

แบบจำลองโครงข่ายประสาทเทียมสำหรับการพยากรณ์น้ำท่วมในลุ่มน้ำมูลตอนล่าง

Artificial Neural Network Models for Flood Forecasting in Lower Mun Catchment

ทวี ชัยพิมลผลิน¹ ทวีศักดิ์ วังไพศาล¹

Tawe Chaipimonplin¹ Thaveesak Vangpaisal¹

Received: 8 December 2015; Accepted: 29 March 2016

บทคัดย่อ

งานวิจัยนี้ทำการศึกษาการคัดเลือกข้อมูลนำเข้าโดยใช้จำนวนข้อมูลนำเข้าทั้งหมด เปรียบเทียบกับ เทคนิคการคัดเลือกข้อมูล 5 วิธี (Cross correlation-C, Stepwise regression-S, Cross correlation+Stepwise regression-CS, Genetic algorithms-G และ Supervise-Sp) เพื่อให้แบบจำลองโครงข่ายประสาทเทียมพยากรณ์ระดับน้ำ 24 และ 48 ชั่วโมงล่วงหน้า ณ สถานี M.7 โดยข้อมูลนำเข้าเป็นข้อมูลระดับน้ำรายชั่วโมงจากสถานี M.181 M.179 M.176 และ M.182 นอกจากนี้ยังมีการทดสอบกระบวนการเรียนรู้ของโครงข่ายประสาทเทียม 2 ประเภท (Levenberg-Marquardt algorithm และ Bayesian Regularization algorithm) และหาจำนวนโหนดในชั้นซ่อนเร้นที่เหมาะสม (เพิ่มจำนวนโหนดตั้งแต่ 1 โหนด จนถึงจำนวน $2n+1$) ซึ่งจากผลการวิจัยพบว่า การพยากรณ์ระดับน้ำล่วงหน้า 24 และ 48 ชั่วโมงในเหตุการณ์ปี 2007 เทคนิคการคัดเลือกข้อมูลนำเข้าวิธี C และ CS เป็นเทคนิคที่คัดเลือกข้อมูลที่ดีที่สุด จำนวนโหนดในชั้นซ่อนเร้นที่เหมาะสมคือ 1 โหนดและกระบวนการเรียนรู้ทั้ง 2 ประเภท ให้ผลการพยากรณ์ที่ใกล้เคียงกันโดยมีประสิทธิภาพในการพยากรณ์ค่อนข้างดีโดยมีค่าความคลาดเคลื่อนประมาณ 8.7 และ 12.7 เซนติเมตร หรือ ค่า CE มีค่า 0.99 และ 0.98 สำหรับการพยากรณ์ 24 และ 48 ชั่วโมงล่วงหน้า ตามลำดับ

คำสำคัญ: โครงข่ายประสาทเทียม พยากรณ์น้ำท่วม ลุ่มน้ำมูลตอนล่าง

Abstract

Five input determination techniques (Cross correlation-C, Stepwise regression-S Cross correlation+Stepwise regression-CS, Genetic algorithms-G and Supervise-Sp) were investigated by comparing them using all input variables. An artificial neural network was used for flood forecasting at 24 and 48 hr in advance at M.7 station, and the input variables were hourly water levels monitored from M.181, M.179, M.176 and M.182 stations. In addition, two learning algorithms of the artificial neural network (Levenberg-Marquardt algorithm and Bayesian Regularization algorithm) were investigated. Finding the suitable number of hidden nodes (increasing from 1 to $2n+1$ node) was also included in this research. It was found that for flood forecasting at 24 and 48 hr in a 2007 event, C and CS techniques were the best. The suitable number of hidden nodes was 1 node and both learning algorithms had similar performance. In addition, the model performances were pretty good by error value approximately 8.7 and 12.7 centimeters or CE value with 0.99 and 0.98 for forecasting 24 and 48 hr in advance respectively.

Keywords: Artificial Neural Network, Flood Forecasting, Lower Mun Catchment

¹ อาจารย์, ภาควิชาภูมิศาสตร์ คณะสังคมศาสตร์ มหาวิทยาลัยเชียงใหม่ 50200

¹ Lecturer, Department of Geography, Faculty of Social Sciences, Chiang Mai University, 50200, Thailand
E-mail: tawe.c@cmu.ac.th/chaipimonplin@hotmail.com

บทนำ

ในรอบ 50 ปีที่ผ่านมาบริเวณพื้นที่สะพานเสรีประชาธิปไตย อำเภอเมือง และอำเภวารินชำราบ จังหวัดอุบลราชธานีประสบปัญหาน้ำท่วมจำนวน 23 ครั้ง โดยน้ำท่วมใหญ่จำนวน 9 ครั้ง และรุนแรงมาก 3 ครั้ง (พ.ศ. 2493 2521 และ 2545 ตามลำดับ) ซึ่งในปัจจุบันพบว่าน้ำท่วมแต่ละครั้งใช้ระยะเวลาท่วมขังประมาณ 2-3 เดือน¹ โดยแนวทางในการลดผลกระทบหรือความเสียหายจากน้ำท่วมคือ ควรจะมีการเตือนภัยล่วงหน้า เพื่อที่จะมีเวลาในการเตรียมการป้องกัน โดยในปัจจุบันวิธีการที่นิยมใช้คือ การใช้ความสัมพันธ์การเดินทางของมวลน้ำจากสถานีต้นทางถึงสถานีปลายทาง เช่น ลุ่มน้ำปิง อ่างอิงระดับน้ำจากสถานี P.67 เพื่อเตือนภัยน้ำท่วม สถานี P.1² หรือ ลุ่มน้ำมูล อ่างอิงระดับน้ำจากสถานี M.190 เพื่อเตือนภัยน้ำท่วม สถานี M.9³ เป็นต้น แต่อย่างไรก็ตามในปัจจุบัน กลุ่มงานสารสนเทศและการพยากรณ์น้ำ กรมชลประทานได้เริ่มมีการพัฒนาแบบจำลองโครงข่ายประสาทเทียมสำหรับใช้ในการเตือนภัยน้ำท่วมใน 11 ลุ่มน้ำ เช่น ลุ่มน้ำเจ้าพระยา (C.2) ลุ่มน้ำแม่กลอง (K.37 และ B.10A) ลุ่มน้ำป่าสัก (S.42) เป็นต้น⁴ แบบจำลองโครงข่ายประสาทเทียมจัดอยู่ในกลุ่มของ Black box model ซึ่งโครงข่ายประสาทเทียมเป็นแบบจำลองที่มีลักษณะโครงสร้าง และหลักการทำงานคล้ายสมองคน ซึ่งประกอบด้วยโหนดต่างๆ ซึ่งโครงสร้างมาตรฐานจะประกอบไปด้วย 3 ชั้น คือ ชั้นข้อมูลนำเข้า (Input layer) ชั้นซ่อนเร้น (Hidden layer) และชั้นข้อมูลออกหรือข้อมูลสำหรับพยากรณ์ (Output layer) โดยสามารที่จะเรียนรู้ จัดจำรูปแบบต่างๆ เรียนรู้สิ่งใหม่ๆ ได้ตลอดเวลา ข้อดีของแบบจำลองประเภทนี้ก็สามารถที่เรียนรู้ได้ภายในระยะเวลาอันสั้น⁵ ซึ่งเป็นปัจจัยสำคัญในการเตือนภัยน้ำท่วมล่วงหน้า หรือโครงข่ายประสาทเทียมสามารถที่จะพยากรณ์เหตุการณ์ที่แบบจำลองไม่เคยได้เรียนรู้มาก่อน⁶ ซึ่งสอดคล้องกับสถานการณ์ปัจจุบัน ที่มีแนวโน้มการเกิดน้ำท่วมที่มีความรุนแรงและความถี่มากขึ้น

ทวี ชัยพิมลผลิน⁷ สรุปประเด็นในการที่จะพัฒนาแบบจำลองโครงข่ายประสาทเทียมให้มีความแม่นยำหรือเหมาะสมต่อการพยากรณ์นั้น มีปัจจัยต่างๆ ที่มีผลต่อประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียม เช่น ความถูกต้องของข้อมูล การคัดเลือกข้อมูลนำเข้า การกำหนดจำนวนโหนดในชั้นซ่อนเร้น การคัดเลือกช่วงเหตุการณ์สำหรับการเรียนรู้และทดสอบ หรือ ประเภทของกระบวนการเรียนรู้ที่แตกต่างกัน เป็นต้น โดยถ้ามีการคัดเลือกข้อมูลนำเข้าที่มีนัยสำคัญจะช่วยให้แบบจำลองโครงข่ายประสาทเทียมมีประสิทธิภาพที่มากขึ้น^{8, 9, 10, 11} โดยเทคนิคในการคัดเลือกข้อมูลนำเข้ามีหลายวิธี เช่น วิธี Sensitive Analysis¹² วิธี Partial Mutual Information^{13, 14} วิธี Pruning Algorithm^{14, 15} วิธี Genetic Algorithm^{16, 17} วิธี Step-

wise Regression¹⁰ และ วิธี Correlation Analysis^{10, 14, 18} โดยวิธี Correlation analysis เป็นวิธีที่นิยมและใช้กันอย่างกว้างขวางที่สุด^{19, 20} Chaipimonplin²⁰ ได้ทำการเปรียบเทียบ วิธีการคัดเลือกชนิดข้อมูลนำเข้า ทั้งหมด 8 วิธี สำหรับการพยากรณ์ระดับน้ำที่ลุ่มน้ำปิง และได้สรุปว่า วิธีที่คัดเลือกข้อมูลนำเข้าเหมาะสมสำหรับลุ่มน้ำปิง คือ Stepwise Regression และ Correlation Analysis

จำนวนโหนดในชั้นซ่อนเร้น ถ้ามีน้อยเกินไปจะทำให้แบบจำลองมีประสิทธิภาพลดลง แต่ถ้ามากเกินไปก็อาจจะทำให้แบบจำลองเรียนรู้ดีเกินไปจนเกิดเหตุการณ์ที่เรียกว่า overfitting ซึ่งมีผลต่อการพยากรณ์ทำให้มีความแม่นยำลดลง โดยไม่มีข้อสรุปที่แน่ชัดว่าจำนวนโหนดในชั้นซ่อนเร้นควรมีจำนวนเท่าใด ดังนั้น ASCE⁹ แนะนำว่าการที่จะรู้ว่าจำนวนโหนดจำนวนเท่าใดที่จะเหมาะสมที่สุดในชั้นแอบแฝง ต้องทำการลองผิดลองถูกเองในแต่ละกรณีศึกษา ขึ้นอยู่กับพื้นที่และความซับซ้อนของข้อมูล

สำหรับประเภทการเรียนรู้ของโครงข่ายประสาทเทียมมีกระบวนการเรียนรู้หลายประเภท เช่น Conjugate gradient, Quasi-Newton, Bayesian regularization (BR) และ Levenberg-Marquardt (LM) โดย LM เป็นกระบวนการเรียนรู้ที่รวดเร็วที่สุด และเป็นกระบวนการเรียนรู้มาตรฐานที่ใช้ในโปรแกรม Matlab²¹ โดย LM ถูกนำมาใช้ในการพยากรณ์ด้านอุทกวิทยา เช่น โอม ไทยสวัสดิ์ และคณะ²² ใช้ในการพยากรณ์น้ำท่ารายวัน, Sahoo and Ray²³ ใช้พยากรณ์อัตราการผลิตของน้ำ, Chaipimonplin²⁴ ใช้พยากรณ์ระดับรายชั่วโมง ส่วน BR ถูกนำมาใช้สำหรับการพยากรณ์ด้านอุทกวิทยา เช่น Anctil and Lauzon²⁵ และ Anctil et al.^{16, 26, 27} ใช้พยากรณ์ปริมาณน้ำท่า Chaipimonplin et al.^{28, 29} ใช้พยากรณ์ระดับน้ำรายวัน Zhang and Govindaraju³⁰ ใช้สำหรับพยากรณ์น้ำท่า ทวี ชัยพิมลผลิน³¹ พยากรณ์ระดับน้ำ และ ทวีศักดิ์ วังไพศาล และจักรฤทธิ์ ตรีนาง³² ใช้พยากรณ์ ระดับน้ำรายชั่วโมง เป็นต้น นอกจากนี้ เนื่องจากงานวิจัยของ Chaipimonplin et al.²⁸ สรุปว่า กระบวนการเรียนรู้ BR พยากรณ์ค่าระดับน้ำสูงสุดได้ดีกว่าแบบ LM

ดังนั้นงานวิจัยนี้จึงเป็นการพยากรณ์ระดับน้ำที่สถานี M.7 ตั้งอยู่บริเวณสะพานเสรีประชาธิปไตย อำเภอเมือง จังหวัดอุบลราชธานี โดยใช้ข้อมูลระดับน้ำที่สถานีต้นน้ำของสถานี M.181, M.179, M.176 และ M.182 ซึ่งมีระยะทางตามลำน้ำประมาณ 25.4, 76.1, 76 และ 72.2 กิโลเมตรตามลำดับ³³ โดยมีการเปรียบเทียบการใช้ข้อมูลนำเข้าที่แตกต่างกันการเปรียบเทียบระหว่าง LM และ BR และมีการปรับเปลี่ยนจำนวนโหนดในชั้นซ่อนเร้น

วิธีการวิจัย

พื้นที่ศึกษาและข้อมูล

พื้นที่ศึกษาคือ พื้นที่ลุ่มมูลตอนล่าง (Figure1) โดยพยากรณ์ระดับน้ำล่งหน้าทีสถานี M.7 ที่อยู่ในพื้นที่ลุ่มน้ำมูล ส่วนที่ 3 จังหวัดอุบลราชธานี มีระดับตลิ่งประมาณ 7 เมตร หรือ +112 เมตร เหนือระดับน้ำทะเลปานกลางซึ่งข้อมูลที่ใช้ในการพยากรณ์ระดับน้ำท่วม คือ ข้อมูลระดับน้ำรายชั่วโมง จากสถานี M.181, M.179, M.176 และ M.182 (Figure 2)




Figure 1 Mun Catchment




Figure 2 Water level station in the study area

ข้อมูลระดับน้ำรายชั่วโมงที่มีครบทุกสถานีนั้นมีตั้งแต่ปี ค.ศ. 2007- 2011 ในการคัดเลือกช่วงเวลาของข้อมูลสำหรับการศึกษานี้ จะทำการคัดเลือกช่วงข้อมูลที่เกิดเหตุการณ์น้ำท่วมคือช่วงเดือนสิงหาคมถึงเดือนพฤศจิกายนจากไฮโดรกราฟ (Figure 3) จะพบว่า มีเหตุการณ์น้ำท่วม 4 ปี คือ 2007, 2008, 2009 และ 2011 และ Flood คือระดับของตลิ่ง




Figure 3 Hydrograph at M.7 between 2007-2011

การออกแบบของแบบจำลองและการคัดเลือกข้อมูลนำเข้า

สำหรับการทดสอบความสามารถของแบบจำลองโครงข่ายประสาทเทียมจะใช้เหตุการณ์น้ำท่วมที่ไม่รุนแรง (ปี 2007) เป็นปีทดสอบ (สำหรับเหตุการณ์น้ำท่วมปีที่รุนแรงปี 2011 ในการพยากรณ์ 24 ชั่วโมงล่วงหน้า ดูเพิ่มเติมได้จาก Chaipimonplin and Vangpaisal³⁴ และ 48 ชั่วโมงล่วงหน้า Chaipimonplin and Vangpaisal³⁵) โดยเลือกใช้การเรียนรู้แบบ LM และ BR ซึ่งในการวิจัยนี้ได้กำหนดให้ช่วงข้อมูลสำหรับการเรียนรู้แบบสุ่มซึ่งหมายความว่า ไม่มีการกำหนดช่วงข้อมูลสำหรับตรวจสอบ (Validation) ในการเรียนรู้ เนื่องจากการเรียนรู้แบบ BR ไม่สามารถที่จะกำหนดข้อมูลสำหรับตรวจสอบได้ และเพื่อให้ได้ผลการเรียนรู้ และพยากรณ์ที่เป็นตัวแทนของการทดสอบ จึงทำการเรียนรู้และทดสอบแบบจำลองทั้งสิ้น 50 ครั้งแล้วนำผลพยากรณ์มาหาค่าเฉลี่ยเพื่อเป็นตัวแทนของแบบจำลองในแต่ละประเภทของแบบจำลองเนื่องจากการกำหนดช่วงข้อมูลสำหรับการตรวจสอบความถูกต้องให้เป็นแบบสุ่มซึ่งจะทำให้ผลพยากรณ์ที่ได้จากการสุ่มนี้มีค่าที่แตกต่างกัน และการเรียนรู้แบบ BR เป็นกระบวนการเรียนรู้แบบสุ่ม ดังนั้นเพื่อให้ได้ค่าที่เป็นตัวแทนของแบบจำลองจึงต้องมีการทำการเรียนรู้และทดสอบมากกว่า 1 ครั้ง ส่วนจำนวนรอบที่ต้องทำการเรียนรู้และทดสอบที่ระบุไว้ 50 ครั้งเนื่องจาก เป็นจำนวนรอบที่เหมาะสม^{20, 25}

จำนวนข้อมูลนำเข้าทั้งหมดมีจำนวน 15 ตัวแปร โดยข้อมูลระดับน้ำจากทั้งหมด 5 สถานี และข้อมูลระดับน้ำรายชั่วโมงของแต่ละสถานีจะใช้ข้อมูล ณ เวลา t และ ใช้ข้อมูลย้อนหลังรายชั่วโมง 12 และ 24 ชั่วโมง (t-12 และ t-24) สำหรับการคัดเลือกข้อมูลนำเข้ามี 5 วิธี ได้แก่ วิธี Cross correlation-C (เลือกเฉพาะตัวแปรที่มีความสัมพันธ์ มากกว่า 0.9 โดยโปรแกรม SPSS), วิธี Stepwise regression-S (โดยโปรแกรม SPSS) และใช้ตัวแปรที่มีค่าสหสัมพันธ์มากกว่า 0.9 ใส่ในกระบวนการ Stepwise regression เพื่อคัดเลือกตัวแปรอีกขั้นหนึ่ง (Cross correlation+Stepwise regression-CS) โดยใช้

โปรแกรม SPSS ในการวิเคราะห์ วิธี Genetic algorithms-G ใช้โปรแกรม WEKA รุ่น 3.6.8³⁶ และวิธีเลือกโดยผู้วิจัย (Sp) โดยใช้ข้อมูลนำเข้าเฉพาะเวลาปัจจุบัน (t) นอกจากนั้นยังมีการใช้ตัวแปรที่มีทั้งหมด (A) มาเปรียบเทียบกับเทคนิคต่างๆ

การกำหนดจำนวนโหนดในชั้นซ่อนเร้นจะเพิ่มจำนวนโหนดทีละ 1 โหนด แต่ไม่ให้เกินจำนวน $2n+1$ (n คือจำนวนข้อมูลนำเข้าและการพยากรณ์ 24(A) และ 48 (B) ชั่วโมงล่วงหน้า ดังนั้นแบบจำลองในบทความนี้สามารถแบ่งได้จำนวน 12 แบบจำลอง (AC, AS, ACS, AG, ASp, AA, BC, BS, BCS, BG, BSp, BA)

การประเมินประสิทธิภาพ

สำหรับการประเมินประสิทธิภาพของแบบจำลองจะใช้ค่าสถิติ Peak Difference (PDIFF), Root Mean Squared Error (RMSE), Coefficient of Efficiency (CE)³⁷ โดย PDIFF คือค่าความแตกต่างของระดับน้ำสูงสุด (ค่าผลต่าง ณ จุดระดับน้ำที่สูงระหว่างค่าจริงที่วัดได้ และค่าเฉลี่ยจากแบบจำลอง ถ้าค่าติดลบ หมายถึงแบบจำลองพยากรณ์ระดับน้ำต่ำกว่าระดับจริง), RMSE คือ ค่าความคลาดเคลื่อนรวมระหว่างค่าจริงและค่าจากแบบจำลองค่าที่เข้าใกล้ 0 หมายถึงแบบจำลองมีประสิทธิภาพที่ดีและ CE คือค่าความสัมพันธ์ระหว่างค่าจริงและค่าจากแบบจำลองถ้าค่าใกล้ 1 หมายถึงแบบจำลองมีประสิทธิภาพที่ดี

ผลการวิจัยและอภิปราย

ผลการพยากรณ์ 24 ชั่วโมงล่วงหน้า

ผลการคัดเลือกข้อมูลนำเข้า (Table 1) พบว่าสำหรับการพยากรณ์ 24 ชั่วโมงล่วงหน้า (t+24) เทคนิค Cross correlation และ Stepwise regression เลือกข้อมูลเหมือนกัน โดยเลือกข้อมูลจาก 4 สถานี ยกเว้น M.176 ส่วนเทคนิคผสมมีการลดจำนวนข้อมูลนำเข้าโดยการตัด M.179_24 และ M.181_12 ออกไปทำให้เหลือจำนวนข้อมูลเพียง 10 ตัวแปร แต่สำหรับเทคนิค Genetic algorithms เลือกข้อมูล M.176_24 และไม่เลือกข้อมูล M.181_24 และ M.182_24 (แต่เทคนิค C, CS, S เลือก) ในการคัดเลือกข้อมูลนำเข้าสำหรับการพยากรณ์ 48 ชั่วโมงล่วงหน้า (t+48) พบว่าเทคนิค C มีการคัดเลือกข้อมูลนำเข้าเหมือนกันการพยากรณ์ 24 ชั่วโมงล่วงหน้า ส่วนเทคนิค S มีการคัดเลือกข้อมูลเพิ่มจากเทคนิค C คือ M.176 และ M.176_12 โดยมีการตัดข้อมูล M.179_24 ออกไป แต่สำหรับเทคนิค G เลือก M.176 แทน M.176_24 (Table 2)

Table 1 Input variables t+24

Variables	Input determination techniques				
	AC	AS	ACS	AG	ASp
M.7	X	X	X	X	X
M.7_12	X	X	X	X	
M.7_24	X	X	X	X	
M.181	X	X	X	X	X
M.181_12	X	X		X	
M.181_24	X	X	X		
M.179	X	X	X	X	X
M.179_12	X	X	X	X	
M.179_24	X	X		X	
M.176					X
M.176_12					
M.176_24				X	
M.182	X	X	X	X	X
M.182_12	X	X	X	X	
M.182_24	X	X	X		
Total	12	12	10	11	5

Table 2 Input variables t+48

Variables	Input determination techniques				
	BC	BS	BCS	BG	BSp
M.7	X	X	X	X	X
M.7_12	X	X	X	X	
M.7_24	X	X	X	X	
M.181	X	X	X	X	X
M.181_12	X	X	X	X	
M.181_24	X	X	X		
M.179	X	X	X	X	X
M.179_12	X	X	X	X	
M.179_24	X				
M.176		X		X	X
M.176_12		X			
M.176_24					
M.182	X	X	X		X
M.182_12	X	X	X	X	
M.182_24	X	X	X		
Total	12	13	11	9	5

ผลการพยากรณ์ 24 ชั่วโมงล่วงหน้าเมื่อพิจารณาค่าสถิติ CE และ RMSE (Figure 4) พบว่าแบบจำลองที่เรียนรู้แบบ LM และ BR มีค่าสถิติที่ใกล้เคียงกันยกเว้นแบบจำลองที่มีการใช้ข้อมูลนำเข้าทั้งหมด (AA) โดยการเรียนรู้ BR ให้ผลการพยากรณ์ที่ค่อนข้างเสถียรกว่า LM เมื่อมีการเพิ่มจำนวนโหนดในชั้นซ่อนเริ่มมีจำนวนมากขึ้น โดยจำนวนโหนดชั้นซ่อนเริ่มที่ให้ผลการพยากรณ์ที่ดีที่สุดคือ 1 โหนด




Figure 4 CE and RMSE of ANN models for t+24 hr

ค่าสถิติในแต่ละแบบจำลองแสดงใน (Table 3) ซึ่งทุกแบบจำลองที่มีเทคนิคการคัดเลือกข้อมูลนำเข้าที่แตกต่างกันเล็กน้อย แบบจำลองที่มีการคัดเลือกข้อมูลนำเข้า AC/AS และ ACS มีค่าสถิติที่ดีที่สุด โดยค่า CE มีค่า 0.990 ส่วนค่า RMSE มีค่า 0.087 ส่วน ASp ให้ค่าสถิติที่แย่ที่สุด ซึ่งแสดงว่าใช้ข้อมูลนำเข้าเฉพาะเวลาปัจจุบันไม่เพียงพอสำหรับการพยากรณ์ล่วงหน้า 24 ชั่วโมง หรือแบบจำลอง AA ที่มีการใช้ข้อมูลนำเข้าทุกตัวซึ่งทำให้มีข้อมูลที่มากเกินไปหรือเป็นข้อมูลที่ไม่มีความสัมพันธ์จะทำให้การพยากรณ์มีประสิทธิภาพลดลงหรือไม่มีส่วนช่วยให้มีประสิทธิภาพเพิ่มมากขึ้น

Table 3 RMSE and CE for ANN model performances t+24

Model	t+24			
	RMSE		CE	
	LM	BR	LM	BR
AC/AS	0.087	0.087	0.990	0.990
ACS	0.087	0.087	0.990	0.990
AG	0.093	0.092	0.989	0.989
ASp	0.146	0.146	0.973	0.973
AA	0.093	0.093	0.989	0.989

สำหรับไฮโดรกราฟในช่วงน้ำท่วม (Figure 5) พบว่าในภาพรวมการเรียนรู้แบบ BR และ LM ให้ผลที่ไม่แตกต่างกัน และช่วงที่ระดับน้ำเริ่มล้นตลิ่ง พบว่าแบบจำลองไม่สามารถที่จะพยากรณ์เตือนภัยน้ำท่วมล่วงหน้าได้โดยมีการพยากรณ์ช้ากว่าเหตุการณ์จริงประมาณ 12 ชั่วโมง ยกเว้นแบบจำลอง ASp ที่สามารถพยากรณ์ช่วงระยะเวลาการเกิดที่ระดับน้ำเริ่มล้นตลิ่งได้ล่วงหน้า ซึ่งอาจจะแสดงว่าข้อมูลเฉพาะเวลาปัจจุบันของทั้ง 5 สถานี เป็นข้อมูลที่เหมาะต่อการใช้เตือนภัยน้ำท่วมล่วงหน้าถึงแม้ว่าในภาพรวมค่า CE จะมีค่าต่ำกว่าการคัดเลือกข้อมูลนำเข้าประเภทอื่นๆ ก็ตาม

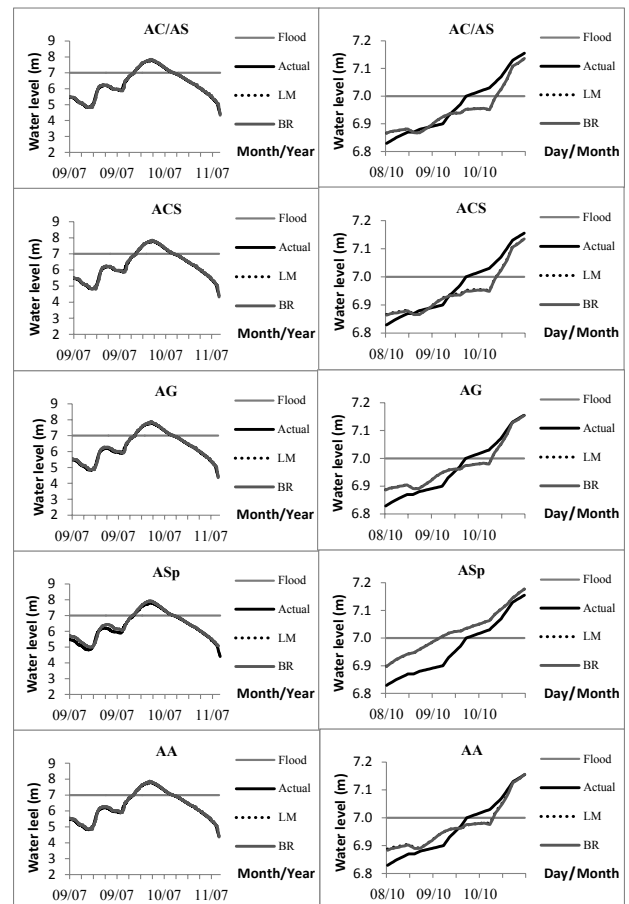


Figure 5 Hydrographs for t+24 hr

เมื่อพิจารณาการพยากรณ์ระดับน้ำสูงสุด ในภาพรวม การเรียนรู้ทั้งสองประเภทให้ผลที่ค่อนข้างเหมือนกัน แต่เมื่อมีการใช้ข้อมูลนำเข้าและจำนวนโหนดในชั้นซ่อนเร้นที่แตกต่างกันจะมีผลต่อการพยากรณ์ค่าระดับน้ำสูงสุดแบบจำลอง AC/AS ซึ่งจำนวนโหนดที่เหมาะสมที่สุดคือ 16 และที่มีการเรียนรู้ BR ให้ค่าที่ค่อนข้างดีกว่า LM เมื่อพิจารณาค่าสถิติ CE และ RMSE แบบจำลอง ที่มีจำนวนโหนดในชั้นซ่อนเร้น 1 โหนดมีประสิทธิภาพดีที่สุด ซึ่งพยากรณ์ค่าระดับน้ำสูงสุดได้สูงกว่าระดับจริงประมาณ 5 เซนติเมตร ซึ่งเทคนิคที่พยากรณ์ได้ใกล้เคียงกับค่าจริงพบว่า เป็นเทคนิคที่ไม่มีการคัดเลือกข้อมูลนำเข้าของสถานี M.176 (Figure 6)




Figure 6 PDIFF of ANN models for t+24 hr

ผลการพยากรณ์ 48 ชั่วโมงล่วงหน้า

การเรียนรู้ LM และ BR ให้ผลการพยากรณ์ที่ใกล้เคียงกัน โดยเทคนิคการคัดเลือกข้อมูลนำเข้าจะมีประสิทธิภาพลดลงเมื่อมีการเพิ่มจำนวนโหนดในชั้นซ่อนเร้น โดยจำนวนโหนดในชั้นซ่อนเร้นที่มีจำนวนไม่เกินร้อยละ 50 ของจำนวนข้อมูลนำเข้า (เช่น กรณีแบบจำลอง BC มีจำนวนข้อมูลนำเข้า 12 ตัวแปร (Table 2) จำนวนโหนดในชั้นซ่อนเร้นควรมีจำนวนไม่มากกว่า 6 โหนด) จะให้ผลแตกต่างกันเล็กน้อย แต่เมื่อจำนวนโหนดมีมากกว่าร้อยละ 50 ประสิทธิภาพของแบบจำลองจะลดลง (Figure 7)




Figure 7 CE and RMSE of ANN models for t+48 hr

โดยจำนวนโหนด 1 โหนดมีความแม่นยำมากที่สุด ซึ่งมีค่า CE และ RMSE ที่ดีที่สุด โดยเทคนิคการคัดเลือกข้อมูลนำเข้า BCS, BC และ BS ให้ผลการพยากรณ์ที่ดีกว่าการคัดเลือกข้อมูลแบบ BG, BSp และ BA ซึ่งเมื่อพิจารณาค่าสถิติแล้ว เทคนิค BCS และ BC ให้ผลการพยากรณ์ที่ดีที่สุด (Table 4)

Table 4 RMSE and CE for ANN model performances t+48

Model	t+48			
	RMSE		CE	
	LM	BR	LM	BR
BC	0.128	0.128	0.980	0.980
BS	0.144	0.143	0.975	0.975
BCS	0.127	0.127	0.980	0.980
BG	0.151	0.151	0.972	0.972
BSp	0.284	0.285	0.935	0.935
BA	0.144	0.143	0.975	0.975

ส่วนกระบวนการเรียนรู้แบบ BR และ LM ให้ผลที่ไม่แตกต่างกัน และช่วงที่ระดับน้ำเริ่มล้นตลิ่ง ผลการพยากรณ์คล้ายกับการพยากรณ์ ณ 24 ชั่วโมงล่วงหน้า ซึ่งแบบจำลองบางแบบจำลองไม่สามารถที่จะพยากรณ์เตือนภัยน้ำท่วมล่วงหน้าได้โดยมีการพยากรณ์ช้ากว่าเหตุการณ์จริงค่อนข้างมาก

ยกเว้นแบบจำลอง BS, BSp และ BA ที่สามารถพยากรณ์ระดับน้ำล้นตลิ่งได้ล่วงหน้า โดย BSp พยากรณ์ได้ล่วงหน้ากว่าเหตุการณ์จริงมากกว่า 24 ชั่วโมง ซึ่งแสดงให้เห็นว่าผลที่แบบจำลอง BSp พยากรณ์ก่อนเหตุการณ์จริงเป็นค่าความผิดพลาดของแบบจำลองที่เกิดขึ้นซึ่งอาจจะแสดงว่าข้อมูลเฉพาะเวลาปัจจุบันของทั้ง 5 สถานี เป็นข้อมูลที่อาจจะไม่เพียงพอในการพยากรณ์ล่วงหน้าที่ค่อนข้างยาวนาน คือ 48 ชั่วโมง แต่อย่างไรก็ตามแบบจำลอง BS และ BA (มีข้อมูลนำเข้าที่ถูกคัดเลือกมากที่สุด 13 และ 15 ข้อมูลนำเข้า ตามลำดับ) แสดงผลการพยากรณ์ระดับน้ำล้นตลิ่งได้ค่อนข้างดีกว่าแบบจำลองประเภทอื่นๆซึ่งอาจจะแสดงว่าในการพยากรณ์ล่วงหน้าที่ยาวนานจำนวนข้อมูลนำเข้าอาจจะส่งผลต่อประสิทธิภาพในการพยากรณ์ของแบบจำลอง นอกจากนี้ข้อมูลนำเข้าของสถานี M.176 มีผลต่อประสิทธิภาพในการพยากรณ์ 48 ชั่วโมงล่วงหน้า โดยแบบจำลอง BC และ BCS เป็นเพียง 2 แบบจำลองที่ไม่มีการเลือกข้อมูลนำเข้าจากสถานี M.176 ทำให้แบบจำลองไม่สามารถที่จะพยากรณ์เตือนภัยน้ำท่วมได้ (Figure 8)




Figure 8 Hydrographs for t+48 hr

สำหรับการพยากรณ์ระดับน้ำสูงสุดในการพยากรณ์ 48 ชั่วโมงล่วงหน้า ซึ่งการเรียนรู้ BR จะให้ผลที่แม่นยำกว่า LM และเมื่อมีจำนวนโหนดในชั้นซ่อนเร้นมากกว่า ร้อยละ 50 ของจำนวนข้อมูลนำเข้า สำหรับจำนวนโหนดที่มีค่าสถิติ CE และ RMSE ที่ดีที่สุด คือ 1 โหนด พยากรณ์ค่าระดับน้ำสูงสุดเกินกว่าระดับจริงประมาณ 10 เซนติเมตร และแบบจำลองที่ให้ความแม่นยำมากที่สุดคือ BC และ BCS เมื่อพิจารณาข้อมูลนำเข้าพบว่า BC และ BCS ไม่ได้คัดเลือกข้อมูลนำเข้า M. 176 ซึ่งอาจจะแสดงให้เห็นว่าข้อมูลระดับน้ำ M.176 มีผลต่อความแม่นยำในการพยากรณ์ค่าระดับน้ำสูงสุด ต่อสถานี M.7 (Figure 9)

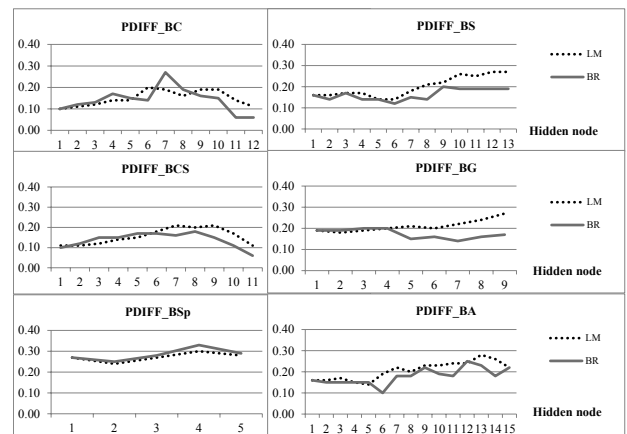


Figure 9 PDIFF of ANN models for t+48 hr

สรุปและข้อเสนอแนะ

จากผลการพยากรณ์น้ำท่วมเหตุการณ์ที่ไม่รุนแรง ปี 2007 พบว่า ในการพยากรณ์ระดับน้ำล้นตลิ่งนั้นแบบจำลองที่มีค่า CE, RMSE ที่ดีที่สุดพยากรณ์ระดับ (0.99 และ 0.087 ตามลำดับ) น้ำล้นตลิ่งได้ช้ากว่าเวลาจริง แต่เนื่องจากพื้นที่น้ำท่วมในบริเวณ สถานี M.7 นั้นจะเป็นการเพิ่มขึ้นของระดับอย่างช้าๆ และเมื่อท่วมแต่ละครั้งจะท่วมประมาณ 1 เดือน ดังนั้น สำหรับการพยากรณ์ระดับน้ำ ณ สถานี M.7 ควรจะมุ่งไปที่การพยากรณ์ค่าระดับน้ำท่วมสูงสุด เพื่อเป็นข้อมูลประกอบการตัดสินใจ วางแผน ป้องกัน น้ำท่วม สำหรับหน่วยงานราชการที่เกี่ยวข้อง ดังนั้น แบบจำลองที่เหมาะสมสำหรับการวางแผนในพื้นที่ศึกษานี้ ควรจะเป็นแบบจำลองที่พยากรณ์ค่าระดับน้ำสูงสุดได้ใกล้เคียงที่สุด เมื่อพยากรณ์ 24 และ 48 ชั่วโมงล่วงหน้า คือเทคนิคการคัดเลือกข้อมูลนำเข้าแบบ C, S และ CS

กิตติกรรมประกาศ

ขอขอบคุณกองทุนพัฒนาวิชาการ คณะสังคมศาสตร์ มหาวิทยาลัยเชียงใหม่ ขอขอบคุณสำหรับข้อมูลระดับน้ำจากศูนย์อุทกวิทยาและบริหารน้ำ ภาคตะวันออกเฉียงเหนือตอนล่าง และสำนักงานคณะกรรมการวิจัยแห่งชาติ ที่ได้สนับสนุนงบประมาณในการทำวิจัยครั้งนี้

เอกสารอ้างอิง

- คณะวิศวกรรมศาสตร์ มหาวิทยาลัยอุบลราชธานี. โครงการศึกษาสภาพและแนวทางแก้ไขปัญหาการเกิดอุทกภัย จังหวัดอุบลราชธานี. 2547.
- ศูนย์อุทกวิทยาและบริหารน้ำภาคเหนือตอนบน. บอร์ดเตือนภัยสถานี P.1.2558.ได้จาก:URL: <http://hydro-1.net/08HYDRO/PORTAL/IMAGES/100119-BOARD-P1aaaa.jpg> 2 กุมภาพันธ์ 2558.
- ศูนย์อุทกวิทยาและบริหารน้ำภาคตะวันออกเฉียงเหนือตอนล่าง. แผ่นพับเตือนภัยน้ำท่วม.2558ได้จาก: URL: <http://www.hydro-4.com> 2 กุมภาพันธ์ 2558.
- สุรพันธ์ อินแก้ว. แผนที่จุดคาดการณ์น้ำท่าปี 2555.2555.ได้จาก:URL: <http://water.rid.go.th/itcwater/utok/MAP.jpg>:2 กุมภาพันธ์ 2558.
- Haykin S. Neural Networks – A Comprehensive Foundation. 2nded. New Jersey: Prentice-Hall; 1999.
- Kasabov N. Foundations of Neural Network, Fuzzy Systems, and Knowledge Engineering. Cambridge MA: The MIT Press; 1996.
- ทวี ชัยพิมลผลิน. ภูมิศาสตร์และโครงข่ายประสาทเทียมใน งานวิจัยทางภูมิศาสตร์. 2557; 67-75.
- AbrahartRJ, See L. Kneale PE. Investigating the role of saliency analysis with a neural network rainfall-runoff model. Computers & Geosciences 2001;27:921-928.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. Artificial neural networks in hydrology I: Preliminary concepts. Journal of Hydrologic Engineering 2000;5:115-123.
- Chaipimonplin T, See LM, Kneale PE. Neural network prediction of flooding in Chiang Mai, Thailand: comparison of input determination techniques. EGU General Assembly 2008, Vienna, Austria. April 2008.
- Dawson CW, Wilby RL. Hydrological modelling using artificial neural networks. Progress in Physical Geography 2001;25(1):80-108.
- Sudheer KP. Knowledge extraction from trained neural network river flow models. Journal of Hydrologic Engineering 2005; 10, 264-269.
- Bowden GJ, Dandy GC, Maier HR. Input determination for neural network models in water resources applications. Part 1-background and methodology. J Hydrology 2001;301:75-92.
- Chaipimonplin T, See LM, Kneale PE. Use of neural network to predict flooding in Chiang Mai, Thailand: comparison of input determination techniques. AOGS 2008, Pusan, South Korea, June 2008.
- Cheen ST, Yu PS. Pruning of Support vector networks on flood forecasting. J Hydrology 2007;347:67-78.
- Anctil F, Lauzon N, Andreassian V, Oudin L, Perrin C. Improvement of rainfall-runoff forecasts through mean areal rainfall optimization. J Hydrology 2006;328:717-725.
- Heo GS, Oh IS. Simultaneous node pruning of input and hidden layers using genetic algorithms, Proceedings of 2008 International Conference on Machine Learning and Cybernetics. Chian: IEEE
- Shevnina EV. Methods of long-rang forecasting of dates of the spring flood beginning and peak flow in the Estuary sections of the Ob and Yenisei Rivers. Russian Meteorology and Hydrology 2009;34:51-57.
- Maier HR, Jain A, Dandy GC, Sudheer KP. Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions. Environmental Modelling & Software 2010;25: 891-909.
- Chaipimonplin T. An Exploration of Neural Network Modelling Options for the UpperRiverPing, Thailand. PhD in Physical Geography. Leeds: University of Leeds; 2010.
- Beale MH, Hagan MT, Demuth HB. Neural Network Toolbox™ 7 User's Guide, The Math Works, Inc., Natick, MA, 2011.
- โอม ไทยสวัสดิ์, นุชนารถ ศรีวงศิตานนท์, สุรัชย์ ลิปิวัฒนา การ. การประเมินน้ำท่ารายวันในลุ่มน้ำขนาดเล็กที่ไม่มี การวัดน้ำท่าโดยแบบจำลองโครงข่ายประสาทเทียม. การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ ครั้งที่ 12, พฤษภาคม 2550 161-167.
- Sahoo GB, Ray C. Flow forecasting for a Hawaii stream using rating curves and neural networks. J Hydrology 2006;317:63-80.
- Chaipimonplin T. Investigation internal parameter of neural network model for flood forecasting at Upper

- River Ping, Thailand. *KSCE Journal of Civil Engineering* 2016;20(1): 478-484.
25. Anctil F, Lauzon N. Generalisation for neural networks through data sampling and training procedures, with applications to streamflow predictions. *Hydrological Earth System Science* 2004;8:940-58.
26. Anctil F, Michel C, Perrin C, Andreassian V. A soil moisture index as an auxiliary ANN input for stream flow forecasting. *J Hydrology* 2004;286:155-67.
27. Anctil F, Perrin C, Andreassian V. Impact of the length of observed records on the performance of ANN and of conceptual parsimonious rainfall-runoff forecasting models. *Environmental Modelling & Software* 2004;19:357-68.
28. Chaipimonplin T, See LM, Kneale PE. Comparison of neural network learning algorithms; BR and LM for flood forecasting, Upper Ping catchment. *USMCA 2001, 10th International Symposium on New Technologies for Urban Safety Mega Cities in Asia, 2011 October*; Chiang Mai, Thailand.
29. Chaipimonplin T, See LM, Kneale PE. Improving Neural Network for Flood Forecasting Using Radar Data on the Upper Ping River. In Chan F, Marinova D, Anderssen RS, editors. *MODSIM2011, Proceedings of the 19th International Congress on Modelling and Simulation*; 2011 December 12-16; Perth, Australia. Modelling and Simulation Society of Australia and New Zealand; 2011.p. 1070-6.
30. Zhang B, Govindaraju RS. Prediction of watershed runoff using Bayesian concepts and modular neural networks. *Water Resources Research* 2000;36: 753-62.
31. ทวี ชัยพิมลผลิน. การใช้ภาพเรดาร์และข้อมูลอุทกวิทยา ร่วมกับแบบจำลองโครงข่ายประสาทเทียมสำหรับการพยากรณ์น้ำท่วมในลุ่มน้ำปิงตอนบน. *วารสารวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยมหาสารคาม* 2557;33(3): 267-274.
32. ทวีศักดิ์ วั่งไพศาล, จักรฤทธิ์ ตรีนาจ. ปัจจัยที่มีผลต่อความแม่นยำในการพยากรณ์ระดับน้ำหลากที่สถานีวัดระดับน้ำ M.7 โดยใช้แบบจำลองโครงข่ายประสาทเทียม. *วารสารวิชาการ วิศวกรรมศาสตร์ ม.อบ* 2556;6(1): 50-60.
33. ศูนย์อุทกวิทยาชลประทานภาคตะวันออกเฉียงเหนือตอนล่าง. แผนภูมิแสดงสถานีสำรวจอุทกวิทยา ลุ่มน้ำมูล, กรมชลประทาน 2559.
34. Chaipimonplin T, Vangpaisal T. Comparison of the efficiency of input determinations techniques with LM and BR algorithms in ANN for flood forecasting, Mun Basin, Thailand. *International Journal of Computer and Electrical Engineering* 2014;6:90-94.
35. Chaipimonplin T, Vangpaisal T. The efficiency of input determinations techniques in ANN for flood forecasting, Mun Basin, Thailand. *Journal of Water Resource and Hydraulic Engineering*. 2015;4:131-137
36. WEKA. The University of Waikato, available from: URL:<http://www.cs.waikato.ac.nz/ml/weka/downloading.html> Accessed March 2013.
37. Hydrotest. References[online], available from: URL: www.hydrotest.org.uk Accessed April 2013