

การพยากรณ์อัตราการไหลโดยใช้แบบจำลองโครงข่ายประสาทเทียมและพารามิเตอร์ การตอบสนองของเวลา

Discharge Prediction Using Artificial Neural Networks and Response Time Parameter

วรินตรา แซ่โล^{1,3}, พาพิศ วงษ์ชัยวัฒน์² และ วรณดี ไทยสยาม^{1,*}

¹ภาควิชาวิศวกรรมทรัพยากรน้ำ, คณะวิศวกรรมศาสตร์, มหาวิทยาลัยเกษตรศาสตร์ ลาดยาว จตุจักร

กรุงเทพมหานคร 10900

²ภาควิชาวิศวกรรมอุตสาหกรรม, คณะวิศวกรรมศาสตร์, มหาวิทยาลัยเกษตรศาสตร์ ลาดยาว จตุจักร

กรุงเทพมหานคร 10900

³ฝ่ายออกแบบ, ส่วนวิศวกรรม, สำนักงานชลประทานที่ 13, กรมชลประทาน ม่วงชุม ทาม่วง กาญจนบุรี 71110

Warintra Saelo^{1,3}, Papis Wongchaisuwat² and Wande Thaisiam^{1,*}

¹Department of Water Resources Engineering, Faculty of Engineering, Kasetsart University, Lad Yao, Chatuchak, Bangkok, 10900, Thailand

²Department of Industrial Engineering, Faculty of Engineering, Kasetsart University, Lad Yao, Chatuchak, Bangkok, 10900, Thailand

³Design Branch, Engineering Division, Regional Irrigation Office 13, Royal Irrigation Department, Muang Chum, Tha Muang, Kanchanaburi, 71110, Thailand

*Corresponding Author E-mail: wande.t@ku.th

Received: Feb 23, 2023; Revised: Jun 15, 2023; Accepted: Jun 21, 2023

บทคัดย่อ

การพยากรณ์น้ำท่าเป็นหนึ่งในมาตรการป้องกันที่สำคัญสำหรับการบรรเทาความเสียหายจากอุทกภัยที่ส่งผลกระทบต่อชีวิตและทรัพย์สินของมนุษย์ การพัฒนาแบบจำลองที่มีความซับซ้อนร่วมกับชุดข้อมูลที่มีอยู่อย่างเพียงพอจะช่วยให้ผลการคาดการณ์มีความแม่นยำยิ่งขึ้น ในการศึกษานี้ได้เสนอแนวคิดการพยากรณ์อัตราการไหลโดยใช้แบบจำลองโครงข่ายประสาทเทียมร่วมกับการประยุกต์ใช้พารามิเตอร์ของการตอบสนองของเวลาในกลุ่มน้ำ เพื่อพยากรณ์อัตราการไหลรายชั่วโมงล่วงหน้า 12 ชั่วโมง ในพื้นที่ลุ่มน้ำน่านตอนบนและลุ่มน้ำเลย ในการศึกษาได้จัดทำแบบจำลองเป็น 2 กรณี ได้แก่ กรณีที่ 1 การประยุกต์ใช้ค่าความสัมพันธ์ทางสถิติ (Case-Correl) และกรณีที่ 2 การประยุกต์ใช้พารามิเตอร์ของการตอบสนองของเวลา (Case-T_c) จากผลการศึกษาพบว่า ผลการพยากรณ์อัตราการไหลล่วงหน้า 12 ชั่วโมง ที่สถานีวัดน้ำท่า N.1 ของลุ่มน้ำน่านตอนบน และสถานีวัดน้ำท่า Kh.58A ของลุ่มน้ำเลย แบบจำลองในกรณีที่ 2 (Case-T_c) มีความแม่นยำในการพยากรณ์อัตราการไหลได้ดีกว่ากรณีที่ 1 (Case-Correl) ในทั้งสองลุ่มน้ำ นอกจากนี้ยังพบว่าแบบจำลองสามารถคาดการณ์อัตราการไหลในช่วงเวลาที่เกิดปริมาณน้ำท่าสูงสุด (Peak flow) ได้ใกล้เคียงกับค่าตรวจวัด โดยมีเปอร์เซ็นต์ความแตกต่างจากค่าตรวจวัดประมาณ 3–8% และ 8–11% สำหรับกรณี Case-T_c และ Case-Correl ตามลำดับ จากผลการศึกษาแสดงให้เห็นว่าแบบจำลองโครงข่ายประสาทเทียมที่ประยุกต์ใช้ร่วมกับพารามิเตอร์

การตอบสนองของเวลาในลุ่มน้ำมีประสิทธิภาพในการพยากรณ์น้ำท่าที่ล่วงหน้าได้เป็นอย่างดี และสามารถนำผลพยากรณ์ไปใช้เพื่อการติดตามสถานการณ์น้ำตลอดจนการวางแผนเตือนภัยน้ำท่วมในพื้นที่เป้าหมายต่อไปได้

คำสำคัญ: การพยากรณ์อัตราการไหล, พารามิเตอร์การตอบสนองของเวลา, โครงข่ายประสาทเทียม

Abstract

Flood forecasting is one of the most essential preventative measures for decreasing the damage caused by floods to human life and property. Developing advanced models in conjunction with a significant amount of available data will improve the accuracy of forecasts. This study proposes the concept of discharge forecasting utilizing a neural network model and the application of time response parameters in the watershed. To forecast the hourly discharge in the Upper Nan and Loei watersheds of 12 hours in advance. In this study, we investigated the model in the setting of two case studies: case 1, the application of statistical correlation (Case–Correl) and case 2, the application of the time response parameter (Case– T_C). From the study results, it showed that the outcomes of 12-hour advance discharge forecasting at runoff Station N.1 in Upper Nan Basin and runoff station Kh.58A in Loei Basin were as follows: Case 2 (Case– T_C) was more accurate than Case 1 (Case–Correl) in predicting flow rates in both watersheds. In addition, it was determined that the model accurately predicted the flow rate during the period of peak flow, with a deviation from the observed discharge approximately 3–8% and 8–11% for Case– T_C and Case–Correl examples, respectively. The results indicate that the neural network model applying with time response parameters has a high forecasting capability of flow rate. And the findings of the forecast can be used to monitor the water situation and prepare for flood warning in the target area.

Keywords: Discharge Prediction, Response Time Parameter, Artificial Neural Networks

1. บทนำ

การเปลี่ยนแปลงสภาพภูมิอากาศและการเปลี่ยนแปลงการใช้ประโยชน์ที่ดินในปัจจุบัน ส่งผลต่อสภาพการเกิดน้ำฝน น้ำท่า ในพื้นที่ประเทศไทย ทำให้เกิดสภาพแห้งแล้งที่ยาวนานขึ้นในช่วงฤดูแล้ง และมีความเข้มข้นมากขึ้นในช่วงฤดูฝน ซึ่งส่งผลให้เกิดอุทกภัยในหลายพื้นที่ของประเทศไทย ก่อให้เกิดความเสียหายต่อชีวิตและทรัพย์สินของประชาชน [1] การเตือนภัยล่วงหน้าจึงเป็นมาตรการสำคัญที่จะบรรเทาและลดผลกระทบต่อนิคมและทรัพย์สินได้ ดังนั้นการพยากรณ์น้ำท่าในพื้นที่เสี่ยงภัยน้ำหลากที่แม่นยำจึงมีความจำเป็นอย่างยิ่งที่จะทำให้การเตือนภัยล่วงหน้าได้อย่างมีประสิทธิภาพ ปัจจุบันการพยากรณ์น้ำท่าในพื้นที่ต่างๆ ของประเทศไทยได้มีการประยุกต์ใช้แบบจำลองน้ำฝน–น้ำท่าในหลายรูปแบบ อาทิเช่น ประยุกต์ใช้แบบจำลองน้ำฝน–น้ำท่า ประเภท Physical based distributed model [2–4] การประยุกต์ใช้แบบจำลองประเภท Lumped

conceptual model เพื่อพยากรณ์น้ำท่าโดยใช้ข้อมูลฝน [5–7] แบบจำลองดังกล่าวข้างต้นสามารถจำลองเหตุการณ์การเกิดน้ำท่าใกล้เคียงสภาพความเป็นจริงและมีความถูกต้องแม่นยำในระดับสูง อย่างไรก็ตามกระบวนการดังกล่าวนี้มีความยุ่งยากในการเตรียมข้อมูลด้านเข้าหลายชุดข้อมูล นอกจากนั้นแล้วยังต้องอาศัยความชำนาญในการสอบเทียบแบบจำลองเพื่อให้ได้มาซึ่งชุดพารามิเตอร์ที่เป็นตัวแทนของพื้นที่อีกด้วย ในปัจจุบันการประยุกต์ใช้ Data-driven model นิยมนำมาประยุกต์ใช้ในงานด้านวิศวกรรมทรัพยากรน้ำ สำหรับการคาดการณ์ข้อมูลต่าง ๆ ซึ่งให้ผลการประเมินอยู่ในระดับสูงไม่ด้อยไปกว่าแบบจำลองประเภทอื่น อีกทั้งยังใช้ข้อมูลนำเข้าที่ไม่ซับซ้อนและง่ายต่อการนำไปใช้งาน [8] โดยหนึ่งในวิธี Data-driven model ที่เป็นที่รู้จักกันทั่วไป คือ แบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Networks, ANNs) ซึ่งเป็นแบบจำลองที่มีโครงสร้างที่ไม่ซับซ้อน สามารถสร้างความสัมพันธ์ของ

ชุดข้อมูลได้ทั้งแบบเชิงเส้น (Linear) และแบบไม่เชิงเส้น (Nonlinear) จึงถูกนิยมนำมาใช้สำหรับงานด้านอุทกวิทยา โดยเฉพาะอย่างยิ่งการพยากรณ์น้ำท่า [9–12] นอกจากนี้แล้ว ANNs มักจะถูกนำมาใช้เป็นแบบจำลองพื้นฐานเพื่อเปรียบเทียบประสิทธิภาพกับแบบจำลอง Data-driven model ตัวอื่น ๆ [13–15] อาทิเช่น Parisouj และคณะ [15] ได้เปรียบเทียบประสิทธิภาพแบบจำลอง Data-driven model ประกอบด้วย SVR, ANN, และ ELM สำหรับการพยากรณ์น้ำท่ารายวันและรายเดือนใน 4 กลุ่มน้ำ ที่มีสภาพอากาศที่แตกต่างกันในประเทศสหรัฐอเมริกา ผลการศึกษาโดยรวมได้สรุปว่าแบบจำลอง SVR ให้ผลการประเมินดีที่สุด อย่างไรก็ตามจะเห็นได้ว่าแบบจำลอง ANN แสดงให้เห็นถึงผลการประเมินที่ไม่ได้แตกต่างอย่างมีนัยสำคัญกว่าแบบจำลองทั้งสอง โดยเฉพาะผลการประเมินในช่วงของการตรวจพิสูจน์ในลุ่มน้ำ Chehalis River ที่ ANN ให้ผลการประเมินดีที่สุด ในช่วงหลายปีที่ผ่านมา บรรดานักวิจัยได้พัฒนาอัลกอริทึมของ Data-driven model ให้มีประสิทธิภาพมากยิ่งขึ้น โดยการผสมผสานแบบจำลองเข้าไปมากกว่าหนึ่งแบบจำลอง หรือการเพิ่มเติมคุณลักษณะทางอุทกวิทยาเข้าไปเป็นหนึ่งในเงื่อนไขของแบบจำลองเพื่อให้สามารถเรียนรู้กระบวนการทางอุทกวิทยาได้มากยิ่งขึ้น สำหรับวิธีการแบบดั้งเดิมในการวิเคราะห์กราฟน้ำท่วม (Flood Hydrograph) ที่มีพารามิเตอร์ของการตอบสนองของเวลา อาทิเช่น Time of Concentration (T_c), Lag Time (T_L) และ Time to Peak (T_p) พารามิเตอร์เหล่านี้มักใช้เพื่อระบุลักษณะของพื้นที่รับน้ำ น้ำท่า ตลอดจนการกระจายปริมาณน้ำฝนที่มีประสิทธิภาพ [16] แนวคิด T_c มักจะนำมาใช้เพื่อคำนวณเวลาของการไหลที่ส่งผลต่อการระบายน้ำสูงสุดของกลุ่มน้ำจากจุดที่ไกลที่สุดจนถึงจุดออก [17] โดยพารามิเตอร์ T_c นั้นสามารถประเมินได้จากสมการเชิงประจักษ์ (Empirical formula) หลายหลายสมการ [16],[18–22] ซึ่งแต่ละสมการนั้นมักเกี่ยวข้องกับข้อมูลธรณีสัณฐานวิทยา และภูมิอากาศวิทยาของพื้นที่รับน้ำ รวมทั้งข้อมูลการไหลของน้ำบนพื้นดินและการไหลของน้ำในแม่น้ำลำธาร ซึ่งข้อมูลเหล่านี้จะถูกนำมาสร้างความสัมพันธ์โดยวิธี Stepwise


Multiple Regression Analysis [18],[23],[24] เพื่อประเมินค่าพารามิเตอร์ T_c ซึ่งพารามิเตอร์ดังกล่าวนี้จะถูกนำไปประยุกต์ใช้สำหรับการวิเคราะห์น้ำท่วมต่างๆ อาทิเช่น การทำนายปริมาณน้ำหลาก [25] การวิเคราะห์การเคลื่อนตัวของน้ำหลากในแม่น้ำ [26] และการออกแบบปริมาณน้ำหลากของระบบระบายน้ำ [24]

การประเมินเวลาการเกิดน้ำท่าสูงสุด (T_c) ด้วยวิธี NRCS velocity method ซึ่งพัฒนาโดย Natural Resources Conservation Service (NRCS) มักถูกนำมาใช้เพื่อประเมินค่า T_c สำหรับ Overland Flow และ Channel Flow [17],[27],[28] ซึ่งวิธีการดังกล่าวนี้จะแบ่งเส้นทางการไหลออกเป็นแต่ละส่วน จากนั้นจะคำนวณการเดินทางของน้ำเป็นช่วงๆ และรวมแต่ละส่วนเข้าด้วยกันจนเป็นพารามิเตอร์ T_c ที่เป็นตัวแทนของกลุ่มน้ำนั้น

ดังนั้นในการศึกษานี้ ได้นำเสนอแบบจำลองการพยากรณ์น้ำท่าแบบ Multi-Step Forecasting Model ตั้งแต่ชั่วโมงที่ 1 ถึง 12 โดยใช้ข้อมูลน้ำท่ารายชั่วโมงจากสถานีฝักระวังและสถานีเตือนภัยน้ำท่วมจากกรมชลประทานสำหรับพื้นที่ศึกษาในลุ่มน้ำน่านตอนบนและลุ่มน้ำเลย โดยแนวคิด T_c จะถูกนำมาประยุกต์ใช้เพื่อเพิ่มคุณลักษณะทางอุทกวิทยาให้กับแบบจำลองโครงข่ายประสาทเทียมเพื่อเพิ่มประสิทธิภาพให้กับผลการพยากรณ์น้ำท่า โดยเปรียบเทียบกับผลการประเมินด้วยกระบวนการสหสัมพันธ์ไขว้ (Cross correlation) แบบทั่วไป สำหรับวิธีการศึกษารวมทั้งกรอบแนวคิดได้ถูกสรุปไว้ในหัวข้อที่ 2 การวิเคราะห์ผลและการประเมินประสิทธิภาพของแบบจำลองได้รับการอธิบายอย่างละเอียดโดยระบุไว้ในหัวข้อที่ 3 และบทสรุปผลการศึกษาจะระบุไว้ในหัวข้อที่ 4

2. พื้นที่ศึกษาและวิธีการวิจัย

ในการศึกษานี้ ได้นำเสนอวิธีการพยากรณ์น้ำท่าโดยใช้ข้อมูลอัตราการไหลรายชั่วโมงจากสถานีตรวจวัดด้านเหนือน้ำเพื่อเป็นข้อมูลนำเข้าสำหรับแบบจำลองโครงข่ายประสาทเทียม ซึ่งได้ทำการศึกษา 2 พื้นที่ ประกอบด้วยลุ่มน้ำน่านตอนบนและลุ่มน้ำเลย ดังแสดงในรูปที่ 1 โดยมีรายละเอียดที่สำคัญดังต่อไปนี้



รูปที่ 1 พื้นที่ศึกษา (ก) สถานีวัดน้ำท่าในลุ่มน้ำน่านตอนบน และ (ข) สถานีวัดน้ำท่าในลุ่มน้ำเลย

2.1 พื้นที่ศึกษา


พื้นที่ศึกษาลุ่มน้ำน่านตอนบนและลุ่มน้ำเลยดังแสดงในรูปที่ 1 โดยลุ่มน้ำน่านตอนบนตั้งอยู่ทางภาคเหนือของประเทศไทย มีขนาดพื้นที่รับน้ำ 8,706 ตารางกิโลเมตร พื้นที่ส่วนใหญ่อยู่ในเขตจังหวัดน่าน สภาพภูมิประเทศของลุ่มน้ำน่านตอนบนประกอบไปด้วยเทือกเขาสูง ลำน้ำสายหลักคือ แม่น้ำน่าน มีต้นกำเนิดมาจากเทือกเขาหลวงพระบาง ลำน้ำสาขาที่สำคัญ ประกอบด้วย น้ำว้า ซึ่งไหลมาจากเทือกเขาหลวงพระบาง มาบรรจบทางฝั่งซ้ายของแม่น้ำน่านที่อำเภอเวียงสา จังหวัดน่าน สำหรับการศึกษาจะพิจารณาเฉพาะพื้นที่ลุ่มน้ำน่านตอนบน บริเวณพื้นที่รับน้ำของสถานีวัดน้ำท่า N.1 ซึ่งมีขนาดพื้นที่รับน้ำ 4,560 ตารางกิโลเมตร สำหรับลุ่มน้ำเลย ตั้งอยู่ทางภาคตะวันออกเฉียงเหนือของประเทศไทย มีขนาดพื้นที่รับน้ำ 3,956 ตารางกิโลเมตร พื้นที่ส่วนใหญ่อยู่ในเขตจังหวัดเลย สภาพภูมิประเทศของลุ่มน้ำเลยเป็นที่ราบลุ่มระหว่างหุบเขา มีภูเขาล้อมรอบ ลักษณะเป็นแอ่งกระทะ ลำน้ำสายหลักคือ แม่น้ำเลย ซึ่งมีความยาว 231 กิโลเมตร และมีต้นกำเนิดมาจากเทือกเขาภูหลวง ไหลผ่านอำเภอภูหลวง วังสะพุง เมืองเลยและไหลสู่แม่น้ำโขง ที่อำเภอเชียงคาน สำหรับ

การศึกษานี้จะพิจารณาเฉพาะพื้นที่ลุ่มน้ำเลย บริเวณพื้นที่รับน้ำของสถานีวัดน้ำท่า Kh.58A ซึ่งมีขนาดพื้นที่รับน้ำ 3,093 ตารางกิโลเมตร

2.2 แบบจำลองที่ใช้ในการศึกษา

ในการศึกษานี้ ใช้โครงสร้างแบบจำลองโครงข่ายประสาทเทียม (ANNs) ซึ่งเป็นที่นิยมใช้ในงานทางด้านอุทกวิทยา การพยากรณ์น้ำท่าซึ่งต้องใช้ข้อมูลที่เป็นอนุกรมเวลา ANNs เป็นโครงข่ายที่มีแนวคิดมาจากการเลียนแบบการทำงานของระบบประสาทของมนุษย์ โดยจะจำลองการทำงานเหมือนกลุ่มเซลล์ประสาทที่เชื่อมโยงกัน สามารถทำให้คอมพิวเตอร์เรียนรู้ภาษามนุษย์ได้อย่างเข้าใจ อ่านออก และจดจำ การทำงานของ ANNs นั้นจะประกอบออกเป็น 3 ส่วน คือ Input Layer, Hidden Layer และ Output Layer ดังแสดงในรูปที่ 2 โดยชั้น Input Layer จะรับข้อมูลจากภายนอกมาที่ชั้น Hidden Layer โดยอยู่ระหว่าง Input Layer และ Output Layer ทำหน้าที่ประเมินชุดข้อมูลหรือแปลงสิ่งที่ Input Layer นำเข้ามา ให้สามารถนำออกไปใช้ใน Output Layer ได้ ส่วนสุดท้าย คือ ชั้น Output Layer จะส่งออกข้อมูลที่แปลงออกมา เครือข่าย

ประสาทส่วนใหญ่มักมีการเชื่อมต่อกันทั้งหมด ซึ่งหมายถึง Hidden Layer ทั้งหมดจะเชื่อมต่อกับเซลล์ประสาททุกตัว ในชั้น Input Layer และ Output Layer เพื่อจับความสัมพันธ์เป็นลำดับ



รูปที่ 2 แสดงโครงสร้างของโครงข่ายประสาทเทียม

2.3 สหสัมพันธ์ไขว้ (Cross Correlation)

กระบวนการสหสัมพันธ์ไขว้ คือ การตรวจสอบความเข้ากันได้ของชุดข้อมูลระหว่าง 2 อนุกรมเวลา (Time series) ซึ่งมีวัตถุประสงค์เพื่อนำไปศึกษาความเข้ากันได้ของชุดข้อมูลทั้ง 2 ตามช่วงเวลาของ Lag time ต่าง ๆ โดยทั่วไปความสัมพันธ์ระหว่าง 2 ชุดข้อมูล จะถูกตรวจสอบโดยใช้ดัชนีสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient, R) ดังสมการที่ (1) โดยหากทั้งสองชุดข้อมูลที่ Lag time ใด ๆ มีค่า R เข้าใกล้ 1 แสดงว่าชุดข้อมูลเหล่านั้นมีความเข้ากันได้มากที่สุด ณ ช่วงเวลานั้น ในการศึกษาได้ทำการหาค่าสหสัมพันธ์ระหว่างค่าอัตราการไหลของสถานีวัดน้ำท่าที่ต้องการพยากรณ์ ณ เวลาที่สนใจ (t_0) กับค่าอัตราการไหลของสถานีวัดน้ำท่าที่ใช้พยากรณ์ ณ เวลาเดียวกันและเวลาซ้อนหลังไปทีละ 1 ชั่วโมง (t_0 ถึง t_{0+n}) เพื่อหาค่าสหสัมพันธ์ที่ดีที่สุด ซึ่งค่าสหสัมพันธ์ของชั่วโมงซ้อนหลังที่ดีที่สุดจะนำไปใช้เป็นขอบเขตการนำเข้าข้อมูลย้อนหลังของสถานีที่ใช้พยากรณ์นั้น

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

เมื่อ X_i คือ ผลการคำนวณจากแบบจำลอง, Y_i คือ ข้อมูลการตรวจวัด, $\bar{X}$ คือ ค่าเฉลี่ยของข้อมูลที่ได้จากแบบจำลอง, $\bar{Y}$ คือ ค่าเฉลี่ยของข้อมูลที่ได้จากการตรวจวัด, N คือ จำนวนข้อมูล และ i คือ ลำดับของอนุกรมข้อมูล

2.4 เวลาของการเกิดน้ำท่าสูงสุด (Time of Concentration, T_C)

เวลาของการเกิดน้ำท่าสูงสุด หมายถึง เวลาที่น้ำฝนตกลงบนบริเวณต่าง ๆ ของพื้นที่ลุ่มน้ำและไหลมาถึงทางออกพร้อมกัน ซึ่งจะเท่ากับเวลาที่น้ำใช้เวลาเดินทางจากจุดที่ไกลที่สุดในเชิงชลศาสตร์ถึงทางออกของกลุ่มน้ำ เวลาของการเกิดน้ำท่าสูงสุดสามารถประเมินได้จากการคำนวณระยะเวลาที่น้ำจะต้องไหลบนผิวดิน (Overland Flow) ผ่านส่วนต่าง ๆ ของลุ่มน้ำลงสู่ทางน้ำซึ่งการไหลจะเป็นแบบการไหลในทางน้ำ (Channel Flow) และน้ำจะไหลลงสู่ทางน้ำที่มีขนาดใหญ่กว่าจนกระทั่งถึงจุดออก Seybert, 2006 [24] ได้แนะนำวิธี NRCS velocity method ซึ่งเป็นวิธีการที่สามารถประเมิน T_C ได้ใกล้เคียงกับสภาพความเป็นจริง และนิยมใช้งานกันอย่างแพร่หลาย โดยกระบวนการดังกล่าวนี้เป็นวิธีทางชลศาสตร์ที่มักใช้ในการประเมินค่า T_C ทั้งในแบบ overland และ/หรือ channel flow ในกรณีของการไหลในลำน้ำ วิธี NRCS velocity method จะแบ่งการไหลเป็นช่วง ๆ โดยพิจารณาแบ่งตามลักษณะการไหลที่สม่ำเสมอ สำหรับการคำนวณการแบ่งช่วงเวลากการเดินทาง จะดำเนินการแบ่งแต่ละส่วน ดังสมการที่ (2) ในขณะที่ T_C รวมทั้งหมด จะถูกคำนวณ ดังสมการที่ (3)

$$T_{C(i)} = 0.0167 \left(\frac{n L_{O,CH}}{R^{0.667} \sqrt{S_{O,CH}}} \right) \quad (2)$$

$$T_C = \sum_{i=1}^N T_{C(i)} \quad (3)$$

เมื่อ T_C คือ เวลาที่น้ำเดินทางจากจุดไกลสุดบนสันปันน้ำหรือสันเขาของกลุ่มน้ำถึงจุดออกของกลุ่มน้ำ (นาท), $T_{C(i)}$ คือ เวลาที่น้ำเดินทางจากจุดไกลสุดบนสันปันน้ำหรือสันเขาของกลุ่มน้ำถึงจุดออกของกลุ่มน้ำของส่วนที่ i (นาท), $L_{O,CH}$ คือ ความยาวของกลุ่มน้ำจากจุดไกลสุดถึงจุดออก (เมตร), n คือ สัมประสิทธิ์ความขรุขระของ Manning's, R คือ รัศมีชลศาสตร์ ซึ่งเท่ากับความลึกของการไหล (เมตร),

$S_{O,CH}$ คือ อัตราส่วน H/L หรือโดยประมาณเท่ากับความลาดชันเฉลี่ยของกลุ่มน้ำ, H คือ ผลต่างของระดับที่จุดออกและจุดใกล้สุดบนสันเขา (เมตร)

2.5 การประเมินประสิทธิภาพของแบบจำลอง

ในการศึกษานี้ใช้ดัชนีประสิทธิภาพ จำนวน 3 ดัชนี ในการตรวจสอบความถูกต้องระหว่างข้อมูลที่ประเมินได้จากแบบจำลองเทียบกับข้อมูลจากการตรวจวัด โดยประกอบด้วย ดัชนี Correlation Coefficient (R) ดังสมการที่ (1) ดัชนี Nash–Sutcliffe Efficiency (NSE) และ Root Mean Square Error (RMSE) ดังสมการที่ (4)–(5) ตามลำดับ โดยที่ดัชนี NSE, R จะมีค่าเข้าใกล้ 1 เมื่อค่าที่ประเมินได้จากแบบจำลองเข้ากันได้กับข้อมูลจากการตรวจวัด ในขณะที่ RMSE จะมีค่าเข้าใกล้ 0

$$NSE = 1 - \frac{\sum_{i=1}^N (Y_i - X_i)^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2} \quad (4)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - X_i)^2} \quad (5)$$

เมื่อ X_i คือ ผลการคำนวณจากแบบจำลอง, Y_i คือ ข้อมูลการตรวจวัด, $\bar{X}$ คือ ค่าเฉลี่ยของข้อมูลที่ได้จากแบบจำลอง, $\bar{Y}$ คือ ค่าเฉลี่ยของข้อมูลที่ได้จากการตรวจวัด, N คือ จำนวนข้อมูล และ i คือ ลำดับของอนุกรมข้อมูล

2.6 วิธีการศึกษา


ในการศึกษานี้ได้จัดทำแบบจำลองโครงข่ายประสาทเทียม (ANNs) แบบ Multi-Step Forecasting เพื่อพยากรณ์น้ำท่าที่สถานีเฝ้าระวังของกลุ่มน้ำน่านตอนบน (N.1) และกลุ่มน้ำเลข (Kh.58A) โดยการศึกษาได้จัดทำแบบจำลองเป็น 2 กรณีประกอบด้วย กรณีที่ 1 การประยุกต์ใช้ค่าสหสัมพันธ์ไขว้ (Case–Correl) เพื่อใช้เป็นขอบเขตการนำเข้าข้อมูลย้อนหลังของข้อมูลนำเข้าแบบจำลอง (Predictors) และกรณีที่ 2 การประยุกต์ใช้พารามิเตอร์ของการตอบสนองของเวลา (Case– T_C) เพื่อใช้เป็นขอบเขตการนำเข้าข้อมูลย้อนหลังของข้อมูลนำเข้าแบบจำลอง (Predictors) โดยขั้นตอนการศึกษาดังแสดงในรูปที่ 3

ประกอบด้วย การรวบรวมข้อมูลระดับน้ำรายชั่วโมงของสถานีวัดน้ำท่าในพื้นที่ศึกษา การหาค่าสหสัมพันธ์ไขว้ระหว่างข้อมูลอัตราการไหลที่สถานีเฝ้าระวังกับข้อมูลอัตราการไหลของสถานีในพื้นที่ต้นน้ำที่เวลาต่าง ๆ การคำนวณเวลาการเกิดน้ำท่าสูงสุด (T_C) ในแต่ละพื้นที่ศึกษา การจัดทำแบบจำลองโครงข่ายประสาทเทียม และการตรวจพิสูจน์แบบจำลอง โดยรายละเอียดขั้นตอนการศึกษามีดังต่อไปนี้

1. รวบรวมข้อมูลระดับน้ำรายชั่วโมงที่ได้จากสถานีตรวจวัดน้ำท่าในพื้นที่ศึกษา ประกอบด้วยข้อมูลระดับน้ำรายชั่วโมงในกลุ่มน้ำน่านตอนบนของสถานีวัดน้ำท่า N.1 N.49 N.64 และ N.65 ตั้งแต่ปี พ.ศ. 2539 ถึง 2563 และสถานีวัดน้ำท่า Kh.58A Kh.105 Kh.28A Kh.78 Kh.61 และ Kh.77A ตั้งแต่ปี พ.ศ. 2549 ถึง 2563 ในพื้นที่ลุ่มน้ำเลขทั้งนี้ในการเลือกช่วงเวลาของข้อมูลที่นำมาทำการศึกษาของกลุ่มน้ำทั้งสอง ได้ทำการรวบรวมข้อมูลจากช่วงปีที่เริ่มมีการตรวจวัดระดับน้ำรายชั่วโมงของแต่ละพื้นที่ศึกษาของกรมชลประทาน สำหรับรายละเอียดของข้อมูลและช่วงเวลา ดังแสดงในตารางที่ 1 จากนั้นข้อมูลอัตราการไหลที่ได้จะถูกนำไปตรวจสอบความผิดปกติด้วยวิธีการพล็อตกราฟเพื่อดูค่าที่สูงผิดปกติหรือค่าติดลบ ซึ่งข้อมูลเหล่านี้รวมทั้งข้อมูลที่ขาดหายจะถูกเติมแทนที่ด้วยวิธีการเฉลี่ยเส้นตรง จากนั้นจึงทำการเปลี่ยนค่าระดับน้ำเป็นอัตราการไหลด้วยไค้ความสัมพันธ์ระหว่างระดับน้ำและอัตราการไหลที่จัดทำโดยกรมชลประทานของสถานีวัดน้ำท่านั้น ๆ

ตารางที่ 1 รายละเอียดข้อมูลน้ำท่ารายชั่วโมงในพื้นที่ศึกษา

พื้นที่ศึกษา	ข้อมูลระดับน้ำรายชั่วโมง		ช่วงปีข้อมูล
	สถานีพยากรณ์ (Target)	สถานีที่ใช้พยากรณ์ (Predictors)	
กลุ่มน้ำน่านตอนบน	N.1	N.49, N.64, N.65, N.1	2539–2563
กลุ่มน้ำเลข	Kh.58A	Kh.105, Kh.28A, Kh.78, Kh.61, Kh.77A, Kh.58A	2549–2563



รูปที่ 3 แผนผังการดำเนินงาน

2. คำนวณค่าสหสัมพันธ์ระหว่างค่าอัตราการไหลของสถานีพยากรณ์ (Target) ณ เวลาที่สนใจ กับค่าอัตราการไหลของสถานีที่ใช้พยากรณ์ (Predictors) ที่เวลาซ้อนหลัง (Lag time) ต่าง ๆ เพื่อหาค่าสหสัมพันธ์ที่ดีที่สุด ในทั้งสองลุ่มน้ำ โดยค่าสหสัมพันธ์ที่เวลาซ้อนหลังที่ดีที่สุดของแต่ละ Predictor จะถูกนำมาเป็นขอบเขตการนำเข้าข้อมูลซ้อนหลัง (Lag time) ของข้อมูลอัตราการไหลของสถานีนั้น ๆ

3. คำนวณหาค่าเวลาของการเกิดน้ำท่าสูงสุด (Time of concentration, T_C) ของลุ่มน้ำน่านตอนบนและลุ่มน้ำเลย โดยวิธี NRCS velocity method ในการคำนวณค่า T_C ของแต่ละพื้นที่ศึกษาได้แบ่งความยาวของแม่น้ำที่ไกลที่สุดออกเป็นช่วง ๆ ตามสภาพความลาดเอียงท้องน้ำ จากนั้น T_C ของแต่ละช่วงจะถูกคำนวณดังสมการที่ (2) และค่า T_C ของพื้นที่ศึกษาคำนวณได้ดังสมการที่ (3) ในการคำนวณค่าพารามิเตอร์ต่าง ๆ ประกอบด้วย พื้นที่ลุ่มน้ำ (A) ความยาวของลำน้ำจากจุดไกลสุดจนถึงจุดไกลสุด (L) ความลาดชันเฉลี่ยของลุ่มน้ำ (S) ใช้ข้อมูล Digital elevation model, DEM (STRM) [29] ที่มีความละเอียดเชิงพื้นที่ 30×30 เมตร รูปตัดของลำน้ำที่สถานีวัดน้ำท่าและระดับน้ำรวบรวมข้อมูลมาจากกรมชลประทาน สำหรับลุ่มน้ำน่านตอนบน มีแม่น้ำน่านเป็นลำน้ำที่ยาวที่สุดจากจุดที่ไกลที่สุด

จนถึงสถานี N.1 เท่ากับ 205 กิโลเมตร ซึ่งแบ่งความลาดชันท้องน้ำเป็น 3 ช่วง โดยมีความลาดชันจากต้นน้ำเท่ากับ 0.0593, 0.00596 และ 0.00128 ตามลำดับ ในขณะที่ลุ่มน้ำเลยมีลำน้ำที่ยาวที่สุดถึงสถานี Kh.58A เท่ากับ 157 กิโลเมตร ความลาดชันลำน้ำแบ่งเป็น 3 ช่วงเช่นเดียวกัน มีความชันท้องน้ำเท่ากับ 0.0506, 0.0059 และ 0.00056 ตามลำดับ จากการวิเคราะห์ พบว่า ค่า T_C ของลุ่มน้ำน่านตอนบนและลุ่มน้ำเลยมีค่าเท่ากับ 15 ชั่วโมง และ 24 ชั่วโมง ตามลำดับ โดยระยะเวลาเหล่านี้จะถูกนำไปเป็นขอบเขตการนำเข้าข้อมูลซ้อนหลัง (Lag time) ของ Predictors ในกรณีที่ 2 Case- T_C ของพื้นที่ศึกษาทั้งสองลุ่มน้ำ

4. เลือกช่วงเวลาของข้อมูลน้ำท่าเพื่อทำการฝึกฝนแบบจำลอง (Training) และตรวจพิสูจน์แบบจำลอง (Validation) โดยใช้ข้อมูล 80% ของจำนวนข้อมูลทั้งหมดสำหรับการฝึกฝน และอีก 20% สำหรับการตรวจพิสูจน์แบบจำลอง โดยลุ่มน้ำน่านตอนบนจะใช้ข้อมูลปี พ.ศ. 2539–2558 สำหรับฝึกฝนแบบจำลอง และข้อมูลปี พ.ศ. 2559–2563 สำหรับการตรวจพิสูจน์แบบจำลอง ลุ่มน้ำเลยใช้ข้อมูลปี พ.ศ. 2549–2559 สำหรับฝึกฝน และข้อมูลปี พ.ศ. 2560–2563 สำหรับการตรวจพิสูจน์แบบจำลอง

5. จัดเตรียมข้อมูลสำหรับนำเข้าแบบจำลอง ANNs โดยกลุ่มน้ำน่านตอนบนเลือกสถานีวัดน้ำท่า N.1 เป็นสถานีพยากรณ์อัตราการไหล (Target) เลือกใช้สถานีวัดน้ำท่า N.49, N.64, N.65 และ N.1 เป็นสถานีที่ใช้ในการพยากรณ์ (Predictors) สำหรับกลุ่มน้ำเลยเลือกสถานีวัดน้ำท่า Kh.58A เป็นสถานีสำหรับการพยากรณ์อัตราการไหล (Target) โดยสถานีวัดน้ำท่า Kh.105, Kh.28A, Kh.78, Kh.61, Kh.77A และ Kh.58A เป็นสถานีที่ใช้ในการพยากรณ์ (Predictors) ทั้งนี้ ได้แบ่งกรณีศึกษาออกเป็น 2 กรณี ดังนี้

5.1) กรณีที่ 1 การประยุกต์ใช้ค่าสหสัมพันธ์ชั่ว (Case-Correl) เพื่อใช้เป็นขอบเขตการนำเข้าข้อมูลย้อนหลังของข้อมูลนำเข้าแบบจำลอง (Predictors) โดยนำเข้าข้อมูลของแต่ละสถานีไปจนถึงชั่วโมงที่มีความสัมพันธ์กันสูงสุด (Case-Correl) สามารถเขียนฟังก์ชันการพยากรณ์น้ำท่าตั้งแต่ชั่วโมงที่ 1-12 ของกลุ่มน้ำน่านตอนบนและกลุ่มน้ำเลย ดังสมการที่ (6)–(7) ตามลำดับ

$$\begin{aligned} Q(N1_{t0+1}) &= f(Q(N1_{t0 \text{ to } t0-15}), Q(N49_{t0 \text{ to } t0-20}), \\ &Q(N64_{t0 \text{ to } t0-6}), Q(N65_{t0 \text{ to } t0-16})) \end{aligned} \quad (6)$$

$$\begin{aligned} Q(Kh58A_{t0+1}) &= f(Q(Kh58A_{t0 \text{ to } t0-24}), Q(Kh105_{t0 \text{ to } t0-7}), \\ &Q(Kh28A_{t0 \text{ to } t0-11}), Q(Kh78_{t0 \text{ to } t0-13}), \\ &Q(Kh61_{t0 \text{ to } t0-28}), Q(Kh77A_{t0 \text{ to } t0-30})) \end{aligned} \quad (7)$$

5.2) กรณีที่ 2 การประยุกต์ใช้พารามิเตอร์ของการตอบสนองของเวลา (Case-T_c) โดยนำเข้าข้อมูลย้อนหลังของแต่ละสถานีไปจนถึงชั่วโมงที่ T_c สำหรับค่า T_c ของกลุ่มน้ำน่านตอนบนและกลุ่มน้ำเลยที่คำนวณได้จากวิธี NRCS velocity (Case-T_c) มีค่าเท่ากับ 15 และ 24 ชั่วโมง ตามลำดับ ฟังก์ชันการพยากรณ์น้ำท่าตั้งแต่ชั่วโมงที่ 1-12 ของกลุ่มน้ำน่านตอนบนและกลุ่มน้ำเลย ดังสมการที่ (8)–(9) ตามลำดับ

$$\begin{aligned} Q(N1_{t0+1}) &= f(Q(N1_{t0 \text{ to } t0-15}), Q(N49_{t0 \text{ to } t0-15}), \\ &Q(N64_{t0 \text{ to } t0-15}), Q(N65_{t0 \text{ to } t0-15})) \end{aligned} \quad (8)$$

$$\begin{aligned} Q(Kh58A_{t0+1}) &= f(Q(Kh58A_{t0 \text{ to } t0-24}), Q(Kh105_{t0 \text{ to } t0-24}), \\ &Q(Kh28A_{t0 \text{ to } t0-24}), Q(Kh78_{t0 \text{ to } t0-24}), \\ &Q(Kh61_{t0 \text{ to } t0-24}), Q(Kh77A_{t0 \text{ to } t0-24})) \end{aligned} \quad (9)$$

6. การฝึกฝนแบบจำลอง (Training) และการตรวจพิสูจน์แบบจำลอง (Validation) ในแต่ละกรณีศึกษา โดยพารามิเตอร์ที่ใช้ในการศึกษาของ ANNs จะใช้แบบซ้อนกัน 2 layers และรับ Input nodes เท่ากับจำนวน Predictors ที่นำมาพยากรณ์ กำหนด MSE Loss Function ให้มีค่า Learning Rate เท่ากับ 0.001 และ Batch Size เท่ากับ 32 ชุด และสร้างแบบจำลองการพยากรณ์แบบหลายขั้นตอน ที่มี Output nodes เท่ากับ 12 nodes ใน Network Structure เพื่อแสดงเวกเตอร์การพยากรณ์อัตราการไหลล่วงหน้า ตั้งแต่ชั่วโมงที่ 1 ถึงชั่วโมงที่ 12 ของแบบจำลอง ซึ่งจะเปรียบเทียบประสิทธิภาพของผลการประเมินจากแบบจำลองด้วยดัชนีประสิทธิภาพ NSE, R และ RMSE

7. สรุปผลการศึกษาเพื่อเปรียบเทียบประสิทธิภาพการพยากรณ์น้ำท่าล่วงหน้าของแบบจำลอง ANNs ตามช่วงเวลาต่าง ๆ ทั้ง 2 กรณีศึกษา

3. ผลการศึกษา

3.1 ผลพยากรณ์กราฟน้ำท่าล่วงหน้า

การพยากรณ์น้ำท่าของสถานีวัดน้ำท่า N.1 และ Kh.58A ของกลุ่มน้ำน่านตอนบนและกลุ่มน้ำเลย ได้จัดทำแบบจำลอง ANNs ใน 2 กรณี คือ กรณีที่ 1 Case-Correl และกรณีที่ 2 Case-T_c ซึ่งผลการพยากรณ์น้ำท่าที่ได้จากแบบจำลอง ANNs ได้ถูกนำมาเปรียบเทียบกับข้อมูลน้ำท่าที่ได้จากการตรวจวัด (Observed data) ดังแสดงในรูปที่ 4 แสดงผลเปรียบเทียบระหว่างอัตราการไหลพยากรณ์กับอัตราการไหลตรวจวัดที่ชั่วโมงที่ 12 ล่วงหน้าของสถานีวัดน้ำท่า N.1 และ Kh.58A สำหรับกลุ่มน้ำน่านตอนบนและกลุ่มน้ำเลย จากผลการเปรียบเทียบจะเห็นได้ว่า แบบจำลองทั้งสองกรณีสามารถพยากรณ์อัตราการไหลได้ใกล้เคียงกับค่าตรวจวัดทั้งในช่วงฤดูฝนและฤดูแล้ง โดยพบว่าแบบจำลองทั้งสองกรณีพยากรณ์ค่าอัตราการไหลได้ค่อนข้างสูงกว่าค่าตรวจวัดโดยเฉพาะอย่างยิ่งในช่วงฤดูฝน นอกจากนี้กรณีที่ 1 Case-Correl พยากรณ์ค่าอัตราการไหลได้ค่อนข้างสูงกว่าค่าอัตราการไหลที่พยากรณ์ได้จากแบบจำลองกรณีที่ 2 Case-T_c สังเกตได้จากเส้นสีแดง (Case-Correl) ที่สูงกว่าสีน้ำเงิน (Case-T_c) ในช่วงเวลา

น้ำหลากในทั้งสองพื้นที่ศึกษา จากรูปที่ 4 จะเห็นได้ว่า ลักษณะกราฟน้ำท่าในช่วงฤดูฝนของพื้นที่ศึกษาทั้งสอง มีการเปลี่ยนแปลงอัตราการไหลค่อนข้างรวดเร็ว ทั้งนี้เนื่องจากพื้นที่ศึกษาทั้งสองมีลักษณะภูมิประเทศ เป็นพื้นที่ภูเขาสูงและที่ราบสูงเชิงเขา ส่งผลให้น้ำท่าไหล จากบริเวณต้นน้ำมายังพื้นที่ท้ายน้ำเกิดขึ้นอย่างรวดเร็ว จากคุณลักษณะของกราฟน้ำท่าดังกล่าวทำให้แบบจำลอง พยายามเรียนรู้รูปแบบการเกิดน้ำท่าที่มีลักษณะการ เปลี่ยนแปลงอย่างรวดเร็วของพื้นที่ศึกษา ส่งผลให้เกิด ความคลาดในการพยากรณ์มากในช่วงฤดูฝนซึ่งมีการ เปลี่ยนแปลงอัตราการไหลอย่างรวดเร็ว อย่างไรก็ตาม ผล การเปรียบเทียบกราฟน้ำหลากจะเห็นได้ว่าแบบจำลอง สามารถพยากรณ์อัตราการไหลได้ค่อนข้างแม่นยำทั้งใน รูปร่างของกราฟน้ำหลาก และค่าอัตราการไหลในแต่ละ ช่วงเวลา


3.2 ผลการพยากรณ์น้ำท่าล่วงหน้ารายชั่วโมงของกรณีที่ 2 (Case-T_c)

ในการพยากรณ์อัตราการไหลล่วงหน้ารายชั่วโมงของ กลุ่มน้ำน่านตอนบนและกลุ่มน้ำเลย ได้ทำการพยากรณ์ราย ชั่วโมงล่วงหน้าตั้งแต่ชั่วโมงที่ 1 ถึง ชั่วโมงที่ 12 รูปที่ 5 แสดงการกระจายตัวระหว่างผลการพยากรณ์อัตราการไหล ล่วงหน้าสำหรับชั่วโมงที่ 3, 6, 9 และ 12 กับข้อมูลอัตรา การไหลที่ได้จากการตรวจวัด (Observed) ในกรณีที่ 2 (Case-T_c) ของกลุ่มน้ำน่านตอนบน (รูปบน) และกลุ่มน้ำเลย (รูปล่าง) จากกราฟแสดงให้เห็นว่าแบบจำลอง ANNs กรณี Case-T_c สามารถพยากรณ์น้ำหลากล่วงหน้า 3 ชั่วโมง มีความแม่นยำค่อนข้างสูงเมื่อเทียบกับการพยากรณ์ ล่วงหน้าในชั่วโมงที่ 6, 9 และ 12 โดยมีค่าสหสัมพันธ์ เท่ากับ 0.9981 และ 0.9983 ในกลุ่มน้ำน่านตอนบนและ กลุ่มน้ำเลย ตามลำดับ และมีค่าความแม่นยำลดลงเมื่อจำนวน ชั่วโมงการทำนายล่วงหน้าเพิ่มขึ้น อย่างไรก็ตามจะเห็นว่า


แบบจำลองพยากรณ์ค่าอัตราการไหลได้สูงกว่าค่าตรวจวัด ในทั้งสองพื้นที่ศึกษา โดยเฉพาะในพื้นที่ลุ่มน้ำน่าน ตอนบน ทั้งนี้เนื่องจากแบบจำลองมุ่งเน้นเพื่อพยากรณ์ อัตราการไหลในช่วงฤดูน้ำหลาก ผลจากการพยากรณ์ที่สูง กว่าความเป็นจริงนั้น เปรียบเสมือนได้กับการเพิ่ม ระยะเวลาการเตือนภัยน้ำท่วม ซึ่งเป็นหัวใจสำคัญสำหรับ การบรรเทาอุทกภัย [30] ทำให้ประชาชนเกิดความตื่นตัว ในการเตรียมความพร้อมรับมือได้ทันทั่วถึง ดังนั้นผลการ พยากรณ์ที่ได้มากกว่าค่าตรวจวัดจึงสามารถยอมรับได้

3.3 ประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียม ในการพยากรณ์น้ำท่าล่วงหน้ารายชั่วโมง


ในการวัดประสิทธิภาพของแบบจำลอง ANNs ได้ใช้ค่า ดัชนีประสิทธิภาพ R, RMSE และ NSE ในการตรวจสอบ ประสิทธิภาพของแบบจำลองทั้งสองกรณี ในการพยากรณ์ อัตราการไหลล่วงหน้าตั้งแต่ชั่วโมงที่ 1 ถึง 12 ของกลุ่มน้ำ น่านตอนบนและกลุ่มน้ำเลย ผลการคำนวณแสดงดังแสดง ในรูปที่ 6 ซึ่งผลการประเมินของทั้ง 2 กรณี จะเห็นได้ว่า ความถูกต้องจะมีค่าลดลงตามชั่วโมงการพยากรณ์ที่เพิ่ม มากขึ้น ซึ่งในกรณีของ Case-T_c ให้ผลการประเมินที่มี ความถูกต้องมากกว่ากรณี Case-Correl อย่างไรก็ตาม ผลการพยากรณ์ของทั้ง 2 กรณีนั้น แสดงให้เห็นถึงความ ถูกต้องที่อยู่ในระดับสูง ยกตัวอย่างเช่นค่าดัชนี NSE ในกลุ่มน้ำน่านตอนบน ตั้งแต่ชั่วโมงที่ 1 ถึง ชั่วโมงที่ 12 ซึ่งมีค่าอยู่ระหว่าง 0.999 ถึง 0.962 สำหรับกรณี Case-T_c และมีค่าอยู่ระหว่าง 0.999 ถึง 0.952 สำหรับกรณี Case-Correl ตามลำดับ ซึ่งจะเห็นได้ว่าเมื่อการพยากรณ์ ในชั่วโมงที่เพิ่มมากขึ้น จะมีความผิดพลาดออกจากค่า ตรวจวัดมากขึ้น โดยรายละเอียดของค่าดัชนีประสิทธิภาพ NSE ตั้งแต่ชั่วโมงที่ 1 ถึง ชั่วโมงที่ 12 สำหรับกลุ่มน้ำน่าน ตอนบนและกลุ่มน้ำเลย ดังแสดงในตารางที่ 2



รูปที่ 4 กราฟน้ำท่าของการพยากรณ์ล่วงหน้า 12 ชั่วโมง สำหรับช่วงการตรวจพิสูจน์ กรณี T_c และ กรณี Correl เทียบกับ ข้อมูลจากสถานีตรวจวัด (Observed) สำหรับลุ่มน้ำน่านตอนบน (บน) และลุ่มน้ำเลย (ล่าง)



รูปที่ 5 ความสัมพันธ์ระหว่างผลที่ได้จากการประเมิน (Simulated) และข้อมูลจากการตรวจวัด (Observed) ของการพยากรณ์ น้ำท่าล่วงหน้า 3, 6, 9, และ 12 ชั่วโมง กรณีที่ 2 Case- T_c สำหรับลุ่มน้ำน่านตอนบน (บน) และลุ่มน้ำเลย (ล่าง)



รูปที่ 6 ประสิทธิภาพของการพยากรณ์ล่วงหน้าตั้งแต่ชั่วโมงที่ 1 ถึงชั่วโมงที่ 12 ของกรณี Case-T_c และ กรณี Case-Correl เทียบกับข้อมูลจากสถานีตรวจวัด (Observed) โดยดัชนี R, NSE และ RMSE ของกลุ่มน้ำน่านตอนบน (บน) และกลุ่มน้ำเลย (ล่าง)

ตารางที่ 2 ดัชนีประสิทธิภาพ NSE ตั้งแต่ชั่วโมงที่ 1 ถึง ชั่วโมงที่ 12 ของกลุ่มน้ำน่านตอนบนและกลุ่มน้ำเลย

ดัชนีประสิทธิภาพ NSE													
กลุ่มน้ำ	กรณีศึกษา	ชั่วโมงที่											
		1	2	3	4	5	6	7	8	9	10	11	12
น่านตอนบน	Case-Correl	0.999	0.997	0.996	0.993	0.990	0.986	0.982	0.977	0.972	0.966	0.959	0.952
	Case-T _c	0.999	0.998	0.996	0.994	0.991	0.988	0.985	0.981	0.977	0.973	0.968	0.962
เลย	Case-Correl	0.997	0.996	0.995	0.993	0.990	0.987	0.984	0.980	0.976	0.971	0.966	0.961
	Case-T _c	0.998	0.996	0.997	0.995	0.993	0.991	0.987	0.984	0.980	0.976	0.972	0.968

3.4 ข้อจำกัดและแนวทางการวิจัยในอนาคต

ในการศึกษานี้ได้ประยุกต์ใช้กระบวนการทางอุทกวิทยาที่เกี่ยวข้องกับพารามิเตอร์สำหรับการตอบสนองของน้ำท่าในกลุ่มน้ำเพื่อเพิ่มประสิทธิภาพให้กับแบบจำลองโครงข่ายประสาทเทียม โดยในการศึกษานี้ได้ใช้เฉพาะเพียงข้อมูลปริมาณน้ำท่าจากสถานีเหนือน้ำสำหรับเป็นข้อมูลนำเข้าแบบจำลอง อย่างไรก็ตาม ชุดข้อมูลฝนเป็นข้อมูลที่มีความสำคัญอย่างมากสำหรับงานทางด้านการพยากรณ์น้ำท่วม แต่เนื่องด้วยข้อจำกัดด้านข้อมูลโดยเฉพาะอย่างยิ่งข้อมูลรายชั่วโมงที่ไม่เพียงพอจึงทำให้การศึกษานี้พิจารณาเพียงข้อมูลน้ำท่าเท่านั้น ทั้งนี้ หากใช้ข้อมูลฝนเข้ามาร่วมในแบบจำลอง ก็จะสามารถช่วยเพิ่มประสิทธิภาพการประเมิน

น้ำท่าที่เกิดจากปริมาณฝนที่ตกโดยตรงในพื้นที่ ทำให้ผลการประเมินน้ำท่าจากแบบจำลองสามารถครอบคลุมกระบวนการทางอุทกวิทยาได้มากยิ่งขึ้น โดยมีหลายงานวิจัยที่นำข้อมูลฝน ข้อมูลน้ำท่า และข้อมูลอื่น ๆ ที่เกี่ยวข้องมาเป็นตัวพยากรณ์ (Predictors) ซึ่งก็ให้ผลการประเมินที่อยู่ในระดับสูง [8],[31] นอกจากนั้นแล้วในปัจจุบันได้มีการพัฒนาแบบจำลองการเรียนรู้เชิงลึกมากมายที่มีพื้นฐานมาจากแบบจำลอง ANN อาทิเช่น Recurrent Neural Network (RNN), Long Short-Term Memory network (LSTM) และ Gated Recurrent Unit (GRU) ซึ่งแบบจำลองเหล่านี้มีโครงสร้างและการคำนวณที่ซับซ้อน สามารถแก้ไขปัญหาลำดับเชิงตัวเลขได้อย่าง

มีประสิทธิภาพ จึงเห็นสมควรที่จะประยุกต์ใช้แบบจำลองดังกล่าวสำหรับการพยากรณ์น้ำท่าในการศึกษาครั้งต่อไป

4. สรุปผลการศึกษา

การประยุกต์ใช้แบบจำลองโครงข่ายประสาทเทียมเพื่อการพยากรณ์อัตราการไหลล่วงหน้า 12 ชั่วโมงของกลุ่มน้ำน่านตอนบนและลุ่มน้ำเลย พบว่าพารามิเตอร์ที่มีผลต่อประสิทธิภาพของแบบจำลองได้แก่ ข้อมูลอัตราการไหลย้อนหลังของสถานีวัดน้ำท่าในพื้นที่ต้นน้ำ จากการศึกษาการนำเข้าข้อมูลย้อนหลังทั้งสองกรณี พบว่าแบบจำลองโครงข่ายประสาทเทียมร่วมกับการประยุกต์ค่าเวลาการเกิดน้ำท่าสูงสุด (T_c) ซึ่งเป็นพารามิเตอร์การตอบสนองของเวลาของกลุ่มน้ำ โดยใช้ค่า T_c เพื่อเป็นขอบเขตการนำเข้าข้อมูลย้อนหลังสามารถเพิ่มประสิทธิภาพให้แบบจำลองการพยากรณ์น้ำท่าล่วงหน้ามีประสิทธิภาพดีขึ้นอย่างเห็นได้ชัด โดยแบบจำลองสามารถพยากรณ์อัตราการไหลล่วงหน้าได้ทั้งค่าปริมาณอัตราการไหลและรูปร่างของกราฟน้ำหลาก ทั้งนี้ประสิทธิภาพของแบบจำลองมีค่าลดลงตามลำดับเมื่อชั่วโมงการพยากรณ์เพิ่มมากขึ้นในทั้งสองพื้นที่ศึกษา ซึ่งในกรณีของ Case- T_c ให้ผลการประเมินที่มีความถูกต้องมากกว่ากรณี Case-Correl อย่างไรก็ตาม ประสิทธิภาพของแบบจำลองทั้ง 2 กรณี ให้ผลการพยากรณ์ 12 ชั่วโมง ล่วงหน้าอยู่ในระดับสูง ซึ่งมีค่าNSE มากกว่า 0.95 ทั้งนี้จากผลการศึกษาดังกล่าวข้างต้น สามารถนำไปใช้เพื่อการพยากรณ์อัตราการไหลในอนาคตได้ เพื่อเป็นเครื่องมือในการบริหารจัดการภัยพิบัติและวางแผนเตือนภัยน้ำท่วมต่อไปได้

5. กิตติกรรมประกาศ

ขอขอบคุณทุนโครงการส่งเสริมจากการศึกษาระดับปริญญาโท แผนการเรียนแบบ ก (ภาคต้น ปีการศึกษา 2564) คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์

เอกสารอ้างอิง

- [1] J. Noymanee and T. Theeramunkong, "Flood Forecasting with Machine Learning Technique on Hydrological Modeling," *Procedia Computer Science*, vol. 156, pp. 377–386, 2019, doi: 10.1016/j.procs.2019.08.214.
- [2] N. Noori and L. Kalin, "Coupling SWAT and ANN models for enhanced daily streamflow prediction," *Journal of Hydrology*, vol. 533, pp. 141–151, 2016, doi: 10.1016/j.jhydrol.2015.11.050.
- [3] W. El Harraki, D. Ouazar, A. Bouziane, I. El Harraki and D. Hasnaoui, "Streamflow prediction upstream of a dam using SWAT and assessment of the impact of land use spatial resolution on model performance," *Environmental Processes*, vol. 8, pp. 1165–1186, 2021, doi: 10.1007/s40710-021-00532-0.
- [4] H. M. Yesuf, A. M. Melesse, G. Zeleke and T. Alamirew, "Streamflow prediction uncertainty analysis and verification of SWAT model in a tropical watershed," *Environmental Earth Sciences*, vol. 75, pp. 1–16, 2016, doi: 10.1007/s12665-016-5636-z.
- [5] M. R. Aredo, S. D. Hatiye and S. M. Pingale, "Modeling the rainfall-runoff using MIKE 11 NAM model in Shaya catchment, Ethiopia," *Modeling Earth Systems and Environment*, vol. 7, pp. 2545–2551, 2021, doi: 10.1007/s40808-020-01054-8.
- [6] A. S. Nannawo, T. K. Lohani, A. A. Eshete and M. T. Ayana, "Evaluating the dynamics of hydroclimate and streamflow for data-scarce areas using MIKE11–NAM model in Bilate river basin, Ethiopia," *Modeling Earth Systems and Environment*, vol. 8, pp. 4563–4578, 2022, doi: 10.1007/s40808-022-01455-x.
- [7] P. P. Mapiam, N. Sriwongsitanon, "Estimation of the URBS model parameters for flood estimation of ungauged catchments in the upper Ping river basin,

- Thailand,” *ScienceAsia*, vol. 35, no. 2009, pp. 49–56, 2009, doi: 10.2306/scienceasia1513-1874.2009.35.049.
- [8] H. Tongal and M. J. Booij, “Simulation and forecasting of streamflows using machine learning models coupled with base flow separation,” *Journal of hydrology*, vol. 564, pp. 266–282, 2018, doi: 10.1016/j.jhydrol.2018.07.004.
- [9] M. Campolo, A. Soldati and P. Andreussi, “Artificial neural network approach to flood forecasting in the river Arno,” *Hydrological Sciences Journal*, vol. 48, no. 3, pp. 381–398, 2003, doi: 10.1623/hysj.48.3.381.45286.
- [10] J. S. Wu, J. Han, S. Annambhotla and S. Bryant, “Artificial neural networks for forecasting watershed runoff and stream flows,” *Journal of hydrologic engineering*, vol. 10, no. 3, pp. 216–222, 2005, doi: 10.1061/(ASCE)1084-0699(2005)10:3(216).
- [11] W. C. Wang, K. W. Chau, C. T. Cheng and L. Qiu, “A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series,” *Journal of hydrology*, vol. 374, no. 3–4, pp. 294–306, 2009, doi: 10.1016/j.jhydrol.2009.06.019.
- [12] S. S. Patel, P. Ramachandran, “A comparison of machine learning techniques for modeling river flow time series: the case of upper Cauvery river basin,” *Water resources management*, vol. 29, no. 2, pp. 589–602, 2015, doi: 10.1007/s11269-014-0705-0.
- [13] Z. M. Yaseen, A. El-Shafie, O. Jaafar, H. A. Afan and K. N. Sayl, “Artificial intelligence based models for stream-flow forecasting: 2000–2015,” *Journal of Hydrology*, vol. 530, pp. 829–844, 2015, doi: 10.1016/j.jhydrol.2015.10.038.
- [14] Z. M. Yaseen, M. F. Allawi, A. A. Yousif, O. Jaafar, F. M. Hamzah and A. El-Shafie, “Non-tuned machine learning approach for hydrological time series forecasting,” *Neural Computing and Applications*, vol. 30, pp. 1479–1491, 2018, doi: 10.1007/s00521-016-2763-0.
- [15] P. Parisouj, H. Mohebzadeh and T. Lee, “Employing machine learning algorithms for streamflow prediction: a case study of four river basins with different climatic zones in the United States,” *Water Resources Management*, vol. 34, pp. 4113–4131, 2020, doi: 10.1007/s11269-020-02659-5.
- [16] U. S. Department of Agriculture Natural Resources Conservation Service (USDA–NRCS), “Time of concentration,” in *National Engineering Handbook*, Washington, DC, USA, 2010, ch. 15, pp. 1–29.
- [17] O. J. Gericke and J. C. Smithers, “Review of methods used to estimate catchment response time for the purpose of peak discharge estimation,” *Hydrological Sciences Journal*, vol. 59, no. 11, pp. 1935–1971, 2014, doi: 10.1080/02626667.2013.866712.
- [18] Z. P. Kirpich, “Time of Concentration of Small Agricultural Watersheds,” *Civil engineering*, vol. 10, no. 6, pp. 362, 1940.
- [19] W. S. Kerby, “Time of concentration for overland flow,” *Civil Engineering*, vol. 29, pp. 60, 1959.
- [20] J. R. Morgali and R. K. Linsley, “Computer simulation of overland flow,” *Journal of the Hydraulics Division, ASCE*, vol. 90, pp. 81–100, 1965.
- [21] Federal Aviation Administration (FAA), “Circular on Airport Drainage,” US. Department of Transportation, Washington, D.C., USA, Rep. A/C 050-5320-5B, 1970.
- [22] United States Department of the Interior Bureau of Reclamation (USBR), “Flood Hydrology Studies,” in *Design of Small Dams*, 3rd ed. Washington, D.C., USA, 1987, ch. 3, sec. 3.9, pp. 28–51.
- [23] W. E. Watt and K. C. A. Chow, “A general expression for basin lag time,” *Canadian Journal of Civil Engineering*, vol. 12, no. 2, pp. 294–300, 1985, doi: 10.1139/l85-031.

-
- [24] T. A. Seybert, "Travel Time," in *Stormwater Management for Land Development*, Hoboken, NJ, USA: John Wiley & Sons, Inc., 2006, ch. 7, sec. 2, pp. 145–178.
- [25] K. Aziz, M. M. Haque, A. Rahman, A. Y. Shamseldin and M. Shoaib, "Flood estimation in ungauged catchments: application of artificial intelligence based methods for Eastern Australia," *Stochastic Environmental Research and Risk Assessment*, vol. 31, pp. 1499–1514, 2017, doi: 10.1007/s00477-016-1272-0.
- [26] A. Hazzab, A. Seddini, A. Ghenaim and K. Korichi, "Hydraulic flood routing in an ephemeral channel: Wadi Mekerra, Algeria," *Modeling Earth Systems and Environment*, vol. 2, pp. 1–12, 2016, doi: 10.1007/s40808-016-0237-0.
- [27] F. Fang, D. B. Thompson, T. G. Cleveland and P. Pradhan, "Variations of time of concentration estimates using NRCS velocity method," *Journal of irrigation and drainage engineering*, vol. 133, no. 4, pp. 314–322, 2007, doi: 10.1061/(ASCE)0733-9437(2007)133:4(314).
- [28] J. Perdikaris, B. Gharabaghi and R. Rudra, "Reference time of concentration estimation for ungauged catchments," *Earth science research*, vol. 7, no. 2, pp. 58–73, 2018, doi: 10.5539/esr.v7n2p58.
- [29] USGS EROS Archive-Digital Elevation-Shuttle Radar Topography Mission (SRTM) 1 Arc-Second Global, United States Geological Survey (USGS) by Earth Resources Observation and Science (EROS) Center, Jul. 2018. [Online]. Available: <https://www.usgs.gov/centers/eros/science/usgs-eros-archive-digital-elevation-shuttle-radar-topography-mission-srtm-1>.
- [30] K. M. Carsell, N. D. Pingel and D. T. Ford, "Quantifying the benefit of a flood warning system," *Natural Hazards Review*, vol. 5, no. 3, pp. 131–140, 2004, doi: 10.1061/(ASCE)1527-6988(2004)5:3(131).
- [31] X. H. Le, H. V. Ho, G. Lee and S. Jung, "Application of long short-term memory (LSTM) neural network for flood forecasting," *Water*, vol. 11, no. 7, 2019, Art. no. 1387.