

การเปรียบเทียบ 12 กระบวนการเรียนรู้ของแบบจำลองโครงข่ายประสาทเทียมสำหรับการพยากรณ์น้ำท่วมในลุ่มน้ำปิงตอนบน

Comparison of 12 Learning Algorithms of Artificial Neural Network Models for Flood Forecasting in the Upper Ping Catchment

ทวี ชัยพิมลผลิน

Tawe Chaipimonplin

Received: 5 June 2017 ; Accepted: 13 November 2017

บทคัดย่อ

กระบวนการเรียนรู้ของโครงข่ายประสาทเทียมในโปรแกรม MATLAB มีทั้งสิ้น 12 ประเภท (Levenberg-Marquardt-LM, Bayesian Regularization-BR, BFGS Quasi-Newton-BFG, Resilient Backpropagation-RP, Scaled Conjugate Gradient-SCG, Conjugate Gradient with Powell/Beale Restarts-CGB, Fletcher-Powell Conjugate Gradient-CGF, Polak-Ribiere Conjugate Gradient-CGP, One Step Secant-OSS, Variable Learning Rate Gradient Descent-GDX, Gradient Descent with Momentum-GDM และ Gradient Descent-GD) ซึ่งแต่ละประเภทจะมีขั้นตอนการเรียนรู้ที่ต่างกัน ดังนั้นบทความนี้จะทำการเปรียบเทียบหากระบวนการเรียนรู้ที่เหมาะสมสำหรับการพยากรณ์น้ำท่วม 6 และ 12 ชั่วโมงล่วงหน้า ณ สถานี P.1 โดยมีการเลือกใช้วิธีการคัดเลือกข้อมูลนำเข้า 4 วิธี (Cross Correlation-C, Stepwise Regression-S, Cross Correlation+Stepwise Regression-CS และ Genetic Algorithms-G) และยังมีกำหนดจำนวนโหนดในชั้นซ่อนเร้น จำนวน 1 โหนด และ จำนวนโหนดในชั้นซ่อนเร้นที่อ้างอิงตามจำนวนตัวแปรนำเข้า ร้อยละ 25, 50, 75 และ 100 จากผลการทดสอบพบว่า กระบวนการเรียนรู้แต่ละประเภทส่วนมากให้ผลการพยากรณ์ที่คล้ายกัน ($R^2 = 0.99$ และ 0.97) แต่อย่างไรก็ตามสามารถสรุปได้ว่า SCG, CGB, CGP, OSS หรือ LM เป็นกระบวนการเรียนรู้ที่เหมาะสมที่สุด เพราะสามารถพยากรณ์น้ำท่วมได้ดีและเป็นกระบวนการเรียนรู้ที่ค่อนข้างเร็ว (ประมาณ 1-2 นาที) ด้วยจำนวนโหนดในชั้นซ่อนเร้นไม่เกิน ร้อยละ 50 และ การคัดเลือกข้อมูลนำเข้าที่เหมาะสมคือ วิธี C และ CS สำหรับการพยากรณ์น้ำท่วม 6 และ 12 ชั่วโมงล่วงหน้า ณ สถานี P.1

คำสำคัญ: โครงข่ายประสาทเทียม การพยากรณ์น้ำท่วม กระบวนการเรียนรู้ ลุ่มน้ำปิงตอนบน

Abstract

There are 12 Learning algorithms of artificial neural networks in the MATLAB program (Levenberg-Marquardt-LM, Bayesian Regularization-BR, BFGS Quasi-Newton-BFG, Resilient Backpropagation-RP, Scaled Conjugate Gradient-SCG, Conjugate Gradient with Powell/Beale Restarts-CGB, Fletcher-Powell Conjugate Gradient-CGF, Polak-Ribiere Conjugate Gradient-CGP, One Step Secant-OSS, Variable Learning Rate Gradient Descent-GDX, Gradient Descent with Momentum-GDM and Gradient Descent-GD) and each learning algorithm type has a difference in its learning process. Therefore, in this article 12 learning algorithms were compared to find the one most suitable for flood forecasting at P.1 station, t+6 and t+12 hr. using 4 input determination techniques (Cross Correlation-C, Stepwise Regression-S, Cross Correlation+Stepwise Regression-CS and Genetic Algorithms-G), also hidden nodes were set to 1 node and based on number of input variables 25%, 50%, 75% and 100%. It was found that the majority of

¹ ผู้ช่วยศาสตราจารย์, ภาควิชาภูมิศาสตร์ คณะสังคมศาสตร์ มหาวิทยาลัยเชียงใหม่ 50200

¹ Assistant Professor, Department of Geography, Faculty of Social Sciences, Chiang Mai University, 50200, Thailand

E-mail: tawe.c@cmu.ac.th/ chaipimonplin@hotmail.com

learning algorithms gave the similar results of flood forecasting ($R^2 = 0.99$ and 0.97). In conclusion, however, for flood forecasting t+6 and t+12 hr in advance at P.1 station, SCG, CGB, CGP, OSS or LM are the most suitable learning algorithms because all of them can forecast flood events and they seem to be the fastest learning algorithms (approximately 1-2 minutes), with number of hidden nodes are not greater than 50% of number of input variables and the suitable process of input determination techniques are C and CS.

Keywords: Artificial Neural Network, Flood Forecasting, Learning Algorithms, Upper Ping Catchment

บทนำ

ในแต่ละปีเหตุการณ์น้ำท่วมมักจะเกิดเกือบทุกปีในประเทศไทย และในทุกๆ ครั้งที่เกิดน้ำท่วมจะก่อให้เกิดความเสียหายไม่มากนักน้อย ซึ่งระดับความเสียหายขึ้นอยู่กับระดับความรุนแรงของน้ำท่วม และประสิทธิภาพของระบบการจัดการ (การเตือนภัย การป้องกัน การให้ความช่วยเหลือ การบรรเทาภัย) สำหรับการพยากรณ์เตือนภัยน้ำท่วมในลุ่มน้ำปิงตอนบนจะเป็นการใช้ระดับน้ำจากสถานีต้นน้ำเป็นเกณฑ์ โดยระยะเวลาการเตือนภัยล่วงหน้าขึ้นอยู่กับระยะทางการเดินทางของมวลน้ำ จากสถานีต้นน้ำไปยังสถานีปลายน้ำ เช่น ในลุ่มน้ำปิงตอนบน อำเภอเมืองเชียงใหม่ ศูนย์อุทกวิทยาและบริหารน้ำ ภาคเหนือตอนบน จะพยากรณ์เตือนภัยน้ำท่วม สถานี P.1 โดยอาศัยความสัมพันธ์ของระดับน้ำของสถานี P.67 โดยมวลน้ำใช้ระยะเวลาเดินทางจากสถานีต้นน้ำ P.67 ไปยัง P.1 ใช้เวลาประมาณ 6-7 ชั่วโมงในระยะห่างประมาณ 32 กิโลเมตร¹ ดังนั้นในการพยากรณ์เตือนภัยน้ำท่วมโดยใช้การวิเคราะห์จาก สถานีต้นน้ำ จึงถูกจำกัดด้วยระยะทางระหว่างสถานี

งานวิจัยสำหรับการประยุกต์ใช้แบบจำลองโครงข่ายประสาทเทียมในงานด้านอุทกภัยที่สืบค้นจากฐานข้อมูลวิทยานิพนธ์ไทยจากโครงการเครือข่ายห้องสมุดไทย, Science Direct, Scopus และ Web of Science พบว่าในประเทศไทยเริ่มมีการใช้ครั้งแรกตั้งแต่ปี พ.ศ. 2535² โดยเป็นวิทยานิพนธ์ของสถาบันเทคโนโลยีแห่งเอเชีย (AIT)³ และในปัจจุบันยังมีการศึกษาในการประยุกต์ใช้แบบจำลองโครงข่ายประสาทเทียมทั้งในด้านอุทกวิทยา⁴ ด้านพลังงาน⁵ ด้านโรงงานอุตสาหกรรม⁶ ด้านการแพทย์⁷ ด้านไฟฟ้า⁸ ด้านอาชญากรรม⁹ ด้านดินถล่ม¹⁰ และด้านผลผลิตทางการเกษตร¹¹ และด้านเศรษฐกิจ¹² เป็นต้น แต่อย่างไรก็ตามงานวิจัยส่วนมากจะศึกษาในประเด็นประเภทของกลุ่มข้อมูล¹³ และจำนวนตัวแปรข้อมูลนำเข้าที่เหมาะสม¹⁴ หรือมีการปรับเปลี่ยนโครงสร้างสถาปัตยกรรมของแบบจำลองโครงข่ายประสาทเทียม โดยการเพิ่มการเพิ่มของจำนวนโหนดในชั้นซ่อนเร้น¹⁵ หรือการเพิ่มจำนวนชั้นซ่อนเร้น¹⁶ หรือมีเพียงบางงานวิจัยที่มีการเปรียบเทียบประสิทธิภาพของกระบวนการ

เรียนรู้ เช่น เปรียบเทียบระหว่างการเรียนรู้ระหว่าง LM และ BR¹⁷⁻²⁰ แต่เนื่องจากกระบวนการเรียนรู้ของโครงข่ายประสาทเทียมมีหลายประเภท โดยสำหรับโปรแกรม Matlab²¹ มีกระบวนการเรียนรู้ทั้งหมด 12 ประเภท (Levenberg-Marquardt-LM, Bayesian Regularization-BR, BFGS Quasi-Newton-BFG, Resilient Backpropagation-RP, Scaled Conjugate Gradient-SCG, Conjugate Gradient with Powell/Beale Restarts-CGB, Fletcher-Powell Conjugate Gradient-CGF, Polak-Ribiere Conjugate Gradient-CGP, One Step Secant-OSS, Variable Learning Rate Gradient Descent-GDX, Gradient Descent with Momentum-GDM และ Gradient Descent-GD) โดยการใช้หลักการเรียนรู้จากวิธี gradient หรือ Jacobian เป็นพื้นฐานในการเรียนรู้ งานวิจัยที่ศึกษาเปรียบเทียบกระบวนการเรียนรู้ประเภทต่างๆ คือ Beale et al.²¹ ได้ทำการทดสอบกระบวนการเรียนรู้ 9 ประเภท ใน 6 กรณีศึกษา เช่น พยากรณ์ระดับคอเลสเตอรอล การคาดการณ์การมีภาวะเบาหวาน หรือ การประเมินเซลล์มะเร็ง เป็นต้น โดยได้สรุปว่า การเรียนรู้แต่ละประเภทจะมีประสิทธิภาพที่แตกต่างกันในแต่ละลักษณะของงาน

ดังนั้นงานวิจัยนี้มีจุดมุ่งหมายเพื่อเปรียบเทียบประสิทธิภาพของกระบวนการเรียนรู้ทั้ง 12 ประเภท ของแบบจำลองโครงข่ายประสาทเทียมในการพยากรณ์ระดับน้ำที่สถานี P. 1 ณ 6 และ 12 ชั่วโมงล่วงหน้า

วิธีการวิจัย

พื้นที่ศึกษาในงานวิจัยนี้คือ พื้นที่ลุ่มน้ำปิงตอนบน (Figure 1) โดยพยากรณ์ระดับน้ำล่วงหน้าที่สถานีวัดระดับน้ำ P.1 ซึ่งข้อมูลที่ใช้ในการพยากรณ์ระดับน้ำท่วม คือ ข้อมูลระดับน้ำรายชั่วโมง จาก 4 สถานี (P.1, P.67, P.75 และ P.20) เนื่องจากเป็นสถานีที่ตั้งอยู่ในแม่น้ำปิงสายหลัก ระยะห่างระหว่างสถานี P.20 และ P.75 ไปยังสถานี P.1 ประมาณ 100 และ 48 กิโลเมตร ตามลำดับ



Figure 1 Water level stations in the study area¹³

ในการคัดเลือกช่วงเวลาของข้อมูลสำหรับการศึกษาครั้งนี้ จะทำการเลือกตั้งแต่ปี ค.ศ. 2005-2011 โดยจะคัดเลือกเฉพาะปีที่เกิดเหตุการณ์น้ำท่วมเท่านั้น ซึ่งเหตุผลที่ไม่นำเอาข้อมูลก่อนปี ค.ศ. 2005 เนื่องจากได้มีการสร้างกำแพงเพิ่มระดับตลิ่งจากเดิม 3.40 เป็น 3.70 เมตร ทั้งสองฝั่งของลำน้ำในปี ค.ศ. 2004 ณ บริเวณเขตตัวเมืองและแนวสะพานนาครี โดยในการเพิ่มระดับตลิ่งทำให้มีผลต่อพฤติกรรมการไหลท่วมของน้ำ ณ สถานีวัดระดับน้ำ P.1 และจากการเปรียบเทียบการ

ใช้ช่วงปีข้อมูลก่อนเพิ่มระดับตลิ่งเป็นข้อมูลเรียนรู้ และการใช้ช่วงปีข้อมูลหลังการเพิ่มตลิ่ง พบว่า การใช้ข้อมูลหลังการเพิ่มตลิ่งช่วยให้แบบจำลองโครงข่ายประสาทเทียมมีความแม่นยำมากขึ้น¹⁷

การคัดเลือกช่วงข้อมูลที่เกิดเหตุการณ์น้ำท่วมจะเริ่มตั้งแต่ปี 2005-2011 โดยมีจำนวนเหตุการณ์น้ำท่วมทั้งสิ้น 9 เหตุการณ์ ตั้งแต่ช่วงเดือนสิงหาคมถึงเดือนตุลาคม โดยจากไฮโดรกราฟ (Figure 2) พบว่า มีเหตุการณ์น้ำท่วมใหญ่ (ระดับน้ำสูงกว่า 4.5 เมตร) จำนวน 4 เหตุการณ์ ดังนั้นสำหรับการทดสอบความสามารถของแบบจำลองโครงข่ายประสาทเทียมที่มีการใช้กระบวนการเรียนรู้ที่แตกต่างกัน โดยการแบ่งชุดข้อมูลสำหรับชุดเรียนรู้และชุดทดสอบจะใช้หลักการ 80:20 ซึ่งเป็นหลักการที่นิยมใช้มากที่สุดเพื่อที่มีสัดส่วนข้อมูลสำหรับการเรียนรู้ที่เพียงพอและสำหรับข้อมูลการทดสอบไม่มากหรือน้อยเกินไป ดังนั้น จะใช้เหตุการณ์น้ำท่วม 2 เหตุการณ์แรกในปี 2005 (1 เหตุการณ์ใหญ่ และ 1 เหตุการณ์เล็ก) เป็นชุดทดสอบ และเนื่องจากไม่มีการกำหนดข้อมูลสำหรับการตรวจสอบ (Validation) แต่เป็นการกำหนดให้แบ่งแบบสุ่มโดยตัวแบบจำลองเองเพื่อลดความเบี่ยงเบนของการพยากรณ์ ดังนั้นจึงต้องทำการประมวลผลซ้ำ 50 รอบแล้วนำค่าผลการพยากรณ์จาก 50 รอบมาหาค่าเฉลี่ยเพื่อเป็นตัวแทนค่าพยากรณ์ของแต่ละแบบจำลอง




Figure 2 Flood events during year 2005-2011

สำหรับการออกแบบของแบบจำลองโครงข่ายประสาทเทียม ข้อมูลนำเข้า (ระดับน้ำรายชั่วโมง) จาก 4 สถานี จะนำมาใช้เป็นตัวแปรตั้งแต่ เวลา $t, t-1, t-2, \dots, t-24$ ทำให้

ข้อมูลนำเข้ามีทั้งหมด $(4 \times 25) 100$ ตัวแปร และก่อนจะนำมาใช้เป็นข้อมูลนำเข้าในแบบจำลองโครงข่ายประสาทเทียม เทคนิคการคัดเลือกตัวแปร 4 วิธี (Cross correlation-C,

Stepwise regression-S, วิธีผสม CS และ Genetic algorithms) อ้างอิงจากงานวิจัยของ Chaipimonplin²² เมื่อได้จำนวนตัวแปรที่ถูกเลือกแล้ว กำหนดจำนวนโหนดในชั้นซ่อนเร้น จะอ้างอิงตามจำนวนตัวแปรนำเข้า โดยจะกำหนดที่ 1, 25%, 50%, 75% และ 100% โดยทำการพยากรณ์ระดับน้ำ ณ เวลา 6 และ 12 ชั่วโมงล่วงหน้า ที่สถานี P.1

สำหรับการประเมินประสิทธิภาพของแบบจำลองจะใช้ค่าสถิติ R² (Coefficient of Determination Pearson's squared)²³ ถ้าค่าใกล้ 1 หมายถึงแบบจำลองมีประสิทธิภาพที่ดี

$$R^2 = \left[\frac{\sum_{i=1}^n (Q_i - \bar{Q})(Q_i - \bar{Q})}{\sqrt{\sum_{i=1}^n (Q_i - \bar{Q})^2 \sum_{i=1}^n (Q_i - \bar{Q})^2}} \right]^2 \quad (1)$$

- โดย คือค่าระดับน้ำจริง ณ เวลา i
- คือค่าระดับน้ำจากแบบจำลอง ณ เวลา i
- คือค่าเฉลี่ยของระดับน้ำจริง
- คือค่าเฉลี่ยระดับน้ำจากแบบจำลอง

ผลการวิจัยและอภิปราย

จากการคัดเลือกตัวแปรนำเข้า ทั้ง 4 วิธี ผลการคัดเลือกแสดงใน Table 1 และ Table 2 สำหรับ 6 และ 12 ชั่วโมงล่วงหน้า ตามลำดับ โดย การพยากรณ์ 6 ชั่วโมงล่วงหน้า วิธี G มีการคัดเลือกตัวแปรมากที่สุดคือ 32 ตัวแปร ส่วนวิธี CS เลือกมาเพียง 9 ตัวแปร ซึ่งไม่มีตัวแปรของสถานี P.67 และ P.20 เนื่องจากทั้งสองสถานีไม่มีความสัมพันธ์กับระดับน้ำ สถานี P.1 t+6 เนื่องจากมีค่าสหสัมพันธ์น้อยกว่า 0.9

Table 1 Input variables selection t+6

P.1	C	CS	G	S	P.67	C	CS	G	S	P.75	C	CS	G	S	P.20	C	CS	G	S	
t	X	X	X	X	t				X	t	X	X	X	X	t			X	X	
t-1	X		X		t-1					t-1	X	X	X		t-1					
t-2	X	X	X	X	t-2					t-2	X				t-2				X	
t-3	X		X		t-3				X	t-3	X				t-3					
t-4	X				t-4			X		t-4	X		X		t-4				X	
t-5	X				t-5			X	X	t-5	X				t-5				X	
t-6	X	X	X		t-6					t-6	X				t-6				X	
t-7	X		X		t-7			X		t-7	X				t-7				X	X
t-8	X		X		t-8					t-8	X				t-8					
t-9	X		X		t-9					t-9	X	X			t-9					
t-10	X	X			t-10				X	t-10	X	X			t-10				X	
t-11	X		X		t-11					t-11					t-11					
t-12	X				t-12					t-12			X		t-12					X
t-13	X	X	X		t-13					t-13					t-13					
t-14					t-14					t-14					t-14				X	X
t-15			X		t-15					t-15				X	t-15				X	
t-16					t-16					t-16			X		t-16				X	
t-17				X	t-17					t-17					t-17					
t-18					t-18					t-18			X		t-18					X

Table 1 Input variables selection t+6 (continue)

P.1	C	CS	G	S	P.67	C	CS	G	S	P.75	C	CS	G	S	P.20	C	CS	G	S
t-19					t-19					t-19				X	t-19			X	
t-20					t-20					t-20					t-20				
t-21					t-21					t-21				X	t-21				
t-22					t-22					t-22					t-22			X	X
t-23					t-23				X	t-23					t-23				
t-24					t-24					t-24					t-24				X
Total																25	9	32	19

ส่วนตัวแปรที่ถูกเลือกสำหรับพยากรณ์ 12 ชั่วโมงล่วงหน้ารูปแบบการคัดเลือกมีความคล้ายกับการพยากรณ์ 6 ชั่วโมงล่วงหน้า เช่น วิธี G เลือกตัวแปรมากที่สุด 33 ตัวแปร และวิธี CS เลือกเพียง 7 ตัวแปรโดยไม่เลือกตัวแปรของสถานี P.67 และ P.20 แต่อย่างไรก็ตาม สิ่งที่เห็นได้ชัดเจนคือ เมื่อระยะเวลาการพยากรณ์มากขึ้น จำนวนตัวแปรที่มีนัยสำคัญ

กับค่าพยากรณ์ ที่ถูกเลือกจะเริ่มมีจำนวนลดลง เนื่องจากเมื่อคำนวณหาค่าสหสัมพันธ์จากวิธี Cross Correlation พบว่าตัวแปรที่มีค่าสหสัมพันธ์มากกว่า 0.9 มีจำนวนลดลงเมื่อเทียบกับตัวแปรที่มีค่าสหสัมพันธ์มากกว่า 0.9 สำหรับการพยากรณ์ 6 ชั่วโมงล่วงหน้า ยกเว้นวิธี S ที่มีตัวแปรเพิ่มจาก 19 เป็น 24 ตัวแปร

Table 2 Input variables selection t+12

P.1	C	CS	G	S	P.67	C	CS	G	S	P.75	C	CS	G	S	P.20	C	CS	G	S
t	X	X	X	X	t			X	X	t	X	X	X	X	t			X	X
t-1	X		X		t-1			X		t-1	X	X	X		t-1			X	
t-2	X	X	X	X	t-2			X	X	t-2	X		X		t-2			X	X
t-3	X				t-3					t-3	X				t-3				
t-4	X				t-4				X	t-4	X	X		X	t-4				
t-5	X	X			t-5			X		t-5			X		t-5			X	
t-6	X		X		t-6				X	t-6			X		t-6			X	
t-7	X	X	X		t-7					t-7				X	t-7			X	
t-8					t-8					t-8					t-8			X	X
t-9			X		t-9					t-9					t-9				
t-10					t-10				X	t-10			X		t-10			X	
t-11					t-11					t-11				X	t-11			X	X
t-12			X		t-12				X	t-12			X		t-12				
t-13					t-13					t-13					t-13				X
t-14					t-14					t-14					t-14				
t-15					t-15					t-15				X	t-15				
t-16					t-16					t-16			X		t-16			X	
t-17					t-17					t-17					t-17				
t-18			X	X	t-18				X	t-18					t-18				
t-19					t-19					t-19					t-19			X	X
t-20					t-20					t-20					t-20				
t-21			X		t-21					t-21					t-21				

Table 2 Input variables selection t+12 (continue)

P.1	C	CS	G	S	P.67	C	CS	G	S	P.75	C	CS	G	S	P.20	C	CS	G	S
t-22					t-22					t-22				X	t-22				
t-23					t-23					t-23					t-23				
t-24				X	t-24					t-24					t-24			X	X
Total																13	7	33	24

เมื่อได้ตัวแปรที่ถูกคัดเลือกแล้วจำนวนโหนดในชั้น
ซ่อนเร้นจะถูกกำหนดตามจำนวนตัวแปรนำเข้า (Table 3)

Table 3 Number of hidden nodes

t+6	No. of input variable	No. of hidden node				
		1	25%	50%	75%	100%
C	25	1	7	13	19	25
CS	9	1	3	5	7	9
G	32	1	8	16	24	32
S	19	1	5	10	15	19
t+12	No. of input variable	No. of hidden node				
		1	25%	50%	75%	100%
C	13	1	3	6	9	13
CS	7	1	2	3	5	7
G	33	1	8	16	24	33
S	24	1	6	12	18	24

จาก Figure 3 แสดงค่าสถิติ R² จากการพยากรณ์น้ำท่วม 6 ชั่วโมงล่วงหน้า กระบวนการเรียนรู้แต่ละเกทส่วนมากจะมีประสิทธิภาพค่อนข้างคงที่แม้จะมีการใช้จำนวนโหนดในชั้นซ่อนเร้นที่แตกต่างกันหรือตัวแปรที่แตกต่างกัน โดยมีค่า

R² ประมาณ 0.99 ยกเว้นการเรียนรู้ GD, GDM และ GD_X ที่มีประสิทธิภาพเปลี่ยนแปลงตามจำนวนโหนดในชั้นซ่อนเร้นและมีช่วงค่า R² ส่วนมากต่ำกว่า 0.99

Table 4 R² values of models with 1 hidden node at t+6 and t+12 hour

t+6	BFG	BR	CGB	CGF	CGP	LM	OSS	RP	SCG	GD	GDM	GD _X
Model C	0.99	0.99	0.99	0.99	0.99	0.99	0.99	0.99	0.99	0.95	0.94	0.97
Model CS	0.99	0.99	0.99	0.99	0.99	0.99	0.99	0.99	0.99	0.93	0.94	0.97
Model G	0.99	0.99	0.99	0.99	0.99	0.99	0.98	0.98	0.99	0.95	0.94	0.95
Model S	0.99	0.99	0.99	0.99	0.99	0.99	0.99	0.98	0.99	0.96	0.95	0.97
t+12	BFG	BR	CGB	CGF	CGP	LM	OSS	RP	SCG	GD	GDM	GD _X
Model C	0.97	0.97	0.97	0.97	0.97	0.97	0.97	0.97	0.97	0.88	0.88	0.91
Model CS	0.97	0.97	0.97	0.97	0.97	0.97	0.97	0.97	0.97	0.89	0.90	0.93
Model G	0.97	0.97	0.97	0.97	0.96	0.97	0.96	0.96	0.97	0.93	0.93	0.95
Model S	0.97	0.97	0.97	0.97	0.97	0.97	0.97	0.96	0.97	0.93	0.93	0.95




Figure 3 R² Values of testing all 12 learning algorithms between August and September 2005 at t+6

สำหรับ Figure 4 แสดงให้เห็นผลของการพยากรณ์ 12 ชั่วโมงล่วงหน้า รูปแบบของค่าสถิติ R² มีความคล้ายกับการพยากรณ์ 6 ชั่วโมงล่วงหน้า โดยกระบวนการเรียนรู้ GD, GDM และ GD มีประสิทธิภาพที่ค่อนข้างแย่ที่สุด เพราะเมื่อ

พิจารณาเส้นกราฟ เส้นที่บิกบาทสี่เหลี่ยม (GD) เส้นประวงกลมสี่เหลี่ยม (GDM) และ เส้นประดอกจันสี่เหลี่ยม (GD) แสดงค่าสถิติ R² ได้น้อยที่สุด ส่วนจำนวนโหนดในชั้นซ่อนเร้นที่เหมาะสมที่สุดคือ ร้อยละ 50 โดยมีค่าสถิติ R² สูงสุด 0.98

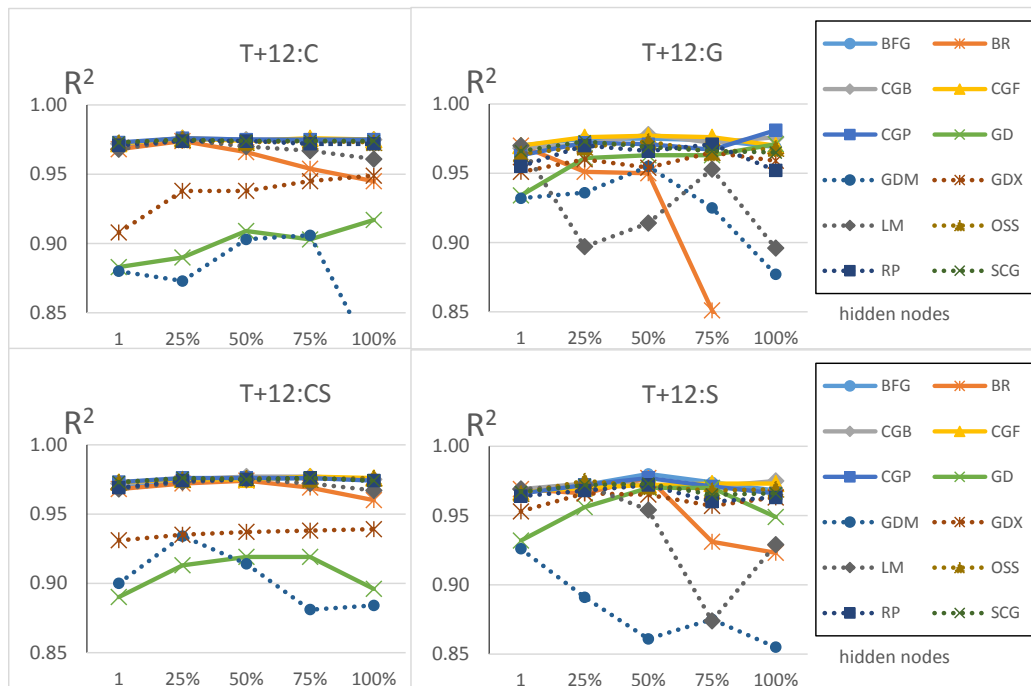


Figure 4 R² Values of testing all 12 learning algorithms between August and September 2005 at t+12

จากค่าสถิติ R^2 จะเห็นได้ชัดว่าเมื่อใช้ตัวแปรนำเข้าที่ได้จากการคัดเลือกโดยวิธี C ทุกประเภทการเรียนรู้จะมีประสิทธิภาพที่ค่อนข้างคงที่มากกว่าทุกวิธี แม้ว่าจะมีการใช้จำนวนโหนดในชั้นซ่อนเร้นที่แตกต่างกัน เมื่อนำผลพยากรณ์จากแบบจำลองที่มีจำนวนโหนดในชั้นซ่อนเร้น ร้อยละ 50 มาแสดงในไฮโดรกราฟ (Figure 5) พบว่า กระบวนการเรียนรู้แต่ละประเภทพยากรณ์ได้ค่อนข้างแม่นยำซึ่งสอดคล้องกับค่า R^2 แต่เนื่องจากการเป็นกราฟรายชั่วโมงไฮโดรกราฟที่แสดงใน Figure 5 ไม่สามารถที่จะสรุปได้ชัดเจนว่ากระบวนการเรียนรู้ประเภทใดให้ผลเหมือนกันหรือแตกต่างกัน ดังนั้นไฮโดรกราฟที่แสดงใน Figure 6 เป็นการตัดช่วงข้อมูลเฉพาะช่วงที่เกิดเหตุการณ์น้ำท่วม 2 เหตุการณ์ โดยกระบวนการเรียนรู้ที่

พยากรณ์ใกล้เคียงกับระดับน้ำจริงในช่วงที่ระดับน้ำล้นตลิ่งได้ดีและเหมือนกันคือ BFG, CGB, CGF, CGP, RP, OSS และ SCG ส่วน BR, GD, GDM, GDX และ LM พยากรณ์ช้ากว่าเหตุการณ์จริง แต่อย่างไรก็ตาม เมื่อพิจารณาถึงการพยากรณ์ระดับน้ำท่วมสูงสุดพบว่า การพยากรณ์ 6 ชั่วโมงล่วงหน้ากระบวนการเรียนรู้ที่พยากรณ์ได้ดีในช่วงระดับน้ำล้นตลิ่งจะพยากรณ์ค่าระดับน้ำสูงสุดได้สูงเกินกว่าระดับจริงประมาณ 30-45 เซนติเมตร (เหตุการณ์น้ำท่วมใหญ่) และนอกจากนั้นกลุ่มกระบวนการเรียนรู้ที่พยากรณ์ช้ากว่าเหตุการณ์จริงในช่วงน้ำล้นตลิ่งพบว่า พยากรณ์ค่าระดับน้ำสูงสุดได้ค่อนข้างดี เช่น BR, GD, GDX และ LM พยากรณ์คลาดเคลื่อนเพียง 13, 15, 8, และ 5 เซนติเมตร ตามลำดับ




Figure 5 Hydrographs of Cross Correlation with hidden node 50% of 12 learning algorithms at the first and second flood event 2005, t+6




Figure 6 Rescaled hydrographs of Cross Correlation with hidden node 50% of 12 learning algorithms at the first and second flood event 2005, t+6

สำหรับการพยากรณ์ 12 ชั่วโมงล่วงหน้า (Figure 7) ไฮโดรกราฟให้ผลการพยากรณ์สอดคล้องกับค่า R^2 ซึ่งแสดงว่ากระบวนการเรียนรู้ส่วนมากให้ผลการพยากรณ์ที่คล้ายกันและมีค่าคลาดเคลื่อนในการพยากรณ์ในช่วงค่าระดับน้ำสูงสุดมากกว่าค่าระดับน้ำจริง เพื่อให้สามารถแยกแยะประสิทธิภาพของกระบวนการเรียนรู้แต่ละประเภทในการพยากรณ์ระดับน้ำรายชั่วโมง ไฮโดรกราฟใน Figure 8 จึงถูกตัดและแสดงผลการพยากรณ์ในเฉพาะช่วงการเกิดน้ำท่วม โดยกลุ่มกระบวนการเรียนรู้ที่สามารถพยากรณ์ระดับน้ำล่วงหน้าในช่วงน้ำล้นตลิ่ง

ได้ดีและพยากรณ์ได้ช้ากว่าเหตุการณ์จริง เหมือนกับผลการพยากรณ์ 6 ชั่วโมงล่วงหน้า และเนื่องจากการพยากรณ์ 12 ชั่วโมงล่วงหน้า ค่าความคลาดเคลื่อนจากการพยากรณ์โดยเฉพาะ ณ ระดับน้ำสูงสุดจึงเกิดค่าความคลาดเคลื่อนมากกว่าการพยากรณ์ 6 ชั่วโมงล่วงหน้า โดยพยากรณ์สูงกว่าระดับน้ำสูงสุดประมาณ 70-80 เซนติเมตร โดยกระบวนการเรียนรู้ BR เป็นกระบวนการเรียนรู้ที่พยากรณ์ค่าระดับน้ำสูงสุดได้ใกล้เคียงที่สุดคือพยากรณ์สูงกว่าระดับจริง 26 เซนติเมตร




Figure 7 Hydrographs of Cross Correlation with hidden node 50% of 12 learning algorithms at the first and second flood event 2005, t+12




Figure 8 Rescaled hydrographs of Cross Correlation with hidden node 50% of 12 learning algorithms at the first and second flood event 2005, t+12

สรุปและข้อเสนอแนะ

จากการทดสอบ 2 เหตุการณ์น้ำท่วม ในปี ค.ศ. 2005 พบว่า กระบวนการเรียนรู้ส่วนมากในภาพรวมให้ผลการพยากรณ์ไม่แตกต่างกันมากนัก ดังค่าสถิติ R² มีค่า 0.99 สำหรับพยากรณ์ 6 ชั่วโมงล่วงหน้า และ 0.97 สำหรับพยากรณ์ 12 ชั่วโมงล่วงหน้า (Table 4) แต่อย่างไรก็ตามเมื่อพิจารณาไฮโดรกราฟแล้วพบว่า แบบจำลองที่สามารถพยากรณ์ช่วงระดับน้ำล้นตลิ่งได้

ดี มี BFG, CGB, CGF, CGP, RP, OSS และ SCG ซึ่งให้ผลการพยากรณ์ใกล้เคียงกันมาก

เมื่อพิจารณาถึงระยะเวลาในการประมวลผล กระบวนการเรียนรู้เกือบทุกกระบวนการเรียนรู้ค่อนข้างเร็ว ยกเว้น BR ที่ใช้เวลามากที่สุด โดยตัวอย่างระยะเวลาการประมวลผลของแบบจำลอง 50 รอบ (สำหรับเครื่องคอมพิวเตอร์ Intel R Core (TM) i7-6700 CPU@ 3.4 GHz และ 8GB Ram)

เมื่อใช้จำนวนโหนดในชั้นซ่อนเร้นมากที่สุดคือ 33 โหนด คือ 1 นาที่ (SCG, GDM และ GDX) 2 นาที่ (CGB, CGP และ OSS) 3 นาที่ (CGF และ RP) 4 นาที่ (GD) 8 นาที่ (LM) 30 นาที่ (BFG) และ 240 นาที่ หรือ 4 ชั่วโมง (BR)

นอกจากนั้นแล้วการเลือกใช้ตัวแปรข้อมูลนำเข้าที่แตกต่างกันก็มีผลต่อประสิทธิภาพในการพยากรณ์ในแต่ละประเภทกระบวนการเรียนรู้ แต่อย่างไรก็ตามสำหรับการออกแบบโครงข่ายประสาทเทียมต่อไปสำหรับการพยากรณ์น้ำท่วม ณ 6 และ 12 ชั่วโมงล่วงหน้า ในลุ่มน้ำปิงตอนบน สถานี P.1 ควรจะใช้กระบวนการเรียนรู้ประเภทใดประเภทหนึ่งได้ เพราะมีประสิทธิภาพที่ใกล้เคียงกัน (BFG, CGB, CGF, CGP, RP, OSS และ SCG) แต่ถ้าต้องการเลือกใช้กระบวนการเรียนรู้ที่ใช้เวลาการประมวลผลที่รวดเร็ว ควรเลือกใช้กระบวนการเรียนรู้ SCG, CGB, CGP หรือ OSS เนื่องจากใช้เวลาประมวลผลค่อนข้างเร็ว หรือถ้าต้องการให้ได้ความแม่นยำในการพยากรณ์ค่าระดับน้ำสูงสุดกระบวนการเรียนรู้ที่ควรเลือกใช้คือ LM เนื่องจาก LM พยากรณ์คลาดเคลื่อนเพียง 5 เซนติเมตร และใช้ระยะเวลาประมวลผลเพียง 8 นาที่ แต่อย่างไรก็ตาม จำนวนโหนดในชั้นซ่อนเร้นที่เหมาะสมสำหรับงานวิจัยนี้คือ 13 และ 6 โหนด สำหรับการพยากรณ์ 6 และ 12 ชั่วโมง ตามลำดับ (จำนวน 50% จากจำนวนตัวแปรข้อมูลนำเข้าที่คัดเลือกจากวิธี C หรือ วิธี ผสม ระหว่าง Cross Correlation + Stepwise Regression) ซึ่งทำให้ระยะเวลาการประมวลผล 50 รอบ จะใช้ระยะเวลาเพียง 1-2 นาที่ ซึ่งเหมาะสำหรับเครื่องคอมพิวเตอร์ที่มีใช้กันทั่วไป

กิตติกรรมประกาศ

ผู้วิจัยขอขอบคุณสำนักงานคณะกรรมการวิจัยแห่งชาติ สำหรับการสนับสนุนงบประมาณในการทำวิจัยครั้งนี้ ขอขอบคุณศูนย์อุทกวิทยาชลประทานภาคเหนือตอนบน สำหรับข้อมูลระดับน้ำ และ กองทุนพัฒนาวิชาการ คณะสังคมศาสตร์ มหาวิทยาลัยเชียงใหม่ ประจำปี 2560

เอกสารอ้างอิง

1. ศูนย์อุทกวิทยาและบริหารน้ำ ภาคเหนือตอนบน (2550) ไปประชาสัมพันธุ์ การเตือนภัยน้ำท่วมในเขตภาคเหนือตอนบน, กรมชลประทาน.
2. ทวี ชัยพิมลผลิน. 50 ปี กกับการประยุกต์ใช้แบบจำลองโครงข่ายประสาทเทียมสำหรับการพยากรณ์น้ำท่วมในประเทศไทย. วารสารสังคมศาสตร์. 2557;26(2):171-91.
3. Siang JJ. Application of back propagation method in forecasting problem. Master thesis, Asian Institute of

Technology.1992.

4. วีรวิฑูร เลพล, สิงห์ทอง พัฒนเศรษฐานนท์, อภินันท์ อรุโสมภณ. การพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียมสำหรับบริเวณภูมิอากาศเขตร้อนชื้น. วารสารวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยมหาสารคาม.2554; 30(2): 135-44.
5. Limanond T, Jomnonkwo S, Srikaew A. Projection of future transport energy demand of Thailand. Nrg Poli. 2011;39: 2754-63.
6. Niamnuay C, Kerdpi boon S, Devahastin S. Artificial neural network modeling of physicochemical changes of shrimp during boiling. LWT-FST. 2012; 45:110-16.
7. เพชรนรินทร์ แก้วหล้า. ระบบการพยากรณ์จำนวนผู้ป่วยโรคหัวใจโดยใช้โครงข่ายประสาทเทียม. วิทยานิพนธ์วิทยาศาสตร์มหาบัณฑิต มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ. 2553
8. อติศร แก้วสินธุ์. การพยากรณ์ความต้องการไฟฟ้าระยะสั้นโดยใช้โครงข่ายประสาทเทียม. วิทยานิพนธ์ครุศาสตรอุตสาหกรรมมหาบัณฑิต มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี. 2552
9. วรากุล กาญจนกัญญไธ, สิริภัทร เขียวชาญพัฒนา, คำรณ สุนธิ. การคัดเลือกปัจจัยที่อธิบายตัวแบบโครงข่ายประสาทเทียมในการพยากรณ์การเกิดอาชญากรรม. วารสารวิจัย มข. (ฉบับบัณฑิตศึกษา). 2553;10(1):22-30.
10. วิภา อินเรือง, ทวี ชัยพิมลผลิน. การคาดการณ์พื้นที่เสี่ยงต่อการเกิดดินถล่มในจังหวัดอุตรดิตถ์ โดยประยุกต์ใช้เทคโนโลยีภูมิสารสนเทศร่วมกับโครงข่ายประสาทเทียม. วารสารสังคมศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ. 2558;18: 191-207.
11. อรณรงค์ บุเกตุ, พุทธดี ศิริแสงตระกูล. แบบจำลองการพยากรณ์ปริมาณอ้อยของภาคตะวันออกเฉียงเหนือโดยใช้โครงข่ายประสาทเทียม. วารสารวิทยาศาสตร์ มหาวิทยาลัยขอนแก่น. 2556;41(1):213-25.
12. วิจิตร คลังภูเขียว, ปิยภัทร บุชบาบดินทร์ และ บังอร กุมพล. การพยากรณ์ความผันผวนราคาทองคำด้วยโครงข่ายประสาทเทียม. วารสารวิทยาศาสตร์บูรพา. 2560;22(1): 125-34.
13. Elsafi SH. Artificial neural network (ANNs) for flood forecasting at Dongola station in the River Nile, Sudan. Alexandria E J. 2014;53(3): 655-62.
14. ทวี ชัยพิมลผลิน. การใช้ภาพเรดาร์และข้อมูลอุทกวิทยาร่วมกับแบบจำลองโครงข่ายประสาทเทียมสำหรับการ

- พยากรณ์น้ำท่วมในลุ่มน้ำปิงตอนบน. วารสาร
วิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยมหาสารคาม.
2557;33(3): 267-74.
15. Hong JL, Hong K. Flood forecasting for Klang River
at Kuala Lumpur using artificial neural networks. Intl
J of Hy IT. 2016;9(3): 39-60.
 16. สุภาวดี ช้องกำ, ทวี ชัยพิมลผลิน. การพัฒนาแบบจำลอง
โครงข่ายประสาทเทียมสำหรับการคาดการณ์น้ำท่วม ณ
สถานี Y.16 บางระกำ. วารสารวิทยาศาสตร์และ
เทคโนโลยี มหาวิทยาลัยมหาสารคาม. 2561;37(1) (กำลัง
ตีพิมพ์).
 17. 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 Tech-
nologies for Urban Safety Mega Cities in Asia, 2011
Oct; Chiang Mai, Thailand. (Poster).
 18. Chaipimonplin T, Vangpaisal T. Comparison of the
efficiency of input determination techniques with LM
and BR algorithms in ANN for flood forecasting, Mun
Basin, Thailand. Intl J of CEE. 2014;6(2): 90-4.
 19. Chaipimonplin T. Investigation internal parameter of
neural network model for flood forecasting at Upper
River Ping, Chiang Mai. KSCE JCE. 2016;20(1);
478-84.
 20. ยุพิน ไชยสมภาร, ทวี ชัยพิมลผลิน. การพยากรณ์ระดับ
น้ำโดยแบบจำลองโครงข่ายประสาทเทียมด้วยข้อมูล
ปริมาณน้ำฝนจากแบบจำลอง WRF-ECHAM5. วารสาร
มหาวิทยาลัยศรีนครนทรวิโรฒ (สาขาวิทยาศาสตร์และ
เทคโนโลยี). 2560;9(17): 9 หน้า (กำลังตีพิมพ์).
 21. Beale MH, Hagan MT, Demuth HB. (2017). Neural
network toolbox™ user's guide. Retrieved May 5,
2017, from [https://www.mathworks.com/help/pdf_doc/
nnet/nnet_ug.pdf](https://www.mathworks.com/help/pdf_doc/nnet/nnet_ug.pdf).
 22. Chaipimonplin, T. An exploration of neural network
modelling options for the Upper River Ping. PhD
thesis, University of Leeds, UK. 2010.
 23. Hydrotest. (2016). Details (modelling and statistics).
Retrieved 30 March 2016, from [http://co-public.lboro.
ac.uk/cocwd/HydroTest/Details.html](http://co-public.lboro.
ac.uk/cocwd/HydroTest/Details.html)