

<http://journal.rmutp.ac.th/>

การพัฒนาแบบจำลองสำหรับคาดการณ์ปริมาณน้ำท่าบริเวณลุ่มน้ำมูล

รติพร จันทร์กลั่น^{1*} เกตุกาญจน์ ไชยขันธ์² กิตติศักดิ์ เกิดประสพ¹ และ นิตยา เกิดประสพ¹

¹ สำนักวิศวกรรมศาสตร์ วิศวกรรมคอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีสุรนารี

² คณะวิศวกรรมศาสตร์และสถาปัตยกรรมศาสตร์ วิศวกรรมคอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีราชมงคลอีสาน

¹ 111 ถนนมหาวิทยาลัย อำเภอเมือง จังหวัดนครราชสีมา 30000

² 744 ถนนสุรนารายณ์ อำเภอเมือง จังหวัดนครราชสีมา 30000

รับบทความ 4 กุมภาพันธ์ 2017; ตอบรับบทความ 1 สิงหาคม 2017

บทคัดย่อ

บทความนี้นำเสนอการใช้การสำรวจระยะไกลด้วยดัชนีผลต่างพื้นพรรณจากดาวเทียม NOAA ค่าการจัดกลุ่มจาก k-means อุณหภูมิ ปริมาณน้ำฝน จำนวนวันที่ฝนตก และปริมาณน้ำท่า เพื่อสร้างโมเดลคาดการณ์ค่าปริมาณน้ำท่ารายเดือนด้วยโครงข่ายประสาทเทียม ประเมินประสิทธิภาพโดยใช้ค่า R² และ RMSE เปรียบเทียบประสิทธิภาพด้วยสมการทดถอย ผลการทดลองสรุปว่าเมื่อเพิ่มค่าการจัดกลุ่มร่วมกับพารามิเตอร์อื่น ๆ เพื่อนำมาสร้างโมเดลสามารถเพิ่มประสิทธิภาพการคาดการณ์ได้ เมื่อใช้ค่าดัชนีผลต่างพื้นพรรณร่วมกับอุณหภูมิ ที่เวลา y ตอนหลัง 1 และ 2 เดือน และค่าการจัดกลุ่ม ที่เวลา y ตอนหลัง 1 เดือน สร้างโมเดลให้มีประสิทธิภาพดีที่สุด โดยให้ผล RMSE=0.09 และ R²=0.743 ผลการทดลองแสดงให้เห็นว่าการใช้ข้อมูลการสำรวจระยะไกล และค่าการจัดกลุ่ม สามารถใช้ในการคาดการณ์ค่าปริมาณน้ำท่าได้อย่างมีประสิทธิภาพ

คำสำคัญ: การสำรวจระยะไกล; น้ำท่า; โครงข่ายประสาทเทียม; สมการทดถอยเชิงเส้น

* ผู้พิพนธ์ประจำงาน โทร: +669 9469 6164, ไปรษณีย์อิเล็กทรอนิกส์: arc_angle@hotmail.com

<http://journal.rmutp.ac.th/>

Development Model for Predict Runoff in Mun Basin

Ratiporn Chanklan^{1*} Kedkarn Chaiyakhan² Kittisak Kerdprasop¹ and Nittaya Kerdprasop¹

¹ Institute of Engineering, Computer Engineering, Suranaree University of Technology

² Faculty of Engineering and Architecture, Computer Engineering, Rajamangala University of Technology Isan

¹ 111 University Avenue, Muang, Nakhon Ratchasima 30000

² 744 Suranarai Road, Muang, Nakhon Ratchasima 30000

Received 4 February 2017; accepted 1 August 2017

Abstract

In this paper proposed remote sensing using Normalized Difference Vegetation Index from NOAA STAR, cluster value from k-means, temperature, rainfall, number of rainy days and runoff to create runoff prediction model using Artificial Neural Network (ANN) and evaluated runoff models with the R^2 and RMSE. The results show that the using of cluster value with other parameters to create predictive models can enhance forecasting results. When using Normalized Difference Vegetation Index with temperature value at lag time 1-2 month and cluster value at lag time 1 month to create model with ANN, we have got the best performance which are RMSE=0.09 and R^2 =0.743. The experimental results shows that remote sensing data and cluster value from k-means can be used to predictive the runoff effectively.

Keywords: Remote Sensing; Runoff; Artificial Neural Network; Linear Regression

* Corresponding Author. Tel.: +669 9469 6164, E-mail address: arc_angle@hotmail.com

1. บทนำ

การคาดการณ์ปริมาณน้ำท่าหรือปริมาณน้ำในแม่น้ำที่เกิดขึ้นจากฝนเป็นการวิเคราะห์ค่อนข้างยาก เพราะมีกระบวนการเกิดที่ซับซ้อนและมีความสัมพันธ์ที่ซับซ้อนไม่เป็นเชิงเด่น การคาดการณ์ปริมาณน้ำท่าที่ได้จะช่วยในการตัดสินใจการวางแผนและจัดการการใช้ทรัพยากรน้ำ กล่าวคือถ้าสามารถถูกรุ่งปริมาณน้ำท่าหรือปริมาณน้ำในแม่น้ำได้ล่วงหน้า ทำให้สามารถรู้ว่าจะเกิดปัญหาจากน้ำได้แก่ น้ำท่วม และการขาดแคลนน้ำ ในอนาคตหรือไม่ ดังนั้นการสร้างโมเดลเพื่อคาดการณ์น้ำท่าจะช่วยให้หลักเลี้ยงอันตรายที่อาจจะเกิดขึ้นเนื่องจากน้ำท่วมและภัยแล้ง โครงข่ายประสาทเทียม (ANN) เป็นเครื่องมือที่ได้ถูกนำมาใช้ในอุกวิทยาและสร้างแบบจำลองคาดการณ์ปริมาณน้ำท่า เพราะมีความสามารถในการจำลองทั้งเชิงเส้นและไม่เชิงเส้นโดยไม่จำเป็นต้องตั้งสมมติฐานใด ๆ ตามวิธีการทางสถิติแบบดั้งเดิม มีงานวิจัยหลายชิ้นที่ประสบความสำเร็จในการสร้างแบบจำลองน้ำท่าโดยใช้ ANN

S. Riad et al. [1] ศึกษา ANN เพื่อยืนยันว่าเครือข่ายประสาทเทียมเหมาะสมที่จะคาดการณ์น้ำท่ามากกว่าวิธีการพื้นฐานด้วยการวิเคราะห์การถดถอยโดยใช้ตัวแปรอินพุท 14 ตัวคือ ปริมาณน้ำฝนและปริมาณน้ำท่าข้อมูลหลัง 1-7 วัน เพื่อทำนายน้ำท่าที่เวลา t โดยใช้มาตรฐาน Squared of Error (ASE), ค่าสัมประสิทธิ์การตัดสินใจ (R^2) ผลการทดลองแสดงให้เห็นว่าวิธี ANN ช่วยให้การคาดการณ์ที่ดีกว่าวิธีการวิเคราะห์การถดถอย

A.R. Ghumman et al. [2] พัฒนา ANN เพื่อให้เหมาะสมกับชุดข้อมูลที่เก็บรวบรวมที่เป็นระยะสั้น เพื่อทำการคาดการณ์น้ำท่าเดือนต่อไป ค่าพารามิเตอร์ที่ใช้ได้แก่ ค่าน้ำท่าเดือนปัจจุบัน, ค่าน้ำท่าก่อนหน้า, ค่าน้ำฝนเดือนปัจจุบัน, ค่าน้ำฝนก่อนหน้า โดยใช้ค่าจำนวนโน่นในชั้นช่วงตั้งแต่ 2-15 โดยเลือกค่าจำนวนโน่นในชั้นช่วงที่ให้ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (MSE) น้อยที่สุด ทดสอบประสิทธิภาพ

การคาดการณ์น้ำท่าโดยใช้ ค่าสัมประสิทธิ์ของความมีประสิทธิภาพ (CE) และค่าเฉลี่ยกำลังสองข้อผิดพลาด (RMSE) ผลการทดลองยืนยันว่า ANN ให้ประสิทธิภาพดี

R. Modarres et al. [3] ใช้ค่าทางสถิติ 17 ค่าในการทดสอบการคาดการณ์ปริมาณน้ำท่า ใช้พารามิเตอร์ 6 ตัวในการสร้างแม่แบบด้วย ANN ได้แก่ ปริมาณน้ำฝนประจำวันของสถานีที่ 1 ก่อนหน้า 1 และ 2 วัน, น้ำฝนประจำวันของสถานีที่ 2 ก่อนหน้า 1 วัน, สถานีที่ 3 ก่อนหน้า 2 วัน, น้ำท่ารายวันในเวลา ก่อนหน้า 1 และ 2 วัน เปรียบเทียบกับการวิเคราะห์การถดถอย โดยใช้ข้อมูลน้ำฝนและน้ำท่ารายวันตั้งแต่ ค.ศ. 1978-2000 ผลการทดลองแสดงให้เห็นว่า ANN ให้ผลที่ดีกว่าวิเคราะห์การถดถอย

Gunwant Sharma et al. [4] ใช้ข้อมูลปริมาณน้ำฝนและน้ำท่ารายปี ค.ศ. 1987-2012 จาก 6 สถานีเพื่อวิเคราะห์น้ำท่าโดยใช้สมการถดถอยแบบ Linear กับ Parabolic โดยใช้ค่าปริมาณน้ำฝนปีก่อนหน้าเป็นอินพุตเพื่อคาดการณ์ปริมาณน้ำท่า ทำการเปรียบเทียบประสิทธิภาพโดยใช้ค่า R^2 จะเห็นว่าเมื่อใช้ Parabolic มีประสิทธิภาพการทำนายน้ำท่าดีกว่า Linear และแสดงให้เห็นว่าความสัมพันธ์ระหว่างปริมาณน้ำฝนปีก่อนหน้าและน้ำท่าในปีปัจจุบันสอดคล้องกัน

F. Machado et al. [5] สร้างแบบจำลองการทำนายปริมาณน้ำท่าด้วย ANN ด้วยข้อมูลรายเดือนให้มีความแม่นยำ แบ่งข้อมูลออกเป็น 3 ชุด กำหนดค่าโหนดใน Hidden Layer 3, 5, 8, 10 ทดสอบข้อมูลด้วยวิธีการ Nash-Sutcliffe Efficiency Coefficient (NS), R-square Value (R^2) ผลการทดลองที่ข้อมูลชุดที่หนึ่งใช้ อินพุต $P(t)$, $EVT(t)$ และ $Q(t-1)$ ตีที่สุดชุดที่สองและสามใช้อินพุต $P(t-1)$, $P(t)$, $EVT(t-1)$, $EVT(t)$, $Q(t-1)$ ประสิทธิภาพดีที่สุด

จากที่กล่าวมีข้างต้นจะเห็นว่างานวิจัยส่วนใหญ่นิยมใช้ค่าปริมาณน้ำฝนและปริมาณน้ำท่าข้อมูลหลัง มาใช้ในการสร้างโมเดลคาดการณ์ปริมาณน้ำท่า และ

พยายามปรับปรุงค่าอินพุตที่ใช้กับ ANN เพื่อเพิ่มประสิทธิภาพการคาดการณ์ปริมาณน้ำท่า

ในงานวิจัยนี้เสนอการใช้ข้อมูลรายเดือนได้แก่ ค่าจากการสำรวจระยะใกล้คือดัชนีผลต่างพืชพรรณ (NDVI) อุณหภูมิ ค่าคลัสเตอร์หรือค่าการจัดกลุ่มน้ำฝน น้ำท่า จำนวนวันที่ฝนตก จาก K-means เพื่อสร้างโมเดลในการคาดการณ์ค่าน้ำท่าที่สถานี M.145 ลำพระเพลิง อ.ปากช่อง จ.นครราชสีมา และเปรียบเทียบผลการคาดการณ์น้ำท่าด้วยการใช้การวิเคราะห์การถดถอย โดยทำการประเมินประสิทธิภาพการคาดการณ์โดยใช้ค่า R^2 และ RMSE

2. วิธีการศึกษา

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 การวิเคราะห์การถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression Analysis)

การวิเคราะห์การถดถอยเชิงเส้นอย่างง่าย เป็นการศึกษาความสัมพันธ์ระหว่างสองตัวแปร กำหนดให้ตัวแปร X เป็นตัวแปรอิสระเป็นตัวแปรที่ทราบค่าตัวแปร Y เป็นตัวแปรตามเป็นตัวแปรที่ไม่ทราบค่า สองตัวแปรนี้มีความสัมพันธ์กันในลักษณะเส้นตรง (Linear) เมื่อนำค่า X และ Y หลาย ๆ ค่ามาพล็อตบนแกน X และ Y แล้วลากเส้นตรงผ่านจุดที่พล็อตลงในกราฟ เส้นตรงที่ลากนั้นจะแสดงความสัมพันธ์ระหว่างค่าเฉลี่ยของตัวแปร X และตัวแปร Y ซึ่งเส้นตรงนี้เรียกว่า เส้นกราฟถดถอย (Regression Line) ค่าของตัวแปร Y จะเปลี่ยนแปลงไปตามตัวแปร X ค่าของ X หนึ่งค่าจะมีค่า Y ที่เป็นคุ่ของค่า X เมื่อนำข้อมูลจากตัวแปรมาวิเคราะห์หาความสัมพันธ์ซึ่งสามารถบอกแนวโน้มของความสัมพันธ์โดยใช้แผนภาพเส้นตรง และจะทำการหาเส้นตรงที่ดีที่สุดเพื่อเป็นตัวแทนของรูปแบบความสัมพันธ์ของตัวแปรที่ศึกษา เส้นตรงที่ดีที่สุดจะมีเพียงเส้นเดียว

2.1.2 การวิเคราะห์การถดถอยเชิงเส้นพุ

(Multiple Linear Regression Analysis)

ในการหาความสัมพันธ์ของตัวแปรอิสระกับตัวแปรตามบางครั้งที่จำนวนตัวแปรอิสระที่สนใจในการศึกษามีมากกว่าหนึ่งตัว ความสัมพันธ์นี้ไม่สามารถใช้การถดถอยเชิงเส้นอย่างง่ายในการวิเคราะห์ได้ สำหรับกรณีที่มีตัวแปรอิสระ 2 ตัว (X_1 และ X_2) ที่มีความสัมพันธ์เชิงเส้นกับตัวแปรตาม สามารถถดถอยสามารถเขียนในรูปสมการคือ $Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \varepsilon_i$ เมื่อ Y_i เป็นตัวแปรตามที่ในการเก็บข้อมูลครั้งที่ i ตัวแปรอิสระตัวที่ 1 และ 2 ในการเก็บข้อมูลครั้งที่ i แทนด้วย X_{i1} และ X_{i2} ตามลำดับ β_0 คือค่าเฉลี่ยของตัวแปรตามที่ตัวแปรอิสระทั้งสองมีค่าเป็นศูนย์ β_1 และ β_2 ค่าสัมประสิทธิ์การถดถอยของ X_1 และ X_2 ตามลำดับและ ε_i เป็นค่าความคลาดเคลื่อนในการเก็บข้อมูลครั้งที่ i

การประมาณค่าพารามิเตอร์ใช้วิธีการเช่นเดียวกับสมการถดถอยเชิงเส้นอย่างง่ายคือการใช้วิธีกำลังสองน้อยที่สุด ซึ่งสมการถดถอยเชิงเส้นพุของกลุ่มตัวอย่างคือ $\hat{Y} = b_0 + b_1 X_1 + b_2 X_2$ ในที่นี้ b คือค่าโดยประมาณ โดยสามารถเขียนในรูปของเมตริกซ์ซึ่งสามารถหาเวกเตอร์ b ได้ดังนี้ $b = (X'X)^{-1} \cdot X'Y$ โดย $X'X$ ต้องสามารถหาระยะห่าง $p \times p$ โดย p คือจำนวนตัวแปรอิสระบทนี้จะและค่าของสมาชิกในแนวเนี้ยงเป็นผลรวมกำลังสองของค่าในแต่ละหลัก

2.1.3 ดัชนีผลต่างพืชพรรณ (Normalized

Differential Vegetation Indices: NDVI)

ดัชนีผลต่างพืชพรรณแบบนอมัลไลซ์เป็นค่า ที่ใช้แสดงการสะท้อนของคลื่นแม่เหล็ก (Electromagnetic Spectrum) ของช่วงคลื่นไนโตรเจนฟารีด (Near Infrared Reflectance) กับช่วงคลื่นตามมองเห็นสีแดง (Visible Red Reflectance) โดยสามารถนำมาใช้ ในการ

วิเคราะห์การวัดระยะไกล (Remote Sensing Analysis) โดย NDVI เป็นการคำนวณหาสัดส่วนของช่วงคลื่นที่เกี่ยวข้องกับพืชพรรณ โดยนำค่าความแตกต่างของการสะท้อนของพื้นผิว ระหว่างช่วงคลื่นไกล์อินฟราเรด กับช่วงคลื่นตามองเห็นสีแดง มาทำสัดส่วนกับค่าผลรวมของทั้งสองช่วงคลื่น เพื่อปรับให้เป็นลักษณะการกระจายแบบปกติ เพื่อให้การแปรผลทำได้ง่ายขึ้น NDVI นิยมใช้ในการตรวจด้วยความสมบูรณ์ของป่าไม้ หรือพืชพรรณ เพื่อประเมินว่าพื้นที่ที่ทำการวิเคราะห์มีพืชพรรณสีเขียวหนาแน่นมากน้อยเพียงใด [6] NDVI มีค่าอยู่ระหว่าง -1.0 ถึง +1.0 บริเวณที่ค่า NDVI อยู่ในช่วงค่าลบพื้นที่จะเป็นผืนน้ำ หรือทะเล ในบริเวณที่มีค่า NDVI เข้าใกล้ค่า 0 แสดงถึงพื้นที่ที่มีพืชพรรณสีเขียวน้อย และหากค่า NDVI มีค่าเข้าใกล้ +1.0 แสดงถึงพื้นที่ที่พืชสีเขียวปกคลุมมาก

2.1.4 โครงข่ายประสาทเทียม

(Artificial Neural Network: ANN)

โครงข่ายประสาทเทียมเป็นแนวความคิดที่ต้องการให้คอมพิวเตอร์มีความสามารถในการเรียนรู้ เมื่อมีข้อมูล โครงข่ายประสาทเทียมประกอบไปด้วย เชตของโหนดและเส้นเชื่อมระหว่างโหนด สามารถแบ่งโหนดเป็น 3 ระดับได้แก่ โหนดในชั้นอินพุต (Input Layer) มีจำนวนเท่ากับจำนวนคุณสมบัติ (Attribute) ที่ใช้อธิบายข้อมูลแต่ละตัว โหนดในชั้นเอ้าท์พุต (Output Layer) มีจำนวนเท่ากับจำนวนกลุ่มหรือจำนวนประเภทของข้อมูลที่ต้องการจำแนก โหนดในชั้นซ่อน (Hidden Layer) ในแต่ละชั้นอาจมีได้มากกว่า 1 ชั้น จำนวนชั้นและจำนวนโหนดจะขึ้นอยู่กับผู้ออกแบบ โดยต้องทดลองหลาย ๆ แบบแล้วพิจารณาว่าแบบใดให้ประสิทธิภาพที่ดีที่สุด

ในโครงข่ายจะมีเส้นเชื่อมจากทุกโหนดในชั้นอินพุตไปยังทุกโหนดในชั้นซ่อนและมีเส้นเชื่อมจากทุกโหนดในชั้นซ่อนไปยังทุกโหนดในชั้นเอ้าท์พุต ในแต่ละโหนดจะมีค่า Bias (b) เส้นเชื่อมแต่ละเส้นมีค่าน้ำหนัก (Weight) การทำงานของแต่ละโหนดเทียบได้กับ

เซลล์ประสาทในสมองมนุษย์ 1 เซลล์ อินพุตที่เข้าสู่โหนดจะเป็นเวกเตอร์ของคุณสมบัติของข้อมูลตัวอย่าง มีค่า $p = [p_1, p_2, \dots, p_R]$ มีจำนวน R องค์ประกอบ (คอลัมน์) และเวกเตอร์น้ำหนัก $W = [w_1, w_2, \dots, w_R]$ นำอินพุตมาคูณกับน้ำหนักของแต่ละเส้นเชื่อม ผลที่ได้จากอินพุตทุกๆ เส้นเชื่อมของโหนดจะนำมารวมกันแล้วส่งต่อไปยังฟังก์ชันถ่ายโอน (Transfer Function) ซึ่งเกิดเป็นค่าเอ้าท์พุต a ในที่นี้ f เป็นฟังก์ชันถ่ายทำหน้าที่รับค่าอินพุต t เพื่อเปลี่ยนเป็นค่าเอ้าท์พุต a ค่าเอ้าท์พุต a สามารถคำนวณค่าเอ้าท์พุต a [7] ได้จาก $a = f(Wp + b)$ เมื่อ $n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b$ ดังนั้น $n = Wp + b$

การค้นหาค่าน้ำหนักของเส้นเชื่อมแต่ละเส้นที่เหมาะสมที่ทำให้สามารถจำแนกประเภทของข้อมูลตัวอย่างที่ใช้สอน (Training Data) ได้ถูกต้องมากที่สุด เป็นการสอนโครงข่ายประสาทเทียมให้เรียนรู้ ค่าน้ำหนักจะทำการปรับจนกว่าค่าความผิดพลาดจะน้อยลงหรืออยู่ในเกณฑ์ที่ยอมรับ

สิ่งสำคัญคือต้องทราบค่า Weight สำหรับสิ่งที่ต้องการให้โครงข่ายเรียนรู้ ซึ่งเป็นค่าที่ไม่แน่นอน แต่สามารถกำหนดให้โครงข่ายปรับค่าเหล่านี้ได้โดยการสอนให้รู้จักรูปแบบ (Pattern) ของสิ่งที่ต้องการให้รู้จำเรียกว่า “Back Propagation” ถ้าโครงข่ายประสาทเทียมให้ค่าเอ้าท์พุตผิด

2.1.5 การแบ่งกลุ่มข้อมูลแบบเคมิน

(K-means Clustering)

เป็นการจัดให้ข้อมูลที่มีลักษณะคล้ายกันมาไว้ด้วยกัน ใช้สำหรับการแบ่งข้อมูลจำนวน n เป็น k กลุ่ม [8] ขั้นแรกจะรับค่าพารามิเตอร์ k ซึ่งค่านี้คือจำนวน Cluster ที่ต้องการค้นหา จากนั้นกำหนดจุดศูนย์กลาง (Centroid) ขั้นตอนต่อไปคือสร้างกลุ่มข้อมูลและความสัมพันธ์กับจุดศูนย์กลางที่ใกล้กันมากที่สุด ซึ่งจุดแต่ละจุดแทนด้วยข้อมูลหนึ่งตัว โดยแต่ละจุดจะถูกกำหนดกลุ่มไปยังจุดศูนย์กลางที่ใกล้ที่สุดจนครบหมดทุกจุด และคำนวณจุดศูนย์กลางใหม่ โดยการหา

ค่าเฉลี่ยทุกจุดที่อยู่ในกลุ่ม หากจุดศูนย์กลางในแต่ละกลุ่มถูกเปลี่ยนตำแหน่ง จะได้จุดที่มีความสัมพันธ์กับกลุ่มใหม่และใกล้กับจุดศูนย์กลางใหม่ ทำขึ้นไปเรื่อยๆ จนกว่าทั้งจุดศูนย์กลางไม่มีการเปลี่ยนแปลง

2.1.6 ค่าสัมประสิทธิ์การตัดสินใจ

(Coefficient of Determination: R^2)

ค่าสัมประสิทธิ์การตัดสินใจ เป็นค่าที่บอกรถึงความสัมพันธ์ระหว่างตัวแปรตามกับตัวแปรอิสระว่ามีความสัมพันธ์กันมากน้อยเพียงใด ค่าสัมประสิทธิ์การตัดสินใจมีค่าตั้งแต่ 0-1 ถ้าค่า R^2 มีค่าเข้าใกล้ 1 แสดงว่าตัวแปรอิสระและตัวแปรตามมีความสัมพันธ์กันมาก ในเชิงเส้นตรง คำนวนได้จากสูตร

$$R^2 = \frac{(N \sum XY - (\sum X)(\sum Y))^2}{(N \sum X^2 - (\sum X)^2)(N \sum Y^2 - (\sum Y)^2)} \quad (1)$$

โดยที่

X, Y = ตัวแปรที่พิจารณา

N = จำนวนข้อมูลทั้งหมด

2.1.7 ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Squared Error: RMSE)

ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยใช้ในการประเมินความผิดพลาดในการคาดการณ์ ปริมาณน้ำท่า ถ้าค่า RMSE ยิ่งน้อยหมายถึงการคาดการณ์ยิ่งแม่นยำ สามารถคำนวนได้ดังสมการต่อไปนี้

$$RMSE = \sqrt{\left(\frac{\sum(T_i - O_i)^2}{N} \right)} \quad (2)$$

โดยที่

T_i = ค่าของข้อมูลน้ำท่าจริง

O_i = ค่าของข้อมูลน้ำท่าที่คาดการณ์

N = จำนวนข้อมูลทั้งหมด

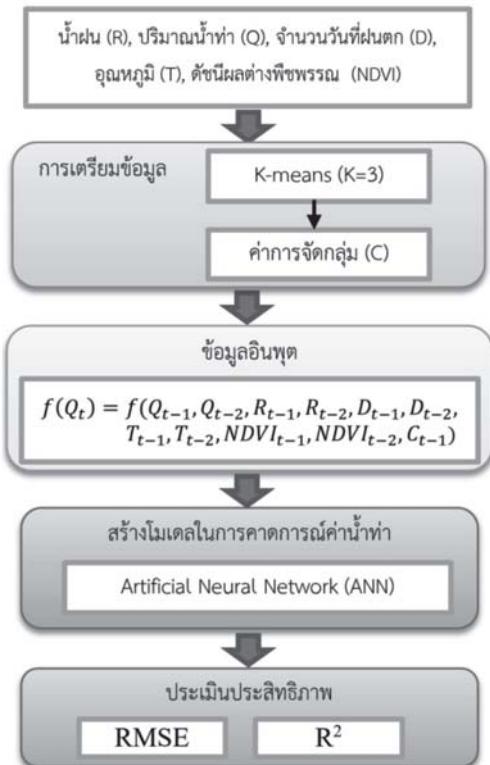
2.2 ขั้นตอนการดำเนินงาน

งานวิจัยนี้ใช้ข้อมูลอุณหภูมิ ปริมาณน้ำฝน และ

ปริมาณน้ำท่าเฉลี่ย ปริมาณน้ำฝน จำนวนวันที่ฝนตก และอุณหภูมิรายเดือน โดยเป็นข้อมูลที่เกี่ยวข้องกับสถานีน้ำท่า M.145 ที่ตั้งอยู่ในจังหวัดนครราชสีมา ซึ่งเป็นบริเวณลุ่มน้ำมูล จากศูนย์อุทกવิทยาชลประทานภาคตะวันออกเฉียงเหนือตอนล่าง (ดาวน์โหลดข้อมูลได้จาก www.hydro-4.com) และใช้ข้อมูลด้านนี้ผลิต่างพื้นที่พิจารณาจากดาวเทียม NOAA STAR - Global Vegetation Health Products (ดาวน์โหลดข้อมูลจาก www.star.nesdis.noaa.gov) โดยจะใช้ข้อมูลที่เก็บรวบรวม 15 ปีตั้งแต่ปี พ.ศ. 2543 ถึง พ.ศ. 2557 โดยในขั้นตอนแรกจะนำข้อมูลทั้งหมดได้แก่ ปริมาณน้ำฝน จำนวนวันที่ฝนตก อุณหภูมิ ปริมาณน้ำท่า ดัชนีผลต่างพื้นที่พิจารณา ซึ่งเป็นข้อมูลที่ผ่านการลดความชี้ช่องของข้อมูลด้วยวิธีการรวมมัลไลเซชัน มาทำการจัดกลุ่มด้วยอัลกอริทึม k-means โดยอยู่ในสมมติฐานที่ว่าข้อมูลส่วนมากจะแบ่งเป็นข้อมูลที่มีค่าต่ำปานกลาง และสูง จึงจัดกลุ่มเป็น $k=3$ หลังจากนั้นจะนำค่าดัชนีผลต่างพื้นที่พิจารณา ปริมาณน้ำฝน ปริมาณน้ำท่า จำนวนวันที่ฝนตก และอุณหภูมิที่เวลาเย็นหลังหนึ่งและสองเดือนร่วมกับค่าการจัดกลุ่มที่เวลาเย็นหลังหนึ่งเดือน แล้วนำไปสร้างโมเดลการคาดการณ์ด้วยโครงข่ายประสาทเทียม โดยจะสับบการใช้ข้อมูลในการสร้างโมเดลเพื่อพิจารณาว่าควรใช้ข้อมูลใดในการสร้างโมเดลในการทำนายปริมาณน้ำท่าให้ประสิทธิภาพดีที่สุด กล่าวคือ ถ้าต้องการคาดการณ์ค่าน้ำท่าเดือนมีนาคม จะทำการสร้างโมเดลการคาดการณ์โดยใช้ค่าดัชนีผลต่างพื้นที่พิจารณา ปริมาณน้ำฝน ปริมาณน้ำท่า จำนวนวันที่ฝนตก และอุณหภูมิที่เดือนมกราคมและเดือนกุมภาพันธ์ ส่วนค่าการจัดกลุ่มจะใช้ที่เดือนกุมภาพันธ์เพื่อนำไปใช้ในการสร้างโมเดลการคาดการณ์ด้วยโครงข่ายประสาทเทียม

ในการวิจัยนี้จะใช้โครงข่ายประสาทเทียมแบบการแพร่ย้อนกลับ (Back-propagation Algorithm) ใช้จำนวนขั้นในขั้นชั้น 1 ขั้น ทำการเลือกจำนวนโน๊ตภายในขั้นชั้นตั้งแต่ 1-10 และเลือกใช้จำนวนโน๊ต

ที่ให้ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (RMSE) ที่น้อยที่สุดกับการคาดการณ์ค่าน้ำท่าในชุดข้อมูลฝึกสอน



รูปที่ 1 กรอบแนวคิดของงานวิจัย

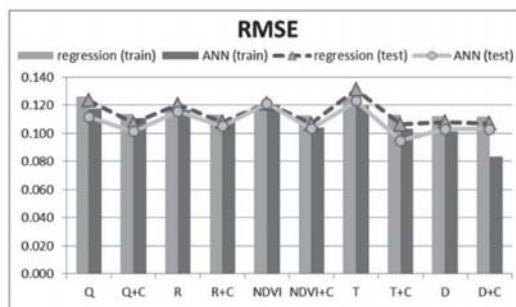
นอกจากนี้เปรียบเทียบประสิทธิภาพด้วยการวิเคราะห์การถดถอยเชิงเส้น และใช้พารามิเตอร์ตัวอื่น ๆ ในการสร้างโมเดลการคาดการณ์ปริมาณน้ำท่าได้แก่ ปริมาณน้ำฝนรายเดือน (R) จำนวนวันที่ฝนตกในแต่ละเดือน (D) และปริมาณน้ำท่ารายเดือน (Q) ที่เวลา y องศา 1 เดือนและ 2 เดือน ($t-1, t-2$) การทดลองนี้ใช้มาตรวัดทางสถิติคือ ค่าสัมประสิทธิ์การตัดสินใจ (R^2) ซึ่งใช้แสดงความสัมพันธ์ระหว่างค่าน้ำท่าจริงกับค่าที่คาดการณ์ และใช้ค่า根ที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) ซึ่งเป็นค่าที่แสดงความผิดพลาดของการคาดการณ์โดยกรอบแนวคิดของงานวิจัยนี้สามารถแสดงดังรูปที่ 1

3. ผลการศึกษาและอภิปรายผล

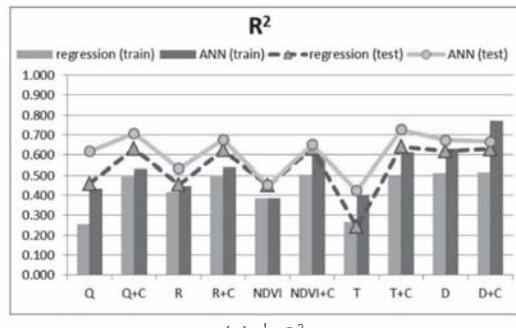
ในขั้นตอนแรกจะใช้อินพุตเป็นพารามิเตอร์ 1 ชนิด เปรียบเทียบกับการใช้ค่าการจัดกลุ่มร่วมด้วย เพื่อจะแสดงการทดสอบว่าค่าการจัดกลุ่มนี้ผลต่อประสิทธิภาพการคาดการณ์น้ำท่า จากรูปสร้างแบบจำลองการคาดการณ์น้ำท่าด้วยโครงข่ายประสาทเทียม (ANN) และ การวิเคราะห์การถดถอยเชิงเส้น (Linear Regression: LR) เปรียบเทียบประสิทธิภาพการคาดการณ์ด้วยมาตรวัดทางสถิติด้วยการหาค่า R^2 และ RMSE ผลการทดลองแสดงในตารางที่ 1 และกราฟแสดงในรูปที่ 2

ตารางที่ 1 ใช้พารามิเตอร์ 1 ชนิดและผลการเพิ่มค่าการจัดกลุ่มเพื่อใช้คาดการณ์น้ำท่า (ข้อมูลฝึกสอน)

Parameters	Hidden Nodes	Test Data			
		RMSE		R^2	
		LR	ANN	LR	ANN
Q	9	0.123	0.111	0.459	0.618
Q+C	9	0.107	0.101	0.631	0.707
R	6	0.12	0.115	0.453	0.533
R+C	6	0.108	0.105	0.623	0.677
NDVI	7	0.121	0.121	0.451	0.451
NDVI+C	7	0.107	0.103	0.631	0.651
T	7	0.131	0.123	0.242	0.423
T+C	7	0.106	<u>0.095</u>	0.642	<u>0.727</u>
D	6	0.108	0.103	0.620	0.673
D+C	6	0.107	0.103	0.630	0.667



(ก) ค่า RMSE



(ข) ค่า R^2

รูปที่ 2 กราฟการทดลองใช้พารามิเตอร์ 1 ชนิด และ การเพิ่มค่าการจัดกลุ่มของข้อมูลฝึกสอน (กราฟแท่ง) และข้อมูลทดสอบ (กราฟเส้น) ในรูป (ก) แสดงค่า RMSE (ข) และค่า R²

ตารางที่ 2 ผลการใช้พารามิเตอร์ 2 ชนิดร่วมกับค่าการจัดกลุ่มเพื่อใช้พยากรณ์ (ข้อมูลฝึกสอน)

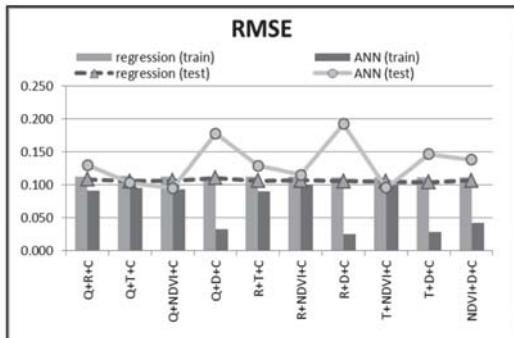
Parameters	Hidden Nodes	Test Data			
		RMSE		R ²	
		LR	ANN	LR	ANN
Q+R+C	8	0.109	0.13	0.615	0.409
Q+T+C	9	0.106	0.103	0.644	0.653
Q+NDVI+C	2	0.107	0.095	0.632	0.711
Q+D+C	10	0.111	0.178	0.595	0.498
R+T+C	9	0.107	0.129	0.638	0.519
R+NDVI+C	6	0.107	0.116	0.629	0.545
R+D+C	10	0.106	0.193	0.642	0.419
T+NDVI+C	3	0.105	<u>0.096</u>	0.66	<u>0.743</u>
T+D+C	10	0.104	0.147	0.655	0.532
NDVI+D+C	9	0.107	0.138	0.629	0.458

จากตารางที่ 1 เมื่อใช้พารามิเตอร์ 1 ชนิดที่ เวลาյ้อนหลัง 1 เดือนและ 2 เดือน ร่วมกับค่าการจัดกลุ่มที่เวลา�้อนหลัง 1 เดือน ให้ค่า RMSE ลดลง และ ค่า R² เพิ่มขึ้นในทุกพารามิเตอร์ ซึ่งแสดงให้เห็นว่า หากใช้ค่าการจัดกลุ่มร่วมกับพารามิเตอร์อื่น สามารถเพิ่มประสิทธิภาพการพยากรณ์ได้ดี ดังนั้นจึงทดลองการใช้พารามิเตอร์ 2 ชนิด ร่วมกับค่าการจัดกลุ่ม ซึ่งแสดงในตารางที่ 2 โดยที่ ANN ให้ค่า RMSE=0.095 และค่า R²= 0.727

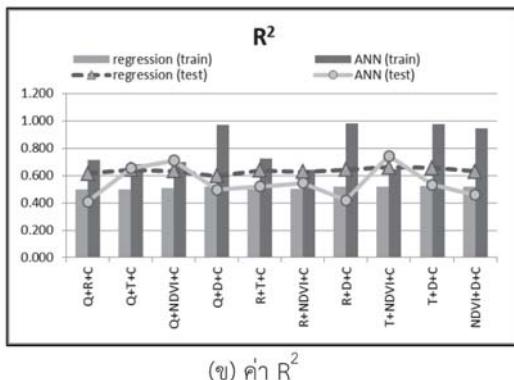
รูปที่ 2 แสดงให้เห็นว่าในข้อมูลฝึกสอนและ ข้อมูลทดสอบมีค่า RMSE และค่า R² ไปในทิศทางเดียวกัน เนื่องจากการทดลองตารางที่ 1 แสดงให้เห็น ว่าเมื่อใช้ค่าการจัดกลุ่มสามารถเพิ่มประสิทธิภาพการพยากรณ์ได้ ดังนั้นจึงทดลองการใช้พารามิเตอร์ 2 ชนิด ร่วมกับค่าการจัดกลุ่ม ซึ่งแสดงในตารางที่ 2

จากตารางที่ 2 เมื่อใช้ค่าอุณหภูมิ และดัชนี ผลต่างพืชพรรณ ร่วมกับค่าการจัดกลุ่ม (T+NDVI+C) ที่ ANN มีประสิทธิภาพดีที่สุดในข้อมูลทดสอบโดยให้ ค่า RMSE = 0.096 และ R² = 0.743 Regression ให้ ประสิทธิภาพการพยากรณ์โดยพิจารณาจาก RMSE ไม่แตกต่างจากการใช้พารามิเตอร์ 1 ชนิดแต่ใน R² มีค่า สูงตั้งแต่ 0.6 ขึ้นไปในทุกกรณี

เมื่อนำผลการทดลองมาแสดงเป็นกราฟใน รูปที่ 3 จะเห็นว่ารูปที่ 3 (ก) ค่า RMSE และรูปที่ 4 (ข) ค่า R² ที่ ANN เกิดปัญหาการ Overfitting ชัดเจน ในกรณี Q+D+C, R+D+C และ NDVI+D+C กล่าว คือการที่โน้มเดลที่ได้จากการใช้ชุดข้อมูลฝึกสอนให้ ประสิทธิภาพการพยากรณ์สูง แต่เมื่อนำโน้มเดลไปใช้ กับชุดข้อมูลทดสอบให้ประสิทธิภาพการพยากรณ์ต่ำ จะสังเกตเห็นว่าในทุกกรณีเมื่อใช้ D+C จะทำให้เกิด ปัญหา Overfitting ดังนั้นผลการทดลองต่อไปจะใช้ พารามิเตอร์ Q, T, NDVI, R และ C เป็นพารามิเตอร์ ในการทดลองต่อไป เพราะไม่มีแนวโน้มทำให้เกิด ปัญหา Overfitting และจะไม่ใช้ D+C ผลการทดลองใช้ พารามิเตอร์ 3 ชนิดและ 4 ชนิดร่วมกับค่าการจัดกลุ่ม แสดงในตารางที่ 3



(ก) ค่า RMSE

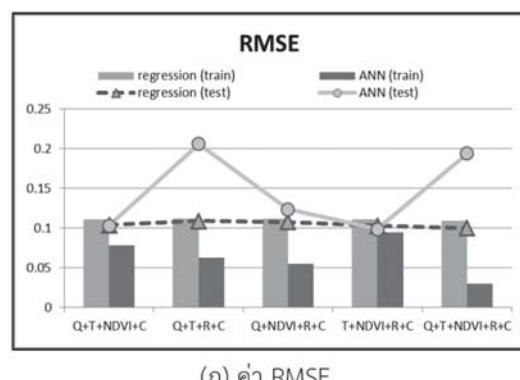
(ข) ค่า R^2

รูปที่ 3 กราฟการใช้พารามิเตอร์ 2 ชนิด ร่วมกับค่าการจัดกลุ่มของข้อมูลฝึกสอน (กราฟแท่ง) และข้อมูลทดสอบ (กราฟเส้น) ในรูป (ก) แสดงค่า RMSE (ข) และค่า R^2

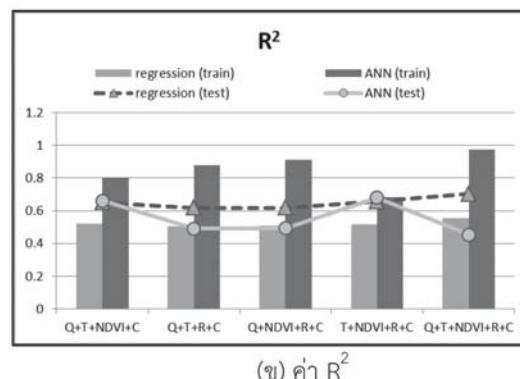
ตารางที่ 3 การใช้พารามิเตอร์ 3 และ 4 ชนิดร่วมกับค่าการจัดกลุ่มเพื่อใช้พยากรณ์ (ข้อมูลฝึกสอน)

Parameters	Hidden Nodes	Test Data			
		RMSE		R^2	
		LR	ANN	LR	ANN
Q+T+NDVI+C	7	0.104	0.103	0.652	0.661
Q+T+R+C	10	0.109	0.206	0.617	0.491
Q+NDVI+R+C	10	0.108	0.124	0.617	0.494
T+NDVI+R+C	8	0.103	0.099	0.658	0.681
Q+T+NDVI+R+C	10	0.100	0.194	0.702	0.453

จากตารางที่ 3 เมื่อใช้ $T+NDVI+R+C$ มีประสิทธิภาพดีที่สุดที่ ANN ในข้อมูลทดสอบให้ค่า RMSE=0.099 และ $Q+T+NDVI+R+C$ ให้ค่า $R^2=0.702$ มีประสิทธิภาพดีที่สุดที่ ANN และจากรูปที่ 4 จะเห็นว่าเกิดปัญหาการ Overfitting ที่ ANN ยกเว้นกรณี $T+NDVI+R+C$ และประสิทธิภาพการพยากรณ์น้ำท่าไม่ดีกว่าการใช้พารามิเตอร์ 2 ชนิดร่วมกับค่าการจัดกลุ่ม ($T+NDVI+C$) ที่แสดงในตารางที่ 2



(ก) ค่า RMSE



รูปที่ 4 กราฟการใช้พารามิเตอร์ 3 และ 4 ชนิด ร่วมกับค่าการจัดกลุ่มของข้อมูลฝึกสอน (กราฟแท่ง) และข้อมูลทดสอบ (กราฟเส้น) ในรูป (ก) และค่า RMSE (ข) และค่า R^2

จากการทดลองทั้งหมดแสดงให้เห็นว่าเมื่อใช้ ANN ในการสร้างแบบจำลองมีประสิทธิภาพดีที่สุด โดยใช้อินพุตเป็น T+NDVI+C ที่ชุดข้อมูลทดสอบให้ค่า RMSE = 0.096 และ R² = 0.743 (แสดงในตารางที่ 2) และไม่เกิดปัญหาการ Overfitting ส่วนในการสร้างแบบจำลองด้วย Regression การคาดการณ์น้ำท่าให้ประสิทธิภาพดีที่สุดเมื่อใช้ Q+T+NDVI+R+C ในชุดข้อมูลทดสอบโดยให้ค่า RMSE = 0.100 และ R² = 0.702 (แสดงในตารางที่ 3) และไม่เกิดการ Overfitting จะเห็นว่าเมื่อใช้ ANN ให้ประสิทธิภาพดีที่สุดในการทดลองนี้และมีประสิทธิภาพการคาดการณ์น้ำท่าดีกว่า Regression นอกจากนี้ยังแสดงให้เห็นว่าการเลือกใช้พารามิเตอร์ในการสร้างโมเดลในการทำนายมีผลต่อความถูกต้องของการทำนาย

4. สรุป

การคาดการณ์น้ำท่าถือเป็นข้อมูลสำคัญที่สามารถช่วยให้สามารถบังคับกันปัญหาที่เกิดจากน้ำได้แก่น้ำท่วม และการขาดแคลนน้ำ กล่าวคือถ้าเราสามารถรู้ปริมาณน้ำท่าหรือปริมาณน้ำในแม่น้ำได้ล่วงหน้า ทำให้สามารถรู้ว่าจะเกิดปัญหาเกี่ยวกับน้ำขึ้นในอนาคตหรือไม่ ทำให้มีการวางแผนรับมือกับปัญหาที่จะเกิดขึ้นในอนาคตได้ งานวิจัยนี้เสนอการสร้างโมเดลคาดการณ์ค่าปริมาณน้ำท่าด้วยโครงข่ายประสาทเทียมโดยการทดลองใช้ค่าอุณหภูมิ (T) และตัวนิผลต่างพืชพรรณ (NDVI) ปริมาณน้ำฝน (R) จำนวนวันที่ฝนตก (D) และปริมาณน้ำท่า (Q) ที่เวลา y ชั่วโมงหลัง 1 และ 2 เดือน (t-1 และ t-2) รวมกับค่าการจัดกลุ่ม (C) ที่เวลา y ชั่วโมงหลัง 1 เดือน (t-1) เพื่อแสดงให้เห็นว่าการเลือกใช้พารามิเตอร์ในการสร้างโมเดลมีผลต่อการทำนาย การใช้ค่าการจัดกลุ่มเพื่อเพิ่มประสิทธิภาพของการทำนายค่าน้ำท่า และค่าการสำรวจน้ำที่สามารถใช้ในการทำนายน้ำท่าได้ การประเมินประสิทธิภาพโดยใช้วิธีทางสถิติ 2 ชนิดคือค่า RMSE ที่แสดงความผิดพลาดของการคาดการณ์ปริมาณน้ำท่าและ R² เพื่อ

ดูความสัมพันธ์ระหว่างค่าน้ำท่าจริงกับค่าน้ำท่าที่ได้จากการคาดการณ์ นอกจากนี้ยังเปรียบเทียบประสิทธิภาพกับการสร้างแบบจำลองด้วยสมการตัดถอย

ผลการทดลองสรุปได้ว่าเมื่อใช้การจัดกลุ่มร่วมกับพารามิเตอร์อื่น ๆ เพื่อสร้างโมเดลคาดการณ์ปริมาณน้ำท่าสามารถเพิ่มประสิทธิภาพการคาดการณ์ได้ และเมื่อใช้ค่าตัวนิผลต่างพืชพรรณ รวมกับอุณหภูมิ และค่าการจัดกลุ่ม (NDVI+T+C) สร้างโมเดลด้วยโครงข่ายประสาทเทียม ให้ประสิทธิภาพดีที่สุดโดยให้ค่า RMSE=0.09 และ R²=0.743 (แสดงในตารางที่ 2) จะเห็นว่าการใช้ข้อมูลการสำรวจจะระยะใกล้ด้วยตัวนิผลต่างพืชพรรณ และค่าการจัดกลุ่มจาก k-means สามารถนำมาใช้ในการสร้างโมเดลคาดการณ์ค่าปริมาณน้ำท่าได้ และการสร้างโมเดลด้วยโครงข่ายประสาทเทียมเป็นวิธีการที่มีการคำนวณที่ซับซ้อน การเลือกใช้พารามิเตอร์ในการสร้างโมเดลที่ใช้ในการคาดการณ์ค่าปริมาณน้ำท่ามีประสิทธิภาพ และสามารถบังคับการเกิดปัญหาการ Overfitting จำนวนพารามิเตอร์และการเลือกใช้พารามิเตอร์ไม่เหมาะสม และพารามิเตอร์ที่เลือกใช้จะต้องมีความสัมพันธ์กับค่าที่คาดการณ์ ถ้าเราเลือกใช้พารามิเตอร์ไม่เหมาะสมจะทำให้ไม่เดลคาดการณ์น้ำท่าจากโครงข่ายประสาทเทียมคาดการณ์ปริมาณน้ำท่าผิดพลาด

นอกจากนี้ข้อมูลปริมาณน้ำฝนและน้ำท่าที่ใช้ทำการทดลองในงานวิจัยนี้ใช้แค่หนึ่งสถานี หากทำการทดลองเพิ่มโดยนำข้อมูลปริมาณน้ำฝนและน้ำท่าจากสถานีข้างเคียงมาพิจารณา หรือต้องการวิธีการเลือกพารามิเตอร์ที่เหมาะสมในการสร้างโมเดลคาดการณ์ปริมาณน้ำท่าอาจจะช่วยให้เพิ่มประสิทธิภาพการคาดการณ์ปริมาณน้ำท่าได้ การทดลองต่อไปในอนาคตจะต้องทดลองกับข้อมูลน้ำท่าสถานีอื่นและลุ่มน้ำบริเวณอื่น เพื่อแสดงให้เห็นประสิทธิภาพของวิธีการที่นำเสนอ

5. เอกสารอ้างอิง

- [1] S. Riad, J. Mania, L. Bouchaou and Y. Najjar, "Rainfall-runoff model using an artificial neural network approach," *Mathematical and Computer Modelling*, vol. 40, no. 7, pp. 839-846, 2004.
- [2] A. R. Ghumman, Y. M. Ghazaw, A. R. Sohail and K. Watanabe, "Runoff forecasting by artificial neural network and conventional mode," *Alexandria Engineering Journal*, vol. 50, no. 4, pp. 345-350, 2011.
- [3] R. Modarres, "Multi-criteria validation of artificial neural network rainfall-runoff modeling," *Hydrology and Earth System Sciences*, vol. 13, no.3, pp. 411-421, 2009.
- [4] G. Sharm, Y.P. Mathur, S. K. Vyas, & P.K. Navin, "Rainfall-Runoff Regression Model for Meja Catchment," *International Journal of Inventions in Research, Engineering Science and Technology (IJIREST)*, vol. 1, no. 1, pp. 58-62, 2014.
- [5] F. Machado, M. Mine, E. Kaviski and H. Fill, "Monthly rainfall-runoff modelling using artificial neural networks," *Hydrological Sciences Journal-Journal des Sciences Hydrologiques*, vol. 56, no.3, pp. 349-361, 2011.
- [6] F.N. Kogan, "Vegetation index for a real analysis of crop conditions," in *Proceedings of the 18th Conference on Agricultural and Forest Meteorology*, AMS, W. Lafayette, Indiana, 15–18 September 1987, Indiana, USA, pp. 103–106.
- [7] Mark Hudson Beale, Martin T. Hagan and Howard B. Demuth, *Neural Network Toolbox™ User's Guide*: MathWorks Inc, 2015.
- [8] Alsabti Khaled, Sanjay Ranka and Vineet Singh, "An efficient k-means clustering algorithm," *Electrical Engineering and Computer Science*, 1997.