

การพยากรณ์ปริมาณน้ำท่าล่องหน้าแบบหลายขั้นตอน ในพื้นที่ลุ่มน้ำยมตอนบน Multi-Step Discharge Forecasting in The Upper Yom Basin

ศุภสัณห์ นาคะเวช^{1,*} วรณดี ไทยสยาม¹

¹ภาควิชาวิศวกรรมทรัพยากรน้ำ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ จ.กรุงเทพมหานคร

*Corresponding author; E-mail address: suphasan.nak@ku.th

บทคัดย่อ

พื้นที่ลุ่มน้ำยมตอนบนมักประสบปัญหาน้ำหลากเป็นประจำทุกปี เนื่องจากสภาพภูมิประเทศเป็นภูเขาและมีความลาดชันของพื้นที่สูง ประกอบกับไม่มีแหล่งเก็บกักน้ำในบริเวณพื้นที่ต้นน้ำ การพยากรณ์ปริมาณน้ำท่าเป็นหนึ่งในมาตรการป้องกันและบรรเทาความเสียหายจากอุทกภัยที่ส่งผลกระทบต่อชีวิตและทรัพย์สินของมนุษย์ ในงานศึกษานี้ได้พัฒนาแบบจำลองพยากรณ์น้ำท่าล่องหน้า 24 ชั่วโมงในพื้นที่ลุ่มน้ำยมตอนบนโดยใช้แบบจำลอง Recurrent Neural Networks (RNNs), Long Short-Term Memory networks (LSTMs) และ Gated Recurrent Units (GRUs) ร่วมกับการประยุกต์ใช้พารามิเตอร์ของการตอบสนองของเวลาในลุ่มน้ำ โดยใช้ข้อมูลจากสถานีวัดฝนจำนวน 8 สถานี และสถานีวัดน้ำท่าจำนวน 4 สถานี เพื่อเป็นข้อมูลนำเข้าสำหรับการฝึกฝนแบบจำลอง โดยแบ่งสัดส่วนชุดข้อมูลสำหรับการฝึกฝนแบบจำลอง (Training) 60% ตรวจสอบพิสูจน์แบบจำลอง (Validation) 20% และตรวจสอบแบบจำลอง (Testing) 20% ผลการศึกษาพบว่าแบบจำลอง GRUs สามารถพยากรณ์อัตราการไหลของน้ำท่าล่องหน้า 24 ชั่วโมงได้อย่างแม่นยำที่สุด โดยในช่วงตรวจสอบแบบจำลองมีค่าดัชนีทางสถิติ r, RMSE และ NSE คือ 0.9649, 19.7187 และ 0.9283 ตามลำดับ ซึ่งให้ผลที่ดีกว่าแบบจำลอง LSTMs และ RNNs ที่มีประสิทธิภาพลดหลั่นลงมา ผลการศึกษานี้แสดงให้เห็นว่าแบบจำลองมีความสามารถในการเรียนรู้และปรับตัวตามลักษณะข้อมูลที่เปลี่ยนแปลงได้ดี สามารถนำไปประยุกต์ใช้ประกอบการตัดสินใจในการบริหารจัดการน้ำและการเตือนภัยน้ำท่วมในพื้นที่ที่มีความเสี่ยงสูงจากน้ำท่วมได้อย่างมีประสิทธิภาพ

คำสำคัญ: การพยากรณ์น้ำท่า, การพยากรณ์แบบหลายขั้นตอน, การเรียนรู้เชิงลึก, ลุ่มน้ำยมตอนบน

Abstract

The upper Yom River basin often experiences flooding every year due to its mountainous terrain and steep slopes, coupled with the lack of water storage facilities in the upstream area. Discharge forecasting is one of the measures

for preventing and mitigating the damage caused by floods that affect human lives and property. This study developed a 24-hour runoff forecasting model for the upper Yom River basin using Recurrent Neural Networks (RNNs), Long Short-Term Memory networks (LSTMs), and Gated Recurrent Units (GRUs), combined with the application of watershed response time parameters. Data from 8 rainfall stations and 4 runoff stations were used as inputs to train the models, with 60% of the data allocated for training, 20% for model validation and 20% for model testing. The study found that the GRU model can most accurately predict water flow rates 24 hours in advance. The GRU model achieved r, RMSE and NSE values of 0.9649, 19.7187, and 0.9283, respectively, outperforming the LSTM and RNN models. The study demonstrates that the model can effectively learn and adapt to changing data patterns, making it suitable for water management decision-making and flood warning systems in flood-prone areas with high risk.

Keywords: Discharge Forecasting, Multi-Step Forecasting, Deep Learning, The Upper Yom Basin

1. บทนำ

ปัจจุบันเป็นที่ยอมรับกันทั่วไปแล้วว่า ภัยพิบัติทางธรรมชาติเช่น พายุ น้ำท่วม แผ่นดินถล่ม ความแห้งแล้ง ฯลฯ ได้มีส่วนก่อให้เกิดความเสียหายจำนวนมาก ทั้งในแง่ชีวิต และทรัพย์สินทั้งของส่วนรวม และส่วนตัว ทำให้รัฐบาลและประชาชนต้องใช้ทรัพยากรจำนวนมาก เพื่อบูรณะฟื้นฟูที่ได้รับ ความเสียหายจากภัยธรรมชาติ ยิ่งไปกว่านั้น ยังมีแนวโน้มว่าอนาคตอาจจะมีภัยทางธรรมชาติเกิดขึ้นบ่อยครั้งยิ่งขึ้น และความรุนแรงยิ่งขึ้นการคาดการณ์น้ำท่าให้ถูกต้องนั้น เป็นสิ่งจำเป็นอย่างมากในการบริหารจัดการทรัพยากรน้ำให้เกิดประโยชน์สูงสุด แบบจำลองการคาดการณ์น้ำท่าจึงเป็นเครื่องมือที่สำคัญสำหรับการวางแผนเพื่อรับมือกับภัยพิบัติได้อย่างมีประสิทธิภาพ

พื้นที่ลุ่มน้ำยมตอนบนมีพื้นที่ส่วนใหญ่ครอบคลุมบริเวณจังหวัดแพร่ ลักษณะวางตัวตามแนวเหนือ-ใต้ มีแม่น้ำยมเป็นแม่น้ำสายหลัก ไหลผ่านหุบเขาที่มีความลาดชันมาก มีที่ราบแคบริมแม่น้ำเป็นบางตอน ส่งผลให้การเคลื่อนที่ของปริมาณน้ำหลากที่เกิดจากฝนตกหนักทำให้พื้นที่บริเวณอำเภอเมืองจังหวัดแพร่ เกิดสภาพน้ำล้นตลิ่งและท่วมที่ราบน้ำท่วมถึง จากปัญหาอุทกภัยซ้ำซากที่เกิดขึ้น ส่งผลกระทบต่อวิถีชีวิตทรัพย์สินของประชาชน รวมถึงเศรษฐกิจในพื้นที่ [1] การพยากรณ์ปริมาณน้ำท่าล่วงหน้าที่เหมาะสมจะสามารถนำไปใช้ในการบริหารจัดการน้ำและการแจ้งเตือนภัยแก่ประชาชนในพื้นที่ได้รวมถึงการประยุกต์ใช้กับมาตรการรับมืออุทกภัยต่างๆให้มีประสิทธิภาพมากยิ่งขึ้น

การพยากรณ์ปริมาณน้ำท่ามีความสำคัญต่อการบริหารจัดการทรัพยากรน้ำอย่างมีประสิทธิภาพ โดยมีการนำแบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Networks, ANNs) มาใช้กันอย่างแพร่หลาย เนื่องจากสามารถเรียนรู้ความสัมพันธ์ที่ซับซ้อนระหว่างปัจจัยทางอุทกวิทยาได้ดี [2] ได้สรุปการประยุกต์ใช้ ANNs ในงานด้านอุทกวิทยาหลายด้าน เช่น การแปลงปริมาณฝนเป็นปริมาณน้ำท่า การพยากรณ์ปริมาณน้ำท่า และการพยากรณ์คุณภาพน้ำ ต่อมา ได้มีการพัฒนาแบบจำลองโครงข่ายประสาทเทียมแบบวนซ้ำ (RNNs) ซึ่งสามารถเก็บข้อมูลจากอดีตเพื่อนำไปวิเคราะห์ข้อมูลอนุกรมเวลาได้อย่างแม่นยำมากขึ้น การศึกษาของ Kumar และคณะ พบว่า RNNs มีประสิทธิภาพสูงกว่า Feedforward Neural Networks (FNNs) ในการพยากรณ์ปริมาณน้ำท่ารายเดือนของแม่น้ำ Hemavathi ประเทศอินเดีย [3] และในประเทศไทย ได้มีการศึกษาการใช้แบบจำลอง RNNs ร่วมกับเวลาของการเกิดน้ำท่าสูงสุด (T_c) เพื่อพยากรณ์ปริมาณน้ำท่าล่วงหน้า 24 ชั่วโมงในพื้นที่ลุ่มน้ำชีตอนบน จังหวัดชัยภูมิ โดยผลการศึกษาพบว่าแบบจำลองสามารถพยากรณ์ปริมาณน้ำท่าได้อย่างแม่นยำ [4] ในการศึกษานี้ได้เสนอแนวคิดการพยากรณ์อัตราไหล โดยใช้แบบจำลองการเรียนรู้เชิงลึก (Deep Learning) สำหรับการพยากรณ์อัตราการไหลรายชั่วโมงล่วงหน้า 24 ชั่วโมง ที่สถานีวัดน้ำท่า Y.1C อำเภอเมือง จังหวัดแพร่ และทำการเปรียบเทียบประสิทธิภาพของแบบจำลองการนำเข้าสู่ข้อมูลแต่ละกรณี เพื่อให้สามารถเพิ่มประสิทธิภาพในการพยากรณ์และนำผลพยากรณ์ไปใช้ในการติดตามสถานการณ์น้ำตลอดจนการวางแผนการแจ้งเตือนอุทกภัยในพื้นที่ต่อไป


2. การรวบรวมข้อมูลและวิธีการดำเนินงานวิจัย

ในการศึกษานี้เสนอการพัฒนาแบบพยากรณ์ปริมาณน้ำท่าในพื้นที่ศึกษาลุ่มน้ำยม (สถานี Y.1C) โดยใช้ข้อมูลปริมาณฝน และข้อมูลน้ำท่าร่วมกับโครงข่ายประสาทเทียมเชิงลึกแบบหลายขั้นตอน (Multi-Step) และได้มีการประยุกต์ใช้เวลาของการเกิดน้ำท่าสูงสุด (T_c) ในการช่วยกำหนดขอบเขตการนำเข้าสู่ข้อมูลย้อนหลัง เพื่อสร้างความสัมพันธ์ระหว่างปริมาณฝนและปริมาณน้ำท่าให้มีความเหมาะสมเชิงอุทกวิทยามากขึ้น โดยมีรายละเอียดและวิธีการดำเนินงานวิจัยดังต่อไปนี้


2.1 พื้นที่ศึกษา

ลุ่มน้ำยมตอนบนตั้งอยู่ทางตอนเหนือของประเทศไทย ขนาดพื้นที่ลุ่มน้ำ 7,749 ตารางกิโลเมตร พื้นที่ครอบคลุมจังหวัดลำปาง น่าน พะเยา และแพร่ ลักษณะลุ่มน้ำวางตัว ตามแนวเหนือ-ใต้ มีแม่น้ำยมเป็นแม่น้ำสายหลัก ซึ่งมีต้นกำเนิดจากดอยขุนยวมในทิวเขาผีปันน้ำในเขต อำเภอปง และอำเภอเชียงม่วน จังหวัดพะเยา ไหลผ่านหุบเขาที่มีความลาดชันมาก มีที่ราบแคบริมแม่น้ำ เป็นบางตอน เข้าสู่เขตจังหวัดแพร่ จากนั้นจะไหลออกสู่ที่ราบผืนใหญ่ ผ่านอำเภอสอง และอำเภอเมืองแพร่แล้วไหลลงทางใต้เข้าสู่อำเภอต่างๆของจังหวัดแพร่และจังหวัดสุโขทัยต่อไป

การแบ่งลุ่มน้ำสาขาในลุ่มน้ำยม ได้กำหนดตามผลการศึกษาของโครงการศึกษาทบทวนการแบ่งพื้นที่ลุ่มน้ำที่เหมาะสมสำหรับการบริหารจัดการทรัพยากรน้ำ และผลกระทบจากการแบ่งพื้นที่ลุ่มน้ำโดยสำนักงานทรัพยากรน้ำแห่งชาติ ปี 2562 ซึ่งในพื้นที่ลุ่มน้ำยมตอนบนประกอบไปด้วย 8 ลุ่มน้ำสาขา ได้แก่แม่น้ำยมตอนบนส่วนที่ 1 แม่น้ำควน แม่น้ำยมตอนบนส่วนที่ 2 น้ำบี แม่น้ำยมตอนบนส่วนที่ 3 แม่น้ำจาว แม่น้ำยมตอนกลางส่วนที่ 1 และแม่น้ำคำมี [6] รายละเอียดของแต่ละลำน้ำสาขาแสดงในรูปที่ 1 และสามารถแสดงเป็นแผนผังได้ตามรูปที่ 2 [7]



รูปที่ 1 แผนที่แสดงที่ตั้งสถานีวัดน้ำฝน (สสน.) และสถานีวัดน้ำท่า (กรมชลประทาน) ของลุ่มน้ำยม [7]



รูปที่ 2 แผนผังกลุ่มน้ำยม [7]

2.2 ข้อมูลน้ำฝน

ในรอบ 30 ปี (ปี 2531 - 2560) กลุ่มน้ำยมมีปริมาณฝนรายปีเฉลี่ยเท่ากับ 1,369 มิลลิเมตร ปริมาณน้ำฝนส่วนใหญ่จะเกิดขึ้นในช่วงฤดูฝนระหว่างเดือนพฤษภาคมถึงเดือนตุลาคม คิดเป็น 87.3% ของปริมาณฝนรายปี โดยเดือนที่มีฝนตกสูงสุดได้แก่เดือนสิงหาคม มีปริมาณฝนเฉลี่ย 258.1 มิลลิเมตร [5-6]

ข้อมูลปริมาณน้ำฝนรายชั่วโมงที่ใช้เป็นข้อมูลนำเข้าสำหรับการฝึกฝนแบบจำลองนั้น ได้มาจากเว็บไซต์ของสถาบันสารสนเทศทรัพยากรน้ำ [8] ซึ่งมีสถานีวัดน้ำฝนภายในลุ่มน้ำยมตอนบนทั้งหมด 13 สถานี ได้แก่ สถานีวัดน้ำฝน BLUG, CGMN, CHHA, LGTI, NMKI, PONG, RGKG, SNGT, YOM001, YOM002, YOM003, YOM010 และ YOM011 โดยตำแหน่งที่ตั้งของแต่ละสถานีได้จากรูปที่ 1 เมื่อตรวจสอบข้อมูลด้วยวิธีเส้นโค้งทับทวี (Double-Mass Curve) พบว่ามีข้อมูลบางช่วงที่ขาดหายไป ดังนั้นผู้เขียนจึงเลือกใช้ข้อมูลจากสถานี CGMN, LGTI, NMKI, PONG, RGKG, YOM001, YOM002 และ YOM003 เพียงเท่านั้น เนื่องจากยังพอที่จะปรับแก้ส่วนที่ขาดหายไปได้ ซึ่งการปรับแก้ใช้นี้ใช้วิธีการถ่วงน้ำหนักระยะทางผกผัน (Inverse Distance Weighting, IDW) จากนั้นข้อมูลที่ถูกรับปรับแก้แล้วของทุกสถานีจะถูกแปลงเป็นข้อมูลปริมาณน้ำฝนตัวแทนด้วยวิธีแฟคเตอร์ธิเอสเซน (Thiessen Factor Method)

2.3 ปริมาณน้ำท่า

การศึกษาปริมาณน้ำท่าของกลุ่มน้ำยม [9] ประกอบด้วยการรวบรวมและวิเคราะห์ข้อมูลปริมาณน้ำท่า รายเดือนและรายปี การวิเคราะห์ความสัมพันธ์ระหว่างปริมาณน้ำท่ารายปีเฉลี่ยและพื้นที่รับน้ำฝน การวิเคราะห์ปริมาณน้ำท่าในแต่ละลุ่มน้ำสาขาและการวิเคราะห์แนวโน้มการเปลี่ยนแปลงปริมาณน้ำท่า โดยเป็นการรวบรวมข้อมูลปริมาณน้ำท่าจากสถานีวัดน้ำท่าจำนวน 15 สถานีที่กระจายตัวอยู่ทั่วทั้งลุ่มน้ำ

บริเวณพื้นที่ลุ่มน้ำยมตอนบนนั้น มีข้อมูลสถานีวัดน้ำท่าจำนวน 9 สถานี ซึ่งอยู่ในความรับผิดชอบของกรมชลประทาน ประกอบไปด้วย สถานีวัดน้ำท่า Y.36, Y.31, Y.24, Y.13A, Y.30, Y.20, Y.38, Y.34 และ Y.1C ดังแสดงในรูปที่ 1 โดยที่ข้อมูลน้ำท่ารายชั่วโมงนั้น ผู้เขียนได้รับความอนุเคราะห์จากสำนักบริหารจัดการน้ำและอุทกวิทยา กรมชลประทาน แต่เนื่องจากข้อมูลของบางสถานีมีการขาดช่วง ผู้เขียนจึงเลือกใช้เฉพาะข้อมูลที่ค่อนข้างครบถ้วนจาก 4 สถานี ได้แก่ Y.1C, Y.13A, Y.20 และ Y.31 ตารางที่ 1 สรุปสถานีวัดต่าง ๆ ที่ถูกใช้ในการการศึกษานี้

ตารางที่ 1 สถานีวัดน้ำฝนและสถานีวัดน้ำท่าที่ถูกเลือกใช้

สถานีวัดน้ำฝน	สถานีวัดน้ำท่า
CGMN, LGTI, NMKI, PONG, RGKG, YOM001, YOM002 และ YOM003	Y.1C, Y.13A, Y.20 และ Y.31

ข้อมูลที่น่ามาใช้เพื่อเป็นข้อมูลนำเข้าสำหรับฝึกฝนแบบจำลองนั้นเป็นข้อมูลน้ำท่ารายชั่วโมง ตั้งแต่ปี พ.ศ. 2555 ถึง 2564 ซึ่งได้จากการรวบรวมข้อมูลระดับน้ำและการแปลงข้อมูลเป็นอัตราการไหลรายชั่วโมงโดยใช้ Rating Table

2.4 โครงข่ายประสาทเทียมเชิงลึก

โครงข่ายประสาทเทียมเชิงลึก (Deep Learning) ใช้ ANNs ที่ประกอบด้วยหลายชั้นเชื่อมต่อกัน เรียกว่า Deep Neural Networks (DNNs) ซึ่งจำลองการทำงานของสมองมนุษย์ โดยมี 3 ชั้นหลัก ได้แก่ Input Layer, Hidden Layer และ Output Layer ข้อมูลจากภายนอกจะเข้าสู่ Input Layer ผ่านการประมวลผลใน Hidden Layer และส่งผลลัพธ์ออกจาก Output Layer [10]


การทำนายหลายขั้นตอน (Multi-Step Prediction) หมายถึงการทำนายหลายค่าในอนาคตจากข้อมูลในอดีต แทนที่จะทำนายแค่ค่าเดียวในอนาคต ซึ่งมักใช้ในงานที่เกี่ยวข้องกับการพยากรณ์ชุดข้อมูลตามลำดับเวลา เช่น การพยากรณ์ข้อมูลเชิงเวลา (Time Series Forecasting) การทำนายมีสองวิธีหลัก ได้แก่ การทำนายหลายขั้นตอนโดยตรง (Direct Multi-Step Prediction) ซึ่งโมเดลจะทำนายหลายขั้นตอนในครั้งเดียว และการทำนายหลายขั้นตอนแบบวนซ้ำ (Iterative Multi-step Prediction)

จากการศึกษาของ Kumar และคณะ [3] พบว่าแบบจำลอง RNNs มีประสิทธิภาพดีกว่าแบบจำลอง FNNs ดังนั้นงานวิจัยนี้จึงมุ่งเน้นศึกษาการทำนายหลายขั้นตอนโดยตรง โดยใช้แบบจำลอง RNNs, และแบบจำลองที่ถูกพัฒนาต่อยอดจาก RNNs ซึ่งได้แก่ LSTMs และ GRUs แบบจำลองเหล่านี้มักถูกใช้ในงานพยากรณ์ เพราะสามารถจับลำดับความสัมพันธ์ในข้อมูลที่มีลำดับเวลาได้ดี [10]

2.4.1 Recurrent Neural Networks (RNNs)

RNNs มีลักษณะพื้นฐานคล้ายกับ Neural Network แต่มีข้อแตกต่างคือ การเก็บ Hidden State ก่อนหน้าเอาไว้ สำหรับการคำนวณค่า Hidden State ณ ปัจจุบัน จะได้มาจากการนำค่า Hidden State ก่อนหน้า มาประมวลผลร่วมกับค่า input ณ เวลาปัจจุบัน

RNNs มีการทำงานในลักษณะป้อนค่า State ไปประมวลผล คือมีการวนเป็น Step โดยเมื่อคลี่ส่วนรอบออกมา (Unroll) จะแสดงดังรูปที่ 3 [11] ซึ่งมี RNNs เพียง Cell เดียว แต่แสดงให้เห็นถึงการทำงาน 3 รอบ



รูปที่ 3 โครงสร้างการทำงานของ RNNs [11]


2.4.2 Long Short-Term Memory Networks (LSTMs)

การทำงานภายใน LSTMs จุดเด่นอยู่ที่สถานะของเซลล์ (Cell state) สามารถเก็บ (Keep) หรือ ลืม (Forget) ข้อมูลสถานะก่อนหน้าได้ เปรียบเสมือน Cell state เป็นท่อส่งข้อมูลโดยในตัว LSTMs จะทำงานส่งสถานะข้อมูลที่สำคัญไปประมวลผลต่อ หรือลดค่าความสำคัญลง หรือจะทำการยกเลิกก็ได้ (ไม่ป้อนไปประมวลผลต่อ) ภายในเซลล์ LSTMs มี Sigmoid และ Tanh ซึ่งเป็น Neural Network ทำงานและมี Activation Function ดังแสดงในรูปที่ 4 [12] และสามารถสรุปรายละเอียดได้ดังนี้

Forget gate ควบคุมว่าจะเก็บหรือลืมข้อมูลก่อนหน้า โดยใช้ Sigmoid และคูณกับ Cell state เดิม เพื่อตัดค่าที่ไม่จำเป็น

Input gate ควบคุมการเพิ่มข้อมูลใหม่เข้าไปใน Cell state โดยใช้ Sigmoid และ Tanh เพื่อเลือกข้อมูลที่สำคัญ

Output gate กรองข้อมูลสุดท้ายก่อนส่งออกไปประมวลผลรอบถัดไป โดยใช้ Sigmoid และค่าที่ผ่าน Tanh




รูปที่ 4 โครงสร้างการทำงานของ LSTMs [12]

2.4.3 Gated Recurrent Units (GRUs)

GRUs เป็น Neural Network ที่เกิดหลัง LSTMs แต่จัดอยู่ในกลุ่ม RNNs เช่นกัน โดย GRUs มีลักษณะคล้าย LSTMs เพียงแต่ตัด Cell State ออกไป เหลือเพียง Hidden State และเหลือ Gate เพียง 2 ตัว คือ Reset gate และ Update Gate

Update Gate ทำหน้าที่ตัดสินใจว่าจะตัดอะไรทิ้ง หรือจะเพิ่มอะไรสำหรับส่งไปประมวลผลในรอบถัดไป ส่วน Reset Gate ทำหน้าที่ตัดสินใจว่าจะนำข้อมูลเก่าอะไรทิ้ง (Reset) ดังแสดงในรูปที่ 5 [12] จะเห็นได้ว่า GRUs มีการทำงานที่ซับซ้อนน้อยกว่า ดังนั้นจึงใช้ทรัพยากรน้อยกว่า ส่งผลให้การประมวลผลเร็วกว่า แต่ประสิทธิภาพโดยรวมอาจไม่ได้ดีกว่า LSTMs เสมอไป อย่างไรก็ตามโดยปกติแล้วจะทดลองเปรียบเทียบผลควบคู่กันไป [10]



รูปที่ 5 โครงสร้างการทำงานของ GRUs [12]

2.5 เวลาของการเกิดน้ำท่าสูงสุด Time of Concentration (T_C)

เวลาของการเกิดน้ำท่าสูงสุด (Time of Concentration, T_C) หมายถึง ช่วงเวลาตั้งแต่ที่ฝนใช้การมีการแผ่กระจายเชิงพื้นที่และเวลาอย่างสม่ำเสมอ ที่ส่งผลให้เกิดปริมาณน้ำท่าสูงสุด หรือในอีกความหมายหนึ่ง เวลาที่น้ำใช้เวลาเดินทางจากจุดที่ไกลสุดของพื้นที่ลุ่มน้ำในทางน้ำที่มีความยาวที่สุด จนถึงจุดออกของพื้นที่ลุ่มน้ำ

NRCS Velocity Method เป็นวิธีการทางชลศาสตร์ที่ใช้กันอย่างแพร่หลายในการประเมินเวลาของการเกิดน้ำท่าสูงสุด (T_C) ทั้งในกรณีการไหลบ่าบนผิวดินและการไหลในลำน้ำ โดยที่คุณลักษณะเฉพาะของพื้นที่ลุ่มน้ำ ค่าสัมประสิทธิ์ความขรุขระ และค่าความลาดชันมีความสัมพันธ์ต่อกัน [13] ในกรณีของการไหลในทางน้ำสายหลัก วิธีการนี้อ้างอิงจากวิธี NRCS Segmental Method ที่มีการแบ่งช่วงการไหลตามลักษณะการไหลที่สม่ำเสมอสำหรับการคำนวณการแบ่งช่วงเวลาการเดินทาง จะดำเนินการแบ่งแต่ละส่วนตามสมการ (1) ในขณะที่ เวลาของการเกิดน้ำท่าสูงสุด (T_C) รวมทั้งหมด จะถูกคำนวณโดยสมการ (2)

$$T_{C(i)} = 0.0167 \left[\frac{nL_{0,CH}}{R^{0.667} \sqrt{S_{0,CH}}} \right] \quad (1)$$

$$T_C = \sum_{i=1}^N T_{C(i)} \quad (2)$$

โดยที่ T_C คือ เวลาที่น้ำเดินทางจากจุดไกลสุดบนสันปันน้ำหรือสันเขาของตุ่มน้ำถึงจุดออกของลุ่มน้ำ (นาที่), $T_{C(i)}$ คือ เวลาที่น้ำเดินทางจากจุดไกลสุดบนสันปันน้ำหรือสันเขาของลุ่มน้ำถึงจุดออกของลุ่มน้ำของส่วนที่ i (นาที่), $L_{0,CH}$ คือ ความยาวของลุ่มน้ำจากจุดไกลสุดถึงจุดออก (เมตร), n คือ สัมประสิทธิ์ความขรุขระของ Manning's, R คือ รัศมีชลศาสตร์ ซึ่งเท่ากับ ความลึกของการไหล (เมตร), $S_{0,CH}$ คือ อัตราส่วน H/L หรือโดยประมาณ

เท่ากับความลาดชันเฉลี่ยของกลุ่มน้ำ และ H คือ ผลต่างของระดับที่จุดออก และจุดใกล้สุดบนสันเขา (เมตร)

การนำ T_c มาประยุกต์ใช้ร่วมกับแบบจำลองการเรียนรู้เชิงลึก เป็นการทำให้ช่วงของข้อมูลนำเข้ากับช่วงเวลาที่ผ่านมาที่มีความสัมพันธ์ที่ยั่งยืน ซึ่งจะสามารถเพิ่มประสิทธิภาพของแบบจำลองได้ไม่ว่าแบบจำลองนั้นจะใช้เครือข่ายในรูปแบบใดก็ตาม [14]

2.6 การประเมินประสิทธิภาพของแบบจำลอง

ในการศึกษานี้ได้ประยุกต์ใช้ดัชนีประสิทธิภาพจำนวน 3 ดัชนีในการตรวจสอบความถูกต้องระหว่างข้อมูลที่ประเมินได้จากแบบจำลองเทียบกับข้อมูลจากการตรวจวัดโดยประกอบด้วย Correlation Coefficient (r), Root Mean Square Error (RMSE) และ Nash-Sutcliffe's Efficiency (NSE) [15] ซึ่งคำนวณได้จากสมการ (3) ถึง (5) ตามลำดับโดยที่ r และ NSE จะมีค่าเข้าใกล้ 1 เมื่อค่าที่ประเมินได้จากแบบจำลองเข้ากันได้กับข้อมูลจากการตรวจวัด ในขณะที่ RMSE จะมีค่าเข้าใกล้ 0

$$r = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(X_i - \bar{X})}{\sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2 \sum_{i=1}^n (X_i - \bar{X})^2}} \quad (3)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (Y_i - X_i)^2} \quad (4)$$

$$NSE = 1 - \left[\frac{\sum_{i=1}^n (Y_i - X_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \right] \quad (5)$$

โดยที่ Y_i คือ ปริมาณน้ำท่าจากแบบจำลอง, X_i คือ ปริมาณน้ำท่าจากการตรวจวัด, $\bar{Y}$ คือ ค่าเฉลี่ยของปริมาณน้ำท่าจากแบบจำลอง, $\bar{X}$ คือ ค่าเฉลี่ยของปริมาณน้ำท่าจากการตรวจวัด, N คือ จำนวนข้อมูล และ i คือ ลำดับของอนุกรมข้อมูล

2.7 การปรับแต่งไฮเปอร์พารามิเตอร์

เพื่อให้แบบจำลองมีประสิทธิภาพมากที่สุด การเลือกไฮเปอร์พารามิเตอร์ที่เหมาะสมเป็นสิ่งสำคัญ ไฮเปอร์พารามิเตอร์เหล่านี้จะถูกกำหนดก่อนการฝึกฝนแบบจำลอง เทคนิคที่ใช้ในการปรับแต่งไฮเปอร์พารามิเตอร์ที่นิยม ได้แก่ การค้นหาแบบกริด (Grid Search), การค้นหาแบบสุ่ม (Random Search) และการปรับแต่งแบบเบย์เซียน (Bayesian Optimization) ใน การศึกษานี้ ได้เลือกใช้เทคนิคการค้นหาแบบสุ่ม [16] เนื่องจากเป็นวิธีที่ครอบคลุมและมีประสิทธิภาพโดยไม่ต้องทดลองทุกคอมบินชันเหมือนกับการค้นหาแบบกริด การเลือกชุดไฮเปอร์พารามิเตอร์ที่ดีที่สุด จะพิจารณาจากชุดที่ให้ค่าของฟังก์ชันความสูญเสีย (Loss Function) ที่น้อยที่สุด ซึ่งคำนวณจากข้อมูลช่วงตรวจสอบ (Validation Data)

2.8 วิธีการดำเนินงานวิจัย

การศึกษานี้เป็นการคาดการณ์ปริมาณน้ำท่าล่วงหน้า โดยใช้ ประยุกต์ใช้แบบจำลองการเรียนรู้เชิงลึก 3 แบบ ได้แก่ แบบจำลอง RNNs, แบบจำลอง LSTMs และแบบจำลอง GRUs แบบจำลองใช้ข้อมูลปริมาณฝนและข้อมูลปริมาณน้ำท่าเป็นข้อมูลนำเข้า (Input) และให้ข้อมูลน้ำท่ารายชั่วโมงเป็นข้อมูลส่งออก (Output) รวมถึงใช้ T_c ช่วยกำหนดขอบเขต

ของข้อมูลนำเข้า รูปที่ 6 แสดงแผนผังของวิธีการดำเนินงานวิจัย วิธีการศึกษามีรายละเอียดแสดงดังต่อไปนี้

1. รวบรวมข้อมูลระดับน้ำรายชั่วโมงและ Rating Table ของสถานีวัดน้ำท่ากรมชลประทานในลุ่มน้ำยมตอนบน 4 สถานี (Y.1C, Y13A, Y20 และ Y.31) ตั้งแต่ปี พ.ศ. 2555 ถึง พ.ศ. 2564 และนำข้อมูลระดับน้ำมาคำนวณอัตราการไหลรายชั่วโมงโดยใช้กราฟหรือสมการจาก Rating Table เพื่อแปลงระดับน้ำเป็นอัตราการไหลตามความสัมพันธ์ที่กำหนดใน Rating Table ของแต่ละสถานี

2. รวบรวมข้อมูลปริมาณฝนรายชั่วโมงของสถานีวัดน้ำฝน สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน) ในพื้นที่ลุ่มน้ำชีตอนบน จำนวน 8 สถานี โดยมีขอบเขตข้อมูลที่ใช้ตั้งแต่ปี พ.ศ. 2556 ถึง ปี พ.ศ. 2562 ได้แก่ สถานีวัดน้ำฝน CGMN, CHHA, LGTI, PONG, RGKG, YOM001, YOM002 และ YOM003 โดยสถานีที่มีข้อมูลที่ขาดหายเป็นระยะเวลานานจะพิจารณาไม่นำมาใช้ในการศึกษา ทำการตรวจสอบข้อมูลปริมาณฝนรายชั่วโมงด้วยวิธีเส้นโค้งทับทวี (Double-Mass Curve) และสำหรับข้อมูลฝนที่มีความผิดปกติจะทำการแก้ไขด้วยวิธีการถ่วงน้ำหนักระยะทางผกผัน (Inverse Distance Weighting, IDW)

3. ประเมินเวลาการเกิดน้ำท่าสูงสุด (Time of Concentration, T_c) ด้วยวิธี NRCS Velocity โดยจะทำการแบ่งลำน้ำออกเป็นช่วง ๆ ตามสภาพความลาดเอียงของลำน้ำ และหาค่า T_c ของแต่ละช่วง โดยใช้คาร์ทีเซียนศาสตร์ที่คำนวณจากระดับน้ำเฉลี่ย จากนั้นรวมค่า T_c ของทุกช่วงเข้าด้วยกัน

4. จัดเตรียมข้อมูลสำหรับนำเข้าแบบจำลอง โดยใช้ข้อมูลปริมาณฝนรายชั่วโมงและข้อมูลปริมาณน้ำท่าเพื่อพยากรณ์น้ำท่าล่วงหน้าสำหรับสถานีวัดน้ำท่า Y.1C โดยดำเนินการแบ่งข้อมูลออกเป็น 3 ชุดข้อมูล สำหรับการฝึกฝนแบบจำลอง (Training) 60% ตรวจสอบแบบจำลอง (Validation) 20% และตรวจสอบแบบจำลอง (Testing) 20%

5. พัฒนาแบบจำลองโดยใช้เวลาการเกิดน้ำท่าสูงสุด (T_c) เป็นขอบเขตของข้อมูลนำเข้าย้อนหลังในกระบวนการฝึกฝนแบบจำลองจะดำเนินการหาค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมในแต่ละแบบจำลอง (RNNs, LSTMs หรือ GRUs) จากนั้นจึงนำไปใช้ในการตรวจพิสูจน์แบบจำลองต่อไป

6. ประเมินประสิทธิภาพแบบจำลองประเมินประสิทธิภาพแบบจำลองในการศึกษาข้างต้น โดยใช้ข้อมูลปริมาณน้ำท่าที่ได้จากการตรวจวัดและปริมาณน้ำท่าที่ได้จากการพยากรณ์ที่สถานีวัดน้ำท่า Y.1C ด้วยดัชนีประเมินประสิทธิภาพ 3 ดัชนี ได้แก่ r , RMSE และ NSE


7. สรุปผลการศึกษา

3. ผลการศึกษา

3.1 ผลการพยากรณ์ปริมาณน้ำล่วงหน้ารายชั่วโมง

การพยากรณ์ปริมาณน้ำท่ารายชั่วโมงเทียบกับสถานีวัดน้ำท่า Y.1C ในพื้นที่ลุ่มน้ำยม ด้วยแบบจำลองโครงข่ายประสาทเทียมเชิงลึกแบบ RNNs, LSTMs และ GRUs โดยการประยุกต์ใช้ T_c เป็นขอบเขตการนำเข้าข้อมูลย้อนหลัง จากการคำนวณด้วยวิธี NRCS Velocity จะได้ T_c เท่ากับ 51

ชั่วโมง หลังจากทำการฝึกฝนแบบจำลอง จะได้กราฟค่าการสูญเสียดังรูปที่ 7 จะเห็นได้ว่ากราฟมีลักษณะค่อนข้างราบเรียบแสดงถึงแบบจำลองมีการเรียนรู้ที่ดีและให้ผลลัพธ์การพยากรณ์ซึ่งแสดงดังรูปที่ 8 จากรูปเป็นผลการพยากรณ์ล่วงหน้า 24 ชั่วโมงเปรียบเทียบกราฟน้ำท่าของข้อมูลที่ได้จากการพยากรณ์ (Predicted Flow) กับข้อมูลที่ได้จากการตรวจวัด (Observed Flow) จะสังเกตได้ว่าข้อมูลปริมาณน้ำท่าที่ได้จากแบบจำลองมีความใกล้เคียงกับข้อมูลที่ได้จากสถานีตรวจวัด เว้นแต่ในช่วงที่มีน้ำหลากแบบจำลองให้ค่าการพยากรณ์ที่ช้ากว่าความเป็นจริง (Delay) ประมาณ 14 ชั่วโมง และให้การไหลที่จุดยอดของกราฟ (Peak Flow) ได้ค่อนข้างสูงเกินไป โดยช่วงฤดูฝนซึ่งสังเกตได้ชัดเจนคือช่วงสิงหาคมของปี ค.ศ. 2020 แบบจำลองให้ค่าพยากรณ์สูงกว่าค่าตรวจวัดประมาณ 90-200 ลบ.ม.ต่อวินาที จากกราฟแสดงให้เห็นถึงการเปลี่ยนแปลงปริมาณน้ำท่าอย่างฉับพลัน สาเหตุหลักอาจมาจากสภาพภูมิประเทศเป็นพื้นที่ลาดชัน ส่งผลให้น้ำฝนไหลลงสู่ลำน้ำอย่างรวดเร็ว แบบจำลองพยายามเรียนรู้รูปแบบลักษณะการเกิดน้ำท่าดังกล่าว แต่ด้วยความซับซ้อนของปัจจัยต่าง ๆ ที่เกี่ยวข้อง เช่น ปริมาณฝน ความหนาแน่นของดิน การซึมผ่านน้ำ ความจุของลำน้ำทำให้เกิดความคลาดเคลื่อนของการพยากรณ์ที่สังเกตได้ชัดเจนในช่วงนี้




รูปที่ 6 แผนผังแสดงวิธีการดำเนินงานวิจัย

ทั้งนี้การที่จะนำแบบจำลองไปใช้งานจริง แบบจำลองจะต้องสามารถพยากรณ์ปริมาณน้ำท่าล่วงหน้าได้ก่อนพอสมควร โดยเฉพาะก่อนที่น้ำจะท่วมต้องมีเวลาให้ประชาชนเตรียมพร้อมรับมือได้อย่างทันท่วงที

ตารางที่ 2 ไฮเปอร์พารามิเตอร์ที่เหมาะสมสำหรับแบบจำลอง

ไฮเปอร์พารามิเตอร์	RNNs	LSTMs	GRUs
Batch size	32	64	128
Buffer size	15000	10000	15000
Epochs	150	250	200
Steps	250	250	250
Optimizer	RMSprop	RMSprop	RMSprop
Activation	Relu	Relu	Relu
Learning rate	0.001	0.001	0.001
Node	8	8	8
Dropout	-	0.2	-
Recurrent dropout	-	0.2	-




รูปที่ 7 กราฟค่าการสูญเสียของแบบจำลอง RNNs, LSTMs, GRUs

3.2 ประสิทธิภาพของโครงข่ายประสาทเทียม ในการพยากรณ์ปริมาณน้ำท่าล่วงหน้ารายชั่วโมง

การประเมินประสิทธิภาพของแบบจำลองสำหรับใช้พยากรณ์ปริมาณน้ำท่าที่ระยะเวลา 3, 6, 9, 12, 16, 18 และ 24 ชั่วโมงล่วงหน้าแสดงดังรูปที่ 9-11 และตารางที่ 3 ซึ่งเป็นการประเมินด้วยด้วยดัชนีทางสถิติจำนวน 3 ค่า


ได้แก่ r , RMSE และ NSE จะเห็นว่าเมื่อระยะเวลาของการพยากรณ์ล่วงหน้าเพิ่มขึ้นประสิทธิภาพของการพยากรณ์จะลดลง สังเกตได้จากค่า r และ NSE ที่มีค่าน้อยลง และค่า RMSE ที่มากขึ้น แบบจำลอง GRUs สามารถพยากรณ์ได้มีความแม่นยำมากที่สุด โดยสำหรับการพยากรณ์ล่วงหน้า 24 ชั่วโมงนั้น แบบจำลอง GRUs มีค่าดัชนี r , RMSE และ NSE คือ 0.9649, 19.7187 และ 0.9283 ตามลำดับ แบบจำลอง LSTMs มีค่าดัชนี r , RMSE และ NSE คือ 0.9581, 22.3544 และ 0.9078 ตามลำดับ และแบบจำลอง RNNs มีค่าดัชนี r , RMSE และ NSE คือ 0.9500, 23.5502 และ 0.8977 ตามลำดับ จากกราฟจะเห็นได้ว่าแบบจำลองทั้งสามให้ลักษณะการกระจายตัวของข้อมูลที่เบี่ยงตัวลงมาอยู่ใต้เส้นทแยง หมายถึงแบบจำลองนั้นให้ค่าพยากรณ์ที่ต่ำกว่าค่าจริง ซึ่งสอดคล้องกับรูปที่ 8 ที่แสดงให้เห็นว่าในช่วงน้ำหลาก แบบจำลองจะพยากรณ์ได้ต่ำกว่าค่าที่วัดได้



รูปที่ 8 ผลการพยากรณ์ด้วยแบบจำลอง RNNs, LSTMs และ GRUs

ตารางที่ 3 ค่า r , RMSE และ NSE ของข้อมูลช่วงตรวจสอบแบบจำลอง


แบบจำลอง	RNNs			LSTMs			GRUs		
ชั่วโมงที่	R	RMSE	NSE	R	RMSE	NSE	R	RMSE	NSE
3	0.9983	4.4246	0.9964	0.9950	8.2476	0.9875	0.9985	4.2549	0.9967
6	0.9950	7.4443	0.9898	0.9927	9.7092	0.9826	0.9958	6.9912	0.9910
9	0.9905	10.2857	0.9805	0.9896	11.4595	0.9758	0.9927	9.1281	0.9846
12	0.9850	12.9201	0.9692	0.9859	13.2168	0.9678	0.9898	10.8777	0.9782
24	0.9500	23.5502	0.8977	0.9581	22.3544	0.9078	0.9649	19.7187	0.9283




รูปที่ 9 การประเมินประสิทธิภาพของแบบจำลอง RNNs

4. สรุปผลการศึกษา

จากผลการศึกษาแสดงให้เห็นถึงความสามารถของแบบจำลองโครงข่ายประสาทเทียมทั้งสามแบบซึ่งถูกพัฒนาในการศึกษาครั้งนี้โดยใช้ข้อมูลนำเข้าเพียงปริมาณฝนและข้อมูลปริมาณน้ำท่ารายชั่วโมงของสถานีวัดต้นน้ำมีความสามารถในการพยากรณ์ปริมาณน้ำท่าในพื้นที่ลุ่มน้ำยมในระดับที่ดี ถึงแม้ว่าการพัฒนาแบบจำลองจะมีความเรียบง่ายแต่แบบจำลองเหล่านี้มีความสามารถในการเรียนรู้ข้อมูลที่ซับซ้อน ซึ่งอาจทำได้ยากเมื่อใช้วิธีการทำแบบจำลองแบบดั้งเดิมที่ต้องการทรัพยากรที่สูง เมื่อเปรียบเทียบประสิทธิภาพของแบบจำลองทั้งสาม พบว่า แบบจำลอง GRUs มีประสิทธิภาพที่สูงที่สุด สังเกตได้จากการที่มีค่า R และ NSE ที่มากที่สุด และ RMSE ที่น้อยที่สุด แบบจำลอง LSTMs มีประสิทธิภาพรองลงมา และแบบจำลอง RNNs นั้นมีประสิทธิภาพที่แย่ที่สุด ทั้งนี้ในช่วงที่มีน้ำหลากแบบจำลองทั้งสามให้ค่าการพยากรณ์ที่ต่ำกว่าความเป็นจริง ประมาณ 14 ชั่วโมง และให้ค่าการไหลที่จุดยอดของกราฟ ได้ค่อนข้างสูงกว่าค่าตรวจวัด อาจเป็นเพราะว่าในช่วงน้ำหลากลักษณะทางอุทกวิทยาของลำน้ำอาจมีการเปลี่ยนแปลงอย่างมีนัยสำคัญ เช่น รัศมีชลศาสตร์มีการเปลี่ยนแปลง จึงส่งผลทำให้ค่า T_c เปลี่ยนไปจากที่คำนวณไว้ตอนแรก ทำให้แบบจำลองไม่สอดคล้องกับความเป็นจริง อย่างไรก็ตาม การประยุกต์ใช้แบบจำลองแบบใหม่เหล่านี้ จะส่งผลให้การบริหารจัดการน้ำและเตรียมพร้อมรับมือกับภัยพิบัติมีประสิทธิภาพและรวดเร็วมากยิ่งขึ้น



รูปที่ 10 การประเมินประสิทธิภาพของแบบจำลอง LSTMs



รูปที่ 11 การประเมินประสิทธิภาพของแบบจำลอง GRUs

5. ข้อเสนอแนะ

ในสภาวะการไหลปกติ แบบจำลองสามารถพยากรณ์ปริมาณน้ำท่ารายชั่วโมงได้อย่างแม่นยำ ในขณะที่ช่วงที่มีน้ำหลาก แบบจำลองไม่สามารถพยากรณ์ได้อย่างทันทั่วทั้งที่ การนำแบบจำลองไปใช้เพื่อแจ้งเตือนน้ำท่วมจึงยังไม่มีประสิทธิภาพดีเท่าที่ควร สาเหตุอาจเป็นเพราะช่วงน้ำหลาก ค่า T_c นั้นแตกต่างจากช่วงการไหลปกติ การพยากรณ์ให้แม่นยำขึ้น อาจใช้แบบจำลองคู่ขนาน ซึ่งถูกฝึกฝนด้วย T_c คนละค่ากัน และเลือกใช้แบบจำลองที่เหมาะสมตามสภาวะการไหล ณ ช่วงเวลานั้น ๆ แบบอัตโนมัติ

กิตติกรรมประกาศ

งานวิจัยครั้งนี้สามารถสำเร็จลุล่วงไปได้ด้วยดีด้วยความกรุณาและความช่วยเหลืออย่างดียิ่งจากสำนักบริหารจัดการน้ำและอุทกวิทยา กรมชลประทาน ที่กรุณาให้ความอนุเคราะห์ข้อมูลน้ำท่ารายชั่วโมงของกลุ่มน้ำยม รวมถึงขอขอบพระคุณอาจารย์ประจำภาควิชาวิศวกรรมทรัพยากรน้ำ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ ที่ได้ให้คำแนะนำ แนวทาง และการสนับสนุนทางวิชาการอย่างดีตลอดกระบวนการวิจัย ผู้วิจัยขอขอบพระคุณทุกท่านที่มีส่วนช่วยเหลือและทำให้การวิจัยครั้งนี้สำเร็จลุล่วงไปด้วยดี

เอกสารอ้างอิง

- [1] ศูนย์อุทกวิทยาชลประทานภาคเหนือตอนบนสำนักบริหารจัดการน้ำและอุทกวิทยา กรมชลประทาน (2563). รายงานสถานการณ์น้ำท่วมจังหวัดแพร่วันที่ 20 – 23 สิงหาคม 2563.
- [2] ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000). Artificial Neural Networks in Hydrologic Applications. Journal of Hydrologic Engineering, 2000 (5), pp. 124-137
- [3] Kumar, D.N., Raju, K.S., Sathish, T. (2004). River Flow Forecasting using Recurrent Neural Networks. Water Resources Management Kluwer Academic Publishers, 2004 (18), pp. 143-161
- [4] วริภาส พัฒนเจริญ. (2566). การพยากรณ์ปริมาณน้ำท่าล่วงหน้าด้วยแบบจำลองการเรียนรู้เชิงลึกในพื้นที่ลุ่มน้ำชีตอนบน. 16th THAICID National Symposium 2023. pp. 256-270
- [5] สำนักงานทรัพยากรน้ำแห่งชาติ (2564). ข้อมูลลุ่มน้ำยม.
- [6] สำนักงานทรัพยากรน้ำแห่งชาติ (2563). รายงานสรุปข้อมูลพื้นฐานของกลุ่มน้ำ ลุ่มน้ำยม โครงการจัดทำฐานข้อมูลพื้นฐานลุ่มน้ำ 22 ลุ่มน้ำ.
- [7] ศูนย์อุทกวิทยาชลประทานภาคเหนือตอนบนสำนักบริหารจัดการน้ำและอุทกวิทยา กรมชลประทาน. <https://www.hydro-1.net/>
- [8] สถาบันสารสนเทศทรัพยากรน้ำ.

https://tiservice.hii.or.th/opendata/data_catalog/hourly_rain/

- [9] สถาบันสารสนเทศทรัพยากรน้ำและการเกษตร (2555). การดำเนินการด้านการรวบรวมข้อมูลและวิเคราะห์ข้อมูลโครงการพัฒนาระบบคลังข้อมูล 25 กลุ่มน้ำ และแบบจำลองน้ำท่วมน้ำแล้งกลุ่มน้ำยม.บริษัท แอสติคอน คอร์ปอเรชั่น จำกัด.
- [10] กอบเกียรติ สระอุบล. (2565). เรียนรู้ AI: Deep Learning ด้วย Python. กรุงเทพฯ: สำนักพิมพ์ อินเทอร์เน็ตเดีย.
- [11] Borges P. (2018). Deep Learning: Recurrent Neural Networks, <https://medium.com/deeplearningbrasil/deep-learning-recurrent-neural-networks-f9482a24d010>
- [12] Phi M. (2018). Illustrated Guide to LSTM's and GRU's: A step by step explanation. <https://medium.com/towards-data-science/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21>
- [13] Seybert, T.A. (2006). In Stormwater Management for Land Development. John Wiley & Sons, Inc., pp.145-178.
- [14] Thaisiam, W., Saelo W., Wongchaisuwat, P. (2022). Enhancing a Multi-Step Discharge Prediction with Deep Learning and a Response Time Parameter. Water, 14, 2898.
- [15] วราวุธ วุฒิวิชัย. (2553). การวิเคราะห์ความแม่นยำของแบบจำลองโดยใช้ Nash-Sutcliffe Efficiency และ R^2 . สมาคมศิษย์เก่าวิศวกรรมชลประทานในพระบรมราชูปถัมภ์, หน้า 77-87.
- [16] Bergstra, J., and Bengio, Y. (2012). Random Search for Hyper-Parameter Optimization. Journal of Machine Learning Research, 13(Feb), pp. 281-305