

แบบจำลองโครงข่ายประสาทเทียมชนิดแพร่กลับที่เหมาะสมที่สุดในการพยากรณ์ปริมาณน้ำท่วม สำหรับแม่น้ำปิง

AN OPTIMIZED BACK-PROPAGATION NEURAL NETWORK FOR FLOOD FORECASTING IN THE PING RIVER

สุประภาพ พัฒน์สิงหนะณี (Supapap Patsinghasanee)

นิสิตปริญญาโท ภาควิชาวิศวกรรมทรัพยากรน้ำ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์

supapap@hotmail.com

สุรัชย์ ลิปิวัฒนาการ (Surachai Lipiwattanakarn)

ผู้ช่วยศาสตราจารย์ ภาควิชาวิศวกรรมทรัพยากรน้ำ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์

fengsuli@ku.ac.th

นุชนารถ ศรีวงศิตานนท์ (Nuchanart Sriwongsitanon)

รองศาสตราจารย์ ภาควิชาวิศวกรรมทรัพยากรน้ำ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์

fengnns@ku.ac.th

บทคัดย่อ: การศึกษานี้มีวัตถุประสงค์เพื่อหาจุดทำงานที่เหมาะสมที่สุดของแบบจำลองโครงข่ายประสาทเทียมชนิดแพร่กลับในการพยากรณ์ปริมาณน้ำท่วมล่วงหน้ารายชั่วโมง สำหรับสถานีวัดน้ำท่าอัตโนมัติ P.1 ซึ่งตั้งอยู่ที่สะพานนวรัตน์ อ.เมือง จ.เชียงใหม่ ในลุ่มน้ำปิงตอนบน ซึ่งประสบกับปัญหาสภาวะน้ำท่วมเป็นประจำโดยเฉพาะอย่างยิ่งในบริเวณตัวเมือง จ.เชียงใหม่ ผลการศึกษาพบว่า โครงสร้างที่เหมาะสมที่สุดคือ โครงสร้างขนาด 9-12-1 ที่มีค่าอัตราการเรียนรู้เท่ากับ 0.2 และค่าโมเมนตัมเท่ากับ 0.7 การประยุกต์แบบจำลองโครงข่ายประสาทเทียมชนิดแพร่กลับในการพยากรณ์ปริมาณน้ำท่วมให้ผลเป็นที่น่าพอใจ ซึ่งแสดงว่าแบบจำลองโครงข่ายประสาทเทียมชนิดแพร่กลับสามารถใช้ในการพยากรณ์ปริมาณน้ำท่วมได้เป็นอย่างดี

ABSTRACT: This study aimed at finding an optimized back-propagation neural networks model (BPNN) for hourly flood forecasting in the Ping River. The automatic gauging station P.1, which is located at the Nawarat Bridge, Amphoe Mueang, Chiang Mai Province, was selected as a forecasted station. The study area is part of the Upper Ping River Basin where flooding normally occurs, especially at the city of Chiang Mai Province. The results showed that the optimal model had a structure of 9-12-1. The optimal learning rate and momentum factor were found to be 0.2 and 0.7, respectively. The optimized model was found to satisfactorily forecast flooding hydrograph. The results indicated that the optimized back-propagation neural networks model performed flood forecasting tasks reasonably well.

KEYWORDS: BACK PROPAGATION NEURAL NETWORK, FLOOD FORECASTING, PING RIVER

1. บทนำ

การพยากรณ์ปริมาณน้ำท่วมจัดเป็นมาตรการที่ไม่ใช้สิ่งก่อสร้างที่มีความสำคัญ โดยสามารถนำมาใช้ในการวางแผนการจัดการทรัพยากรน้ำ และการวิเคราะห์มาตรการบรรเทาสถานะน้ำท่วมในธรรมชาตินั้นปริมาณน้ำท่วมขึ้นอยู่กับกระบวนการทางอุทกวิทยาและกระบวนการทางด้านศาสตร์ของกลุ่มน้ำ และลำน้ำนั้นๆ ซึ่งกระบวนการดังกล่าวมีความสลับซับซ้อน ทำให้การพยากรณ์ปริมาณน้ำท่วมเป็นไปได้ยาก แม้ว่าจะมีแบบจำลองที่ใช้ในการวิเคราะห์ห้อยู่มากมาย แต่แบบจำลองเหล่านั้นมีความต้องการข้อมูลจำนวนมาก ตลอดจนการใช้งานและการสอบเทียบแบบจำลองนั้นมักจะยุ่งยาก ซึ่งใช้กระบวนการการคำนวณที่มีความซับซ้อน และต้องอาศัยประสบการณ์ของผู้ใช้แบบจำลอง [1]

แบบจำลองระบบโครงข่ายประสาทเทียมชนิดแพร่กลับ (Back-Propagation Neural Networks, BPNN) เป็นแบบจำลองที่สามารถจำลองกระบวนการที่ซับซ้อนของธรรมชาติได้ และได้นำมาใช้ในการพยากรณ์ปริมาณน้ำท่วมอย่างมีประสิทธิภาพ ดังผลการศึกษาของ Campolo และคณะ [2] และ Dawson และ Wilby [3] อย่างไรก็ตาม Maier และ Dandy [4] พบว่าในงานศึกษาวิจัยส่วนใหญ่ได้มีการกล่าวถึงและเสนอแนะเกี่ยวกับโครงสร้างของแบบจำลอง และค่าพารามิเตอร์ต่าง ๆ ที่ใช้ในแบบจำลองน้อยมาก ทำให้ไม่สามารถศึกษาถึงการเปลี่ยนแปลงของค่าพารามิเตอร์ต่าง ๆ ในแบบจำลองโครงข่ายประสาทเทียมว่าส่งผลกระทบต่อแบบจำลองอย่างไรจากงานวิจัยเหล่านั้นได้ ดังนั้นงานวิจัยนี้มีวัตถุประสงค์ในการวิเคราะห์หาจุดทำงานที่เหมาะสมของแบบจำลองโครงข่ายประสาทเทียมชนิดแพร่กลับที่ใช้ในการพยากรณ์ปริมาณน้ำท่วม เพื่อเป็นแนวทางสำหรับการประยุกต์แบบจำลองโครงข่ายประสาทเทียมในการพยากรณ์ปริมาณน้ำท่วมล่วงหน้ารายชั่วโมงอย่างเหมาะสม

2. แบบจำลองโครงข่ายประสาทเทียมชนิดแพร่กลับ


แบบจำลองระบบโครงข่ายประสาทเทียม เป็นแบบจำลองทางคณิตศาสตร์ที่ประกอบไปด้วยโครงสร้างการทำงาน และการเชื่อมต่อเลียนแบบระบบการทำงานของเซลล์สมองของมนุษย์ งานวิจัยด้านโครงข่ายประสาทเทียมมีความแพร่หลายอย่างมาก หลังจากงานวิจัยของ [5] ซึ่งพัฒนากระบวนการแพร่กลับ (Back Propagation Algorithm) สำหรับงานด้านแหล่งน้ำ Maier และ

Dandy [4] สรุปว่าแบบจำลองที่นิยมใช้มากที่สุดคือ แบบจำลองโครงข่ายประสาทเทียมชนิดแพร่กลับ (BPNN)

โดยทั่วไปแล้วโครงข่ายของแบบจำลองประกอบด้วยชั้นของ node 3 ชั้น ได้แก่ ชั้นข้อมูลด้านเข้า (Input layer) ชั้นแฝง (Hidden layer) และชั้นแสดงผล (Output layer) ดังแสดงในรูปที่ 1 ข้อมูลจากชั้นข้อมูลด้านเข้าจะถูกคำนวณและส่งผ่านฟังก์ชันแปลงรูปจากชั้นแฝงไปยังชั้นแสดงผล โดยหลักการของกระบวนการเรียนรู้ของแบบจำลองคือ การเปลี่ยนแปลงค่าถ่วงน้ำหนักของแต่ละการเชื่อมต่อ เพื่อปรับผลลัพธ์ของแบบจำลองให้ใกล้เคียงกับค่าความจริงมากที่สุดโดยอาศัยการแพร่กลับ ซึ่งใช้สมการที่ (1) ในการปรับแก้ค่าถ่วงน้ำหนักมีดังนี้

$$\Delta w_{ji}(n+1) = \eta \delta(n) \cdot y_j(n) + \alpha \Delta w_{ji}(n) \quad (1)$$

เมื่อ x_i คือค่าข้อมูลด้านเข้าที่ node i, w_i คือค่าถ่วงน้ำหนักที่ node i, Δw_{ji} คือค่าปรับแก้ค่าถ่วงน้ำหนักระหว่าง node i และ j, η คือค่าอัตราการเรียนรู้, α คือค่าโมเมนตัม, δ_j คือค่าผลต่างระหว่างค่าจริงกับค่าที่ได้จากการคำนวณในรูปของอนุพันธ์ของ transfer function ของ node j, y_j คือค่าผลลัพธ์ของแบบจำลองที่ node j และ $n, n+1$ คือ ค่าที่แสดงถึงรอบของการปรับแก้ที่ n หรือ n+1



รูปที่ 1 โครงสร้างของแบบจำลอง BPNN

สมการดังกล่าวแสดงถึงค่าพารามิเตอร์หลักของแบบจำลอง ได้แก่ค่าอัตราการเรียนรู้และค่าโมเมนตัม ซึ่งมีผลกระทบต่อการทำงานของแบบจำลอง [6] นอกจากนี้แล้วยังมี

ส่วนประกอบอื่น ๆ ที่มีผลกระทบต่อการทำงานของแบบจำลอง เช่น โครงสร้างของแบบจำลองและชนิดของฟังก์ชันแปลงรูป (Transfer function) จะมีผลต่อประสิทธิภาพของแบบจำลองเช่นกัน ([7],[8])

3. วิธีการศึกษา

3.1 พื้นที่ศึกษา

พื้นที่ที่ใช้ในการศึกษานี้ คือพื้นที่ลุ่มน้ำปิงตอนบน โดยมีสถานีวัดน้ำท่า P.20, P.21 และ P.4A เป็นสถานีด้านเหนือน้ำ ซึ่งตั้งอยู่ในแม่น้ำปิงส่วนที่ 1, แม่ริม และแม่แตง ตามลำดับ และสถานีวัดน้ำท่า P.1 เป็นสถานีด้านท้ายน้ำ ซึ่งตั้งอยู่ในแม่น้ำปิงโดยสถานีวัดน้ำท่า P.1 มีพื้นที่รับน้ำเท่ากับ 6,355 ตร.กม. สำหรับความยาวลำน้ำจากสถานี P.20 ถึงสถานี P.1 เท่ากับ 102.5 กม. และใช้ข้อมูลในการเรียนรู้ตั้งแต่วันที่ 2 กรกฎาคม พ.ศ. 2543 ถึงวันที่ 31 สิงหาคม พ.ศ. 2543 จำนวน 1,450 ชุดข้อมูล และใช้ข้อมูลตั้งแต่วันที่ 1 กันยายน พ.ศ. 2543 ถึงวันที่ 1 พฤศจิกายน พ.ศ. 2543 จำนวน 1,450 ชุดข้อมูลสำหรับการทดสอบแบบจำลอง

3.2 การศึกษาความเหมาะสมของข้อมูลด้านเข้า

ในการศึกษาจำนวนข้อมูลปริมาณน้ำท่าที่ใช้ประกอบในการพยากรณ์ปริมาณน้ำท่วมล่วงหน้ารายชั่วโมงนั้น กระทำได้โดยคำนวณค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation coefficient) ที่ลู่ระหว่างข้อมูลปริมาณน้ำท่าที่สถานีด้านเหนือน้ำ (P.20 P.21 และ P.4A) และสถานีด้านท้ายน้ำ (P.1) ตามระยะเวลาในการเดินทางของน้ำท่าจากสถานีด้านเหนือน้ำต่าง ๆ ถึงสถานีด้านท้ายน้ำ โดยการนำข้อมูลของสถานีวัดน้ำท่าเหล่านั้นนี้มาวางเรียงกันตามเวลาการเกิดน้ำท่าสำหรับแต่ละสถานี เพื่อเปรียบเทียบเวลาการเกิดน้ำท่าที่แตกต่างกัน (Lag time) กับสถานีวัดน้ำท่า P.1 ดังสมการที่ (2)

$$r = \frac{\sum (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \cdot \sum (y_i - \bar{y})^2}} \quad (2)$$

เมื่อ r คือค่าสัมประสิทธิ์สหสัมพันธ์, x_i คือข้อมูลชุดที่หนึ่งที่ช่วงเวลา i , \bar{x} คือค่าเฉลี่ยของข้อมูลด้านเข้าที่ใช้ในแบบจำลอง,

y_i คือข้อมูลชุดที่สองที่ช่วงเวลา i และ \bar{y} คือค่าเฉลี่ยของข้อมูลชุดที่สอง

3.3 การศึกษาจุดทำงานที่เหมาะสมของแบบจำลอง

BPNN

การศึกษาจุดทำงานที่เหมาะสมของแบบจำลอง BPNN มีขั้นตอนการทำงานดังต่อไปนี้

1. ทำการศึกษาผลการเปลี่ยนแปลงจำนวน node ในชั้นแฝงโดยการเปลี่ยนแปลงจำนวน node ตั้งแต่ไม่มีจำนวน node ชั้นแฝงไปจนกระทั่งจำนวนชั้นแฝงมีค่าประมาณ 2 เท่าของจำนวน node ในชั้นข้อมูลด้านเข้า โดยพิจารณาจากค่า NSSE (Normalized sum square error) ที่ต่ำที่สุด โดยค่า NSSE มีสมการดังนี้

$$NSSE = \sum_{i=1}^N (Q_i - F_i)^2 \quad (3)$$

เมื่อ Q_i คือปริมาณน้ำท่าที่ได้จากการเก็บข้อมูลภาคสนามที่เวลา i , F_i คือปริมาณน้ำท่าที่คำนวณได้โดยแบบจำลองที่เวลา i และ N คือจำนวนชุดข้อมูลทั้งหมด

2. ทำการศึกษาผลการเปลี่ยนแปลงอัตราการเรียนรู้ตั้งแต่ 0.1-0.9 โดยพิจารณาจากค่า NSSE

3. ทำการศึกษาผลการเปลี่ยนแปลงค่าโมเมนตัมตั้งแต่ 0.1-0.9 โดยนำผลจำนวน node ในชั้นแฝงที่ได้จากการศึกษาในขั้นตอนการทำงานที่ 1 และค่าอัตราการเรียนรู้จากการศึกษาในขั้นตอนการทำงานที่ 2 มาประยุกต์ใช้กับแบบจำลองโครงข่ายประสาทเทียมเพื่อหาค่าโมเมนตัมที่เหมาะสมโดยพิจารณาจากค่า NSSE

3.4 การประยุกต์แบบจำลองกับการพยากรณ์น้ำท่วม

นำโครงสร้างของแบบจำลองโครงข่ายประสาทเทียมที่ได้จากการศึกษา และค่าพารามิเตอร์ต่าง ๆ ที่เหมาะสม มาประยุกต์ใช้ในการพยากรณ์ปริมาณน้ำท่วมล่วงหน้ารายชั่วโมง สำหรับสถานีวัดน้ำท่า P.1 โดยทำการเปรียบเทียบปริมาณน้ำท่าที่ได้จากแบบจำลอง กับปริมาณน้ำท่าที่ได้จากข้อมูลที่ได้จากการวัดจริง โดยใช้ค่าทางสถิติ 3 ค่า คือค่า Correlation coefficient (r) ดังสมการที่ 2, ค่า Efficiency index (EI) และค่า Root mean square error (RMSE) ดังสมการ

$$EI = \frac{\sum_{i=1}^N (Q_i - \bar{Q})^2 - \sum_{i=1}^N (Q_i - F_i)^2}{\sum_{i=1}^N (Q_i - \bar{Q})^2} \quad (4)$$

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

เมื่อ Q_i คือปริมาณน้ำท่าที่ได้จากการเก็บข้อมูลภาคสนามที่เวลา i , \bar{Q} คือค่าเฉลี่ยของปริมาณน้ำท่าที่ได้จากการเก็บข้อมูลภาคสนามโดยที่ $\bar{Q} = \frac{1}{N} \sum_{i=1}^N Q_i$, F_i คือปริมาณน้ำท่าที่คำนวณได้โดยแบบจำลองที่เวลา i และ N คือจำนวนข้อมูล

4. ผลการศึกษา

4.1 ผลการศึกษาความเหมาะสมของข้อมูลด้านเข้า

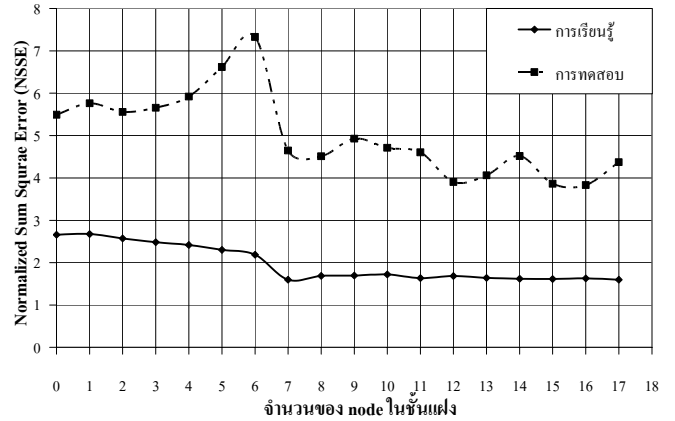
จำนวนของข้อมูลด้านเข้าที่เหมาะสมของสถานี P.20 P.4A และ P.21 ได้จากการศึกษาค่าสัมประสิทธิ์สหสัมพันธ์ของอัตราการไหลตามระยะเวลาการเกิดน้ำท่าที่แตกต่างกันระหว่างสถานีวัดน้ำท่าต่าง ๆ กับสถานีวัดน้ำท่า P.1 โดยเลือกช่วงเวลาที่ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างสถานีวัดน้ำท่าต่าง ๆ กับสถานีวัดน้ำท่า P.1 ให้ค่าสูงสุดและค่ารองลงมาสองลำดับ ทำให้การพยากรณ์ปริมาณน้ำท่าที่สถานี P.1 ประกอบด้วยโครงสร้างชั้นข้อมูลด้านเข้า 9 หน่วย ได้แก่ ข้อมูลปริมาณน้ำท่าที่สถานี P.20 ที่เวลา t-24, t-25 และ t-26 ตามลำดับ ข้อมูลปริมาณน้ำท่าที่สถานี P.4A ที่เวลา t-13, t-14 และ t-15 ตามลำดับ และข้อมูลปริมาณน้ำท่าที่สถานี P.21 ที่เวลา t-12, t-13 และ t-14 ตามลำดับ แสดงว่าสามารถพยากรณ์ปริมาณน้ำท่าล่วงหน้าได้นานถึง 12 ชั่วโมง และสามารถเขียนความสัมพันธ์ให้อยู่ในรูปของสมการได้ดังนี้

$$P.1_t = f(P.20_{t-24}, P.20_{t-25}, P.20_{t-26}, P.4A_{t-13}, P.4A_{t-14}, P.4A_{t-15}, P.21_{t-12}, P.21_{t-13}, P.21_{t-14}) \quad (6)$$

4.2 ผลกระทบของจำนวน node ในชั้นแฝง

การศึกษาการเปลี่ยนแปลงจำนวน node ในชั้นแฝง โดยการเปลี่ยนจำนวน node ตั้งแต่ 0-17 node พบว่าจำนวน node ในชั้นแฝงมีผลกระทบต่อประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียม โดยเมื่อจำนวน node ในชั้นแฝงมีจำนวนน้อยกว่าจำนวน node ของข้อมูลด้านเข้า (0-6 node) ค่า NSSE จะมีแนวโน้มลดลงเล็กน้อยแต่ไม่มีการเปลี่ยนแปลงมากนัก และเมื่อ

จำนวน node มีค่าใกล้เคียงกับจำนวน node ในชั้นข้อมูลด้านเข้า (7-13 node) ผลลัพธ์ที่ได้จากแบบจำลองจะอยู่ในเกณฑ์ดี ส่วนในกรณีที่จำนวน node มากกว่าจำนวน node ในชั้นข้อมูลด้านเข้าค่อนข้างมาก (มากกว่า 13 node) พบว่าผลการคำนวณจะมีลักษณะที่แกว่งมากในช่วงการคำนวณของรอบต้น ๆ และผลการคำนวณจะเข้าสู่ค่าจริงได้ช้า ทำให้แบบจำลองต้องใช้เวลาในการเรียนรู้สำหรับจำนวน node ที่เหมาะสมพบว่า จำนวน node ที่เหมาะสมเท่ากับ 12 node ซึ่งให้ค่าของ NSSE ดีที่สุดทั้งในการเรียนรู้ (Learning) และการทดสอบ (Testing) ดังรูปที่ 2



รูปที่ 2 ผลกระทบของจำนวน node ในชั้นแฝงที่มีต่อแบบจำลอง


4.3 ผลกระทบจากการเปลี่ยนแปลงอัตราการเรียนรู้

เนื่องจากค่าอัตราการเรียนรู้มีผลกระทบต่อความเร็วในการเรียนรู้ของแบบจำลองโครงข่ายประสาทเทียม ในการหาค่าชดเชยน้ำหนัก (weights) และค่าเบี่ยงเบน (bias) ที่เหมาะสม ซึ่งมีค่ามากกว่า 0 จึงได้ทำการเปลี่ยนแปลงค่าอัตราการเรียนรู้ในช่วง 0.1-0.9 ผลการศึกษาแสดงดังรูปที่ 3 โดยพบว่าเมื่อค่าอัตราการเรียนรู้มีค่าไม่สูงมาก (0.1-0.7) จะไม่มีผลต่อค่า NSSE มากนัก แต่เมื่อค่าอัตราการเรียนรู้มีค่าสูงขึ้น คือมีค่าตั้งแต่ 0.8 ขึ้นไปจะส่งผลให้กระบวนการการเรียนรู้ต้องใช้เวลาในการคำนวณมาก และค่าความคลาดเคลื่อนก็จะสูงขึ้นตามไปด้วย จากการศึกษาในครั้งนี้พบว่าค่าอัตราการเรียนรู้ที่เหมาะสมคือ 0.2 โดยจะให้ค่าผลลัพธ์ที่ดีที่สุด โดยค่าของ NSSE ของการเรียนรู้และการทดสอบมีค่าเท่ากับ 1.6841 และ 3.9068 ตามลำดับ


4.4 ผลกระทบจากการเปลี่ยนแปลงค่าโมเมนตัม

การกำหนดค่าโมเมนตัมในแบบจำลองโครงข่ายประสาทเทียม มีวัตถุประสงค์เพื่อใช้ในการปรับปรุงค่าถ่วงน้ำหนัก และค่าเบี่ยงเบนที่ใช้ในการคำนวณในรอบต่อไป การเพิ่มค่าโมเมนตัม

จะช่วยให้กระบวนการการเรียนรู้ของโครงข่ายประสาทเทียมลดการสั่น (Oscillation) และลดระยะเวลาที่ใช้ในการคำนวณ เพื่อให้แบบจำลองเข้าสู่ค่าชุกของน้ำหนักและค่าเบี่ยงเบนที่เหมาะสมได้อย่างรวดเร็วขึ้น จึงได้ทำการทดสอบค่าโมเมนตัมตั้งแต่ 0.1-0.9 ผลการศึกษาแสดงได้ดังรูปที่ 4 ซึ่งแสดงให้เห็นว่าค่าโมเมนตัมในช่วง 0.1-0.8 ให้ค่าความคลาดเคลื่อนทางสถิติใกล้เคียงกัน แต่เมื่อค่าโมเมนตัมเท่ากับ 0.9 ค่า NSSE จะสูงขึ้นมาก แสดงว่าแบบจำลองอาจก้าวข้ามจุดต่ำสุดแท้จริง (Global minima) ไปสู่จุดต่ำสุดเทียม (Local minima) ผลการศึกษาพบว่าค่าโมเมนตัมที่เหมาะสมเท่ากับ 0.7 ซึ่งให้ผลลัพธ์ทางสถิติที่ดีที่สุด โดยค่าของ NSSE ของการเรียนรู้และการทดสอบมีค่าเท่ากับ 1.6841 และ 3.9068 ตามลำดับ



รูปที่ 3 ผลกระทบของอัตราการเรียนรู้ที่มีต่อแบบจำลอง

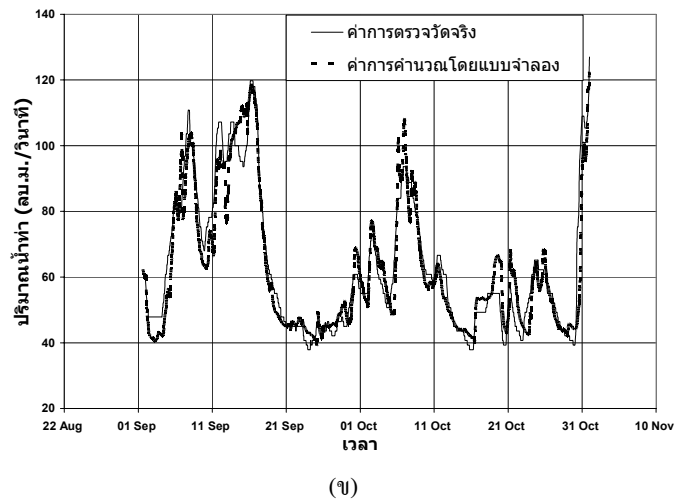



รูปที่ 4 ผลกระทบของค่าโมเมนตัมที่มีต่อแบบจำลอง

4.5 ผลการประยุกต์แบบจำลองในการพยากรณ์ปริมาณน้ำท่วม

จากผลการศึกษาข้างต้น ทำให้ได้แบบจำลองโครงข่ายประสาทเทียมที่มีความเหมาะสมสำหรับพื้นที่และชุดข้อมูลที่ใช้ในการศึกษา โดยแบบจำลองดังกล่าวมีโครงสร้างเป็น 9-12-1

ประกอบด้วยหน่วยในชั้นข้อมูลนำเข้า 9 หน่วย หน่วยในชั้นแฝงจำนวน 12 หน่วย และหน่วยในชั้นแสดงผล 1 หน่วย ค่าอัตราการเรียนรู้เท่ากับ 0.2 และค่าโมเมนตัมเท่ากับ 0.7 ผลการเรียนรู้และการทดสอบแบบจำลองแสดงได้ดังรูปที่ 5 โดยค่า Correlation coefficient (r) ของการเรียนรู้และการทดสอบมีค่าเท่ากับ 0.8893 และ 0.8921 ตามลำดับ แสดงให้เห็นว่าผลลัพธ์ที่ได้จากการคำนวณ โดยแบบจำลองกับค่าที่ได้จากการวัดจริงมีสอดคล้องกัน ค่า Efficiency Index (EI) ของการเรียนรู้และการทดสอบมีค่าเท่ากับ 0.8677 และ 0.8894 ตามลำดับ ซึ่งอยู่ในเกณฑ์ดีมาก สำหรับในกรณีของค่า RMSE ซึ่งเป็นดัชนีที่ใช้ในการบ่งบอกถึงความแตกต่างระหว่างค่าที่ได้จากการตรวจวัดกับค่าที่คำนวณ โดยแบบจำลอง ได้ค่า RMSE ของการเรียนรู้และการทดสอบเท่ากับ 8.3096 ลบ.ม./วินาที และ 7.0739 ลบ.ม./วินาที ตามลำดับ สามารถแสดงให้เห็นว่าแบบจำลองมีความคลาดเคลื่อนต่ำทั้งในกรณีการเรียนรู้และการทดสอบ



รูปที่ 5 ผลการพยากรณ์ปริมาณน้ำท่วมโดยแบบจำลองโครงข่ายประสาทเทียม (ก) การเรียนรู้ (ข) การทดสอบ

5. สรุปผลการศึกษา

1. จำนวนหน่วยในชั้นแฝงมีผลต่อประสิทธิภาพของแบบจำลองสำหรับชุดข้อมูลที่ใช้ในการศึกษาวิจัย พบว่าจำนวนหน่วยในชั้นแฝง จะต้องมามีค่าใกล้เคียงกับจำนวนหน่วยในชั้นข้อมูลด้านเข้าจึงจะทำให้ผลลัพธ์ของการพยากรณ์ที่ดีที่สุด
2. ค่าอัตราการเรียนรู้มีผลต่อประสิทธิภาพของแบบจำลองสำหรับข้อมูลที่ศึกษาพบว่า ควรกำหนดค่าอัตราการเรียนรู้ที่ไม่สูงจนเกินไป เนื่องจากค่าที่สูงเกินไปจะทำให้แบบจำลองเกิดการเรียนรู้ช้าลง และมีการแกว่งตัวมากขึ้น
3. ค่าโมเมนตัมมีผลกระทบต่อแบบจำลอง สำหรับข้อมูลที่ศึกษาพบว่าค่าที่เหมาะสมมีอยู่ในช่วง 0.1-0.8 โดยให้ค่าความผิดพลาดใกล้เคียงกันมาก แต่เมื่อค่าโมเมนตัมสูงเกินไปเท่ากับ 0.9 ปรากฏว่ามีค่าความผิดพลาดสูงมาก เนื่องจากค่าโมเมนตัมที่สูงเกินไปอาจทำให้เกิดการกระโดดข้ามจุดต่ำสุดที่แท้จริง ส่งผลให้มีค่าความผิดพลาดมาก
4. จากโครงสร้างที่ได้จากการศึกษา และค่าพารามิเตอร์ต่าง ๆ ที่เหมาะสมที่สุดของแบบจำลอง ทำให้สามารถนำมาประยุกต์ใช้ในการพยากรณ์ปริมาณน้ำท่วมรายชั่วโมงในแม่น้ำปิงตอนบนที่สถานีวัดน้ำท่าอัด โนมัด P.1 ได้อย่างมีประสิทธิภาพทั้งในช่วงการเรียนรู้และการทดสอบแบบจำลอง โดยค่า Correlation coefficient (r) ของการเรียนรู้และการทดสอบมีค่าเท่ากับ 0.8893 และ 0.8921 ตามลำดับ ค่า Efficiency Index (EI) ของการเรียนรู้และการทดสอบมีค่าเท่ากับ 0.8677 และ 0.8894 ตามลำดับ และค่า Root mean square error (RMSE) ของการเรียนรู้และการทดสอบมีค่าเท่ากับ 8.3096 ลบ.ม./วินาที และ 7.0739 ลบ.ม./วินาที ตามลำดับ ค่าทั้งหมดแสดงให้เห็นว่าแบบจำลองโครงข่ายประสาทเทียมสามารถใช้พยากรณ์ปริมาณน้ำท่วมได้เป็นอย่างดี

กิตติกรรมประกาศ

ขอขอบคุณสถาบันวิจัยและพัฒนาแห่งมหาวิทยาลัยเกษตรศาสตร์ ที่ให้ทุนสนับสนุนงานวิจัยนี้

เอกสารอ้างอิง

- [1] Duan, Q., Sorooshian, S and Gupta, V.K., Optimal use of SCE-UA global optimization method on calibrating watershed model, Journal of Hydrology, Vol.158, Page 265-284, 1994.

- [2] Compolo, M., P.Andreussi and A. Soldali., River flood forecasting with a neural network model, Water Resources Research, Vol.35(4), Page 1191-1197, 1999.
- [3] Dawson, C.W. and Wilby, R.L., Hydrological modeling using artificial neural networks, Progress in Physical Geography, Vol.25(1), Page 80-108, 2001.
- [4] Maier, H.R. and Dandy, G.C., Neural Networks for prediction and forecasting of water resources variables: a review of modeling issues and applications, Environmental Modeling & Software, Vol.15, Page 101-124, 2000.
- [5] Rumelhart, D.E. and Mc.Clelland J.L.(Eds.), Parallel distributed processing, Exploration in the microstructures of Cognition, Vol.1, The MIT Press.
- [6] Dai, H.C. and Mcbeth, C., Effects of learning parameters on learning procedure and performance of a BPNN, Neural Networks 10(8), Page 1505-1521, 1997.
- [7] Sheta, A.F. and El-Sherif, M.S., Optimal prediction of the Nile River flow using neural networks, International Joint Conference on Neural Networks, Vol.5, Page 3438-3441, 1999.
- [8] Maier, H.R. and Dandy, G.C., Understanding the behavior and optimizing the performance of back-propagation neural network: an empirical study, Environmental Modeling & Software, Vol.13, Page 179-191, 1998.