

## การใช้ภาพเรดาร์และข้อมูลอุทกวิทยาร่วมกับแบบจำลองโครงข่ายประสาทเทียมสำหรับการพยากรณ์น้ำท่วมในลุ่มน้ำปิงตอนบน

### The Use of Radar Imagery and Hydrology Information with Artificial Neural Network Model for Flood Forecasting in the Upper Ping Catchment

ทวี ชัยพิมลผลิน<sup>1</sup>

Tawe Chaipimonplin<sup>1</sup>

Received: 14 May 2013; Accepted: 4 August 2013

#### บทคัดย่อ

การเตือนภัยน้ำท่วมในตัวเมืองเชียงใหม่ในปัจจุบันจะอ้างอิงจากความสัมพันธ์ของระดับน้ำระหว่างสถานี P.67 และ P.1 ซึ่งมีเวลาการเตือนภัยน้ำท่วมประมาณ 6-7 ชั่วโมง ส่วนแบบจำลองโครงข่ายประสาทเทียมเป็นแบบจำลองที่ถูกนำมาใช้ในงานด้านพยากรณ์น้ำอย่างแพร่หลาย แต่แบบจำลองจะมีประสิทธิภาพแตกต่างกันขึ้นอยู่กับพื้นที่ที่ศึกษา หรือการคัดเลือกตัวแปรข้อมูลนำเข้า หรือการกำหนดตัวแปรภายในของแบบจำลอง งานวิจัยนี้ได้ทำการศึกษาวิเคราะห์ และปัจจัยต่างๆ เพื่อเพิ่มประสิทธิภาพของแบบจำลองสำหรับการพยากรณ์ระดับน้ำที่สถานี P.67 โดยมีปัจจัยต่างๆ คือ ข้อมูลระดับน้ำ อัตราการไหลของน้ำที่ถูกปล่อยออกจากเขื่อน และข้อมูลภาพเรดาร์ ผลของการวิจัยสามารถสรุปได้ว่า การนำอัตราการไหลของน้ำที่ถูกปล่อยออกจากเขื่อนมาปรับแก้ค่าระดับน้ำสถานี P.75 เป็นตัวแปรร่วมกับข้อมูลภาพเรดาร์ จะเพิ่มศักยภาพของแบบจำลอง โดยแบบจำลองสามารถพยากรณ์ระดับน้ำที่สถานี P.67 ได้ล่วงหน้า 18 ชั่วโมง ซึ่งเมื่อใช้แบบจำลองบูรณาการร่วมกับวิธีการเตือนภัยน้ำท่วมในปัจจุบัน จะการเพิ่มระยะเวลาการเตือนภัยน้ำท่วมที่สถานี P.1 โดยใช้แบบจำลองพยากรณ์ระดับน้ำที่ P.67 ล่วงหน้า 18 ชั่วโมง แล้วอ้างอิงความสัมพันธ์ระดับน้ำระหว่างสถานี P.67 และ P.1 ซึ่งมีระยะเวลาการเตือนภัย 6-7 ชั่วโมง ทำให้เพิ่มระยะเวลาการเตือนภัยล่วงหน้าในตัวเมืองเชียงใหม่ได้ประมาณ 24 ชั่วโมง เพราะฉะนั้น ในการเตือนภัยน้ำท่วมโดยใช้ข้อมูลเรดาร์ ข้อมูลระดับน้ำ และอัตราการปล่อยน้ำออกจากเขื่อนโดยใช้แบบจำลองโครงข่ายประสาทเทียม สามารถเป็นทางเลือกใหม่สำหรับการเตือนภัยน้ำท่วมทั้ง สถานี P.67 และสถานี P.1

**คำสำคัญ:** โครงข่ายประสาทเทียม พยากรณ์น้ำท่วม ภาพเรดาร์ ลุ่มน้ำปิงตอนบน

#### Abstract

The current flood warning system at Chiang Mai city is based on the correlation between water level at P.67 and P.1. The station, has a warning time of around 6-7 hour. A Artificial Neural Network (ANN) model has been widely used for hydrology forecasting. However, the performance of the model depends on various factors e.g. the study area or input variable selection or setting the internal parameters in the model. This research investigates several parameters, i.e. water level, outflow discharge rate from a dam and radar images. These might increase the model's performance for water level forecasting at the P.67 station. The result exhibit that adjusting the water level at P.75 with various input of outflow discharge rates with radar images improve the model's performance. The model can predict water level at the P.67 18 hour in advances. Moreover, integration between the models with the current flood warning system might be a new method of increasing flood warning time at the P.1 station. This method will increase the warning time in the Chiang Mai city to 24 hr. Hence, for flood warning using the radar image, water level and outflow discharge rate from the dam with the ANN model is an alternative method for the flood warning system at both P.67 and P.1 stations.

**Keywords:** artificial neural network, flood forecasting, radar image, upper ping catchment

<sup>1</sup> อาจารย์, ภาควิชาภูมิศาสตร์ คณะสังคมศาสตร์ มหาวิทยาลัยเชียงใหม่ 50200

<sup>1</sup>Lecturer, Department of Geography, Faculty of Social Sciences, Chiang Mai University, 50200, Thailand

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

## บทนำ

การเตือนภัยน้ำท่วม สิ่งที่สำคัญที่สุดคือ ความแม่นยำและความรวดเร็วในการเตือนภัย ซึ่งหน่วยงานที่เกี่ยวข้องสามารถคาดการณ์ล่วงหน้าได้อย่างถูกต้อง และเตือนภัยล่วงหน้าก่อนการเกิดน้ำท่วมได้ หลายชั่วโมงก็จะสามารถที่จะช่วยลดการสูญเสียชีวิตและทรัพย์สินได้ แบบจำลองโครงข่ายประสาทเทียมจัดอยู่ในกลุ่มของ Black box model ซึ่งโครงข่ายประสาทเทียมเป็นแบบจำลองที่มีลักษณะโครงสร้าง และหลักการงานคล้ายสมองคน ซึ่งประกอบด้วยเซลล์ต่างๆ และโครงสร้างมาตรฐานจะประกอบไปด้วย 3 ชั้น คือ ชั้นข้อมูลนำเข้า (Input layer) ชั้นซ่อนเร้น (Hidden layer) และชั้นข้อมูลออก (Output layer) โดยสามารถที่จะเรียนรู้ จัดจํารูปแบบต่างๆ เรียนรู้สิ่งใหม่ๆ ได้ตลอดเวลา โดยเมื่อมีข้อมูลใหม่เพิ่มมากขึ้น แบบจำลองประเภทนี้ก็สามารถที่จะเรียนรู้ได้ภายในระยะเวลาอันสั้น<sup>1</sup> ซึ่งเป็นปัจจัยสำคัญในการเตือนภัยน้ำท่วมล่วงหน้า อีกทั้งยังเหมาะสำหรับพื้นที่ ที่มีงบประมาณน้อยในการลงสำรวจเก็บข้อมูลในภาคสนามและโครงข่ายประสาทเทียมมีลักษณะเด่น คือสามารถที่จะพยากรณ์เหตุการณ์ที่แบบจำลองไม่เคยได้เรียนรู้มาก่อน<sup>2</sup> ซึ่งถือว่าเป็นจุดเด่นที่สำคัญต่อสภาวะเหตุการณ์ในปัจจุบัน ที่ความรุนแรงของอุทกภัย มีแนวโน้มเพิ่มมากขึ้นเมื่อเปรียบเทียบกับในอดีตที่ผ่านมา โดยแบบจำลองโครงข่ายประสาทเทียมเป็นที่นิยมอย่างแพร่หลายในการนำมาประยุกต์ใช้ในการพยากรณ์น้ำท่วม<sup>3,4</sup> ประเภทการเรียนรู้ของแบบจำลองโครงข่ายประสาทเทียมส่วนมากจะมีการแบ่งสัดส่วนจำนวนข้อมูล สำหรับการเรียนรู้ (Training หรือ Learning) สำหรับการตรวจสอบการเรียนรู้ (Validation) และสำหรับการทดสอบ (Testing) ถ้าข้อมูลสำหรับการเรียนรู้เป็นตัวแทนของข้อมูลทั้งหมดที่ไม่มีคุณภาพก็จะส่งผลให้โครงข่ายประสาทเทียมพยากรณ์ผิดพลาด แต่อย่างไรก็ตามถ้าโครงข่ายประสาทเทียมเรียนรู้ดีเกินไป เรียกว่า "Overfitting" จะมีผลทำให้ประสิทธิภาพของแบบจำลองลดลงในเวลาทดสอบ เพราะฉะนั้นจึงจำเป็นต้องมีกลุ่มข้อมูลสำหรับตรวจสอบการเรียนรู้ เพื่อเป็นการป้องกันไม่ให้โครงข่ายประสาทเทียม เกิดการเรียนรู้ดีเกินไป แต่ในกรณีที่จำนวนข้อมูลมีอยู่อย่างจำกัด จึงทำให้ข้อมูลสำหรับการเรียนรู้ต้องถูกแบ่งเป็นข้อมูลสำหรับการตรวจสอบการเรียนรู้ ซึ่งอาจจะทำให้ข้อมูลมีจำนวนไม่เพียงพอสำหรับการเรียนรู้ของแบบจำลองโครงข่ายประสาทเทียม แต่กระบวนการเรียนรู้ประเภท Bayesian Regularization (BR) ของโครงข่ายประสาทเทียมไม่จำเป็นต้องแบ่งสัดส่วนข้อมูลสำหรับการตรวจสอบการเรียนรู้ (Validation) ซึ่งเหมาะสมในกรณีที่มีจำนวนข้อมูลจำกัด โดยตัวอย่างการใช้ BR สำหรับการประยุกต์ใช้ในงานด้าน

อุทกวิทยา คือ Ancil and Lauzon,<sup>5</sup> Ancil et al.,<sup>6,7,8</sup> Chaipimonplin et al.<sup>9,10</sup> และ Zhang and Govindaraju<sup>11</sup> เป็นต้น การพยากรณ์เตือนภัยน้ำท่วมในประเทศไทยส่วนมากจะเป็นการใช้ระดับน้ำจากสถานีต้นน้ำเป็นเกณฑ์ โดยระยะเวลาการเตือนภัยล่วงหน้าขึ้นอยู่กับระยะทางการเดินทางของมวลน้ำ จากสถานีต้นน้ำไปยังสถานีปลายน้ำ เช่น ในลุ่มน้ำปิงตอนบน อำเภอเมืองเชียงใหม่ ศูนย์อุทกวิทยาและบริหารน้ำ ภาคเหนือตอนบน จะพยากรณ์เตือนภัยน้ำท่วมโดยอาศัยความสัมพันธ์ของระดับน้ำ โดยมวลน้ำใช้ระยะเวลาเดินทางจากสถานีต้นน้ำ P.67 ไปยัง P.1 ใช้เวลาประมาณ 6-7 ชั่วโมง<sup>12</sup> ดังนั้นในการพยากรณ์เตือนภัยน้ำท่วมโดยใช้การวิเคราะห์จาก สถานีต้นน้ำ จึงถูกจำกัดด้วยระยะทางระหว่างสถานี โดย Chaipimonplin<sup>13</sup> ใช้แบบจำลองโครงข่ายประสาทเทียม สำหรับพยากรณ์ระดับน้ำที่สถานี P.1 โดยใช้ข้อมูลระดับน้ำของสถานีต้นน้ำ P.75 และ P.67 แบบจำลองโครงข่ายประสาทเทียมใช้เวลาในการวิเคราะห์และพยากรณ์เสร็จสิ้นภายใน 10 นาที และผลที่ได้สามารถเตือนภัยน้ำท่วมได้ล่วงหน้าได้ประมาณ 7-12 ชั่วโมง และ Chaipimonplin et al.<sup>14</sup> ได้นำค่าการสะท้อนกลับของอนุภาคน้ำในก้อนเมฆ จากภาพเรดาร์ มาช่วยในการพยากรณ์ และสรุปว่าแบบจำลองโครงข่ายประสาทเทียมสามารถพยากรณ์เตือนภัยน้ำท่วมที่สถานี P.1 ได้ 24 ชั่วโมงล่วงหน้า โดยเฉพาะในการพยากรณ์น้ำท่วมใหญ่ที่สุดในประวัติศาสตร์เมืองเชียงใหม่ พ.ศ. 2545 แต่ในการพยากรณ์น้ำท่วมบางเหตุการณ์ ผลที่ได้ยังมีความคลาดเคลื่อนหรือสามารถพยากรณ์ล่วงหน้าได้น้อยกว่า 24 ชั่วโมงซึ่งอาจจะเกิดจาก ลักษณะรูปแบบทิศทางการเคลื่อนที่ของพายุฝน และการปล่อยน้ำจากเขื่อนที่อยู่เหนือสถานี P.75 อาจจะมีผลต่อข้อมูลระดับน้ำที่สถานี P.67 และ P.1 ดังนั้นงานวิจัยนี้จึงเป็นการพยากรณ์ระดับน้ำที่สถานี P.67 โดยใช้ข้อมูลระดับน้ำท่าที่สถานีต้นน้ำร่วมกับข้อมูลมวลน้ำที่ถูกปล่อยออกจากเขื่อน และข้อมูลเรดาร์ โดยใช้ประเภทการเรียนรู้ BR เนื่องจากจำนวนข้อมูลที่มีอย่างจำกัด

## วิธีการวิจัย

### พื้นที่ศึกษาและข้อมูล

พื้นที่ศึกษาในงานวิจัยนี้คือ พื้นที่ลุ่มน้ำปิงตอนบน (Figure 1) โดยพยากรณ์ระดับน้ำล่วงหน้าที่สถานีวัดน้ำท่า P.67 ซึ่งข้อมูลที่ใช้ในการพยากรณ์ระดับน้ำท่วม คือ ข้อมูลระดับน้ำรายชั่วโมง จาก 1 สถานี (P.75) ข้อมูลอัตราการปล่อยน้ำออกจากเขื่อนแม่งัดสมบูรณ์ชล และข้อมูลภาพเรดาร์

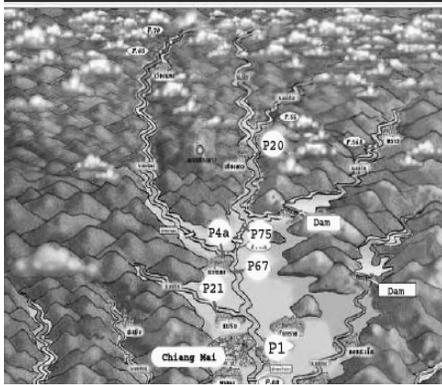


Figure 1 Water level stations in the Stay area<sup>13</sup>

วิธีการใช้ข้อมูลอัตราการปล่อยน้ำออกจากเขื่อน สำหรับการทดสอบแบ่งได้ 2 วิธีคือ (1) แปลงหน่วยจาก ลูกบาศก์เมตรต่อวินาที เป็นลูกบาศก์เมตรต่อชั่วโมง โดยอ้างอิงตามระยะเวลาการปิดเปิดประตูน้ำทางประตูชัยและ ขวา แล้วนำมารวมกันแล้วเพื่อเป็นปริมาณน้ำสะสมรวมใน แต่ละชั่วโมงที่ถูกระบายออกจากเขื่อน และนำค่าที่ได้มา คำนวณแบบ Moving average t-6 ซึ่งเป็นการเอาปริมาณ การไหลของน้ำมาหาค่าเฉลี่ย ณ เวลา t ถึง t-6 และ (2) ใช้ ค่าความสัมพันธ์ระหว่างอัตราการไหลของน้ำและระดับน้ำ (Rating curve) โดยจะปรับแก้ค่าระดับน้ำเฉพาะสถานี P.75 เนื่องจากเป็นสถานีที่อยู่หลังเขื่อนและใกล้ที่สุด ซึ่งน่าจะได้รับ ผลกระทบมากที่สุด โดยวิธีการปรับแก้จะอ้างอิงจาก ปริมาณ การไหลของน้ำที่ออกจากเขื่อนแล้วเปรียบเทียบกับค่าระดับน้ำ จาก Rating curve เมื่อได้ค่าระดับน้ำแล้วก็จะเอาไปลบออก จากค่าระดับน้ำจริงที่วัดได้จากสถานี P.75

ข้อมูลภาพเรดาร์รายชั่วโมง เป็นภาพข้อมูลเรดาร์ จากสถานีเรดาร์ฝนหลวง อำเภอมก๋อย ซึ่งจะมีแถบสีต่างๆ ที่แสดงถึงความเข้มของปริมาณความชื้นในก้อนเมฆ (สีเขียว คือความเข้มน้อย และสีฟ้าคือความเข้มมาก) โดยมีหน่วยเป็น เดซิเบล (dBZ) โดยความเข้มของปริมาณความชื้นหรือปริมาณ หยาดน้ำฟ้าในก้อนเมฆจะมีความสัมพันธ์กับประมาณความ เข้มของฝนที่ตก (Figure 2 บน) ในการใช้ข้อมูลค่าการสะท้อน พลังงานคลื่นแม่เหล็กไฟฟ้าของปริมาณหยาดน้ำฟ้าในก้อน เมฆ จะทำการกำหนดจุดสมมติขึ้น โดยใช้หลักการตรึงแนวทั่ว ทั้งพื้นที่ศึกษาบริเวณรอบลำน้ำปิง ซึ่งแต่ละจุดจะห่างกัน 10 กิโลเมตร (Figure 2 ล่าง) ในการนำค่าการสะท้อนของพลังงาน คลื่นแม่เหล็กไฟฟ้ามาใช้พยากรณ์ระดับน้ำนั้น จะทำการหา ค่าเฉลี่ยของค่าการสะท้อนของพลังงานคลื่นแม่เหล็กไฟฟ้า รอบๆ จุดสมมติ (3x3 pixel) โดยแต่ละจุดจะมีขนาดประมาณ 1 ตารางกิโลเมตร ซึ่งค่าที่ได้เป็นค่าเฉลี่ยทั้งหมด 9 จุดภาพ จุด สมมติที่นำมาใช้คือ จุด Z11, Z12, Z13, Z21, Z22 และ Z23

เนื่องจากมีระยะไม่ไกลจากแม่น้ำปิงเกินไป ส่วนตำแหน่งแถว Z3 อยู่ใกล้ตำแหน่งสถานี P.67 (จุดวงกลมสีดำ) มากเกินไป สำหรับการพยากรณ์ระดับน้ำล่วงหน้า

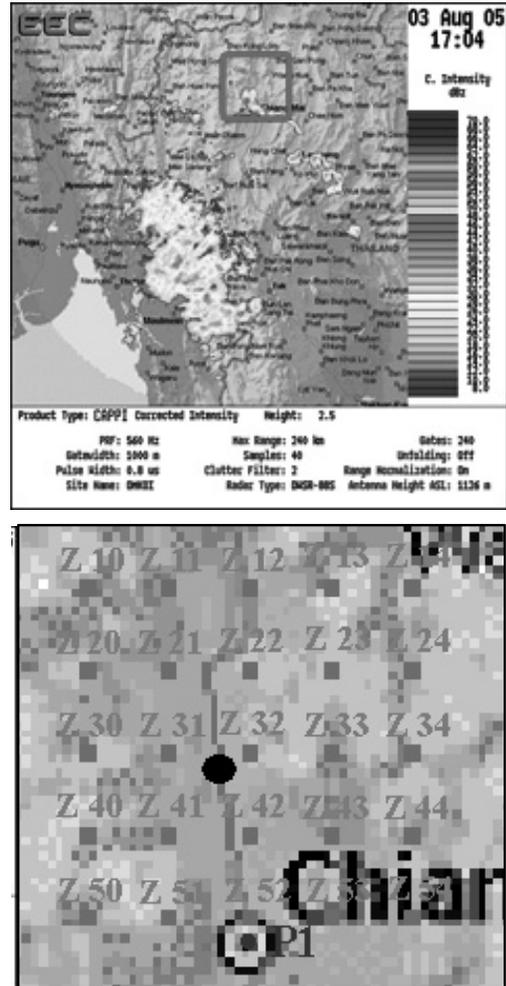


Figure 2 Radar image and sample points

**ช่วงเวลากการคัดเลือกข้อมูล**

ในการคัดเลือกช่วงเวลาของข้อมูลสำหรับการ ศึกษาครั้งนี้ จะทำการเลือกเฉพาะ ปี 2005 เท่านั้นที่จะนำมา วิเคราะห์ ด้วยเหตุผล 3 ประการคือ

(1) ข้อมูลภาพเรดาร์ของสถานีอมก๋อย มีข้อมูลภาพ ตั้งแต่ปี 2005 เป็นต้นไป เนื่องจากมีการปรับเปลี่ยนระบบการ จัดเก็บข้อมูล และในช่วงที่เกิดเหตุการณ์น้ำท่วมปี 2006 เครื่อง เรดาร์ขัดข้องจึงไม่สามารถบันทึกข้อมูลในช่วงการเกิดน้ำท่วม ได้

(2) มีการสร้างกำแพงเสริมความสูงของระดับตลิ่งใน บริเวณตัวเมืองเชียงใหม่ เพิ่มจากเดิม 3.40 เมตร เป็น 3.70 ตั้งแต่ปี 2004 ซึ่งการเพิ่มระดับตลิ่งทำให้พฤติกรรมของ น้ำท่วมเปลี่ยนแปลงไป โดยถ้าพยากรณ์ระดับน้ำ ปี 2005 และ

ใช้เฉพาะข้อมูลระดับน้ำ ในปี 2005 อย่างเดียวสำหรับการเรียนรู้จะให้ผลดีกว่าการใช้ข้อมูลปี 2001-2004 สำหรับการเรียนรู้ ดังนั้นสำหรับการพยากรณ์น้ำท่วมในปีปัจจุบันควรจะต้องใช้ข้อมูลหลังจากปี 2004 เป็นต้นไป

(3) เนื่องจากงานวิจัยนี้เป็นงานวิจัยต่อเนื่องจากงานวิจัยของ Chaipimonplin<sup>13</sup> ซึ่ง ณ เวลาดังกล่าวเหตุการณ์น้ำท่วมล่าสุดมีเพียง เหตุการณ์ ปี 2006 เท่านั้น

การคัดเลือกช่วงข้อมูลที่เกิดเหตุการณ์น้ำท่วม จะเริ่มตั้งแต่ปี 2005 โดยเป็นเหตุการณ์น้ำท่วมครั้งใหญ่ในประวัติศาสตร์เชียงใหม่ ซึ่งมีจำนวนเหตุการณ์น้ำท่วมทั้งสิ้น 5

เหตุการณ์ ตั้งแต่เดือนสิงหาคมถึงเดือนตุลาคม โดยจากไฮโดรกราฟ (Figure 3) จะพบว่า เหตุการณ์น้ำท่วมเดือนสิงหาคม มีระดับน้ำที่สูงที่สุด ดังนั้นสำหรับการทดสอบความสามารถของแบบจำลองโครงข่ายประสาทเทียมจะใช้เหตุการณ์น้ำท่วมที่รุนแรงที่สุดในปี 2005 คือเหตุการณ์น้ำท่วมในเดือนสิงหาคม ส่วนอีก 4 เหตุการณ์จะใช้สำหรับการเรียนรู้ของแบบจำลอง สำหรับการวัดค่าความสัมพันธ์ระหว่างอัตราการไหลของน้ำและระดับน้ำ (Rating curve) จะใช้ของปี 2004 (ตามกรมชลประทาน นำค่าความสัมพันธ์ของปี 2004 มาใช้ในปี 2005)

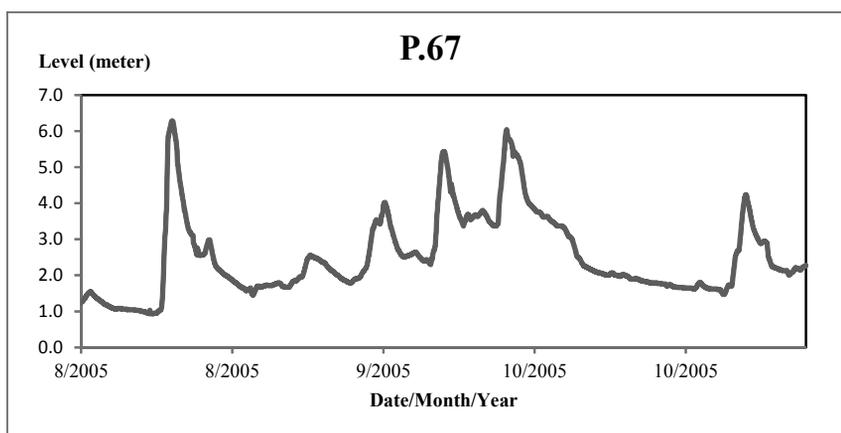


Figure 3 Water levels at P.67 between August-October 2005

**การออกแบบของแบบจำลอง**

สำหรับการออกแบบของแบบจำลองโครงข่ายประสาทเทียม ข้อมูลนำเข้าประกอบด้วยอัตราการปล่อยน้ำออกจากเขื่อน ข้อมูลระดับน้ำ และข้อมูลสภาพเรดาร์ ซึ่งใช้การเรียนรู้ประเภท BR และกำหนดจำนวนเซลล์ในชั้นซ่อนเร้น (Hidden node) จำนวน 10 เซลล์โดยทำการพยากรณ์ระดับน้ำ ณ เวลา 6, 12, และ 18 ชั่วโมงล่วงหน้า ที่สถานี P.67 สามารถแบ่งการทดลองได้ทั้งหมด 3 การทดลอง ดังนี้

การทดลองที่ 1 ใช้ข้อมูลสภาพเรดาร์ ทั้งหมด 6 จุด คือ Z11-Z23 ที่เวลา t และ t-6 ร่วมกับข้อมูลระดับน้ำที่สถานี P.75 ณ เวลา t และ t-6 (ข้อมูลนำเข้า 14 ข้อมูล) ใช้อักษร B เป็นสัญลักษณ์

การทดลองที่ 2 ใช้ข้อมูลสภาพเรดาร์ ทั้งหมด 6 จุด คือ Z11-Z23 ที่เวลา t และ t-6 ร่วมกับข้อมูลระดับน้ำที่สถานี P.75 ณ เวลา t และ t-6 โดยมีการปรับแก้ค่าระดับน้ำจากอัตราการปล่อยน้ำออกจากเขื่อน (ข้อมูลนำเข้า 14 ข้อมูล) ใช้อักษร BXX เป็นสัญลักษณ์

การทดลองที่ 3 ใช้ข้อมูลในแบบจำลอง B ร่วมกับอัตราการปล่อยน้ำออกจากเขื่อนลูกบาศก์เมตรต่อชั่วโมง (flow t, moving average flow t-6) (ข้อมูลนำเข้า 16 ข้อมูล) ใช้อักษร C เป็นสัญลักษณ์

**การประเมินประสิทธิภาพ**

สำหรับการประเมินประสิทธิภาพของแบบจำลอง จะใช้ค่าสถิติ Peak Difference (PDIFF) คือค่าความแตกต่างของระดับน้ำสูงสุด (ค่าผลต่าง ณ จุดระดับน้ำที่สูงระหว่างค่าจริง และค่าจากแบบจำลอง ถ้าค่าติดลบ หมายถึงแบบจำลองพยากรณ์ระดับน้ำต่ำกว่าระดับจริง), Root Mean Squared Error (RMSE) คือ ค่าความคลาดเคลื่อนรวมระหว่างค่าจริง และค่าจากแบบจำลอง ค่าที่เข้าใกล้ 0 หมายถึงแบบจำลองมีประสิทธิภาพที่ดี และ Coefficient of Efficiency (CE) คือค่าความสัมพันธ์ระหว่างค่าจริงและค่าจากแบบจำลอง ถ้าค่าใกล้ 1 หมายถึงแบบจำลองมีประสิทธิภาพที่ดี

**ผลการวิจัยและอภิปราย**

เนื่องจากแบบจำลอง B (ใช้ข้อมูลเรดาร์ และระดับน้ำสถานี P.75) แบบจำลอง BXX (ใช้ข้อมูลเรดาร์และระดับน้ำสถานี P.75 ที่มีการปรับแก้ค่าระดับน้ำ) และ แบบจำลอง C (ใช้ข้อมูลเรดาร์, ระดับน้ำสถานี P.75 และอัตราการปล่อยน้ำออกจากเขื่อน) จาก Figure 4 พบว่าแบบจำลองทั้งสามมีประสิทธิภาพการเรียนรู้ที่ดี แต่แบบจำลองที่ใช้ข้อมูลเรดาร์ ข้อมูลระดับน้ำและอัตราการปล่อยน้ำจากเขื่อน (C เส้นสีม่วง) มีการเรียนรู้ที่ดีที่สุด เมื่อพยากรณ์ 6, 12 และ 18 ชั่วโมงล่วงหน้า ส่วนแบบจำลองที่มีการปรับแก้ค่าระดับน้ำจากเขื่อน (BXX-เส้นสีเขียว) มีประสิทธิภาพการเรียนรู้ที่ต่ำที่สุด เมื่อ

เทียบกับแบบจำลองที่ไม่มีมีการปรับแก้ค่าใดๆ โดยค่าสถิติที่ RMSE มากที่สุด และ CE น้อยที่สุด โดยเฉพาะเมื่อพยากรณ์ 12 และ 18 ชั่วโมงล่วงหน้า (Table 1) และแบบจำลอง C เป็นแบบจำลองที่มีประสิทธิภาพสูงสุดในการพยากรณ์ล่วงหน้า 6 ชั่วโมง ซึ่งพยากรณ์ระดับน้ำสูงสุดคลาดเคลื่อนเพียง 0.0085 เมตร หรือ 0.85 เซนติเมตร และมีค่า RMSE และ CE ที่ดีที่สุด (0.0656, 0.9962 ตามลำดับ) แต่แบบจำลอง B ซึ่งเป็นแบบจำลองเดียวที่ไม่มีมีการใช้ข้อมูลการปล่อยน้ำออกจากเขื่อน มีประสิทธิภาพการพยากรณ์ระดับน้ำสูงสุดที่ดีที่สุดโดยพยากรณ์ระดับน้ำสูงสุด ณ เวลา 12 และ 18 ชั่วโมงล่วงหน้าคลาดเคลื่อนเพียง 0.69 และ 0.08 เซนติเมตร

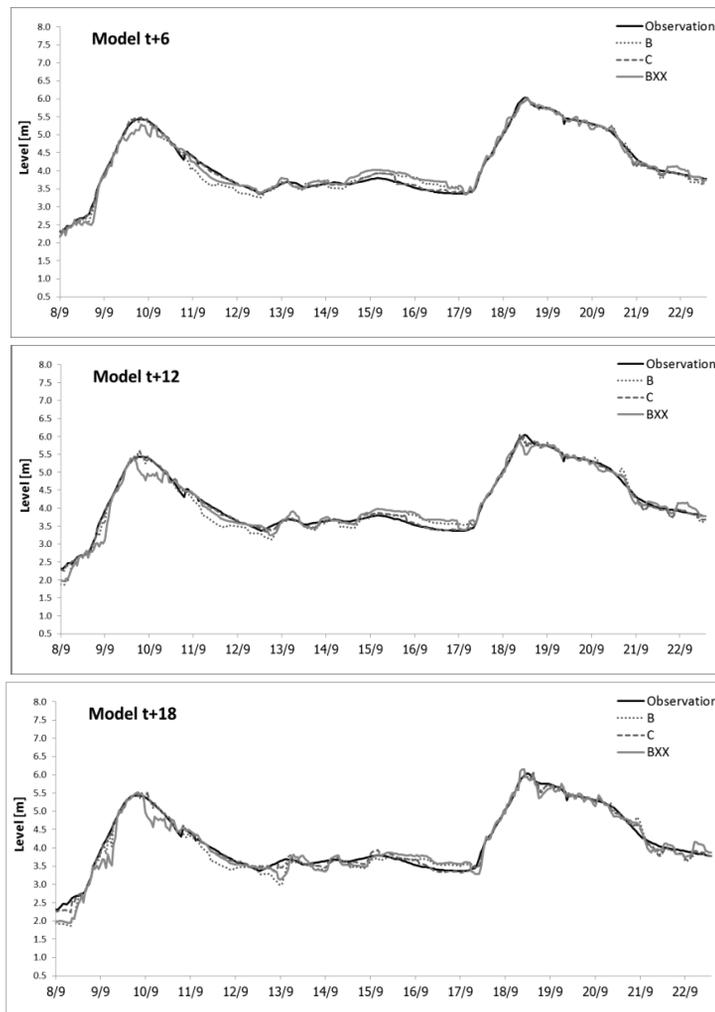


Figure 4 Hydrographs of ANN learning at P.67 in September 2005

Table 1 Statistic result of ANN learning

Model	t+6			t+12			t+18		
	PDIFF	RMSE	CE	PDIFF	RMSE	CE	PDIFF	RMSE	CE
B	-0.0142	0.1384	0.9829	0.0069	0.1459	0.9811	-0.0008	0.1628	0.9764
C	-0.0085	0.0656	0.9962	-0.0271	0.0763	0.9948	0.0105	0.1017	0.9908
BXX	-0.0576	0.1383	0.983	-0.1474	0.159	0.9775	0.1097	0.1861	0.9692

แต่เมื่อทดสอบแบบจำลองโดยการพยากรณ์ระดับน้ำล่วงหน้าในช่วงเดือน สิงหาคม (Figure 5) พบว่าแบบจำลองที่มีการใช้ข้อมูลเรดาร์ร่วมกับการปรับแก้ระดับน้ำ (BXX เส้นสีเขียว) มีประสิทธิภาพดีที่สุด โดยเส้นไฮโดรกราฟในช่วงระดับน้ำขึ้น-น้ำลง และระดับน้ำสูงสุดแสดงผลได้ดีกว่าแบบจำลอง B (เส้นสีแดง) และ C (เส้นสีม่วง) โดยแบบจำลอง BXX สามารถพยากรณ์ได้ล่วงหน้า ทั้ง 3 ช่วงเวลาพยากรณ์ และค่าสถิติ (Table 2) แสดงว่าแบบจำลอง BXX มีประสิทธิภาพมากที่สุด สำหรับการพยากรณ์ระดับน้ำ 6, 12, 18 ชั่วโมงล่วงหน้า โดยมีค่า CE มากกว่า 0.90 ค่า PDIFF ที่ดีที่สุด และค่า RMSE ที่น้อยที่สุด ซึ่งมีปัจจัย 2 ข้อ คือ (1) แบบจำลอง B และ C ใช้ข้อมูลที่ไม่มีการปรับแก้ระดับน้ำ ซึ่งช่วงเหตุการณ์น้ำท่วมที่ใช้ในการทดสอบประสิทธิภาพของแบบจำลองนั้น พบว่ามี

การปิดประตูระบายน้ำในช่วงวันที่ 13 สิงหาคม เป็นต้นไป จึงทำให้มีประสิทธิภาพแบบจำลอง B และ C ในการพยากรณ์ช่วงเหตุการณ์ดังกล่าวลดลง เพราะข้อมูลของการเรียนรู้มีอิทธิพลของการปล่อยน้ำออกจากเขื่อน ซึ่งมีผลต่อพฤติกรรมของระดับน้ำในลำน้ำปิงแต่เหตุการณ์ที่ใช้ทดสอบ ไม่มีอิทธิพลของการปล่อยน้ำออกจากเขื่อนเนื่องจากเขื่อนปิดประตูระบายน้ำในทางตรงข้าม แบบจำลอง BXX มีการใช้ข้อมูลการปล่อยน้ำจากเขื่อนมาปรับแก้ค่าระดับน้ำที่สถานีต้นน้ำ (P. 75) จึงทำให้มีค่าระดับน้ำที่มีสัมพันธการปิด เปิดประตูน้ำถูกต้องมากที่สุดสำหรับการเรียนรู้ และ (2) ในกระบวนการเรียนรู้แบบจำลอง B และ C อาจมีการเรียนรู้ดีเกินไป (Table 1) จึงทำให้ประสิทธิภาพของแบบจำลองลดลงเมื่อทดสอบในเหตุการณ์ที่มีความแตกต่างจากเหตุการณ์ในการเรียนรู้

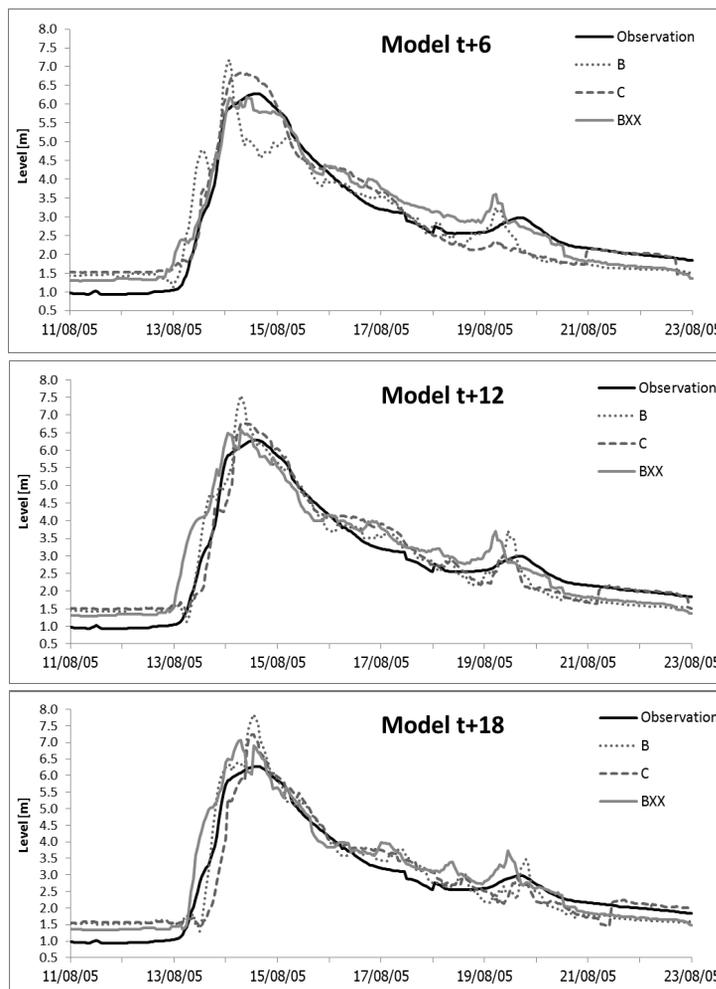


Figure 5 Hydrographs of ANN testing at P.67 in August 2005

Table 2 Statistic result of ANN testing

Model	t+6			t+12			t+18		
	PDIFF	RMSE	CE	PDIFF	RMSE	CE	PDIFF	RMSE	CE
B	0.8962	0.5107	0.8584	1.2718	0.4001	0.9131	1.566	0.4445	0.8927
C	0.5445	0.4992	0.8647	0.4871	0.4906	0.8693	0.9567	0.5423	0.8403
BXX	-0.1002	0.3545	0.9318	0.2938	0.3442	0.9357	0.784	0.3854	0.9193

## สรุปและข้อเสนอแนะ

จากการทดสอบ 3 วิธี คือ ใช้ข้อมูลเรดาร์ร่วมกับข้อมูลระดับน้ำ P.75 (B) ใช้ข้อมูลเรดาร์ร่วมกับข้อมูลระดับน้ำและอัตราการปล่อยน้ำจากเขื่อน (C) และ ใช้ข้อมูลเรดาร์ ร่วมกับข้อมูลระดับน้ำที่มีการปรับแก้ค่าระดับน้ำจากการปล่อยน้ำออกจากเขื่อน (BXX) พบว่าวิธีที่จะช่วยให้แบบจำลองมีประสิทธิภาพมากที่สุดสำหรับการพยากรณ์ระดับน้ำที่ P.67 คือการใช้ข้อมูลเรดาร์ร่วมกับข้อมูลระดับน้ำสถานี P.75 ที่มีการปรับแก้จากอัตราการไหลของน้ำจากเขื่อน (BXX) โดยใช้ความสัมพันธ์ระหว่างอัตราการไหลของน้ำ และระดับน้ำของสถานี P.75 โดยแบบจำลองสามารถพยากรณ์ระดับน้ำของสถานี P.67 ได้ล่วงหน้า 18 ชั่วโมง ดังนั้นแบบจำลองโครงข่ายประสาทเทียม สามารถที่จะเป็นเครื่องมือที่จะช่วยให้การเตือนภัยน้ำท่วมได้ล่วงหน้ามากขึ้น โดยต้องมีการบูรณาการข้อมูลหลายประเภท คือ ข้อมูลเรดาร์ ข้อมูลระดับน้ำ และข้อมูลอัตราการปล่อยน้ำออกจากเขื่อน และเมื่ออ้างอิงความสัมพันธ์ของระดับน้ำระหว่างสถานี P.67 และ P.1 ที่อ้างอิงระดับน้ำวิกฤตจากสถานี P.67 เพื่อใช้ในการเตือนภัยน้ำท่วมที่สถานี P.1 โดยระยะเวลาเตือนภัย 6-7 ชั่วโมง ซึ่งหมายความว่า ถ้าแบบจำลองสามารถพยากรณ์ระดับน้ำที่สถานี P.67 ได้ล่วงหน้า 18 ชั่วโมง ก็แสดงว่า ระยะเวลาการเตือนภัยน้ำท่วมของสถานี P.1 สามารถเพิ่มขึ้นจาก 6 ชั่วโมง เป็น 24 ชั่วโมง

ข้อเสนอแนะสำหรับการเป็นแนวทางในการทำการวิจัยในอนาคต คือ (1) มีการปรับแก้ค่าระดับน้ำกับอัตราการไหลของน้ำที่ถูกปล่อยออกมาจากเขื่อน ควรจะลองนำมาปรับแก้ที่สถานี P.67 ในกรณีที่จะพยากรณ์น้ำท่วมที่สถานี P.1 (2) เนื่องจากระยะเวลาที่ใช้ในการประมวลผลของการเรียนรู้ BR จะใช้ระยะเวลาที่ค่อนข้างนาน โดยเฉพาะแบบจำลองที่มีปริมาณข้อมูลมากและจำนวนเซลล์ในชั้นซ่อนเร้นที่มาก จึงควรทำการศึกษาวิเคราะห์จำนวนรอบการเรียนรู้ของ BR สำหรับในพื้นที่ลุ่มน้ำปิง (3) มีการทดสอบประเภทการเรียนรู้ประเภทอื่นๆ เพื่อหาประเภทการเรียนรู้ที่เหมาะสมที่สุดในการพยากรณ์น้ำท่วมในลุ่มน้ำปิง เช่น Levenberg-Marquardt (LM), BEGS Quasi-Newton, Resilient Backpropagation, Scaled Conjugate Gradient, Conjugate Gradient with Powell/Beale Restarts, Fletcher-Powell Conjugate Gradient, One Step Secant, Gradient Descent หรือ Gradient Descent with Momentum เป็นต้น และ (4) เพื่อป้องกันการเรียนรู้ที่เกินไปของแบบจำลองโครงข่ายประสาทเทียม ควรจะมีการปรับแก้ค่าความคลาดเคลื่อนที่ยอมรับได้ในกระบวนการเรียนรู้ของแบบจำลอง (Parameter goal) ให้มีค่ามากขึ้น หรือ การกำหนดจำนวนเซลล์ในชั้นซ่อนเร้นให้น้อยลง หรือ กำหนดค่า

อัตราการเรียนรู้ (Learning rate) หรือค่าเบี่ยงเบน (Bias) ซึ่งในการกำหนดค่านี้ขึ้นอยู่กับกรณีศึกษาในแต่ละกรณี

## กิตติกรรมประกาศ

ขอขอบคุณกองทุนพัฒนาวิชาการ คณะสังคมศาสตร์ มหาวิทยาลัยเชียงใหม่ ที่ได้สนับสนุนงบประมาณในการทำวิจัยครั้งนี้ และขอบคุณศูนย์อุทกวิทยาและบริหารน้ำ ภาคเหนือตอนบน สำหรับข้อมูลระดับน้ำ และสำนักฝนหลวงและการบินเกษตร สำหรับข้อมูลภาพเรดาร์

## เอกสารอ้างอิง

- Haykin S. Neural Networks – A Comprehensive Foundation. 2<sup>nd</sup> ed. New Jersey: Prentice-Hall; 1999.
- Kasabov N. Foundations of Neural Network, Fuzzy Systems, and Knowledge Engineering. Cambridge MA: The MIT Press; 1996.
- Abrahart RJ, See LM, Dawson CW, Shamseldin AY, Wilby RL. Nearly two decades of neural network hydrological modelling. In: Sivakumar B, Berndtsson R, editors. Advances in Data-Based Approaches for Hydrologic Modelling and Forecasting. Singapore: World Scientific; 2010: p. 267-346.
- 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.
- Anctil F, Lauzon N. Generalisation for neural networks through data sampling and training procedures, with applications to streamflow predictions. Hydrol Earth Syst Sci 2004;8:940-58.
- 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.
- 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.
- Anctil F, Lauzon N, Andreassian V, Oudin L, Perrin C. Improvement of rainfall-runoff forecasts through mean areal rainfall optimization. J Hydrology. 2006;328:717-25.

9. Chaipimonplin T, See LM, Kneale PE. Comparison of neural network learning algorithms; BR and LM for flood forecasting, Upper Ping catchment. USMCA 2001, 10<sup>th</sup> International Symposium on New Technologies for Urban Safety Mega Cities in Asia, 2011 October; Chiang Mai, Thailand.
10. 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. MODSIM 2011, Proceedings of the 19<sup>th</sup> 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.
11. Zhang B, Govindaraju RS. Prediction of watershed runoff using Bayesian concepts and modular neural networks. *Water Resources Research*. 2000;36:753-62.
12. ศูนย์อุทกวิทยาและบริหารน้ำ ภาคเหนือตอนบน (2550) ไปประชาสัมพันธ์ การเตือนภัยน้ำท่วมในเขตภาคเหนือตอนบน, กรมชลประทาน.
13. Chaipimonplin T. An Exploration of Neural Network Modelling Options for the Upper River Ping, Thailand. PhD in Physical Geography. Leeds: University of Leeds; 2010.
14. Chaipimonplin T, See LM, Kneale PE. Using radar data to extend the lead time of neural network forecasting on the River Ping. *Disaster Advances*. 2010;3(3):35-43.