

การพยากรณ์ปริมาณน้ำท่าแบบหลายจุดเวลาในแม่น้ำเพชรบุรี Multi-step Runoff Prediction in Phetchaburi River

จารุตา พึ่งแสง^{1*} และ วรณดี ไทยสยาม¹

¹ ภาควิชาวิศวกรรมทรัพยากรน้ำ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ กรุงเทพมหานคร

*Corresponding author; E-mail address: jaruda.pua@ku.th

บทคัดย่อ

สภาพปัญหาอุทกภัยในพื้นที่ อ.เมือง จ.เพชรบุรี มักมีสาเหตุมาจากปริมาณฝนตกหนักในพื้นที่ ร่วมกับปริมาณน้ำที่ระบายมาจากอ่างเก็บน้ำแก่งกระจาน ส่งผลทำให้ระดับน้ำในแม่น้ำเพชรบุรีเพิ่มสูงขึ้นและเกิดสถานการณ์น้ำล้นตลิ่ง ส่งผลให้เกิดน้ำท่วมในพื้นที่เศรษฐกิจ และบ้านเรือนประชาชน การพยากรณ์น้ำหลากล่วงหน้าจึงเป็นมาตรการที่สำคัญที่ช่วยในการแจ้งเตือน เตรียมแผนเผชิญเหตุ เพื่อลดความเสียหายต่อชีวิตและทรัพย์สินได้ การศึกษานี้ได้ประยุกต์ใช้แบบจำลองการเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Networks, RNNs) ในการพยากรณ์ปริมาณน้ำท่าล่วงหน้า 24 ชั่วโมงในพื้นที่จังหวัดเพชรบุรี บริเวณสถานีวัดน้ำท่า B.10 เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองการพยากรณ์แบบหลายจุดเวลาและการพยากรณ์แบบหนึ่งจุดเวลา โดยแบ่งกรณีศึกษาเป็น 2 กรณี ได้แก่ กรณีที่ 1 พยากรณ์ปริมาณน้ำท่าล่วงหน้าแบบหลายจุดเวลา (Multi – Step Discharge Forecasting) และกรณีที่ 2 พยากรณ์ปริมาณน้ำท่าล่วงหน้าแบบจุดเวลาเดียว (Single Step Discharge Forecasting) ผลการพยากรณ์พบว่าในช่วงฤดูน้ำหลากแบบจำลองสามารถพยากรณ์ปริมาณน้ำท่าสูงสุดได้ใกล้เคียงกับค่าตรวจวัด เนื่องจากการประยุกต์ใช้เวลาการเกิดน้ำท่าสูงสุด แต่ทั้งนี้ดัชนีทางสถิติที่ใช้ในการประเมินประสิทธิภาพของแบบจำลองทั้ง 2 กรณีนั้น มีค่าไม่แตกต่างกันมากนัก โดยเปรียบเทียบการพยากรณ์ล่วงหน้าในชั่วโมงที่ 6, 12 และ 24 สามารถสรุปได้ดังนี้ ค่า Nash - Sutcliffe's Efficiency (NSE) กรณีที่ 1 มีค่า 0.989, 0.960 และ 0.860 และกรณีที่ 2 มีค่า 0.984, 0.965 และ 0.793 จากผลการศึกษาแสดงให้เห็นถึงประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึกได้เป็นอย่างดี และสามารถนำไปประยุกต์ใช้ในการพยากรณ์ปริมาณน้ำท่าล่วงหน้าเพื่อใช้ในวางแผนการบริหารจัดการน้ำในช่วงอุทกภัยได้อย่างมีประสิทธิภาพ

คำสำคัญ: การพยากรณ์น้ำท่า, โครงข่ายประสาทเทียมแบบวนกลับ, แบบจำลองการเรียนรู้เชิงลึก

Abstract

Flooding in Mueang District, Phetchaburi Province, is often caused by heavy rainfall in the area, combined with water discharge from the Kaeng Krachan Reservoir. This results in rising water levels in the Phetchaburi River, leading to overflow and flooding in economic zones and residential areas. Flood forecasting is therefore a crucial measure for issuing early warnings and preparing response plans to minimize damage to lives and property. This study applied deep learning models using Recurrent Neural Networks (RNNs) to predict water flows 24 hours in advance at the B.10 runoff station, in order to compare the efficiency of multi-step forecasting and single step forecasting. The case study was divided into two scenarios for predicting water discharge: Case 1 involved Multi-Step forecasting, while Case 2 focused on Single-Step forecasting. The results indicated that during the peak flooding season, the model was able to forecast maximum water discharge values closely aligned with measured values, due to the application of the timing of peak water flows. However, the statistical indices used to evaluate the model's performance in both scenarios showed little difference. Specifically, when comparing forecasts made 6, 12, and 24 hours in advance, the Nash-Sutcliffe's Efficiency (NSE) values for Case 1 were 0.989, 0.960, and 0.860, while for Case 2, they were 0.984, 0.961, and 0.813. The results highlight the effectiveness of the deep learning model, demonstrating its potential application in forecasting water flows in advance for effective water management planning during flooding situations.

Keywords: Runoff Prediction, Recurrent Neural Networks (RNNs), Deep Learning

1. คำนำ

แม่น้ำเพชรบุรี เป็นแม่น้ำสายสำคัญของจังหวัดเพชรบุรี มีต้นกำเนิดจากเทือกเขาตะนาวศรีในเขตอำเภอแก่งกระจาน ไหลไปทางทิศเหนือมาบรรจบกับแม่น้ำบางกลอยไหลผ่านเขื่อนเพชร แล้วจึงไหลผ่านอำเภอยางชุมน้อย อำเภอเมืองเพชรบุรี ก่อนไหลลงสู่อ่างไทยที่อำเภอบ้านแหลม ที่ผ่านมาพบว่ามีน้ำเพชรบุรีเป็นพื้นที่หนึ่งที่มีประสบปัญหาอุทกภัยที่รุนแรงเนื่องจากฝนตกหนักด้านเหนือเขื่อนเพชร ร่วมกับปริมาณน้ำที่ระบายมาจากอ่างเก็บน้ำแก่งกระจาน ทำให้ปริมาณน้ำในแม่น้ำเพชรบุรีเพิ่มมากขึ้นเกินความจุกิตติของลำน้ำ และยังได้รับอิทธิพลจากน้ำทะเลหนุน ทำให้มีการระบายน้ำได้ช้า จึงทำให้พื้นที่ชุมชนและพื้นที่การเกษตรทั้งสองฝั่งตั้งแต่ท้ายเขื่อนเพชรลงไปได้รับผลกระทบเสียหาย [1]

การพยากรณ์ปริมาณน้ำท่าล่วงหน้าเป็นหนึ่งในเครื่องมือที่ใช้ในการประกอบการตัดสินใจที่ใช้ในการวางแผนและการจัดการทรัพยากรน้ำเพื่อเฝ้าระวังและเตรียมความพร้อมรับมือกับเหตุการณ์อุทกภัยที่จะเกิดขึ้นในอนาคต ซึ่งในปัจจุบันได้มีการนำ Machine Learning มาใช้ในทางด้านอุทกวิทยาอย่างกว้างขวาง เช่น การพยากรณ์ปริมาณน้ำท่า การพยากรณ์ปริมาณน้ำฝน และการเรียนรู้เชิงลึก (Deep Learning) ที่นิยมนำมาใช้ได้แก่ แบบจำลอง Artificial Neural Networks (ANNs), แบบจำลอง Recurrent Neural Network (RNNs), แบบจำลอง Long Short-Term Memory Network (LSTM) และแบบจำลอง Gated Recurrent Unit (GRU) [2] ทั้งนี้ได้มีการประยุกต์ใช้แบบจำลองที่กล่าวมาข้างต้นในการพยากรณ์ปริมาณน้ำท่าล่วงหน้า ร่วมกับพารามิเตอร์ที่มีผลต่อการพยากรณ์ปริมาณน้ำท่า นั่นคือ เวลาการเกิดน้ำท่าสูงสุด (Time of Concentration, T_c) ในพื้นที่ลุ่มน้ำชตอนบน โดยใช้ข้อมูลปริมาณน้ำท่ารายชั่วโมง และปริมาณน้ำฝนรายชั่วโมงของลุ่มน้ำชตอนบน ได้มีการแบ่งชุดข้อมูลเพื่อฝึกฝนแบบจำลองจำนวน 75 เปอร์เซนต์ และชุดข้อมูลสำหรับตรวจพิสูจน์แบบจำลองจำนวน 25 เปอร์เซนต์ จากผลการศึกษาแสดงให้เห็นว่าแบบจำลอง RNNs กรณีที่ข้อมูลนำเข้าใช้ข้อมูลปริมาณน้ำท่ารายชั่วโมงและปริมาณน้ำฝนรายชั่วโมง มีประสิทธิภาพในการพยากรณ์ปริมาณน้ำท่าล่วงหน้า 24 ชั่วโมงมากที่สุด [3] และยังมีการประยุกต์ใช้แบบจำลอง RNNs, LSTM และ GRU ในลุ่มน้ำ Yangtze ตอนบนของประเทศจีน โดยใช้ข้อมูลปริมาณน้ำท่ารายวันเพื่อทำการพยากรณ์ปริมาณน้ำท่าในช่วงเวลาที่แตกต่างกัน เช่น รายวัน รายสัปดาห์ รายเดือน เป็นต้น โดยผลการศึกษาแสดงให้เห็นว่าทั้ง 3 แบบจำลองนั้นไม่สามารถพยากรณ์ค่าปริมาณน้ำท่าสูงสุดในแต่ละช่วงเวลาได้ แต่การศึกษานี้ได้สรุปว่าช่วงเวลาย้อนหลัง (Time Lag) ของข้อมูลนำเข้า และช่วงเวลาในการพยากรณ์ข้อมูลล่วงหน้า (Lead Time) เป็น Parameter ที่ควรออกแบบให้เหมาะสมสำหรับแบบจำลองการเรียนรู้เชิงลึก เนื่องจากมีอิทธิพลต่อการพยากรณ์ปริมาณน้ำท่าในแต่ละช่วงเวลา [4] ทั้งนี้ยังมีการประยุกต์ใช้แบบจำลองการเรียนรู้เชิงลึก เช่น RNNs และ LSTM เพื่อแสดงให้เห็นถึงความไม่แน่นอนในการพยากรณ์ล่วงหน้าหลายจุดเวลาของอัตราการไหลในพื้นที่ที่กักเก็บน้ำอันประเทศจีน โดยใช้ทฤษฎี ANOVA, แนวทางการเลือกใช้แบบจำลองการเรียนรู้เชิงลึก และการออกแบบสถาปัตยกรรมของแบบจำลอง โดยข้อมูลที่เลือกใช้มีเหตุการณ์น้ำท่วมทั้งหมด 75 เหตุการณ์ แบ่งออกเป็น 5 ส่วน จากนั้นจะสร้างชุดตัวอย่างที่ประกอบด้วย Train set (4 ส่วน) Validation set (1 ส่วน) จากผลการศึกษาแสดงให้เห็นว่า 1. จากการประเมินการมีส่วนร่วมจากแหล่งความไม่แน่นอนต่างๆ ในการพยากรณ์อัตราการไหลจะแตกต่างกันตามระยะเวลาและอัตราการไหลที่เพิ่มขึ้น ซึ่งเน้นความสำคัญของการพิจารณาการมีปฏิสัมพันธ์ระหว่างส่วนประกอบต่างๆ ของแบบจำลอง 2. แบบจำลอง LSTM มีประสิทธิภาพดีกว่าแบบจำลอง RNNs

ในการพยากรณ์อัตราการไหล โดยเฉพาะในช่วงอัตราการไหลระดับกลาง และสูง สามารถการคาดการณ์เหตุการณ์น้ำท่วมได้อย่างมีประสิทธิภาพ 3. การออกแบบสถาปัตยกรรมของแบบจำลองมีความสำคัญไม่น้อยไปกว่าการเลือกวิธีการของแบบจำลองการเรียนรู้เชิงลึก โดยสถาปัตยกรรมที่ 2 แสดงประสิทธิภาพที่ดีกว่าสถาปัตยกรรมที่ 1 [5]


ในพื้นที่ลุ่มน้ำเพชรบุรี การเลือกใช้แบบจำลองโครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Networks, RNNs) มีความเหมาะสม เนื่องจากแบบจำลองนี้สามารถนำไปปรับใช้ในสถานการณ์ที่มีการเปลี่ยนแปลงของอัตราการไหลอย่างต่อเนื่อง เช่น กรณีที่ได้รับผลกระทบจากฝนตกหนักและการระบายน้ำจากอ่างเก็บน้ำแก่งกระจาน ซึ่งส่งผลให้น้ำในแม่น้ำเพชรบุรีมีพฤติกรรมไม่แน่นอน ดังนั้นการศึกษานี้จึงได้ประยุกต์ใช้แบบจำลองโครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Networks, RNNs) เพื่อพยากรณ์ปริมาณน้ำท่าล่วงหน้าในพื้นที่จังหวัดเพชรบุรี สำหรับนำไปใช้แจ้งเตือนเหตุการณ์อุทกภัยในพื้นที่

2. วิธีการศึกษา

2.1 พื้นที่ศึกษา

พื้นที่ศึกษาอยู่ในลุ่มน้ำเพชรบุรี - ประจวบคีรีขันธ์ (เฉพาะบริเวณลุ่มน้ำเพชรบุรี) มีพื้นที่รับน้ำ 4,158 ตร.กม ประกอบไปด้วย 3 ลุ่มน้ำย่อย ได้แก่ แม่น้ำเพชรบุรีตอนบน, ห้วยแม่ประจันต์ และแม่น้ำเพชรบุรีตอนล่าง

โดยมีแม่น้ำเพชรบุรีเป็นแม่น้ำสายหลักของกลุ่มน้ำ มีต้นกำเนิดที่เทือกเขาทางด้านตะวันตกของกลุ่มน้ำเพชรบุรี บริเวณอำเภอแก่งกระจาน พื้นที่จะค่อยๆ ลาดเทลงมาทางทิศตะวันออกบริเวณอำเภอยาง่าง ทางด้านตะวันตกของกลุ่มน้ำเพชรบุรีจะเป็นเทือกเขาสูงซึ่งเป็นที่กำเนิดของแม่น้ำสาขาสายสำคัญของลัดเข้ามาทางตอนกลางของกลุ่มน้ำจะมีลักษณะภูมิประเทศเป็นที่ราบลุ่มแม่น้ำ ซึ่งแม่น้ำเพชรบุรีจะไหลผ่านอ่างเก็บน้ำเขื่อนแก่งกระจานและเขื่อนเพชร ส่วนพื้นที่ตอนล่างทางด้านตะวันออกของกลุ่มน้ำมีลักษณะเป็นที่ราบลุ่มชายฝั่งทะเล มีลำน้ำสายสั้นๆ กระจายอยู่ทั่วไป ซึ่งลำน้ำส่วนใหญ่จะไหลลงสู่แม่น้ำเพชรบุรีและออกทะเลบริเวณอำเภอบ้านแหลม แสดงขอบเขตพื้นที่ศึกษากลุ่มน้ำเพชรบุรี ตำแหน่งและข้อมูลของสถานีวิจัยน้ำท่า ดังรูปที่ 1




รูปที่ 1 แผนที่แสดงขอบเขตพื้นที่ศึกษา และสถานีวิัดน้ำท่าในพื้นที่ศึกษา

2.2 ทฤษฎีและแบบจำลองที่ใช้ในการศึกษา

2.2.1 แบบจำลองโครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Networks, RNNs)

แบบจำลอง RNNs เป็นหนึ่งในแบบจำลองการเรียนรู้เชิงลึกที่มีการพัฒนาจาก Machine Learning โดยประยุกต์ใช้ความรู้ทางสถิติในการสังเคราะห์และทำนายผลลัพธ์จากข้อมูลซึ่งมีหลักการจากการเลียนแบบกระบวนการคิดและลักษณะเซลล์สมองของมนุษย์ โดย RNNs เป็นแบบจำลองที่มีการพัฒนาจากแบบจำลองโครงข่ายประสาทเทียมให้มีความเหมาะสมสำหรับการจัดการกับข้อมูลที่เป็นแบบลำดับเหตุการณ์ (Sequence) หรืออนุกรมเวลา (Time series) สำหรับหลักการการทำงานนั้นจะประกอบด้วย 3 ส่วน คือ Input Layer, Hidden Layer และ Output Layer โดย Input Layer จะรับข้อมูลจากภายนอกส่งไปที่ Hidden Layer ซึ่งทำหน้าที่ประมวลผลจากสิ่งที่ได้รับมาและส่งไปยัง Output Layer เพื่อส่งออกข้อมูลที่วิเคราะห์แล้ว โดยที่ RNNs ได้มีการออกแบบให้นำค่า Output ย้อนกลับไปเป็น Input อีกครั้ง กล่าวคือ จะนำเอาผลลัพธ์ที่ได้จากการคำนวณใน state ก่อนหน้ามาวิเคราะห์พร้อมกับ Input ที่ state ปัจจุบันเพื่อส่งออกผลลัพธ์ไปยัง state ถัดไป ดังรูปที่ 2



รูปที่ 2 โครงสร้างแบบจำลองโครงข่ายประสาทแบบวนกลับ
(Recurrent Neural Networks, RNNs)

2.2.2 เวลาการเกิดน้ำท่าสูงสุด (Time of Concentration, T_c)

เวลาการเกิดน้ำท่าสูงสุด (T_c) หมายถึง เวลาที่น้ำฝนที่ตกลงในส่วนต่างๆ ของลุ่มน้ำจะไหลมาถึงทางออกพร้อมๆ กัน ซึ่งจะเท่ากับเวลาที่น้ำใช้ในการไหลจากจุดที่ไกลที่สุดในเชิงชลศาสตร์ถึงทางออกของลุ่มน้ำ เวลานั้นน้ำท่าสูงสุดจะหาได้โดยการคำนวณหาระยะเวลาที่น้ำจะต้องไหลบนผิวดิน (Overland Flow) ผ่านส่วนต่างๆ ของลุ่มน้ำ ลงทางน้ำซึ่งการไหลจะเป็นแบบไหลในทางน้ำ (Channel Flow) และน้ำจะไหลลงสู่ทางน้ำที่มีขนาดใหญ่กว่าจนกระทั่งถึงทางออก

ในการหาเวลาการเกิดน้ำท่าสูงสุด (T_c) โดยวิธี NRCS Velocity Method เป็นวิธีการทางชลศาสตร์ที่ใช้ประเมินเวลาการเกิดน้ำท่าสูงสุดอย่างแพร่หลาย ทั้งในกรณีการไหลบนผิวดินและการไหลในลำ ซึ่งวิธีการดังกล่าวซึ่งจะแบ่งการไหลเป็นช่วงๆ ตามลักษณะของพื้นที่ลุ่มน้ำ เช่น ค่าสัมประสิทธิ์ความขรุขระ ค่าความลาดชันของลุ่มน้ำ โดยการประเมินเวลาการเกิดน้ำท่าสูงสุดของแต่ละพื้นที่ และของพื้นที่ลุ่มน้ำ ดังแสดงในสมการที่ (1) และ สมการที่ (2) ตามลำดับ

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

$$T_c = \sum_{i=1}^n T_{c(i)} \quad (2)$$

เมื่อ $T_{c(i)}$ คือ เวลาที่น้ำเดินทางจากจุดไกลสุดบนสันปันน้ำหรือสันเขาของลุ่มน้ำถึงจุดออกของลุ่มน้ำส่วนที่ i (นาที)

L_c คือ ความยาวของลำน้ำจากจุดไกลสุดถึงจุดทางออก (เมตร)

$L_{0,CH}$ คือ ความยาวของลำน้ำจากจุดไกลสุดถึงจุดทางออก (เมตร)

S_c คือ ความลาดชันเฉลี่ยของลุ่มน้ำ

$S_{0,CH}$ คือ ความลาดชันเฉลี่ยของลำน้ำ

n คือ สัมประสิทธิ์ความขรุขระของ Manning's

R คือ รัศมีชลศาสตร์ เท่ากับ ความลึกของการไหล (เมตร)

2.2.3 การประเมินประสิทธิภาพแบบจำลอง

การศึกษานี้ใช้ดัชนีประสิทธิภาพ จำนวน 3 ดัชนี สำหรับการตรวจสอบความถูกต้องของข้อมูลที่ได้จากแบบจำลองเทียบกับข้อมูลจากการตรวจวัด ประกอบด้วย ดัชนี Correlation Coefficient (R) ดัชนี Nash-Sutcliffe Efficiency (NSE) และ Root Mean Square Error (RMSE) ซึ่งมีความสัมพันธ์ดังสมการที่ (3) ถึง สมการที่ (5) ตามลำดับ โดยดัชนี R, NSE จะมีค่าเข้าใกล้ 1 เมื่อค่าที่ได้จากแบบจำลองเข้ากันได้กับข้อมูลจากการตรวจวัด ในขณะที่ RMSE จะมีค่าเข้าใกล้ 0

$$R = \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \quad (3)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad (5)$$

เมื่อ O_i คือ อัตราการไหลจากการตรวจวัด (ลบ.ม./วินาที),

P_i คือ อัตราการไหลจากการพยากรณ์ (ลบ.ม./วินาที),

$\bar{O}$ คือ อัตราการไหลจากการตรวจวัดเฉลี่ย (ลบ.ม./วินาที),

$\bar{P}$ คือ อัตราการไหลจากการพยากรณ์เฉลี่ย (ลบ.ม./วินาที)

n คือ จำนวนข้อมูล

2.3 วิธีการศึกษา


สำหรับวิธีการศึกษานี้ได้จัดทำแบบจำลองโครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Networks, RNNs) เพื่อพยากรณ์ปริมาณน้ำท่าล่วงหน้า 24 ชั่วโมงที่สถานีวัดน้ำท่า B.10 โดยแบ่งกรณีศึกษาเป็น 2 กรณี ได้แก่ กรณีที่ 1 พยากรณ์ปริมาณน้ำท่าล่วงหน้าแบบหลายจุดเวลา (Multi – Step Discharge Forecasting) และกรณีที่ 2 พยากรณ์ปริมาณน้ำท่าจุดเวลาเดียว (Single Step Discharge Forecasting) สำหรับขั้นตอนการศึกษาแสดงดังรูปที่ 3 รายละเอียดดังนี้

- รวบรวมข้อมูล ดำเนินการรวบรวมข้อมูลที่เกี่ยวข้องโดยครอบคลุมปี พ.ศ.2555 ถึงปีพ.ศ.2565 ซึ่งมีข้อมูลที่เกี่ยวข้องดังแสดงในตารางที่ 1 ประกอบด้วย ข้อมูลระดับน้ำรายชั่วโมง นำมาแปลงเป็นอัตราการไหลรายชั่วโมง โดยใช้ความสัมพันธ์ระหว่างระดับน้ำและอัตราการไหลจาก Rating Table ของแต่ละสถานี

ตารางที่ 1 แสดงข้อมูลสถานีน้ำในพื้นที่ศึกษา

ข้อมูล	รายชื่อสถานี	ช่วงปีข้อมูล
ระดับน้ำรายชั่วโมง	B.3A, B.8A, B.9, B.10, B.11	2555 - 2565

- การประเมินพารามิเตอร์เวลาทางอุทกวิทยา ดำเนินการประเมินข้อมูลลักษณะทางอุทกวิทยา ได้แก่ พื้นที่ลุ่มน้ำ ความยาวของลำน้ำ และข้อมูลความลาดชันของลำน้ำได้จากการใช้เครื่องมือในโปรแกรม ArcGIS โดยใช้ข้อมูล Digital Elevation Model (DEM) จากโครงการ Shuttle Radar Topography Mission (SRTM) ขององค์การบริหารการบินและอวกาศแห่งชาติ (NASA) ในการวิเคราะห์ค่า Profile ของลำน้ำ จากนั้นนำมาแทนในความสัมพันธ์ของสมการที่ (1) และ สมการที่ (2) เพื่อหาค่า T_c ของพื้นที่ศึกษาแสดงถึงเวลาที่น้ำฝนที่ตกลงในแต่ละพื้นที่ของลุ่มน้ำเดินทางมาถึงจุดออกพร้อมกัน ซึ่งมีค่าเท่ากับ 25 ชั่วโมง จากนั้นนำพารามิเตอร์เวลา T_c ที่ประเมินได้มาเป็นขอบเขตข้อมูลย้อนหลังของชุดข้อมูลน้ำเข้าแบบจำลองเพื่อการพยากรณ์อัตราการไหลล่งหน้า



รูปที่ 3 แผนผังแสดงขั้นตอนการศึกษา

- การจัดเตรียมข้อมูลเข้าสู่แบบจำลอง ซึ่งดำเนินการแบ่งข้อมูลออกเป็นชุดข้อมูลสำหรับฝึกฝนแบบจำลอง (Training) และข้อมูลสำหรับทดสอบแบบจำลอง (Testing) โดยใช้ข้อมูลปี พ.ศ.2555-2563 สำหรับการฝึกฝนแบบจำลอง และข้อมูลปี พ.ศ.2564-2565 สำหรับการทดสอบแบบจำลอง จากนั้นจัดเตรียมข้อมูลสำหรับน้ำเข้าแบบจำลอง โดยได้แบ่งกรณีศึกษาออกเป็น 2 กรณี ดังนี้
 - กรณีที่ 1 พยากรณ์ปริมาณน้ำท่าล่งหน้าแบบหลายจุดเวลา (Multi - Step Discharge Forecasting) คือการพยากรณ์ปริมาณน้ำท่าหลายค่าล่งหน้าต่อเนื่องในอนาคต ในการศึกษานี้จะทำการคาดการณ์ปริมาณน้ำท่าล่งหน้าทุกชั่วโมงตั้งแต่ชั่วโมงที่ 1-24
 - กรณีที่ 2 พยากรณ์ปริมาณน้ำท่าล่งหน้าแบบจุดเวลาเดียว (Single Step Discharge Forecasting) คือการพยากรณ์ปริมาณน้ำท่าล่งหน้าในช่วงเวลาเดียวเท่านั้น ในการศึกษานี้จะทำการคาดการณ์ปริมาณน้ำท่าล่งหน้า ณ ชั่วโมงที่ 6, 12 และ 24
- การพัฒนาแบบจำลอง โดยดำเนินการปรับค่าไฮเปอร์พารามิเตอร์ (hyperparameter) ให้เหมาะสมเพื่อให้แบบจำลองมีประสิทธิภาพสูงสุด ได้แก่ Batch size, Buffer size, Epochs, Steps และ Node โดย Batch size เป็นการกำหนดจำนวนข้อมูลที่ใช้ในการปรับค่าพารามิเตอร์แต่ละรอบการเรียนรู้ของแบบจำลอง, Buffer size ขนาดชุดข้อมูลที่เก็บไว้เพื่อการสุ่มตัวอย่างในการเรียนรู้, Epochs จำนวนรอบที่แบบจำลองจะเรียนรู้ข้อมูลทั้งหมด, Steps จำนวนการเรียนรู้ที่ต้องทำในแต่ละรอบของ Epoch และ Node จำนวนหน่วยประมวลผลในแต่ละชั้นของโครงข่ายประสาทเทียมแบบวนกลับ การปรับค่าไฮเปอร์พารามิเตอร์เหล่านี้จะดำเนินการควบคู่กันเพื่อเพิ่มประสิทธิภาพในการเรียนรู้ของแบบจำลอง โดยจะพิจารณาค่าที่เหมาะสมจาก MSE Loss Function ซึ่งเป็นตัวชี้วัดในการเลือกพารามิเตอร์ที่ดีที่สุด พร้อมทั้งสังเกตลักษณะของกราฟ Loss Function ที่มีค่าลดลงอย่างคงที่
- จากนั้นทำการพยากรณ์ปริมาณน้ำท่า 2 กรณี ได้แก่ 1) พยากรณ์ปริมาณน้ำท่าล่งหน้าชั่วโมงที่ 1 ถึง 24 2) พยากรณ์ปริมาณน้ำท่าล่งหน้า ณ ชั่วโมงที่ 6, 12 และ 24 และเปรียบเทียบประสิทธิภาพแบบจำลองด้วยดัชนีประสิทธิภาพ R, RMSE และ NSE
- สรุปผลการศึกษาเพื่อเปรียบเทียบประสิทธิภาพการพยากรณ์ปริมาณน้ำท่าล่งหน้า 24 ชั่วโมงของแบบจำลองที่ช่วงเวลาต่างๆ ทั้ง 2 กรณีศึกษา

3. ผลและวิจารณ์ผลการทดลอง

การพยากรณ์น้ำท่าล่งหน้า 24 ชั่วโมงที่สถานีวัดน้ำท่า B.10 ทั้ง 2 กรณี ด้วยแบบจำลอง RNNs ซึ่งใช้ค่าการสูญเสีย (Loss Function) ที่ประเมินด้วย Mean Squared Error (MSE) ของชุดข้อมูลฝึกฝนในช่วงปี พ.ศ.2555 - พ.ศ.2563 เป็นเกณฑ์ในการพิจารณาค่าพารามิเตอร์ที่เหมาะสม ผลการศึกษาพบว่าค่าพารามิเตอร์ที่เหมาะสมสำหรับแบบจำลองแสดงในตาราง 2 และตารางที่ 3 ซึ่งเป็นชุดพารามิเตอร์ที่ค่า MSE ที่มีแนวโน้มคงตัวสังเกตได้จากกราฟเส้นสีน้ำเงิน (Train Loss) และเส้นสีแดง


(Validation Loss) ที่มีลักษณะการลดลงและค่อนข้างคงที่ดังแสดงในรูปที่ 4

ตารางที่ 2 แสดงค่าพารามิเตอร์ที่เหมาะสมของแบบจำลองในกรณีที่ 1

Parameter กรณีที่ 1	Batch size	Buffer size	Epochs	Steps	Node	Learning rate
	128	20,000	200	200	0.01	128


ตารางที่ 3 แสดงค่าพารามิเตอร์ที่เหมาะสมของแบบจำลองในกรณีที่ 2

Parameter กรณีที่ 2	Batch size	Buffer size	Epochs	Steps	Node	Learning rate
ชั่วโมงที่ 6	64	20,000	100	200	128	0.01
ชั่วโมงที่ 12	512	20,000	100	200	128	0.01
ชั่วโมงที่ 24	64	20,000	100	200	64	0.01




รูปที่ 4 กราฟ Loss Function ที่ประเมินด้วยดัชนี MSE : กรณีที่ 1 พยากรณ์ปริมาณน้ำท่าล่วงหน้าแบบหลายจุดเวลา (A), กรณีที่ 2 พยากรณ์ปริมาณน้ำท่าล่วงหน้าจุดเวลาเดียว ณ ชั่วโมงที่ 6 (B), ชั่วโมงที่ 12 (C) และ ชั่วโมงที่ 24 (D)


เมื่อได้ชุดพารามิเตอร์สำหรับแบบจำลองที่เหมาะสม จึงนำพารามิเตอร์ชุดดังกล่าวมาทำการพยากรณ์ปริมาณน้ำท่าล่วงหน้าทั้ง 2 กรณี โดยใช้ชุดข้อมูลตรวจวัดปี พ.ศ. 2564 -พ.ศ.2565 เพื่อเปรียบเทียบกับผลพยากรณ์จากแบบจำลอง โดยนำผลการพยากรณ์น้ำท่าล่วงหน้า 24 ชั่วโมง ณ ชั่วโมงที่ 6, 12 และ 24 ของทั้ง 2 กรณี มาเปรียบเทียบกับข้อมูลน้ำท่าจากการตรวจวัด ดังกราฟแสดงปริมาณน้ำท่าในรูปที่ 5 โดยกรณีที่ 1 เส้นสีน้ำเงินแทนข้อมูลจากการตรวจวัดและเส้นสีแดงแทนข้อมูลจากการพยากรณ์ด้วยแบบจำลอง และกรณีที่ 2 เส้นสีน้ำเงินแทนข้อมูลจากการตรวจวัดและเส้นสีเขียวแทนข้อมูลจากการพยากรณ์ด้วยแบบจำลอง ผลการศึกษาแสดงให้เห็นว่าทั้ง 2 กรณีสามารถพยากรณ์อัตราการไหลได้ใกล้เคียงกับค่าตรวจวัด โดยกรณีที่ 1 ณ ชั่วโมงที่ 6 สามารถพยากรณ์ปริมาณน้ำท่าได้ใกล้เคียงกับค่าตรวจวัดทั้งในฤดูฝนและฤดูแล้ง ปริมาณน้ำท่าสูงสุดที่พยากรณ์ได้ มีค่าเท่ากับ 279.89 ลบ.ม./วินาที ในช่วงเวลาเดียวกัน กรณีที่ 2 ปริมาณน้ำท่าสูงสุดที่พยากรณ์ได้ มีค่าเท่ากับ 253.19 ลบ.ม./วินาที ซึ่งกรณีที่ 1 มีค่าพยากรณ์ปริมาณน้ำท่าที่ใกล้เคียงกับค่าจากการตรวจวัด คือ 277.85 ลบ.ม./วินาที และมีค่าประสิทธิภาพของแบบจำลองสูงที่สุด



(A)



(B)




(C)


รูปที่ 5 กราฟแสดงการพยากรณ์ปริมาณน้ำท่าล่วงหน้าเพื่อเปรียบเทียบผลการพยากรณ์กับผลจากการตรวจวัดของทั้ง 2 กรณี ณ ชั่วโมงที่ 6 (A), ชั่วโมงที่ 12 (B) และชั่วโมงที่ 24 (C)

นอกจากนี้ได้แสดงกราฟการกระจายตัวระหว่างอัตราการไหลจากการตรวจวัดและจากการพยากรณ์ในช่วงเวลา 6, 12 และ 24 ชั่วโมงล่วงหน้า ในกรณีที่ 1 พยากรณ์ปริมาณน้ำท่าล่วงหน้าแบบหลายจุดเวลา (Multi-Step Discharge Forecasting) และกรณีที่ 2 พยากรณ์ปริมาณน้ำท่าแบบจุดเวลาเดียว (Single Step Discharge Forecasting) ที่ขอบเขตข้อมูลนำเข้าย้อนหลัง 25 ชั่วโมง ดังแสดงในรูป 6 จากรูปจะเห็นว่าทั้ง 2 กรณีมีค่าอัตราการไหลพยากรณ์ที่ใกล้เคียงกับค่าอัตราการไหลตรวจวัดจะเห็นได้จากการกระจายตัวของจุดข้อมูลที่มีการเรียงตัวตามแนวเส้น 45° โดยเฉพาะการพยากรณ์ล่วงหน้าชั่วโมงที่ 6 แต่เมื่อชั่วโมงพยากรณ์ล่วงหน้ามากขึ้น การพยากรณ์มีแนวโน้มที่มีความคลาดเคลื่อนมากยิ่งขึ้น สังเกตได้จากข้อมูลมีการกระจายตัวออกจากเส้น 45° ในชั่วโมงพยากรณ์ที่ 12 และ 24 ชั่วโมงล่วงหน้า โดยในช่วงที่อัตราการไหลน้อยข้อมูลยังมีการเกาะกลุ่มกันตามแนวเส้น 45° แสดงถึงข้อมูลทั้งสองยังมีความสัมพันธ์กันค่อนข้างดี ในขณะที่ช่วงอัตราการไหลสูงพบว่าอัตราการไหลพยากรณ์มีค่าสูงกว่าอัตราการไหลตรวจวัด สังเกตได้จากจุดข้อมูลที่มีการกระจายตัวไปทางด้านบนของแนวเส้น 45° ซึ่งแสดงให้เห็นว่าแบบจำลองทั้งสองกรณีมีลักษณะของการพยากรณ์ที่สูงกว่าค่าตรวจวัด (Overprediction)


เมื่อพิจารณาประสิทธิภาพของแบบจำลองด้วยดัชนีประสิทธิภาพ R, RMSE และ NSE เพื่อประเมินประสิทธิภาพของแบบจำลองในการพยากรณ์ปริมาณน้ำท่าล่วงหน้า 24 ชั่วโมงล่วงหน้า ณ ชั่วโมงที่ 6, 12 และ 24 ดังแสดงในตารางที่ 4 จะเห็นว่ากรณีที่ 1 ณ เวลาที่ 6 และ 12 ชั่วโมง มีค่า NSE เท่ากับ 0.989 และ 0.960 ตามลำดับ และกรณีที่ 2 มีค่า NSE เท่ากับ 0.984 และ 0.965 ตามลำดับ ซึ่งมีค่ามีประสิทธิภาพของแบบจำลองสูงและใกล้เคียงกัน ในขณะที่ ณ ชั่วโมงที่ 24 กรณี 1 และกรณีที่ 2 มีค่าประสิทธิภาพแบบจำลองลดลง โดยมีค่า NSE เท่ากับ 0.860 และ 0.793 ตามลำดับ นอกจากนี้ยังพบว่าความถูกต้องของแบบจำลองจะมีค่าลดลงเมื่อชั่วโมงพยากรณ์เพิ่มมากขึ้นสังเกตได้จากแนวโน้มของค่า R และ NSE ที่ลดลง ในขณะที่ RMSE มีค่าเพิ่มขึ้นตามช่วงเวลาพยากรณ์ที่เพิ่มขึ้น แต่อย่างไรก็ตามแบบจำลองยังคงให้ผลการพยากรณ์ที่น่าเชื่อถือ



(A)



(B)



(C)

รูปที่ 6 กราฟเปรียบเทียบระหว่างผลการพยากรณ์ปริมาณน้ำท่าล่วงหน้ากับปริมาณน้ำท่าจากการตรวจวัดของทั้ง 2 กรณี ในชั่วโมงที่ 6 (A), ชั่วโมงที่ 12 (B) และชั่วโมงที่ 24 (C)

ตารางที่ 4 แสดงค่าดัชนีประเมินประสิทธิภาพของแบบจำลองทั้งกรณีที่ 1 และกรณีที่ 2

ดัชนีประเมินประสิทธิภาพแบบจำลอง		กรณีที่ 1	กรณีที่ 2
ชั่วโมงที่ 6	R	0.994	0.993
	RME	2.321	2.768
	NSE	0.989	0.984
ชั่วโมงที่ 12	R	0.983	0.984
	RME	4.405	4.145
	NSE	0.960	0.965
ชั่วโมงที่ 24	R	0.944	0.951
	RME	8.270	10.011
	NSE	0.860	0.793

4. บทสรุป

ผลการพยากรณ์ปริมาณน้ำท่าล่วงหน้า 24 ชั่วโมงในพื้นที่จังหวัดเพชรบุรี โดยใช้แบบจำลองการเรียนรู้เชิงลึกโครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Networks, RNNs) ร่วมกับการประยุกต์ใช้เวลาการเกิดน้ำท่าสูงสุด โดยพิจารณา 2 กรณีคือ กรณีที่ 1 พยากรณ์ปริมาณน้ำท่าล่วงหน้าแบบหลายจุดเวลา (Multi – Step Discharge Forecasting) กรณีที่ 2 พยากรณ์ปริมาณน้ำท่าจุดเวลาเดียว (Single Step Discharge Forecasting) โดยทำการเปรียบเทียบผลการพยากรณ์ปริมาณน้ำท่าล่วงหน้า ณ ชั่วโมงที่ 6, 12 และ 24 พบว่าการพยากรณ์ระยะสั้น ในช่วงเวลา ชั่วโมงที่ 6 และชั่วโมงที่ 12 กรณีที่ 2 มีค่าประสิทธิภาพแบบจำลองดีกว่า แต่ในการพยากรณ์ระยะยาว 24 ชั่วโมงล่วงหน้า กรณีที่ 1 มีค่าประสิทธิภาพแบบจำลองมากกว่ากรณีที่ 2

กิตติกรรมประกาศ

ขอขอบคุณบุคลากรกรมชลประทาน สถาบันสารสนเทศทรัพยากรน้ำ ที่ให้ความอนุเคราะห์สนับสนุนด้านข้อมูลที่เกี่ยวข้องในการศึกษานี้ รวมทั้งคณาจารย์ภาควิชาวิศวกรรมทรัพยากรน้ำ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ ที่ให้คำปรึกษาและคำแนะนำตลอดการศึกษาในครั้งนี้

เอกสารอ้างอิง

- [1] กรมชลประทาน (2566). การเฝ้าระวังกลุ่มน้ำเพชรบุรี จังหวัดเพชรบุรี. จุลสารวิชาการ สำนักบริหารจัดการน้ำและอุทกวิทยา, ปีที่ 10, ฉบับที่ 1
- [2] วรินทร์า แซ่โล้ (2566). การพยากรณ์ปริมาณน้ำท่าโดยใช้แบบจำลองการเรียนรู้เชิงลึกและพารามิเตอร์การตอบสนองของเวลา. วิทยานิพนธ์ปริญญาโท, มหาวิทยาลัยเกษตรศาสตร์.
- [3] รวิภาส พัฒนเจริญ (2565). การพยากรณ์ปริมาณน้ำท่าด้วยแบบจำลองการเรียนรู้เชิงลึกในพื้นที่ลุ่มน้ำชีตอนบน. วิทยานิพนธ์ปริญญาโท, มหาวิทยาลัยเกษตรศาสตร์.
- [4] Ren, Y., Zeng, S., Liu, J., Tang, Z., Hua, X., Li, Z., Xia, J. (2022). Mid- to Long-Term Runoff Prediction Based on Deep Learning at Different Time Scales in the Upper Yangtze River Basin. Water, 14 (11). doi:10.3390/w14111692
- [5] Song, T., Ding, W., Wu, J., Liu, H., Zhou, H., & Chu, J. (2019). Flash Flood Forecasting Based on Long Short-Term Memory Networks. Water, 12 (1). doi:10.3390/w12010109