



การพยากรณ์ออกซิเจนละลายในน้ำโดยใช้เทคนิคการเรียนรู้เชิงลึก
FORECASTING DISSOLVED OXYGEN IN WATER USING DEEP LEARNING
TECHNIQUES

เลิศลักษณ์ สุนทรานุสรณ์

บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ

2567

การพยากรณ์ออกซิเจนละลายในน้ำโดยใช้เทคนิคการเรียนรู้เชิงลึก



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตร์มหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ

ปีการศึกษา 2567

ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

FORECASTING DISSOLVED OXYGEN IN WATER USING DEEP LEARNING
TECHNIQUES



An Master's Project Submitted in Partial Fulfillment of the Requirements
for the Degree of MASTER OF SCIENCE
(Data Science)

Faculty of Science, Srinakharinwirot University

2024

Copyright of Srinakharinwirot University

สารนิพนธ์
เรื่อง
การพยากรณ์ออกซิเจนละลายในน้ำโดยใช้เทคนิคการเรียนรู้เชิงลึก
ของ
เลิศลักษณ์ สุนทรานุสรณ์

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)
คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

..... ที่ปรึกษาหลัก	 ประธาน
(อาจารย์ ดร.เรืองศักดิ์ ตระกูลพุทธิรักษ์)	(ผู้ช่วยศาสตราจารย์ ดร.จันตรี ผลประเสริฐ)
	 กรรมการ
	(อาจารย์ ดร.ศุภร คนธรักษ์ดี)

ชื่อเรื่อง	การพยากรณ์ออกซิเจนละลายในน้ำโดยใช้เทคนิคการเรียนรู้เชิงลึก
ผู้วิจัย	เลิศลักษณ์ สุนทรานุสรณ์
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2567
อาจารย์ที่ปรึกษา	อาจารย์ ดร. เรืองศักดิ์ ตระกูลพุทธิรักษ์

ค่าออกซิเจนละลายน้ำ (Dissolved Oxygen: DO) เป็นตัวบ่งชี้คุณภาพน้ำที่สำคัญต่อสิ่งมีชีวิตในน้ำ การลดลงของค่า DO อาจทำให้เกิดความเครียดหรือถึงขั้นเสียชีวิตของสิ่งมีชีวิตเหล่านี้ได้ ดังนั้น การติดตามและพยากรณ์ค่า DO จึงเป็นสิ่งจำเป็นสำหรับการจัดการคุณภาพน้ำในระบบนิเวศและการเพาะเลี้ยงสัตว์น้ำ ปัจจุบัน มีการนำเทคนิคปัญญาประดิษฐ์มาประยุกต์ใช้ โดยเฉพาะแบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Networks) ซึ่งสามารถวิเคราะห์ข้อมูลอนุกรมเวลาได้อย่างมีประสิทธิภาพ งานวิจัยนี้จึงมีเป้าหมายในการสร้างแบบจำลองเพื่อพยากรณ์ค่าออกซิเจนละลายน้ำ โดยใช้ข้อมูลค่าออกซิเจนละลายน้ำรายวันรวม 1,603 ชุดข้อมูลเพื่อศึกษาแบบจำลองการเรียนรู้เชิงลึกทั้งหมด 5 เทคนิค ได้แก่ แบบจำลอง RNNs (Recurrent Neural Networks), แบบจำลอง LSTM (Long Short-Term Memory), แบบจำลอง GRU (Gated Recurrent Unit), แบบจำลอง CNN-LSTM (Convolutional Neural Network + LSTM) และ แบบจำลอง CNN-GRU (Convolutional Neural Network + GRU) ได้ทำการปรับค่าไฮเปอร์พารามิเตอร์ต่าง ๆ (Hyperparameters) จากผลการทดลองพบว่าแบบจำลอง CNN-GRU มีประสิทธิภาพสูงสุด โดยมีค่า MSE 0.0551, RMSE 0.2347 และ MAPE 1.9895% และยังพบว่าแบบจำลองในกลุ่มที่ใช้เทคนิค CNN ช่วยทำให้ประสิทธิภาพของแบบจำลองดีขึ้นกว่ากลุ่มที่ไม่ได้ใช้เทคนิค CNN และแบบจำลองที่ใช้เทคนิค GRU ยังเป็นเทคนิคที่ให้ประสิทธิภาพของแบบจำลองดีที่สุดทั้งในกลุ่มที่ใช้และไม่ใช้เทคนิค CNN อีกด้วย โดยในอนาคตสามารถทำให้ประสิทธิภาพของแบบจำลองในกลุ่มที่ใช้เทคนิค CNN ดีขึ้นได้โดยการปรับค่าไฮเปอร์พารามิเตอร์ต่าง ๆ (Hyperparameters) ในส่วนของเทคนิค CNN เพื่อให้ได้แบบจำลองที่มีประสิทธิภาพดีและเหมาะสมที่สุด

คำสำคัญ : ค่าออกซิเจนละลายน้ำ, โครงข่ายประสาทเทียม, การเรียนรู้เชิงลึก, ข้อมูลอนุกรมเวลา

Title	FORECASTING DISSOLVED OXYGEN IN WATER USING DEEP LEARNING TECHNIQUES
Author	LERTLAK SUNTRANUSORN
Degree	MASTER OF SCIENCE
Academic Year	2024
Thesis Advisor	Dr. Ruangsak Trakunphutthirak

Dissolved Oxygen (DO) is a key indicator of water quality that is essential for the survival of aquatic organisms. A decline in DO levels can cause stress or even death to these organisms. Therefore, monitoring and forecasting DO levels are crucial for water quality management in ecosystems and aquaculture operations. In recent years, artificial intelligence techniques, particularly Artificial Neural Networks (ANNs), have been increasingly applied due to their high efficiency in analyzing time series data. This research aims to develop predictive models for dissolved oxygen levels using a dataset of 1,603 daily DO measurements, evaluating five deep learning techniques. Recurrent Neural Networks (RNNs), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), Convolutional Neural Network combined with LSTM (CNN-LSTM), and Convolutional Neural Network combined with GRU (CNN-GRU). Various hyperparameters were tuned for optimal performance. The experimental results show that the CNN-GRU model achieved the highest performance, with an MSE of 0.0551, RMSE of 0.2347, and MAPE of 1.9895%. It was also found that models incorporating CNN components outperformed those without CNN. Additionally, GRU-based models yielded superior performance in both CNN and non-CNN groups. Future improvements in CNN-based models may be achieved by tuning CNN-specific hyperparameters, enabling the development of more effective and robust predictive models for dissolved oxygen forecasting.

Keyword : Dissolved Oxygen (DO), Neural Network, Deep Learning, Time-Series Data

กิตติกรรมประกาศ

สารนิพนธ์นี้เสร็จสมบูรณ์ด้วยดี อันเนื่องมาจากคำแนะนำและการสนับสนุนอย่างดีจาก อาจารย์ ดร.เรืองศักดิ์ ตระกูลพุทธิรักษ์ และเหล่าคณาจารย์หลักสูตรวิทยาการข้อมูล ภาควิชา วิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ ขอขอบพระคุณอาจารย์ทุกท่านเป็นอย่างสูง รวมถึงขอขอบคุณบุคคลากรท่านอื่นของคณะวิทยาศาสตร์และบัณฑิตวิทยาลัยที่สนับสนุนเรื่องเอกสารที่เกี่ยวข้องด้วยดี ขอขอบคุณเพื่อนร่วมรุ่นและรุ่นพี่ นิสิตปริญญาโท ที่ให้ความช่วยเหลือทุกเรื่อง ขอขอบคุณผู้บริหารและเพื่อนร่วมงานของบริษัทที่ข้าพเจ้าทำงานอยู่ที่สนับสนุนข้าพเจ้าตลอดมา และที่สำคัญยิ่ง ขอขอบคุณอย่างที่สุดสำหรับครอบครัวของข้าพเจ้าที่สนับสนุนและให้กำลังใจในทุกเรื่องอย่างดีที่สุดกับข้าพเจ้าเสมอมา ผู้วิจัยหวังว่างานวิจัยนี้จะเป็นประโยชน์กับผู้ที่ได้อ่าน หากมีข้อผิดพลาดประการใด ผู้วิจัยขออภัยมา ณ ที่นี้

เลิศลักษณ์ สุนทรานุสรณ์

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ	ช
สารบัญตาราง.....	ณ
สารบัญรูปภาพ	ญ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญของงานวิจัย	1
1.2 ความมุ่งหมายของงานวิจัย	3
1.3 ขอบเขตงานวิจัย.....	3
1.4 สมมติฐานของงานวิจัย	4
1.5 ประโยชน์ที่จะได้รับจากงานวิจัย	4
บทที่ 2 ทบทวนวรรณกรรม.....	5
2.1 วิธีวัดออกซิเจนละลายน้ำ (Methods of Measuring Dissolved Oxygen)	5
2.2 ทฤษฎีเกี่ยวกับ Artificial Neural Network (ANN)	6
2.3 งานวิจัยที่เกี่ยวข้อง	12
บทที่ 3 วิธีดำเนินการวิจัย.....	30
3.1 วางแผนการดำเนินงานวิจัย.....	30
3.2 ขั้นตอนการทำงานของแบบจำลอง	31
3.3 การคัดเลือกและเก็บรวบรวมข้อมูล (Data Selection and Data Collection)	32
3.4 การเตรียมข้อมูล (Pre-Processing)	34

3.5 การสร้างและปรับค่าพารามิเตอร์ของแบบจำลอง (Modeling and Fine-tuning Hyperparameters)	36
3.6 การประเมินผลแบบจำลอง (Model Evaluation)	37
บทที่ 4 ผลการดำเนินการวิจัย	39
4.1 แบบจำลอง RNNs (Recurrent Neural Networks)	39
4.2 แบบจำลอง LSTM (Long Short-Term Memory)	40
4.3 แบบจำลอง GRU (Gated Recurrent Unit)	41
4.4 แบบจำลอง CNN-LSTM (Convolutional Neural Network + LSTM)	43
4.5 แบบจำลอง CNN-GRU (Convolutional Neural Network + GRU)	44
บทที่ 5 สรุปผลการวิจัย อภิปรายผลการวิจัย และข้อเสนอแนะ	46
5.1 สรุปผลการวิจัย	46
5.2 อภิปรายผลการวิจัย	48
5.3 ข้อเสนอแนะ	49
บรรณานุกรม	51
ภาคผนวก	54
ประวัติผู้เขียน	60

สารบัญตาราง

	หน้า
ตาราง 1 แสดงผลลัพธ์จากเทคนิคโครงข่ายประสาทเทียม LSTM	13
ตาราง 2 ประสิทธิภาพของผลการพยากรณ์จากแบบจำลอง	15
ตาราง 3 พารามิเตอร์ที่ต่างกันของแต่ละเทคนิค	17
ตาราง 4 ประสิทธิภาพของผลการพยากรณ์จากข้อมูลทดสอบ	18
ตาราง 5 จำนวนพารามิเตอร์และเวลาในการฝึกของ LSTM และ GRU	18
ตาราง 6 การประยุกต์ใช้แบบจำลองในการพยากรณ์ปริมาณออกซิเจนละลายน้ำ (DO)	19
ตาราง 7 โครงสร้างแบบจำลองของน้ำเสียที่เข้าสู่ระบบ (influent) และตัวชี้วัดประสิทธิภาพ	20
ตาราง 8 โครงสร้างแบบจำลองของน้ำเสียที่ออกจากระบบ (effluent) และตัวชี้วัดประสิทธิภาพ	21
ตาราง 9 คุณลักษณะของแบบจำลองที่ใช้กับข้อมูล	23
ตาราง 10 ค่า MSE และ MAE ของแบบจำลอง ARIMA, LSTM NN และ GRU NN	26
ตาราง 11 สถิติผลการทดสอบของแบบจำลองการเรียนรู้ของเครื่อง	27
ตาราง 12 สรุปโดยย่อจากงานวิจัยที่เกี่ยวข้อง	28
ตาราง 13 แผนการดำเนินงานวิจัย	30
ตาราง 14 พารามิเตอร์ต่าง ๆ พร้อมหน่วยการวัด	32
ตาราง 15 การเปรียบเทียบประสิทธิภาพของแบบจำลอง RNNs	40
ตาราง 16 การเปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM	41
ตาราง 17 การเปรียบเทียบประสิทธิภาพของแบบจำลอง GRU	42
ตาราง 18 การเปรียบเทียบประสิทธิภาพของแบบจำลอง CNN-LSTM	43
ตาราง 19 การเปรียบเทียบประสิทธิภาพของแบบจำลอง CNN-GRU	44
ตาราง 20 การเปรียบเทียบประสิทธิภาพของแบบจำลองทั้ง 5 เทคนิค	47
ตาราง 21 แสดงเวลาในการเรียนรู้และค่าจาก Loss Function (MSE) ของแบบจำลอง RNNs	55

ตาราง 22 แสดงเวลาในการเรียนรู้และค่าจาก Loss Function (MSE) ของแบบจำลอง LSTM...	56
ตาราง 23 แสดงเวลาในการเรียนรู้และค่าจาก Loss Function (MSE) แบบจำลอง GRU	57
ตาราง 24 แสดงเวลาในการเรียนรู้และค่าจาก Loss Function (MSE) แบบจำลอง CNN-LSTM	58
ตาราง 25 แสดงเวลาในการเรียนรู้และค่าจาก Loss Function (MSE) แบบจำลอง CNN-GRU .	59



สารบัญรูปภาพ

หน้า

ภาพประกอบ 1 แสดงโครงสร้าง Artificial Neural Network แบบพื้นฐาน	7
ภาพประกอบ 2 แสดงโครงสร้างเพอร์เซปตรอน (Perceptron) แบบพื้นฐาน	7
ภาพประกอบ 3 แสดงโครงสร้างของ Recurrent Neural Networks (RNN) แบบพื้นฐาน	8
ภาพประกอบ 4 แสดงโครงสร้างภายในของ Long Short-Term Memory (LSTM)	9
ภาพประกอบ 5 แสดงโครงสร้างภายในของ Gated Recurrent Unit (GRU)	11
ภาพประกอบ 6 แสดงกรอบการพยากรณ์พื้นฐานของแบบจำลอง LSTM	15
ภาพประกอบ 7 แสดงขั้นตอนการทำงานของแบบจำลอง	31
ภาพประกอบ 8 แสดงกราฟค่าออกซิเจนละลายน้ำ (DO หรือ Dissolved Oxygen) ตามวันที่ ...	33
ภาพประกอบ 9 แสดงคำสั่งการสเกลข้อมูล	34
ภาพประกอบ 10 แสดงกราฟค่าออกซิเจนละลายน้ำที่ยังไม่ผ่านการแบ่งข้อมูลและการสเกล	35
ภาพประกอบ 11 แสดงกราฟค่าออกซิเจนละลายน้ำที่ผ่านการแบ่งข้อมูลและการสเกลแล้ว	35
ภาพประกอบ 12 แสดงกราฟเปรียบเทียบค่าจริงและค่าพยากรณ์ของแบบจำลอง CNN-GRU ..	48
ภาพประกอบ 13 แสดงกราฟค่าออกซิเจนละลายน้ำ (DO หรือ Dissolved Oxygen)	49
ภาพประกอบ 14 แสดงกราฟค่าอุณหภูมิ (Temperature)	49

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของงานวิจัย

ออกซิเจนละลายน้ำ (DO หรือ Dissolved Oxygen) เป็นตัวบ่งชี้สำคัญตัวหนึ่งของคุณภาพน้ำ (Water Quality) และสิ่งมีชีวิตในน้ำ (Aquatic Life) จำเป็นอย่างยิ่งที่ต้องใช้ออกซิเจนในการดำรงชีวิตอยู่ (Bulbul Ali และ Mishra, 2022) การลดลงของระดับออกซิเจนละลายน้ำจะทำให้สิ่งมีชีวิตที่อาศัยอยู่ในน้ำ ทั้งปลา จุลลินทรีย์ แบคทีเรีย สัตว์ไม่มีกระดูกสันหลัง อาจเกิดภาวะเครียดหรือเสียชีวิตได้ โดยออกซิเจนสามารถละลายน้ำได้หลายวิธี (Scientific, 2022) ดังนี้

1. ออกซิเจนจากบรรยากาศจะละลายและผสมเข้ากับผิวน้ำ (Atmospheric Diffusion)
2. สาหร่ายและพืชน้ำได้นำปฏิกิริยาออกซิเจนระหว่างการสังเคราะห์แสง (Photosynthesis)
3. น้ำไหลลงสู่แอ่งจากลำธาร แม่น้ำ และมหาสมุทร โดยทั่วไปน้ำทะเลมีออกซิเจนมากกว่าน้ำในแม่น้ำ เนื่องจากน้ำทะเลไหลเร็วซึ่งช่วยให้ออกซิเจนจากอากาศผสมกับเข้าน้ำ
4. การไหลออกของน้ำบาดาล

ในสภาวะแวดล้อมของน้ำ นอกจากออกซิเจนจะเป็นปัจจัยที่จำเป็นต่อกระบวนการหายใจของสัตว์ที่อาศัยในน้ำแล้ว ออกซิเจนยังมีผลกระทบกับกระบวนการชีวเคมีในระบบนิเวศน้ำอีกด้วย และยังมีปัจจัยอื่นที่มีผลต่อปริมาณออกซิเจนละลายน้ำ (Bulbul Ali และ Mishra, 2022) ดังนี้

1. ปัจจัยทางกายภาพ
 - 1.1 อุณหภูมิที่อุ่นขึ้นจะมีออกซิเจนละลายน้ำน้อยกว่าน้ำที่เย็นกว่า
 - 1.2 น้ำที่มีการเคลื่อนไหวที่มากขึ้น ทำให้การดูดซับออกซิเจนจากบรรยากาศของน้ำทำได้ดีขึ้น เช่น น้ำในแม่น้ำหรือลำธาร
 - 1.3 ระดับความสูงจากน้ำทะเลที่สูงขึ้นทำให้ความดันบรรยากาศลดลง ทำให้การกักเก็บออกซิเจนของน้ำมีความสามารถลดลง
2. ปัจจัยทางเคมี
 - 2.1 น้ำเค็มมีปริมาณออกซิเจนละลายน้ำน้อยกว่าน้ำจืด
 - 2.2 ค่าความเป็นกรด-ด่าง (pH) ที่สูงหรือต่ำเกินไป มีผลต่อออกซิเจนที่จะสามารถละลายเข้าสู่
3. ปัจจัยทางชีวภาพ

3.1 อัตราการหายใจของปลา พืช และจุลินทรีย์ในน้ำที่เพิ่มขึ้นจะลดระดับออกซิเจนละลายน้ำ

3.2 การสังเคราะห์แสงของสาหร่ายและพืชน้ำเป็นกระบวนการทำให้เกิดออกซิเจน ยังมีแสงมากอย่างในช่วงเวลากลางวัน จะทำให้ปริมาณออกซิเจนละลายน้ำเพิ่มขึ้น

3.3 การใช้ออกซิเจนย่อยสลายอินทรีย์สารของแบคทีเรีย ซึ่งทำให้ปริมาณออกซิเจนลดลง โดยเฉพาะในบริเวณที่มีธาตุอาหารสูง

ซึ่งปัจจัยทางชีวภาพเป็นส่วนสำคัญของการรักษาระบบนิเวศน้ำ สิ่งมีชีวิตในน้ำกับออกซิเจนต่างต้องพึ่งพาอาศัยกันและกัน ดังนั้นการทราบค่าออกซิเจนละลายน้ำจึงเป็นสิ่งที่สำคัญโดยมีวิธีการวัดค่าออกซิเจนละลายน้ำ (Methods of Measuring Dissolved Oxygen) หลายวิธี เช่น กระบวนการวิเคราะห์ทางเคมี การใช้อุปกรณ์ตรวจวัด (Sensor) ต่าง ๆ (Scientific, 2021) เป็นต้น ด้วยเหตุนี้ปัจจัยในการเลือกวิธีการวัดค่าออกซิเจนละลายน้ำมีหลายประการ เช่น ความแม่นยำที่ต้องการ ความเหมาะสมและความสะดวกในกระบวนการวัดกับสภาพแวดล้อมที่แตกต่างกัน ด้วยการเข้าใจและการเลือกใช้วิธีที่เหมาะสมนั้น มีผลในการพยากรณ์ค่าออกซิเจนละลายน้ำให้มีความแม่นยำที่สูงยิ่งขึ้น

การทราบค่าออกซิเจนละลายน้ำในปริมาณที่เหมาะสมมีส่วนช่วยให้ทำการบริหารและจัดการคุณภาพน้ำได้อย่างมีประสิทธิภาพ การพยากรณ์ค่าออกซิเจนละลายน้ำเป็นเรื่องที่ทำทนายเนื่องจากต้องพิจารณาหลากหลายปัจจัยที่ซับซ้อน

การศึกษาเกี่ยวกับการพยากรณ์ค่าออกซิเจนละลายน้ำนำไปสู่การพัฒนาระบบพยากรณ์ที่มีประสิทธิภาพและความแม่นยำสูง การนำเทคนิคโครงข่ายประสาทเทียมมาช่วยพยากรณ์ค่าออกซิเจนละลายน้ำเป็นอีกวิธีการที่มีศักยภาพสูง โดยสามารถนำข้อมูลจากหลากหลายแหล่งมาใช้ในการสร้างและฝึกฝนให้ได้เทคนิคที่มีประสิทธิภาพ

ประโยชน์ของการพัฒนาระบบพยากรณ์ค่าออกซิเจนละลายน้ำที่มีความแม่นยำนั้น อีกด้านหนึ่งคือช่วยเรื่องการตัดสินใจของผู้ที่มีส่วนเกี่ยวข้อง ยกตัวอย่างเช่น การวางแผนการใช้ทรัพยากรน้ำ การจัดการน้ำในระบบชลประทาน และการบริหารจัดการน้ำทิ้งจากโรงงานอุตสาหกรรมและครัวเรือน เป็นต้น การวิจัยนี้จึงเพิ่มความเข้าใจในเรื่องการจัดการออกซิเจนละลายน้ำซึ่งเป็นส่วนสำคัญของคุณภาพน้ำและการรักษาระบบนิเวศน้ำให้เกิดสมดุล ซึ่งเป็นส่วนสำคัญในการจัดการน้ำแบบยั่งยืนในระยะยาว

นอกจากนี้ การพยากรณ์ค่าออกซิเจนละลายน้ำสามารถใช้ให้เกิดประโยชน์ในหลายด้าน เช่น การแก้ไขและป้องกันปัญหาน้ำเสีย การรักษาสภาพแวดล้อมและระบบนิเวศน้ำ การ

ปรับปรุงคุณภาพน้ำสำหรับการบริโภค และการสนับสนุนการวิจัยและพัฒนาในด้านสิ่งแวดล้อม ดังนั้น การวิจัยเรื่องการพยากรณ์ค่าออกซิเจนละลายน้ำจึงเป็นเรื่องจำเป็นและสำคัญในยุคปัจจุบัน

1.2 ความมุ่งหมายของงานวิจัย

1. เพื่อศึกษาการสร้างแบบจำลองเพื่อการพยากรณ์ค่าออกซิเจนละลายน้ำ จากข้อมูลประเภทอนุกรมเวลา (Time-Series Data)
2. เพื่อสร้างแบบจำลอง RNN (Recurrent Neural Network) และเทคนิคที่พัฒนาขึ้นเพื่อแก้ปัญหาที่เกิดกับเทคนิคโครงข่ายประสาทเทียมแบบเวียนซ้ำ ได้แก่ เทคนิค LSTM (Long Short-Term Memory) และเทคนิค GRU (Gated Recurrent Unit) ร่วมกับการใช้เทคนิคของแบบจำลอง CNN (Convolutional Neural Network) ที่ช่วยดึงคุณลักษณะสำคัญออกมาจากข้อมูล
3. ปรับค่าพารามิเตอร์ (Fine-tuning Hyperparameters) เพื่อให้เทคนิคแต่ละเทคนิคที่มีประสิทธิภาพสูงสุด
4. เพื่อเทียบประสิทธิภาพจากการประเมินเทคนิคโครงข่ายประสาทเทียมแบบเวียนซ้ำ (RNN) และเทคนิคที่พัฒนาขึ้นอื่น ๆ

1.3 ขอบเขตงานวิจัย

1. ใช้ข้อมูลที่เป็นข้อมูลคุณภาพน้ำ โดยเป็นข้อมูล Public Dataset ที่ได้จากโครงการของ Bhatt (Bhawna Bhatt, 2019)
2. ข้อมูลคุณภาพน้ำนี้เก็บรวบรวมจากสถานีตรวจวัด 31 แห่ง ในรัฐจอร์เจีย ประเทศสหรัฐอเมริกา ตั้งแต่วันที่ 1 ตุลาคม ค.ศ. 2014 ถึง 18 กุมภาพันธ์ ค.ศ. 2019 วันละ 1 ชุด
3. เทคนิคที่ใช้ศึกษามีทั้งหมด 5 เทคนิค เป็นเทคนิคการเรียนรู้เชิงลึก เพื่อประมวลผลข้อมูลลำดับต่อเนื่อง (Sequential Data) ได้แก่ RNN, LSTM, GRU, CNN-LSTM และ CNN-GRU
4. เพื่อให้แบบจำลองทั้ง 5 เทคนิคมีประสิทธิภาพดีที่สุด โดยการปรับค่าพารามิเตอร์ต่าง ๆ (Hyperparameters)
5. ประเมินแบบจำลองเทคนิคการเรียนรู้เชิงลึก (Model Evaluation) จาก MSE, RMSE และ MAPE และนำผลประเมินมาเปรียบเทียบประสิทธิภาพ

1.4 สมมติฐานของงานวิจัย

แบบจำลองที่มีชั้นของ CNN (Convolutional Neural Network) คือ เทคนิค CNN-LSTM และ CNN-GRU มีประสิทธิภาพดีกว่า แบบจำลองที่ไม่มีชั้นของ CNN คือ เทคนิค RNN, LSTM และ GRU เพราะเป็นการผสมผสานคุณสมบัติของเทคนิค CNN ที่ช่วยดึงคุณลักษณะสำคัญออกมาจากข้อมูล กับ คุณสมบัติของเทคนิคที่ได้รับการพัฒนามาจากโครงข่ายประสาทเทียมแบบเวียนซ้ำเดิมคือ LSTM และ GRU (Li และคณะ, 2021) ทำให้การพยากรณ์ข้อมูลเชิงอนุกรมเวลามีประสิทธิภาพที่ดีขึ้น

1.5 ประโยชน์ที่จะได้รับจากงานวิจัย

1. สร้างแบบจำลองโดยใช้เทคนิค RNN, LSTM, GRU, CNN-LSTM และ CNN-GRU ได้ พร้อมทั้งสามารถประเมินประสิทธิภาพของแบบจำลอง
2. ทำให้ได้ความรู้และความเข้าใจในเทคนิคโครงข่ายประสาทเทียมแบบเวียนซ้ำแบบต่าง ๆ จากการพยากรณ์ค่าออกซิเจนละลายน้ำจากข้อมูลเชิงอนุกรมเวลา
3. การพยากรณ์ค่าออกซิเจนละลายน้ำด้วยการใช้เทคโนโลยีสร้างแบบจำลอง เพื่อช่วยให้สามารถวางแผนการบำรุงรักษาและตรวจสอบแหล่งน้ำได้
4. สามารถลดความถี่ในการวัดค่าออกซิเจนละลายน้ำด้วยวิธีที่ใช้เวลาและทรัพยากรมาก เช่น วิธีการตรวจวัดแบบเคมี เป็นต้น

บทที่ 2

ทบทวนวรรณกรรม

ในการวิจัยครั้งนี้ ผู้วิจัยได้ศึกษางานวิจัยและเอกสารที่เกี่ยวข้อง และนำเสนอตามหัวข้อต่อไปนี้

1. วิธีวัดออกซิเจนละลายน้ำ (Methods of Measuring Dissolved Oxygen)
2. ทฤษฎีเกี่ยวกับ Artificial Neural Network (ANN)
 - ทฤษฎีเกี่ยวกับ Recurrent Neural Networks (RNNs)
 - ทฤษฎีเกี่ยวกับ Long Short-Term Memory (LSTM)
 - ทฤษฎีเกี่ยวกับ Gated Recurrent Unit (GRU)
3. งานวิจัยที่เกี่ยวข้อง

2.1 วิธีวัดออกซิเจนละลายน้ำ (Methods of Measuring Dissolved Oxygen)

เป็นกระบวนการที่ใช้ในตรวจวัดปริมาณออกซิเจนละลายน้ำ มีวิธีหลัก ๆ ที่ใช้ในการวัดออกซิเจนละลายน้ำ (Fondriest Environmental, 2014) ดังนี้

1. วิธีการใช้อุปกรณ์ตรวจวัด (Sensor Method)

1.1 เครื่องวัดค่าออกซิเจนละลายน้ำแบบแสง (Optical DO Sensor) ใช้เทคโนโลยีการเรืองแสง (luminescence) ในการวัดค่าออกซิเจนละลายน้ำ เครื่องวัดมีหลักการทำงานโดยการเปลี่ยนแปลงการเรืองแสงเมื่อมีการสัมผัสกับออกซิเจน ข้อดีของวิธีนี้คือมีความแม่นยำสูงและไม่ต้องบำรุงรักษามาก

1.2 เครื่องวัดค่าออกซิเจนละลายน้ำแบบเคมีไฟฟ้า (Electrochemical DO Sensor) เครื่องวัดนี้มีความสะดวกและสามารถให้ผลลัพธ์ได้รวดเร็ว แต่เครื่องวัดต้องได้รับการดูแลรักษาและสอบเทียบอย่างสม่ำเสมอ

2. วิธีการแบบสี (Colorimetric Method) ความเข้มหรือจางของสีจะเป็นสัดส่วนกับความปริมาณของออกซิเจนละลายน้ำ

2.1 ครามอินดิโก (Indigo Carmine) วิธีนี้จะให้ผลเป็นสีฟ้า อาจมีความคลาดเคลื่อนจากธาตุเหล็กเฟอริก (Fe^{3+}), ธาตุเหล็กเฟอรัส (Fe^{2+}), ไนไตรต์ (NO_2^-) และโซเดียมไฮโดรซัลไฟต์ ($\text{Na}_2\text{S}_2\text{O}_4$) แต่ควรหลีกเลี่ยงการโดนแสงเนื่องจากทำให้เสื่อมสภาพ ช่วงเวลาในการประมวลผลอยู่ระหว่าง 30 วินาที - 2 นาที

2.2 โรดาซีน ดี (Rhodazine D) วิธีนี้จะให้ผลเป็นสีชมพู เหมาะกับความเข้มข้นของออกซิเจนละลายน้ำในระดับต่ำมาก ความขุ่นของตัวอย่างน้ำอาจส่งผลต่อความแม่นยำ ช่วงเวลาที่ต้องการวิเคราะห์ภายใน 30 วินาที

3. วิธีการไทเทรต (Titrimetric Method)

3.1 วิธี Winkler (Winkler Method) เป็นวิธีคลาสสิกและแม่นยำในการวัดออกซิเจนละลายน้ำ กระบวนการนี้ประกอบด้วยการเติมสารเคมีลงในน้ำเพื่อทำให้น้ำตกตะกอนจากสารที่มีออกซิเจน จากนั้นทำการไทเทรตสารตกตะกอนนั้นเพื่อหาค่าออกซิเจนในน้ำ วิธีนี้มีความแม่นยำสูง แต่ต้องใช้ความระมัดระวังและใช้เวลาในการทำงาน

3.2 วิธี Modified Winkler (Modified Winkler Method) ปัจจุบันมีหลายแบบ ถูกสร้างขึ้นเพื่อตอบสนองต่อปัญหาต่าง ๆ ซึ่งมีข้อจำกัดใหม่ คือ ต้องรู้ล่วงหน้าเกี่ยวกับข้อมูลของธาตุในตัวอย่างน้ำเพื่อเลือกใช้วิธีที่เหมาะสม

4. วิธีการใช้ปัญญาประดิษฐ์ (AI) เป็นเทคโนโลยีที่สามารถให้ค่าปริมาณออกซิเจนละลายน้ำจากข้อมูลอื่น ๆ ที่เกี่ยวข้องกับข้อมูลคุณภาพน้ำได้ และยังสามารถพยากรณ์ค่าปริมาณออกซิเจนละลายน้ำได้ล่วงหน้าจากข้อมูลในอดีต (Chen และคณะ, 2020) (Tung และ Yaseen, 2020)


2.2 ทฤษฎีเกี่ยวกับ Artificial Neural Network (ANN)

โครงข่ายประสาทเทียมมีการทำงานโดยได้รับแรงบันดาลใจจากระบบประสาทในสมองของมนุษย์ (Choi และคณะ, 2020) โดยโครงสร้างพื้นฐานประกอบด้วย เซลล์ประสาท (Neurons) และจุดประสานประสาท (Synapses) (Wikipedia, 2567) เป็นหน่วยที่ทำงานร่วมกันเป็น หน่วยที่รับข้อมูล ประมวลผลข้อมูล และส่งข้อมูลไปส่วนอื่น ๆ โดยการทำงานเชื่อมต่อกันเป็นโครงข่าย

โครงข่ายประสาทเทียมมีโครงสร้างพื้นฐานที่ประกอบด้วย นิวรอน (Neurons) หรือ โหนด (Nodes) หรือ เพอร์เซปตรอน (Perceptron) ที่มีการเชื่อมต่อกันหลายชั้น (Layers) ทำการร่วมกันประกอบด้วย 3 ส่วน (Choi และคณะ, 2020) ตามภาพประกอบ 1 ดังนี้


1. Input Layer (สีแดง): ชั้นอินพุตเป็นชั้นที่รับข้อมูลเข้ามา เช่น ค่าเชิงตัวเลข หรือภาพ และส่งข้อมูลต่อไปยังชั้นถัดไป โดยงานวิจัยนี้ส่งค่าเชิงตัวเลข
2. Hidden Layer(s) (สีน้ำเงิน): ชั้นซ่อนเป็นชั้นที่ทำการประมวลผลข้อมูล โดยการรับข้อมูลจากชั้นก่อนหน้าเป็นได้ทั้งชั้นอินพุตหรือชั้นซ่อน เนื่องจากชั้นซ่อนสามารถมีได้มากกว่า 1 ชั้น

และทำการส่งผลลัพธ์ที่ผ่านการคำนวณน้ำหนัก (Weights) และ ฟังก์ชันกระตุ้น (Activation Function) ต่อไปยังชั้นถัดไป



ภาพประกอบ 1 แสดงโครงสร้าง Artificial Neural Network แบบพื้นฐาน
ที่มา : [https://en.wikipedia.org/wiki/Neural_network_\(machine_learning\)](https://en.wikipedia.org/wiki/Neural_network_(machine_learning))

3. Output Layer (สีเขียว): ชั้นเอาต์พุตเป็นชั้นที่ส่งผลลัพธ์ออกมา โดยเป็นชั้นที่รับผลลัพธ์จากชั้นซ่อนชั้นสุดท้าย เช่น การพยากรณ์ค่าหรือการจำแนกประเภท



ภาพประกอบ 2 แสดงโครงสร้างเพอร์เซปตรอน (Perceptron) แบบพื้นฐาน
ที่มา : <https://weather4thai.kmitl.ac.th/ANN.php>


ดังแสดงในภาพประกอบ 2 โครงสร้างของเพอร์เซปตรอน (Perceptron) ในชั้น Hidden นั้น เพอร์เซปตรอนจะทำการรับข้อมูลเข้า (Inputs) และน้ำหนัก (Weights) เข้ามาหลายค่า ซึ่งจำนวนน้ำหนักจะเท่ากับจำนวนข้อมูลเข้า และข้อมูลเข้าแต่ละตัวจะทำการคูณกับค่าน้ำหนักแล้วนำมารวมกัน จากนั้นจึงนำมารวมกับค่าไบแอส (biases) ข้อมูลเข้าที่ผ่านการคำนวณนี้แล้ว จะส่งเข้าไปยังส่วนของฟังก์ชันกระตุ้น (Activation Function) ดังสมการ 2.1

$$y = f(w_1x_1 + w_2x_2 + \dots + w_nx_n + b) \quad (2.1)$$

ตัวอย่าง ฟังก์ชันแอคติเวชันที่ถูกนำมาใช้กับข้อมูลเชิงอนุกรมเวลา เช่น Sigmoid, Tanh เป็นต้น (Fu และคณะ, 2016) (Wang และคณะ, 2017) (Ye และคณะ, 2019) (Li และคณะ, 2021)

2.2.1 ทฤษฎี Recurrent Neural Networks (RNNs)

RNNs เป็นเทคนิคที่ออกแบบมาเพื่อประมวลผลข้อมูลตามลำดับต่อเนื่อง (Sequential Data) หรือข้อมูลประเภทอนุกรมเวลา (Time-Series Data) และเพื่อจัดการกับข้อมูลเข้า (Input) ที่ความยาวไม่คงที่ได้ จากภาพประกอบ 3(1) นั้น เป็นโครงสร้างแบบซ่อนของ RNN โดยการวนลูป (Loop) และภาพประกอบ 3(2) เป็นโครงสร้างแบบคลี่ออกของ RNN แสดงให้เห็นว่า ข้อมูลที่เข้าสู่สถานะ Hidden ในช่วงเวลาปัจจุบันนั้นเป็นผลลัพธ์จากทั้งข้อมูลเข้าในช่วงเวลาปัจจุบันและผลลัพธ์จากชั้น Hidden ของช่วงเวลาก่อนหน้า (Li และคณะ, 2021)



(1) แบบซ่อนของ RNN

(2) แบบคลี่ออกของ RNN


ภาพประกอบ 3 แสดงโครงสร้างของ Recurrent Neural Networks (RNN) แบบพื้นฐาน

ที่มา : (Wikipedia, 2024b)

งานประเภทต่าง ๆ ที่เหมาะกับ RNNs เช่น การจดจำเสียงพูด (Speech) การประมวลผลข้อความ (Processing Text) และการพยากรณ์ข้อมูลเชิงอนุกรมเวลา (Wikipedia, 2024b) ซึ่งข้อมูลคุณภาพน้ำที่ประกอบด้วยค่าต่าง ๆ หนึ่งในนั้นคือค่าออกซิเจนละลายน้ำก็เป็นข้อมูลเชิงอนุกรมเวลาเช่นกัน อย่างไรก็ตามเทคนิค RNN ได้ถูกพัฒนาเพื่อแก้ไขข้อจำกัดที่สำคัญในขั้นตอนฝึกการเรียนรู้ (Train) ของแบบจำลองสำหรับข้อมูลลำดับเวลาที่ยาวเกินไป (Ye และคณะ, 2019) (Li และคณะ, 2021)

2.2.2 ทฤษฎี Long Short-Term Memory (LSTM)

LSTM เป็นเทคนิคที่ถูกพัฒนาขึ้นและนำเสนอในปี ค.ศ. 1997 โดย Hochreite และ Jurgen Schmidhuber (Wang และคณะ, 2017) (Ye และคณะ, 2019) เพื่อปรับปรุงข้อจำกัดที่เกิดขึ้นในขั้นตอนการฝึกการเรียนรู้ (Training) ของเทคนิค RNNs คือ การหายไปของเกรเดียนต์ (Gradient Vanishing) และการระเบิดของเกรเดียนต์ (Gradient Explosion) ของแบบจำลอง ด้วยวิธีถอยกลับ (back-propagation) เพื่อหาค่าพารามิเตอร์ (Wikipedia, 2024a) ได้แก่ น้ำหนัก (Weights) และไบแอส (Biases) เพื่อนำข้อผิดพลาดที่เกิดขึ้นให้แบบจำลองเรียนรู้ (Fu และคณะ, 2016) (Wang และคณะ, 2017) (Ye และคณะ, 2019) เพื่อลดค่าฟังก์ชันความสูญเสีย (Loss Function) ที่เทียบผลลัพธ์ที่ได้จากการพยากรณ์กับค่าจริง



ภาพประกอบ 4 แสดงโครงสร้างภายในของ Long Short-Term Memory (LSTM)

ที่มา : (Wikipedia, 2024b)

จากภาพประกอบ 4 โดย LSTM มีโครงสร้างหลัก 2 ส่วน (Kala, 2024) ดังนี้

1. สถานะเซลล์ (cell state) เป็นเส้นทางหลักที่ข้อมูลไหลผ่านอย่างต่อเนื่องโดยไม่ถูกแก้ไข และสามารถเพิ่มหรือลบข้อมูลออกได้
2. ประตู (gates) เป็นตัวควบคุมการไหลของข้อมูล มีหน้าที่ตัดสินใจว่าจะลบหรือเก็บข้อมูลในแต่ละช่วงเวลา ซึ่งทำให้ LSTM จัดการกับข้อมูลที่สำคัญและไม่สำคัญได้อย่างมีประสิทธิภาพ โดยประตูประกอบด้วย 3 ประตูหลัก ได้แก่

2.1 Forget Gate เป็นประตูที่ตัดสินใจว่าจะลบข้อมูลใดในสถานะเซลล์ออกไป โดยดูข้อมูลจากสถานะเซลล์ปัจจุบันและข้อมูลใหม่ที่เข้ามา ค่านี้จะถูกคำนวณผ่านชั้นซิกมอยด์ (sigmoid layer) ที่ให้ค่าระหว่าง 0 ถึง 1 โดย 0 คือ การลบข้อมูลทั้งหมด และ 1 คือ การเก็บข้อมูลทั้งหมด

2.2 Input Gate เป็นประตูที่เลือกข้อมูลใหม่ที่จะเพิ่มเข้าไปในสถานะเซลล์ โดยคำนวณผ่านชั้นซิกมอยด์และชั้น Tanh

2.3 Output Gate เป็นประตูที่ตัดสินใจว่าจะส่งข้อมูลใดจากสถานะเซลล์เพื่อใช้คำนวณผลลัพธ์ผ่านชั้น Tanh เพื่อปรับค่าสถานะเซลล์ให้มีความระหว่าง -1 ถึง 1 จากนั้นคูณด้วยผลลัพธ์จาก Output Gate


ข้อมูลในสถานะเซลล์จะไหลผ่านโครงข่ายตลอดเวลา โดยจะถูกปรับแต่งไปตามข้อมูลใหม่ที่เข้ามาในแต่ละช่วงเวลา ทำให้ LSTM สามารถเรียนรู้และประมวลผลข้อมูลที่เป็นลำดับต่อเนื่อง (Sequential Data) และมีความสัมพันธ์ในระยะยาวได้อย่างมีประสิทธิภาพมากกว่า RNN ปกติ

2.2.3 ทฤษฎีเกี่ยวกับ Gated Recurrent Unit (GRU)

GRU เป็นหนึ่งในรูปแบบของ RNN ที่ออกแบบมาเพื่อแก้ปัญหการสูญเสียความจำในลำดับข้อมูลยาว (Long-term Dependencies) เช่นเดียวกับ LSTM แต่มีโครงสร้างที่เรียบง่ายกว่า จากภาพประกอบ 5 โดย GRU มีโครงสร้าง gate หลักประกอบด้วย 2 ส่วน (Dey และ Salem, 2017) ดังนี้

1. Update Gate เป็นประตูที่ควบคุมข้อมูลในปัจจุบันว่าควรถูกบันทึกไว้หรือแทนที่ข้อมูลเก่า

2. Reset Gate เป็นประตูที่ตัดสินใจว่าข้อมูลเก่าจากสถานะก่อนหน้าควรถูกลบหรือยังคงถูกใช้ในการคำนวณสถานะใหม่ โดยกำหนดน้ำหนักว่าข้อมูลส่วนใดควรถูกลบออกหรือเก็บไว้สำหรับการใช้งานต่อไป



ภาพประกอบ 5 แสดงโครงสร้างภายในของ Gated Recurrent Unit (GRU)
ที่มา : (Wikipedia, 2024b)

คุณสมบัติเด่นของ GRU

1. โครงสร้างที่เรียบง่ายกว่า LSTM: ใช้ gate เพียง 2 ตัว (Update Gate และ Reset Gate) แทนที่จะเป็น 3 ตัวเหมือน LSTM (Forget Gate, Input Gate และ Output Gate) ซึ่งช่วยลดจำนวนพารามิเตอร์ ทำให้คำนวณได้เร็วขึ้น
2. ลดปัญหา Vanishing Gradient: GRU ช่วยรักษาการไหลของข้อมูลย้อนหลังในลำดับข้อมูลยาว ทำให้เรียนรู้ความสัมพันธ์ระยะยาวได้ดีขึ้น
3. ประสิทธิภาพสูง: ในงานวิจัย (Fu และคณะ, 2016) (Dey และ Salem, 2017) GRU แสดงประสิทธิภาพที่ใกล้เคียงกับ LSTM หรือดีกว่าในบางกรณีโดยเฉพาะงานที่ต้องการการคำนวณที่รวดเร็ว เช่น การพยากรณ์ลำดับข้อมูล (Sequence prediction)

2.2.4 ทฤษฎีเกี่ยวกับ CNN-LSTM (Convolutional Neural Network + LSTM)

CNN (Convolutional Neural Network) เป็นเทคนิคการเรียนรู้เชิงลึก (Deep Learning) โครงข่ายประสาทเทียมที่ใช้ชั้น Convolutional เพื่อดึงฟีเจอร์ที่สำคัญจากข้อมูลต้นฉบับ โดยเฉพาะ ลักษณะเฉพาะเชิงพื้นที่ (Spatial Features) ซึ่งเดิมที่ถูกพัฒนาเพื่อวิเคราะห์ข้อมูลภาพ

(Pan และคณะ, 2024) เมื่อนำเทคนิค CNN มาสกัดข้อมูลก่อนส่งข้อมูลไปยังชั้น LSTM ทำให้เทคนิค CNN-LSTM มีโครงสร้างดังนี้

1. Input Layer เป็นชั้นที่ทำหน้าที่ระบุรูปร่างของข้อมูลนำเข้า (Input Shape)
2. CNN Layer ประกอบด้วย 2 ชั้น ได้แก่
 - 2.1 Conv1D: มีหน้าที่ดึงคุณลักษณะ (Features) จากข้อมูลลำดับเวลา
 - 2.2 MaxPooling1D: มีหน้าที่ลดขนาดข้อมูล
3. LSTM Layer ทำหน้าที่เรียนรู้ลำดับข้อมูล (Sequence Learning) และส่งออกข้อมูลเฉพาะค่าล่าสุด
4. Output Layer (Dense) ชั้นเอาต์พุตเป็นชั้นที่ทำหน้าที่ทำนายค่าผลลัพธ์

คุณสมบัติเด่นของ CNN-LSTM (Pan และคณะ, 2024)

1. CNN ทำหน้าที่สกัดฟีเจอร์ที่สำคัญจากข้อมูล และ LSTM ทำหน้าที่เรียนรู้ความสัมพันธ์ในลำดับเวลา เพื่อจัดการข้อมูลที่มีความซับซ้อน ช่วยเพิ่มความแม่นยำและความสามารถในการพยากรณ์แบบไดนามิก
2. โครงสร้างของ CNN-LSTM เหมาะกับข้อมูลที่มีหลายฟีเจอร์ เนื่องจากแบบจำลองมีความสามารถในการลดมิติและเลือกข้อมูลที่สำคัญโดยอัตโนมัติ
3. ลดปัญหา Overfitting เนื่องจากเทคนิค CNN ทำหน้าที่เรียนรู้ลักษณะเฉพาะและตัดข้อมูลส่วนที่ไม่สำคัญหรือลด Noise ออกทำให้มิติของข้อมูลนำเข้าลดลงก่อนส่งข้อมูลเข้าชั้นของ LSTM ทำให้ชั้น LSTM ไม่ต้องรับข้อมูลดิบที่มีขนาดใหญ่ทั้งหมด

2.3 งานวิจัยที่เกี่ยวข้อง

2.3.1 งานวิจัยเรื่อง Water Quality Prediction Method Based on LSTM Neural Network (Wang และคณะ, 2017)

งานวิจัยนี้ศึกษาการพยากรณ์ค่าคุณภาพน้ำเพื่อการจัดการทรัพยากรน้ำเชิงป้องกัน โดยใช้ค่าของข้อมูลตัวชี้วัดคุณภาพน้ำ 2 ตัว คือ ออกซิเจนละลายน้ำ (DO) และฟอสฟอรัสรวม (TP หรือ Total Phosphorus) จากทะเลสาบไท่หู ประเทศสาธารณรัฐประชาชนจีน เป็นข้อมูลรายเดือนจำนวน 657 รายการ ระหว่าง มกราคม ค.ศ. 2000 ถึง ธันวาคม ค.ศ. 2006 เป็นข้อมูลเชิงอนุกรมเวลา และได้ทำการแบ่งข้อมูลเป็นสัดส่วน 9:1 สำหรับการฝึกการเรียนรู้และการทดสอบ

ตาราง 1 แสดงผลลัพธ์จากเทคนิคโครงข่ายประสาทเทียม LSTM

d	Hiddnum	epoch	DO		TP	
			RMSE	Max Error	RMSE	Max Error
3	10	10	0.066	0.160	0.043	0.116
	10	20	0.061	0.156	0.048	0.155
	13	25	0.058	0.151	0.042	0.118
	15	20	0.051	0.138	0.041	0.103
	15	25	0.102	0.215	0.054	0.188
	17	30	0.060	0.225	0.043	0.094
4	10	20	0.053	0.152	0.044	0.118
	13	25	0.054	0.162	0.047	0.135
	15	20	0.049	0.127	0.042	0.130
	15	25	0.050	0.181	0.046	0.108
	17	30	0.054	0.153	0.046	0.097
5	10	20	0.057	0.198	0.043	0.112
	13	25	0.061	0.196	0.041	0.121
	15	20	0.053	0.143	0.042	0.103
	15	25	0.046	0.116	0.047	0.125
	17	30	0.048	0.127	0.043	0.124

ที่มา: (Wang และคณะ, 2017)

งานวิจัยนี้ใช้เทคนิคโครงข่ายประสาทเทียม LSTM บนเฟรมเวิร์ก Keras มีการทดลองปรับค่าพารามิเตอร์หลายครั้ง โดยค่าที่ปรับมีดังนี้

1. Time Steps (d): เป็นจำนวนขั้นเวลาสำหรับข้อมูลในอดีต
2. Hidden nodes (Hiddnum): เป็นจำนวนของนิวรอน (Neurons) ของชั้นซ่อน
3. Epochs: จำนวนรอบการฝึก

แบบจำลองใช้ค่า RMSE ในการวัดประสิทธิภาพ โดยผลลัพธ์ที่แสดงในตาราง 1 พบว่า

- ค่าปริมาณออกซิเจนละลายน้ำ (DO) ได้ค่า RMSE ต่ำที่สุดคือ Time step = 5, Hiddnum = 15 และ Epoch = 25


- ค่าฟอสฟอรัสรวม (TP) ได้ค่า RMSE ต่ำที่สุดคือ Time step = 3, Hiddnum = 15 และ Epoch = 20

และทำการเปรียบเทียบผลลัพธ์ด้วยค่า RMSE (Root Mean Square Error) กับเทคนิคอีก 2 แบบ คือ Back Propagation Neural Network (BP NN) และ Online Sequential Extreme Learning Machine (OS-ELM) ผลลัพธ์ที่ได้คือ LSTM ให้ผลลัพธ์ที่แม่นยำกว่าทั้ง 2 เทคนิคในทุกเงื่อนไข ทั้งในกรณีที่ข้อมูลมีความผันผวนมากและน้อย

2.3.2 งานวิจัยเรื่อง River Water Quality Parameters Prediction Method Based on LSTM-RNN Model (Ye และคณะ, 2019)

งานวิจัยนี้ศึกษาการพยากรณ์ค่าคุณภาพน้ำในแม่น้ำเพื่อประเมินระดับมลพิษสำหรับการป้องกันมลพิษและปกป้องแหล่งน้ำ โดยแก้ปัญหาข้อผิดพลาดในการพยากรณ์ของแบบจำลอง GM (Grey Model) และ RNN โดยใช้ข้อมูลรายวันจากสถานีตรวจสอบคุณภาพน้ำจากแม่น้ำในมณฑลเหอหนาน ประเทศสาธารณรัฐประชาชนจีน ระหว่าง มกราคม ค.ศ. 2017 ถึง พฤษภาคม ค.ศ. 2018 เป็นข้อมูลเชิงอนุกรมเวลา ข้อมูลที่วัดได้จากตัวอย่างน้ำมีหลายตัว โดยมุ่งทำการศึกษาข้อมูลค่า COD (Chemical Oxygen Demand) จากค่าดัชนีโพแทสเซียมเปอร์แมงกาเนต (Potassium Permanganate) (Kosseva, 2013) มีการแบ่งข้อมูลจำนวน 460 ชุด สำหรับการฝึก (Training) และจำนวน 25 ชุด สำหรับการทดสอบ (Test) ใช้กับเทคนิคโครงข่ายประสาทเทียม LSTM-RNN เปรียบเทียบกับเทคนิค GM และ RNN

ข้อมูลค่า COD ที่วัดได้เป็นข้อมูลเข้า (Input) ในขั้นอินพุต โดยทำการแบ่งข้อมูลสำหรับฝึกและทดสอบ แล้วทำให้อยู่ในรูปแบบมาตรฐาน (Data Standardization) ก่อนส่งข้อมูลไปขึ้นช้อนซึ่งเป็นเทคนิค LSTM-RNN มีการประมวลผลผ่านหลายชั้น แต่ละชั้นจะจำค่าของพารามิเตอร์ก่อนหน้าเพื่อใช้ในการพยากรณ์ค่าถัดไป หลังจากผ่านการประมวลผลจากชั้นช้อน LSTM แล้ว จะได้ค่าพยากรณ์ COD และนำค่านั้นไปใช้ในการตรวจสอบกับค่าในชุดข้อมูลทดสอบ หากค่าพยากรณ์ COD ที่ได้ไม่ตรงกับค่าที่ทฤษฎีคาดการณ์ไว้ จะมีการปรับแต่งแบบจำลองให้แม่นยำขึ้นโดยการคำนวณหาข้อผิดพลาด (Loss calculation) จาก BPTT (Backpropagation Through Time) กระบวนการเหล่านี้จะพยากรณ์ค่าอย่างต่อเนื่อง (Iterative prediction) แล้วจะทำการแปลงข้อมูลกลับ (Data De-standardization) ให้อยู่ในรูปแบบที่ใช้งานได้ ตามภาพประกอบ 6



ภาพประกอบ 6 แสดงกรอบการพยากรณ์พื้นฐานของแบบจำลอง LSTM
ที่มา : (Ye และคณะ, 2019)

โดยการแปลงข้อมูลให้อยู่ในรูปแบบมาตรฐาน (Data Standardization) จะทำการปรับค่า COD ให้ข้อมูลอยู่ในช่วง -1 ถึง 1 เพื่อนำมาใช้งานกับฟังก์ชันกระตุ้น (Activation Function) ซึ่งในงานวิจัยนี้ใช้ฟังก์ชันแอคติเวชัน คือ Sigmoid, Tanh

ตาราง 2 ประสิทธิภาพของผลการพยากรณ์จากแบบจำลอง

Model	RMSE	MAPE
GM model	3.089	2.278
RNN model	3.758	2.159
LSTM-RNN model	1.174	0.594

ที่มา: (Ye และคณะ, 2019)

ใช้ค่า RMSE และ MAPE ในการวัดประสิทธิภาพของแบบจำลองทั้ง 3 เทคนิค ผลลัพธ์จากตาราง 2 แสดงให้เห็นว่า เทคนิค LSTM-RNN มีความแม่นยำสูงกว่าเทคนิค RNN และ GM โดยมีค่า RMSE และ MAPE ต่ำที่สุดอย่างชัดเจน ซึ่งบ่งบอกได้ว่าเทคนิค LSTM-RNN นั้นมีประสิทธิภาพในการพยากรณ์คุณภาพน้ำ

2.3.3 งานวิจัยเรื่อง A Review of the Artificial Neural Network Models for Water Quality Prediction (Chen และคณะ, 2020)

งานวิจัยนี้มีเป้าหมายเพื่อทบทวนการใช้ Artificial Neural Networks (ANNs) ในการพยากรณ์คุณภาพน้ำ เน้นถึงความสามารถของแบบจำลอง ANNs ในการจัดการข้อมูลที่มีความซับซ้อนและไม่เป็นเชิงเส้น (Nonlinear) รวมถึงสำรวจโครงสร้างพื้นฐานต่าง ๆ เช่น Feedforward, Recurrent และ Hybrid เพื่อพัฒนาวิธีการพยากรณ์ที่มีประสิทธิภาพมากขึ้นสำหรับการจัดการคุณภาพน้ำในอนาคต โดยรวบรวมเอกสารงานวิจัยเกี่ยวกับ ANNs ในการพยากรณ์คุณภาพน้ำจากปี ค.ศ. 2008 ถึง ค.ศ. 2019 เน้นแหล่งข้อมูลจากวารสารที่มีชื่อเสียงในด้านสิ่งแวดล้อมและวิศวกรรมทรัพยากรน้ำ

สำรวจตัวแปรที่เกี่ยวข้องกับคุณภาพน้ำ 23 ชนิด ตัวอย่างค่าพารามิเตอร์ที่สำคัญ เช่น ค่าปริมาณออกซิเจนละลายน้ำ (DO), ค่าความต้องการออกซิเจนทางชีวเคมี (BOD), ค่าความต้องการออกซิเจนทางเคมี (COD) และ ค่าความเป็นกรด-ด่าง (pH)

บริบทหรือสภาพแวดล้อมที่การวิจัยถูกออกแบบหรือดำเนินการ เช่น แม่น้ำ (River), ทะเลสาบ (Lake), อ่างเก็บน้ำ (Reservoir), โรงบำบัดน้ำเสีย (WWTP: Wastewater Treatment Plant), บ่อน้ำ (Ponds) เป็นต้น

RNN และ LSTM ต้องการข้อมูลจำนวนมากเมื่อเทียบกับแบบจำลอง Feedforward เพื่อให้สามารถเรียนรู้ความสัมพันธ์เชิงเวลาได้อย่างมีประสิทธิภาพ โดยขนาดข้อมูลที่ใช้ในวิจัยนั้น

- RNN: ตั้งแต่ 61 ถึง 23,268 ตัวอย่าง โดยเฉลี่ยประมาณ 1,000 ตัวอย่างขึ้นไป
- LSTM: ตั้งแต่ 710 ถึง 23,268 ตัวอย่าง

ส่วนใหญ่แบ่งข้อมูลเป็น ชุดฝึก (Training) และ ชุดทดสอบ (Testing) โดยชุดฝึกเป็น 70% ถึง 90% ของข้อมูลทั้งหมด ข้อมูลสำหรับ RNN และ LSTM มักมีการเก็บเชิงอนุกรมเวลา เช่น ทุก 5 นาที, รายชั่วโมง, รายครึ่งวัน, หรือรายเดือน และมักเจอปัญหาเกี่ยวกับข้อมูลที่ขาดหายหรือมีสัดส่วนข้อมูลน้อยในช่วงเวลาสำคัญ เช่น ค่าผิดปกติหรือค่าพีค (Peaks) ซึ่งต้องทำการเตรียมข้อมูลล่วงหน้า เช่น การเติมค่าที่ขาดหายด้วยวิธีการ Interpolation หรือ Normalization

2.3.4 งานวิจัยเรื่อง Prediction of dissolved oxygen in a fishery pond based on gated recurrent unit (GRU) (Li และคณะ, 2021)

งานวิจัยนี้มีเป้าหมายเพื่อพัฒนาและเปรียบเทียบเทคนิค RNN, LSTM และ GRU ในการพยากรณ์ปริมาณออกซิเจนละลายน้ำ (DO) ในบ่อเลี้ยงสัตว์น้ำ คือ ปูขน (hairy crab) ในเมือง Yixing มณฑลเจียงซู ประเทศสาธารณรัฐประชาชนจีน โดยเก็บข้อมูล ระหว่าง พฤษภาคม ถึง กรกฎาคม ค.ศ. 2018 ข้อมูลที่วัดได้จากตัวอย่างน้ำมีหลายตัว โดยมุ่งทำการศึกษาข้อมูลค่า DO มีการแบ่งข้อมูลจำนวน 5,040 ชุด (35 วัน) สำหรับการฝึก (Training) และจำนวน 150 ชุด (1 วัน) สำหรับการทดสอบ (Test)

ข้อมูลค่าตัวแปรสิ่งแวดล้อม คือ pH, ความขุ่น (turbidity), อุณหภูมิ (temperature) และ แอมโมเนีย-ไนโตรเจน (NH) เป็นข้อมูลเข้า (Input) ในชั้นอินพุต มีการทำความสะอาดข้อมูลโดยการแทนค่าผิดปกติด้วยค่ามัธยฐานของข้อมูลใกล้เคียง (Median) และวิเคราะห์การกระจายตัวของข้อมูล และแบ่งข้อมูลสำหรับฝึกและทดสอบ โดยการฝึกการเรียนรู้ของแต่ละเทคนิคมีค่าพารามิเตอร์ที่เหมือนกัน คือ Epoch = 6000, Lag time = 2 ชั่วโมง และ Forecast horizon = 1 วัน และมีค่าพารามิเตอร์ที่ต่างกันดังตาราง 3

ตาราง 3 พารามิเตอร์ที่แตกต่างกันของแต่ละเทคนิค

Model	Learning rate	Hidden layers	Optimizer
RNN	0.015	30	Adam
LSTM	0.01	30	RMSprop
GRU	0.01	25	RMSprop

ที่มา: (Li และคณะ, 2021)

ใช้ค่า MAE, MSE, MAPE และ R^2 ในการวัดประสิทธิภาพของแบบจำลองทั้ง 3 เทคนิค ผลลัพธ์จากตาราง 4 แสดงให้เห็นว่าเทคนิค LSTM และ GRU มีค่าประสิทธิภาพที่ดีกว่า RNN ที่ใกล้เคียงกัน

ตาราง 4 ประสิทธิภาพของผลการพยากรณ์จากข้อมูลทดสอบ

Model	MAE (mg/L)	MSE	MAPE	R ²
RNN	1.27	2.672	0.258	0.721
LSTM	0.407	0.294	0.059	0.970
GRU	0.450	0.411	0.054	0.991

ที่มา: (Li และคณะ, 2021)

จึงทำการนำการใช้ทรัพยากรของเทคนิค LSTM และ GRU มาเปรียบเทียบ จากตาราง 5 แสดงให้เห็นว่าเทคนิค GRU เหมาะสมที่สุดสำหรับการใช้งานจริงในบ่อเลี้ยงสัตว์น้ำ เนื่องจากประสิทธิภาพที่ดีและความต้องการทรัพยากรที่ต่ำกว่าแบบจำลองอื่น ๆ

ตาราง 5 จำนวนพารามิเตอร์และเวลาในการฝึกของ LSTM และ GRU

Model	Number of parameters	Training time (min)
LSTM	4591	17.9
GRU	2501	15.6

ที่มา: (Li และคณะ, 2021)

2.3.5 งานวิจัยเรื่อง A review of the application of machine learning in water quality evaluation (Zhu และคณะ, 2022)

งานวิจัยนี้มุ่งเน้นศึกษาการใช้เทคโนโลยีการเรียนรู้ของเครื่อง (Machine Learning) ในการประเมินคุณภาพน้ำในสภาพแวดล้อมต่าง ๆ รวมถึงน้ำผิวดิน น้ำดื่ม น้ำเสีย และน้ำทะเล โดยอ้างอิงข้อมูลจากงานวิจัยอื่น ๆ ครอบคลุมช่วงระหว่าง ปี ค.ศ. 2000 ถึง ค.ศ. 2020 โดยชี้ให้เห็นถึงประโยชน์ ข้อจำกัด และการประยุกต์ใช้งาน เพื่อปรับปรุงการจัดการน้ำและการควบคุมมลพิษ ข้อมูลคุณภาพน้ำที่ถูกนำมาประยุกต์ใช้กับ Machine Learning ขึ้นอยู่กับประเภทน้ำ เช่น ค่าปริมาณออกซิเจนละลายน้ำ (DO), ค่าความเป็นกรด-ด่าง (pH), อุณหภูมิ, ค่าความต้องการออกซิเจนทางชีวเคมี (BOD) และ ค่าความต้องการออกซิเจนทางเคมี (COD)

ข้อมูลเหล่านี้มาจากหลายวิธี เช่น เซนเซอร์ ระบบตรวจวัดระยะไกล หรือ ฐานข้อมูลที่มีอยู่เดิม โดยแบบจำลองที่ใช้ในงานวิจัยมีหลายประเภท ตัวอย่างเช่น Decision Trees (DT), Support

Vector Machines (SVM), Neural Networks (NN) และผลลัพธ์ที่ได้พบว่าการเรียนรู้ของเครื่องสามารถช่วยเพิ่มความแม่นยำและความเร็วในการพยากรณ์คุณภาพน้ำ อีกทั้งยังลดต้นทุนการบำบัดน้ำเสีย และตรวจจับมลพิษในน้ำทะเล

ตาราง 6 การประยุกต์ใช้แบบจำลองในการพยากรณ์ปริมาณออกซิเจนละลายน้ำ (DO)

Algorithms	Sample size	Evaluation results
BWNN, ANN, ARIMA, BANN	370	BWNN > BANN > ANN > ARIMA
LSTM	236	The model performed well at 74% of sites

ที่มา: (Zhu และคณะ, 2022)

จากงานวิจัยนี้มีการประยุกต์ใช้แบบจำลองการเรียนรู้การพยากรณ์และพารามิเตอร์เข้าคือ ค่าปริมาณออกซิเจนละลายน้ำ (DO) และเป็นข้อมูลประเภทอนุกรมเวลา (Time Series) ตามตาราง 6

2.3.6 งานวิจัยเรื่อง Data-Based Modelling of Chemical Oxygen Demand for Industrial Wastewater Treatment (Pörhö และคณะ, 2023)

งานวิจัยนี้มีเป้าหมายเพื่อพัฒนาแบบจำลองที่สามารถพยากรณ์ค่าความต้องการออกซิเจนทางเคมี Chemical Oxygen Demand (COD) ทั้งในน้ำเสียที่เข้าระบบ (influent) และน้ำเสียที่ออกจากระบบบำบัด (effluent) ในโรงงานอุตสาหกรรมกระดาษ ประเทศฟินแลนด์ โดยใช้ข้อมูลออนไลน์จากระบบการบำบัดน้ำเสีย จุดมุ่งหมายเพื่อพัฒนา soft sensor สำหรับเฝ้าระวังและเพิ่มประสิทธิภาพของระบบบำบัดน้ำเสียในแบบเรียลไทม์ ใช้ข้อมูล 3 ชุด ข้อมูลถูกเก็บทุก 1 นาที และผ่านการทำความสะอาด เช่น การแทนค่า NaN ด้วยค่า interpolated และการกำจัด outliers มีการบันทึกค่าที่สำคัญ เช่น COD, pH, อุณหภูมิ และอัตราการไหลของน้ำ รายละเอียดมีดังนี้

- ชุดข้อมูลที่ 1: ครอบคลุมเวลา 1 ปี ใช้สำหรับพัฒนาแบบจำลองน้ำเสียที่ออกจากระบบบำบัด (effluent)
- ชุดข้อมูลที่ 2: ครอบคลุมเวลา 4.5 เดือน ใช้สำหรับพัฒนาและตรวจสอบแบบจำลอง

- ชุดข้อมูลที่ 3: ครอบคลุมเวลา 6 เดือน รวบรวมจากระบบอัตโนมัติของเครื่องจักร
ในกระบวนการผลิตกระดาษ ใช้พัฒนาแบบจำลองน้ำเสียที่เข้าระบบ (influent)

กระบวนการพัฒนาแบบจำลองใช้ exhaustive algorithm เพื่อค้นหาค่าพารามิเตอร์ที่ดีที่สุด โดยมีการทดสอบค่าพารามิเตอร์ เช่น time delays, training windows, และ combinations ของค่าพารามิเตอร์อินพุต โดยแบบจำลองที่ใช้ประกอบด้วย

- แบบจำลองเวลา (Time-Series Models): ARX และ ARMAX
- แบบจำลองเชิงสถิติ: MLR, PLSR, และ LASSO

ใช้ค่า RMSE, MAPE และ Correlation (r) ในการวัดประสิทธิภาพของแบบจำลองทั้ง 5 เทคนิค ผลลัพธ์ในชุดข้อมูลทดสอบ คือ แบบจำลอง ARX ให้ผลลัพธ์ที่ดีที่สุดสำหรับการพยากรณ์ COD ในน้ำเสียที่เข้าระบบ (influent) โดยมีค่า Correlation (r) 0.89 และค่า MAPE 8.1% ตามตาราง 7

ตาราง 7 โครงสร้างแบบจำลองของน้ำเสียที่เข้าสู่ระบบ (influent) และตัวชี้วัดประสิทธิภาพ

Model	Nonlinear Scaling	r	MAPE (%)	RMSE (mg/L)
ARX	No	0.89	8.1	191.1
ARMAX	No	0.85	7.5	177.4
MLR	Yes	0.4	17.1	371.4
PLSR	Yes	0.74	7.8	147.6
LASSO	Yes	0.7	12.2	208.5

ที่มา: (Pörhö และคณะ, 2023)

สำหรับน้ำเสียที่ออกจากระบบบำบัด (effluent) แบบจำลอง PLSR ให้ผลลัพธ์ที่ดีเช่นกัน โดยสามารถพยากรณ์ได้ล่วงหน้า 20 ชั่วโมง ด้วยค่า Correlation (r) 0.77 และ MAPE 7.6% ตามตาราง 8

ตาราง 8 โครงสร้างแบบจำลองของน้ำเสียที่ออกจากระบบ (effluent) และตัวชี้วัดประสิทธิภาพ

Model	Nonlinear Scaling	r	MAPE (%)	RMSE (mg/L)
PLSR	No	0.77	7.6	23.0
PLSR	Yes	0.68	14.5	36.3
MLR	Yes	0.67	25.1	59.4
LASSO	Yes	0.54	21.3	29.4
ARX	No	0.8	10.4	31.7
ARMAX	No	0.78	10.3	31.4

ที่มา: (Pörhö และคณะ, 2023)

แบบจำลองที่พัฒนาขึ้นในงานวิจัยนี้ได้พิสูจน์ว่ามีความแม่นยำเพียงพอสำหรับการใช้งานจริงในกระบวนการบำบัดน้ำเสีย

2.3.7 งานวิจัยเรื่อง The Dissolved Oxygen Prediction Method Based on Neural Network (Xiao และคณะ, 2017)

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและเปรียบเทียบความแม่นยำของแบบจำลอง Backpropagation Neural Network (BP-NN) ในการพยากรณ์ค่าปริมาณออกซิเจนละลายน้ำ (DO) ในระบบเพาะเลี้ยงสัตว์น้ำ คือ บ่อเลี้ยงกุ้งขาวสายพันธุ์ South American จำนวน 3 บ่อ ในเมือง Beihai มณฑลกว่างซี ประเทศสาธารณรัฐประชาชนจีน โดยเปรียบเทียบกับวิธีดั้งเดิม คือ Curve Fitting (CF), Autoregression (AR), Grey Models (GM) และ Support Vector Machine (SVM) เพื่อหาแนวทางที่แม่นยำและเหมาะสมที่สุดในการจัดการคุณภาพน้ำและลดความเสี่ยงในการเพาะเลี้ยงสัตว์น้ำ

โดยข้อมูลค่าปริมาณออกซิเจนละลายน้ำ (DO) ถูกบันทึกเวลา 4:00 น. ติดต่อกัน 7 วัน ในช่วงกลางเดือนมิถุนายน ค.ศ. 2016 สำหรับเป็นชุดข้อมูลฝึก (Train) และ 3 วันเป็นชุดข้อมูลทดสอบ (Test) ซึ่งมีการควบคุมค่าพารามิเตอร์ที่เกี่ยวข้องอื่น ๆ ให้อยู่ในระดับใกล้เคียงกัน เช่น อุณหภูมิเฉลี่ย 31°C (ความต่าง $\pm 3^{\circ}\text{C}$), ความชื้น 90%, ความดันบรรยากาศ 1 atm เป็นต้น

ทำการทำความสะอาดข้อมูลและเตรียมค่าพารามิเตอร์ เช่น ค่าปริมาณออกซิเจนละลายน้ำ (DO), ความต่างอุณหภูมิ, ระยะเวลาที่แดดออก เป็นต้น ใช้ฟังก์ชันกระตุ้น (Activation Function) แบบ purelin, logsig, และ tansig ใน BP-NN เพื่อปรับปรุงความแม่นยำ โดยเทคนิค

BP-NN มีโครงสร้าง 3 ชั้น คือ Input Layer, Hidden Layer และ Output Layer พร้อมใช้ฟังก์ชันการปรับน้ำหนัก (Weight) แบบ Error Backpropagation ทำการฝึกการเรียนรู้โดยการวนซ้ำจำนวน 5,000 ครั้ง และอัตราการเรียนรู้ (Learning rate) คือ 0.01 และนำมาเปรียบเทียบกับแบบจำลองดั้งเดิม คือ Curve Fitting (CF), Autoregression (AR), Grey Models (GM) และ Support Vector Machine (SVM) โดยใช้ตัวชี้วัดความแม่นยำคือ ค่า Absolute Error ผลปรากฏว่าเทคนิค BP-NN ให้ผลลัพธ์ที่แม่นยำที่สุดทั้ง 3 บ่อและทุกวัน โดยมีข้อผิดพลาดน้อยกว่า 5%

2.3.8 งานวิจัยเรื่อง Gate-Variants of Gated Recurrent Unit (GRU) Neural Networks (Dey และ Salem, 2017)

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาประสิทธิภาพและลดจำนวนพารามิเตอร์ของ Gated Recurrent Unit (GRU) โดยการพัฒนา 3 รูปแบบของ GRU ได้แก่ GRU1, GRU2, และ GRU3 ซึ่งเปรียบเทียบกับ GRU ดั้งเดิม (GRU0) ในการพยากรณ์ข้อมูลจากชุดข้อมูล MNIST และ IMDB และใช้ Python ในการพัฒนาและการฝึกสอนแบบจำลอง ใช้ Keras ไบบรารีสร้างและปรับแต่งแบบจำลอง เพื่อเพิ่มประสิทธิภาพการคำนวณและลดทรัพยากรที่ใช้โดยยังคงความแม่นยำให้ใกล้เคียงกับ GRU และ LSTM แบบดั้งเดิมไว้ โดยมีรายละเอียดและการจัดเตรียมข้อมูลดังนี้

- ข้อมูล MNIST: เป็นชุดข้อมูลภาพตัวเลขที่เขียนด้วยมือ จำนวน 60,000 ภาพ สำหรับการฝึกการเรียนรู้ (Train) และ 10,000 ภาพสำหรับการทดสอบ (Test) โดยมีรูปแบบดังนี้
 - Pixel-wise: สร้างข้อมูลลำดับจากพิกเซลทั้งหมด (784 จุดต่อภาพ)
 - Row-wise: สร้างข้อมูลลำดับจากแถวของพิกเซล (28 จุดต่อภาพ)
- ข้อมูล IMDB: เป็นชุดข้อมูลความคิดเห็นเกี่ยวกับภาพยนตร์ พร้อมคลาสแสดงอารมณ์ (บวก/ลบ) จำนวน 25,000 ตัวอย่างสำหรับการฝึกการเรียนรู้ (Train) และ 25,000 ตัวอย่างสำหรับการทดสอบ (Test) โดยมีการจำกัดจำนวนคำในความคิดเห็นแต่ละรายการที่ 80 คำและใช้คำที่พบบ่อยที่สุด 20,000 คำในคลังคำศัพท์

โดยมีคุณลักษณะของแบบจำลองที่ใช้กับข้อมูลที่แตกต่างกันตามตาราง 9 และที่เหมือนกันดังนี้

- การกระตุ้นเกต (Gate Activation): Sigmoid
- ฟังก์ชันกระตุ้น (Activation Function): ReLU/tanh
- จำนวนรอบการฝึก (Epochs): 100
- ตัวปรับพารามิเตอร์ (Optimizer): RMSProp

- การสุ่มปิดโหนด (Dropout): 20%
- ขนาดแบตช์ (Batch Size): 32

ตาราง 9 คุณลักษณะของแบบจำลองที่ใช้กับข้อมูล

Model	MNIST Pixel-wise	MNIST Row-wise	IMDB
จำนวนหน่วยซ่อน (Hidden Units)	100	100	128
ตัวชี้วัดความเสียหาย (Cost)	Categorical Cross-entropy	Categorical Cross-entropy	Binary Cross-entropy

ที่มา: (Dey และ Salem, 2017)

การทดลองมี GRU0 เป็นเทคนิคแบบดั้งเดิม และ GRU1, GRU2 และ GRU3 ที่มีการลดจำนวนพารามิเตอร์ในฟังก์ชัน gating โดยมีรายละเอียดดังนี้

- GRU1: ลดการใช้ input vector ในฟังก์ชัน gating
- GRU2: ใช้ hidden state และ bias เท่านั้น
- GRU3: ใช้เฉพาะ bias

ตัวชี้วัดผลลัพธ์ มีดังนี้

- Accuracy: ใช้วัดความแม่นยำของแบบจำลอง แสดงเป็นเปอร์เซ็นต์ของข้อมูลที่แบบจำลองทำนายถูกต้อง ใช้ในชุดข้อมูล MNIST ทั้ง Pixel-wise, Row-wise และ IMDB
- Cross-Entropy Loss: วัดความคลาดเคลื่อนระหว่างค่าที่แบบจำลองทำนายและค่าจริง ใช้ฟังก์ชัน Categorical Cross-entropy สำหรับชุดข้อมูล MNIST (Pixel-wise Row-wise) และ Binary Cross-entropy สำหรับ IMDB
- จำนวนพารามิเตอร์ (Parameter Count): ใช้เปรียบเทียบความซับซ้อนของแบบจำลองทั้ง 4 แบบ

การประเมินผล (Evaluation Process) แบ่งตามข้อมูลมีดังนี้

- MNIST: ใช้การทำนายภาพตัวเลขในรูปแบบ Pixel-wise และ Row-wise
- IMDB: ใช้การวิเคราะห์ความรู้สึกในความคิดเห็น (Sentiment Analysis)

และเปรียบเทียบผลการทำนายของแบบจำลองทั้ง 4 แบบโดยพิจารณาความแม่นยำ (Accuracy) และความซับซ้อน (จำนวนพารามิเตอร์) โดยสามารถสรุปผลลัพธ์ของชุดข้อมูล MNIST ได้ดังนี้

- GRU0 มีความแม่นยำสูงสุด (Train: 99.2%, Test: 98.6%) แต่ใช้พารามิเตอร์มากที่สุด
- GRU1 และ GRU2 มีความแม่นยำใกล้เคียง GRU0 แต่ใช้พารามิเตอร์น้อยกว่า ~1-2%
- GRU3 มีพารามิเตอร์ลดลงมากที่สุด (~66%) แต่ประสิทธิภาพลดลงในลำดับข้อมูลที่ยาว

และผลลัพธ์ของชุดข้อมูล IMDB ได้ดังนี้

- GRU1 และ GRU2 มีความแม่นยำใกล้เคียง GRU0 (Train/Test ~85%)
- GRU3 มีความแม่นยำต่ำเมื่ออัตราการเรียนรู้ต่ำ (Train/Test ~0.5%)

2.3.9 งานวิจัยเรื่อง A survey on river water quality modelling using artificial intelligence (Tung และ Yaseen, 2020)

งานวิจัยนี้มีวัตถุประสงค์เพื่อรวบรวมและสังเคราะห์ข้อมูลเกี่ยวกับการใช้ปัญญาประดิษฐ์ (Artificial Intelligence - AI) ในการจำลองคุณภาพน้ำในแม่น้ำ ทำการสำรวจเทคนิค AI ที่ใช้ในการวิเคราะห์และคาดการณ์พารามิเตอร์ต่าง ๆ ที่เกี่ยวข้องกับคุณภาพน้ำ เช่น ค่า DO, COD, BOD ฯลฯ โดยอ้างอิงข้อมูลจากงานวิจัยที่ผ่านมาครอบคลุมช่วงตั้งแต่ปี ค.ศ. 2000 ถึง ค.ศ. 2020 และนำเสนอข้อได้เปรียบของ AI เมื่อเทียบกับวิธีการแบบดั้งเดิม เช่น การใช้แบบจำลองทางสถิติ พร้อมทั้งแนะนำกรอบการทำงานหรือแนวโน้มสำหรับการพัฒนาแบบจำลองที่มีประสิทธิภาพในอนาคต การคาดการณ์ค่า DO โดยใช้ AI ช่วยให้สามารถระบุแนวโน้มและพฤติกรรมของค่า DO ภายใต้สภาวะที่ซับซ้อนได้ เช่น การเปลี่ยนแปลงตามฤดูกาล หรือการปล่อยของเสีย

มีแบบจำลองที่ถูกใช้ในการพยากรณ์คุณภาพน้ำ เช่น ANN (Artificial Neural Network), MLP (Multi-Layer Perceptron), SVM (Support Vector Machine), RNN (Recurrent Neural Network), LSTM (Long Short-Term Memory), GRU (Gated Recurrent Unit) เป็นต้น

การประเมินประสิทธิภาพของเทคนิค RNN, LSTM และ GRU ในการพยากรณ์ DO ที่มักใช้ คือ ค่า RMSE, ค่า MAE และ ค่า R^2

ช่วงเวลาของข้อมูล (Data Time Scale) หรือความถี่ในการบันทึกข้อมูลเชิงเวลาของเทคนิค RNN, LSTM และ GRU ที่มักใช้ คือ รายชั่วโมง (Hourly), รายวัน (Daily) หรือระดับเวลาที่ละเอียดมากขึ้นหากข้อมูลถูกบันทึกอย่างต่อเนื่อง

ทั้งนี้ ข้อมูลจากบทความไม่ได้ระบุเฉพาะเจาะจงว่าการศึกษา LSTM พยากรณ์ DO ในบทความนี้ใช้ตัวแปรใดบ้าง แต่เน้นไปที่การทบทวนงานวิจัยที่เกี่ยวข้องและข้อดีข้อเสียของเทคนิคต่าง ๆ ในการพยากรณ์คุณภาพน้ำโดยใช้ AI

2.3.10 งานวิจัยเรื่อง Using LSTM and GRU Neural Network Methods for Traffic Flow Prediction (Fu และคณะ, 2016)

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและเปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (Long Short-Term Memory) และ GRU (Gated Recurrent Unit) ในการพยากรณ์การไหลของการจราจร โดยเปรียบเทียบกับเทคนิค ARIMA (AutoRegressive Integrated Moving Average) เพื่อเพิ่มความแม่นยำในการพยากรณ์ข้อมูลเชิงอนุกรมเวลาในระบบจราจร และช่วยให้การบริหารจัดการจราจรมีประสิทธิภาพมากขึ้น ข้อมูลที่ใช้เป็นข้อมูลการจราจรที่บันทึกจากเซ็นเซอร์ตรวจจับในระบบ PeMS (Performance Measurement System) ซึ่งเป็นฐานข้อมูลการจราจรในรัฐแคลิฟอร์เนีย ประเทศสหรัฐอเมริกา โดยแสดงปริมาณยานพาหนะที่ผ่านไปในแต่ละชั่วโมง (Hourly Traffic Data) ซึ่งเหมาะสำหรับการใช้งานในแบบจำลอง LSTM และ GRU มีการแบ่งข้อมูลเป็นชุดฝึกการเรียนรู้ (Train) 80% และชุดทดสอบ (Test) 20% และใช้การปรับข้อมูล (Normalization) เพื่อช่วยเพิ่มประสิทธิภาพของแบบจำลอง

การตั้งค่าพารามิเตอร์ (Hyperparameter Settings) มีดังนี้

- ฟังก์ชันกระตุ้น (Activation Function): ใช้ ReLU และ Tanh สำหรับการเปลี่ยนค่าภายในโนนด
- ตัวปรับพารามิเตอร์ (Optimizer): ใช้ Adam หรือ RMSProp เพื่อปรับปรุงค่าพารามิเตอร์ในระหว่างการฝึก
- อัตราการเรียนรู้ (Learning Rate): ตั้งค่าที่ 0.001 และปรับแบบ Exponential Decay ในบางการทดลอง
- ขนาดแบตช์ (Batch Size): ใช้ขนาด 32 ตัวอย่างต่อ Batch
- จำนวนรอบการฝึก (Epochs): ฝึกโมเดลทั้งหมดเป็นเวลา 100 รอบ

ตัวชี้วัดผลลัพธ์ (Performance Metrics) ใช้ MSE และ MAE เป็นเกณฑ์วัดความแม่นยำของการพยากรณ์ โดยผลลัพธ์จากทั้ง 3 เทคนิค แสดงตามตาราง 10

ตาราง 10 ค่า MSE และ MAE ของแบบจำลอง ARIMA, LSTM NN และ GRU NN

Model	MSE	MAE
ARIMA	841.0065	19.1753
LSTM NN	710.0502	18.127758
GRU NN	668.9304	17.2116

ที่มา: (Fu และคณะ, 2016)

ผลลัพธ์จากค่า MSE และ MAE ตามตาราง 10 แสดงให้เห็นว่าเทคนิค LSTM และ GRU มีประสิทธิภาพสูงกว่าเมื่อเทียบกับเทคนิค ARIMA ในการพยากรณ์ข้อมูลจราจร โดยเฉพาะในชุดข้อมูลที่มีความซับซ้อน และ GRU ยังให้ผลลัพธ์ที่ดีกว่า LSTM อีกด้วย

2.3.11 งานวิจัยเรื่อง Dissolved Oxygen Forecasting for Lake Erie's Central Basin Using Hybrid Long Short-Term Memory and Gated Recurrent Unit Networks (Pan และ คณะ, 2024)

งานวิจัยนี้มุ่งเน้นการพัฒนาแบบจำลองปัญญาประดิษฐ์ โดยหาวิธีในการพยากรณ์ระดับออกซิเจนละลายน้ำ (Dissolved Oxygen - DO) ล่วงหน้าได้แม่นยำที่สุด เพื่อนำมาใช้ในการพยากรณ์ระดับออกซิเจนละลายน้ำในทะเลสาบอีรี (Lake Erie) ซึ่งเป็นทะเลสาบน้ำจืดขนาดใหญ่ที่มีความสำคัญของทวีปอเมริกาเหนือ ซึ่งประสบปัญหาการลดลงของออกซิเจนละลายน้ำในชั้นน้ำลึก ส่งผลกระทบต่อสิ่งมีชีวิตในน้ำและคุณภาพน้ำโดยรวม มีการแบ่งข้อมูลโดยใช้ข้อมูลจากปี ค.ศ. 2020 เป็นชุดฝึกสอนประกอบด้วย Training Set 80% และ Validation Set 20% และข้อมูลทั้งหมดจากปี ค.ศ. 2021 เป็น Testing Set นักวิจัยได้พัฒนาแบบจำลองการเรียนรู้เชิงลึก (Deep Learning) แบบไฮบริด ใช้ข้อมูลจาก 21 สถานีตรวจวัดในทะเลสาบอีรี 2 ช่วง คือ 19 มิถุนายน ถึง 11 ตุลาคม ของปี ค.ศ. 2020 และ 2021 ข้อมูลประกอบด้วย อุณหภูมิและระดับออกซิเจนละลาย (DO Concentration) แบบจำลองมี 5 เทคนิค ได้แก่

- LSTM (Long Short-Term Memory)
- GRU (Gated Recurrent Unit)
- CNN-LSTM (Convolutional Neural Network + LSTM)
- CNN-GRU (CNN + GRU)
- ConvLSTM (Convolutional LSTM)

ทำการทดลองโดยการปรับค่าพารามิเตอร์และฝึกแบบจำลองทั้ง 5 เทคนิค ให้ทำการพยากรณ์เป็น 1, 3, 6 และ 12 ชั่วโมงล่วงหน้า และใช้ตัวชี้วัดผลลัพธ์ (Performance Metrics) คือ MSE, MAE และ R² เป็นเกณฑ์วัดความแม่นยำของการพยากรณ์จากชุดข้อมูลทดสอบ ได้ผลลัพธ์แสดงตามตาราง 11

ตาราง 11 สถิติผลการทดสอบของแบบจำลองการเรียนรู้ของเครื่อง

Hours Ahead	Model	MSE	MAE	R ²
1	LSTM	1.3468	0.7810	0.8573
	GRU	0.9477	0.6785	0.8995
	CNN-LSTM	1.5118	0.8338	0.8398
	CNN-GRU	0.8359	0.6432	0.9114
	ConvLSTM	0.2842	0.3622	0.9699
3	LSTM	1.4117	0.7908	0.8503
	GRU	1.002	0.6889	0.8938
	CNN-LSTM	1.5530	0.8426	0.8354
	CNN-GRU	0.8757	0.6511	0.9092
	ConvLSTM	0.3208	0.3837	0.9685
6	LSTM	1.4644	0.7955	0.8447
	GRU	1.0656	0.7008	0.8870
	CNN-LSTM	1.5889	0.8454	0.8315
	CNN-GRU	0.9449	0.6623	0.8998
	ConvLSTM	0.3825	0.3899	0.9594
12	LSTM	1.5917	0.8359	0.8310
	GRU	1.2350	0.7329	0.8689
	CNN-LSTM	1.7068	0.8612	0.8188
	CNN-GRU	1.0836	0.6820	0.8850
	ConvLSTM	0.5092	0.4172	0.9460

ที่มา: (Pan และคณะ, 2024)

ตามตาราง 11 แสดงให้เห็นว่าแบบจำลอง ConvLSTM มีผลลัพธ์จากค่า MSE, MAE และ R^2 ที่ดีที่สุดในทุก ๆ ชั่วโมงการพยากรณ์ล่วงหน้า และจากค่า $R^2 = 0.9460$ ของแบบจำลอง ConvLSTM ยังบ่งบอกว่าเป็นแบบจำลองที่ดีที่สุด ที่มีความสามารถในการพยากรณ์ค่าระดับออกซิเจนละลายน้ำล่วงหน้าได้ถึง 12 ชั่วโมง

จากการที่ผู้วิจัยทบทวนวรรณกรรมงานวิจัยที่เกี่ยวข้องทั้งหมดได้ทำการสรุปเนื้อหาโดยย่อ ดังตาราง 12 เพื่อที่ผู้วิจัยใช้ในการคัดเลือกชุดข้อมูล, แบบจำลอง, การปรับค่าพารามิเตอร์ของแบบจำลอง และเครื่องมือวัดประสิทธิภาพ สำหรับการดำเนินการวิจัยต่อไป

ตาราง 12 สรุปโดยย่อจากงานวิจัยที่เกี่ยวข้อง


Region	Applied Models	Input/Output (Variable)	Performance Metrics	Data Time Scale	Research Remark
ทะเลสาบ, จีน	LSTM, BP NN, OS-ELM	DO, TP	RMSE, Max Error	รายเดือน (657 ชุด)	LSTM มีประสิทธิภาพดีกว่า BP NN และ OS-ELM
แม่น้ำ, จีน	GM, RNN, LSTM-RNN	COD	RMSE, MAPE	รายวัน (460 ชุด)	LSTM-RNN มีความแม่นยำกว่า GM และ RNN
(Review)	Various ANNs	DO, BOD, COD, pH, ฯลฯ		ทุก 5 นาที, รายชั่วโมง, วัน, เดือน	ทบทวนการใช้ ANN ในช่วงปี ค.ศ. 2008 - 2019
บ่อเลี้ยง, จีน	RNN, LSTM, GRU	DO (Input: pH, turbidity, temp, NH)	MAE, MSE, MAPE, R^2	ทุก 2 ชม. (5,190 ชุด)	GRU มีความแม่นยำและใช้ทรัพยากรได้มีประสิทธิภาพที่สุด
(Review)	Various ML, DL	DO, pH, temp, COD, BOD		รายนาที่, ชั่วโมง, วัน, สัปดาห์, เดือน	การเรียนรู้ของเครื่องช่วยเพิ่มความแม่นยำและความเร็วในการพยากรณ์คุณภาพน้ำ

ตาราง 12 (ต่อ)

Region	Applied Models	Input/Output (Variable)	Performance Metrics	Data Time Scale	Research Remark
โรงงานอุตสาหกรรม, กระดาษ, ฟินแลนด์	ARX, ARMAX, MLR, PLSR, LASSO	COD	RMSE, MAPE, Correlation	ทุก 1 นาที	แบบจำลอง ARX เหมาะกับข้อมูลน้ำเสียเข้า ส่วน PLSR เหมาะกับน้ำเสียออก
บ่อเลี้ยง, จีน	BP-NN, CF, AR, GM, SVM	DO	Absolute Error	รายวัน	BP-NN แม่นยำกว่าวิธีดั้งเดิมทั้งหมด
MNIST, IMDB	GRU0 - GRU3	Image pixels, sentiment text	Accuracy, Loss, จำนวนพารามิเตอร์	-	ศึกษา GRU แบบใหม่เพื่อลดพารามิเตอร์โดยยังรักษาความแม่นยำไว้ได้
แม่น้ำ, ทั่วโลก	ANN, MLP, RNN, LSTM, GRU	DO, COD, BOD, ฯลฯ	RMSE, MAE, MAPE, NSE, Accuracy, DC, R, ฯลฯ	รายชั่วโมง, วัน, เดือน, ฤดู	เปรียบเทียบแบบจำลอง AI ในการพยากรณ์คุณภาพน้ำในแม่น้ำ
จวากร, สหรัฐอเมริกา	ARIMA, LSTM, GRU	การไหลของ การจวากร	MSE, MAE	รายชั่วโมง	GRU ให้ผลดีกว่า LSTM และ ARIMA ในการทำนายการจวากร
ทะเลสาบ, ทวีปอเมริกาเหนือ	LSTM, GRU, CNN-LSTM, CNN-GRU, ConvLSTM	DO, Temperature	MSE, MAE, R^2	รายชั่วโมง (ช่วงเวลาเดียวกัน ของ 2 ปี)	ConvLSTM มีค่าความแม่นยำสูงที่สุดในทุกตัวชี้วัด

ผู้วิจัยเลือกศึกษาแบบจำลองทั้งหมด 5 เทคนิค ได้แก่ แบบจำลอง RNN ที่ออกแบบมาเพื่อประมวลผลข้อมูลประเภทอนุกรมเวลา (Time-Series Data) และแบบจำลองที่พัฒนาต่อยอดจากแบบจำลอง RNN ได้แก่ LSTM และ GRU และแบบจำลองที่เพิ่มการใช้เทคนิคของ CNN เพื่อเพิ่มประสิทธิภาพให้กับแบบจำลอง ได้แก่ CNN-LSTM และ CNN-GRU สำหรับงานวิจัยนี้

3.2 ขั้นตอนการทำงานของแบบจำลอง



ภาพประกอบ 7 แสดงขั้นตอนการทำงานของแบบจำลอง

ขั้นตอนในงานวิจัยจากภาพประกอบ 7 เริ่มจากการเก็บรวบรวมข้อมูล (Data Collection) โดยการค้นหาข้อมูลที่เป็นข้อมูล Public Dataset โดยข้อมูลที่จะใช้สำหรับการวิจัยนี้ มีลักษณะเป็นข้อมูลอนุกรมเวลา (Time-Series) ที่มีช่วงเวลาของข้อมูลเป็นรายวันและมีค่าออกซิเจนละลายน้ำ (DO) เพื่อเป็นข้อมูลเข้า (Input Data) เมื่อได้ข้อมูลแล้วจะทำให้ข้อมูลค่าออกซิเจนละลายน้ำ (DO) มีมาตรฐาน (Data Standardization) โดยการแปลงข้อมูลค่าออกซิเจนละลายน้ำ (DO) ให้อยู่ในสเกลที่เหมาะสมเพื่อใช้ในการฝึกการเรียนรู้ของแบบจำลอง จากนั้นแบ่งข้อมูล (Splitting Data) ออกเป็น Training Set และ Test Set ในสัดส่วน 80:20 จากนั้นใช้ข้อมูล Training Set ทำการฝึกการเรียนรู้ของแบบจำลองที่มีการปรับค่าพารามิเตอร์ตามที่กำหนดไว้ด้วยวิธี Manual โดยเป็นชุดข้อมูลเดียวกันทั้ง 5 เทคนิค จากนั้นทดสอบการพยากรณ์ค่าออกซิเจนละลายน้ำ (DO) ด้วยข้อมูล Test Set และใช้เครื่องมือประเมินประสิทธิภาพของแบบจำลอง (Model Evaluation) ทั้ง 5 เทคนิค โดยก่อนการประเมินนั้น จะทำ Inverse Standardization โดยการปรับสเกลของข้อมูลค่าออกซิเจนละลายน้ำ (DO) ของ Test Set และค่าที่พยากรณ์ได้ให้กลับมามีค่าก่อนการทำขั้นตอน Data Standardization แล้วนำผลลัพธ์มาเปรียบเทียบประสิทธิภาพเพื่อหาเทคนิคที่ได้ผลลัพธ์ที่ดีที่สุด

3.3 การคัดเลือกและเก็บรวบรวมข้อมูล (Data Selection and Data Collection)

งานวิจัยนี้ใช้ข้อมูลคุณภาพน้ำที่เป็นข้อมูล Public Dataset จากโครงการของ Bhatt (Bhawna Bhatt, 2019) โดยเก็บรวบรวมข้อมูลจากสถานีตรวจวัด 31 แห่งในรัฐจอร์เจีย ประเทศสหรัฐอเมริกา ตั้งแต่วันที่ 1 ตุลาคม ค.ศ. 2014 ถึง 18 กุมภาพันธ์ ค.ศ. 2019 วันละ 1 ชุด จำนวน 1,603 ชุด เป็นข้อมูลอนุกรมเวลา (Time-Series) โดยมีข้อมูลวันที่ พารามิเตอร์ และการวัดค่าต่าง ๆ พร้อมหน่วยการวัด ดังแสดงในตาราง 14

ตาราง 14 พารามิเตอร์ต่าง ๆ พร้อมหน่วยการวัด

พารามิเตอร์		หน่วยวัด
Temperature	อุณหภูมิ	°C
pH	ความเป็นกรด - ด่าง	-
Dissolved Oxygen (DO)	ออกซิเจนละลายน้ำ	mg/L
Turbidity	ความขุ่น	FNU

ที่มา: (Bhawna Bhatt, 2019)

โครงการของ Bhatt (Bhawna Bhatt, 2019) ทำการจัดการข้อมูลจากข้อมูลดิบจำนวน 150,729 ชุด ที่เก็บรวบรวมจากสถานีตรวจวัด 31 แห่ง วัดทุก 15 นาที ให้อยู่ในรูปแบบของข้อมูลเฉลี่ยจำนวน 1,603 ชุด โดยมีขั้นตอนดังนี้

1. ทำความสะอาดข้อมูล โดยการลบ NaN และแปลงวันที่ (Datetime)
2. คำนวณค่าเฉลี่ยรายวัน (Resample) ของแต่ละสถานีตรวจวัด
3. รวมข้อมูลเฉลี่ยรายวันจากทุกสถานีด้วยค่าเฉลี่ย


และเหตุผลที่ใช้ข้อมูลเฉลี่ยในโครงการของ Bhatt (Bhawna Bhatt, 2019) มีดังนี้

- ข้อมูลดิบที่ทำการวัดทุก 15 นาที มีความผันผวนสูงจากหลายปัจจัย การใช้ค่าเฉลี่ยจึงช่วยเน้นแนวโน้ม (Trend) หรือ วัฏจักร (Cycle) ที่สำคัญทางสถิติ โดยไม่ถูกรบกวนจากความผันผวนระยะสั้น

- การลดขนาดชุดข้อมูล (Data Volume) ทำให้ Train แบบจำลองได้เร็วขึ้น, ใช้หน่วยความจำ (Memory) น้อยลง และลดความเสี่ยง Overfitting ที่มาจากข้อมูลที่ละเอียดเกินไป

- เหมาะสมกับวัตถุประสงค์การพยากรณ์ระดับรายวัน

- การใช้ข้อมูลเฉลี่ยร่วมกับ Normalization ช่วยให้โมเดลเรียนรู้ได้ง่ายขึ้นและคงเสถียรภาพในการ Train



ภาพประกอบ 8 แสดงกราฟค่าออกซิเจนละลายน้ำ (DO หรือ Dissolved Oxygen) ตามวันที่

จากภาพประกอบ 8 แสดงรูปแบบของการขึ้นและลงของข้อมูลค่า DO ที่มีลักษณะซ้ำ ๆ กันทุกปี ดังนี้

- ค่า DO สูง: มักเกิดในช่วงปลายปีถึงต้นปี คือ ช่วงเดือน 1 ของทุกปี
- ค่า DO ต่ำ: มักเกิดในช่วงกลางปี คือ ช่วงเดือน 7 ของทุกปี

แสดงให้เห็นว่าลักษณะการขึ้นและลงของข้อมูลค่า DO นี้ เกิดซ้ำทุก 12 เดือน หรือ 1 ปี โดยข้อมูลทั้งหมดอยู่ในช่วงระยะเวลาประมาณ 4 ปีกว่า มีการขึ้นของข้อมูล 5 ครั้ง และการลงของข้อมูล 4 ครั้ง เนื่องจากข้อมูลไม่ครบ 5 ปี ชี้ว่าข้อมูลค่า DO นี้ มีลักษณะเป็นฤดูกาล (Seasonality) ที่ชัดเจน


3.4 การเตรียมข้อมูล (Pre-Processing)

เตรียมข้อมูลโดยการอ่านข้อมูลคุณภาพน้ำที่ถูกเก็บในรูปแบบของไฟล์ CSV ที่มีบรรทัดแรกเป็นชื่อข้อมูลวันที่และค่าต่าง ๆ ของคุณภาพน้ำ ให้อยู่ในรูปแบบ Data Frame เนื่องจากข้อมูลที่ใช้ได้ผ่านกระบวนการทำความสะอาด, การปรับความละเอียดเชิงเวลา (Resampling) และรวมข้อมูลจากหลายสถานีมาแล้ว ข้อมูลจึงมีความสมบูรณ์ จากนั้นทำการแบ่งข้อมูล (Splitting Data) ออกเป็น Training Set สำหรับฝึกการเรียนรู้และ Test Set สำหรับทดสอบในสัดส่วน 80:20 ดังนั้นจึงมีข้อมูลฝึกการเรียนรู้ของแบบจำลองจำนวน 1,282 ชุดและข้อมูลทดสอบจำนวน 321 ชุด โดยใช้ Sliding Window หรือ Lookback Window ซึ่งกำหนดขนาดของข้อมูลย้อนหลังคือ 1 วัน หลังจากนั้นทำการแปลงข้อมูลค่าออกซิเจนละลายน้ำ (DO) เพื่อใช้ในการฝึกการเรียนรู้ของแบบจำลองด้วยการสเกลข้อมูลให้มีค่าอยู่ระหว่าง 0 ถึง 1 โดยคำสั่งที่ใช้ในการสเกลข้อมูลคือ MinMaxScaler ตามภาพประกอบ 9


```
scaler = MinMaxScaler(feature_range=(0, 1))
```

ภาพประกอบ 9 แสดงคำสั่งการสเกลข้อมูล

โดยขั้นตอนการสเกลข้อมูลนี้ทำให้ข้อมูลมีมาตรฐาน (Data Standardization) เพื่อช่วยให้แบบจำลองมีประสิทธิภาพที่ดีขึ้น



ภาพประกอบ 10 แสดงกราฟค่าออกซิเจนละลายน้ำที่ยังไม่ผ่านการแบ่งข้อมูลและการสเกล



ภาพประกอบ 11 แสดงกราฟค่าออกซิเจนละลายน้ำที่ผ่านการแบ่งข้อมูลและการสเกลแล้ว

จากภาพประกอบ 10 แสดงค่าออกซิเจนละลายน้ำที่ยังไม่ผ่านการแบ่งข้อมูลการสเกล โดยข้อมูลค่า DO ต่ำสุดอยู่ที่ ~ 5.596 และสูงสุดอยู่ที่ ~ 12.3722 จำนวนข้อมูลทั้งหมด 1,603 ชุด และจากภาพประกอบ 11 แสดงกราฟค่าออกซิเจนละลายน้ำที่ผ่านการแบ่งข้อมูลและการสเกลแล้ว โดยข้อมูลค่า DO ต่ำสุดอยู่ที่ 0 และสูงสุดอยู่ที่ 1 จำนวนข้อมูลทั้งหมด 1,282 ชุด สำหรับใช้ฝึกการเรียนรู้ของแบบจำลอง

3.5 การสร้างและปรับค่าพารามิเตอร์ของแบบจำลอง (Modeling and Fine-tuning Hyperparameters)

งานวิจัยนี้ดำเนินการบน Google Colab ทำการเซต Runtime type เป็น Python 3 และ Hardware accelerator เป็น CPU และใช้ไลบรารี (Library) ในการสร้างและฝึกการเรียนรู้ของแบบจำลอง คือ Keras โดยใช้แบบจำลองทั้งหมด 5 เทคนิค ในการทำทดลองดังนี้

1. แบบจำลอง RNNs (Recurrent Neural Networks)
2. แบบจำลอง LSTM (Long Short-Term Memory)
3. แบบจำลอง GRU (Gated Recurrent Unit)
4. แบบจำลอง CNN-LSTM (Convolutional Neural Network + LSTM)
5. แบบจำลอง CNN-GRU (Convolutional Neural Network + GRU)

จากแบบจำลองข้อ 4 และ 5 คือแบบจำลอง CNN-LSTM และ CNN-GRU มีการใช้เทคนิค Convolutional หรือ CNN นั้น เนื่องจากเทคนิค CNN มีลักษณะเด่นคือ ความสามารถเรียนรู้ข้อมูลรูปแบบซ้ำ ๆ และเน้นเฉพาะจุดเปลี่ยนแปลงของข้อมูลเชิงอนุกรมเวลาที่สำคัญ (Pan และคณะ, 2024) อย่างการมีฤดูกาล (Seasonality) ของข้อมูลที่ใช้ในงานวิจัยนี้ และสกัดคุณลักษณะนั้นออกมาได้ แล้วส่งข้อมูลไปขั้นถัดไป

3.5.1 โครงสร้างทั่วไปของทุกแบบจำลอง

ในแต่ละแบบจำลองมีโครงสร้างทั่วไปที่เหมือนกัน ก่อนการปรับค่าไฮเปอร์พารามิเตอร์ (Fine-tuning Hyperparameters) ต่าง ๆ ดังนี้

- จำนวนหน่วยความจำ (Unit) ในชั้นซ่อน (Hidden Layer) คือ 50
- ฟังก์ชันกระตุ้น (Activation Function) ในชั้นเอาต์พุต (Output Layer) คือ Tanh

(Hyperbolic Tangent)

- ตัวปรับค่าน้ำหนัก (Optimizer) คือ SGD (Stochastic Gradient Descent)
- ฟังก์ชันค่าความสูญเสีย (Loss Function) คือ mean_squared_error
- จำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs) คือ 5
- ขนาดของกลุ่มข้อมูล (Batch Size) คือ 1
- แบ่งข้อมูล Validation คือ 10% (0.1) แบบสุ่ม คือ shuffle=True

3.5.2 โครงสร้างของแบบจำลอง CNN-LSTM และ CNN-GRU

ชั้น Convolutional หรือ CNN นั้นจะเป็นชั้นที่รับข้อมูลจากชั้นอินพุต (Input Layer) แล้วประมวลผล ก่อนส่งข้อมูลไปชั้นถัดไป โดยในชั้น CNN ของแบบจำลอง CNN-LSTM และ CNN-GRU มีค่าไฮเปอร์พารามิเตอร์ต่าง ๆ ดังนี้

- ขนาดของ Kernel คือ 3
- จำนวนฟิลเตอร์ (Filters) ในชั้น Convolutional คือ 64
- ฟังก์ชันกระตุ้น (Activation Function) คือ ReLU (Rectified Linear Unit)
- ชั้น Max Pooling (MaxPooling1D) คือ 2
- ใช้ Dropout คือ 20% (0.2)

โดยในชั้นของ Convolutional หรือ CNN ของแบบจำลองทั้ง 2 เทคนิค ไม่มีการปรับค่าไฮเปอร์พารามิเตอร์ (Fine-tuning Hyperparameters)

3.5.3 การปรับค่าพารามิเตอร์ของแบบจำลอง (Fine-tuning Hyperparameters)

การปรับค่าไฮเปอร์พารามิเตอร์ต่าง ๆ ของแบบจำลองทั้ง 5 เทคนิค เพื่อหาประสิทธิภาพของแบบจำลองที่ดีที่สุดมีดังนี้

- อัตราการเรียนรู้ (Learning Rate) ของตัวปรับค่าน้ำหนัก (Optimizer) SGD คือ $0.1 (10^{-1})$ และ $0.01 (10^{-2})$
- ขนาดของกลุ่มข้อมูล (Batch Size) คือ 1 และ 4
- จำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs) คือ 5, 8 และ 10

3.6 การประเมินผลแบบจำลอง (Model Evaluation)

ผู้วิจัยใช้เครื่องมือวัดประสิทธิภาพทั้งหมด 3 เครื่องมือ เพื่อการประเมินผลของแบบจำลองทั้ง 5 เทคนิค ในการพยากรณ์ค่าออกซิเจนละลายน้ำ (DO) และเวลาที่แต่ละเทคนิคใช้ในการฝึกการเรียนรู้ (Training Time) โดยก่อนการประเมินผลได้ทำ Inverse Standardization โดยการปรับสเกลของข้อมูลค่าออกซิเจนละลายน้ำ (DO) ของ Test Set และค่าที่พยากรณ์ได้ให้กลับมามีค่าก่อนการทำขั้นตอน Data Standardization ได้แก่ MSE, RMSE และ MAPE

3.6.1 MSE (Mean Squared Error)

ค่าเฉลี่ยความแตกต่างระหว่างค่าที่แบบจำลองพยากรณ์และค่าจริง แล้วนำค่านี้มายกกำลังสอง ดังแสดงตามสมการ 3.1

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.1)$$

3.6.2 RMSE (Root Mean Squared Error)

ค่ารากที่สองของค่าเฉลี่ยความแตกต่างระหว่างค่าที่แบบจำลองพยากรณ์และค่าจริง แล้วนำค่านี้มายกกำลังสอง ดังแสดงตามสมการ 3.2

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.2)$$

3.6.3 MAPE (Mean Absolute Percentage Error)

ค่าเฉลี่ยความแตกต่างระหว่างค่าที่แบบจำลองพยากรณ์และค่าจริงเป็นเปอร์เซ็นต์ในรูปแบบค่าสัมบูรณ์ ดังแสดงตามสมการ 3.3

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad (3.3)$$

งานวิจัยนี้มี 4 ขั้นตอนหลัก ตามลำดับดังนี้ 1. การคัดเลือกและเก็บรวบรวมข้อมูล (Data Selection and Data Collection) โดยใช้ข้อมูลค่าออกซิเจนละลายน้ำ (DO) รายวัน 2. การเตรียมข้อมูล (Pre-Processing) โดยการทำให้ข้อมูลมีมาตรฐาน (Data Standardization) ด้วยการสเกลข้อมูลให้อยู่ระหว่าง 0 ถึง 1 ก่อนทำการส่งข้อมูลเข้าแบบจำลอง 3. การสร้างและปรับค่าพารามิเตอร์ของแบบจำลอง (Modeling and Fine-tuning Hyperparameters) ทั้งหมด 5 เทคนิค และ 4. การประเมินผลแบบจำลอง (Model Evaluation)

บทที่ 4

ผลการดำเนินการวิจัย

ในการวิจัยศึกษาการสร้างแบบจำลองเพื่อพยากรณ์ออกซิเจนละลายในน้ำโดยใช้เทคนิคการเรียนรู้เชิงลึก ผู้วิจัยได้ดำเนินการวิจัยโดยการศึกษาตามขอบเขตและขั้นตอนต่าง ๆ ตลอดจนการประเมินประสิทธิภาพของแบบจำลอง เพื่อให้สอดคล้องกับสมมติฐานที่กำหนดไว้ โดยกำหนดการทดลองไว้ดังนี้

1. แบบจำลอง RNNs (Recurrent Neural Networks)
2. แบบจำลอง LSTM (Long Short-Term Memory)
3. แบบจำลอง GRU (Gated Recurrent Unit)
4. แบบจำลอง CNN-LSTM (Convolutional Neural Network + LSTM)
5. แบบจำลอง CNN-GRU (Convolutional Neural Network + GRU)

การเปรียบเทียบผลลัพธ์จากการใช้แบบจำลองทั้ง 5 เทคนิค มีการปรับค่าไฮเปอร์พารามิเตอร์ 3 ค่าของแบบจำลอง ดังนี้

1. อัตราการเรียนรู้ (Learning Rate) ของตัวปรับค่าน้ำหนัก (Optimizer) SGD
2. ขนาดของกลุ่มข้อมูล (Batch Size)
3. จำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs)

4.1 แบบจำลอง RNNs (Recurrent Neural Networks)

การเปรียบเทียบผลลัพธ์จากการใช้เทคนิค RNNs (Recurrent Neural Networks) ได้ผลการดำเนินการดังตาราง 15

ตาราง 15 การเปรียบเทียบประสิทธิภาพของแบบจำลอง RNNs

Learning Rate	Batch Size	Epochs	MSE	RMSE	MAPE (%)
10^{-1}	1	5	0.1539	0.3923	3.8327
		8	0.1136	0.3370	2.8487
		10	0.1131	0.3362	3.6522
	4	5	0.1069	0.3270	2.6947
		8	0.1046	0.3234	2.6497
		10	0.0995	0.3154	2.5387
10^{-2}	1	5	0.0949	0.3080	2.4516
		8	0.0969	0.3113	2.5718
		10	0.0896	0.2994	2.4216
	4	5	0.1045	0.3232	2.5175
		8	0.0927	0.3045	2.4365
		10	0.0930	0.3050	2.4423

จากตาราง 15 อธิบายผลการดำเนินการของแบบจำลอง RNNs ได้ผลลัพธ์ว่า ในการใช้เครื่องมือวัดประสิทธิภาพ MSE, RMSE และ MAPE ได้ประสิทธิภาพที่ดีที่สุดเมื่ออัตราการเรียนรู้ (Learning Rate) เท่ากับ 10^{-2} ขนาดของกลุ่มข้อมูล (Batch Size) เท่ากับ 1 และจำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs) เท่ากับ 10 โดยค่าต่ำสุดของแต่ละเครื่องมือวัดประสิทธิภาพมีดังนี้

- MSE เท่ากับ 0.0896
- RMSE เท่ากับ 0.2994
- MAPE เท่ากับ 2.4216%

โดยใช้เวลาในการฝึกข้อมูล 32.92 วินาที ซึ่งสามารถดูข้อมูลเพิ่มเติมได้จากตาราง 21 ในส่วนของภาคผนวก

4.2 แบบจำลอง LSTM (Long Short-Term Memory)

การเปรียบเทียบผลลัพธ์จากการใช้เทคนิค LSTM (Long Short-Term Memory) ได้ผลการดำเนินการดังตาราง 16

ตาราง 16 การเปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM

Learning Rate	Batch Size	Epochs	MSE	RMSE	MAPE (%)
10^{-1}	1	5	0.0856	0.2927	2.3866
		8	0.1093	0.3306	2.7674
		10	0.0899	0.2999	2.3982
	4	5	0.1049	0.3239	2.4974
		8	0.0904	0.3007	2.4064
		10	0.0891	0.2984	2.4022
10^{-2}	1	5	0.5080	0.7127	7.1329
		8	0.1461	0.3823	2.9501
		10	0.1111	0.3334	2.5646
	4	5	2.0291	1.4245	15.5210
		8	1.3563	1.1646	12.3562
		10	1.2710	1.1274	12.1016

จากตาราง 16 อธิบายผลการดำเนินการของแบบจำลอง LSTM ได้ผลลัพธ์ว่า ในการใช้เครื่องมือวัดประสิทธิภาพ MSE, RMSE และ MAPE ได้ประสิทธิภาพที่ดีที่สุดเมื่ออัตราการเรียนรู้ (Learning Rate) เท่ากับ 10^{-1} ขนาดของกลุ่มข้อมูล (Batch Size) เท่ากับ 1 และจำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs) เท่ากับ 5 โดยค่าต่ำสุดของแต่ละเครื่องมือวัดประสิทธิภาพมีดังนี้

- MSE เท่ากับ 0.0856
- RMSE เท่ากับ 0.2927
- MAPE เท่ากับ 2.3866%

โดยใช้เวลาในการฝึกข้อมูล 15.67 วินาที ซึ่งสามารถดูข้อมูลเพิ่มเติมได้จากตาราง 22 ในส่วนของภาคผนวก

4.3 แบบจำลอง GRU (Gated Recurrent Unit)

การเปรียบเทียบผลลัพธ์จากการใช้เทคนิค GRU (Gated Recurrent Unit) ได้ผลการดำเนินการดังตาราง 17

ตาราง 17 การเปรียบเทียบประสิทธิภาพของแบบจำลอง GRU

Learning Rate	Batch Size	Epochs	MSE	RMSE	MAPE (%)
10^{-1}	1	5	0.0851	0.2918	2.4575
		8	0.0907	0.3012	2.4601
		10	0.0832	0.2884	2.4884
	4	5	0.1000	0.3162	2.5675
		8	0.0902	0.3004	2.4190
		10	0.0877	0.2961	2.3921
10^{-2}	1	5	0.0976	0.3124	2.4740
		8	0.0879	0.2965	2.3812
		10	0.0895	0.2992	2.3967
	4	5	0.6885	0.8298	8.6503
		8	0.5964	0.7722	7.7940
		10	0.1812	0.4257	3.4813

จากตาราง 17 อธิบายผลการดำเนินการของแบบจำลอง GRU ได้ผลลัพธ์ดังนี้

1. ในกรณีใช้เครื่องมือวัดประสิทธิภาพด้วย MSE ได้ประสิทธิภาพที่ดีที่สุดเมื่ออัตราการเรียนรู้ (Learning Rate) เท่ากับ 10^{-1} ขนาดของกลุ่มข้อมูล (Batch Size) เท่ากับ 1 และจำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs) เท่ากับ 10 โดยได้ค่า MSE ต่ำสุดที่ 0.0832
2. ในกรณีใช้เครื่องมือวัดประสิทธิภาพด้วย RMSE ได้ประสิทธิภาพที่ดีที่สุดเมื่ออัตราการเรียนรู้ (Learning Rate) เท่ากับ 10^{-1} ขนาดของกลุ่มข้อมูล (Batch Size) เท่ากับ 1 และจำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs) เท่ากับ 10 โดยได้ค่า RMSE ต่ำสุดที่ 0.2884
3. ในกรณีใช้เครื่องมือวัดประสิทธิภาพด้วย MAPE ได้ประสิทธิภาพที่ดีที่สุดเมื่ออัตราการเรียนรู้ (Learning Rate) เท่ากับ 10^{-2} ขนาดของกลุ่มข้อมูล (Batch Size) เท่ากับ 1 และจำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs) เท่ากับ 8 โดยได้ค่า MAPE ต่ำสุดที่ 2.3812%

เมื่อทำการเปรียบเทียบการปรับค่าไฮเปอร์พารามิเตอร์ที่ดีที่สุดของแบบจำลอง GRU พิจารณาจากค่า MSE และ RMSE โดยใช้อัตราการเรียนรู้ (Learning Rate) เท่ากับ 10^{-1} ขนาดของกลุ่มข้อมูล (Batch Size) เท่ากับ 1 และจำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs) เท่ากับ

10 ซึ่งการใช้ค่านี้ให้ค่า MSE ต่ำสุดที่ 0.0832 และค่า RMSE ต่ำสุดที่ 0.2884 โดยใช้เวลาในการฝึกข้อมูล 33.10 วินาที ซึ่งสามารถดูข้อมูลเพิ่มเติมได้จากตาราง 23 ในส่วนของภาคผนวก

4.4 แบบจำลอง CNN-LSTM (Convolutional Neural Network + LSTM)

การเปรียบเทียบผลลัพธ์จากการใช้เทคนิค CNN-LSTM (Convolutional Neural Network + LSTM) ได้ผลการดำเนินการดังตาราง 18

ตาราง 18 การเปรียบเทียบประสิทธิภาพของแบบจำลอง CNN-LSTM

Learning Rate	Batch Size	Epochs	MSE	RMSE	MAPE (%)
10^{-1}	1	5	0.0571	0.2390	2.0009
		8	0.0782	0.2796	2.2864
		10	0.0604	0.2458	2.2954
	4	5	0.0848	0.2911	2.7237
		8	0.0758	0.2753	2.5626
		10	0.0687	0.2620	2.1534
10^{-2}	1	5	0.2286	0.4782	3.8647
		8	0.0947	0.3077	2.3786
		10	0.0866	0.2942	2.3043
	4	5	1.7317	1.3159	14.5400
		8	1.0860	1.0421	11.0037
		10	0.5361	0.7322	7.4331

จากตาราง 18 อธิบายผลการดำเนินการของแบบจำลอง CNN-LSTM ได้ผลลัพธ์ว่า ในการใช้เครื่องมือวัดประสิทธิภาพ MSE, RMSE และ MAPE ได้ประสิทธิภาพที่ดีที่สุดเมื่ออัตราการเรียนรู้ (Learning Rate) เท่ากับ 10^{-1} ขนาดของกลุ่มข้อมูล (Batch Size) เท่ากับ 1 และจำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs) เท่ากับ 5 โดยค่าต่ำสุดของแต่ละเครื่องมือวัดประสิทธิภาพมีดังนี้

- MSE เท่ากับ 0.0571
- RSME เท่ากับ 0.2390

- MAPE เท่ากับ 2.0009%

โดยใช้เวลาในการฝึกข้อมูล 16.96 วินาที ซึ่งสามารถดูข้อมูลเพิ่มเติมได้จากตาราง 24 ใน ส่วนของภาคผนวก

4.5 แบบจำลอง CNN-GRU (Convolutional Neural Network + GRU)

การเปรียบเทียบผลลัพธ์จากการใช้เทคนิค CNN-GRU (Convolutional Neural Network + GRU) ได้ผลการดำเนินการดังตาราง 19

ตาราง 19 การเปรียบเทียบประสิทธิภาพของแบบจำลอง CNN-GRU

Learning Rate	Batch Size	Epochs	MSE	RMSE	MAPE (%)
10^{-1}	1	5	0.0551	0.2347	1.9895
		8	0.0583	0.2415	2.3233
		10	0.0538	0.2320	2.0072
	4	5	0.0701	0.2648	2.1453
		8	0.0616	0.2483	2.0309
		10	0.0623	0.2496	2.0567
10^{-2}	1	5	0.0819	0.2862	2.3296
		8	0.0728	0.2699	2.1665
		10	0.0670	0.2588	2.1069
	4	5	0.2534	0.5034	4.5804
		8	0.1772	0.4210	3.4753
		10	0.1086	0.3295	2.5267

จากตาราง 19 อธิบายผลการดำเนินการของแบบจำลอง CNN-GRU ได้ผลลัพธ์ดังนี้

1. ในกรณีใช้เครื่องมือวัดประสิทธิภาพด้วย MSE ได้ประสิทธิภาพที่ดีที่สุดเมื่ออัตราการเรียนรู้ (Learning Rate) เท่ากับ 10^{-1} ขนาดของกลุ่มข้อมูล (Batch Size) เท่ากับ 1 และจำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs) เท่ากับ 5 โดยได้ค่า MSE ต่ำสุดที่ 0.0551

2. ในกรณีใช้เครื่องมือวัดประสิทธิภาพด้วย RMSE ได้ประสิทธิภาพที่ดีที่สุดเมื่ออัตราการเรียนรู้ (Learning Rate) เท่ากับ 10^{-1} ขนาดของกลุ่มข้อมูล (Batch Size) เท่ากับ 1 และจำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs) เท่ากับ 10 โดยได้ค่า RMSE ต่ำสุดที่ 0.2320

3. ในกรณีใช้เครื่องมือวัดประสิทธิภาพด้วย MAPE ได้ประสิทธิภาพที่ดีที่สุดเมื่ออัตราการเรียนรู้ (Learning Rate) เท่ากับ 10^{-1} ขนาดของกลุ่มข้อมูล (Batch Size) เท่ากับ 1 และจำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs) เท่ากับ 5 โดยได้ค่า MAPE ต่ำสุดที่ 1.9895%

เมื่อทำการเปรียบเทียบการปรับค่าไฮเปอร์พารามิเตอร์ที่ดีที่สุดของแบบจำลอง CNN-GRU พิจารณาจากค่า MSE และ MAPE โดยใช้อัตราการเรียนรู้ (Learning Rate) เท่ากับ 10^{-1} ขนาดของกลุ่มข้อมูล (Batch Size) เท่ากับ 1 และจำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs) เท่ากับ 5 ซึ่งการใช้ค่านี้ให้ค่า MSE ต่ำสุดที่ 0.0551 และค่า MAPE ต่ำสุดที่ 1.9895% โดยใช้เวลาในการฝึกข้อมูล 19.19 วินาที ซึ่งสามารถดูข้อมูลเพิ่มเติมได้จากตาราง 25 ในส่วนของภาคผนวก

ในบทนี้ได้แสดงผลลัพธ์จากการศึกษาวิจัย โดยแบ่งผลลัพธ์จากเครื่องมือวัดประสิทธิภาพทั้ง 3 ประเภท ดังนี้

1. MSE พบว่า แบบจำลอง CNN-GRU เป็นแบบจำลองที่มีประสิทธิภาพสูงสุด โดยมีค่าอยู่ที่ 0.0551 ตามด้วยแบบจำลอง CNN-LSTM มีค่าอยู่ที่ 0.0571, แบบจำลอง GRU มีค่าอยู่ที่ 0.0832, แบบจำลอง LSTM มีค่าอยู่ที่ 0.0856 และแบบจำลอง RNNs มีค่าอยู่ที่ 0.0896 ตามลำดับ

2. RMSE พบว่า แบบจำลอง CNN-GRU เป็นแบบจำลองที่มีประสิทธิภาพสูงสุด โดยมีค่าอยู่ที่ 0.2320 ตามด้วยแบบจำลอง CNN-LSTM มีค่าอยู่ที่ 0.2390, แบบจำลอง GRU มีค่าอยู่ที่ 0.2884, แบบจำลอง LSTM มีค่าอยู่ที่ 0.2927 และแบบจำลอง RNNs มีค่าอยู่ที่ 0.2994 ตามลำดับ

3. MAPE (%) พบว่า แบบจำลอง CNN-GRU เป็นแบบจำลองที่มีประสิทธิภาพสูงสุด โดยมีค่าอยู่ที่ 1.9895 ตามด้วยแบบจำลอง CNN-LSTM มีค่าอยู่ที่ 2.0009, แบบจำลอง GRU มีค่าอยู่ที่ 2.3812, แบบจำลอง LSTM มีค่าอยู่ที่ 2.3866 และแบบจำลอง RNNs มีค่าอยู่ที่ 2.4216 ตามลำดับ

โดยรวมจากเครื่องมือวัดประสิทธิภาพทั้ง 3 เครื่องมือ พบว่า แบบจำลอง CNN-GRU เป็นแบบจำลองที่มีประสิทธิภาพสูงที่สุด ตามด้วยแบบจำลอง CNN-LSTM, แบบจำลอง GRU, แบบจำลอง LSTM และแบบจำลอง RNNs ตามลำดับ

บทที่ 5

สรุปผลการวิจัย อภิปรายผลการวิจัย และข้อเสนอแนะ

ในการวิจัยนี้ได้วัดประสิทธิภาพของแบบจำลอง 5 เทคนิค ได้แก่ แบบจำลอง RNNs (Recurrent Neural Networks), LSTM (Long Short-Term Memory), GRU (Gated Recurrent Unit), CNN-LSTM (Convolutional Neural Network + LSTM) และ CNN-GRU (Convolutional Neural Network + GRU) สำหรับพยากรณ์ออกซิเจนละลายในน้ำ เพื่อนำมาเปรียบเทียบและสรุปผล โดยสามารถแบ่งหัวข้อในการสรุปผลได้ดังต่อไปนี้

1. สรุปผลการวิจัย
2. อภิปรายผลการวิจัย
3. ข้อเสนอแนะ

5.1 สรุปผลการวิจัย

งานวิจัยนี้ใช้แบบจำลองทั้งหมด 5 เทคนิค ได้แก่ RNNs, LSTM, GRU, CNN-LSTM และ CNN-GRU โดยมุ่งเน้นการศึกษาวิเคราะห์และเปรียบเทียบประสิทธิภาพของแต่ละเทคนิค เพื่อค้นหาไฮเปอร์พารามิเตอร์ที่เหมาะสมสำหรับแต่ละเทคนิคสำหรับการพยากรณ์ระดับออกซิเจนละลายในน้ำ เพื่อนำไปปรับใช้ให้เกิดประสิทธิภาพสูงสุด โดยการวิเคราะห์และเปรียบเทียบแบ่งออกเป็น 3 รูปแบบ ได้แก่ ค้นหาแบบจำลองที่เหมาะสมที่สุดจาก 5 เทคนิค, ค้นหากลุ่มของแบบจำลองที่เหมาะสมจากการแบ่งแบบจำลองเป็น 2 กลุ่มใหญ่ ดังนี้

1. กลุ่มที่ไม่มีชั้นของเทคนิค CNN โดยแบบจำลองที่อยู่ในกลุ่มนี้ ได้แก่ แบบจำลอง RNNs, LSTM และ GRU
2. กลุ่มที่มีชั้นของเทคนิค CNN โดยแบบจำลองที่อยู่ในกลุ่มนี้ ได้แก่ แบบจำลอง CNN-LSTM และ CNN-GRU

และค้นหาแบบจำลองที่เหมาะสมที่สุดในแต่ละกลุ่มใหญ่

โดยการเปรียบเทียบประสิทธิภาพดังตาราง 20 สามารถอธิบายสรุปผลการดำเนินการวิจัยได้ดังนี้


1. แบบจำลอง CNN-GRU มีประสิทธิภาพสูงสุด โดยได้ค่าต่ำสุดในทุกเครื่องมือวัดประสิทธิภาพ คือ MSE เท่ากับ 0.0551, RMSE เท่ากับ 0.2347 และ MAPE เท่ากับ 1.9895% ตามด้วยแบบจำลอง CNN-LSTM มีค่า MSE เท่ากับ 0.0571, RMSE เท่ากับ 0.2390 และ MAPE เท่ากับ 2.0009%, แบบจำลอง GRU มีค่า MSE เท่ากับ 0.0832, RMSE เท่ากับ 0.2884 และ MAPE เท่ากับ 2.4884%, แบบจำลอง LSTM มีค่า MSE เท่ากับ 0.0856, RMSE เท่ากับ 0.2927 และ MAPE เท่ากับ 2.3866% และแบบจำลอง RNNs มีค่า MSE เท่ากับ 0.0896, RMSE เท่ากับ 0.2994 และ MAPE เท่ากับ 2.4216%
2. กลุ่มแบบจำลองที่มีชั้นของเทคนิค CNN ได้แก่ แบบจำลอง CNN-LSTM และ CNN-GRU มีประสิทธิภาพสูงกว่า กลุ่มแบบจำลองที่ไม่มีชั้นของเทคนิค CNN ได้แก่ แบบจำลอง RNNs, LSTM และ GRU
3. แบบจำลอง GRU มีประสิทธิภาพสูงสุด ในกลุ่มที่ไม่มีชั้นของเทคนิค CNN
4. แบบจำลอง CNN-GRU มีประสิทธิภาพสูงสุด ในกลุ่มที่มีชั้นของเทคนิค CNN
5. แบบจำลองที่ใช้การให้เทคนิค GRU ได้แก่ แบบจำลอง GRU และ CNN-GRU มีประสิทธิภาพสูงสุด ทั้งในกลุ่มที่มีและไม่มีชั้นของเทคนิค CNN

ตาราง 20 การเปรียบเทียบประสิทธิภาพของแบบจำลองทั้ง 5 เทคนิค

Model	Learning Rate	Batch Size	Epochs	MSE	RMSE	MAPE (%)
RNNs	10^{-2}	1	10	0.0896	0.2994	2.4216
LSTM	10^{-1}	1	5	0.0856	0.2927	2.3866
GRU	10^{-1}	1	10	0.0832	0.2884	2.4884
CNN-LSTM	10^{-1}	1	5	0.0571	0.2390	2.0009
CNN-GRU	10^{-1}	1	5	0.0551	0.2347	1.9895

5.2 อภิปรายผลการวิจัย

ในงานวิจัยนี้ได้ทำการวิเคราะห์ค่าออกซิเจนละลายน้ำจากข้อมูลประเภทอนุกรมเวลา (Time-Series Data) ที่ได้จากการพยากรณ์ผลลัพธ์จากชุดข้อมูลทดสอบ (Test Set) โดยใช้แบบจำลอง CNN-GRU ที่ทำการปรับแต่ง (Fine Tune) อัตราการเรียนรู้ (Learning Rate) เท่ากับ 10^{-1} ขนาดของกลุ่มข้อมูล (Batch Size) เท่ากับ 1 และ จำนวนรอบที่ใช้ในการฝึกชุดข้อมูล (Epochs) เท่ากับ 5 ซึ่งเป็นแบบจำลองที่มีประสิทธิภาพสูงสุด



ภาพประกอบ 12 แสดงกราฟเปรียบเทียบค่าจริงและค่าพยากรณ์ของแบบจำลอง CNN-GRU

จากภาพประกอบ 12 สามารถอธิบายการเปรียบเทียบค่าจริง (Actual คือ เส้นสีเทา) กับ ค่าที่ได้จากการพยากรณ์ (Predicted คือ เส้นปะสีแดง) ดังนี้


- ความแม่นยำของแบบจำลองมีแนวโน้มใกล้เคียงกับค่าจริงตลอดช่วงของข้อมูลทดสอบแสดงให้เห็นว่าแบบจำลองสามารถจับแนวโน้มของข้อมูลได้ดี
- ความสามารถในการติดตามแนวโน้มของข้อมูลในช่วงค่าต่ำ แบบจำลองสามารถพยากรณ์ได้อย่างแม่นยำ และในช่วงค่าที่เพิ่มสูงขึ้น แบบจำลองยังคงติดตามแนวโน้มของข้อมูลได้ดี แม้ว่าจะมีความผันผวนในบางช่วงของข้อมูล
- ข้อสังเกตเกี่ยวกับข้อผิดพลาด (Error) มีบางจุดที่ค่าพยากรณ์คลาดเคลื่อนจากค่าจริงพอสมควร โดยเฉพาะในช่วงที่ค่าของข้อมูลมีการเปลี่ยนแปลงอย่างรวดเร็ว จากกราฟที่เห็นได้ชัดเจน คือ ช่วงข้อมูลแกน X ระหว่าง 150 ถึง 200 และช่วงข้อมูลระหว่าง 250 ถึง 300

โดยรวมแบบจำลองสามารถจับแนวโน้มหลักของข้อมูลได้ แม้ว่าจะมีข้อผิดพลาดในช่วงของข้อมูลที่มีการเปลี่ยนแปลงอย่างรวดเร็ว แต่แบบจำลองสามารถใช้งานได้สำหรับการพยากรณ์ข้อมูลประเภทอนุกรมเวลา (Time-Series Data)


5.3 ข้อเสนอแนะ

ในงานวิจัยนี้ ผู้วิจัยได้มีข้อเสนอแนะเพื่อเป็นแนวทางในการพัฒนาต่อไปได้ ดังนี้

1. การเพิ่มจำนวนของชุดข้อมูลฝึกการเรียนรู้ (Training Set) ให้มากขึ้น เพื่อช่วยในการลดข้อผิดพลาดในช่วงที่ค่าของข้อมูลมีการเปลี่ยนแปลงอย่างรวดเร็ว
2. เพิ่มตัวแปร (Feature) อุณหภูมิ (Temperature) เพื่อให้ได้ข้อมูลที่ครอบคลุมมากขึ้น เนื่องจากอุณหภูมิเป็นปัจจัยสำคัญที่มีผลต่อระดับออกซิเจนละลายในน้ำ



ภาพประกอบ 13 แสดงกราฟค่าออกซิเจนละลายน้ำ (DO หรือ Dissolved Oxygen)



ภาพประกอบ 14 แสดงกราฟค่าอุณหภูมิ (Temperature)

จากภาพประกอบ 13 และภาพประกอบ 14 แสดงค่าออกซิเจนละลายน้ำและอุณหภูมิ จากชุดข้อมูลที่ใช้ในการวิจัยนี้ตามลำดับ จะเห็นได้ว่าออกซิเจนละลายน้ำและอุณหภูมามีความสัมพันธ์ผกผันกัน คือ เมื่ออุณหภูมิสูงขึ้น การละลายของออกซิเจนในน้ำลดลง

3. ในขั้น Convolutional หรือ CNN ทำการเพิ่มการปรับค่าไฮเปอร์พารามิเตอร์ (Fine-tuning Hyperparameter) เช่น ขนาดของ Kernal, จำนวนฟิวเตอร์ (Filters), ค่า Dropout เป็นต้น เพื่อช่วยให้แบบจำลองทำการเรียนรู้ตัวแปร (Feature) สำคัญได้ดีขึ้น ลด Overfitting และเพิ่มความสามารถของแบบจำลองในการทำงานกับข้อมูลใหม่ที่ไม่เคยเห็นมาก่อน (Generalization) หรือในช่วงที่ค่าของข้อมูลมีการเปลี่ยนแปลงอย่างรวดเร็ว ส่งผลให้การพยากรณ์มีความแม่นยำและมีประสิทธิภาพสูงขึ้น

4. ในขั้นตอนการฝึกแบบจำลองของแต่ละเทคนิคมีการแบ่งข้อมูล Validation คือ 10% (0.1) นั้น ควรใช้วิธีการกำหนดข้อมูล Validation เองตามช่วงเวลา เพื่อให้แบบจำลองถูกประเมินบนข้อมูลที่ยังไม่เคยเห็นมาก่อนในเชิงเวลา และเพื่อผลการประเมินสะท้อนประสิทธิภาพจริงของแบบจำลอง

5. เนื่องจากข้อมูลที่ใช้ในการวิจัยนี้เป็นข้อมูลที่มีความซับซ้อนไม่มาก จึงควรศึกษาแบบจำลองเทคนิคอื่นที่มีประสิทธิภาพในการพยากรณ์ข้อมูลเชิงอนุกรมเวลา (Time-Series) เช่น ARIMA หรือ SARIMA ที่เป็นเทคนิคการเรียนรู้เชิงลึก (Deep Learning) ที่เหมาะกับข้อมูลตัวแปรเดียว (Univariate) และข้อมูลที่มีฤดูกาล (Seasonality) หรือเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) เช่น Random Forest (RF) หรือ XGBoost ที่สามารถรองรับข้อมูลหลายตัวแปร ที่ใช้ทรัพยากรน้อยกว่าทั้งในเรื่องของเวลาและหน่วยความจำที่ใช้ในการฝึกการเรียนรู้ของแบบจำลอง

บรรณานุกรม

- Bhawna Bhatt, B. T., Himanshi Sharma. (2019). *Short Term and Long Term Water Quality Prediction Using Machine Learning* [Project Report for Bachelor of Technology in Information Technology].
- Bulbul Ali, A., และ Mishra, A. (2022). Effects of dissolved oxygen concentration on freshwater fish: a review. *International Journal of Fisheries and Aquatic Studies*, 10(4), 113-127. <https://doi.org/10.22271/fish.2022.v10.i4b.2693>
- Chen, Y., Song, L., Liu, Y., Yang, L., และ Li, D. (2020). A review of the artificial neural network models for water quality prediction. *Applied Sciences*, 10(17), 5776.
- Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., และ Campbell, J. P. (2020). Introduction to machine learning, neural networks, and deep learning. *Translational vision science & technology*, 9(2), 14-14.
- Dey, R., และ Salem, F. M. (2017, 6-9 Aug. 2017). Gate-variants of Gated Recurrent Unit (GRU) neural networks. 2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS),
- Fondriest Environmental, I. (2014, 7 Jan 2014). *Measuring Dissolved Oxygen*. <https://www.fondriest.com/environmental-measurements/measurements/measuring-water-quality/dissolved-oxygen-sensors-and-methods/>
- Fu, R., Zhang, Z., และ Li, L. (2016, 11-13 Nov. 2016). Using LSTM and GRU neural network methods for traffic flow prediction. 2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC),
- Kala, R. (2024). Chapter 12 - An introduction to machine learning and deep learning. ใน R. Kala, *Autonomous Mobile Robots* (569-625). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-443-18908-1.00022-4>
- Kosseva, M. R. (2013). Chapter 3 - Sources, Characterization, and Composition of Food Industry Wastes. ใน M. R. Kosseva และ C. Webb, *Food Industry Wastes* (37-60). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-12-391921-2.00003-2>

- Li, W., Wu, H., Zhu, N., Jiang, Y., Tan, J., และ Guo, Y. (2021). Prediction of dissolved oxygen in a fishery pond based on gated recurrent unit (GRU). *Information Processing in Agriculture*, 8(1), 185-193. <https://doi.org/https://doi.org/10.1016/j.inpa.2020.02.002>
- Pan, D., Zhang, Y., Deng, Y., Van Griensven Thé, J., Yang, S. X., และ Gharabaghi, B. (2024). Dissolved Oxygen Forecasting for Lake Erie's Central Basin Using Hybrid Long Short-Term Memory and Gated Recurrent Unit Networks. *Water*, 16(5), 707.
- Pörhö, H., Tomperi, J., Sorsa, A., Juuso, E., Ruuska, J., และ Ruusunen, M. (2023). Data-Based Modelling of Chemical Oxygen Demand for Industrial Wastewater Treatment. *Applied Sciences*, 13(13). https://mdpi-res.com/d_attachment/applsci/applsci-13-07848/article_deploy/applsci-13-07848-v2.pdf?version=1689058999
- Scientific, A. (2021). How To Test Dissolved Oxygen In Water. <https://atlas-scientific.com/blog/how-to-test-dissolved-oxygen-in-water/#:~:text=They%20either%20use%20the%20colorimetric,using%20galvanic%20or%20polarographic%20probes.>
- Scientific, A. (2022). How Does Dissolved Oxygen Get Into Water? <https://atlas-scientific.com/blog/how-does-dissolved-oxygen-get-into-water/>
- Tung, T. M., และ Yaseen, Z. M. (2020). A survey on river water quality modelling using artificial intelligence models: 2000–2020. *Journal of Hydrology*, 585, 124670.
- Wang, Y., Zhou, J., Chen, K., Wang, Y., และ Liu, L. (2017, 24-26 Nov. 2017). Water quality prediction method based on LSTM neural network. 2017 12th International Conference on Intelligent Systems and Knowledge Engineering (ISKE),
- Wikipedia. (2024a, Oct 9). *Long short-term memory*.
https://en.wikipedia.org/wiki/Long_short-term_memory#cite_note-calin2020-16
- Wikipedia. (2024b, Oct 10). *Recurrent neural network*.
https://en.wikipedia.org/wiki/Recurrent_neural_network
- Wikipedia. (2567). โครงข่ายประสาทเทียม.
<https://th.wikipedia.org/wiki/%E0%B9%82%E0%B8%84%E0%B8%A3%E0%B8%87%E0%B8%82%E0%B9%88%E0%B8%B2%E0%B8%A2%E0%B8%9B%E0%B8%A3%E0%B8%>

[B0%E0%B8%AA%E0%B8%B2%E0%B8%97%E0%B9%80%E0%B8%97%E0%B8%B5%E0%B8%A2%E0%B8%A1](#)

Xiao, Z., Peng, L., Chen, Y., Liu, H., Wang, J., และ Nie, Y. (2017). The dissolved oxygen prediction method based on neural network. *Complexity*, 2017(1), 4967870.

Ye, Q., Yang, X., Chen, C., และ Wang, J. (2019, 3-5 June 2019). River Water Quality Parameters Prediction Method Based on LSTM-RNN Model. 2019 Chinese Control And Decision Conference (CCDC),

Zhu, M., Wang, J., Yang, X., Zhang, Y., Zhang, L., Ren, H., Wu, B., และ Ye, L. (2022). A review of the application of machine learning in water quality evaluation. *Eco-Environment & Health*, 1(2), 107-116.

<https://doi.org/https://doi.org/10.1016/j.eehl.2022.06.001>



ภาคผนวก

ตาราง 21 แสดงเวลาในการเรียนรู้และค่าจาก Loss Function (MSE) ของแบบจำลอง RNNs

Learning Rate	Batch Size	Epochs	Training Time (sec)	Average Train	Average Validation	Evaluate Train
10^{-1}	1	5	16.86	0.0021	0.0056	0.0031
		8	22.06	0.0021	0.0054	0.0022
		10	34.26	0.0020	0.0049	0.0033
	4	5	5.13	0.0027	0.0050	0.0020
		8	6.95	0.0018	0.0050	0.0020
		10	11.88	0.0020	0.0050	0.0019
10^{-2}	1	5	19.81	0.0033	0.0051	0.0019
		8	30.52	0.0026	0.0051	0.0019
		10	32.92	0.0021	0.0050	0.0018
	4	5	6.10	0.0045	0.0086	0.0020
		8	9.39	0.0030	0.0068	0.0018
		10	9.47	0.0027	0.0065	0.0018

ตาราง 22 แสดงเวลาในการเรียนรู้และค่าจาก Loss Function (MSE) ของแบบจำลอง LSTM

Learning Rate	Batch Size	Epochs	Training Time (sec)	Average Train	Average Validation	Evaluate Train
10^{-1}	1	5	15.67	0.0043	0.0054	0.0018
		8	22.51	0.0037	0.0051	0.0021
		10	39.31	0.0029	0.0050	0.0018
	4	5	6.38	0.0130	0.0204	0.0020
		8	10.22	0.0081	0.0128	0.0018
		10	12.40	0.0069	0.0106	0.0018
10^{-2}	1	5	18.80	0.0270	0.0526	0.0103
		8	25.17	0.0137	0.0274	0.0027
		10	29.70	0.0115	0.0229	0.0021
	4	5	5.87	0.0475	0.0941	0.0433
		8	10.33	0.0360	0.0748	0.0291
		10	10.35	0.0362	0.0750	0.0270

ตาราง 23 แสดงเวลาในการเรียนรู้และค่าจาก Loss Function (MSE) แบบจำลอง GRU

Learning Rate	Batch Size	Epochs	Training Time (sec)	Average Train	Average Validation	Evaluate Train
10^{-1}	1	5	17.21	0.0025	0.0049	0.0022
		8	25.68	0.0024	0.0049	0.0018
		10	33.10	0.0022	0.0047	0.0019
	4	5	5.45	0.0048	0.0062	0.0019
		8	9.46	0.0041	0.0060	0.0018
		10	11.38	0.0030	0.0054	0.0018
10^{-2}	1	5	17.06	0.0104	0.0152	0.0019
		8	31.34	0.0068	0.0115	0.0018
		10	34.96	0.0057	0.0106	0.0018
	4	5	6.46	0.0288	0.0528	0.0142
		8	9.60	0.0283	0.0553	0.0124
		10	10.81	0.0129	0.0271	0.0034

ตาราง 24 แสดงเวลาในการเรียนรู้และค่าจาก Loss Function (MSE) แบบจำลอง CNN-LSTM

Learning Rate	Batch Size	Epochs	Training Time (sec)	Average Train	Average Validation	Evaluate Train
10^{-1}	1	5	16.96	0.0042	0.0040	0.0015
		8	28.98	0.0034	0.0042	0.0017
		10	40.34	0.0036	0.0039	0.0017
	4	5	6.48	0.0099	0.0107	0.0020
		8	10.17	0.0072	0.0086	0.0017
		10	13.34	0.0067	0.0082	0.0015
10^{-2}	1	5	19.94	0.0246	0.0420	0.0044
		8	27.37	0.0139	0.0235	0.0018
		10	42.15	0.0133	0.0227	0.0017
	4	5	5.97	0.0431	0.0840	0.0365
		8	11.37	0.0354	0.0700	0.0231
		10	13.18	0.0254	0.0494	0.0109

ตาราง 25 แสดงเวลาในการเรียนรู้และค่าจาก Loss Function (MSE) แบบจำลอง CNN-GRU

Learning Rate	Batch Size	Epochs	Training Time (sec)	Average Train	Average Validation	Evaluate Train
10^{-1}	1	5	19.19	0.0030	0.0038	0.0014
		8	28.69	0.0031	0.0041	0.0020
		10	38.80	0.0027	0.0042	0.0015
	4	5	7.06	0.0054	0.0047	0.0015
		8	13.97	0.0042	0.0043	0.0014
		10	13.76	0.0038	0.0041	0.0014
10^{-2}	1	5	24.72	0.0080	0.0079	0.0017
		8	36.29	0.0057	0.0065	0.0015
		10	40.89	0.0065	0.0079	0.0015
	4	5	8.46	0.0192	0.0308	0.0049
		8	12.62	0.0180	0.0314	0.0033
		10	12.77	0.0118	0.0203	0.0020

ประวัติผู้เขียน

