

การพยากรณ์ปริมาณน้ำในลำน้ำยมและน่าน ด้วยโปรแกรมโครงข่ายประสาทเทียม KUnet

Discharge Forecasting in Yom and Nan Rivers by KUnet Artificial Neural Networks Program

คำนำ

การพยากรณ์อัตราการไหลเป็นกระบวนการที่ใช้ในการวางแผนและบริหารจัดการน้ำ รวมถึงการเตือนภัยที่อาจเกิดขึ้นจากสภาวะอุทกภัย (Flood Warning) เนื่องจากกระบวนการทางอุทกวิทยาและคุณสมบัติต่างๆ ของลุ่มน้ำมีความสัมพันธ์ทางกายภาพที่สลับซับซ้อนและเป็นแบบไม่เชิงเส้น (Nonlinear) ส่งผลให้การพยากรณ์อัตราการไหลมีความน่าเชื่อถือในระดับที่จำกัด ดังนั้นควรมีแบบจำลองในการพยากรณ์อัตราการไหลที่มีประสิทธิภาพ

วิทยานิพนธ์ฉบับนี้ ได้ใช้โครงข่ายประสาทเทียมแบบ Backpropagation สำหรับการพยากรณ์อัตราการไหล โดยโครงข่ายดังกล่าวจัดอยู่ในชนิด Meso Structure ซึ่งมีลักษณะโครงข่ายเป็นแบบ Multilayered Feed Forward Networks ประกอบด้วยชั้นรับข้อมูล (Input Layer) ชั้นแฝง (Hidden Layer) และชั้นแสดงผล (Output Layer) โครงข่ายประสาทเทียมชนิดนี้มีลักษณะยืดหยุ่น ใช้ข้อมูลนำเข้า (Input Data) ที่มีตัวแปรจำนวนน้อย และเหมาะสมกับการนำไปประยุกต์ใช้ในการพยากรณ์

วิทยานิพนธ์ฉบับนี้เป็นการศึกษาเพื่อนำหลักการและทฤษฎีของโครงข่ายประสาทเทียมแบบ Backpropagation มาประยุกต์ใช้ในการพยากรณ์อัตราการไหลของแม่น้ำในประเทศไทย เพื่อประโยชน์ในการวางแผนและบริหารจัดการน้ำต่อไป โดยได้ใช้โปรแกรมคอมพิวเตอร์ชื่อ KUnet เพื่อช่วยในการพยากรณ์อัตราการไหล และทำการทดสอบโดยใช้ลำน้ำยมและน่านเป็นกรณีศึกษา เนื่องจากสภาพลำน้ำในลุ่มน้ำยมและน่านส่วนใหญ่ตื้นเขินและเก็บกักน้ำได้น้อย มักเกิดปัญหาอุทกภัยขึ้น สำหรับการคัดเลือกข้อมูลนำเข้าได้นำข้อมูลปริมาณน้ำของสถานีวัดปริมาณน้ำจำนวน 3 สถานี ในพื้นที่ลำน้ำในลุ่มน้ำยมและอีก 3 สถานี ในพื้นที่ลุ่มน้ำน่านมาทำการวิเคราะห์ หลังจากนั้นได้ทำการทดสอบโปรแกรม เพื่อวิเคราะห์ประสิทธิภาพในการพยากรณ์อัตราการไหล

วัตถุประสงค์

1. ศึกษาการพยากรณ์ปริมาณน้ำท่าของลำน้ำยมและลำน้ำน่าน โดยใช้โปรแกรมโครงข่ายประสาทเทียม KUnet
2. ทดสอบกระบวนการพยากรณ์อัตราการไหลรายวัน โดยใช้กรณีศึกษาของลำน้ำยมและลำน้ำน่าน โดยเปรียบเทียบผลการพยากรณ์กับข้อมูลทางสถิติที่มีการบันทึกไว้
3. นำค่า พารามิเตอร์ ที่ได้จากการปรับแก้ค่าที่เหมาะสมในการคำนวณ โดยใช้โปรแกรมโครงข่ายประสาทเทียม KUnet ของลำน้ำยมลำน้ำน่านมาเปรียบเทียบความแตกต่างของทั้ง 2 กลุ่มน้ำ

ขอบเขตการศึกษา

1. กรณีศึกษาที่ใช้ในการทดสอบการพยากรณ์อัตราการไหล ได้แก่ลำน้ำยม ณ สถานีวัดปริมาณน้ำท่า Y.1 , ลำน้ำน่าน ณ สถานีวัดปริมาณน้ำที่ N.1 โดยทำการพยากรณ์ในช่วงฤดูฝนระหว่าง เดือนกรกฎาคม ถึง เดือนกันยายน
2. ข้อมูลที่นำมาใช้ในการพยากรณ์อัตราการไหล ได้แก่ข้อมูลปริมาณน้ำท่ารายวันของสถานีตรวจวัดปริมาณน้ำในพื้นที่ลุ่มน้ำที่มีอิทธิพลตามค่าสัมประสิทธิ์สหสัมพันธ์ต่อปริมาณน้ำท่ารายวัน ณ สถานีที่ทำการพยากรณ์
3. ทำการทดสอบโครงสร้างของโครงข่ายประสาทเทียมและค่าพารามิเตอร์ต่างๆ ที่มีผลต่อการพยากรณ์อัตราการไหลรายวัน

การตรวจเอกสาร

อัตราการไหล

อัตราการไหล (Discharge) หมายถึง ปริมาณน้ำในลำน้ำที่ไหลผ่านหน้าตัดของลำน้ำในช่วงเวลาหนึ่ง ปัจจัยที่ทำให้เกิดการไหลประกอบด้วยแรงโน้มถ่วงของโลก (Gravity) ที่กระทำต่อมวลของไหล แรงดันน้ำ (Water Pressure) และแรงเสียดทานที่ต้านทานการไหลของของไหล โดยมีทิศทางการไหลจากบริเวณที่มีพลังงาน (Energy) สูงไปสู่บริเวณที่มีพลังงานต่ำ ซึ่งปริมาณของอัตราการไหลขึ้นอยู่กับกระบวนการทางอุทกวิทยาและคุณลักษณะต่างๆ ของลุ่มน้ำ เช่น รูปร่างความลาดชันและความขรุขระของลำน้ำ (Channel Characteristic) ชนิดของดินในพื้นที่ลุ่มน้ำ (Soil Type) และลักษณะของพื้นที่ลุ่มน้ำ (Watershed Topography) เป็นต้น

จากกระบวนการทางอุทกวิทยาสามารถอธิบายการเกิดอัตราการไหลของปริมาณน้ำทำได้ดังนี้ น้ำระเหยจากมหาสมุทร แหล่งน้ำต่างๆ และพื้นดินกลายเป็นไอน้ำในบรรยากาศแล้วกลั่นตัวเป็นน้ำจากอากาศ (Precipitation) ตกลงสู่มหาสมุทรและพื้นดิน เช่น ฝน ลูกเห็บและหิมะ เป็นต้น ฝนบางส่วนได้ระเหยกลายเป็นไอน้ำก่อนที่จะตกลงถึงพื้นดิน และบางส่วนก็ตกค้างอยู่ตามต้นไม้และสิ่งก่อสร้างแล้วระเหยสู่บรรยากาศ ในกรณีที่ฝนมีปริมาณมากกว่าอัตราการซึมทำให้เกิดการไหลตามผิวดิน (Overland Flow) และไหลลงสู่ลำน้ำเรียกว่าน้ำท่าผิวดิน (Surface Runoff) ส่วนปริมาณน้ำที่ซึมลงไปในดิน แบ่งออกเป็น 2 ส่วน โดยส่วนแรกเป็นส่วนที่ซึมลงไปในดินชั้นบน แล้วไหลออกสู่ลำน้ำ (Interflow) อีกส่วนไหลซึมลงไปสะสมในชั้นน้ำใต้ดินแล้วค่อยไหลออกลงสู่ลำน้ำในที่สุด (Groundwater Flow) ดังนั้นอัตราการไหลของปริมาณน้ำท่าจึงประกอบด้วยน้ำจากการไหลออกโดยตรง (Direct Runoff) และการไหลออกพื้นฐาน (Base Flow) สำหรับการไหลออกโดยตรง คือ การไหลตามผิวยรวมกับการไหลออกทันทีของน้ำที่ซึมลงไปในดินชั้นบน และรวมกับน้ำฝนที่ตกลงบนลำน้ำโดยตรง (Direct Rainfall) ส่วนการไหลพื้นฐาน คือ การไหลใต้ดินที่เกิดจากการซึมลึกลงขณะที่ฝนตกรวมกับการไหลของน้ำใต้ดินจากชั้นน้ำใต้ดินออกสู่ลำน้ำ ซึ่งกราฟที่ใช้แสดงความสัมพันธ์ของอัตราการไหลหรือคุณสมบัติต่างๆ ของการไหลเทียบกับเวลา คือ ไฮโดรกราฟ (Hydrograph) โดยลักษณะรูปร่างของไฮโดรกราฟ มีผลมาจากปริมาณน้ำและคุณลักษณะต่างๆ ของลุ่มน้ำ

การเคลื่อนที่ของปริมาณน้ำ

การเคลื่อนที่ของปริมาณน้ำ (Flow Routing) เป็นวิธีการหาอัตราการไหลเทียบกับเวลาที่ตำแหน่งท้ายน้ำ ณ จุดใดๆ จากข้อมูล Hydrograph ที่ทราบค่าที่ตำแหน่งต้นน้ำ โดยการวิเคราะห์การเคลื่อนที่ของปริมาณน้ำ สามารถแบ่งออกเป็น 2 ประเภท (Subramanya, 1994) ได้แก่

1. Lumped Flow Routing

Lumped Flow Routing หมายถึง การเคลื่อนที่ทางอุทกวิทยา (Hydrologic Routing) โดยพิจารณาฟังก์ชันของเวลา (Time) เพียงอย่างเดียว ซึ่งนำมาใช้ในการอธิบายการเปลี่ยนแปลงฝน (Rainfall) ไปเป็นน้ำท่า (Runoff) ที่เกิดบนพื้นที่ลุ่มน้ำ แบ่งเป็น 2 ลักษณะดังนี้

Reservoir Routing

1.1 Reservoir Routing เป็นการเคลื่อนที่ของปริมาณน้ำในอ่างเก็บน้ำ สามารถวิเคราะห์ได้จาก Full Method ซึ่งแสดงไว้ในสมการดังต่อไปนี้

$$\text{Inflow} = \text{Outflow} + \text{Change in Storage} \quad (1)$$

$$= \frac{I_1 + I_2}{2} - \frac{O_1 + O_2}{2} + \frac{S_1 - S_2}{2} \quad (2)$$

1.2 Channel Routing

Channel Routing เป็นการเคลื่อนที่ของปริมาณน้ำในลำน้ำ สามารถวิเคราะห์ได้จาก Muskingum Method ซึ่งแสดงไว้ในสมการดังต่อไปนี้

$$S = K[XI + (1 - X)O] \quad (3)$$

$$O_2 = C_0 I_2 + C_1 I_1 + C_2 O_1 \quad (4)$$

$$C_0 = -\left(\frac{KX - 0.5t}{K - KX + 0.5t} \right) \quad (5)$$

$$C_1 = \frac{KX + 0.5t}{K - KX + 0.5t} \quad (6)$$

$$C_2 = \frac{K - KX - 0.5t}{K - KX + 0.5t} \quad (7)$$

เมื่อ S คือ Storage (m^3/s)

K คือ Storage Constant with the Dimensions of Time

X คือ Dimensionless Constant for Reach

I คือ Inflow (m^3/s)

O คือ Outflow (m^3/s)

T คือ Duration (s)

2. Distribute Flow Routing

Distribute Flow Routing หมายถึงการเคลื่อนที่ทางชลศาสตร์ (Hydraulic Routing) โดยได้พิจารณาทั้งฟังก์ชันของเวลาและตำแหน่ง (Time & Space) สำหรับกระบวนการเคลื่อนที่ของปริมาณน้ำเป็นการเคลื่อนที่แบบมีการเปลี่ยนแปลงทั้ง 3 มิติ (Three Dimension Flow) ได้แก่ การเปลี่ยนแปลงตามแนวการเคลื่อนที่ของน้ำ ตามแนวขวางของลำน้ำและจากผิวน้ำลงสู่ลำน้ำ

การเคลื่อนที่ทางชลศาสตร์สามารถแบ่งเป็น 3 ลักษณะ คือ แบบ Kinematic Wave แบบ Diffusion Wave แบบ Dynamic Wave สำหรับการเคลื่อนที่แบบ Kinematic Wave คือ การที่แรงโน้มถ่วงและแรงเสียดทานมีความสมดุลกัน ปริมาณของไหลคงที่ทั้งในระยะทางและช่วงเวลาที่พิจารณา ได้แก่การไหลแบบ Uniform Steady Flow ส่วนการเคลื่อนที่แบบ Diffusion Wave คือ การเคลื่อนที่ทางชลศาสตร์ที่มีการเปลี่ยนแปลงปริมาณของไหลตามความยาวของลำน้ำ แต่คงที่ในช่วงเวลาที่พิจารณา ได้แก่ การไหลแบบ Non Uniform Steady Flow สำหรับการเคลื่อนที่แบบ Dynamic Wave คือ การเคลื่อนที่ทางชลศาสตร์มีการเปลี่ยนแปลงปริมาณของไหลตามความยาวของลำน้ำและช่วงเวลาที่พิจารณา ได้แก่ การไหลแบบ Non Uniform Unsteady Flow

การวิเคราะห์การเคลื่อนที่ทางชลศาสตร์ ใช้วิธี Saint Venant Equation โดยมีสมมุติฐาน คือ การไหลเป็นแบบ 1 มิติ (กระบวนการเคลื่อนที่ของปริมาณน้ำมีการเปลี่ยนแปลงตามความยาวของลำน้ำเท่านั้น) โดยที่การไหลมีการเปลี่ยนแปลงอย่างช้าๆ (Gradually Varied Flow) ความลาดชันของท้องน้ำน้อย ท้องน้ำมีลักษณะไม่เปลี่ยนแปลง การไหลไม่สามารถกดอัดได้ (Incompressible) และความหนาแน่นมีค่าคงที่ตลอดช่วงการไหล โดย Saint Venant Equations ประกอบด้วยสมการพื้นฐาน 2 สมการ คือ Continuity Equation และ Momentum Equation แสดงได้ตามลำดับดังนี้

$$\frac{\partial Q}{\partial x} + \frac{\partial A}{\partial t} - q = 0 \quad (8)$$

$$\frac{1}{A} \frac{\partial Q}{\partial t} + \frac{1}{A} \frac{\partial}{\partial x} \left(\frac{Q^2}{A} \right) + g \frac{\partial y}{\partial x} - g(S_0 - S_f) = 0 \quad (9)$$



- เมื่อ Q คือ อัตราการไหล (m^3/s)
- y คือ ความลึกของการไหล (m)
- x คือ ระยะทางตามแนวความยาวของลำน้ำ (m)
- A คือ พื้นที่หน้าตัดตามขวางของลำน้ำ (m^2)
- t คือ เวลา (s)
- g คือ ความเร่งเนื่องจากแรงโน้มถ่วง (m^2/s)
- S_0 คือ ความลาดชันของท้องน้ำ
- S_f คือ ความลาดชันของเส้นระดับพลังงาน (Energy Grade Line)

จากสมมุติฐานดังกล่าว สามารถนำไปประยุกต์ใช้ในการวิเคราะห์การเคลื่อนที่ทางชลศาสตร์ แบบ Kinematic Wave และแบบ Diffusion Wave โดยการนำวิธี Finite Difference และวิธี Muskingum Method มาใช้ร่วมกัน ดังแสดงในสมการที่ (10) ถึงสมการที่ (14) โดยค่า C_0 ค่า C_1 และค่า C_2 สามารถหาได้จากสมการที่ (5) ถึงสมการที่ (7) ดังที่กล่าวไว้ในข้างต้น ส่วนการวิเคราะห์การเคลื่อนที่ทางชลศาสตร์แบบ Dynamic Wave ใช้วิธี Finite Difference ดังแสดงในสมการที่ (15) ถึงสมการที่ (19)

$$\frac{\partial Q}{\partial x} = \frac{Q_{i+1}^{j+1} - Q_i^{j+1}}{\Delta x} \quad (10)$$

$$\frac{\partial A}{\partial t} = \frac{A_{i+1}^{j+1} - A_{i+1}^j}{\Delta t} \quad (11)$$

$$\frac{\partial Q}{\partial t} = \frac{Q_{i+1}^{j+1} - Q_{i+1}^j}{\Delta t} \quad (12)$$

$$q = \frac{q_{i+1}^{j+1} - q_{i+1}^j}{2} \quad (13)$$

$$Q_{i+1}^{j+1} = C_0 Q_i^{j+1} + C_1 Q_i^j + C_3 Q_{i+1}^j \quad (14)$$

$$\frac{\partial Q}{\partial x} = \theta \frac{Q_{i+1}^{j+1} - Q_i^{j+1}}{\Delta x} + (1 - \theta) \frac{Q_{i+1}^j - Q_i^j}{\Delta x} \quad (15)$$

$$\frac{\partial A}{\partial t} = \frac{A_i^{j+1} + A_{i+1}^{j+1} - A_i^j - A_{i+1}^j}{\Delta t} \quad (16)$$

$$\frac{\partial Q}{\partial t} = \frac{Q_i^{j+1} - Q_{i+1}^{j+1} - Q_i^j - Q_{i+1}^j}{\Delta t} \quad (17)$$


$$q = \theta \frac{q_i^{j+1} + q_{i+1}^{j+1}}{2} + (1 - \theta) \frac{q_i^j + q_{i+1}^j}{2} \quad (18)$$

$$A = \theta \frac{A_i^{j+1} + A_{i+1}^{j+1}}{2} + (1 - \theta) \frac{A_i^j + A_{i+1}^j}{2} \quad (19)$$

- เมื่อ j คือ เวลาที่พิจารณา
 i คือ ตำแหน่งที่พิจารณา
 q คือ Lateral Inflow (m^3/s)
 θ คือ Weighting Factor

ความสัมพันธ์ระหว่างระดับน้ำและอัตราการไหล (Stage-Discharge Relation)

Subramanya (1994) ได้อธิบายว่า Rating curve คือ กราฟแสดงความสัมพันธ์ระหว่างระดับน้ำและอัตราการไหลที่ได้จากการสำรวจในสนามดังแสดงในภาพที่ 1 การหาความสัมพันธ์ของค่าทั้งสองในกราฟ ทำได้โดย Least Square Method มีหลักการ คือ ผลรวมของระยะจากจุดที่พล็อตไปยังเส้นที่ลากเฉลี่ยยกกำลังสองมีค่าน้อยที่สุด ปัจจุบันการหาอัตราการไหลโดยใช้ Rating curve เป็นที่นิยมเนื่องจากค่าอัตราการไหลมีความยุ่งยากในการวัดรวมทั้งค่าใช้จ่ายสูง แต่ค่าระดับน้ำสามารถวัดได้ง่ายและข้อมูลมีความต่อเนื่อง



ภาพที่ 1 Rating curve

สมการ Rating curve แสดงได้ดังนี้

$$\sqrt{Q} = ah + b \quad (20)$$

$$a = \frac{(\sum \sqrt{Q_i})(\sum h_i) - n(\sum h_i \sqrt{Q_i})}{(\sum h_i)^2 - n(\sum h_i^2)} \quad (21)$$

$$b = \frac{(\sum h_i \sqrt{Q_i})(\sum h_i) - (\sum h_i^2)(\sqrt{Q_i})}{(\sum h_i)^2 - n(\sum h_i^2)} \quad (22)$$

เมื่อ Q คือ อัตราการไหล (m³/s)

h คือ ระดับน้ำ (m)

a และ b คือ ค่าคงที่

การพยากรณ์อัตราการไหล

การพยากรณ์อัตราการไหลได้ถูกต้องแม่นยำเพียงใดนั้นขึ้นอยู่กับข้อมูลทางอุทกวิทยาของกลุ่มน้ำที่ต้องการพยากรณ์ ถ้ามีข้อมูลครบถ้วน การประมาณอัตราการไหลจะทำได้ใกล้เคียงกับความเป็นจริง สำหรับการจำลองทางคณิตศาสตร์ที่ใช้ในการพยากรณ์อัตราการไหล แบ่งออกเป็น 3 ชนิด ได้แก่แบบจำลองน้ำฝนและน้ำท่า (Rainfall-Runoff Model) แบบจำลองเชิงคาดการณ์ (Stochastic Model) และแบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network Model) แสดงรายละเอียดได้ดังนี้

1. แบบจำลองน้ำฝนและน้ำท่า (Rainfall-Runoff Model)

แบบจำลองน้ำฝนและน้ำท่าเป็นแบบจำลองที่อาศัยความสัมพันธ์ระหว่างน้ำฝนและน้ำท่ามาใช้ในการพยากรณ์อัตราการไหลที่นิยมใช้ ได้แก่

1.1 NAM Model (Nedbor Afstormnings Model)

Danish Hydraulic Institute ได้พัฒนา NAM Model ขึ้น ข้อมูลที่ใช้ในการนำเข้าแบบจำลองประกอบด้วยข้อมูลน้ำฝนรายวันและปริมาณการระเหยจากผิวดิน (Potential Evaporation) ผลลัพธ์ที่ได้จาก NAM Model คือ ปริมาณน้ำท่ารายวัน (Danish Hydraulic Institute, 1990)

1.2 SSARR Model (The Streamflow Synthesis and Reservoir Regulation Model)

SSARR Model ถูกพัฒนาขึ้นโดย U.S. Corps of Engineers มีองค์ประกอบพื้นฐาน 3 ส่วน คือ 1. Generalized Watershed Model เป็นแบบจำลองสำหรับสร้างข้อมูลน้ำท่าจากข้อมูลน้ำฝน 2. River System Model เป็นแบบจำลองที่ใช้ในการเคลื่อนย้าย (Route) ปริมาณน้ำในลำน้ำจากทางต้นน้ำไปยังจุดต่างๆ และ 3. Reservoir Regulation Model เป็นแบบจำลองสำหรับการจัดการอ่างเก็บน้ำ ข้อมูลน้ำเข้าของ Generalized Watershed Model ได้แก่ ปริมาณน้ำฝน อุณหภูมิที่ทำให้หิมะละลาย พื้นที่ที่หิมะปกคลุมและค่าการระเหยน้ำ ผลลัพธ์ที่ได้จากแบบจำลอง คือ ระดับน้ำ ปริมาณอัตราการไหล กราฟแสดงความสัมพันธ์ระหว่างปริมาณน้ำกับเวลา (Hydrograph) และข้อมูลอุทกนิยามวิทยา (U.S. Army Corps of Engineers, 1991)

1.3 Tank Model

Tank Model ถูกพัฒนาขึ้นโดย Nation Research Center for Disaster Prevention หลักการของ Tank Model คือ การแทน Storage ต่างๆ ของกลุ่มน้ำด้วยแท่งขนาดต่างๆ โดยมีพารามิเตอร์หลัก ได้แก่ ค่าสัมประสิทธิ์ของจุดออก (Outlet) ของแท่งและพารามิเตอร์ที่เกี่ยวกับ Storage ข้อมูลน้ำเข้าแบบจำลองประกอบด้วยข้อมูลปริมาณน้ำฝน ข้อมูลการคายน้ำของพืชรวมกับค่าการระเหยน้ำ ค่าเฉลี่ยของปริมาณน้ำฝน และข้อมูลความชื้นในดิน ผลลัพธ์ที่ได้จาก Tank Model คือ ปริมาณน้ำท่า (Riverdeep, 2003)

2 แบบจำลองเชิงคาดการณ์ (Stochastic Model)

แบบจำลองเชิงคาดการณ์เป็นแบบจำลองที่นำหลักการทางสถิติมาใช้ในการพยากรณ์อัตราการไหล ที่นิยมใช้ ได้แก่

2.1 Hec-4 Monthly Streamflow Synthesis

แบบจำลองชนิดนี้ถูกพัฒนาโดย U.S. Army Corps of Engineers เป็นแบบจำลองถดถอยเชิงซ้อน (Multiple Regression Model) โดยใช้หลักการทางสถิติชนิดสมการ

ถดถอย (Regression Equation) ในการวิเคราะห์ความสัมพันธ์ระหว่างปริมาณน้ำท่าและปริมาณน้ำฝน เพื่อการประมาณปริมาณน้ำท่ารายเดือนของสถานีที่มีข้อมูลสั้นหรือไม่มีข้อมูลบันทึก โดยมีข้อมูลน้ำเข้าแบบจำลอง คือ ข้อมูลปริมาณน้ำฝนที่และปริมาณน้ำท่าในอดีตของสถานีที่ตั้งอยู่บริเวณใกล้เคียงกับสถานีที่ต้องการประมาณในพื้นที่ลุ่มน้ำ ผลลัพธ์ที่ได้จากแบบจำลอง ได้แก่ ปริมาณน้ำท่ารายเดือนของสถานีที่ต้องการประมาณ (U.S. Army Corps of Engineers, 1971)

2.2 Box and Jenkins Model

Box and Jenkins Model เป็นแบบจำลองที่นำพื้นฐานของฟังก์ชันสหสัมพันธ์และค่าเฉลี่ยเคลื่อนที่ เรียกว่า วิธี ARIMA มาใช้ในการพยากรณ์อัตราการไหล ซึ่งถูกพัฒนาโดย Box and Jenkins (Box et al., 1994)

3 แบบจำลองเชิงโครงข่ายประสาทเทียม (Artificial Neural Networks Model)

แนวคิดของแบบจำลองโครงข่ายประสาทเทียม คือ การนำหลักการของกระบวนการทำงานระบบประสาทของมนุษย์มาใช้ในการวิเคราะห์ปัญหา (Hebb, 1958) โดยใช้ฟังก์ชันทางคณิตศาสตร์เป็นตัวดำเนินการเพื่อหาผลลัพธ์ที่ต้องการ สำหรับการพยากรณ์อัตราการไหลโดยใช้แบบจำลองในข้างต้นที่ได้กล่าวมานั้น ต้องใช้การจำลองแบบทางอุทกวิทยา โดยพิจารณาถึงความสัมพันธ์ทางกายภาพของตัวแปรต่างๆ หรือการวิเคราะห์ทางสถิติ ข้อมูลที่ใช้ในแบบจำลองชนิดนี้ ได้แก่ข้อมูลทางอุทกวิทยาที่มีความหลากหลาย ซึ่งไม่สามารถหาได้ครบถ้วนตามที่ต้องการ จึงเป็นอุปสรรคต่อการจำลองแบบ ปัจจุบันได้มีการนำแบบจำลองโครงข่ายประสาทเทียมมาใช้ในการพยากรณ์อัตราการไหล ซึ่งเป็นที่ยอมรับในความสามารถและประสิทธิภาพของแบบจำลองชนิดนี้ โดยข้อดีของแบบจำลอง คือ การใช้ข้อมูลนำเข้า (Input Data) ที่มีตัวแปรจำนวนน้อย และผู้ใช้ไม่จำเป็นต้องทำความเข้าใจเกี่ยวกับความสัมพันธ์ทางกายภาพของตัวแปรต่างๆ ที่เกี่ยวข้อง


โครงข่ายประสาทเทียม (Artificial Neural Networks)

คอมพิวเตอร์ไม่สามารถทำงานได้เหมือนระบบประสาทของมนุษย์ จึงทำให้มีนักวิจัยได้ทำการศึกษาและพัฒนาทฤษฎีโครงข่ายประสาทเทียม (Artificial Neural Networks) ซึ่งเป็นแขนงหนึ่งของระบบปัญญาประดิษฐ์ (Artificial Neural Networks) โดยมีโครงสร้างและลักษณะการทำงานคล้ายกับระบบประสาทของมนุษย์ แนวคิดของทฤษฎีโครงข่ายประสาทเทียม ได้แก่การนำข้อดีของระบบประสาทมาใช้ในการทำงานร่วมกับความสามารถของคอมพิวเตอร์ เช่น ความสามารถในการเรียนรู้จากประสบการณ์ การจำแนกลักษณะสิ่งของที่มีคุณลักษณะใกล้เคียงกัน และการแปลความหมายของสัญลักษณ์และภาพ เป็นต้น (Hebb, 1958)

Fausett (1994) ได้อธิบายว่าโครงข่ายประสาทเทียมมีรูปแบบโครงสร้างมาจากแนวคิดของโครงสร้างในระบบประสาทมนุษย์ ซึ่งประกอบด้วยเซลล์ประสาท (Neuron) เชื่อมโยงกันจำนวน

มาก ซึ่งการเชื่อมโยงของ Neuron นี้มีลักษณะเป็นโครงข่ายที่เรียกว่า Synapse โดยแต่ละ Synapse จะมีค่า Synapse Strength ที่ไม่เท่ากัน ซึ่งใน 1 Neuron ประกอบด้วย Dendrite, Soma และ Axon โดยที่ Dendrite และ Soma ทำหน้าที่รวบรวมสัญญาณต่างๆ (Input) มาทำการประมวลผลและส่งผลลัพธ์ (Output) ออกมาทางด้าน Axon ดังแสดงในภาพที่ 2

ตัวอย่างของกระบวนการทำงานของระบบประสาทมนุษย์ เช่น เมื่อสัมผัสกับวัตถุชนิดหนึ่ง Neuron ตัวแรกจะเป็นตัวกำหนดสัญญาณว่ามีลักษณะเช่นใด โดยที่ Dendrite ทำหน้าที่รับสัญญาณผ่านเส้นใยประสาทและส่งข้อมูลมายัง Soma หลังจากนั้น Soma จึงทำการประมวลผลโดยการรวมสัญญาณและแปลงสัญญาณออกไปเป็นสัญญาณที่มีความถี่ต่างกับตอนแรก และส่งสัญญาณนี้ออกไปยัง Axon โดยที่ Axon จะส่งสัญญาณต่อไปยังเซลล์ประสาทอื่นๆ จนกระทั่งเราสามารถรับรู้ได้ว่าวัตถุนั้นคืออะไร มีลักษณะเป็นเช่นไร ถึงสิ้นสุดกระบวนการทำงาน



เซลล์ประสาทมนุษย์มีคุณสมบัติและขั้นตอนการทำงานเหมือนกันเซลล์ประสาทเทียม (Fausett,1994) โดยทั้งสองมีความสัมพันธ์ดังแสดงไว้ในตารางที่ 1 คุณสมบัติและกระบวนการทำงานของเซลล์ประสาทมนุษย์ สามารถอธิบายได้ดังนี้


1. เซลล์ประสาทสามารถรับสัญญาณ (Input) ได้จำนวนมาก
2. สัญญาณต่างๆ ถูกปรับโดยค่า Weight ที่ได้รับจาก Synapse
3. เซลล์ประสาททำการรวมค่า Weight และสัญญาณแล้วส่งผลลัพธ์ไปยัง Axon
4. ผลลัพธ์จากเซลล์ประสาทหนึ่งเซลล์ สามารถส่งไปที่เซลล์ประสาทหลายเซลล์ได้
5. Synapse Strength มีความสามารถในการเรียนรู้แบบอัตโนมัติ ดังนั้นจึงสามารถปรับได้จากประสบการณ์ในการเรียนรู้
6. การกระจายความจำของเซลล์ประสาทประกอบด้วย 2 ลักษณะ ได้แก่ Long Term Memory คือ การกระจาย Weight ที่อยู่ใน Synapse และ Short Term Memory คือ การกระจายสัญญาณที่ถูกส่งมาโดยเซลล์ประสาท

7. การส่งสัญญาณของเซลล์ประสาทจาก Synapse แบ่งเป็น 2 ลักษณะ คือ ลักษณะของการกระตุ้น (Excitatory) เป็นการทำให้สัญญาณที่ส่งผ่านเข้ามามีความถี่สูงขึ้น และลักษณะของการยับยั้ง (Inhibitory) เป็นการทำให้สัญญาณที่ส่งผ่านเข้ามามีความถี่ต่ำลง


ตารางที่ 1 ความสัมพันธ์ระหว่างเซลล์ประสาทมนุษย์กับเซลล์ประสาทเทียม

เซลล์ประสาทมนุษย์	เซลล์ประสาทเทียม
Dendrite	Input Node
Soma	Hidden Node
Axon	Output Node
Synapse	Weight

Patterson (1996) ได้กล่าวถึงขั้นตอนการทำงานของโครงข่ายประสาทเทียมว่าเมื่อข้อมูลนำเข้า (Input Data) ถูกส่งผ่านเข้าไปในชั้นแฝง (Hidden Layer) ภายในชั้นนี้จะทำหน้าที่ประมวลผลโดยการรวมข้อมูล Input กับค่า Weight และส่งผ่านฟังก์ชันแปลงค่า (Transfer Function) เพื่อให้ได้ผลลัพธ์ (Output) ออกมา ดังแสดงในภาพที่ 3 ภาพที่ 4 และสมการที่ (23)



ภาพที่ 3 Simple Artificial Neural Network



ภาพที่ 4 Schematic Diagram of a Single Neural

$$net = x_1 w_1 + x_2 w_2 + x_3 w_3 = \sum x_i w_i \quad (23)$$

เมื่อ net คือ ผลลัพธ์ที่ยังไม่ผ่านฟังก์ชันแปลงค่า

X_i คือ ข้อมูลนำเข้า (Input)

W_i คือ Weight

ฟังก์ชันแปลงค่า (Transfer Function)

Maren et al. (1990) ได้อธิบายว่า Transfer Function คือ ฟังก์ชันที่ใช้ในการแปลงผลรวมของข้อมูลนำเข้า (Input) กับค่า Weight ให้ออกมาเป็นผลลัพธ์ (Output) สามารถแบ่งออกเป็น 4 ชนิดดังนี้

1. Threshold Logic Transfer Function



$$y = 0 \text{ or } -1 \quad \text{for} \quad x \leq 0$$

$$y = 1 \quad \text{for} \quad x \geq 0$$

(24)

เมื่อ y คือ ผลลัพธ์ (Output)

x คือ ข้อมูลนำเข้า (Input)



ภาพที่ 5 Threshold Logic Function

2. Hard Limit Function



$$y = 0 \text{ or } -1 \quad \text{for} \quad x \leq -a$$

$$y = \frac{x}{2a} + \frac{1}{2} \quad \text{for} \quad -a < x < a$$

(25)

$$y = 1 \quad \text{for} \quad x = a$$

เมื่อ a คือ Slope Parameter




ภาพที่ 6 Hard Limit Function

3. Sigmoid Function

$$y = \frac{1}{1 + \exp(-ax)}$$

(26)




ภาพที่ 7 Sigmoid Function

ที่มา : Fausett(1994)

4. Radial Basis Function

$$y = \exp\left[\frac{-x^2}{a^2}\right] \quad (27)$$




ภาพที่ 8 Radial Basis Function


ประเภทของโครงข่ายประสาทเทียม

ประเภทโครงข่ายประสาทเทียมแบ่งตามโครงสร้างได้ 3 ชนิด (Maren et al.,1990) ดังนี้

1. Micro Structure

Micro Structure เป็นโครงสร้างที่มีระดับต่ำที่สุดของโครงข่ายประสาทเทียม กล่าวคือ จะมี Transfer Function ทำหน้าที่ในการแปลงผลรวมของข้อมูลนำเข้า (Input) กับค่า Weight ให้ออกมาเป็นผลลัพธ์ (Output) เท่านั้น ดังแสดงในภาพที่ 9






ภาพที่ 9 Micro Structure

2. Meso Structure

Meso Structure สามารถแบ่งตามความสัมพันธ์ของลักษณะการทำงานของโครงข่ายประสาทเทียมได้ดังนี้

2.1 Multilayered Feed-Forward Networks


ใน Multilayered Feed-Forward Networks มีลักษณะการส่งสัญญาณเข้าไปในโครงข่ายประสาทเทียมในทิศทางข้างหน้า (Feed-Forward) ดังแสดงในภาพที่ 10 โดยสามารถแบ่งชนิดของโครงข่ายประสาทเทียมลักษณะนี้ตามการประยุกต์ในการใช้งานได้คือ การจัดรูปแบบข้อมูลที่ไม่เกี่ยวข้องกัน (Heteroassociation) การจำแนกรูปแบบ (Pattern Recognition) การพยากรณ์ (Forecast) การหาความเหมาะสม (Optimization) และการประมวลผลรูปภาพ (Image Processing) ทฤษฎีที่ใช้ ได้แก่ Basic Perception , ADALINE/MADALINE , Backpropagation , Boltzmann Machine และ Functional Link Net ตามลำดับ



ภาพที่ 10 Multilayered Feed-Forward Networks

2.2 Single Layer , Laterally Connected Networks

ใน Single Layer , Laterally Connected Networks มีลักษณะการส่งสัญญาณเข้าไปในโครงข่ายประสาทเทียมในทิศทางด้านข้าง (Lateral) ซึ่งโครงข่ายจะมีเพียงชั้นเดียวเท่านั้น ดังแสดงในภาพที่ 11 โดยสามารถแบ่งชนิดของโครงข่ายประสาทเทียมลักษณะนี้ตามการประยุกต์ในการใช้งานได้คือ การจัดรูปแบบข้อมูลที่มีรูปแบบเดียวกัน (Autoassociation) และการหาความเหมาะสม (Optimization) ทฤษฎีที่ใช้ ได้แก่ Hopfield และ Brain in a Box ตามลำดับ






ภาพที่ 11 Single Layer , Laterally Connected Networks

2.3 Single Layer , Topologically Ordered Networks


ใน Single Layer , Topologically Ordered Networks มีลักษณะการส่งสัญญาณเข้าไปในโครงข่ายประสาทเทียมแบบ Vector ดังแสดงในภาพที่ 12 โดยสามารถแบ่งชนิดของโครงข่ายประสาทเทียมลักษณะนี้ตามการประยุกต์ใช้งานได้คือ การจัดรูปแบบข้อมูลที่มีรูปแบบเดียวกัน (Autoassociation) การบีบอัดข้อมูล (Data Compression) และการหาความเหมาะสม (Optimization) ทฤษฎีที่ใช้ ได้แก่ Adaptive Vector Quantization , Learning Vector Quantization และ Self-Organizing Topology Preserving Map ตามลำดับ



ภาพที่ 12 Single Layer , Topologically Ordered Networks

2.4 Bilayer Feed-Forward/Feedback Networks


ใน Bilayer Feed-Forward/Feedback Networks มีลักษณะการส่งสัญญาณเข้าไปในโครงข่ายประสาทเทียมในทิศทางข้างหน้า (Feed-Forward) และทิศทางกลับหลัง (Feedback) ซึ่งโครงข่ายจะมีเพียง 2 ชั้นเท่านั้น ดังแสดงในภาพที่ 13 โดยสามารถแบ่งชนิดของโครงข่ายประสาทเทียมลักษณะนี้ตามการประยุกต์ในการใช้งานได้คือ การจัดรูปแบบข้อมูลที่ไม่เกี่ยวข้องกัน (Heteroassociation) และการจำแนกรูปแบบ (Pattern Recognition) ทฤษฎีที่ใช้ได้แก่ Bidirectional Associative Memory และ Adaptive Resonance Theory ตามลำดับ



ภาพที่ 13 Bilayer Feed-Forward/Feedback Networks

2.5 Multilayered Cooperative/Competitive Networks


ใน Multilayered Cooperative/Competitive Networks มีลักษณะการส่งสัญญาณเข้าไปในโครงข่ายประสาทเทียมในทิศทางข้างหน้าหรือ/และข้างหลัง หรือ/และด้านข้าง ดังแสดงในภาพที่ 14 โดยสามารถแบ่งชนิดของโครงข่ายประสาทเทียมลักษณะนี้ตามการประยุกต์ใช้งานได้คือ การจำแนกรูปแบบ (Pattern Recognition) ทฤษฎีที่ใช้ ได้แก่ Competitive Learning Net , Masking Field Neocognitron และการประมวลผลรูปภาพ (Image Processing) ทฤษฎีที่ใช้ได้แก่ Bounday Contour System และ Hierarchical Scene-Structure



ภาพที่ 14 Multilayered Cooperative/Competitive Networks

3 Macro Structure

Macro Structure เป็นโครงสร้างที่รวมโครงข่ายชนิดต่างๆ เข้ามาเป็นโครงข่ายระบบเดียวกัน ดังแสดงในภาพที่ 15 ซึ่งสามารถนำไปประยุกต์ใช้ในการควบคุมระบบต่างๆ (System Control)



ภาพที่ 15 Macro Structure

การประยุกต์โครงข่ายประสาทเทียมในงาน

โครงข่ายประสาทเทียมสามารถนำมาประยุกต์ใช้งานต่างๆ ได้ดังต่อไปนี้

1. การจำแนกรูปแบบ (Pattern Recognition) เช่น การมองเห็นวัตถุและการวิเคราะห์เสียงพูด เพื่อแปลความหมาย ซึ่งได้แก่การสื่อสารผ่านเครือข่ายต่างๆ ระบบรักษาความปลอดภัยด้วยเสียงและการใช้ระบบตอบรับโทรศัพท์อัตโนมัติ เป็นต้น
2. การทำนาย (Prediction) หรือการพยากรณ์ (Forecasting) เช่น การทำนายหุ้นและการพยากรณ์อัตราการไหล เป็นต้น
3. การควบคุม (Control) เช่น การควบคุมระบบของเครื่องปรับอากาศ การควบคุมระบบเครื่องยนต์และการควบคุมหุ่นยนต์ เป็นต้น
4. หาความเหมาะสม (Optimization) เช่น การเลือกกระยะทางที่ใกล้ที่สุดในการเดินทาง เป็นต้น
5. การจัดลำดับ (Clustering) และการจัดหมู่ (Categorization)
6. การบีบอัดข้อมูล (Data Compression)
7. การจดจำตำแหน่ง (Content Addressable Memory)

ประเภทของการเรียนรู้ของโครงข่ายประสาทเทียม

การเรียนรู้ของโครงข่ายประสาทเทียมสามารถแบ่งออกได้ 2 ลักษณะ ดังนี้

1. การเรียนรู้แบบมีการสอน (Supervisor)
การเรียนรู้แบบมีการสอน (Supervisor) คือ การเรียนรู้จากข้อมูลคู่ลำดับของตัวอย่างที่มีจำนวนมากพอ โดยการนำผลลัพธ์ที่ถูกต้องใส่ไว้ในหน่วยแสดงผลของโครงข่ายประสาทเทียมโครงข่ายประสาทเทียมจะเรียนรู้จากการเปรียบเทียบผลลัพธ์ที่ถูกต้องกับผลลัพธ์ที่ได้จากการประมวลผล แล้วทำการปรับค่า Weight และค่า Bias จากค่าความผิดพลาดที่เกิดขึ้น หลังจากนั้นจึงประมวลผลใหม่ เพื่อให้ได้ผลที่ความผิดพลาดน้อยที่สุด
2. การเรียนรู้แบบไม่มีการสอน (Unsupervisor)
การเรียนรู้แบบไม่มีการสอน (Unsupervisor) คือ การเรียนรู้ด้วยตัวเอง โดยไม่จำเป็นต้องเรียนรู้ข้อมูลคู่ลำดับของตัวอย่าง ดังนั้นจึงไม่มีการเปรียบเทียบผลลัพธ์ที่ถูกต้องกับผลลัพธ์ที่ได้จากการประมวลผล ในการปรับ Weight และ Bias นำหลักเกณฑ์อื่นมาพิจารณา

โครงข่ายประสาทเทียมแบบ Backpropagation (Backpropagation Artificial Neural Networks)

Fausst (1994) ได้อธิบายว่าโครงข่ายประสาทเทียมแบบ Backpropagation จัดอยู่ในชนิด Meso Structure ซึ่งลักษณะโครงข่ายเป็นแบบ Multilayered Feed-Forward Networks ดังแสดงในภาพที่ 16 ซึ่งประกอบด้วย ชั้นรับข้อมูล (Input Layer) ชั้นแสดงผล (Output Layer) และชั้นแฝง (Hidden Layer) แสดงรายละเอียดได้ดังนี้


1. ชั้นรับข้อมูล (Input Layer)
ชั้นรับข้อมูล (Input Layer) เป็นชั้นแรกในโครงสร้างของโครงข่ายประสาทเทียม ประกอบด้วยหน่วยรับข้อมูล (Input Nodes) ทำหน้าที่รับข้อมูลเข้าสู่โครงข่ายประสาทเทียม
2. ชั้นแสดงผล (Output Layer)
ชั้นแสดงผล (Output Layer) เป็นชั้นสุดท้ายในโครงสร้างของโครงข่ายประสาทเทียม ประกอบด้วยหน่วยแสดงผล (Output Nodes) ทำหน้าที่แสดงผลลัพธ์ (Output)
3. ชั้นรับข้อมูล (Hidden Layer)
ชั้นแฝง (Hidden Layer) อยู่ระหว่างชั้นรับข้อมูลและชั้นแสดงผล ประกอบด้วยหน่วยแฝง (Hidden Nodes) ทำหน้าที่ในการรวม Input และ Weight เพื่อแปลงให้เป็นผลลัพธ์ (Output) และส่งผลลัพธ์ไปยังชั้นแสดงผล ซึ่งชั้นแฝงมีได้หลายชั้นตามความเหมาะสมของปัญหาที่นำมาวิเคราะห์

Input Layer



Hidden Layer


Output Layer



ภาพที่ 16 โครงสร้างของโครงข่ายประสาทเทียมแบบ Backpropagation

Patterson (1996) ได้อธิบายว่าโครงข่ายประสาทเทียมแบบ Backpropagation มีการเรียนรู้แบบมีการสอน (Supervisor) และมีขั้นตอนกระบวนการทำงาน คือ เมื่อข้อมูลนำเข้า (Input Data) ถูกส่งผ่านไปข้างหน้า (Forward) ตามลำดับชั้น ภายในชั้นแฝง (Hidden Layer) จะทำหน้าที่รวมข้อมูล Input กับค่า Weight และส่งผ่านฟังก์ชันแปลงค่า (Transfer Function) เพื่อประมวลผลโดยแสดงผลลัพธ์ (Output) ไว้ในชั้นแสดงผล (Output Layer) โดยผลลัพธ์ที่ได้จากการคำนวณจะถูกนำมาเปรียบเทียบกับผลลัพธ์จริง (Target Output) และทำการคำนวณค่าความคลาดเคลื่อนทั้งหมดที่เกิดขึ้น (Total Error) หลังจากนั้นจึงดำเนินขั้นตอนการคำนวณย้อนกลับ (Backward) โดยเริ่มจากการปรับค่า Weight ระหว่างชั้นแสดงผลกับชั้นแฝงชั้นสุดท้ายและย้อนกลับไปยังชั้นรับข้อมูล จากนั้นจะเริ่มขั้นตอนของการคำนวณไปข้างหน้าและการคำนวณย้อนกลับอีกครั้งจนกระทั่งค่าความคลาดเคลื่อนทั้งหมดเข้าสู่ค่าความคลาดเคลื่อนต่ำสุดที่ยอมรับได้ จึงหยุดการปรับค่า Weight ดังแสดงในภาพที่ 17

Backpropagated Errors



ภาพที่ 17 ลักษณะการทำงานของโครงข่ายประสาทเทียมแบบ Backpropagation
ที่มา : Patterson (1996)

Backpropagation Algorithm

ฟังก์ชันที่นิยมใช้ในโครงข่ายประสาทเทียมแบบ Backpropagation ได้แก่ Sigmoid function (Theodoridis and Koutroumbas, 1999) ดังแสดงในสมการที่ (26) และภาพที่ 7 วิธีการของ Backpropagation Algorithm ประกอบด้วยขั้นตอนดังนี้

1. การคำนวณไปข้างหน้า (Forward Computation)

ขั้นตอนในการคำนวณไปข้างหน้า (Forward Computation) คือ การนำข้อมูลนำเข้า (Input Data) ส่งผ่านไปข้างหน้าตามลำดับชั้น ซึ่งมีการรวมข้อมูล Input กับค่า Weight เข้าด้วยกัน และส่งผ่านฟังก์ชันแปลงค่า (Transfer Function) เพื่อทำการแปลงให้เป็นผลลัพธ์ภายในชั้นแฝง (Hidden Layer) จากนั้นจึงนำผลลัพธ์ที่ได้จากการคำนวณ (Output) มาเปรียบเทียบกับข้อมูลจริง (Target Output) และทำการคำนวณค่าความคลาดเคลื่อนทั้งหมดที่เกิดขึ้น (Total Error) ซึ่งแสดงไว้ในสมการดังต่อไปนี้

$$v_j^r = \sum_{i=1}^{n_{r-1}} w_{ji}^r y_i^{r-1} + b_j^r \quad (28)$$

$$y_j^r = f(v_j^r) \quad (29)$$

$$\varepsilon = \frac{1}{2} \sum_{j=1}^{n_r} (y_j^r \hat{y}_j)^2 \quad (30)$$

$$J = \sum_{p=1}^q \varepsilon \quad (31)$$

เมื่อ	w_{ji}^r	คือ ค่า Weight
	y_j^r	คือ ผลลัพธ์ที่ได้จากการคำนวณ (Output)
	$\hat{y}_j^r$	คือ ผลลัพธ์จริง (Target Output)
	b_j^i	คือ ค่า Bias
	n_r	คือ จำนวน Node ในชั้นที่ r
	r	คือ ชั้นที่ 1,2,3,...,L
	J	คือ ค่าความคลาดเคลื่อนทั้งหมดที่เกิดขึ้น
	p	คือ ชุดข้อมูลที่ 1,2,3,...,q

2. การคำนวณย้อนกลับ (Backward Computation)

เมื่อผลลัพธ์ที่คำนวณได้มีความคลาดเคลื่อน จะเริ่มขั้นตอนในการคำนวณย้อนกลับ ซึ่งเริ่มจากการปรับค่า Weight ระหว่างชั้นแสดงผลกับชั้นแฝงชั้นสุดท้าย และย้อนกลับไปจนถึงชั้นรับข้อมูล วิธีที่ใช้ในการปรับค่า Weight ได้แก่วิธี Steepest Descent แสดงไว้ในสมการดังต่อไปนี้

$$w_j^r(new) = w_j^r(old) + \Delta w_j^r(new) \quad (32)$$

$$\Delta w_j^r(new) = \alpha \Delta w_{ji}^r(old) - \mu \sum_{i=1}^{n_r} \delta_j^r y_i^{r-1} \quad (33)$$

ค่า δ สำหรับชั้นแสดงผล ($r = L$)

$$\delta_j^r = e_j^r f^r(v_j^r) \quad (34)$$

$$e_j^r = \sum_{j=1}^{n_r} (y_j^r - \hat{y}_j) \quad (35)$$

$$f^r(v_j^r) = a \cdot [(y_j^r)(1 - y_j^r)] \quad (36)$$

ค่า δ สำหรับชั้นแฝง ($r < L$)

$$\delta_j^r = e_j^r f^r(v_j^r) \quad (37)$$

$$e_j^r = \sum_{k=1}^{n_r+1} \delta_k^{r+1} w_{kj}^{r+1} \quad (38)$$

เมื่อ r คือ $L, L-1, L-2, \dots, 2$

α คือ ค่า Momentum Factor

μ คือ ค่า Learning Rate

a คือ ค่า Slope Parameter

สัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient)

Haan (1977) ได้อธิบายว่าสหสัมพันธ์ คือ ระดับความสัมพันธ์ระหว่างสองตัวแปร โดยใช้ค่าสัมประสิทธิ์สหสัมพันธ์เป็นเครื่องวัดระดับความสัมพันธ์ ว่ามีมากน้อยเพียงใดและมีทิศทางเป็นอย่างไร การวิเคราะห์สหสัมพันธ์เป็นการศึกษาสมบัติร่วมกันของตัวแปรทั้งสองโดยไม่คำนึงว่าตัวแปรใดเป็นตัวแปรตามหรือเป็นตัวแปรอิสระ สำหรับการประมาณค่าสัมประสิทธิ์สหสัมพันธ์ทำได้โดยการพล็อตกราฟระหว่างตัวแปรทั้งสอง ค่าการกระจายของจุดที่พล็อตเป็นตัวบอกว่าตัวแปรทั้งสองมีความสัมพันธ์กันอย่างไร ซึ่งค่าสัมประสิทธิ์สหสัมพันธ์มีค่าอยู่ระหว่าง -1 ถึง 1 และสามารถบอกขนาดและทิศทางของสหสัมพันธ์ได้ดังนี้ ถ้า r มีค่าเป็น +1 หมายถึง ตัวแปรทั้งสองมีความสัมพันธ์กันอย่างสมบูรณ์และมีทิศทางเดียวกัน กล่าวคือ ถ้าตัวแปรหนึ่งมีค่าเพิ่มขึ้น อีกตัวแปรก็จะมีค่าเพิ่มขึ้นด้วย ถ้า r มีค่าเป็น -1 หมายถึง ตัวแปรทั้งสองมีความสัมพันธ์กันอย่างสมบูรณ์ แต่มีทิศทางตรงกันข้าม กล่าวคือ ถ้าตัวแปรหนึ่งมีค่าเพิ่มขึ้น อีกตัวแปรก็จะมีค่าลดลง ถ้า r มีค่าเท่ากับศูนย์หรือใกล้เคียงศูนย์แสดงว่าตัวแปรทั้งสองไม่มีสหสัมพันธ์กันหรือมีความสัมพันธ์กันน้อยมาก

สหสัมพันธ์ในงานอุทกวิทยาเป็นความสัมพันธ์เนื่องจากสาเหตุและผลกระทบ (Cause and Effect) ระหว่างตัวแปรใดๆ แบ่งได้เป็น 2 ประเภท (Haan, 1977) ดังนี้

1. Autocorrelation

Autocorrelation คือ ความสัมพันธ์ของตัวแปรชนิดเดียวกัน ณ เวลาต่างกัน เช่น ความสัมพันธ์ของปริมาณน้ำท่ารายวันที่สถานี X ณ วันย้อนหลังและวันปัจจุบัน เป็นต้น แสดงได้ดังสมการที่ (39)

$$r(\tau) = \frac{\text{cov}[X(t), X(t + \tau)]}{\sqrt{\text{var}[X(t)]}} \quad (39)$$

เมื่อ $r(\tau)$ คือ ค่าสัมประสิทธิ์สหสัมพันธ์
 Cov คือ ค่าความแปรปรวนร่วมของตัวแปร X ณ เวลา t และ $t+\tau$
 var คือ ความแปรปรวนของตัวแปร X ณ เวลา t
 τ คือ Lag Time

2. Crosscorrelation

Crosscorrelation คือ ความสัมพันธ์ระหว่างตัวแปรต่างชนิดกัน เช่น ความสัมพันธ์ระหว่างปริมาณน้ำฝนกับปริมาณน้ำท่า ความสัมพันธ์ระหว่างปริมาณน้ำท่ากับปริมาณน้ำท่าหรือระหว่างปริมาณน้ำฝนกับปริมาณน้ำฝนของสถานีที่อยู่ในบริเวณที่ใกล้เคียงกัน เป็นต้น โดยสาเหตุพื้นฐานของการเกิดน้ำท่า ได้แก่ น้ำฝน ซึ่งปริมาณน้ำท่าที่เกิดขึ้นมีปัจจัยเนื่องจากระบวนการทางอุทกวิทยาและคุณลักษณะต่างๆ ของลุ่มน้ำ สาเหตุต่างๆ เหล่านี้ได้ส่งผลต่อความสัมพันธ์ดังกล่าว การวิเคราะห์สหสัมพันธ์ประเภทนี้แสดงได้ดังสมการที่ (40)

$$r = \frac{\sum_{i=1}^n [(X_i - \bar{X})(Y_i - \bar{Y})]}{\sqrt{[\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2]}} \quad (40)$$


เมื่อ r คือ ค่าสัมประสิทธิ์สหสัมพันธ์
 X และ Y คือ ตัวแปรที่พิจารณา
 $\bar{X}$ และ $\bar{Y}$ คือ ค่าเฉลี่ยของตัวแปรที่พิจารณา

ลุ่มน้ำยม

ลักษณะทางกายภาพ

ลุ่มน้ำยม เป็นลุ่มน้ำ 1 ใน 25 ลุ่มน้ำหลักของประเทศไทย อยู่ทางตอนเหนือของประเทศไทย มีพื้นที่ลุ่มน้ำ 23,616 ตารางกิโลเมตร หรือ 14.76 ล้านไร่ คิดเป็นพื้นที่ร้อยละ 4.58 ของประเทศ ลุ่มน้ำยมมีความยาวรวมทั้งสิ้น 735 กิโลเมตร ขอบเขตพื้นที่ลุ่มน้ำครอบคลุม 10 จังหวัด ประกอบด้วย พะเยา น่าน ลำปาง แพร่ ตาก กำแพงเพชร สุโขทัย พิษณุโลก พิจิตร และนครสวรรค์

โดยทิศเหนือเริ่มจากทิวเขาผีปันน้ำติดกับลุ่มน้ำโขง ทิศตะวันตกติดกับลุ่มน้ำวัง และลุ่มน้ำปิง ทิศตะวันออกติดกับลุ่มน้ำน่าน และทิศใต้ติดกับลุ่มน้ำปิง ในการบริหารจัดการลุ่มน้ำยม ได้แบ่งลุ่มน้ำยม ออกเป็นลุ่มน้ำสาขา จำนวน 11 สาขา ดังภาพที่ 18 และรายละเอียดตามตารางที่ 2



ภาพที่ 18 แสดงลุ่มน้ำสาขาของกลุ่มน้ำยม

ตารางที่ 2 รายชื่อ และพื้นที่รับน้ำของลุ่มน้ำสาขา ในลุ่มน้ำยม


รหัสลุ่มน้ำสาขา	ชื่อลุ่มน้ำสาขา	พื้นที่รับน้ำ (ตร.กม.)
08.02	แม่น้ำยมตอนบน	1,978
08.03	แม่น้ำควน	858
08.04	น้ำปี	636
08.05	แม่น้ำางว	1,644
08.06	แม่น้ำยมตอนกลาง	2,884
08.07	น้ำแม่คำมี	444
08.08	น้ำแม่ต้า	518
08.09	ห้วยแม่สิน	522
08.10	น้ำแม่มอก	1,333
08.11	น้ำแม่ราพัน	895
08.12	แม่น้ำยมตอนล่าง	11,906
รวมพื้นที่ลุ่มน้ำยม		23,616

และสามารถแบ่งพื้นที่ลุ่มน้ำยมออกเป็นรายจังหวัด ดังมีรายละเอียดตามตารางที่ 3

ตารางที่ 3 รายชื่อจังหวัด และพื้นที่รับน้ำในลุ่มน้ำยม

ชื่อจังหวัดในลุ่มน้ำยม	พื้นที่รับน้ำ (ตร.กม.)
พะเยา	2,543.15
น่าน	548.70
ลำปาง	2,405.15


ตาก	106.48
กำแพงเพชร	2,271.53
แพร่	6,434.86
สุโขทัย	6,187.39
อุตรดิตถ์	107.19
พิษณุโลก	1,372.44
พิจิตร	1,614.88
นครสวรรค์	24.23
รวมทุกจังหวัด	23,616



ภาพที่ 19 แสดงรูปตัดตามยาวของแม่น้ำยม

ทรัพยากรน้ำ

ลุ่มน้ำยม มีปริมาณฝนรายปีเฉลี่ยสูงสุดของกลุ่มน้ำประมาณ 1,771 มิลลิเมตร ปริมาณฝนรายปีเฉลี่ยต่ำสุดของกลุ่มน้ำประมาณ 662.7 มม. ปริมาณฝนรายปีเฉลี่ยทั้งพื้นที่ลุ่มน้ำประมาณ 1,159.2 มม. การแพร่กระจายของฝนที่ตกในลุ่มน้ำ ฤดูฝนจะอยู่ระหว่างเดือนพฤษภาคมถึงตุลาคม ปริมาณฝนที่ตกในช่วงฤดูฝน 1,037.5 มม. คิดเป็นร้อยละ 89.50 ของปริมาณฝนทั้งปี




ภาพที่ 20 แสดงปริมาณฝนรายเดือนเฉลี่ยลุ่มน้ำยม


ปริมาณน้ำฝนรายปีเฉลี่ยคิดเป็นปริมาตรน้ำประมาณ 27,394 ล้าน ลบ.ม. และเมื่อประเมินความสูญเสียต่าง ๆ รวมทั้ง การอุ้มน้ำของป่า การไหลซึมลงใต้ดิน และบางส่วนถูกนำไปใช้ตามสภาพการพัฒนาของพื้นที่ คงเหลือเป็นปริมาณน้ำท่าที่ไหลออกจากลุ่มน้ำ (Yield) ซึ่งจากการตรวจวัดและประเมินค่า พบว่า มีปริมาณน้ำท่าจุดท้ายน้ำประมาณ 3,656.6 ล้าน ลบ.ม. ต่อปี โดยปริมาณน้ำท่าส่วนใหญ่อยู่ในช่วงฤดูฝนถึงประมาณ 3,216.8 ล้าน ลบ.ม. หรือประมาณร้อยละ 87.97 ของปริมาณน้ำท่าที่ไหลออกจากลุ่มน้ำ ส่วนในช่วงฤดูแล้งมีประมาณ 439.80 ล้าน ลบ.ม. หรือประมาณร้อยละ 12.03 ของปริมาณน้ำท่าที่ไหลออกจากลุ่มน้ำเท่านั้น อัตราปริมาณน้ำท่าที่ไหลออกจากลุ่มน้ำต่อพื้นที่รับน้ำฝนคิดเป็นประมาณ 4.91 ลิตร/วินาที/ตร.กม.

ลุ่มน้ำยมมีลักษณะทางอุทกธรณีวิทยาที่ประกอบด้วยชั้นหินให้น้ำที่เป็นชั้นหินร่วนประมาณ 5,196.80 ตารางกิโลเมตร (คิดเป็นร้อยละ 22) และชั้นหินแข็งประมาณ 18,419.20 ตารางกิโลเมตร (คิดเป็นร้อยละ 78) มีปริมาณน้ำบาดาลกักเก็บรวมทั้งสิ้น 386,669.54 ล้านลูกบาศก์เมตร และปริมาณน้ำที่สามารถนำมาใช้ประโยชน์ได้ประมาณ 25,505.43 ล้านลูกบาศก์เมตรต่อปี ปัจจุบันมีการนำน้ำบาดาลขึ้นมาใช้ประโยชน์ 161.40 ล้านลูกบาศก์เมตร/ปี คงเหลือปริมาณน้ำบาดาลที่จะสามารถนำมาใช้ประโยชน์ได้อีก 25,344.03 ล้านลูกบาศก์เมตร/ปี ซึ่งแต่ละปีจะมีปริมาณน้ำฝนซึมลงสู่ชั้นน้ำบาดาลประมาณ 25,505.43 ล้านลูกบาศก์เมตร/ปี จากลักษณะและคุณสมบัติของชั้นหินที่แตกต่างกันจะทำให้อัตราให้น้ำบาดาลแตกต่างกันด้วย ซึ่งชั้นหินร่วนจะมีอัตราการให้น้ำบาดาลในเกณฑ์ค่อนข้างสูง โดยทั่วไปจะอยู่ในเกณฑ์มากกว่า 20 ลูกบาศก์เมตร/ชั่วโมง บางพื้นที่ที่สูงถึง 80 ลูกบาศก์เมตร/ชั่วโมง ส่วนในชั้นหินแข็งจะมีอัตราการให้น้ำ


บาดาลน้อยกว่าชั้นหินร่วน ซึ่งโดยทั่วไปจะอยู่ในเกณฑ์ 3-20 ลูกบาศก์เมตร/ชั่วโมง แต่บางพื้นที่ก็สามารถให้ปริมาณน้ำบาดาลได้สูงกว่า 50 ลูกบาศก์เมตร/ชั่วโมง (ข้อมูลจากกรมทรัพยากรน้ำบาดาล)



ภาพที่ 21 แสดงปริมาณ และคุณภาพน้ำบาดาลที่คาดว่าจะสามารถพัฒนาได้ของกลุ่มน้ำยม



ภาพที่ 22 แผนผังแสดงสถานีวัดน้ำท่าลำน้ำยม




ภาพที่ 23 แผนที่แสดงที่ตั้งสถานีวัดน้ำท่าและลำน้ำสาขาในลำน้ำยม

ลุ่มน้ำน่าน


ลักษณะทางกายภาพ

ลุ่มน้ำน่าน เป็นลุ่มน้ำ 1 ใน 25 ลุ่มน้ำหลักของประเทศไทย อยู่ทางตอนเหนือของประเทศไทย มีพื้นที่ลุ่มน้ำ 34,331 ตารางกิโลเมตร หรือ 21.46 ล้านไร่ คิดเป็นพื้นที่ร้อยละ 6.714 ของประเทศ ขอบเขตพื้นที่ลุ่มน้ำครอบคลุม 9 จังหวัด ประกอบด้วย จังหวัดน่าน อุตรดิตถ์ พิจิตร โลก พิษณุโลก เพชรบูรณ์ นครสวรรค์ แพร่ สุโขทัยและกำแพงเพชร มีต้นกำเนิดจากคอยภูแวในทิวเขาหลวงพระบาง พื้นที่อำเภอทุ่งช้าง อำเภอเขียงกลาง และอำเภอปัว จังหวัดน่าน ไหลผ่านพื้นที่ราบกว้างใหญ่อันอุดมสมบูรณ์ที่สำคัญในภาคเหนือ เป็นพื้นที่ราบสองฝั่งแม่น้ำน่าน รวมประมาณกว่า 3 ล้านไร่ ซึ่งเปรียบเสมือนเป็นเส้นชีวิตของเกษตรกร โดยเฉพาะอย่างยิ่งในเขตจังหวัดน่าน อุตรดิตถ์ พิจิตร โลก พิษณุโลก และ นครสวรรค์ ซึ่งประกอบอาชีพหลักด้วยการทำเกษตรกรรม และไหลไปรวมกับแม่น้ำปิงเป็นแม่น้ำเจ้าพระยา ที่จังหวัดนครสวรรค์ รวมความยาวแม่น้ำน่าน ประมาณ 780 กิโลเมตร

การบริหารจัดการลุ่มน้ำน่าน ได้แบ่งลุ่มน้ำน่าน ออกเป็น 16 ลุ่มน้ำย่อย คือ




ภาพที่ 26 แสดงปริมาณน้ำฝนรายปี




ภาพที่ 27 แสดงปริมาณน้ำฝนรายเดือน


ปริมาณน้ำฝนรายปีเฉลี่ยคิดเป็นปริมาตรน้ำประมาณ 43,709.73 ล้านลูกบาศก์เมตร และเมื่อประเมินความสูญเสียต่าง ๆ รวมทั้ง การอุ้มน้ำของป่า และการไหลซึมลงใต้ดินแล้ว คงเหลือเป็นปริมาณน้ำท่าตามธรรมชาติของกลุ่มน้ำน่านปริมาณน้ำท่าตามธรรมชาติของกลุ่มน้ำน่านเฉลี่ยรวม 13,375 ล้านลูกบาศก์เมตรต่อปี โดยเป็นปริมาณน้ำท่าเฉลี่ยในช่วงฤดูฝน 8,839 ล้านลูกบาศก์เมตร คิดเป็นร้อยละ 66.08 ของปริมาณน้ำท่ารายปีเฉลี่ย และเป็นปริมาณน้ำท่าเฉลี่ยในช่วงฤดูแล้ง 4,536 ล้านลูกบาศก์เมตร คิดเป็นร้อยละ 33.92 ของปริมาณน้ำท่ารายปีเฉลี่ย และคิดเป็นปริมาณน้ำท่ารายปีเฉลี่ยต่อพื้นที่รับน้ำฝนเท่ากับ 12.54 ลิตร/วินาที/ตร.กม.



ภาพที่ 28 ปริมาณน้ำท่ารายปีเฉลี่ยต่อพื้นที่รับน้ำฝน



ภาพที่ 29 ปริมาณน้ำท่ารายเดือนเฉลี่ยต่อพื้นที่รับน้ำฝน



ภาพที่ 30 แผนผังสถานีวัดน้ำท่า ลำน้ำน่าน

งานวิจัยที่เกี่ยวข้อง

French et al. (1992) พัฒนาโครงข่ายประสาทเทียมแบบ Back propagation เพื่อทำนายปริมาณฝน และได้ทำการเปรียบเทียบกับแบบจำลองทางคณิตศาสตร์ต่างๆ พบว่าแบบจำลองโครงข่ายประสาทเทียมมีประสิทธิภาพสูงที่สุด

Siang (1992) ทำนายคุณภาพน้ำรายเดือนและอัตราการไหลรายเดือน ด้วยกรณีศึกษาของแม่น้ำโขง ประเทศลาว โดยใช้แบบจำลองโครงข่ายประสาทเทียมแบบ Back propagation และแบบจำลอง Box and Jenkins พบว่าแบบจำลองโครงข่ายประสาทเทียมให้ประสิทธิภาพสูงกว่าแบบจำลอง Box and Jenkins

วัชร (2538) พยากรณ์ปริมาณน้ำในลุ่มน้ำอุตะเกา โดยการประยุกต์ใช้แบบจำลองคณิตศาสตร์ MIKE 11 เพื่อการพยากรณ์และเตือนภัยน้ำท่วม ณ สถานีหาดใหญ่ พบว่าปริมาณน้ำท่ารายวันจากการพยากรณ์ของแบบจำลอง ให้ค่าใกล้เคียงกับปริมาณน้ำท่าจากการสำรวจ

Hsu et al. (1995) พัฒนาโครงข่ายประสาทเทียม เพื่อจำลองการเกิดน้ำฝนและน้ำท่า และได้ทำการเปรียบเทียบกับแบบจำลองทางคณิตศาสตร์อื่น ๆ พบว่าแบบจำลองโครงข่ายประสาทเทียมมีประสิทธิภาพสูงที่สุด

Nam (1997) ใช้แบบจำลองโครงข่ายประสาทเทียมแบบ Back propagation พยากรณ์อัตราการไหลรายเดือนด้วยกรณีศึกษาของ Black River Basin ประเทศเวียดนาม ผลการสอบพบว่าการพยากรณ์อัตราการไหลของแบบจำลองมีประสิทธิภาพสูง

Achela et al. (1998) ได้พยากรณ์ปริมาณน้ำท่าด้วยแบบจำลองโครงข่ายประสาทเทียมแบบ Back propagation ชนิดของฟังก์ชันที่ใช้ในแบบจำลอง ได้แก่ Radial Basis Function และได้ใช้วิธี Orthogonal Least Squares ในการคัดเลือกข้อมูลนำเข้าแบบจำลอง ซึ่งเป็นวิธีการวิเคราะห์สหสัมพันธ์ระหว่างปริมาณน้ำท่า ณ ตำแหน่งที่ต้องการพยากรณ์กับปริมาณน้ำท่า หรือปริมาณน้ำฝน ณ ตำแหน่งต่างๆ ผลทดสอบพบว่า การพยากรณ์ปริมาณน้ำท่าด้วยแบบจำลองดังกล่าว มีความถูกต้องใกล้เคียงกับความจริง

Campolo et al. (1999) พัฒนาโครงข่ายประสาทเทียมในการวิเคราะห์ และทำนายระดับน้ำท่วมของแม่น้ำ Taghamento ประเทศอิตาลีในช่วงเวลาฝนตกหนัก พบว่าผลการทำนายมีประสิทธิภาพสูง

Win (1999) ทำการพยากรณ์น้ำท่วมรายวัน ของแม่น้ำประแสโดยใช้แบบจำลองโครงข่ายประสาทเทียมแบบ Back propagation ผลการทดสอบพบว่าการพยากรณ์น้ำท่วมมีประสิทธิภาพ

กิตติพงษ์ (2542) ใช้สมการ Time series ในการทำนายอัตราการไหลรายวัน และทำการทดสอบด้วยกรณีศึกษาของแม่น้ำน่าน โดยใช้หลักการของ Least Square Method ในการกำหนดสมการ ผลการทำสอบพบว่า การทำนายอัตราการไหลมีความน่าเชื่อถือในเกณฑ์ที่ยอมรับได้

เสรี (2543) ได้พัฒนาโครงข่ายประสาทเทียมในการพยากรณ์น้ำท่าแม่น้ำมูล จังหวัดอุบลราชธานี ผลการคำนวณมีความคลาดเคลื่อนเนื่องจากข้อจำกัดของข้อมูล

วริยา (2543) ใช้แบบจำลองคณิตศาสตร์ Rubicon เพื่อการพยากรณ์สภาพการเกิดน้ำท่วมของแม่น้ำบางปะกง พบว่าหลังจากมีการก่อสร้างเขื่อนทดน้ำบางปะกง ทำให้ระดับน้ำในแม่น้ำบางปะกงและลำน้ำสาขาเพิ่มขึ้นสูงกว่าก่อนทำการก่อสร้างเขื่อนเพียงเล็กน้อย และได้เสนอแนวทางในการป้องกันและบรรเทาอุทกภัย

Liong et al. (2002) ประยุกต์แบบจำลองโครงข่ายประสาทเทียม เพื่อการวางแผนป้องกันน้ำท่วมในประเทศบังคลาเทศ พบว่าระบบโครงข่ายประสาทเทียมสามารถใช้ในการเตือนภัยน้ำท่วมได้อย่างมีประสิทธิภาพ

กิตติพงษ์ และ ธีรารัต (2544) พยากรณ์อัตราการไหลรายวันของแม่น้ำชีและมูล โดยใช้แบบจำลองโครงข่ายประสาทเทียมแบบ Back propagation สำหรับการคัดเลือกข้อมูลนำเข้าได้ใช้วิธีวิเคราะห์สหสัมพันธ์ ผลการทดสอบพบว่า สามารถพยากรณ์อัตราการไหลใน 1 วันล่วงหน้า และ 3 วันล่วงหน้าได้อย่างมีประสิทธิภาพ

เสรี (2554) ใช้แบบจำลองโครงข่ายประสาทเทียมแบบ Back propagation ในการพยากรณ์ระดับน้ำของกลุ่มแม่น้ำยม จังหวัดแพร่และจังหวัดสุโขทัย ผลการทดสอบพบว่าให้ผลการพยากรณ์ที่ดีมาก ซึ่งมีประสิทธิภาพสูงกว่า 95%

เสรี และคณะ (2544) นำแบบจำลองโครงข่ายประสาทเทียมแบบ Back propagation มาใช้ในการพยากรณ์ระดับน้ำที่หาดใหญ่ ซึ่งใช้ข้อมูลในช่วงน้ำท่วมปี 2543 สำหรับขั้นตอนของกระบวนการเรียนรู้ และทำการทดสอบผลการพยากรณ์ในช่วงน้ำท่วมในปี 2531 พบว่าให้ผลการทดสอบเป็นที่น่าพอใจแสดงให้เห็นถึงประสิทธิภาพของแบบจำลอง

รสกร (2546) การใช้โครงข่ายประสาทเทียมแบบ Back propagation ในการพยากรณ์อัตราการไหลรายวัน : กรณีศึกษาแม่น้ำปราชินบุรี

อุปกรณ์และวิธีการ


อุปกรณ์

1. คอมพิวเตอร์ Pentium 4
2. ระบบปฏิบัติการ Window XP
3. โปรแกรมโครงข่ายประสาทเทียม Kunet

วิธีการ

การใช้โครงข่ายประสาทเทียมแบบ Back propagation ในการพยากรณ์อัตราการไหลรายวัน ประกอบด้วยวิธีการศึกษา 4 ขั้นตอน ดังแสดงในภาพที่ 21 ได้แก่การเตรียมข้อมูลการศึกษาทฤษฎี โครงข่ายประสาทเทียมแบบ Back propagation และพัฒนากระบวนการประยุกต์ใช้ในการพยากรณ์ อัตราการไหลรายวัน การเขียนโปรแกรมคอมพิวเตอร์พยากรณ์อัตราการไหล โดยหลักการของ โครงข่ายประสาทเทียมแบบ Back propagation และการทดสอบกระบวนการพยากรณ์อัตราการไหลรายวัน ซึ่งมีรายละเอียดดังต่อไปนี้


1. การเตรียมข้อมูล
 - 1.1 เตรียมข้อมูลปริมาณน้ำท่ารายวันของสถานีที่อยู่ในพื้นที่ศึกษา เพื่อใช้ในการ คัดเลือกข้อมูลนำเข้า
 - 1.2 ทำการคัดเลือกข้อมูลของสถานีวัดปริมาณน้ำท่าที่มีอิทธิพลต่ออัตราการไหลที่ ต้องการพยากรณ์ เพื่อใช้เป็นข้อมูลนำเข้า ด้วยวิธีวิเคราะห์สหสัมพันธ์ระหว่าง 2 ตัวแปรใดๆ ซึ่งได้แก่ ปริมาณน้ำท่ารายวัน ปัจจุบันของสถานีที่ต้องการพยากรณ์กับปริมาณน้ำท่ารายวันของสถานีต่างๆ ในวัน ย้อนหลัง
 - 1.3 เตรียมข้อมูลปริมาณน้ำท่ารายวัน เพื่อใช้เป็นข้อมูลนำเข้า (Input Data) ใน กระบวนการเรียนรู้ (Training Process) จำนวน 5 ปี ระหว่างปี พ.ศ. 2539 ถึง พ.ศ. 2543 (ลำนํ้ายม) จำนวน 7 ปี ระหว่างปี พ.ศ. 2537 ถึง พ.ศ. 2543 (ลำนํ้าน่าน) และกระบวนการการทดสอบ (Testing Process) จำนวน 2 ปี ระหว่างปี พ.ศ. 2544 ถึง พ.ศ. 2545 (ลำนํ้ายมและน่าน) โดยใช้ข้อมูลในช่วงฤดูฝน ระหว่างเดือน กรกฎาคม ถึงเดือนกันยายน



ภาพที่ 32 แผนผังวิธีการศึกษา

2. ศึกษาทฤษฎีโครงข่ายประสาทเทียมแบบ Back propagation และพัฒนากระบวนการประยุกต์ใช้ในการพยากรณ์อัตราการไหลรายวัน

โครงข่ายประสาทเทียม (EI) ดังแสดงในสมการที่ (40) และทำการบันทึก ค่า Weight และค่า Bias เพื่อนำไปใช้ในกระบวนการทดสอบ



ภาพที่ 33 ขั้นตอนกระบวนการเรียนรู้ (Training Procedure)

$$EI = \frac{SST - SSE}{SST} \quad (40)$$

$$SST = \sum_{i=1}^n (T_i - \bar{T})^2 \quad (41)$$

$$\bar{T} = \frac{1}{n} \sum_{i=1}^n T_i \quad (42)$$

$$SSE = \sum_{i=1}^n (T_i - O_i)^2 \quad (43)$$


เมื่อ	SST	คือ	ผลรวมของค่าเบี่ยงเบนของอัตราการไหลรายวัน
	SSE	คือ	ผลรวมของความผิดพลาดยกกำลังสอง
	T_i	คือ	อัตราการไหลรายวันที่ได้จากการวัดของข้อมูลชุดที่ i
	$\bar{T}$	คือ	อัตราการไหลรายวันที่ได้จากการวัดเฉลี่ย
	O_i	คือ	อัตราการไหลรายวันที่ได้จากการคำนวณของข้อมูลชุดที่ i
	n	คือ	จำนวนข้อมูลทั้งหมด


3.2.2

กระบวนการทดสอบ (Testing Process)

การนำค่า Weight และค่า Bias และค่าพารามิเตอร์ต่างๆ ที่สรุปได้จากกระบวนการเรียนรู้ เพื่อตรวจสอบประสิทธิภาพของโครงข่ายประสาทเทียมก่อน การนำไปใช้ในการพยากรณ์อัตราการไหลในงานจริง

กระบวนการทดสอบเป็นการคำนวณไปข้างหน้าเพียงอย่างเดียว (Forward Computation) โดยไม่มีการคำนวณย้อนกลับ (Backward Computation) ที่ใช้ในการปรับค่า Weight และค่า Bias ขั้นตอนกระบวนการทดสอบแสดงได้ดังภาพที่ 34 โดยเริ่มจากการนำค่า Weight และค่า Bias และค่าพารามิเตอร์ต่างๆ ที่สรุปได้จากกระบวนการเรียนรู้มาใช้ในการคำนวณไปข้างหน้า ผลลัพธ์ที่ได้จากกระบวนการทดสอบ คือ อัตราการไหลรายวันและค่าประสิทธิภาพของโครงข่ายประสาทเทียม (EI)





ภาพที่ 34 ขั้นตอนในกระบวนการทดสอบ (Testing Procedure)

ผลและวิจารณ์

ผลการศึกษาการพยากรณ์ปริมาณน้ำท่าในลำน้ำยม และลำน้ำน่านโดยใช้โปรแกรมโครงข่ายประสาทเทียม KUnet ณ สถานีวัดน้ำท่า Y.1 ในลำน้ำยม และสถานีวัดน้ำท่า N.1 ในลำน้ำน่านประกอบด้วย

1. ผลการวิเคราะห์ข้อมูล
2. โปรแกรม KUnet
3. การทดสอบกระบวนการพยากรณ์อัตราการไหลราย ซึ่งประกอบด้วย

ผลการวิเคราะห์ข้อมูล


การวิเคราะห์ข้อมูลใช้วิธีวิเคราะห์สหสัมพันธ์ระหว่างข้อมูลปริมาณน้ำท่ารายวัน ในวันปัจจุบัน (t) ของสถานีที่ต้องการพยากรณ์กับข้อมูลปริมาณน้ำท่ารายวัน ของสถานีต่างๆ ในวันย้อนหลัง ($t-n$) เพื่อการคัดเลือกข้อมูลนำเข้า (Input Data) แบ่งการวิเคราะห์เป็น 2 ลักษณะ ได้แก่ การวิเคราะห์สหสัมพันธ์แบบ Auto-correlation คือ การหาความสัมพันธ์ที่เกิดขึ้นในตัวเอง และการวิเคราะห์ความสัมพันธ์แบบ Cross-correlation คือ การหาความสัมพันธ์ระหว่างสถานีวัดปริมาณน้ำที่ตำแหน่งต่างๆ แสดงไว้ในตารางที่ 4 และภาพที่ 35 และ 36 โดยกราฟเส้นบนสุดเป็นการวิเคราะห์สหสัมพันธ์แบบ Auto-correlation นอกนั้นเป็นการวิเคราะห์สหสัมพันธ์แบบ Cross-correlation จากตารางและภาพดังกล่าวเห็นได้ว่า ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างปริมาณน้ำท่ารายวันของสถานี Y.1 ในลำน้อยม ณ วันปัจจุบันกับปริมาณน้ำท่ารายวันของสถานีในพื้นที่ลุ่มน้ำยม ณ เวลา 7 วันย้อนหลัง มีค่าอยู่ระหว่าง 0.2 ถึง 1 โดยสถานีวัดปริมาณน้ำท่าที่มีอิทธิพลต่อสถานี Y.1 มากที่สุดและน้อยที่สุด ได้แก่ สถานี Y.20 และ สถานี Y.24 ตามลำดับและค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างปริมาณน้ำท่ารายวันของสถานี N.1 ในลำน่าน ณ วันปัจจุบันกับปริมาณน้ำท่ารายวันของสถานีในพื้นที่ลุ่มน่าน ณ เวลา 7 วันย้อนหลังมีค่าอยู่ระหว่าง 0.1 ถึง 1 โดยสถานีวัดปริมาณน้ำท่าที่มีอิทธิพลต่อสถานี N.1 มากที่สุดและน้อยที่สุด ได้แก่ สถานี N.64 และ สถานี N.49 ตามลำดับ

จากการวิเคราะห์สหสัมพันธ์แบบ Auto-correlation และ Cross-correlation ระหว่างสถานีวัดน้ำปริมาณน้ำ แสดงให้เห็นว่ามีค่าสัมประสิทธิ์สหสัมพันธ์ (r) ลดลงตามจำนวนวันที่เพิ่มขึ้นโดยข้อมูลของสถานีตัวเองหรือสถานีต่างๆ ณ เวลา 1 วันย้อนหลัง ($t-1$) และ 2 วันย้อนหลัง ($t-2$) มีสหสัมพันธ์กับข้อมูลของสถานี Y.1 (ในลำน้อยม) ที่วันปัจจุบันมากที่สุด ซึ่งข้อมูลปริมาณน้ำท่าของสถานีตัวเองให้ค่าสัมประสิทธิ์สหสัมพันธ์มากที่สุด คือ 0.87 และ 0.72 ตามลำดับ รองลงมา ได้แก่ ข้อมูลของสถานี Y.24 ($r_{t-1} = 0.453$ และ $r_{t-2} = 0.366$) สถานี Y.20 ($r_{t-1} = 0.66$ และ $r_{t-2} = 0.542$) ตามลำดับ และข้อมูลของสถานี N.1 (ลำน่าน) ที่วันปัจจุบันมากที่สุด ซึ่งข้อมูลน้ำท่าของสถานีตัวเองให้ค่าสัมประสิทธิ์สหสัมพันธ์มากที่สุด คือ 0.78 และ 0.61 ตามลำดับ รองลงมา ได้แก่ ข้อมูลของสถานี N.64 ($r_{t-1} = 0.72$ และ $r_{t-2} = 0.57$) สถานี N.49 ($r_{t-1} = 0.33$ และ $r_{t-2} = 0.31$)


ตามลำดับ จากการวิเคราะห์ดังกล่าวได้กำหนดค่าสัมประสิทธิ์สหสัมพันธ์ มากกว่า 0.3 มาใช้เป็นข้อมูลนำเข้า ซึ่งสถานีที่นำมาใช้เป็นข้อมูลนำเข้าในการวิเคราะห์อยู่ในหลักเกณฑ์ที่กำหนด ตามตารางที่ 4

ตารางที่ 4 ผลการวิเคราะห์สหสัมพันธ์

ค่าสัมประสิทธิ์สหสัมพันธ์ ณ วันต่างๆ (r_{t-n})								
Lag Time	t	t-1	t-2	t-3	t-4	t-5	t-6	t-7
สถานี								
ลำน้ำยม								
Y.1	1.00	0.87	0.72	0.61	0.52	0.46	0.41	0.39
Y.24	0.59	0.45	0.37	0.31	0.26	0.25	0.22	0.19
Y.20	0.85	0.66	0.54	0.48	0.42	0.37	0.35	0.33
ลำน้ำน่าน								
N.1	1.00	0.78	0.62	0.51	0.43	0.38	0.36	0.36
N.64	0.98	0.73	0.58	0.49	0.41	0.37	0.34	0.34
N.49	0.61	0.38	0.31	0.22	0.16	0.15	0.14	0.14



ภาพที่ 35 กราฟแสดงค่าสัมประสิทธิ์สหสัมพันธ์ของสถานีวัดน้ำในพื้นที่ลุ่มน้ำยมที่มีอิทธิพลต่อสถานี Y.1 ในวันย้อนหลัง (Lag Time) ต่างๆ



ภาพที่ 36 กราฟแสดงค่าสัมประสิทธิ์สหสัมพันธ์ของสถานีวัดน้ำในพื้นที่ลุ่มน้ำยมที่มีอิทธิพลต่อสถานี N.1 ในวันย้อนหลัง (Lag Time) ต่างๆ


โปรแกรม KUnet

โปรแกรม KUnet เป็นโปรแกรมคอมพิวเตอร์ภาษา Visual Basic ใช้สำหรับการพยากรณ์อัตราการไหลด้วยหลักการของโครงข่ายประสาทเทียมแบบ Backpropagation แสดงรายละเอียดได้ดังนี้

ส่วนประกอบของโปรแกรม KUnet


ส่วนประกอบต่างๆ ของโปรแกรม KUnet แสดงได้ดังภาพที่ 37 แบ่งออกเป็น 4 ส่วนสำคัญอธิบายได้ดังนี้

1. Network Property (1) ใช้ในการกำหนดคุณสมบัติของโครงข่ายประสาทเทียม ได้แก่การออกแบบโครงสร้างของโครงข่ายประสาทเทียม (Design) การกำหนดค่าพารามิเตอร์ต่างๆ (Parameter) การนำข้อมูลเข้าสู่โปรแกรม (Import) การตรวจสอบข้อมูล (Data) การกำหนดชื่อไฟล์และระบุที่อยู่ของไฟล์ (KUnet File)




ภาพที่ 37 ส่วนประกอบของโปรแกรม KUnet

2. Run Network (2) ใช้สำหรับประมวลผลโปรแกรม ประกอบด้วยกระบวนการเรียนรู้ (Training Process) กระบวนการทดสอบ (Testing Process) และกระบวนการพยากรณ์ (Forecasting Process) โดยมีขั้นตอนกระบวนการประมวลผล ดังแสดงในภาพที่ 38 ถึงภาพที่ 40



ภาพที่ 38 ขั้นตอนกระบวนการเรียนรู้ของโปรแกรม KUNet (Training Procedure in KUNet Program)




ภาพที่ 38 (ต่อ)

เมื่อ E คือ ค่าความคลาดเคลื่อนทั้งหมดที่กำหนดเพื่อใช้ในการหยุดโปรแกรม


I คือ จำนวนรอบที่กำหนดเพื่อใช้ในการหยุดโปรแกรม

3. View Target and Calculation ใช้สำหรับแสดงผลการพยากรณ์อัตราการใช้ไฟฟ้าเป็นกราฟเปรียบเทียบระหว่างอัตราการใช้ไฟฟ้าที่ได้จากการวัดจริงกับอัตราการใช้ไฟฟ้าที่ได้อัตราการใช้ไฟฟ้าที่คำนวณ

4. Rating Curve ใช้ในการแปลงอัตราการใช้ไฟฟ้าให้เป็นระดับน้ำ



ภาพที่ 39 ขั้นตอนกระบวนการทดสอบของโปรแกรม KUnet (Training Procedure in KUnet Program)



ภาพที่ 40 ขั้นตอนกระบวนการพยากรณ์ของโปรแกรม KUnet (Training Procedure in KUnet Program)

การใช้งานโปรแกรม KUnet

เมื่อทำการเปิดโปรแกรม KUnet จะปรากฏหน้าจอแนะนำโปรแกรม ดังแสดงในภาพที่ 41 และหน้าจอหลักของโปรแกรม KUnet แสดงไว้ในภาพที่ 37 ซึ่งมีรายละเอียดการใช้งานดังนี้



ภาพที่ 41 หน้าจอแนะนำโปรแกรม KUnet

1. การกำหนดคุณสมบัติโครงข่ายประสาทเทียม ประกอบด้วยขั้นตอนดังนี้
 - 1.1 ตั้งชื่อไฟล์ข้อมูลที่ช่อง KUnet File แล้วทำการบันทึกโดยกดปุ่ม Save
 - 1.2 กดปุ่ม Design เพื่อใช้ในการออกแบบลักษณะโครงสร้างของโครงข่าย ซึ่งได้แก่จำนวนชั้น (Number of Network Layes) จำนวนหน่วยรับข้อมูล (Number of Input Nodes) และจำนวนหน่วยแฝงในแต่ละชั้น (Hidden Layer Nodes) โดยสามารถกำหนดชั้นแฝงได้มากที่สุดเท่ากับ 8 ชั้น ดังแสดงในภาพที่ 42 เมื่อกดปุ่ม Apply and Close จะกลับเข้าสู่หน้าจอหลักสำหรับการดูแลลักษณะโครงสร้างของโครงข่ายประสาทเทียม ที่ได้ทำการออกแบบไว้ดังแสดงในภาพที่ 43 ทำได้โดยการกดปุ่ม View Network และ View ตามลำดับ

KUnet-Network Design

Network Description: 4-3-4-2-1


Network Property

Number of Network Layers	5	Hidden Layer 1 Nodes	3
Number of Input Nodes	4	Hidden Layer 2 Nodes	4
Number of Output Node	1	Hidden Layer 3 Nodes	2
		Hidden Layer 4 Nodes	
		Hidden Layer 5 Nodes	
		Hidden Layer 6 Nodes	
		Hidden Layer 7 Nodes	
		Hidden Layer 8 Nodes	

View Network

Apply and Close

ภาพที่ 42 หน้าจอที่ใช้ในการกำหนดโครงสร้างของโครงข่ายประสาทเทียม



ภาพที่ 43 หน้าจอที่ใช้ดูลักษณะโครงสร้างของโครงข่ายประสาทเทียม

1.3 กลุ่ม Parameter เพื่อกำหนดค่า พารามิเตอร์ต่าง ๆ ได้แก่

1.3.1 ค่า Slope Parameter ใช้ในการปรับความชันของ Sigmoid Function


1.3.2 ค่า Momentum Factor ใช้ในการปรับ Weight และค่า Bias

1.3.3 จำนวนรอบในการเรียนรู้ (Iterations) ใช้ในการหยุดกระบวนการเรียนรู้

1.3.4 ค่าความคลาดเคลื่อนทั้งหมดที่ใช้ในการหยุดกระบวนการเรียนรู้

(Quit at Total Error)

หลักเกณฑ์ในการกำหนดค่า Slope Parameter และค่า Momentum Factor คือ มีค่าอยู่ระหว่าง 0.1 ถึง 1 เมื่อทำการกำหนดพารามิเตอร์ต่างๆ เสร็จให้กดปุ่ม OK เพื่อตกลงหรือ กดปุ่ม Cancel เพื่อยกเลิกสำหรับปุ่ม Default คือ ค่าพารามิเตอร์ที่โปรแกรมแนะนำให้ใช้ได้แก่ค่า Slope Parameter ค่า Momentum Factor จำนวนรอบในการเรียนรู้และค่าความคลาดเคลื่อน ทั้งหมดที่ใช้ในการหยุดกระบวนการเรียนรู้ มีค่าเท่ากับ 0.1 0.9 10,000 และ 0.05 ตามลำดับ ดัง แสดงในภาพที่ 44



ภาพที่ 44 หน้าจอที่ใช้ในการกำหนดค่าพารามิเตอร์

1.4 กดปุ่ม Import เพื่อนำ Input Data เข้าสู่โปรแกรมโดยโปรแกรมจะถามว่า ต้องการนำเข้าข้อมูลจาก MS-Excel หรือไม่ซึ่งสามารถเลือกตอบได้ดังนี้


1.4.1 ถ้าตอบ Yes หลังจากนั้นให้ทำตามขั้นตอนดังนี้ กำหนดบรรทัดเริ่มต้นของข้อมูลที่ใช้ในกระบวนการทดสอบเลือกไฟล์ Excel ที่ต้องการ และกลับเข้าสู่หน้าจอหลักโดยไฟล์ Excel ที่เลือกใช้ต้องมีการจัดรูปแบบของข้อมูลใน Column แรกจนถึง Column ก่อนสุดท้ายเป็น Input Node ดังแสดงในภาพที่ 45

	A	B	C	D	E	F	G	H
1	N.1(t)	N.1(t-1)	N.49(t)	N.49(t-1)	N.1(t+1)			
2	111	103.8	10.6	16.12	111			
3	113.4	111	8.8	10.6	113.4			
4	89.1	113.4	8.35	8.8	89.1			
5	77	89.1	7	8.35	77			
6	77	77	6.68	7	77			
7	103.8	77	18.99	6.68	103.8			
8	125.6	103.8	9.7	18.99	125.6			
9	112.2	125.6	11.5	9.7	112.2			
10	105	112.2	27.98	11.5	105			
11	124.3	105	27	27.98	124.3			
12	174.6	124.3	24.33	27	174.6			
13	128.2	174.6	17.44	24.33	128.2			
14	103.8	128.2	14.14	17.44	103.8			
15	135.2	103.8	41.12	14.14	135.2			
16	166.5	135.2	37.88	41.12	166.5			
17	169.6	166.5	42.2	37.88	169.6			
18	288	169.6	130.9	42.2	288			
19	610.5	288	66	130.9	610.5			
20	544	610.5	127.5	66	544			
21	452.8	544	59.5	127.5	452.8			
22	298	452.8	37.88	59.5	298			
23	225.5	298	28.96	37.88	225.5			


ภาพที่ 45 การจัดรูปแบบข้อมูลนำเข้าโปรแกรมในไฟล์ Excel

1.4.2 ถ้าตอบ No จะปรากฏหน้าจอแสดงในภาพที่ 46 ซึ่งในการนำเข้าจากไฟล์ข้อมูลปริมาณน้ำท่าของกรมชลประทาน โดยมีขั้นตอนการนำเข้าดังนี้ เลือกไฟล์ที่ต้องการกดปุ่ม View List เพื่อแสดงรายชื่อสถานที่ที่มีอยู่ในไฟล์ข้อมูล ทำการเลือกสถานีน้ำท่าที่ต้องการทำนาย (Output Node) และสถานีน้ำท่าที่ใช้ในการทำนาย (Input Node) กำหนดปีที่ใช้ในการเรียนรู้ ปีที่ใช้ในการทดสอบ ปีที่ไม่มีข้อมูล Lag Time และเลือกเดือนที่ใช้ในการทดสอบ ทำการบันทึกโดยกดปุ่ม Write Pat File และกดปุ่ม Close เพื่อกลับสู่หน้าจอหลัก

1.5 กดปุ่ม Data แล้วกดปุ่ม View ดังแสดงในภาพที่ 47 เพื่อใช้ในการเปลี่ยนแปลงข้อมูลหรือตรวจสอบข้อมูล โดยเรียกดูได้จากข้อมูล Input Train ข้อมูล Input Test ข้อมูล Target Train และข้อมูล Target Test แล้วกดปุ่ม Save เพื่อบันทึกข้อมูลที่ได้ทำการเปลี่ยนแปลงและกดปุ่ม Close เพื่อกลับสู่หน้าจอหลัก



ภาพที่ 46 หน้าจอที่ใช้ในการนำเข้าข้อมูลจากไฟล์ข้อมูลปริมาณน้ำท่าของกรมชลประทาน



ภาพที่ 47 หน้าจอที่ใช้ในการเปลี่ยนแปลงข้อมูลหรือตรวจสอบข้อมูล

2. การประมวลผลของโปรแกรม ประกอบด้วยขั้นตอนดังนี้

2.1 กระบวนการเรียนรู้ (Training Process)

จากหน้าจอหลักให้เลือก Train Network และกดปุ่ม Run เพื่อเริ่มกระบวนการเรียนรู้ โดยโปรแกรมจะหยุดและทำการประมวลผลเมื่อค่าความคลาดเคลื่อนทั้งหมด เท่ากับค่าที่กำหนดหรือเมื่อครบตามจำนวนรอบที่กำหนด ภายหลังจากการประมวลผลเสร็จสิ้นได้แสดงค่าความคลาดเคลื่อนทั้งหมด และค่าประสิทธิภาพของโครงข่ายประสาทเทียม (EI) บนหน้าจอ ดังแสดงในภาพที่ 48

The screenshot shows the KUnet-Train Network software interface. It has a blue title bar and a toolbar with icons for file operations, training, and exiting. The main window is divided into several sections:

- Network definition:** A table with parameters for the neural network.

Network layers	5
Input node	4
Output node	1
Hidden node	9
Transfer function	Sigmoid
Training patterns	630
- Training parameter:** A table with parameters for the training process.

Max iterations	10000
Slope parameter	0.1
Momentum factor	0.8
Quit at error	0.05
Autosave	500
- Training results:** A table showing the progress and results of the training.


Iteration	1429	Estimated time	00:16:40
Percent complete	14	Elapsed time	00:00:05
Min error occurred	0.0865	Remaining time	00:14:29
Total Error	0.0865		
- Train:** A section on the right with a 'Train' button and a 'Period' table.

Period	Train
From	0
To	0
Missing	
EI	

ภาพที่ 48 หน้าจอกระบวนการเรียนรู้ของโปรแกรม KUnet

2.2 กระบวนการทดสอบ (Testing Process)


หลังจากประมวลผลของกระบวนการเรียนรู้เสร็จสิ้นให้กดปุ่ม Exit เพื่อเข้าสู่หน้าจอหลัก ถ้าต้องการทดสอบเพื่อตรวจสอบประสิทธิภาพของโครงข่ายประสาทเทียม ก่อนการนำไปใช้ในการพยากรณ์อัตราการไหลในงานจริง ให้ทำการเลือก Test Network และกดปุ่ม Run เพื่อประมวลผลโดยโปรแกรม KUnet จะทำการเรียกไฟล์ข้อมูลของค่า Weight ค่า Bias พารามิเตอร์ต่างๆ ที่ได้จากกระบวนการเรียนรู้ออกมา เพื่อใช้ในกระบวนการทดสอบ ภายหลังจากการประมวลผลเสร็จสิ้นได้แสดงค่าประสิทธิภาพของโครงข่ายประสาทเทียม (EI) บนหน้าจอ ดังแสดงในภาพที่ 49



ภาพที่ 49 หน้าจอกระบวนการทดสอบของโปรแกรม KUnet


2.3 กระบวนการพยากรณ์อัตราการไหล (Forecasting Process)

เมื่อกระบวนการทดสอบเสร็จสิ้น ถ้าต้องการนำโครงข่ายประสาทเทียมที่ได้มาใช้ในการพยากรณ์อัตราการไหล ให้เลือก Forecast จากหน้าจอหลัก แล้วใส่ Input Data และกดปุ่มทำนายน้ำท่า เพื่อพยากรณ์อัตราการไหล ดังแสดงในภาพที่ 50




ภาพที่ 50 หน้าจอที่ใช้ในการพยากรณ์อัตราการไหล

3. ผลการพยากรณ์อัตราการไหลจากโปรแกรม KUnet แสดงได้หลังจากกระบวนการเรียนรู้หรือกระบวนการทดสอบเสร็จสิ้น โดยเรียกดูได้จากการกดปุ่ม View Target บนหน้าจอหลัก แล้วเลือก View Train Data หรือ View Test Data หลังจากนั้นให้กดปุ่ม Get Data เพื่อดูผลการพยากรณ์ ซึ่งแสดงเป็นกราฟเปรียบเทียบระหว่างอัตราการไหลที่ได้จากการวัดจริง กับอัตราการไหลที่ได้จากการคำนวณ ดังแสดงในภาพที่ 51



ภาพที่ 51 หน้าจอแสดงกราฟเปรียบเทียบระหว่างอัตราการไหลที่ได้จากการคำนวณกับอัตราการไหลที่ได้จากการวัดจริง

4. การแปลงอัตราการไหลให้เป็นระดับน้ำทำได้หลังจากการนำ Rating Curve ของสถานีวัดปริมาณน้ำที่ต้องการพยากรณ์มาใส่ในโปรแกรม โดยวิธีการป้อนข้อมูลอัตราการไหล (Discharge) และระดับน้ำ (Elevation) ลงไปในโปรแกรม และเมื่อกดปุ่ม Save โปรแกรมจะแสดงกราฟ Rating Curve ออกมาบนหน้าจอ ดังแสดงในภาพที่ 52 สำหรับกรณีที่ได้ผ่านขั้นตอนของการประมวลผลในกระบวนการพยากรณ์ ค่าอัตราการไหลที่ได้จากการพยากรณ์จะปรากฏบนหน้าจอ นอกเหนือจากกรณีนี้แล้วผู้ใช้ต้องป้อนค่าอัตราการไหล ที่ต้องการแปลงด้วยตัวเอง หลังจากนั้นให้กดปุ่มคำนวณ เพื่อดูค่าระดับน้ำที่ได้จากการแปลงอัตราการไหลของโปรแกรม ตัวอย่างของกราฟ Rating Curve แสดงไว้ดังภาพผนวกที่ 1 ถึงภาพผนวกที่ 4



ภาพที่ 52 หน้าจอที่ใช้ในการแปลงอัตราการไหลให้เป็นระดับน้ำ

ผลการทดสอบกระบวนการพยากรณ์อัตราการไหลรายวัน

ผลการทดสอบกระบวนการพยากรณ์อัตราการไหลรายวันแสดงรายละเอียดได้ดังนี้

การแบ่งกรณีศึกษา

เมื่อทำการคัดเลือกข้อมูลนำเข้าในชั้นรับข้อมูล (Input Layer) ของโครงข่ายประสาทเทียม จากผลการวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์ หลังจากนั้นได้แบ่งกรณีศึกษาออกเป็น 2 กรณี ได้แก่กรณีศึกษา ก เป็นกรณีที่น่าข้อมูลปริมาณน้ำท่ารายวันของสถานี Y.1 ในลำน้ำยม และสถานี N.1 ในลำน้ำน่าน และข้อมูลปริมาณน้ำท่ารายวันของสถานีที่ถูกคัดเลือกจากการวิเคราะห์สหสัมพันธ์ ใช้เป็นข้อมูลนำเข้า เพื่อเป็นแนวทางในการวางแผนและการบริหารจัดการน้ำ รวมถึงการเตือนภัยจากสภาวะอุทกภัยที่อาจเกิดขึ้นในอนาคตได้ และกรณีศึกษา ข เป็นกรณีที่ไม่นำข้อมูลปริมาณน้ำท่ารายวันของสถานี Y.1 ในลำน้ำยมและสถานี N.1 ในลำน้ำน่าน มาใส่เป็นข้อมูลนำเข้า แต่ใช้ข้อมูลปริมาณน้ำท่ารายวันของสถานีที่ถูกคัดเลือกจากการวิเคราะห์สหสัมพันธ์มาใส่เป็นข้อมูลนำเข้าเพียงอย่างเดียว เพื่อใช้เป็นแนวทางในการวางแผนและการบริหารจัดการน้ำ ทั้ง 2 กรณี ได้ทำการพยากรณ์อัตราการไหลรายวัน ณ สถานีใน Y.1 ในลำน้ำยมและสถานี N.1 ในลำน้ำน่าน ดังนั้นจึงมีผลลัพธ์ที่หน่วยแสดงผล (Output Node) 1 ตัวแปร คือ ข้อมูลปริมาณน้ำท่ารายวันในวันปัจจุบันของสถานี Y.1 (ลำน้ำยม) โดยทั้งกรณีศึกษา ก และกรณีศึกษา ข สามารถแบ่งกรณีย่อยได้ 2 กรณี คือ 1.Train 361 Patterns, Test 270 Patterns 2. Train 361 Patterns, Test 270 Patterns และ ข้อมูล

ปริมาณน้ำท่ารายวันในวันปัจจุบันของสถานี N.1 (ลำน้ำน่าน) ในกรณีศึกษา ก และกรณีศึกษา ข สามารถแบ่งกรณีย่อยได้ 2 กรณี คือ 1.Train 630 Patterns, Test 270 Patterns 2. Train 630 Patterns, Test 270 Patterns ดังแสดงในภาพที่ 56 และ 54 ซึ่งรายละเอียดมีดังนี้ (รายละเอียดเพิ่มเติมแสดงไว้ในตารางผนวกที่ 1 ถึงตารางผนวกที่ 12 และภาพผนวกที่ 5 ถึงภาพผนวกที่ 10)

1. กรณีศึกษา ก (ลำน้ำยม)

1.1 Train 361 Patterns, Test 270 Patterns แบ่งเป็น 3 กรณีย่อย คือ กรณีที่ 1 , 3 และ 4 ประกอบด้วยจำนวนหน่วยรับข้อมูล (Input Nodes) 4 หน่วย ซึ่งมีข้อมูลนำเข้า 4 ตัวแปร ได้แก่ ปริมาณน้ำท่ารายวัน ณ เวลา 1 วันย้อนหลัง และ 2 วันย้อนหลังของสถานี Y.1 และ Y.2 ตามลำดับ โดยทั้ง 3 กรณีมีจำนวนชั้นแฝง (Hidden Layers) ต่างกัน คือ 1 , 2 และ 3 ตามลำดับดังต่อไปนี้

1.1.1 กรณีที่ 1 มีจำนวนชั้นแฝง 1 ชั้น แบ่งเป็น 5 กรณีย่อยซึ่งมีจำนวนหน่วยในชั้นแฝง (Hidden Nodes) เพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 1.1 มี 1 หน่วย ถึงกรณีที่ 1.5 มี 5 หน่วย ตามลำดับ

1.1.2 กรณีที่ 3 มีจำนวนชั้นแฝง 2 ชั้น แบ่งเป็น 14 กรณีย่อย คือ กรณีที่ 3.1 ถึง 3.14 อธิบายได้ดังนี้

1.1.2.1 กรณีที่ 3.1 ประกอบด้วยจำนวนหน่วยในชั้นแฝง 1 หน่วย ทั้ง 2 ชั้น

1.1.2.2 กรณีที่ 3.2 ถึง กรณีที่ 3.4 ประกอบด้วยจำนวนหน่วยในชั้นแฝง ที่หนึ่ง 2 หน่วย และชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 3.2 มี 2 หน่วย ถึง กรณีที่ 3.4 มี 4 หน่วย

1.1.2.3 กรณีที่ 3.5 ถึง กรณีที่ 3.8 ประกอบด้วยจำนวนหน่วยในชั้นแฝง ที่หนึ่ง 3 หน่วย และชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 3.5 มี 3 หน่วย ถึง กรณีที่ 3.8 มี 5 หน่วย

1.1.2.4 กรณีที่ 3.9 ถึง กรณีที่ 3.12 ประกอบด้วยจำนวนหน่วยในชั้นแฝง ที่หนึ่ง 4 หน่วย และชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 3.9 มี 2 หน่วย ถึง กรณีที่ 3.12 มี 5 หน่วย

1.1.2.5 กรณีที่ 3.13 และ กรณีที่ 3.14 ประกอบด้วยจำนวนหน่วยในชั้นแฝงที่หนึ่ง 5 หน่วย และชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 3.13 มี 2 หน่วย และ กรณีที่ 3.14 มี 3 หน่วย

1.1.3 กรณีที่ 4 มีจำนวนชั้นแฝง 3 ชั้น แบ่งเป็นกรณีย่อย คือ กรณีที่ 4.1 ถึง กรณีที่ 4.17 อธิบายได้ดังนี้

1.1.3.1 กรณีที่ 4.1 ประกอบด้วยจำนวนหน่วยในชั้นแฝง 1 หน่วยทั้ง 3 ชั้น

1.1.3.2 กรณีที่ 4.2 ถึง กรณีที่ 4.5 ประกอบด้วยจำนวนหน่วยในชั้นแฝงที่หนึ่งและชั้นแฝงที่สอง 2 หน่วย โดยที่ชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 4.2 มี 2 หน่วย ถึง กรณีที่ 4.5 มี 5 หน่วย

1.1.3.3 กรณีที่ 4.6 และกรณีที่ 4.7 ประกอบด้วยจำนวนหน่วยในชั้นแฝงที่หนึ่ง 2 หน่วย และชั้นแฝงที่สอง 5 หน่วย โดยที่ชั้นแฝงที่สามเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 4.6 มี 3 หน่วย และกรณีที่ 4.7 มี 4 หน่วย

1.1.3.4 กรณีที่ 4.8 ถึง กรณีที่ 4.10 ประกอบด้วยจำนวนหน่วยในชั้นแฝงที่หนึ่ง 3 หน่วย และชั้นแฝงที่สอง 2 หน่วย โดยที่ชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 4.8 มี 2 หน่วย ถึง กรณีที่ 4.10 มี 4 หน่วย

1.1.3.5 กรณีที่ 4.11 และกรณีที่ 4.12 ประกอบด้วยจำนวนหน่วยในชั้นแฝงที่หนึ่งและชั้นแฝงที่สอง 3 หน่วย โดยที่ชั้นแฝงที่สามเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 4.11 มี 3 หน่วย และกรณีที่ 4.12 มี 4 หน่วย

1.1.3.6 กรณีที่ 4.13 ถึง กรณีที่ 4.15 ประกอบด้วยจำนวนหน่วยในชั้นแฝงที่หนึ่ง 4 หน่วย และชั้นแฝงที่สอง 2 หน่วย โดยที่ชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 4.13 มี 3 หน่วย ถึง กรณีที่ 4.15 มี 4 หน่วย

1.1.3.7 กรณีที่ 4.16 และกรณีที่ 4.17 ประกอบด้วยจำนวนหน่วยในชั้นแฝงที่หนึ่ง 4 หน่วย และชั้นแฝงที่สอง 3 หน่วย โดยที่ชั้นแฝงที่สามเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 4.16 มี 3 หน่วย และกรณีที่ 4.17 มี 4 หน่วย

1.2 Train 361 Patterns, Test 270 Patterns แบ่งเป็น 1 กรณีย่อย คือ กรณีที่ 2 อธิบายได้ดังนี้


1.2.1 กรณีที่ 2 ประกอบด้วยจำนวนหน่วยรับข้อมูล (Input Nodes) 6 หน่วย ซึ่งมีข้อมูลนำเข้า 6 ตัวแปร ได้แก่ปริมาณน้ำท่ารายวัน ณ เวลา 1 วันย้อนหลัง และ 2 วันย้อนหลังของสถานี Y.1 , Y.20 และ Y.24 ตามลำดับ มีจำนวนชั้นแฝง 1 ชั้น แบ่งเป็น 7 กรณีย่อย ซึ่งมีจำนวนหน่วยในชั้นแฝง (Hidden Nodes) เพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 2.1 มี 1 หน่วย ถึง กรณีที่ 2.7 มี 7 หน่วย ตามลำดับ

2. กรณีศึกษา ข (ลำน้ำยม)

2.1 Train 361 Patterns, Test 270 Patterns คือ กรณีที่ 5 ประกอบด้วยจำนวนหน่วยรับข้อมูล 2 หน่วย ซึ่งมีข้อมูลนำเข้า 2 ตัวแปร ได้แก่ ปริมาณน้ำท่ารายวัน ณ เวลา 1 วันย้อนหลัง และ 2 วันย้อนหลัง ของสถานี Y.20 โดยที่มีจำนวนชั้นแฝง 1 ชั้น แบ่งเป็น 7 กรณีย่อยซึ่งมีจำนวนหน่วยในชั้นแฝงเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 5.1 มี 1 หน่วย ถึง กรณีที่ 5.7 มี 10 หน่วย ตามลำดับ

2.2 Train 361 Patterns , Test 270 Patterns แบ่งเป็น 1 กรณีย่อย คือ กรณีที่ 6 อธิบายได้ดังนี้

2.2.1 กรณีที่ 6 ประกอบด้วย จำนวนหน่วยรับข้อมูล 4 หน่วย ซึ่งมีข้อมูลนำเข้า 4 ตัวแปร ได้แก่ ปริมาณน้ำท่ารายวัน ณ เวลา 1 วันย้อนหลัง และ 2 วันย้อนหลังของสถานี Y.20 และ Y.24 ตามลำดับ มีจำนวนชั้นแฝง 1 ชั้น แบ่งเป็น 6 กรณีย่อย ซึ่งมีจำนวนหน่วยในชั้นแฝงเพิ่มขึ้นสะสม กรณีละ 1 หน่วย คือ กรณีที่ 6.1 มี 1 หน่วย ถึงกรณี 6.6 มี 6 หน่วย ตามลำดับ



ภาพที่ 53 แผนผังแสดงกรณีศึกษา ก (ลำนํ้ายม)

1. กรณีศึกษา ก (ลำน้ำน่าน)

1.1 Train 630 Patterns, Test 180 Patterns แบ่งเป็น 3 กรณีย่อย คือ กรณีที่ 1 , 3 และ 4 ประกอบด้วยจำนวนหน่วยรับข้อมูล (Input Nodes) 4 หน่วย ซึ่งมีข้อมูลนำเข้า 4 ตัวแปร ได้แก่ ปริมาณน้ำท่ารายวัน ณ เวลา 1 วันย้อนหลัง และ 2 วันย้อนหลังของสถานี N.1 และ N.49 ตามลำดับ โดยทั้ง 3 กรณีมีจำนวนชั้นแฝง (Hidden Layers) ต่างกัน คือ 1 , 2 และ 3 ตามลำดับดังต่อไปนี้

1.1.1 กรณีที่ 1 มีจำนวนชั้นแฝง 1 ชั้น แบ่งเป็น 5 กรณีย่อยซึ่งมีจำนวนหน่วยในชั้นแฝง (Hidden Nodes) เพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 1.1 มี 1 หน่วย ถึงกรณีที่ 1.5 มี 5 หน่วย ตามลำดับ

1.1.2 กรณีที่ 3 มีจำนวนชั้นแฝง 2 ชั้น แบ่งเป็น 14 กรณีย่อย คือ กรณีที่ 3.1 ถึง 3.14 อธิบายได้ดังนี้

1.1.2.1 กรณีที่ 3.1 ประกอบด้วยจำนวนหน่วยในชั้นแฝง 1 หน่วย ทั้ง 2 ชั้น

1.1.2.2 กรณีที่ 3.2 ถึง กรณีที่ 3.4 ประกอบด้วยจำนวนหน่วยในชั้นแฝง ที่หนึ่ง 2 หน่วย และชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 3.2 มี 2 หน่วย ถึง กรณีที่ 3.4 มี 4 หน่วย

1.1.2.3 กรณีที่ 3.5 ถึง กรณีที่ 3.8 ประกอบด้วยจำนวนหน่วยในชั้นแฝง ที่หนึ่ง 3 หน่วย และชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 3.5 มี 3 หน่วย ถึง กรณีที่ 3.8 มี 5 หน่วย

1.1.2.4 กรณีที่ 3.9 ถึง กรณีที่ 3.12 ประกอบด้วยจำนวนหน่วยในชั้นแฝง ที่หนึ่ง 4 หน่วย และชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 3.9 มี 2 หน่วย ถึง กรณีที่ 3.12 มี 5 หน่วย

1.1.2.5 กรณีที่ 3.13 และ กรณีที่ 3.14 ประกอบด้วยจำนวนหน่วยในชั้นแฝงที่หนึ่ง 5 หน่วย และชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 3.13 มี 2 หน่วย และ กรณีที่ 3.14 มี 3 หน่วย

1.1.3 กรณีที่ 4 มีจำนวนชั้นแฝง 3 ชั้น แบ่งเป็นกรณีย่อย คือ กรณีที่ 4.1 ถึง กรณีที่ 4.17 อธิบายได้ดังนี้

1.1.3.1 กรณีที่ 4.1 ประกอบด้วยจำนวนหน่วยในชั้นแฝง 1 หน่วยทั้ง 3 ชั้น

1.1.3.2 กรณีสี่ที่ 4.2 ถึง กรณีสี่ที่ 4.5 ประกอบด้วยจำนวนหน่วยในชั้นแฝงที่หนึ่งและชั้นแฝงที่สอง 2 หน่วย โดยที่ชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีสี่ที่ 4.2 มี 2 หน่วย ถึง กรณีสี่ที่ 4.5 มี 5 หน่วย

1.1.3.3 กรณีสี่ที่ 4.6 และกรณีสี่ที่ 4.7 ประกอบด้วยจำนวนหน่วยในชั้นแฝงที่หนึ่ง 2 หน่วย และชั้นแฝงที่สอง 5 หน่วย โดยที่ชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีสี่ที่ 4.6 มี 3 หน่วย และกรณีสี่ที่ 4.7 มี 4 หน่วย

1.1.3.4 กรณีสี่ที่ 4.8 ถึง กรณีสี่ที่ 4.10 ประกอบด้วยจำนวนหน่วยในชั้นแฝงที่หนึ่ง 3 หน่วย และชั้นแฝงที่สอง 2 หน่วย โดยที่ชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีสี่ที่ 4.8 มี 2 หน่วย ถึง กรณีสี่ที่ 4.10 มี 4 หน่วย

1.1.3.5 กรณีสี่ที่ 4.11 และกรณีสี่ที่ 4.12 ประกอบด้วยจำนวนหน่วยในชั้นแฝงที่หนึ่งและชั้นแฝงที่สอง 3 หน่วย โดยที่ชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีสี่ที่ 4.11 มี 3 หน่วย และกรณีสี่ที่ 4.12 มี 4 หน่วย

1.1.3.6 กรณีสี่ที่ 4.13 ถึง กรณีสี่ที่ 4.15 ประกอบด้วยจำนวนหน่วยในชั้นแฝงที่หนึ่ง 4 หน่วย และชั้นแฝงที่สอง 2 หน่วย โดยที่ชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีสี่ที่ 4.13 มี 3 หน่วย ถึง กรณีสี่ที่ 4.15 มี 4 หน่วย

1.1.3.7 กรณีสี่ที่ 4.16 และกรณีสี่ที่ 4.17 ประกอบด้วยจำนวนหน่วยในชั้นแฝงที่หนึ่ง 4 หน่วย และชั้นแฝงที่สอง 3 หน่วย โดยที่ชั้นแฝงที่สองเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีสี่ที่ 4.16 มี 3 หน่วย และกรณีสี่ที่ 4.17 มี 4 หน่วย

1.2 Train 630 Patterns, Test 180 Patterns แบ่งเป็น 1 กรณีย่อย คือ กรณีสี่ที่ 2 อธิบายได้ดังนี้


1.2.1 กรณีสี่ที่ 2 ประกอบด้วยจำนวนหน่วยรับข้อมูล (Input Nodes) 6 หน่วย ซึ่งมีข้อมูลนำเข้า 6 ตัวแปร ได้แก่ปริมาณน้ำท่ารายวัน ณ เวลา 1 วันย้อนหลัง และ 2 วันย้อนหลังของสถานี N.1 , N.49 และ N.64 ตามลำดับ มีจำนวนชั้นแฝง 1 ชั้น แบ่งเป็น 7 กรณีย่อย ซึ่งมีจำนวนหน่วยในชั้นแฝง (Hidden Nodes) เพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีสี่ที่ 2.1 มี 1 หน่วย ถึง กรณีสี่ที่ 2.7 มี 7 หน่วย ตามลำดับ

2. กรณีศึกษา ข (ลำน้ำน่าน)

2.1 Train 630 Patterns, Test 180 Patterns คือ กรณีที่ 5 ประกอบด้วยจำนวนหน่วยรับข้อมูล 2 หน่วย ซึ่งมีข้อมูลนำเข้า 2 ตัวแปร ได้แก่ปริมาณน้ำทำรายวัน ณ เวลา 1 วันย้อนหลัง และ 2 วันย้อนหลัง ของสถานี N.64 โดยที่มีจำนวนชั้นแฝง 1 ชั้น แบ่งเป็น 7 กรณีย่อยซึ่งมีจำนวนหน่วยในชั้นแฝงเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 5.1 มี 1 หน่วย ถึง กรณีที่ 5.7 มี 7 หน่วย ตามลำดับ

2.2 Train 630 Patterns, Test 180 Patterns แบ่งเป็น 1 กรณีย่อย คือ กรณีที่ 6 อธิบายได้ดังนี้

2.2.1 กรณีที่ 6 ประกอบด้วยจำนวนหน่วยรับข้อมูล 4 หน่วย ซึ่งมีข้อมูลนำเข้า 4 ตัวแปร ได้แก่ปริมาณน้ำทำรายวัน ณ เวลา 1 วันย้อนหลัง และ 2 วันย้อนหลังของสถานี N.64 และ N.49 ตามลำดับ มีจำนวนชั้นแฝง 1 ชั้น แบ่งเป็น 6 กรณีย่อยซึ่งมีจำนวนหน่วยในชั้นแฝงเพิ่มขึ้นสะสมกรณีละ 1 หน่วย คือ กรณีที่ 6.1 มี 1 หน่วย ถึง กรณีที่ 6.6 มี 6 หน่วย ตามลำดับ



ภาพที่ 54 แผนผังแสดงกรณีศึกษา ก (ลำนำน้ำหนัก)

ผลการพยากรณ์อัตราการใช้พลังงานจากโปรแกรม KUnet

หลังจากการแบ่งกรณีศึกษา ได้ทำการพยากรณ์อัตราการใช้พลังงานด้วยกรณีศึกษาต่างๆ จากโปรแกรม KUnet โดยแบ่งออกเป็น 2 กระบวนการ คือ กระบวนการเรียนรู้และกระบวนการทดสอบ

ลำนํ้ายม

ในการทำการพยากรณ์ในลำนํ้ายมจะใช้กระบวนการเรียนรู้โดยใช้ข้อมูลนำเข้า 5 ปี (พ.ศ. 2539 ถึง พ.ศ.2543) และกระบวนการทดสอบของลำนํ้ายมใช้ข้อมูลนำเข้า 2 ปี (พ.ศ.2544 ถึง พ.ศ. 2545) ข้อมูลที่ใช้อยู่ในช่วงฤดูฝนระหว่างเดือนกรกฎาคมถึงกันยายน วิธีการปรับเทียบแบบจำลองโครงข่ายประสาทเทียมให้เหมาะสม พิจารณาได้จากความคลาดเคลื่อนทั้งหมดที่เกิดขึ้นในกระบวนการเรียนรู้ ซึ่งมีผลมาจากการกำหนดลักษณะโครงสร้างของโครงข่ายประสาทเทียมและค่าพารามิเตอร์ในกระบวนการเรียนรู้ที่เหมาะสม โดยการศึกษาในครั้งนี้ได้ทำการปรับเทียบแบบจำลองให้เหมาะสมก่อนการวิเคราะห์ประสิทธิภาพของการพยากรณ์อัตราการใช้พลังงาน (EI)


การปรับเทียบแบบจำลองได้ดำเนินการ โดยเริ่มจากการกำหนดโครงสร้างของโครงข่ายให้เหมาะสม ซึ่งมีวิธีการปรับเทียบโดยการสุ่มเลือกจำนวนหน่วยในชั้นแฝง (Hidden Nodes) ตั้งแต่ 1 หน่วยขึ้นไป หลังจากนั้นจึงทำการกำหนดค่าพารามิเตอร์ต่างๆ ให้เหมาะสม โดยเปรียบเทียบจากการเปลี่ยนค่า Slope Parameter ที่ 0.1 แล้วเพิ่มค่าขึ้นไปครั้งละ 0.1 และนำค่า Slope Parameter ที่ทำให้เกิดความคลาดเคลื่อนทั้งหมดน้อยที่สุดมาใช้ในการปรับเทียบค่า Moment Factor ต่อไป โดยวิธีการปรับเทียบค่า Moment Factor เริ่มเปลี่ยนจากค่า 0.9 แล้วลดลงไปครั้งละ 0.1 เมื่อได้ทำการปรับเทียบแบบจำลองตามขั้นตอนดังกล่าว หลังจากนั้นได้เลือกโครงข่ายประสาทเทียมที่ให้ค่าความคลาดเคลื่อนทั้งหมด (Total Error) น้อยที่สุด มาใช้ในการวิเคราะห์ค่าประสิทธิภาพของโครงข่ายประสาทเทียม (EI)

ผลการพยากรณ์อัตราการใช้พลังงานที่สถานี Y.1 ลำนํ้ายม สามารถสรุปได้ดังนี้ สำหรับกรณีศึกษา ก โครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงที่สุด ได้แก่กรณีที่ 4.11 ซึ่งมีโครงสร้างเป็น 4-3-3-3-1 (Input Nodes / Hidden Nodes / Output Nodes) โดยให้ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 97.71% และกระบวนการทดสอบเท่ากับ 97.28% ส่วนโครงข่ายประสาทเทียมให้ค่าประสิทธิภาพต่ำสุด ได้แก่กรณีที่ 3.4 ซึ่งมีโครงสร้างเป็น 4-3-2-1 โดยค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 97.69% และกระบวนการทดสอบเท่ากับ 91.04% สำหรับกรณีศึกษา ข โครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงที่สุด ได้แก่กรณีที่ 6.6 ซึ่งมีโครงสร้างเป็น 4-6-1 โดยให้ค่าประสิทธิภาพที่ได้จากกระบวนการเรียนรู้เท่ากับ 94.47% และกระบวนการทดสอบเท่ากับ

87.45% ส่วนโครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพน้อยที่สุดได้แก่กรณีที่ 5.6 ซึ่งมีโครงสร้างเป็น 2-6-1 โดยให้ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 93.39% และกระบวนการทดสอบเท่ากับ 80.01% ดังแสดงในภาพที่ 55 ผลการเปรียบเทียบประสิทธิภาพของการพยากรณ์อัตราการใช้ไฟในกรณีศึกษาต่างๆ แสดงรายละเอียดได้ดังนี้

1. ผลการเปรียบเทียบประสิทธิภาพเมื่อเปลี่ยนจำนวนหน่วยในชั้นแฝง


การเปรียบเทียบค่าประสิทธิภาพของโครงข่ายประสาทเทียมที่มีจำนวนหน่วยในชั้นแฝงต่างกัน แสดงตัวอย่างได้ดังภาพที่ 56 โดยโครงสร้างของข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงที่สุดได้แก่ กรณีที่ 2.7 (6-7-1) ซึ่งให้ค่าความผิดพลาดทั้งหมดเท่ากับ 0.050 ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 97.68% และกระบวนการทดสอบเท่ากับ 94.23% ส่วนโครงสร้างของข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพต่ำที่สุดได้แก่ กรณีที่ 2.1 (6-1-1) โดยให้ค่าความผิดพลาดทั้งหมดเท่ากับ 0.050 ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 97.68% และกระบวนการทดสอบเท่ากับ 92.80% จากภาพดังกล่าวแสดงให้เห็นว่าเมื่อทำการเพิ่มจำนวนหน่วยในชั้นแฝง (Hidden Nodes) จากหน่วยที่ 2 ขึ้นไป ส่งผลให้ค่าประสิทธิภาพของโครงข่ายประสาทเทียมใกล้เคียงกัน โดยโครงข่ายประสาทเทียมที่มีประสิทธิภาพน้อยที่สุดประกอบด้วยจำนวนหน่วยในชั้นแฝง 1 หน่วย รายละเอียดเพิ่มเติมได้แสดงไว้ในภาพผนวกที่ 11 ถึง ภาพผนวกที่ 16




ภาพที่ 55 แผนผังสรุปผลการพยากรณ์อัตราการใช้พลังงานที่สถานี Y.1 ลำน้ำยม

Case	Slope Parameter	Momentum Factor	Train		Test
			Total Error	EI	EI
2.1	0.1	0.9	0.0500	0.9768	0.9280
2.2	0.1	0.9	0.0499	0.9768	0.9331
2.3	0.1	0.9	0.0499	0.9768	0.9353
2.4	0.1	0.9	0.0500	0.9768	0.9383
2.5	0.1	0.9	0.0500	0.9768	0.9403
2.6	0.1	0.9	0.0499	0.9768	0.9413
2.7	0.1	0.9	0.0500	0.9768	0.9423

ความสัมพันธ์ระหว่าง Total Error กับ Case 2.1-2.7



ความสัมพันธ์ระหว่าง EI กับ Case 2.1-2.7



ภาพที่ 56 การเปรียบเทียบค่าประสิทธิภาพของโครงข่ายประสาทเทียม เมื่อทำการเปลี่ยนจำนวนหน่วยในชั้นแฝง (ลำนํ้ายม)

2. ผลการเปรียบเทียบประสิทธิภาพของกรณีศึกษา ก

การเปรียบเทียบโครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงสุดของกรณีศึกษา ก ที่มีจำนวนชั้นแฝง (Hidden Layer) 1 ชั้น และให้ข้อมูลปริมาณน้ำท่าของสถานี Y.1 มาเป็นข้อมูลนำเข้าแสดงไว้ในภาพที่ 57 ซึ่งได้แก่กรณีที่ 1.5 , กรณีที่ 2.7 , กรณีที่ 3.12 และกรณีที่ 4.11 โดยสามารถพล็อตกราฟแสดงความสัมพันธ์ระหว่างอัตราการไหลที่ได้จากการวัด (Q Observe) และอัตราการไหลที่ได้จากการพยากรณ์ (Q Simulate) ในกรณีดังกล่าวได้ดังภาพที่ 58 ถึงภาพที่ 61 ตามลำดับ (ในภาพ ก และภาพ ข แสดงผลการพยากรณ์อัตราการไหลที่ได้จากกระบวนการเรียนรู้ ส่วนภาพ ค และภาพ ง แสดงผลการพยากรณ์อัตราการไหลที่ได้จากกระบวนการทดสอบ)

จากภาพที่ 57 เห็นได้ว่าการเปลี่ยนจำนวนหน่วยรับข้อมูล (Input Nodes) จาก 4 หน่วย เป็น 6 หน่วย ซึ่งได้แก่กรณีที่ 1.5 และ กรณีที่ 2.7 ตามลำดับ ส่งผลให้ค่าความคลาดเคลื่อนทั้งหมดน้อยลงและค่าประสิทธิภาพของโครงข่ายประสาทเทียมสูงขึ้นซึ่งโครงสร้างของข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงสุด ได้แก่กรณีที่ 2.7 (6-7-1) โดยให้ค่าความผิดพลาดทั้งหมดเท่ากับ 0.0500 ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 97.68% และกระบวนการทดสอบเท่ากับ 94.23% โครงสร้างของข่ายประสาทเทียมที่ให้ค่าสัมประสิทธิ์ประสิทธิภาพต่ำที่สุด ได้แก่กรณีที่ 1.5 (4-5-1) โดยให้ค่าความผิดพลาดทั้งหมดเท่ากับ 0.0500 ค่าประสิทธิภาพกระบวนการเรียนรู้เท่ากับ 97.68% และกระบวนการทดสอบเท่ากับ 94.03%


3. ผลการเปรียบเทียบประสิทธิภาพเมื่อเปลี่ยนจำนวนชั้นแฝง

การเปรียบเทียบข่ายประสาทเทียม ที่ให้ค่าประสิทธิภาพสูงสุดของกรณีศึกษาที่มีจำนวนชั้นแฝงต่างกันคือ จาก 1 ชั้น ถึง 3 ชั้น ซึ่งได้แก่กรณีที่ 1.5 กรณีที่ 3.12 และกรณีที่ 4.11 ตามลำดับ แสดงไว้ในภาพที่ 62 โดยสามารถพล็อตกราฟแสดงความสัมพันธ์ระหว่างอัตราการไหลที่ได้จากการวัดและอัตราการไหลที่ได้จากการพยากรณ์ในกรณีดังกล่าว ได้ดังภาพที่ 58 ภาพที่ 60 และภาพที่ 61 ตามลำดับ จากภาพที่ 62 เห็นได้ว่าการเพิ่มจำนวนชั้นแฝง ส่งผลให้ค่าความคลาดเคลื่อนทั้งหมดที่เกิดขึ้น และค่าประสิทธิภาพของโครงข่ายประสาทเทียมจากกระบวนการเรียนรู้กับกระบวนการทดสอบใกล้เคียงกัน คือ 0.05 97% และ 95% ตามลำดับ


Case	Slope Parameter	Momentum Factor	Train		Test
			Total Error	EI	EI

1.5	0.1	0.9	0.0500	0.9768	0.9403
2.7	0.1	0.9	0.0500	0.9768	0.9423
3.1	0.9	0.1	0.0498	0.9769	0.9199
4.11	0.8	0.5	0.0494	0.9771	0.9728





ความสัมพันธ์ระหว่าง Total Error กับ Case 1.5,2.7,3.1 และ 4.11



ความสัมพันธ์ระหว่าง EI กับ Case Case 1.5,2.7,3.1 และ 4.11







ภาพที่ 57 การเปรียบเทียบโครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงที่สุดของกรณีศึกษา ก (ลำน้ำยม)



— Q observe (cms) - - - Q Simulate (cms)

— Q Simulate (cms) - - - Q observe (cms)





ภาพที่ 58 กราฟเปรียบเทียบระหว่างอัตราการไหลรายวันที่ได้จากการวัดและอัตราการไหลรายวันที่ได้จากพยากรณ์ของกรณี 1.5 (ลุ่มน้ำยม)







— Q observe (cms) - - - Q Simulate (cms)

— Q Simulate (cms) - - - Q observe (cms)

ภาพที่ 59 กราฟเปรียบเทียบระหว่างอัตราการไหลรายวันที่ได้จากการวัดและอัตราการไหลรายวันที่ได้จากพยากรณ์ของกรณี 2.7 (ลุ่มน้ำยม)




ภาพที่ 60 กราฟเปรียบเทียบระหว่างอัตราการไหลรายวันที่ได้จากการวัดและอัตราการไหลรายวันที่ได้จากพยากรณ์ของกรณี 3.12 (ลุ่มน้ำยม)




ภาพที่ 61 กราฟเปรียบเทียบระหว่างอัตราการไหลรายวันที่ได้จากการวัดและอัตราการไหลรายวันที่ได้จากพยากรณ์ของกรณี 4.11 (ลุ่มน้ำยม)

case	Slope Parameter	Momentum Factor	Train		Test
			Total Error	EI	EI
1.5	0.1	0.9	0.0500	0.9768	0.9403
3.12	0.9	0.1	0.0498	0.9769	0.9194
4.1	0.8	0.5	0.0494	0.9771	0.9728

ความสัมพันธ์ระหว่าง Total Error กับ Case 1.5,3.12 และ 4.1



ความสัมพันธ์ระหว่าง EI กับ 1.5,3.12 และ 4.1



ภาพที่ 62 การเปรียบเทียบโครงข่ายประสาทเทียมที่ให้ค่าสัมประสิทธิ์สูงสุดของกรณีศึกษาที่มี จำนวนชั้น
แฝงต่างกัน (ลำน้ำยม)

4. ผลการเปรียบเทียบประสิทธิภาพของกรณีศึกษา ข


การเปรียบเทียบโครงข่ายประสาทเทียม ที่ให้ค่าประสิทธิภาพสูงสุดที่สุดของกรณีศึกษา ข ที่ไม่ใช่ข้อมูลปริมาณน้ำท่าของสถานี Y.1 มาเป็นข้อมูลนำเข้า แสดงไว้ในภาพที่ 63 ซึ่งได้แก่กรณี 5.3 และกรณี 6.6 โดยสามารถพล็อตกราฟแสดงความสัมพันธ์ระหว่างอัตราการไหลที่ได้จากวัด (Q Observe) และอัตราการไหลที่ได้จากการพยากรณ์ (Q Simulate) ดังแสดงในภาพที่ 64 ถึง ภาพที่ 65 ตามลำดับ (ในภาพ ก และภาพ ข) แสดงผลการพยากรณ์อัตราการไหลที่ได้จากกระบวนการเรียนรู้ ส่วนภาพ ค และภาพ ง แสดงผลการพยากรณ์อัตราการไหลที่ได้จากกระบวนการทดสอบ)

จากภาพที่ 63 เห็นได้ว่าการเปลี่ยนจำนวนหน่วยรับข้อมูล (Input Nodes) จาก 2 หน่วย เป็น 4 หน่วย ซึ่งได้แก่กรณี 5.3 และกรณี 6.6 ตามลำดับส่งผลให้ค่าความคลาดเคลื่อนทั้งหมดน้อยลง และทำให้ค่าประสิทธิภาพของโครงข่ายประสาทเทียมเพิ่มขึ้น โดยโครงสร้างของข่ายประสาทเทียม ที่ให้ค่าประสิทธิภาพสูงสุด ได้กรณี 6.6 (4-6-1) ซึ่งให้ค่าความผิดพลาดทั้งหมดเท่ากับ 0.1190 ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 94.47% และกระบวนการทดสอบเท่ากับ 87.45% ส่วนโครงสร้างของข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพต่ำที่สุด ได้กรณี 5.3 (2-3-1) โดยให้ค่าความผิดพลาดทั้งหมดเท่ากับ 0.1476 ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 93.15% และกระบวนการทดสอบเท่ากับ 83.47% ส่งผลให้ค่าความคลาดเคลื่อนทั้งหมดที่เกิดขึ้นและค่าประสิทธิภาพของโครงข่ายประสาทเทียมจากกระบวนการเรียนรู้กับกระบวนการทดสอบใกล้เคียงกัน คือ ระหว่าง 0.12 ถึง 0.14 94% และ 85% ตามลำดับ


5. ผลการเปรียบเทียบประสิทธิภาพเมื่อเปลี่ยนจำนวนรอบที่ใช้ในกระบวนการเรียนรู้
- การเปรียบเทียบค่าประสิทธิภาพของโครงข่ายประสาทเทียม ที่มีจำนวนรอบที่ใช้ในกระบวนการเรียนรู้ต่างกัน แสดงตัวอย่างได้ดังภาพที่ 66 ซึ่งเห็นได้ว่าการเพิ่มจำนวนรอบที่ใช้ในกระบวนการเรียนรู้มากขึ้น ส่งผลให้ค่าความคลาดเคลื่อนทั้งหมดที่เกิดขึ้น และค่าประสิทธิภาพของโครงข่ายประสาทเทียมจากกระบวนการเรียนรู้ กับกระบวนการทดสอบใกล้เคียงกัน คือ 0.7 92% และ 89% ตามลำดับ รายละเอียดเพิ่มเติมได้แสดงไว้ในภาพผนวกที่ 17 ถึงภาพผนวกที่ 22

case	Slope Parameter	Momentum Factor	Train		Test
			Total Error	EI	EI
5.3	0.9	0.1	0.1476	0.9135	0.8347
6.6	0.9	0.1	0.1190	0.9447	0.8745





ความสัมพันธ์ระหว่าง Total Error กับ Case 5.3 และ 6.6







ความสัมพันธ์ระหว่าง EI กับ 5.3 และ 6.6



ภาพที่ 63 การเปรียบเทียบโครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงที่สุดของกรณีศึกษา ข (ลำน้ำยม)





ภาพที่ 64 กราฟเปรียบเทียบระหว่างอัตราการไหลรายวันที่ได้จากการวัดและอัตราการไหลรายวันที่ได้จากพยากรณ์ของกรณี ที่ 5.3 (ลุ่มน้ำยม)



ภาพที่ 65 กราฟเปรียบเทียบระหว่างอัตราการไหลรายวันที่ได้จากการวัดและอัตราการไหลรายวันที่ได้จากพยากรณ์ของกรณี 6.4 (ลุ่มน้ำยม)


Case 6.4			
Iteration	Train		Test
	Total Error	EI	EI
5000	0.1518	0.9295	0.8422
10000	0.1190	0.9447	0.9845
15000	0.1106	0.9486	0.8990
20000	0.1065	0.9506	0.8498



ภาพที่ 66 การเปรียบเทียบค่าประสิทธิภาพของโครงข่ายประสาทเทียมเมื่อทำการเปลี่ยนจำนวน รอบที่ใช้ในกระบวนการเรียนรู้ (ลำนํ้ายม)

6. ผลการเปรียบเทียบประสิทธิภาพเมื่อเปลี่ยนวันที่ทำการพยากรณ์

จากการศึกษาทั้ง 6 กรณี เห็นได้ว่าโครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงที่สุด ได้กรณีที่ 4.11 ซึ่งมีโครงสร้างเป็น 4-3-3-3-1 จึงได้เลือกนำมาใช้ในการทดสอบเพื่อแสดงว่าโครงข่ายประสาทเทียม สามารถพยากรณ์อัตราการไหลได้อย่างมีประสิทธิภาพ ผลการศึกษาแสดงได้ดังภาพที่ 67 ซึ่งเป็นกราฟเทียบประสิทธิภาพของโครงข่ายประสาทเทียมเมื่อเพิ่มจำนวนวันที่ใช้ในการพยากรณ์ (Lag Time) จาก 1 วันล่วงหน้า ถึง 5 วันล่วงหน้า โดยให้ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 97.71% , 90.89%, 80.85%, 70.35% และ 61.15% ตามลำดับและกระบวนการทดสอบเท่ากับ 97.28% , 92.64%, 87.56%, 82.73% และ 75.34% ตามลำดับ จากการศึกษาดังกล่าวเห็นได้ว่าผลการพยากรณ์อัตราการไหลที่ให้ค่าประสิทธิภาพสูงกว่า 80% สามารถเรียงลำดับจากมากไปหาน้อยที่ 1 วันล่วงหน้า 2 วันล่วงหน้า และ 3 วันล่วงหน้า ตามลำดับ แสดงให้เห็นว่าการพยากรณ์อัตราการไหลจากโปรแกรม KUnet สามารถนำไปประยุกต์ใช้ในการพยากรณ์อัตราการไหลได้อย่างมีประสิทธิภาพ



ภาพที่ 67 ประสิทธิภาพของโครงข่ายประสาทเทียม ณ วันพยากรณ์ (Lag Time) ต่างๆ (ล้านน้ำยม)

ลำน่าน


ในการทำการพยากรณ์ในลำนำนาน ใช้กระบวนการเรียนรู้โดยใช้ข้อมูลนำเข้า 7 ปี (พ.ศ. 2537 ถึง พ.ศ.2543) และกระบวนการทดสอบของลำนำนานใช้ข้อมูลนำเข้า 2 ปี (พ.ศ.2544 ถึง พ.ศ. 2545) ข้อมูลที่ใช้อยู่ในช่วงฤดูฝนระหว่างเดือนกรกฎาคมถึงกันยายน วิธีการปรับเทียบแบบจำลองโครงข่ายประสาทเทียมให้เหมาะสม พิจารณาได้จากความคลาดเคลื่อนทั้งหมดที่เกิดขึ้นในกระบวนการเรียนรู้ ซึ่งมีผลมาจากการกำหนดลักษณะโครงสร้างของโครงข่ายประสาทเทียมและค่าพารามิเตอร์ในกระบวนการเรียนรู้ที่เหมาะสม โดยการศึกษาในครั้งนี้ได้ทำการปรับเทียบแบบจำลองให้เหมาะสมก่อนการวิเคราะห์ประสิทธิภาพของการพยากรณ์อัตราการไหล (EI)

การปรับเทียบแบบจำลองได้ดำเนินการ โดยเริ่มจากการกำหนดโครงสร้างของโครงข่ายให้เหมาะสม ซึ่งมีวิธีการปรับเทียบโดยการสุ่มเลือกจำนวนหน่วยในชั้นแฝง (Hidden Nodes) ตั้งแต่ 1 หน่วยขึ้นไป หลังจากนั้นจึงทำการกำหนดค่าพารามิเตอร์ต่างๆ ให้เหมาะสม โดยเปรียบเทียบจากการเปลี่ยนค่า Slope Parameter ที่ 0.1 แล้วเพิ่มค่าขึ้นไปครั้งละ 0.1 และนำค่า Slope Parameter ที่ทำให้เกิดความคลาดเคลื่อนทั้งหมดน้อยที่สุดมาใช้ในการปรับเทียบค่า Moment Factor ต่อไป โดยวิธีการปรับเทียบค่า Moment Factor เริ่มเปลี่ยนจากค่า 0.9 แล้วลดลงไปครั้งละ 0.1 เมื่อได้ทำการปรับเทียบแบบจำลองตามขั้นตอนดังกล่าว หลังจากนั้นได้เลือกโครงข่ายประสาทเทียมที่ให้ค่าความคลาดเคลื่อนทั้งหมด (Total Error) น้อยที่สุด มาใช้ในการวิเคราะห์ค่าประสิทธิภาพของโครงข่ายประสาทเทียม (EI)

ผลการพยากรณ์อัตราการไหลรายวันที่สถานี N.1 ลำนำยม สามารถสรุปได้ดังนี้ สำหรับกรณีศึกษา ก โครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงที่สุด ได้แก่กรณีที่ 4.10 ซึ่งมีโครงสร้างเป็น 4-3-4-2-1 (Input Nodes / Hidden Nodes / Output Nodes) โดยให้ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 99.35% และกระบวนการทดสอบเท่ากับ 99.90% ส่วนโครงข่ายประสาทเทียมให้ค่าประสิทธิภาพต่ำสุด ได้แก่กรณีที่ 4.1 ซึ่งมีโครงสร้างเป็น 4-1-1-1-1 โดยค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 81.83% และกระบวนการทดสอบเท่ากับ 83.60% สำหรับกรณีศึกษา ข โครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงที่สุด ได้แก่กรณีที่ 6.3 ซึ่งมีโครงสร้างเป็น 4-3-1 โดยให้ค่าประสิทธิภาพที่ได้จากกระบวนการเรียนรู้เท่ากับ 97.64% และกระบวนการทดสอบเท่ากับ 92.74% ส่วนโครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพน้อยที่สุดได้แก่กรณีที่ 5.1 ซึ่งมีโครงสร้างเป็น 2-1-1 โดยให้ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 68% และกระบวนการทดสอบเท่ากับ 89.16% ดังแสดงในภาพที่ 68 ผลการเปรียบเทียบประสิทธิภาพของการพยากรณ์อัตราการไหลในกรณีศึกษาต่างๆ แสดงรายละเอียดได้ดังนี้



1. ผลการเปรียบเทียบประสิทธิภาพเมื่อเปลี่ยนจำนวนหน่วยในชั้นแฝง

การเปรียบเทียบค่าประสิทธิภาพของโครงข่ายประสาทเทียมที่มีจำนวนหน่วยในชั้นแฝงต่างกัน แสดงตัวอย่างได้ดังภาพที่ 69 โดยโครงสร้างของข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงที่สุดได้แก่ กรณีที่ 3.14 (4-5-3-1) ซึ่งให้ค่าความผิดพลาดทั้งหมดเท่ากับ 0.0492 ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 99.33% และกระบวนการทดสอบเท่ากับ 99.75% ส่วนโครงสร้างของข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพต่ำที่สุดได้แก่ กรณีที่ 3.1 (4-1-1-1) โดยให้ค่าความผิดพลาดทั้งหมดเท่ากับ 0.2046 ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 97.23% และกระบวนการทดสอบเท่ากับ 97.48% จากภาพดังกล่าวแสดงให้เห็นว่าเมื่อทำการเพิ่มจำนวนหน่วยในชั้นแฝง (Hidden Nodes) จากหน่วยที่ 3 ขึ้นไป ส่งผลให้ค่าประสิทธิภาพของโครงข่ายประสาทเทียมใกล้เคียงกัน โดยโครงข่ายประสาทเทียมที่มีประสิทธิภาพน้อยที่สุดประกอบด้วยจำนวนหน่วยในชั้นแฝง 1 หน่วย รายละเอียดเพิ่มเติมได้แสดงไว้ในภาพผนวกที่ 23 ถึง ภาพผนวกที่ 28



ภาพที่ 68 แผนผังสรุปผลการพยากรณ์อัตราการใช้พลังงาน (ลำน้ำน่าน)

case	Slope Parameter	Momentum Factor	Train		Test
			Total Error	EI	EI
3.1	0.9	0.1	0.0500	0.9768	0.9249
3.2	0.7	0.1	0.0496	0.9770	0.9179
3.3	0.9	0.1	0.0498	0.9769	0.9176
3.4	0.9	0.1	0.0498	0.9769	0.9111
3.5	0.8	0.1	0.0498	0.9769	0.9104
3.6	0.8	0.1	0.0493	0.9771	0.9104
3.7	0.9	0.1	0.0500	0.9768	0.9141
3.8	0.9	0.1	0.0496	0.9770	0.9195
3.9	0.8	0.1	0.0494	0.9771	0.9189
3.10	0.8	0.1	0.0498	0.9769	0.9196
3.11	0.9	0.1	0.0499	0.9770	0.9138
3.12	0.8	0.1	0.0498	0.9769	0.9191
3.13	0.8	0.1	0.0499	0.9768	0.9164
3.14	0.9	0.1	0.0498	0.9769	0.9199



ภาพที่ 69 การเปรียบเทียบค่าประสิทธิภาพของโครงข่ายประสาทเทียม เมื่อทำการเปลี่ยน จำนวนหน่วยใน ชั้นแฝง (ลำนํ้าหนัก)

2. ผลการเปรียบเทียบประสิทธิภาพของกรณีศึกษา ก

การเปรียบเทียบโครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงสุดที่สุดของกรณีศึกษา ก ที่มีจำนวนชั้นแฝง (Hidden Layer) 1 ชั้น และให้ข้อมูลปริมาณน้ำท่าของสถานี N.1 มาเป็นข้อมูลนำเข้า

แสดงไว้ในภาพที่ 70 ซึ่งได้แก่กรณีที่ 1.3 , กรณีที่ 2.6 , กรณีที่ 3.14 และกรณีที่ 4.10 โดยสามารถพล็อตกราฟแสดงความสัมพันธ์ระหว่างอัตราการใช้ไฟที่ได้จากการวัด (Q Observe) และอัตราการใช้ไฟที่ได้จากการพยากรณ์ (Q Simulate) ในกรณีดังกล่าวได้ดังภาพที่ 71 ถึงภาพที่ 74 ตามลำดับ (ในภาพ ก และภาพ ข แสดงผลการพยากรณ์อัตราการใช้ไฟที่ได้จากกระบวนการเรียนรู้ ส่วนภาพ ค และภาพ ง แสดงผลการพยากรณ์อัตราการใช้ไฟที่ได้จากกระบวนการทดสอบ)

จากภาพที่ 70 เห็นได้ว่าการเปลี่ยนจำนวนหน่วยรับข้อมูล (Input Nodes) จาก 4 หน่วย เป็น 6 หน่วย ซึ่งได้แก่กรณีที่ 1.3 และ กรณีที่ 2.6 ตามลำดับ ส่งผลให้ค่าความคลาดเคลื่อนทั้งหมดน้อยลงและค่าประสิทธิภาพของโครงข่ายประสาทเทียมสูงขึ้น ซึ่งโครงสร้างของข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงสุด ได้แก่กรณีที่ 1.3 (4-3-1) โดยให้ค่าความผิดพลาดทั้งหมดเท่ากับ 0.0498 ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 99.33% และกระบวนการทดสอบเท่ากับ 99.60% โครงสร้างของข่ายประสาทเทียมที่ให้ค่าสัมประสิทธิ์ประสิทธิภาพต่ำที่สุด ได้แก่กรณีที่ 2.6 (6-7-1) โดยให้ค่าความผิดพลาดทั้งหมดเท่ากับ 0.0498 ค่าประสิทธิภาพกระบวนการเรียนรู้เท่ากับ 99.33% และกระบวนการทดสอบเท่ากับ 99.38%

3. ผลการเปรียบเทียบประสิทธิภาพเมื่อเปลี่ยนจำนวนชั้นแฝง


การเปรียบเทียบข่ายประสาทเทียม ที่ให้ค่าประสิทธิภาพสูงสุดของกรณีศึกษาที่มี

จำนวนชั้นแฝงต่างกันคือ จาก 1 ชั้น ถึง 3 ชั้น ซึ่งได้แก่กรณีที่ 1.3 กรณีที่ 3.14 และกรณีที่ 4.10 ตามลำดับ แสดงไว้ในภาพที่ 74 โดยสามารถพล็อตกราฟแสดงความสัมพันธ์ระหว่างอัตราการใช้ไฟที่ได้จากการวัดและอัตราการใช้ไฟที่ได้จากการพยากรณ์ในกรณีดังกล่าว ได้ดังภาพที่ 70 ภาพที่ 72 และภาพที่ 73 ตามลำดับ จากภาพที่ 74 เห็นได้ว่าการเพิ่มจำนวนชั้นแฝง ส่งผลให้ค่าความคลาดเคลื่อนทั้งหมดที่เกิดขึ้น และค่าประสิทธิภาพของโครงข่ายประสาทเทียมจากกระบวนการเรียนรู้กับกระบวนการทดสอบใกล้เคียงกัน คือ 0.04 99% และ 99% ตามลำดับ


case	Slope Parameter	Momentum Factor	Train		Test
			Total Error	EI	EI
1.3	0.1	0.9	0.0498	0.9933	0.996
2.6	0.1	0.9	0.0499	0.9932	0.9947

3.14	0.1	0.9	0.0490	0.9933	0.9975
4.10	0.8	0.9	0.0484	0.9935	0.9990





ความสัมพันธ์ระหว่าง Total Error กับ Case 1.3,2.6,3.14 และ 4.10







ความสัมพันธ์ระหว่าง EI กับ Case 1.3,2.6,3.14 และ 4.10







ภาพที่ 70 การเปรียบเทียบโครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงที่สุดของกรณีศึกษา ก (ลำน้ำน่าน)







ภาพที่ 71 กราฟเปรียบเทียบระหว่างอัตราการไหลรายวันที่ได้จากการวัดและอัตราการไหลรายวันที่ได้จากพยากรณ์ของกรณี 1.3 (ลุ่มน้ำน่าน)



ภาพที่ 72 กราฟเปรียบเทียบระหว่างอัตราการไหลรายวันที่ได้จากการวัดและอัตราการไหลรายวันที่ได้จากพยากรณ์ของกรณี 2.6 (ลุ่มน้ำน่าน)




ภาพที่ 73 กราฟเปรียบเทียบระหว่างอัตราการไหลรายวันที่ได้จากการวัดและอัตราการไหลรายวันที่ได้จากพยากรณ์ของกรณี 3.14 (ลุ่มน้ำน่าน)




ภาพที่ 74 กราฟเปรียบเทียบระหว่างอัตราการไหลรายวันที่ได้จากการวัดและอัตราการไหลรายวันที่ได้จากพยากรณ์ของกรณี 4.10 (ลุ่มน้ำน่าน)

case	Slope Parameter	Momentum Factor	Train		Test
			Total Error	EI	EI
1.3	0.1	0.9	0.0498	0.9933	0.9960
3.14	0.1	0.9	0.049	0.9932	0.9975
4.10	0.1	0.9	0.0484	0.9935	0.9990

ความสัมพันธ์ระหว่าง Total Error กับ Case 1.3,3.4 และ 4.10



ความสัมพันธ์ระหว่าง EI กับ Case 1.3,3.4 และ 4.10



ภาพที่ 75 การเปรียบเทียบโครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงที่สุดของกรณีศึกษาที่มีจำนวนชั้นแฝงต่างกัน (ลำนํ้าหนัก)



4. ผลการเปรียบเทียบประสิทธิภาพของกรณีศึกษา ข
- การเปรียบเทียบโครงข่ายประสาทเทียม ที่ให้ค่าประสิทธิภาพสูงสุดที่สุดของกรณีศึกษา ข ที่ไม่ใช่ข้อมูลปริมาณน้ำท่าของสถานี N.1 มาเป็นข้อมูลนำเข้า แสดงไว้ในภาพที่ 76 ซึ่งได้แก่กรณี 5.7 และกรณี 6.3 โดยสามารถพล็อตกราฟแสดงความสัมพันธ์ระหว่างอัตราการไหลที่ได้จากวัด (Q Observe) และอัตราการไหลที่ได้จากการพยากรณ์ (Q Simulate) ดังแสดงในภาพที่ 77 ถึงภาพที่ 78 ตามลำดับ (ในภาพ ก และภาพ ข) แสดงผลการพยากรณ์อัตราการไหลที่ได้จากกระบวนการเรียนรู้ ส่วนภาพ ค และภาพ ง แสดงผลการพยากรณ์อัตราการไหลที่ได้จากกระบวนการทดสอบ)

จากภาพที่ 76 เห็นได้ว่าเมื่อทำการเปลี่ยนจำนวนหน่วยรับข้อมูล (Input Nodes) จาก 2 หน่วย เป็น 4 หน่วย ซึ่งได้แก่กรณี 5.7 และกรณี 6.3 ตามลำดับส่งผลให้ค่าความคลาดเคลื่อนทั้งหมดน้อยลง และทำให้ค่าประสิทธิภาพของโครงข่ายประสาทเทียมเพิ่มขึ้น โดยโครงสร้างของข่ายประสาทเทียม ที่ให้ค่าประสิทธิภาพสูงสุด ได้กรณี 5.7 (2-7-1) ซึ่งให้ค่าความผิดพลาดทั้งหมดเท่ากับ 0.2202 ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 97.02% และกระบวนการทดสอบเท่ากับ 91.08% ส่วนโครงสร้างของข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพต่ำที่สุด ได้กรณี 6.3 (4-6-1) โดยให้ค่าความผิดพลาดทั้งหมดเท่ากับ 0.1691 ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 97.71% และกระบวนการทดสอบเท่ากับ 91.82% ส่งผลให้ค่าความคลาดเคลื่อนทั้งหมดที่เกิดขึ้นและค่าประสิทธิภาพของโครงข่ายประสาทเทียมจากกระบวนการเรียนรู้กับกระบวนการทดสอบใกล้เคียงกัน คือ ระหว่าง 0.16 ถึง 0.22 97% และ 92% ตามลำดับ





5. ผลการเปรียบเทียบประสิทธิภาพเมื่อเปลี่ยนจำนวนรอบที่ใช้ในกระบวนการเรียนรู้
- การเปรียบเทียบค่าประสิทธิภาพของโครงข่ายประสาทเทียม ที่มีจำนวนรอบที่ใช้ในกระบวนการเรียนรู้ต่างกัน แสดงตัวอย่างได้ดังภาพที่ 79 ซึ่งเห็นได้ว่าการเพิ่มจำนวนรอบที่ใช้ในกระบวนการเรียนรู้มากขึ้น ส่งผลให้ความคลาดเคลื่อนทั้งหมดที่เกิดขึ้น และค่าประสิทธิภาพของโครงข่ายประสาทเทียมจากกระบวนการเรียนรู้ กับกระบวนการทดสอบใกล้เคียงกัน คือ 0.7 92% และ 89% ตามลำดับ รายละเอียดเพิ่มเติมได้แสดงไว้ในภาพผนวกที่ 29 ถึงภาพผนวกที่ 34

case	Slope	Momentum	Train	Test
------	-------	----------	-------	------





	Parameter	Factor	Total Error	EI	EI
5.7	0.9	0.1	0.2202	0.9702	0.9108
6.3	0.1	0.9	0.1743	0.9764	0.9274



ภาพที่ 76 การเปรียบเทียบโครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงที่สุดของกรณีศึกษา ข(ลำน้ำน่าน)




ภาพที่ 77 กราฟเปรียบเทียบระหว่างอัตราการไหลรายวันที่ได้จากการวัดและอัตราการไหลรายวันที่ได้จากการพยากรณ์ของกรณี 5.7(ลำน้ำน่าน)




ภาพที่ 78 กราฟเปรียบเทียบระหว่างอัตราการไหลรายวันที่ได้จากการวัดและอัตราการไหลรายวันที่ได้จากการพยากรณ์ของกรณี 6.3 (ลำน้ำน่าน)

Case 6.3			
Iteration	Train		Test
	Total Error	EI	EI
5000	0.1934	0.9738	0.9289
10000	0.1743	0.9764	0.9274
15000	0.1098	0.9791	0.9464
20000	0.1094	0.9792	0.9468

ความสัมพันธ์ระหว่าง Total Error กับ Iteration ของกรณี 6.3




ความสัมพันธ์ระหว่าง EI กับ Iteration ของกรณี 6.3



ภาพที่ 79 การเปรียบเทียบค่าประสิทธิภาพของโครงข่ายประสาทเทียมเมื่อทำการเปลี่ยนจำนวนรอบที่ใช้ในกระบวนการเรียนรู้

6. ผลการเปรียบเทียบประสิทธิภาพเมื่อเปลี่ยนวันที่ทำการพยากรณ์

จากการศึกษาทั้ง 6 กรณี เห็นได้ว่าโครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงที่สุด ได้กรณีที่ 4.10 ซึ่งมีโครงสร้างเป็น 4-3-4-2-1 จึงได้เลือกนำมาใช้ในการทดสอบเพื่อแสดงว่าโครงข่ายประสาทเทียม สามารถพยากรณ์อัตราการไหลได้อย่างมีประสิทธิภาพ ผลการศึกษาแสดงได้กราฟที่ 80 ซึ่งเป็นกราฟเทียบประสิทธิภาพของโครงข่ายประสาทเทียมเมื่อเพิ่มจำนวนวันที่ใช้ในการพยากรณ์ (Lag Time) จาก 1 วันล่วงหน้า ถึง 5 วันล่วงหน้า โดยให้ค่าประสิทธิภาพจากกระบวนการเรียนรู้เท่ากับ 99.35% , 92.90%, 82.90%, 72.40% และ 63.20% ตามลำดับและกระบวนการทดสอบเท่ากับ 99.90% , 94.65%, 88.60%, 83.90% และ 77.40% ตามลำดับ จากการศึกษาดังกล่าวเห็นได้ว่าผลการพยากรณ์อัตราการไหลที่ให้ค่าประสิทธิภาพสูงกว่า 80% สามารถเรียงลำดับจากมากไปหาน้อยที่ 1 วันล่วงหน้า 2 วันล่วงหน้า และ 3 วันล่วงหน้า ตามลำดับ แสดงให้เห็นว่าการพยากรณ์อัตราการไหลจากโปรแกรม KUnet สามารถนำไปประยุกต์ใช้ในการพยากรณ์อัตราการไหลได้อย่างมีประสิทธิภาพ



ภาพที่ 80 ประสิทธิภาพของโครงข่ายประสาทเทียม ณ วันพยากรณ์ (Lag Time) ต่างๆ (ลำน้ำน่าน)

สรุปและข้อเสนอแนะ

สรุป

โปรแกรม KUnet เป็นโปรแกรมคอมพิวเตอร์ภาษา Visual Basic ใช้สำหรับการพยากรณ์อัตราการไหล ด้วยหลักการของโครงข่ายประสาทเทียมแบบ Backpropagation โดยมีส่วนประกอบที่สำคัญ 4 ส่วน คือ

1. Network Property
2. Run Network
3. View Target and Calculation Target
4. Rating Curve

สำหรับกระบวนการทดสอบการพยากรณ์อัตราการไหลรายวันของโปรแกรม ได้เลือกใช้ลำน้ำยมและน่านเป็นกรณีศึกษา โดยแบ่งออกเป็น 2 กระบวนการ คือ กระบวนการเรียนรู้และกระบวนการทดสอบ โดยใช้ข้อมูลของสถานีวัดปริมาณน้ำท่ารายวันในพื้นที่ลุ่มน้ำที่มีอิทธิพลตามค่าสัมประสิทธิ์สหสัมพันธ์ต่อข้อมูลปริมาณน้ำท่ารายวัน ของสถานีที่ต้องการพยากรณ์เป็นข้อมูลนำเข้า (Input Data) จากการศึกษาสามารถสรุปได้ดังนี้

1. จากผลการพยากรณ์อัตราการไหลรายวันของโปรแกรม KUnet พบว่าในขั้นตอนของกระบวนการทดสอบ โครงข่ายประสาทเทียมที่เหมาะสมให้ค่าประสิทธิภาพในการพยากรณ์อัตราการไหล 1 วันล่วงหน้า 2 วันล่วงหน้า 3 วันล่วงหน้าของลำน้ำยม เท่ากับ 97.28% , 92.64% และ 87.56% ตามลำดับ และของลำน้ำน่านเท่ากับ เท่ากับ 99.90% , 94.65% และ 88.60% ตามลำดับ แสดงให้เห็นว่าโปรแกรม KUnet พยากรณ์อัตราการไหลรายวันได้อย่างมีประสิทธิภาพสามารถนำไปประยุกต์ใช้ในการพยากรณ์อัตราการไหลของแม่น้ำอื่นๆ ต่อไป และสามารถนำโครงข่ายประสาทเทียมที่เหมาะสมมาใช้ในการพยากรณ์อัตราการไหลรายวัน 1 วันล่วงหน้า ถึง 3 วันล่วงหน้า ณ สถานีวัดปริมาณน้ำท่า Y.1 ลำน้ำยม และ N.1 ลำน้ำน่านในอนาคต
2. การนำค่าสัมประสิทธิ์สหสัมพันธ์ที่มากกว่า 0.4 มาใช้ในการคัดเลือกข้อมูลนำเข้า มีผลต่อประสิทธิภาพของโครงข่ายประสาทเทียม สามารถนำมาใช้เป็นเกณฑ์พื้นฐานในการคัดเลือกข้อมูลนำเข้าได้ เนื่องจากเมื่อทำการทดลองเปลี่ยนจำนวนหน่วยรับข้อมูล (Input Nodes) โดยกำหนดจำนวนหน่วยในชั้นแฝง จำนวนชั้นแฝง และค่าพารามิเตอร์ต่าง ๆ คงที่ ในการเพิ่มจำนวนหน่วยรับข้อมูลตามค่าสัมประสิทธิ์สหสัมพันธ์ที่ลดลงของข้อมูล จากค่า 0.9 ถึงค่า 0.4 พบว่าประสิทธิภาพของการพยากรณ์อัตราการไหลมีค่าสูงขึ้น ตามจำนวนหน่วยรับข้อมูลที่เพิ่มขึ้น และ

ถ้าเพิ่มข้อมูลค่าสัมประสิทธิ์สหสัมพันธ์เท่ากับ 0.5 ขึ้นในชั้นรับข้อมูลส่งผลให้ค่าประสิทธิภาพของโครงข่ายประสาทเทียม ใกล้เคียงกับกรณีที่เลือกข้อมูลนำเข้าจากเกณฑ์ข้างต้น

3. จากการทดลองเปรียบเทียบแบบจำลองโครงข่ายประสาทเทียม ทำให้ทราบถึงปัจจัยหลักที่มีผลต่อประสิทธิภาพของโครงข่ายประสาทเทียมแบบ Backpropagation ซึ่งได้แก่จำนวนข้อมูลนำเข้าโปรแกรม KUnet และค่า Slope Parameter โดยผลของการเลือกค่าพารามิเตอร์ต่างๆ ในโปรแกรม KUnet แสดงให้เห็นว่าเมื่อกำหนดหน่วยในชั้นแฝง จำนวนชั้นแฝง ค่า Momentum Factor จำนวนรอบ และค่าความคลาดเคลื่อนทั้งหมดที่ใช้ในการหยุดกระบวนการเรียนรู้ครั้งที่ ในการกำหนดค่า Slope Parameter น้อย ส่งผลให้ประสิทธิภาพของโครงข่ายประสาทเทียมที่ได้มีค่าค่อนข้างสูง เนื่องจากเป็นพารามิเตอร์หลักที่ใช้ในการคำนวณผลลัพธ์ของโปรแกรม อย่างไรก็ตามถ้ากำหนดค่า Slope Parameter มากเกินไปจะส่งผลให้ผลลัพธ์ที่ได้ ไม่สู้เข้าหาคำตอบ เนื่องจากการเลือกใช้ค่า Slope Parameter ที่ไม่เหมาะสมกับชุดข้อมูล ซึ่งทำให้ผลการพยากรณ์อัตราการไหลของโครงข่ายประสาทเทียมไม่มีประสิทธิภาพ

เมื่อกำหนดจำนวนหน่วยในชั้นแฝง จำนวนชั้นแฝง ค่า Slope Parameter จำนวนรอบและค่าความคลาดเคลื่อนทั้งหมดที่ใช้ในการเรียนรู้ครั้งที่ ในการกำหนดค่า Momentum Factor มาก ส่งผลให้ประสิทธิภาพของโครงข่ายประสาทเทียมที่ได้มีค่าค่อนข้างสูง แต่มีผลน้อยกว่าแบบแรกเนื่องจากเป็นพารามิเตอร์ที่ใช้ในการปรับแก้ค่า Weight และค่า Bias ของโปรแกรมและเมื่อทำการทดลองเปลี่ยนจำนวนหน่วยในชั้นแฝง หรือทำการทดลองเปลี่ยนจำนวนชั้นแฝง โดยการกำหนดให้ค่าพารามิเตอร์ต่างๆ คงที่ ส่งผลให้ประสิทธิภาพของโครงข่ายประสาทเทียมที่ได้มีค่าใกล้เคียงกัน

เมื่อทำการทดลองเปลี่ยนจำนวนรอบที่ใช้ในกระบวนการเรียนรู้ โดยกำหนดจำนวนหน่วยในชั้นแฝง จำนวนชั้นแฝง และค่าพารามิเตอร์ต่างๆ คงที่ ส่งผลให้ประสิทธิภาพของโครงข่ายประสาทเทียมที่ได้มีค่าใกล้เคียง อย่างไรก็ตามถ้ากำหนดจำนวนรอบที่ใช้ในการหยุดการเรียนรู้มากเกินไป ก็จะไม่มีผลทำให้คำตอบดีขึ้นและยังใช้ระยะเวลาในการเรียนรู้นาน

4. จากผลการทดลองพยากรณ์อัตราการไหลของลำน้ำยมและน่าน โดยใช้โปรแกรม KUnet พบว่าโครงสร้างโครงข่ายประสาทเทียมที่ให้ค่าประสิทธิภาพสูงที่สุดในแต่ละลำน้ำจะให้ค่าพารามิเตอร์ที่แตกต่างกัน ซึ่งไม่สามารถจะนำเอาค่าพารามิเตอร์ดังกล่าวมาเปรียบเทียบกันได้ในแต่ละลำน้ำ และถึงแม้ว่าจะเป็นลำน้ำเดียวกันจึงจำเป็นต้องทำการพยากรณ์อัตราการไหลเป็นแต่ละกรณีไป โดยไม่สามารถนำค่าพารามิเตอร์ที่ได้จากการทดลองพยากรณ์อัตราการไหลที่มีค่าสูงสุด ในวิทยานิพนธ์เล่มนี้มาใช้เป็นค่าอ้างอิงในการพยากรณ์อัตราการไหลได้

ข้อเสนอแนะ

เพื่อให้โปรแกรมคอมพิวเตอร์ที่ใช้ในการพยากรณ์อัตราการไหล มีประสิทธิภาพยิ่งขึ้น จึงควรได้รับการพัฒนาต่อไปดังต่อไปนี้

1. ควรมีการศึกษาและประยุกต์ใช้โครงข่ายประสาทเทียมประเภทอื่นๆ เพื่อนำไปใช้พัฒนาโปรแกรม KUnet ให้มีประสิทธิภาพมากยิ่งขึ้น
2. ควรทำการพัฒนาขั้นตอนในการปรับค่า Weight และค่า Bias โดยศึกษาจากวิธีอื่นๆ เช่น วิธีของ Liebenberg Marquardt Algorithm และวิธีของ Genetic Algorithm เป็นต้น เพื่อให้โปรแกรมมีการเข้าสู่คำตอบเร็วขึ้น และมีความคลาดเคลื่อนทั้งหมดน้อยลง
3. โครงข่ายประสาทเทียมที่ได้ทำการปรับเทียบแล้วนี้ มีความเหมาะสมในการพยากรณ์อัตราการไหลในช่วงระยะเวลาหนึ่งเท่านั้น หากสภาพลุ่มน้ำมีการเปลี่ยนแปลงหรือมีการพัฒนาลุ่มน้ำมากขึ้น เช่น มีการเปลี่ยนแปลงลักษณะการใช้ที่ดินหรือมีการก่อสร้างอาคารชลศาสตร์ ควรทำการปรับเทียบแบบจำลองโครงข่ายประสาทเทียมอีกครั้ง เพื่อให้การพยากรณ์มีความถูกต้องยิ่งขึ้น
4. การศึกษาในครั้งนี้ได้พิจารณาเฉพาะการพยากรณ์อัตราการไหลรายวันล่วงหน้า ณ สถานีวัดปริมาณน้ำท่าเพียงแห่งเดียว ถ้าต้องการพยากรณ์อัตราการไหลที่สถานีวัดน้ำท่าจำนวนมากกว่าหนึ่งแห่ง ควรมีการพัฒนาโปรแกรมคอมพิวเตอร์โดยการเพิ่มจำนวนหน่วยในชั้นแสดงผล (Output Nodes) ให้มากขึ้น

เอกสารอ้างอิง

กิตติพงษ์ จิระยุดิ. 2524 การทำนายอัตราการไหลรายวันด้วยสมการ Time Series ชนิดโพลีโน

เมียล , น. WRE19-WRE25. การประชุมวิชาการวิศวกรรมโยธา ครั้งที่ 5. วิศวกรรม

สถานแห่งประเทศไทย, กรุงเทพฯ.

และ ธิยารัต อัสสุพิ. 2544 การประยุกต์โครงข่ายประสาทเทียมในการทำนายอัตราการไหลรายวัน

ของแม่น้ำชีและมูล น. WRE117-WRE122. การประชุมวิชาการวิศวกรรมโยธา ครั้งที่ 7. วิศวกรรม

สถานแห่งประเทศไทย, กรุงเทพฯ.

ภาควิชาวิศวกรรมทรัพยากรน้ำ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์. 2537.

โครงการศึกษาข้อมูลและศักยภาพการพัฒนาลุ่มน้ำปราจีนบุรี: รายงานฉบับสุดท้าย รายงานสรุป
สำหรับผู้บริหาร. 32 น.

วริยา ผาฟองขุน. 2543. การพยากรณ์สภาพการเกิดน้ำท่วมของแม่น้ำบางปะกงโดยใช้

แบบจำลอง RUBICON. วิทยานิพนธ์ปริญญาโท, มหาวิทยาลัยเกษตรศาสตร์.

วัชร วีระพันธุ์. 2538. การจำลองน้ำท่วมในลุ่มน้ำอุตะเถา. กรมอุตุนิยมวิทยา, กรุงเทพฯ. 44 น.

เสรี ศุภราทิตย์. 2543. การทำนายอัตราการไหลรายเดือนโดยโครงข่ายประสาทเทียม, น.

WRE91-WRE96. การประชุมวิชาการวิศวกรรมโยธา ครั้งที่ 6. วิศวกรรมสถานแห่งประเทศไทย,
กรุงเทพฯ.

.2544 การทำนายน้ำท่วมล้นโดยแบบจำลองโครงข่ายประสาทเทียม, น. WRE35-

WRE40. การประชุมวิชาการวิศวกรรมโยธา ครั้งที่ 7. วิศวกรรมสถานแห่งประเทศไทย, กรุงเทพฯ.

ชัยยุทธ ชินณะราศี และ ทรงพล โนนสว่าง. 2544. การพยากรณ์ระดับน้ำที่หาดใหญ่โดย

โครงข่ายประสาทเทียม, น. WRE11 (1-6). การประชุมวิชาการวิศวกรรมแหล่งน้ำแห่งชาติ ครั้งที่ 1.

วิศวกรรมสถานแห่งประเทศไทย, กรุงเทพฯ.

Achfla, D., K. Fernando and A.W. Jayawardena. 1998. Runoff Forecasting Using RBF

Networks with OLS Algorithm. **Journal of Hydrologic Engineering**. 3(3) : 203-209

- Box, G.E.P., G.M. Jenkins and G.C. Reinsel. 1994. **Time Series Analysis Forecasting and Control**. 3rd ed. Prentice Hall, Inc., New jersey. 598 p.
- Campolo, M., P. Andreussi and A. Soldati. 1999. River Flood Forecasting with a Neural Network Model. **Water Resource research**. 35(4) : 1191-1197.
- Danish Hydraulic Institute. 1990. **Nam Documentation and User's Guide**. Horsholm, Denmark. 279 p.
- Fausett, L. 1994. **Fundamentals of Neural Networks**. Prentice Hall, Inc., New jersey. 461 p.
- French, M.N., W.F. Krajewski and R.R. Cuykendall. 1992. Rainfall Forecasting in Space and Time Using Neural Network. **Journal of Hydrology**. 137 : 1-31
- Haan, C.T. 1977. **Statistical Methods in Hydrology**. The Iowa State University Press- Ames, Iowa. 378 p.
- Hebb, D.O. 1958. **Psychology**. W.B.Saunders Company. Newyork. 275 p.
- Hsu, K., H.V. Gupta and S. Sorooshain. 1995. Artificial Neural Networks Modeling of the Rainfall-Runoff Process. **Water Resource research**. 31(10) : 2517-2530.
- Liong, S.Y., W.H. Lim and G.N. Paudyal. 2000. River Stage Forecasting in Bangladesh : Neural Network Approach. **Journal of Computing in Civil Engineering**. 14 : 1-8
- Maren, A.J.,C.T. Harston and R.M. Pap. 1990. **Handbook of Neural Computing Application**. Academic Press, Sandiegp. 448 p.

Nam, L.H. 1997 . **Simulation and Forecasting of Monthly Streamflows Using a Back Propagation Model a Case Study: Black River Basin in Vietnam.** M.S. thesis, Assian Institute of Technology Bangkok University.

Patterson, D.W. 1996. **Artificial Neural Networks.** Simon & Schuster (Asia) Pte.Ltd., New York. 477 p.

Riverdeep. 2003. What is the Tank Model? Manuals & Guides. Available
Soure: <http://www.riverdeep.net/support/download center>. February 6, 2003.

Siang, G.O. 1992. **Application of Back Propagation Method in Forecasting Problems.**
M.S. thesis, Assian Institute of Technology Bangkok University.

Subramanya, K. 1994. **Engineering Hyrology.** Tata McGraw-Hill, New Delhi, 392 p.

Theodoridis, S. and K. Koutroumbas. 1999. **Pattern Recognition Systems.** Academic Press, Inc., Sandiego. 625 p.

U.S. Army Crops of Engineers. 1971. Hec-4 **Monthly Streamflow Simulation** . The Hydrologic Engineering Center , California. 126 p.

U.S. Army Crops of Engineers. 1991. **User Manual for SSARR Model.** North Pacific Division , Oregon. 411 p.

Win, T.Y. 1999. **Daily Flood forecasting: a Neural Network of Prasae River.** M.S. thesis, Assian Institute of Technology Bangkok University