโลยีให้สอดคล้องกับสภาพแวดล้อมจริง และยกระดับการเฝ้าระวังคุณภาพน้ำทั่วไปสู่การบริหารจัดการเชิงรุกด้วยเทคโนโลยีอัจฉริยะ

วัตถุประสงค์การวิจัย

1. เพื่อพัฒนาต้นแบบระบบพยากรณ์และเฝ้าระวังคุณภาพน้ำอัจฉริยะ ด้วยการบูรณาการเทคโนโลยี IoT สำหรับตรวจวัดพารามิเตอร์หลัก 3 ตัวแปร (อุณหภูมิ pH และ TDS) ร่วมกับเว็บเฟรมเวิร์ก Django และโมเดลการเรียนรู้ของเครื่อง เพื่อแสดงผลและพยากรณ์ค่าดัชนีคุณภาพน้ำแบบลดรูป (rWQI) ผ่านเว็บแอปพลิเคชันแบบเรียลไทม์

2. เพื่อประเมินและเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่องในรูปแบบการวิเคราะห์การถดถอย (Regression Analysis) จำนวน 4 เทคนิค ได้แก่ Extremely Randomized Trees, Random Forest, Linear Regression และ Multiple Linear Regression ในการพยากรณ์ค่าดัชนีคุณภาพน้ำแบบลดรูป (rWQI) ล่วงหน้า 1-6 ชั่วโมง เพื่อคัดเลือกแบบจำลองที่เหมาะสมกับแต่ละกรอบเวลาพยากรณ์

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

งานวิจัยนี้ได้ประยุกต์ใช้ทฤษฎีและทบทวนงานวิจัยที่เกี่ยวข้อง ซึ่งมีรายละเอียดดังนี้

1. ทฤษฎีที่ใช้ในงานวิจัย

1.1 อินเทอร์เน็ตของสรรพสิ่ง (Internet of Things หรือ IoT)

อินเทอร์เน็ตของสรรพสิ่ง หมายถึงเครือข่ายของวัตถุทางกายภาพ (Physical Objects) หรือ สิ่งของที่มีการฝังเซนเซอร์ซอฟต์แวร์ และเทคโนโลยีการเชื่อมต่อ เพื่อให้วัตถุเหล่านั้นสามารถเชื่อมโยงและแลกเปลี่ยนข้อมูลกับอุปกรณ์หรือระบบอื่น ๆ ผ่านอินเทอร์เน็ตได้ ซึ่งกระบวนการนี้จะทำงานได้แบบอัตโนมัติโดยไม่ต้องใช้คนป้อนข้อมูลโดยตรง ซึ่งประกอบด้วย 3 ส่วน ได้แก่

1.1.1 ส่วนรับรู้ (Perception Layer) ทำหน้าที่รวบรวมข้อมูลจากสภาพแวดล้อมผ่านเซนเซอร์ต่าง ๆ ที่ติดตั้งไว้ในระบบ เช่น เซนเซอร์วัดค่าอุณหภูมิ ค่า pH หรือค่า TDS ซึ่งจะแปลงค่าทางกายภาพให้เป็นสัญญาณข้อมูลดิจิทัล

1.1.2 ส่วนเครือข่าย (Network Layer) ทำหน้าที่ส่งข้อมูลจากส่วนรับรู้ไปยังระบบประมวลผลหรือเซิร์ฟเวอร์ (Server) ผ่านโพรโทคอลการสื่อสารไร้สายที่เหมาะสมกับ IoT เช่น Wi-Fi, Message Queuing Telemetry Transport (MQTT) หรือ HTTP

1.1.3 ส่วนประยุกต์ใช้งาน (Application Layer) เป็นส่วนที่นำข้อมูลมาวิเคราะห์ ประมวลผล และแสดงในรูปแบบที่ผู้ใช้เข้าใจง่าย เช่น การแสดงค่าคุณภาพน้ำในแอปพลิเคชันบนมือถือ หรือการคำนวณดัชนีคุณภาพน้ำเพื่อแจ้งเตือนผู้ใช้งานเมื่อค่าคุณภาพน้ำมีความผิดปกติ

สำหรับในบริบทการเกษตรและสิ่งแวดล้อมอัจฉริยะ เทคโนโลยี IoT ถูกนำมาประยุกต์ใช้ในการตรวจวัดและติดตามคุณภาพน้ำแบบเรียลไทม์ผ่านชุดเซนเซอร์ เพื่อส่งผ่านข้อมูลไปยังระบบประมวลผลกลางอย่างต่อเนื่อง ช่วยลดภาระการจัดการเก็บข้อมูลด้วยมนุษย์และสนับสนุนการตัดสินใจในการบริหารจัดการน้ำได้อย่างมีประสิทธิภาพ

1.2 ดัชนีคุณภาพน้ำมาตรฐาน (National Sanitation Foundation Water Quality Index: NSF WQI)

ดัชนีคุณภาพน้ำมาตรฐาน (NSF WQI) คือเกณฑ์ชี้วัดคุณภาพน้ำที่พัฒนาขึ้นโดยมูลนิธิสุขภาพแห่งชาติสหรัฐอเมริกา (National Sanitation Foundation: NSF) อ้างอิงจาก Brown *et al.* (1970) มีวัตถุประสงค์เพื่อแปลงข้อมูลพารามิเตอร์คุณภาพน้ำที่มีความซับซ้อนหลายตัวแปร ให้เป็นตัวเลขดัชนีที่มีค่าเดียวในช่วงคะแนน 0 ถึง 100 โดยหลักการคำนวณของ NSF WQI จะพิจารณาจากพารามิเตอร์คุณภาพน้ำที่สำคัญ 9 ปัจจัย ซึ่งแต่ละปัจจัยมีค่าน้ำหนักความสำคัญ (Weighting Factor: W_i) ที่แตกต่างกันตามผลกระทบต่อคุณภาพน้ำ ได้แก่ ออกซิเจนละลายน้ำ (Dissolved Oxygen: DO) แบคทีเรียกลุ่มฟีคัลโคลิฟอร์ม (Fecal Coliform) ซึ่งเป็นตัวชี้วัดสารปนเปื้อนในน้ำ ค่าความเป็นกรด-ด่าง (pH) ความต้องการออกซิเจนชีวเคมี (Biochemical Oxygen Demand: BOD) การเปลี่ยนแปลงของอุณหภูมิ (Temperature Change) ฟอสเฟตทั้งหมด (Total Phosphate) ไนเตรต (Nitrates) ความขุ่นของน้ำ (Turbidity) และปริมาณของแข็งทั้งหมดในน้ำ (Total Solids) โดยการคำนวณค่าดัชนีคุณภาพน้ำจะใช้หลักการถ่วงน้ำหนักของแต่ละพารามิเตอร์ ดังแสดงในสมการ (1)

$$WQI = \sum_{i=1}^N w_i q_i \quad (1)$$

โดยสมการดังกล่าวเป็นการคำนวณหาค่าดัชนีคุณภาพน้ำในภาพรวม สำหรับค่าสัญลักษณ์พารามิเตอร์ต่างๆ ในแบบจำลองสามารถอธิบายความหมายได้ดังนี้

- W_i แทนค่าน้ำหนักความสำคัญ (Weighting Factor) ของพารามิเตอร์นั้นๆ โดยผลรวมของค่าน้ำหนักทั้งหมดต้องเท่ากับ 1.00
- q_i แทนค่าดัชนีย่อยของพารามิเตอร์ที่ i (sub-index) ที่ได้จากการแปลงค่าจริงเข้าสู่เกณฑ์มาตรฐาน (ช่วงคะแนน 0-100)
- N แทนจำนวนพารามิเตอร์ที่นำมาพิจารณา

ทั้งนี้ การประเมินคุณภาพน้ำในงานวิจัยนี้ได้ประยุกต์ใช้ดัชนีคุณภาพน้ำแบบลดรูป (rWQI) โดยกำหนดช่วงค่าเพื่อจำแนกสถานะตามแนวคิดของ De Oliveira *et al.* (2022) ร่วมกับเกณฑ์ดัชนีคุณภาพน้ำมาตรฐาน เพื่อแบ่งระดับคุณภาพน้ำออกเป็น 5 ระดับ ดังแสดงในตารางที่ 1

ตารางที่ 1 ช่วงค่าและการแปลความหมายดัชนีคุณภาพน้ำแบบลดทอน (rWQI)

ช่วงค่าคุณภาพน้ำ	ระดับคุณภาพน้ำ	คำอธิบายสถานะและการเฝ้าระวัง
มากกว่า 90 – 100	ดีเยี่ยม (Excellent)	คุณภาพน้ำอยู่ในเกณฑ์ดีเยี่ยม เหมาะสมต่อสัตว์น้ำ

มากกว่า 70 – 90	ดี (Good)	คุณภาพน้ำอยู่ในเกณฑ์มาตรฐาน เหมาะสมต่อสัตว์น้ำ
มากกว่า 50 – 70	ปานกลาง (Medium)	คุณภาพน้ำอยู่ในสภาวะปกติ แต่ต้องเฝ้าระวังความผันผวน
มากกว่า 25 – 50	แย่ หรือ วิกฤต (Bad)	คุณภาพน้ำเริ่มเข้าสู่ค่าวิกฤต ต้องเริ่มเฝ้าระวังอย่างมาก
0 ถึง 25	แย่มาก หรือ วิกฤตมาก (Very Bad)	คุณภาพน้ำอยู่ในระดับวิกฤต เป็นอันตรายต่อสัตว์น้ำ

อย่างไรก็ตาม ในการนำไปประยุกต์ใช้งานจริงร่วมกับอุปกรณ์ IoT ที่มีข้อจำกัดด้านทรัพยากรและงบประมาณ การวัดครบทั้ง 9 พารามิเตอร์ โดยเฉพาะ DO และ BOD ทำได้ยากและมีค่าใช้จ่ายสูง ดังนั้นงานวิจัยนี้จึงประยุกต์ใช้ค่า rWQI โดยเลือกใช้พารามิเตอร์หลัก 3 ตัวแปร ได้แก่ อุณหภูมิ (Temperature), ค่าความเป็นกรด-ด่าง (pH) และปริมาณของแข็งละลายน้ำรวม (Total Dissolved Solids: TDS) โดยคำนวณค่าน้ำหนักใหม่ตามสัดส่วนเดิม (Re-weighted Ratio) ได้แก่ $w_{pH} = 0.400$, $w_{TDS} = 0.267$ และ $w_{Temp} = 0.333$ (ผลรวมเท่ากับ 1.00) ทั้งนี้ในทางปฏิบัติได้ใช้ค่า TDS เพื่อทดแทน Total Solids (TS) เนื่องจาก TDS มีความคุ้มค่าและเหมาะสมกับการติดตั้งในระบบฝังตัว และใช้ค่าอุณหภูมิสัมบูรณ์ (Water Temperature) แทนการเปลี่ยนแปลงของอุณหภูมิ (ΔT) เนื่องจากเป็นการตรวจวัด ณ จุดเดียวในบ่อระบบปิด แต่ยังคงความสามารถในการเฝ้าระวังความผันผวนของอุณหภูมิได้อย่างมีประสิทธิภาพ

1.3 เทคนิคการถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression Technique: LR)

การวิเคราะห์การถดถอยเชิงเส้นอย่างง่าย เป็นโมเดลทางสถิติที่ใช้สร้างความสัมพันธ์เชิงโครงสร้างระหว่างตัวแปรอิสระหนึ่งตัวและตัวแปรตาม โดยจะหาเส้นตรงที่ทำให้ผลรวมของค่าความคลาดเคลื่อนกำลังสอง (Sum of Squared Errors) มีค่าน้อยที่สุด ซึ่งโมเดลมีโครงสร้างที่ง่าย สามารถตีความผลลัพธ์ (Interpretability) และอธิบายความสัมพันธ์ระหว่างตัวแปรได้อย่างชัดเจน เหมาะสำหรับการวิเคราะห์แนวโน้มเบื้องต้นและการทดสอบสมมติฐานทางสถิติ ตลอดจนการประยุกต์ใช้ในการพยากรณ์ต่าง ๆ เช่น การประมาณการยอดขายตามงบประมาณทางธุรกิจ หรือการประมาณการดัชนีคุณภาพน้ำจากพารามิเตอร์เดียวในระบบนิเวศทางน้ำ ซึ่งสามารถแสดงได้ดังสมการที่ (2)

$$y = \beta_0 + \beta_1 x + \varepsilon \tag{2}$$

โดยสมการดังกล่าวจะกำหนดให้ y แทน ตัวแปรตาม (Dependent Variable) ที่ต้องการพยากรณ์ ซึ่งในงานวิจัยนี้คือค่าดัชนีคุณภาพน้ำแบบลดรูปในช่วงเวลาอนาคต ($t + h$) และ x แทน ตัวแปรอิสระ (Independent Variable) ที่นำมาใช้เป็นปัจจัยในการพยากรณ์เช่น ค่า rWQI ณ เวลาปัจจุบัน สำหรับค่าสัญลักษณ์พารามิเตอร์ต่าง ๆ ในแบบจำลองสามารถอธิบายความหมายได้ดังนี้

- β_0 แทน ค่าจุดตัดแกน Y (Intercept)
- β_1 แทน ค่าสัมประสิทธิ์ความชันของเส้นถดถอย (Slope Coefficient)
- ε แทน ค่าความคลาดเคลื่อนสุ่ม (Random Error)

1.4 เทคนิคการถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression Technique: MLR)

การวิเคราะห์การถดถอยเชิงเส้นพหุคูณ เป็นแนวคิดที่ต่อยอดมาจากการวิเคราะห์การถดถอยเชิงเส้นอย่างง่าย ใช้วิเคราะห์ความสัมพันธ์ระหว่างกลุ่มตัวแปรอิสระหลายตัวแปรกับตัวแปรตาม ทั้งยังช่วยอธิบายโครงสร้างความสัมพันธ์ที่ซับซ้อนได้อย่างเป็นระบบ จุดเด่นของเทคนิคนี้คือสามารถระบุน้ำหนักความสำคัญของปัจจัย (Feature Importance) ผ่านค่าสัมประสิทธิ์ของตัวแปรอิสระ ทำให้สามารถจำแนกได้ว่าตัวแปรใดส่งผลกระทบต่อผลลัพธ์อย่างชัดเจน นอกจากนี้ยังทำหน้าที่เป็นตัวชี้วัดเพื่อประเมินความซับซ้อนของข้อมูลในลักษณะเชิงเส้น ซึ่งผลลัพธ์ที่ได้จะใช้เป็นเกณฑ์มาตรฐานในการเปรียบเทียบประสิทธิภาพกับแบบจำลองปัญญาประดิษฐ์ในขั้นตอนถัดไป โดยนิยมประยุกต์ใช้ในงานวิจัยที่ต้องการควบคุมปัจจัยแวดล้อม

หลายมิติ เช่น การวิเคราะห์ดัชนีทางสิ่งแวดล้อม หรือคุณภาพน้ำที่ขึ้นอยู่กับความแปรผันของพารามิเตอร์หลายชนิดพร้อมกัน ซึ่งแสดงได้ดังสมการที่ (3)

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \varepsilon \quad (3)$$

โดยที่สัญลักษณ์ y และ ε มีความหมายเช่นเดียวกับสมการที่ (2) สำหรับพารามิเตอร์และกลุ่มตัวแปรอิสระที่เพิ่มขึ้น สามารถอธิบายได้ดังนี้

- $x_1, x_2, \dots, x_n$ แทน กลุ่มตัวแปรอิสระที่นำมาพิจารณา
- $\beta_0, \beta_1, \dots, \beta_n$ แทน ค่าสัมประสิทธิ์ความชันของการถดถอย (Regression Coefficients) ของตัวแปรอิสระนั้น ๆ

1.5 เทคนิคป่าสุ่ม (Random Forest Technique: RF)

เทคนิคป่าสุ่มเป็นแนวทางการเรียนรู้แบบกลุ่ม (Ensemble Learning) ที่ใช้หลักการรวบรวมแบบจำลอง (Bagging) ด้วยการสร้างแบบจำลองต้นไม้ตัดสินใจ (Decision Trees) จำนวนมาก ตามแนวคิดของ Breiman (2001) โดยถูกสุ่มเลือกคุณลักษณะ (Feature Selection) และชุดข้อมูลฝึกฝน (Training Data) ที่แตกต่างกันในแต่ละต้น เมื่อนำมาประยุกต์ใช้กับปัญหาการถดถอยคือ Random Forest Regressor (RFR) ซึ่งแบบจำลองจะนำผลลัพธ์การพยากรณ์จากต้นไม้ทุกต้นมาหาค่าเฉลี่ยเพื่อสร้างคำตอบสุดท้าย เทคนิคนี้มีจุดเด่นในการลดผลกระทบจากข้อมูลผิดปกติ (Outliers) และลดปัญหาการเรียนรู้เกินจำกัด (Overfitting) ได้เป็นอย่างดี ส่งผลให้มีความแม่นยำสูงแม้ในสถานะที่ข้อมูลมีความผันผวน นอกจากนี้ยังช่วยตรวจจับและจัดการกับรูปแบบความสัมพันธ์ของข้อมูลที่ซับซ้อนและไม่เป็นเชิงเส้น (Non-linear Relationship) ได้อย่างมีประสิทธิภาพ โดยทำการพยากรณ์ค่าสุดท้ายตามสมการที่ (4)

$$Y(x) = \frac{1}{M} \sum_{m=1}^M h_m(x) \quad (4)$$

โดยที่สัญลักษณ์ $Y(x)$ แทน ค่าพยากรณ์ค่า rWQI ที่เวลาอนาคต $(t + h)$ สำหรับสัญลักษณ์อื่น อธิบายได้ดังนี้

- $h_m(x)$ แทน ผลการพยากรณ์ค่า rWQI จากต้นไม้ตัดสินใจตัวที่ m
- M แทน จำนวนต้นไม้ตัดสินใจทั้งหมดในแบบจำลอง (n_estimators)
- x แทน ชุดข้อมูลพารามิเตอร์นำเข้า (เช่น ค่า rWQI, อุณหภูมิ, pH และ TDS ในอดีต)

1.6 เทคนิคต้นไม้สุ่มสุดขีด (Extremely Randomized Trees Technique: ET)

เทคนิคต้นไม้สุ่มสุดขีด เป็นแนวทางการเรียนรู้แบบกลุ่ม (Ensemble Learning) ที่ต่อยอดมาจากแบบป่าสุ่ม ตามแนวคิดของ Geurts, Ernst and Wehenkel (2006) โดยความแตกต่างสำคัญระหว่าง ET และ RF คือ กลไกการสร้างจุดตัด (Extremely Randomized Split) กล่าวคือ RF จะสุ่มเลือกกลุ่มของตัวแปรนำเข้า แล้วค้นหาจุดตัดที่ดีที่สุด (Best Cut-point) จากตัวแปรเหล่านั้นเพื่อสร้างโหนด แต่ ET จะสุ่มจุดตัด (Random Cut-point) สำหรับทุกตัวแปรโดยสมบูรณ์โดยไม่ค้นหาจุดตัดที่ดีที่สุด ซึ่งการสุ่มจุดตัดในลักษณะนี้จะช่วยลดความแปรปรวน (Variance) ของแบบจำลองได้อย่างมีประสิทธิภาพ เพิ่มความเร็วในการประมวลผลคำนวณ และลดโอกาสการเรียนรู้เกินจำกัด (Overfitting) จากสัญญาณรบกวนของเซนเซอร์ IoT ได้ดียิ่งขึ้น สำหรับการทำนายค่าในโหมดการถดถอย ET จะคำนวณผลลัพธ์จากการหาค่าเฉลี่ยของต้นไม้ตัดสินใจทุกต้น ดังสมการที่ (5)

$$Y_{ET}(x) = \frac{1}{M} \sum_{m=1}^M h_m^{ET}(x) \quad (5)$$

โดยที่สัญลักษณ์ $Y_{ET}(x)$ แทน ค่า rWQI ที่เวลานาคต ($t + h$) สำหรับสัญลักษณ์อื่นๆ อธิบายได้ดังนี้

- h_m^{ET} แทน ผลการพยากรณ์ค่า rWQI จากต้นไมตัดสินใจตัวที่ m
- M แทน จำนวนต้นไมตัดสินใจทั้งหมดในแบบจำลอง (n_estimators)
- x แทน ชุดข้อมูลพารามิเตอร์นำเข้า (เช่น ค่า rWQI, อุณหภูมิ, pH และ TDS ในอดีต)

2. งานวิจัยที่เกี่ยวข้อง

ในหัวข้อนี้จะทบทวนวรรณกรรมที่เกี่ยวข้องกับการตรวจวัดและวิเคราะห์คุณภาพน้ำ โดยสามารถแบ่งประเด็นการศึกษาออกเป็น 2 ส่วนหลัก ได้แก่

2.1 การพัฒนาระบบตรวจจับและเฝ้าระวังคุณภาพน้ำ

ปัจจุบันมีการพัฒนาระบบตรวจสอบคุณภาพน้ำผ่านเทคโนโลยี IoT อย่างแพร่หลาย โดยแต่ละงานวิจัยมุ่งเน้นการเพิ่มประสิทธิภาพในประเด็นต่าง ๆ เริ่มจาก Bakar *et al.* (2025) ที่นำเสนอระบบตรวจวัดผ่านแพลตฟอร์ม Blynk Cloud โดยใช้บอร์ด Arduino และ NodeMCU เพื่อติดตามค่า pH อุณหภูมิ และความชื้น ซึ่งผลการทดสอบพบว่ามีความแม่นยำสูงเมื่อเทียบกับเครื่องมือมาตรฐาน โดยมีค่าความคลาดเคลื่อนเฉลี่ยของอุณหภูมิเพียง 0.5 องศาเซลเซียส และวัดค่าความผิดพลาดสัมพัทธ์ของ pH ได้น้อยกว่า 3% อย่างไรก็ตามระบบนี้ยังเน้นการแสดงผลผ่านแดชบอร์ดเป็นหลัก ในขณะที่ Patel, Kiradia and Sharma (2025) ได้เพิ่มความคุ้มค่าและเน้นการใช้งานจริงด้วยการใช้ ESP32 ร่วมกับฐานข้อมูล Firebase และระบบแจ้งเตือนผ่าน Telegram Bot ซึ่งช่วยให้ผู้ใช้สามารถรับข้อมูลและการแจ้งเตือนได้แบบเรียลไทม์ แต่ยังคงพบปัญหาของการเชื่อมต่อเครือข่ายและความแม่นยำของเซนเซอร์ที่อาจเสื่อมสภาพตามระยะเวลาการใช้งาน นอกจากนี้ Palconit *et al.* (2021) ได้เพิ่มความสามารถของการจัดตู้ปลาให้เป็นแบบอัตโนมัติซึ่งครอบคลุม 4 ฟังก์ชันหลัก ได้แก่ การวัดคุณภาพน้ำ การเฝ้าระวังด้วยวิดีโอ การจัดเก็บข้อมูลบนคลาวด์ และระบบให้อาหารอัจฉริยะที่ใช้เซนเซอร์วัดความแรง MPU-6050 ซึ่งสามารถตรวจจับพฤติกรรมปลาและสั่งจ่ายอาหารผ่านเซอร์โวมอเตอร์ โดยมี Arduino Uno และ ESP8266 ทำงานร่วมกัน และแม้ว่าระบบจะมีฟังก์ชันการทำงานที่ครบถ้วน แต่พบว่าในทางปฏิบัติการติดตั้งและเชื่อมต่ออุปกรณ์ยังมีความซับซ้อนอยู่

ต่อมาพบว่ามีงานวิจัยที่ให้ความสำคัญกับการเพิ่มประสิทธิภาพระบบในมิติอื่น ๆ มากขึ้น เช่น ด้านความปลอดภัยของข้อมูล โดยงานของ Al-Shareeda *et al.* (2025) ได้นำเสนอระบบตรวจวัดระดับน้ำในถังเก็บโดยใช้ ESP32 และเซนเซอร์อัลตราโซนิก ซึ่งมีจุดเด่นคือการบูรณาการความปลอดภัยทางไซเบอร์ เช่น การเข้ารหัส SSL/TLS และกลไกการยืนยันตัวตน เพื่อป้องกันการดักจับข้อมูลและการโจมตีระบบ นอกจากนี้ยังมีงานวิจัยที่มุ่งแก้ปัญหาด้านความแม่นยำและการเสื่อมสภาพของเซนเซอร์ด้วย เช่นในงานของ Jais *et al.* (2024) ที่เพิ่มความแม่นยำให้เซนเซอร์ด้วยเทคนิค Simple Linear Regression และออกแบบเคสป้องกันเพื่อลดความคลาดเคลื่อนสะสมของค่าชีวิต ซึ่งเป็นการจัดการสัญญาณรบกวนในข้อมูลระดับฮาร์ดแวร์

อย่างไรก็ตาม แม้งานวิจัยจะเพิ่มความแม่นยำในการวัดผลปัจจุบัน แต่ยังคงขาดการนำเทคนิคการเรียนรู้ของเครื่องมาประยุกต์ใช้เพื่อพยากรณ์แนวโน้มคุณภาพน้ำล่วงหน้าแบบหลายช่วงเวลา (Multi-horizon Forecasting) เพื่อแจ้งเตือนเชิงรุกแบบล่วงหน้า

2.2 การประยุกต์ใช้การเรียนรู้ของเครื่องเพื่อพยากรณ์ค่าดัชนีคุณภาพน้ำ

ปัจจุบันพบว่ามีงานวิจัยจำนวนมากที่ศึกษาเปรียบเทียบประสิทธิภาพของแบบจำลองต่างๆ เพื่อเพิ่มความแม่นยำในการพยากรณ์ดัชนีคุณภาพน้ำ เช่น งาน Gaya *et al.* (2020) ที่ระบุว่าแบบจำลองโครงข่ายประสาทเทียม (Neural Network) ให้ความแม่นยำสูงกว่าวิธีจำลองการถดถอยเชิงเส้น (Linear Regression) แบบดั้งเดิม โดยเฉพาะในการจัดการกับข้อมูลคุณภาพน้ำที่มีความซับซ้อนและเปลี่ยนแปลงตลอดเวลา ซึ่งสอดคล้องกับแนวคิดของ Mohd Zebaral Hoque *et al.* (2022) ที่ทำการเปรียบเทียบความแม่นยำของแบบจำลองการเรียนรู้เชิงถดถอยหลายรูปแบบในการประเมินคุณภาพน้ำจากพารามิเตอร์ต่าง ๆ ซึ่งผลการศึกษาชี้ให้เห็นว่าเทคนิคการเรียนรู้ของเครื่องช่วยลดความซับซ้อนและค่าใช้จ่ายในการทดสอบทางห้องปฏิบัติการได้


หรือในงานของ Palabiyik and Akkan (2024) ที่ประเมินคุณภาพน้ำในลำธารด้วยการเปรียบเทียบประสิทธิภาพระหว่างโครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer Perceptron: MLP) การวิเคราะห์การถดถอยพหุคูณ (Multiple Linear Regression: MLR) ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) และ ต้นไม้ตัดสินใจ (Decision Tree: DT) โดยผลการศึกษพบว่าเทคนิค MLR ให้ผลลัพธ์การพยากรณ์ที่มีความแม่นยำสูงสุด นอกจากนี้ Shams *et al.* (2023) ได้ยกระดับการปรับแต่งโมเดลด้วยการใช้เทคนิค Grid Search เพื่อค้นหาค่าพารามิเตอร์ที่เหมาะสมที่สุด ซึ่งพบว่า MLP มีประสิทธิภาพสูงสุดในการพยากรณ์ค่าดัชนีคุณภาพน้ำ ในขณะที่ Gradient Boosting ให้ความแม่นยำที่สูงกว่าในการจำแนกประเภทคุณภาพน้ำ

โดยในระยะต่อมามีหลายงานวิจัยที่นำเทคนิคการเรียนรู้ของเครื่องมาใช่มากขึ้น สอดคล้องกับงานวิจัยของ Hridoy *et al.* (2025) ที่ประยุกต์ใช้เทคนิคที่มีประสิทธิภาพสูง ได้แก่ LightGBM และ XGBoost มาทำงานร่วมกับเทคโนโลยี IoT เพื่อพยากรณ์และจำแนกประเภทดัชนีคุณภาพน้ำ โดยมุ่งเน้นการวิเคราะห์พารามิเตอร์สำคัญ เช่น ออกซิเจนละลายน้ำและความขุ่น ซึ่งช่วยให้สามารถเฝ้าระวังและแจ้งเตือนสถานะคุณภาพน้ำแบบเรียลไทม์ได้อย่างมีประสิทธิภาพ นอกจากนี้ งานวิจัยด้านสิ่งแวดล้อมในช่วงหลังยังนิยมนำแบบจำลอง Random Forest Regressor (RFR) และ Extra Trees Regressor (ET) มาประยุกต์ใช้ เนื่องจากมีความสามารถในการตรวจจับรูปแบบความสัมพันธ์ที่ซับซ้อนไม่เป็นเชิงเส้น (Non-linear Relationship) และช่วยลดผลกระทบจากความผันผวนของข้อมูลเซนเซอร์ IoT ได้เป็นอย่างดี

จากการทบทวนวรรณกรรมข้างต้น แม้งานวิจัยส่วนใหญ่จะมุ่งเน้นการพยากรณ์ดัชนีคุณภาพน้ำ แต่ยังคงมีช่องว่าง (Research Gap) ในการศึกษาแบบการพยากรณ์ค่า rWQI ที่สอดคล้องกับข้อจำกัดของชุดเซนเซอร์ IoT รวมถึงการประเมินประสิทธิภาพของแบบจำลองในหลายกรอบเวลาพยากรณ์ (เช่น 1-6 ชั่วโมงล่วงหน้า) ดังนั้นงานวิจัยนี้จึงได้นำเสนอขั้นตอนออกแบบ ดำเนินงาน และทดสอบระบบเพื่อตอบโต้ดังกล่าว ซึ่งมีรายละเอียดแสดงในหัวข้อถัดไป

วิธีดำเนินการวิจัย

การวิจัยนี้ประยุกต์ใช้หลักการวิจัยและพัฒนา (Research and Development) โดยมุ่งเน้นการใช้ข้อมูลคุณภาพน้ำจากระบบ IoT นำมาคำนวณค่า rWQI เพื่อฝึกฝนแบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์คุณภาพน้ำแบบหลายช่วงเวลา (Multi-horizon Forecasting) ก่อนจะนำแบบจำลองไปบูรณาการร่วมกับระบบเว็บแอปพลิเคชันเพื่อแสดงผลและแจ้งเตือนเชิงรุก ซึ่งแบ่งขั้นตอนการดำเนินงานออกเป็น 5 ขั้นตอนหลัก ดังแสดงในภาพที่ 1



ภาพที่ 1 ขั้นตอนการทำงานของระบบ

1. การเก็บรวบรวมข้อมูล (Data Collection)

ข้อมูลที่ใช้ในงานวิจัยนี้เป็นข้อมูลทุติยภูมิซึ่งได้มาจากชุดข้อมูลเปิดที่เผยแพร่โดย Siswanto *et al.* (2023) ผ่านแพลตฟอร์ม Kaggle โดยงานวิจัยดังกล่าวมีวัตถุประสงค์เพื่อจัดเตรียมชุดข้อมูลคุณภาพน้ำที่ได้จากระบบอินเทอร์เน็ตของสรรพสิ่ง เพื่อสนับสนุนการนำไปใช้งานและการต่อยอดทางวิชาการ โดยชุดข้อมูลประกอบด้วยพารามิเตอร์ตรวจวัดหลักที่สอดคล้องกัน ได้แก่ อุณหภูมิ น้ำ ค่า pH และค่า TDS ซึ่งมีจำนวนข้อมูล 5 รายการและมีขนาด 118,286 แถว ดังแสดงในตารางที่ 2

ตารางที่ 2 รายละเอียดโครงสร้างแอตทริบิวต์ของชุดข้อมูลดัชนีคุณภาพน้ำ

ชื่อแอตทริบิวต์ (Attribute)	คำอธิบายความหมาย (Description)	ประเภทข้อมูล (Data Type)	หน่วยวัด (Unit)
id	ตัวระบุรายการข้อมูล (Primary Key)	Integer	-
created_date	วันและเวลาที่บันทึกข้อมูล (Created Date)	DateTime	-
water_temp	อุณหภูมิน้ำ (Water Temperature)	Float	องศาเซลเซียส (°C)
water_pH	ค่าความเป็นกรด-ด่างของน้ำ (pH)	Float	-
TDS	ปริมาณของแข็งละลายน้ำรวม (TDS)	Float	mg/L

2. การเตรียมข้อมูล (Data Preprocessing)

ในขั้นตอนนี้ เริ่มต้นด้วยการเตรียมข้อมูลเบื้องต้น ได้แก่ การจัดการข้อมูลที่มีการบันทึกค่าซ้ำในช่วงเวลาเดียวกัน ซึ่งผู้วิจัยได้จัดกลุ่มข้อมูลตามช่วงเวลาเดียวกัน และคัดเลือกข้อมูลตัวแทนที่เหมาะสมในแต่ละช่วงเวลา เพื่อลดความเอนเอียงของข้อมูลและคงไว้ซึ่งลักษณะการเปลี่ยนแปลงของคุณภาพน้ำอย่างมีรูปแบบชัดเจน โดยเฉพาะในกรณีของค่าที่อาจส่งผลกระทบต่อสภาพแวดล้อมการเลี้ยงปลา ซึ่งผู้วิจัยเลือกเก็บค่าที่สะท้อนสภาวะวิกฤตที่ส่งผลชัดเจน (Risk-Focused Aggregation) แทนการหาค่าเฉลี่ยทั่วไป เพื่อลดความผิดปกติของข้อมูลที่เกิดจากความคลาดเคลื่อนในการเฝ้าระวัง เช่น การคัดเลือกค่าอุณหภูมิที่ระดับสูงสุด หรือการคัดเลือกค่าความเป็นกรด-ด่างที่เบี่ยงเบนจากค่ามาตรฐานที่มากที่สุด เพื่อให้มั่นใจว่าระบบจะสามารถตรวจจับเหตุการณ์ที่มีความเสี่ยงต่อการประเมินค่าคุณภาพน้ำได้อย่างแม่นยำ โดยเมื่อผ่านการดำเนินการข้างต้น จะทำให้มีชุดข้อมูลสำหรับการวิเคราะห์รวมทั้งหมด 19,509 รายการ

ในขั้นตอนนี้ต่อไปเป็นการปรับแต่งคุณลักษณะเชิงเวลา โดยได้แปลงค่าตัวแปร created_date ให้เป็นชนิดข้อมูลวันเวลา (Datetime) และจัดเรียงลำดับจากอดีตไปปัจจุบัน จากนั้นทำการปรับความถี่ของข้อมูล (Resampling) ให้สม่ำเสมอในรูปแบบอนุกรมเวลา (Time Series) โดยผู้วิจัยกำหนดช่วงเวลาการเก็บข้อมูลทุก 30 นาที (30-minute Interval) เพื่อให้สอดคล้องกับเวลาคาดการณ์ล่วงหน้า (Forecast Horizon) ในช่วงระยะ 1 ถึง 6 ชั่วโมง พร้อมทั้งสร้างตัวแปรเชิงเวลา (time_decimal) ในรูปแบบทศนิยม (0–24) เพื่อสะท้อนอิทธิพลของรอบวันที่มีต่อคุณภาพน้ำ นอกจากนี้ได้สร้างตัวแปรความล่าช้า (Lag Features) โดยอ้างอิงข้อมูลดัชนีคุณภาพน้ำย้อนหลังที่ระยะ 30 นาที 1 ชั่วโมง 3 ชั่วโมง และ 6 ชั่วโมง (คิดเป็นลำดับ lag_1, lag_2, lag_6, และ lag_12) เพื่อให้แบบจำลองสามารถเรียนรู้แนวโน้มในอดีตได้ นอกจากนี้ยังมีการประยุกต์ใช้ค่าทางสถิติแบบเคลื่อนที่ (Rolling Statistics) ได้แก่ ค่าเฉลี่ยเคลื่อนที่ (Rolling Mean) และส่วนเบี่ยงเบนมาตรฐานเคลื่อนที่ (Rolling Standard Deviation) ในรอบเวลา 3 และ 6 ชั่วโมง เพื่อตรวจจับความต่อเนื่องและความผันผวนของข้อมูลเชิงลึกในแต่ละช่วงเวลาร่วมด้วย

ทั้งนี้ในกระบวนการจัดการข้อมูลที่ขาดหาย (Missing Values) และข้อมูลผิดปกติ (Outliers) ผู้วิจัยได้ใช้เทคนิคการประมาณค่าเชิงเส้น (Linear Interpolation) เติมเต็มช่องว่างข้อมูลอนุกรมเวลาขนาดสั้นเพื่อรักษารูปแบบแนวโน้มดั้งเดิมไว้ ร่วมกับการใช้ Min-Max Scaling ปรับช่วงข้อมูลแต่ละพารามิเตอร์ให้อยู่ในช่วง [0, 1] เพื่อลดผลกระทบจากความแตกต่างของสเกลข้อมูล จากนั้นนำค่าพารามิเตอร์ที่ผ่านการปรับสเกลไปคำนวณค่า rWQI สำหรับใช้เป็นตัวแปรเป้าหมาย (Target Variable) และทำการแบ่งชุดข้อมูลตามลำดับเวลา (Time-based Single Split Test) ออกเป็นชุดข้อมูลฝึกฝน (Training Set) และชุดข้อมูลทดสอบ (Testing Set) ในอัตราส่วน 70:30 โดยคงลำดับเวลาจริงไว้เพื่อป้องกันปัญหาข้อมูลรั่วไหล (Data Leakage) และช่วยให้แบบจำลองถูกประเมินผลภายใต้สภาวะอนุกรมเวลาจริง ซึ่งสะท้อนการนำไปใช้งานจริงได้อย่างแม่นยำและน่าเชื่อถือ

3. การคำนวณดัชนีคุณภาพน้ำแบบลดรูป (Calculate rWQI)

ในการกำหนดค่าน้ำหนักความสำคัญ (Weight) สำหรับพารามิเตอร์คุณภาพน้ำ งานวิจัยนี้ได้อ้างอิงตามเกณฑ์มาตรฐานของ NSF WQI ซึ่งเดิมถูกออกแบบสำหรับพารามิเตอร์ 9 รายการ อย่างไรก็ตามเพื่อมุ่งเน้นประสิทธิภาพการเฝ้าระวังภายใต้

ข้อจำกัดด้านต้นทุนที่เหมาะสม ผู้วิจัยจึงคัดเลือกพารามิเตอร์ 3 ค่า ได้แก่ อุณหภูมิ (Temperature) ความเป็นกรด-ด่าง (pH) และปริมาณของแข็งละลายรวม (TDS) ซึ่งสามารถใช้เป็นตัวบ่งชี้หลักในการประเมินคุณภาพน้ำได้โดย Siswanto *et al.* (2023)

และเพื่อให้สอดคล้องกับหลักการของ NSF WQI โดยยังคงรักษาอิทธิพลของค่าน้ำหนักให้เป็นไปตามสัดส่วนเดิม ผู้วิจัยได้ดำเนินการปรับมาตรฐานค่าน้ำหนักใหม่ (Weight Normalization) โดยปรับให้ผลรวมของน้ำหนักพารามิเตอร์ทั้ง 3 รายการมีค่าเท่ากับ 1.000 ดังแสดงในตารางที่ 3

ตารางที่ 3 รายการพารามิเตอร์และค่าน้ำหนักที่ใช้ในระบบ

พารามิเตอร์	สัญลักษณ์	ค่าน้ำหนักมาตรฐาน	อุปกรณ์เซนเซอร์ที่ใช้ตรวจวัด
ความเป็นกรด-ด่าง (pH)	pH	0.400	E-201-C pH Sensor
อุณหภูมิ (Water Temperature)	Temp	0.333	DS18B20 Sensor
ปริมาณของแข็งละลายรวม (Total Dissolved Solids)	TDS	0.267	TDS Sensor

สำหรับขั้นตอนการคำนวณ ผู้วิจัยได้กำหนดค่าพารามิเตอร์แต่ละตัวให้อยู่ในรูปของดัชนีย่อย (Sub-index: I_i) ที่มีค่าอยู่ในช่วง $[0, 100]$ ตามสมการความสัมพันธ์ของ NSF WQI โดยคำนวณจากอัตราส่วนความเบี่ยงเบนของค่าที่วัดได้เทียบกับค่าที่เหมาะสม (Ideal Value) และค่ามาตรฐานหรือค่าขีดจำกัดที่ยอมรับได้ (Standard/Permissible Limit) ของแต่ละพารามิเตอร์ ซึ่งสอดคล้องกับหลักการ Rating Curve ที่อ้างอิงจาก Brown *et al.* (1970) โดยสามารถแสดงการคำนวณได้ดังนี้

- ดัชนีย่อยความเป็นกรด-ด่าง (I_{pH}) คำนวณจากความเบี่ยงเบนค่า pH จากช่วงที่เหมาะสม ดังสมการ (6)

$$I_{pH} = 100 - \left(\frac{|pH - 7.0|}{(8.5 - 7.0)} \right) * 100 \quad (6)$$

- ดัชนีย่อยอุณหภูมิ (I_{Temp}) คำนวณจากความเบี่ยงเบนของอุณหภูมิจากค่าที่เหมาะสม ดังสมการ (7)

$$I_{Temp} = 100 - \left(\frac{|Temp - 25|}{(30 - 25)} \right) * 100 \quad (7)$$

- ดัชนีย่อยปริมาณของแข็งละลายรวม (I_{TDS}) คำนวณจากความเบี่ยงเบนของ TDS จากช่วงที่เหมาะสม ดังแสดงในสมการ (8)

$$I_{TDS} = 100 - \left(\frac{|TDS|}{500} \right) * 100 \quad (8)$$

ในการกำหนดค่าเหมาะสมและค่าขีดจำกัดบนที่ยอมรับได้ (Standard Limit) ในสมการที่ (6)–(8) อ้างอิงตามหลักการคุณภาพน้ำเพื่อการเพาะเลี้ยงสัตว์น้ำจืด โดยค่า pH กำหนดค่าเหมาะสมที่ 7.0 และขีดจำกัดบนที่ 8.5 (Boyd, 1990) ส่วนอุณหภูมิกำหนดค่าเหมาะสมที่ 25.0 °C และขีดจำกัดบนที่ 30.0 °C (Boyd, 1990) ขณะที่ค่า TDS กำหนดค่าเหมาะสมที่ 0 mg/L บนพื้นฐานว่าค่าคุณลักษณะควรมีค่าน้อย และขีดจำกัดบนที่ 500 mg/L เพื่อป้องกันผลกระทบต่อสมดุลของเหลวในร่างกายสัตว์น้ำ (Osmoregulation) ทั้งนี้ ได้ประยุกต์ใช้ฟังก์ชันตัดกรอบ (Clipping Function) เพื่อจำกัดช่วงผลลัพธ์ดัชนีย่อยให้อยู่ในช่วง $[0, 100]$ ด้วย $I_i = \max(0, \min(100, I_i))$ เพื่อป้องกันค่าติดลบหรือเกินเกณฑ์ ก่อนนำไปคำนวณค่าดัชนีคุณภาพน้ำแบบลดรูป (rWQI) ตามสมการที่ (9)

$$rWQI = \sum_{i=1}^3 w_i(I_i)$$

(9)


4. การพัฒนาโมเดลสำหรับพยากรณ์ค่าคุณภาพน้ำ (Develop model and Predict result)

ในขั้นตอนนี้ผู้วิจัยจะพัฒนาแบบจำลองการเรียนรู้ของเครื่องเพื่อพยากรณ์ค่าดัชนีคุณภาพน้ำล่วงหน้า ($rWQI_{future}$) ณ เวลา $t + h$ ซึ่งมีระยะเวลาคาดการณ์ตั้งแต่ 1 ถึง 6 ชั่วโมงล่วงหน้า โดยในงานวิจัยนี้ได้ทำการเปรียบเทียบประสิทธิภาพระหว่างแบบจำลอง ได้แก่ Extra Trees (ET), Random Forest (RF), Linear Regression (LR) และ Multiple Linear Regression (MLR) ร่วมกับการใช้ชุดข้อมูล Persistence Baseline เป็นเกณฑ์อ้างอิงฐาน ทั้งนี้ ในกระบวนการฝึกฝนแบบจำลองได้มีการทำ Hyperparameter Tuning ผ่านวิธี Grid Search ร่วมกับการแบ่งข้อมูลฝึกฝนออกเป็น Validation Set เพื่อค้นหาชุดพารามิเตอร์ที่เหมาะสมที่สุดของแต่ละอัลกอริทึม ดังแสดงรายละเอียดดังตารางที่ 4

ตารางที่ 4 รายการค่าไฮเปอร์พารามิเตอร์ที่ใช้ในระบบ

แบบจำลอง (Model)	ไฮเปอร์พารามิเตอร์ (Hyperparameter)	ค่าเริ่มต้นมาตรฐาน (Default Value)	ค่าที่ปรับแต่ง (Optimal Value)
Extremely Randomized Trees (ET)	n_estimators	100	800
	max_depth	None	None
	min_samples_split	2	2
	random_state	None	42
Random Forest (RF)	n_estimators	100	500
	max_depth	None	None
	min_samples_split	2	2
	random_state	None	42
Simple Linear Regression (LR)	fit_intercept	True	True
Multiple Linear Regression (MLR)	fit_intercept	True	True

โดยในการประเมินประสิทธิภาพของแบบจำลองจะพิจารณาผ่านตัวชี้วัด 4 ค่า ได้แก่ สัมประสิทธิ์การตัดสินใจ (R^2) ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) ค่าความคลาดเคลื่อนเปอร์เซ็นต์สัมบูรณ์เฉลี่ย (MAPE) และค่าความคลาดเคลื่อนเปอร์เซ็นต์สัมบูรณ์เฉลี่ยแบบสมมาตร (sMAPE) โดยแบบจำลองที่ให้ประสิทธิภาพสูงสุดในแต่ละช่วงเวลาจะถูกเลือกนำไปใช้งานในเว็บแอปพลิเคชัน เพื่อสร้างกลไกการแจ้งเตือนล่วงหน้า โดยเมื่อระบบได้รับค่าผลการทำนาย ($rWQI_{future_pred}$) จะตรวจและเทียบกับเกณฑ์มาตรฐานคุณภาพน้ำ NSF WQI ในตารางที่ 1 ซึ่งหากค่าที่ได้ต่ำกว่าเกณฑ์ ระบบจะแจ้งเตือนในระดับเฝ้าระวังหรือระดับอันตราย ในขณะที่หากผลอยู่ในเกณฑ์มาตรฐาน ระบบจะแจ้งสถานะการเฝ้าระวังแบบปกติ ดังสรุปเป็นขั้นตอนในภาพที่ 2



ภาพที่ 2 แผนภาพขั้นตอนการทำงานของระบบพยากรณ์ดัชนีคุณภาพน้ำแบบลดรูป

5. การเชื่อมเซนเซอร์ IoT และพัฒนาต้นแบบแอปพลิเคชัน (Integrate sensor and web application)

ระบบต้นแบบเพื่อการพยากรณ์และเฝ้าระวังคุณภาพน้ำอัจฉริยะ ถูกพัฒนาขึ้นผ่านการบูรณาการเทคโนโลยีไมโครคอนโทรลเลอร์และชุดเซนเซอร์ เพื่อใช้ในการติดตามและบริหารจัดการข้อมูลในลักษณะเรียลไทม์ โดยมีองค์ประกอบดังนี้

5.1) ส่วนฮาร์ดแวร์ ประกอบด้วยเซนเซอร์หลัก 3 ชนิด ได้แก่ เซนเซอร์วัดอุณหภูมิรุ่น DS18B20 (Temperature Sensor) เซนเซอร์วัดค่า pH รุ่น E-201-C (pH Sensor) และ เซนเซอร์วัดปริมาณของแข็งละลายน้ำรวม


5.2) ส่วนซอฟต์แวร์ มีการดำเนินงาน 2 ส่วนหลักดังนี้

- ส่วนควบคุมอุปกรณ์ IoT พัฒนาด้วย Arduino IDE โดยใช้ภาษา C/C++ สำหรับควบคุมการทำงานของเซนเซอร์บนไมโครคอนโทรลเลอร์ ESP32 ซึ่งทำหน้าที่อ่านค่าจากเซนเซอร์อุณหภูมิ ค่า pH และ TDS อย่างต่อเนื่อง และจัดการส่งข้อมูลผ่านโปรโตคอล MQTT โดยมี Mosquitto เป็นตัวกลางในการจัดการเส้นทางข้อมูล (Broker) ระหว่างอุปกรณ์ฮาร์ดแวร์และเซิร์ฟเวอร์ ซึ่งช่วยเพิ่มประสิทธิภาพในการสื่อสารและลดภาระการประมวลผลของตัวอุปกรณ์



ภาพที่ 3 อุปกรณ์เซนเซอร์ในส่วนฮาร์ดแวร์ IoT ที่ใช้ในการตรวจวัดพารามิเตอร์คุณภาพน้ำ ประกอบด้วย 3 ส่วนคือ (ซ้าย) เซนเซอร์วัดอุณหภูมิ (18B20 Temperature Sensor) รุ่น DS18B20 (กลาง) เซนเซอร์วัดค่าความเป็นกรด-ด่างรุ่น E-201-C (pH Sensor) และ (ขวา) เซนเซอร์วัดปริมาณของแข็งละลายน้ำรวม (TDS Sensor)

• ส่วนเว็บแอปพลิเคชัน พัฒนาภายใต้สถาปัตยกรรมแบบไคลเอนต์/เซิร์ฟเวอร์ โดยฝั่งเซิร์ฟเวอร์ใช้ Django (Python) เพื่อจัดการ REST API และเชื่อมต่อฐานข้อมูล MySQL รวมทั้งเรียกใช้แบบจำลองทำนายผล (Predictive Model) การเรียนรู้ของเครื่องเพื่อพยากรณ์ค่าดัชนีคุณภาพน้ำแบบลดรูป ($rWQI$) ล่วงหน้า 1-6 ชั่วโมง สำหรับส่วนติดต่อกับผู้ใช้งานในฝั่งไคลเอนต์ (Client Side) พัฒนาด้วย ReactJS เพื่อรองรับการแสดงผลข้อมูลบนอุปกรณ์เคลื่อนที่ โดยสามารถแสดงภาพรวมการทำงาน และโครงสร้างทางเทคโนโลยี ได้ดังภาพที่ 4



ชุดอุปกรณ์ IoT

ภาพที่ 4 โครงสร้างการทำงานร่วมกันของชุดอุปกรณ์และส่วนแอปพลิเคชัน

ผลการวิจัยและการอภิปราย

ในส่วนนี้จะแสดงการวิเคราะห์และเปรียบเทียบประสิทธิภาพของแต่ละอัลกอริทึมในแต่ละช่วงเวลาผ่านตัวชี้วัด และประเมินความสอดคล้องเชิงเวลาผ่านรูปแบบคลื่นสัญญาณ รวมถึงแสดงผลการพัฒนาและการแจ้งเตือนข้อมูลผ่านเว็บแอปพลิเคชัน โดยมีรายละเอียดดังนี้


1. การเปรียบเทียบประสิทธิภาพของแบบจำลองพยากรณ์คุณภาพน้ำ

ในการประเมินประสิทธิภาพของแบบจำลองพยากรณ์ค่าดัชนีคุณภาพน้ำแบบลดรูป ($rWQI$) ล่วงหน้า 1-6 ชั่วโมงผ่านตัวชี้วัดความแม่นยำ ได้แก่ MAE, R^2 , MAPE และ sMAPE ดังแสดงผลในภาพที่ 5 ซึ่งผลการทดลองชี้ให้เห็นว่ารูปแบบพฤติกรรมและการกระจายตัวของข้อมูลคุณภาพน้ำมีความแปรผันตามมิติเวลา ซึ่งสรุปและอภิปรายได้ดังนี้

• ประสิทธิภาพการพยากรณ์ระยะสั้น (1-3 ชั่วโมงล่วงหน้า) แบบจำลองกลุ่ม Ensemble Tree-based โดยเฉพาะ RF มีความแม่นยำสูงสุด โดยที่ระยะเวลา 1 ชั่วโมงล่วงหน้า RF ให้ค่า R^2 สูงสุดถึง 0.566 และควบคุมความคลาดเคลื่อนได้ดี (MAE = 5.215, sMAPE = 10.16%) สะท้อนว่าแบบจำลองสามารถตรวจจับความสัมพันธ์แบบไม่เป็นเชิงเส้น (Non-Linear Relationship) และตอบสนองต่อการเปลี่ยนแปลงของข้อมูล (Local Volatility) ได้ดี อย่างไรก็ตามเมื่อระยะเวลาเพิ่มขึ้นเป็น 2 และ 3 ชั่วโมง ค่า R^2 ของ RF ลดลงอย่างรวดเร็วเหลือ 0.252 และ 0.022 ตามลำดับ อย่างไรก็ตามในระยะ 1-2

ชั่วโมงแรก พบว่าแบบจำลองมีความคลาดเคลื่อนสูงกว่าค่าเฉลี่ยฐาน (Mean Baseline) เนื่องจากเกิดความผันผวนสูงในระยะสั้น ทำให้แบบจำลองตรวจจับทิศทางของการเปลี่ยนแปลงค่าคุณภาพน้ำแบบฉับพลันได้ยากกว่าการทำนายผลด้วยค่าเฉลี่ย

● **ประสิทธิภาพการพยากรณ์ระยะยาว (4–6 ชั่วโมงล่วงหน้า)** ในระยะนี้พบว่าทุกแบบจำลองมีค่า R^2 ลดลงจนติดลบ สะท้อนว่าความแม่นยำของการพยากรณ์ลดลงจนต่ำกว่าการใช้ค่าเฉลี่ยฐานของข้อมูลจริง (Mean Baseline) ซึ่งเกิดจากความผันผวนของคุณภาพน้ำในสภาพแวดล้อมจริง ร่วมกับการสะสมความคลาดเคลื่อนของการพยากรณ์ข้ามช่วงเวลาหลายก้าว (Error Accumulation) แต่พบว่า LR ให้ประสิทธิภาพดีที่สุดในกลุ่มในช่วงชั่วโมงที่ 4-6 (เช่น ในชั่วโมงที่ 6 LR มีค่า $R^2 = -0.535$ และ $MAE = 10.913$) ซึ่งเหนือกว่าแบบจำลองอื่นๆ รวมทั้งมีค่าที่ดีกว่า Persistence Baseline ด้วย



ภาพที่ 5 ประสิทธิภาพของโมเดลพยากรณ์ ($rWQI$) ในช่วงเวลาต่าง ๆ ตามค่าตัวชี้วัด MAE, R^2 , MAPE และ sMAPE

โดยสรุป เมื่อพิจารณาค่า Forecast Skill Score เทียบกับ Persistence Baseline พบว่า ในการพยากรณ์ระยะสั้น (1–2 ชั่วโมง) แบบจำลองยังมีประสิทธิภาพต่ำกว่า Baseline ($Skill\ Score < 0$) เนื่องจากข้อมูลคุณภาพน้ำในระยะเวลาดังกล่าวมีความคงตัวสูงและเปลี่ยนแปลงแบบค่อยเป็นค่อยไป (High Autocorrelation) อย่างไรก็ตาม ในการพยากรณ์ระยะ 3–6 ชั่วโมงแบบจำลองเริ่มมีประสิทธิภาพที่เหนือกว่า Persistence Baseline โดยค่า Skill Score มีค่าเป็นบวกและมีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่อง เนื่องจากความผันผวนของคุณภาพน้ำส่งผลให้ความคลาดเคลื่อนของ Baseline สูงขึ้นอย่างรวดเร็ว ทั้งนี้ในการพยากรณ์ระยะยาว (4–6 ชั่วโมง) พบว่าทุกแบบจำลองมีค่า $R^2 < 0$ ซึ่งสะท้อนถึงข้อจำกัดในการรับมือกับการสะสมความคลาดเคลื่อน (Error Accumulation) และความผันผวนสูงของคุณภาพน้ำในสภาพแวดล้อมจริง อย่างไรก็ตามผลการพยากรณ์ใน 1 ชั่วโมงแรกสอดคล้องกับแนวคิด Zhu et al. (2022) ที่ระบุว่าแบบจำลองกลุ่ม Ensemble Tree-based Learning มีประสิทธิภาพสูงในการตรวจจับความผันผวนและความสัมพันธ์แบบไม่เป็นเชิงเส้นของข้อมูลคุณภาพน้ำในระยะสั้น


ตารางที่ 5 สรุปประสิทธิภาพแบบจำลองพยากรณ์ดัชนีคุณภาพน้ำแบบลดรูปและเกณฑ์วัดความคลาดเคลื่อนรายชั่วโมง

จำนวนชั่วโมง ล่วงหน้า	Predictive Model	R^2	MAE	MAE (Baseline)	MAPE (%)	sMAPE (%)	Forecast Skill Score
1h	Random Forest	0.566	5.215	4.053	11.23	10.16	-0.287
2h	Random Forest	0.252	6.840	5.997	15.54	14.15	-0.141

3h	Random Forest	0.022	7.804	8.068	19.03	16.94	+0.033
4h	Linear Regression	-0.285	9.271	9.715	22.06	20.22	+0.046
5h	Linear Regression	-0.412	10.255	11.126	24.32	22.26	+0.078
6h	Linear Regression	-0.535	10.913	12.174	25.94	23.63	+0.104

2. การประเมินความสอดคล้องเชิงเวลาของโมเดลกับการเปลี่ยนแปลงคุณภาพน้ำจริง

ในส่วนนี้ผู้วิจัยได้ทดสอบเชิงคุณภาพผ่านการวิเคราะห์รูปคลื่นสัญญาณ (Waveform Analysis) โดยเปรียบเทียบค่าพยากรณ์กับค่าดัชนีคุณภาพน้ำแบบลดรูปจริง (*rWQI*) ณ ระยะเวลาพยากรณ์ 1 ชั่วโมง 3 ชั่วโมงและ 6 ชั่วโมงตามลำดับ ซึ่งการวิเคราะห์ในส่วนนี้มีวัตถุประสงค์เพื่อประเมินเสถียรภาพและการติดตามแนวโน้มของแบบจำลองภายใต้สภาวะความผันผวนของข้อมูลจริง โดยผลลัพธ์แสดงดังภาพที่ 6 ซึ่งสามารถอธิบายพฤติกรรมของแบบจำลองต่าง ๆ ในแต่ละช่วงระยะเวลาได้ดังนี้



ภาพที่ 6 ผลการเปรียบเทียบการพยากรณ์ค่าดัชนีคุณภาพน้ำแบบลดรูปล่วงหน้าในระยะเวลา (บน) 1 ชั่วโมง (กลาง) 3 ชั่วโมง และ (ล่าง) 6 ชั่วโมง เพื่อแสดงพฤติกรรมและความแม่นยำของแต่ละโมเดลพยากรณ์ (Predicted Value) เปรียบเทียบกับค่าจริง (Actual Value)

- ช่วงเวลาการพยากรณ์ในชั่วโมงที่ 1 พบว่าแบบจำลอง RF มีประสิทธิภาพสูงสุด โดยสามารถคาดการณ์ทิศทางการเปลี่ยนแปลงของค่าน้ำได้อย่างรวดเร็วและทันท่วงที ส่งผลให้เส้นกราฟการพยากรณ์มีความสอดคล้องและทับซ้อนเกือบสมบูรณ์กับเส้นข้อมูลจริง (Actual Data) โดยมีความล่าช้า (Time Lag) ต่ำมาก ซึ่งแสดงถึงความแม่นยำในการพยากรณ์ระยะสั้นที่สูง
- ช่วงเวลาการพยากรณ์ในชั่วโมงที่ 3 พบว่าแบบจำลอง RF แสดงพฤติกรรมการพยากรณ์ที่เสถียรและราบเรียบ (Smoothing Effect) ได้ชัดเจนกว่าแบบจำลองเชิงเส้น ช่วยคัดกรองสัญญาณรบกวนจากเซนเซอร์และลดความไวต่อ


ความผันผวนระยะสั้นที่ไม่ได้สะท้อนความผิดปกติที่แท้จริง ซึ่งช่วยลดอัตราการเกิดสัญญาณเตือนผิดพลาด (False Alarms) ซึ่งทำให้โมเดลในกลุ่มนี้มีความเสถียรของผลพยากรณ์ที่สูงกว่า และช่วยลดภาระในการตรวจสอบสัญญาณเตือนที่ไม่จำเป็น ทำให้เหมาะต่อการเฝ้าระวังคุณภาพน้ำในสภาพแวดล้อมจริง

● **ช่วงเวลาพยากรณ์ในชั่วโมงที่ 6** พบว่าเส้นกราฟการพยากรณ์ของทุกแบบจำลองแสดงความล่าช้า (Time Lag) ในการตอบสนองอย่างชัดเจนเมื่อเทียบกับค่าจริง และมีความคลาดเคลื่อนสูงชันอย่างมาก สอดคล้องกับค่า R^2 ที่ติดลบ ด้วยเหตุนี้ในการนำไปประยุกต์ใช้งานจริง ระบบจึงควรจำกัดขอบเขตการพยากรณ์ในระยะสั้นช่วง 1-3 ชั่วโมง โดยไม่นำผลพยากรณ์ในช่วง 4-6 ชั่วโมงมาใช้ในการแจ้งเตือน เพื่อป้องกันการเกิดสัญญาณเตือนผิดพลาด (False Alarms)

โดยผลการทดสอบข้างต้นสอดคล้องกับแนวคิดของ Zhu *et al.* (2022) ที่ชี้ว่าประสิทธิภาพของแบบจำลองมีความผันแปรตามระยะเวลาพยากรณ์ ดังนั้นการบ่งชี้สถานะคุณภาพน้ำที่มีความแม่นยำและน่าเชื่อถือ จำเป็นต้องพิจารณาเลือกใช้แบบจำลองให้สอดคล้องกับพฤติกรรมข้อมูลและระยะเวลาพยากรณ์ที่แตกต่างกัน เพื่อให้ได้ผลลัพธ์ที่ตอบโต้ภัยพิบัติการเฝ้าติดตามระยะสั้นได้อย่างเหมาะสม

3. ผลการพัฒนาและส่วนติดต่อผู้ใช้งานของระบบเฝ้าติดตามคุณภาพน้ำอัจฉริยะ

ในส่วนนี้เป็นการนำแบบจำลองการเรียนรู้ของเครื่องที่มีประสิทธิภาพสูงสุดในแต่ละระยะเวลาพยากรณ์ไปทำงานร่วมกับระบบเว็บแอปพลิเคชันเพื่อสร้างกลไกการแจ้งเตือนค่าดัชนีคุณภาพน้ำล่วงหน้า จากผลการทดสอบพบว่าระบบสามารถประมวลผลพารามิเตอร์คุณภาพน้ำจากอุปกรณ์ IoT ได้แก่ อุณหภูมิ, ค่า pH และ TDS และเลือกใช้แบบจำลองที่เหมาะสมในการคำนวณพร้อมจำแนกค่าดัชนีคุณภาพน้ำแบบลดรูป ($rWQI$) ได้อย่างถูกต้อง โดยแสดงผลผ่านส่วนติดต่อผู้ใช้งาน และระบบแจ้งเตือนระดับคุณภาพน้ำได้อย่างมีประสิทธิภาพ ดังแสดงในภาพที่ 7



ภาพที่ 7 หน้าจอส่วนติดต่อผู้ใช้งานของระบบ โดยแสดงผลการจำลองสถานการณ์การพยากรณ์ค่าดัชนีคุณภาพน้ำแบบลดรูปล่วงหน้าในชั่วโมงที่แตกต่างกันได้แก่ (ซ้าย) แสดงผลการพยากรณ์ค่าดัชนีคุณภาพน้ำแบบลดรูปในระดับอันตราย (Danger) ในชั่วโมงที่ 3 ล่วงหน้า, (กลาง) แสดงผลการพยากรณ์ค่าดัชนีคุณภาพน้ำแบบลดรูประดับเฝ้าระวัง (Caution) ในชั่วโมงที่ 1 ล่วงหน้า และ (ขวา) แสดงผลการพยากรณ์ค่าดัชนีคุณภาพน้ำแบบลดรูประดับปกติ ณ เวลาปัจจุบัน

จากภาพที่ 7 สามารถสรุปประสิทธิภาพการทำงานของระบบแอปพลิเคชันและผลการพยากรณ์ค่าดัชนีคุณภาพน้ำแบบลดรูปล่วงหน้าในระยะเวลา 1-6 ชั่วโมง โดยจำแนกตามสถานะ ซึ่งแบ่งได้ดังนี้

- **ระดับอันตราย (Danger)** แสดงผลผ่านหน้าจอ UI สีส้ม ($rWQI = 48$) ซึ่งเป็นสถานะแจ้งเตือนเมื่อระบบตรวจพบแนวโน้มของคุณภาพน้ำที่อาจเป็นอันตรายต่อสัตว์น้ำในอีก 3 ชั่วโมงล่วงหน้า ทำให้ผู้ใช้สามารถเตรียมการจัดการและป้องกันผลกระทบได้ทัน

- **ระดับเฝ้าระวัง (Caution)** แสดงผลผ่านหน้าจอ UI สีเหลือง ($rWQI = 67$) เป็นการแจ้งเตือนจากระบบเมื่อตรวจพบสัญญาณความผันผวนของพารามิเตอร์คุณภาพน้ำในระยะสั้น (1 ชั่วโมงล่วงหน้า) เพื่อให้ผู้ใช้เพิ่มความถี่ในการติดตามและเฝ้าระวังระบบน้ำอย่างใกล้ชิด

- **ระดับปกติ (Normal)** แสดงผลผ่านหน้าจอ UI สีเขียว ($rWQI = 71$) เป็นการแจ้งเตือนเมื่อระบบพยากรณ์ว่าพารามิเตอร์คุณภาพน้ำในปัจจุบันยังอยู่ในเกณฑ์มาตรฐานและมีความเสถียรสูง

ดังนั้นสรุปได้ว่าแนวคิดการบูรณาการแบบจำลองการทำนายค่าคุณภาพน้ำด้วยเทคนิคการเรียนรู้ของเครื่องมาทำงานร่วมกับเทคโนโลยี IoT และแสดงผลข้อมูลผ่านเว็บแอปพลิเคชัน สามารถวิเคราะห์และแสดงค่าดัชนีคุณภาพน้ำแบบลดรูป ($rWQI$) ล่วงหน้าในระยะสั้น (1-3 ชั่วโมง) ได้อย่างแม่นยำ ซึ่งเฟรมเวิร์กนี้ช่วยยกระดับการประเมินและติดตามคุณภาพน้ำแบบเรียลไทม์ไปสู่ระบบการแจ้งเตือนล่วงหน้าเชิงรุก ทั้งยังช่วยสนับสนุนการตัดสินใจของผู้ใช้ในการบริหารจัดการคุณภาพน้ำได้อย่างรวดเร็วและมีประสิทธิภาพมากขึ้น

สรุปผลการวิจัยและข้อเสนอแนะจากการวิจัย

งานวิจัยนี้ประสบความสำเร็จในการพัฒนาต้นแบบระบบพยากรณ์และเฝ้าระวังคุณภาพน้ำอัจฉริยะ โดยการบูรณาการเทคโนโลยีอินเทอร์เน็ตของสรรพสิ่ง ร่วมกับเว็บเฟรมเวิร์ก Django และแบบจำลองการเรียนรู้ของเครื่อง เพื่อจัดเก็บและประมวลผลข้อมูลจากเซนเซอร์ตรวจวัดอุณหภูมิ ค่าความเป็นกรด-ด่าง และปริมาณของแข็งละลายน้ำรวม ผลการดำเนินงานพบว่าระบบสามารถแสดงผลค่าดัชนีคุณภาพน้ำแบบลดรูป ($rWQI$) แบบเรียลไทม์และพยากรณ์ค่าสถานะล่วงหน้าผ่านเว็บแอปพลิเคชันได้อย่างมีประสิทธิภาพ

จากผลการวิเคราะห์เปรียบเทียบสมรรถนะของแบบจำลองการเรียนรู้ของเครื่องทั้ง 4 ประเภทได้แก่ ET, RF, LR และ MLR ซึ่งเลือกใช้เทคนิคการวิเคราะห์การถดถอย (Regression Analysis) เนื่องจากเป็นวิธีที่ไม่ซับซ้อน คำนวณได้รวดเร็ว เหมาะกับการประมวลผลบนระบบฝังตัวหรือเซิร์ฟเวอร์ขนาดเล็ก ทั้งยังสามารถทำนายค่า $rWQI$ ซึ่งเป็นข้อมูลต่อเนื่อง (0-100) ได้โดยตรง โดยจากผลการทดลองชี้ให้เห็นว่าประสิทธิภาพการทำงานของแบบจำลองจะแปรผันตามระยะเวลาพยากรณ์อย่างชัดเจน โดยในระยะสั้น (1-3 ชั่วโมงล่วงหน้า) แบบจำลอง RF มีประสิทธิภาพสูงสุดในการพยากรณ์ค่าดัชนีคุณภาพน้ำแบบลดรูป เนื่องจากคุณสมบัติในการจับรูปแบบข้อมูลที่ซับซ้อน ทำให้แบบจำลองสามารถตอบสนองต่อความผันผวนของค่าดัชนีคุณภาพน้ำในช่วงเริ่มต้นได้อย่างแม่นยำ โดยในชั่วโมงแรกมีค่า R^2 เท่ากับ 0.566 และ MAE เท่ากับ 5.215 ซึ่งแม้ว่าในระยะ 1-2 ชั่วโมงแรก Persistence Baseline จะมีค่า MAE ต่ำกว่า เนื่องจากข้อมูลมีความคงตัวสูงตามอนุกรมเวลา (High Autocorrelation) แต่แบบจำลองยังคงมีความสำคัญในการจับแนวโน้มความเปลี่ยนแปลงเพื่อแจ้งเตือนล่วงหน้าเมื่อเกิดความผันผวนของค่าคุณภาพน้ำอยู่ และจะสังเกตว่าในชั่วโมงที่ 3 แบบจำลองเริ่มแสดงประสิทธิภาพที่ดีกว่า Baseline (Forecast Skill Score มีค่าเป็นบวกที่ +0.033) เนื่องจากความผันผวนสะสมตามเวลาทำให้ความคลาดเคลื่อนของ Baseline สูงขึ้นอย่างรวดเร็ว จนแบบจำลองเริ่มทำนายผลได้แม่นยำมากกว่าการใช้ค่าเฉลี่ยฐาน (Mean Baseline)

ในขณะทำการพยากรณ์ค่าคุณภาพน้ำในระยะยาว (4-6 ชั่วโมงล่วงหน้า) แม้ว่าแบบจำลอง LR มีความเสถียรสูงสุดในกลุ่ม แต่พบว่าทุกแบบจำลองมีค่า R^2 ติดลบ ($R^2 < 0$) ซึ่งสะท้อนถึงข้อจำกัดจากการสะสมความคลาดเคลื่อน (Error Accumulation) ตามระยะเวลาพยากรณ์ข้ามช่วงเวลาหลายก้าว (Multi-step Ahead Forecasting) ดังนั้นจึงควรจำกัดการนำไปประยุกต์ใช้งานจริงเฉพาะการเฝ้าระวังหรือแจ้งเตือนในช่วงระยะสั้นเท่านั้น โดยข้อค้นพบดังกล่าวชี้ให้เห็นว่าการเลือกใช้แบบจำลองให้สอดคล้องกับกรอบเวลาพยากรณ์เป็นปัจจัยสำคัญในการเพิ่มประสิทธิภาพและความเสถียรในระบบประเมินและพยากรณ์ดัชนีคุณภาพน้ำ ซึ่งองค์ความรู้นี้จะช่วยให้ผู้ใช้สามารถวางแผนควบคุมคุณภาพน้ำได้อย่างแม่นยำและรวดเร็ว ช่วยลด

ต้นทุนและความเสี่ยงในการสูญเสียสัตว์น้ำ อีกทั้งยังเป็นต้นแบบทางเทคโนโลยีเกษตรดิจิทัลที่ช่วยยกระดับการเฝ้าระวังคุณภาพน้ำทั่วไปสู่การบริหารจัดการเชิงรุกด้วยเทคโนโลยีอัจฉริยะ

งานวิจัยนี้สอดคล้องกับเป้าหมายการพัฒนาที่ยั่งยืน (SDGs) โดยยกระดับความมั่นคงทางอาหาร (SDG 2: Zero Hunger) ผ่านการนำเทคโนโลยีการเกษตรอัจฉริยะมาใช้ลดการสูญเสียและเพิ่มความยั่งยืนในการผลิตสัตว์น้ำ ควบคู่กับการส่งเสริมการจัดการน้ำสะอาด (SDG 6: Clean Water and Sanitation) ด้วยนวัตกรรมเฝ้าระวังและป้องกันการสะสมมลพิษในระบบเพาะเลี้ยงสัตว์น้ำน้ำจืดแบบปิด ทั้งนี้ผู้วิจัยได้กำหนดข้อเสนอแนะเพื่อการพัฒนาและขยายผลระบบในอนาคต ดังนี้

- **ด้านการประเมินและเปรียบเทียบเชิงระเบียบวิธี** ควรศึกษาวิจัยเปรียบเทียบร่วมกับแบบจำลองอนุกรมเวลามาตรฐาน เช่น ARIMA, SARIMA, Prophet และแบบจำลองการเรียนรู้เชิงลึก (Deep Learning) รวมถึงทดสอบเปรียบเทียบระหว่างวิธี Risk-Focused Aggregation กับ Mean Aggregation นอกจากนี้ควรเพิ่มการประเมินด้วยเทคนิค Time-Series Cross-Validation (เช่น Rolling Window หรือ Expanding Window) และการทดลองซ้ำหลายรอบ (Multiple Repeated Runs) เพื่อลดปัญหา Overfitting และลดความคลาดเคลื่อนจากการสุ่มขอบเขตข้อมูล ซึ่งจะช่วยยืนยันความแม่นยำและความเสถียรของแบบจำลองให้มีความน่าเชื่อถือยิ่งขึ้น

- **ด้านการทดสอบฮาร์ดแวร์และการใช้งานภาคสนาม** ควรขยายผลจากการทดสอบระบบต้นแบบไปสู่การเชื่อมระบบและทดสอบอุปกรณ์ IoT ในสภาพแวดล้อมจริงต่อเนื่องอย่างน้อย 1–2 สัปดาห์ เพื่อประเมินความแม่นยำของเซนเซอร์เทียบกับเครื่องมือมาตรฐาน โดยตรวจสอบความสามารถในการถ่ายโอนแบบจำลอง (Transferability) และวัดอัตราการแจ้งเตือนที่มีความถูกต้องหรือผิดพลาดเพียงใด (True/False Alarm Rate)

- **ด้านการขยายขอบเขตพารามิเตอร์** พิจารณาติดตั้งเซนเซอร์วัดค่าออกซิเจนละลายน้ำ (Dissolved Oxygen: DO) และค่าความขุ่น (Turbidity) เพิ่มเติม เนื่องจากเป็นตัวแปรสำคัญที่มีผลกระทบต่อระบบนิเวศทางน้ำโดยตรง เพื่อขยายผลจากดัชนีคุณภาพน้ำแบบลดรูป ($rWQI$) ไปสู่การคำนวณดัชนีคุณภาพน้ำที่ครอบคลุมและแม่นยำมากยิ่งขึ้น

กิตติกรรมประกาศ

ขอขอบคุณภาคีวิชาการและวิทยาศาสตร์และเทคโนโลยีดิจิทัล และคณะวิทยาศาสตร์ มหาวิทยาลัยอุบลราชธานี ที่ได้ให้การสนับสนุนด้านเครื่องมือ อุปกรณ์ และห้องปฏิบัติการ ซึ่งเอื้อประโยชน์ต่อการเรียนและการดำเนินงานวิจัยจนสำเร็จลุล่วงด้วยดี

จริยธรรมการวิจัย

งานวิจัยนี้ยึดหลักจริยธรรมทางวิชาการและการจัดการข้อมูลอย่างเคร่งครัด 2 ด้าน ดังนี้

1. **หลักความปลอดภัยต่อสวัสดิภาพสิ่งมีชีวิต** การทดสอบระบบทำในสภาวะจำลองโดยไม่มีการใช้สิ่งมีชีวิตจริง แต่ใช้อุปกรณ์และเซนเซอร์ทั้งหมดผ่านการตรวจสอบความปลอดภัยทางไฟฟ้าและวัสดุ เพื่อให้มั่นใจว่าจะไม่เป็นอันตรายต่อสัตว์น้ำเมื่อนำไปใช้งานจริงในอนาคต

2. **ความถูกต้องและความปลอดภัยของข้อมูล** ข้อมูลพารามิเตอร์ค่าจากอุปกรณ์ IoT (อุณหภูมิ, pH และ TDS) ถูกจัดเก็บตามข้อเท็จจริงโดยไม่มีการบิดเบือน เพื่อความแม่นยำในการวิเคราะห์ ทั้งนี้ข้อมูลระบบทั้งหมดจะถูกเก็บเป็นความลับและเข้าถึงได้เฉพาะกลุ่มผู้วิจัยเพื่อวัตถุประสงค์ทางวิชาการเท่านั้น

การใช้เครื่องมือปัญญาประดิษฐ์

ผู้วิจัยขอเปิดเผยว่าได้มีการใช้เครื่องมือปัญญาประดิษฐ์ (AI tools) เพื่อสนับสนุนงานเขียนบทความวิจัยนี้ โดยเครื่องมือปัญญาประดิษฐ์ถูกนำมาใช้ใน 2 ส่วนได้แก่ (1) ด้านการจัดทำแผนภาพประกอบ โดยใช้เครื่องมือปัญญาประดิษฐ์ในการสนับสนุนการออกแบบภาพแสดงขั้นตอนการทำงานของระบบ และ (2) ด้านภาษาและตรวจสอบรูปแบบเอกสารอ้างอิง โดยใช้ Google Gemini และ Grammarly ช่วยปรับปรุงประโยค รวมถึงโครงสร้างภาษาอังกฤษในบทความวิจัย ทั้งนี้ผู้วิจัยเป็นผู้รับผิดชอบต่อความถูกต้องของข้อมูล แผนภาพ วิธีดำเนินการวิจัย ผลการวิเคราะห์ และข้อสรุปทางวิชาการทั้งหมดในบทความ

References

- Al-Shareeda, M. A., Ali, A. M., Hammoud, M. A., Kazem, Z. H. M. and Hussein, M. A. (2025). Secure IoT-based real-time water level monitoring system using ESP32 for critical infrastructure. **Journal of Cyber Security and Risk Auditing**, 2025(2), 44-52.
- Arthi, P., Mahesh, N., Saipurusoth, H. and Janardhanam, B. (2024). IoT based smart aquaculture monitoring system for fish tank management. **Journal of Ubiquitous Computing and Communication Technologies**, 6(3), 214–227.
- Bakar, A. A., Bakar, Z., Yusoff, Z., Ibrahim, M., Mokhtar, N. and Zaiton, S. (2025). IoT-based real-time water quality monitoring and sensor calibration for enhanced accuracy and reliability. **International Journal of Interactive Mobile Technologies**, 19(1), 155–170.
- Boyd, C. E. (1990). **Water quality in ponds for aquaculture**. Birmingham: Birmingham Publishing Co.
- Breiman, L. (2001). Random forests. **Machine Learning**, 45(1), 5–32.
- Brown, R. M., McClelland, N. I., Deininger, R. A. and Tozer, R. G. (1970). A water quality index-do we dare?. **Water and Sewage Works**, 117(10), 339–343.
- Dayaday, M. G. and Namoco, C. S. (2021). An innovative real-time water quality monitoring system for aquaculture application. **Journal of Engineering and Applied Sciences**, 16(24), 2737-2740.
- De Oliveira, A. R. M., Borges, A. C., Da Silva, G. J. and Nascimento, M. (2022). Development of a water quality index with a reduced number of parameters. **Engenharia Agrícola**, 42(3), e20220006.
- Department of Fisheries. (2024). Director-general of the department of fisheries reveals ornamental fish and Thai Siamese fighting fish are popular worldwide, generating over 1,000 million baht in exports (in Thai). Retrieved 30 May 2026, from **Department of Fisheries**:
https://www4.fisheries.go.th/local/index.php/main/view_activities/1210/255678
- Duangwongsa, J., Ungsethaphand, T., Akaboot, P., Khamjai, S. and Unankard, S. (2022). Real-time water quality monitoring and notification system for aquaculture. **Proceedings of IEEE International Conference on Internet of Things and Intelligence System** (pp. 1–6). Bali, Indonesia.
- Fandiño Pelayo, J. S., Mendoza Castellanos, L. S., Cazes Ortega, R. and Hernández-Rojas, L. G. (2025). AI-driven monitoring for fish welfare in aquaponics: a predictive approach. **Sensors**, 25(19), 6107.
- Forhad, H. M., Uddin, M. R., Chakrovorty, R. S., Ruhul, A. M., Faruk, H. M., Kamruzzaman, S., Sharmin, N., Jamall, A. S. M. M., Haque, M. M. and Morshed, A. K. M. (2024). IoT based real-time water quality monitoring system in water treatment plants (WTPs). **Heliyon**, 10(23), e40746.
- Gaya, M. S., Abba, S. I., Abdu, A. M., Tukur, A. I., Saleh, M. A., Esmaili, P. and Wahab, N. A. (2020). Estimation of water quality index using artificial intelligence approaches and multi-linear regression. **IAES International Journal of Artificial Intelligence**, 9(1), 126–134.
- Geurts, P., Ernst, D. and Wehenkel, L. (2006). Extremely randomized trees. **Machine Learning**, 63(1), 3–42.
- Hridoy, M. A. A. M., Shawkat, A. I., Bordin, C., Acharjee, M. R., Masood, A., Baki, A. O. and Al Mamun, M. A. (2025). Advanced machine learning models for accurate water quality classification and WQI prediction: Implications for aquatic disease risk management. **Science of The Total Environment**, 1008, 180965.

- Jais, N. A. M., Abdullah, A. F., Kassim, M. S. M., Abd Karim, M. M. and Muhadi, N. A. (2024). Improved accuracy in IoT-Based water quality monitoring for aquaculture tanks using low-cost sensors: Asian seabass fish farming. **Heliyon**, 10(8), e29022.
- Mohd Zebaral Hoque, J., Ab. Aziz, N. A., Alelyani, S., Mohana, M. and Hosain, M. (2022). Improving water quality index prediction using regression learning models. **International Journal of Environmental Research and Public Health**, 19(20), 13702.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, 12(85), 2825–2830.
- Palabiyik, S. and Akkan, T. (2024). Evaluation of water quality based on artificial intelligence: performance of multilayer perceptron neural networks and multiple linear regression versus water quality indexes. **Environment, Development and Sustainability**, 26(6), 7521–7545.
- Palconit, M., Concepcion, R. S, Tobias, R. R., Alejandrino, J., Almero, V. J. D, Bandala, A. A, Vicerra, R. R. P., Sybingco, E. and Dadios, E. P. (2021). Development of IoT-based fish tank monitoring system. In **Proceedings of the 2021 IEEE 13th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control Environment (HNICEM)** (pp. 1–6). Manila, Philippines.
- Patel, D., Kiradia, K. and Sharma, P. (2025). IoT-Based Water Quality Monitoring System using ESP32. **International Journal for Research in Applied Science and Engineering Technology**, 13(4), 4942–4949.
- Shams, M. Y., Elshewey, A. M., El-Kenawy, E. S. M., Ibrahim, A., Talaat, F. M. and Tarek, Z. (2023). Water quality prediction using machine learning models based on grid search method. **Multimedia Tools and Applications**, 83, 35307–35334.
- Siswanto, B., Dani, Y., Morika, D. and Mardiyana, B. (2023). A simple dataset of water quality on aquaponic fish ponds based on an internet of things measurement device. **Data in Brief**, 48, 109218.
- Stojanovic, N. and Chaudhary, S. (2023). Real-time water quality monitoring in aquaculture using IoT sensors and cloud-based analytics. **Research Journal of Computer Systems and Engineering**, 4(2), 174–187.
- Straits Research. (2024). Ornamental fish market size, share and trends analysis report by type (tropical freshwater, temperate freshwater, marine), by application, by distribution channel, and segment forecasts 2024–2032. Retrieved 30 May 2026, from **Straits Research**:
<https://straitsresearch.com/report/ornamental-fish-market>
- Zhu, M., Wang, J., Yang, X., Zhang, Y., Zhang, L., Ren, H., Wu, B. and Ye, L. (2022). A review of the application of machine learning in water quality evaluation. **Eco-Environment and Health**, 1(2), 107–116.