

Research Article

การสร้างแบบจำลองพารามิเตอร์รูปร่างของการแจกแจงค่าสุดขีดน้อยทั่วไป น้ำฝน-น้ำท่า ร่วมกับ ข้อมูลภาพถ่ายดาวเทียม ด้วยวิธีโครงข่ายประสาทเทียม

The Modeling Shape Parameter of The Generalized Extreme Value Distribution of Rainfall-Runoff with Satellite Images by Using Artificial Neural Network Approach

ทศพล ภูผิฟ้า¹ ชีรวงศ์ เหล่าสุวรรณ² ปิยภัทร บุษบาบดินทร์^{1*}

Tossapol Phoophiwa¹ Teerawong Loasuwan² Piyapatr Busababodhin^{1*}

¹ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยมหาสารคาม จังหวัดมหาสารคาม 44150 ประเทศไทย

¹Department of Mathematics, Faculty of Science, Mahasarakham University, Mahasarakham 44150, Thailand

²ภาควิชาฟิสิกส์ คณะวิทยาศาสตร์ มหาวิทยาลัยมหาสารคาม จังหวัดมหาสารคาม 44150 ประเทศไทย

²Department of Physics, Faculty of Science, Mahasarakham University, Mahasarakham 44150, Thailand

*E-mail: piyapatr.b@msu.ac.th

Received: 14/12/2021; Revised: 06/05/2022; Accepted: 27/05/2022

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อหาตัวแปรที่ส่งผลต่อการเปลี่ยนแปลงพารามิเตอร์รูปร่าง (Shape parameter) ของการแจกแจงค่าสุดขีดน้อยทั่วไป (Generalized Extreme Value: GEV) โดยขั้นตอนแรกจะพิจารณาจากค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation coefficient) และขั้นตอนต่อมาคือการสร้างแบบจำลองพารามิเตอร์รูปร่างภายใต้การแจกแจงค่าสุดขีดน้อยทั่วไป GEV พร้อมทั้งนำผลการศึกษาภาคการณืพื้นที่เสี่ยงต่อการเกิดอุทกภัยน้ำท่วมด้วยแผนที่ระดับการเกิดซ้ำ (Return level Map) ในการศึกษาครั้งนี้ผู้วิจัยได้รวบรวมข้อมูลดาวเทียม ข้อมูลอุตุนิยมวิทยา และข้อมูลอุทกวิทยา ของลุ่มน้ำชี ประกอบด้วย ดัชนีผลต่างพืชพรรณแบบนอัมัลไลซ์ (NDVI) ข้อมูลสภาพภูมิอากาศ ปริมาณน้ำฝน และข้อมูลน้ำท่าเป็นต้น ทั้งหมด 11 ปีย้อนหลัง (พ.ศ. 2553 ถึง พ.ศ. 2564) จากกรมอุตุนิยมวิทยาและสถานีเกษตรจำนวน 92 สถานี ครอบคลุมพื้นที่ 14 จังหวัดในลุ่มน้ำชี ภายใต้กระบวนการสร้างแบบจำลองพารามิเตอร์ผู้วิจัยได้เปรียบเทียบการประมาณค่าพารามิเตอร์ 2 กระบวนการ ได้แก่ แบบจำลองภายใต้กระบวนการคงที่ (Stationary process) ซึ่งจะใช้วิธีการประมาณค่าด้วยวิธีภาวะน่าจะเป็นสูงสุด (Maximum likelihood estimation: MLE) และแบบจำลองภายใต้กระบวนการไม่คงที่ (Non-stationary process) ซึ่งจะใช้วิธีการประมาณค่าด้วยวิธีโครงข่ายประสาทเทียม (Artificial neural network: ANN) ซึ่งได้สร้างแบบจำลองด้วยการแจกแจง GEV ภายใต้ทั้งสองกระบวนการ โดยใช้ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนเป็นข้อมูลตั้งต้น และทำการเปรียบเทียบประสิทธิภาพของแบบจำลอง ด้วยค่าสัมประสิทธิ์ Nash-Sutcliffe (Nash-Sutcliffe Efficiency: NSE) จากการศึกษาพบว่าแบบจำลองภายใต้กระบวนการไม่คงที่มีความเหมาะสม ทั้งหมด 59 สถานี แบ่งเป็น แบบจำลอง ANN-7 จำนวน 17 สถานี แบบจำลอง

ANN-10 จำนวน 27 สถานี และแบบจำลอง ANN-3 จำนวน 15 สถานี อย่างไรก็ตาม พบว่าแบบจำลองภายใต้กระบวนการคงที่มีความเหมาะสมทั้งหมด 33 สถานี เมื่อพิจารณาภาพรวมของค่า NSE เฉลี่ยของแต่ละแบบจำลอง พบว่ามีค่า NSE สูงกว่า 0.75 ทำให้สรุปได้ว่าแบบจำลองที่ได้ทั้ง 92 สถานี มีความแม่นยำสูง นอกจากนี้ยังพบว่าตัวแปรที่มีความสัมพันธ์กับพารามิเตอร์เบรูปร่างและเป็นองค์ประกอบที่ทำให้แบบจำลอง ANN มีประสิทธิภาพสูงขึ้นคือ ค่าดัชนีผลต่างพืชพรรณแบบนอร์มัลไลซ์ (NDVI) และ ปริมาณน้ำท่า เพื่อเป็นประโยชน์ต่อการนำผลการวิจัยไปประยุกต์ใช้ ผู้วิจัยได้สร้างแผนที่ 2 มิติ ของระดับการเกิดซ้ำในรอบปีการเกิดซ้ำ (Return period) 2 5 10 20 50 และ 100 ปี ตามลำดับ

คำสำคัญ: การแจกแจงค่าสุดขีดน้อยทั่วไป, โครงข่ายประสาทเทียม, ปริมาณน้ำท่า, ดัชนีผลต่างพืชพรรณแบบนอร์มัลไลซ์, ปริมาณน้ำฝน

Abstract

The objectives of this study are to: 1. determine the variables that affect the shape parameter of a generalized extreme value (GEV) distribution changes by considering the correlation coefficient; and 2. model the shape parameter of the GEV distribution to predict flood risk areas with a return level map. The data for this study was compiled from satellite and meteorological data from the Chi River Basin, including the Normalized Difference Vegetation Index (NDVI), climate data, Rainfall data, Runoff data, and so on. It was gathered from Meteorological Department (TMD) and 92 agricultural stations retrospectively (2010 to 2021). It covers an area of 14 provinces in the Chi River Basin. In this study, two parameter estimation processes were compared: stationary process (by maximum likelihood estimation : MLE) and non-stationary process (by artificial neural network : ANN), which were modeled with GEV distributions in both processes the monthly maximum rainfall data was used as the default data in both of them. In addition, Nash-Sutcliffe coefficient, or NSE, was used to compare the two models. The study revealed that the non-stationary model is suitable for 59 stations, categorized into the ANN-7 model of 17 stations, the ANN-10 model of 27 stations, and the ANN-3 model of 15 stations. However, the stationary model is suitable for only 33 stations. When considering the overall mean of the NSE values in each model, the NSE higher than 0.75. This could indicate that a total of 92 models were highly accurate. It was also found that the variables correlated with the shape parameters and made the ANN model more efficient were the NDVI and runoff. Therefore, the researcher created a 2D map of the recurrence levels in the return periods of 2, 5, 10, 20, 50 and 100 years, respectively, for further application.


Keywords: Generalized Extreme Value, Artificial Neural Network, Runoff, Normalized Difference Vegetation Index, Rainfall

บทนำ

สภาพภูมิอากาศที่เกิดขึ้นในปัจจุบันส่งผลกระทบต่อโดยตรงต่อการเปลี่ยนแปลงการกระจายตัวของปริมาณน้ำฝน และการเปลี่ยนแปลงอุณหภูมิเฉลี่ยในชั้นบรรยากาศ ความผันแปรทางสภาพภูมิอากาศ ซึ่งการเปลี่ยนแปลงทางสภาพภูมิอากาศดังกล่าวล้วนแต่ส่งผลกระทบต่อการจัดการทรัพยากรน้ำและอุทกวิทยา ซึ่งในภาคตะวันออกเฉียงเหนือของประเทศไทยเป็นพื้นที่ที่ได้รับความเสียหายอย่างมากจากการเกิดอุทกภัยและภัยแล้ง โดยสาเหตุสำคัญที่ทำให้เกิดอุทกภัยส่วนใหญ่ขึ้นอยู่กับสภาพพื้นที่และ ความผันแปรของธรรมชาติ แต่ในบางพื้นที่ การกระทำของมนุษย์ก็มีส่วนสำคัญในการทำให้เกิดภาวะการเกิด

อุทกภัยนั้นมีความรุนแรงเพิ่มมากขึ้นด้วย ในปัจจุบันปัญหา “น้ำท่วม” ในประเทศไทย ส่งผลกระทบต่อประชาชนในพื้นที่มากกว่า 4.5 ล้านคน พื้นที่เกษตรมากกว่า 7.5 ล้านไร่ ในรอบ 30 ปีที่ผ่านมา พบว่าโดยเฉลี่ยจะมีเหตุการณ์น้ำท่วมปีละ 9 ครั้ง ครอบคลุมพื้นที่ 63 จังหวัด (83% ของจังหวัดทั้งหมด) 532 อำเภอ (61% ของอำเภอทั้งหมด) 2,719 ตำบล (37% ของตำบลทั้งหมด) และ 17,867 หมู่บ้าน (24% ของหมู่บ้านทั้งหมด) โดยกระทบกับประชาชนเฉลี่ยปีละ 4.5 ล้านคน หรือประมาณ 7% ของประชากรทั้งหมดในทุกๆปี ขณะที่ในด้านความเสียหายด้านทรัพย์สินพบว่ามีบ้านเรือนเสียหายประมาณ 45,482 หลังต่อปี พื้นที่การเกษตรอีก 7.56 ล้านไร่ โดยดีเป็นมูลค่าความเสียหายทั้งหมด ปีละ 5,361 ล้านบาท ดังนั้น ความแม่นยำในการคาดการณ์การปริมาณน้ำฝนที่เสี่ยงต่อการเกิดอุทกภัยและภัยแล้ง จึงมีความสำคัญและเป็นประโยชน์อย่างมาก ในการวางแผนแนวทางการจัดการน้ำ เพื่อเตรียมรับมือกับปัญหาด้านที่จะเกิดขึ้นในอนาคต ข้อมูลจากสำนักข่าวออนไลน์ไทยพับลิก้า รวบรวมข้อมูลภัยพิบัติเพิ่มเติมจากศูนย์อำนวยการบรรเทาสาธารณภัย กรมป้องกันและบรรเทาสาธารณภัย กระทรวงมหาดไทย ย้อนหลังไป 30 ปีตั้งแต่ปี 2532-2561 (Thaipublica, 2019) ซึ่งในภาคตะวันออกเฉียงเหนือ มีพื้นที่การเกษตรมากกว่า 63 ล้านไร่ มีแม่น้ำสำคัญหลายสาย อาทิ แม่น้ำชี แม่น้ำมูล แม่น้ำสงคราม แม่น้ำพระเพลิง แต่ในปัจจุบันหลายพื้นที่ยังคงประสบปัญหาการขาดแคลนน้ำ ปัญหาภัยแล้ง และน้ำท่วมซ้ำซาก โดยเฉพาะอย่างยิ่งในพื้นที่ลุ่มแม่น้ำชีที่เกิดปัญหาน้ำท่วมซ้ำซาก จากรายงานของสำนักข่าวไทยพีบีเอส เมื่อวันที่ 30 กรกฎาคม พ.ศ. 2560 ได้รายงานถึงสถานการณ์ระดับน้ำในแม่น้ำชีที่เพิ่มสูงขึ้นอย่างต่อเนื่อง ไหลท่วมพื้นที่การเกษตรตลอดจนบ้านเรือนเสียหายจำนวนมาก ในหลายอำเภอที่ติดฝั่งแม่น้ำชี ได้แก่ จังหวัดชัยภูมิ ขอนแก่น กาฬสินธุ์ มหาสารคาม ร้อยเอ็ด บุรีรัมย์ ดังนั้น ความแม่นยำในการคาดการณ์การปริมาณน้ำฝนที่เสี่ยงต่อการเกิดอุทกภัย จึงมีความสำคัญและเป็นประโยชน์อย่างมาก ในการวางแผนแนวทางการรับมือกับอุทกภัย

การสร้างแบบจำลองเพื่ออธิบายลักษณะการเปลี่ยนแปลงของข้อมูลปริมาณน้ำฝนเนื่องจากข้อมูลมีค่าสูงสุดและค่าต่ำสุดเกิดขึ้น ข้อมูลลักษณะดังกล่าวเรียกว่า .ค่าสุดขีด (Extreme Value) ซึ่งมีจำนวนข้อมูลน้อยและอยู่ในส่วนของปลายหาง ดังนั้นข้อมูลในลักษณะนี้มักถูกตัดทิ้งไม่นำมาทำการวิเคราะห์หรือสร้างแบบจำลอง เนื่องจากมีความซับซ้อน (Busabodhin and Keawmun, 2015) โดยการวิเคราะห์ค่าสุดขีดถูกนำมาประยุกต์ใช้ในการวิเคราะห์เหตุการณ์ความรุนแรงของปรากฏการณ์ทางธรรมชาติ เช่น อุณหภูมิสุดขีด ความเร็วลมสูงสุด-ต่ำสุดสำหรับการศึกษาแบบจำลองในการพยากรณ์ปริมาณน้ำฝนสูงสุด พบว่าการแจกแจงค่าสุดขีดวางนัยทั่วไป (Generalized extreme value distribution: GEVD) เป็นการแจกแจงที่เหมาะสม (Busabodhin, 2017) ซึ่งการแจกแจงนี้มีพารามิเตอร์ทั้งหมด 3 ชนิด ได้แก่ พารามิเตอร์บ่งตำแหน่ง (Location Parameter) พารามิเตอร์บ่งขนาด (Scale Parameter) และพารามิเตอร์บ่งรูปร่าง (Shape Parameter) โดยมีพารามิเตอร์ที่สำคัญ คือ พารามิเตอร์บ่งรูปร่าง เนื่องจากพารามิเตอร์นี้จะเป็นสิ่งที่บ่งบอกว่าแบบจำลองใดเหมาะสมกับข้อมูลที่ศึกษาอยู่



รูปที่ 1 แผนที่ลุ่มแม่น้ำชีแสดงพิสัยขอบเขตการปกครองและเส้นทางน้ำ

ดังนั้นจึงได้มีนักวิจัยหลายคนศึกษาวิธีการประมาณค่าพารามิเตอร์บ่งรูปร่าง อาทิเช่น ในปี 2019 Hristos และคณะ ได้พยากรณ์พารามิเตอร์บ่งรูปร่าง จากข้อมูลขนาดใหญ่ของกลุ่มแม่น้ำในพื้นที่ของสหรัฐอเมริกาและพัฒนาแบบจำลองที่เหมาะสมกับพื้นที่แต่ละพื้นที่โดยใช้ แบบจำลองเส้นตรง และ แบบจำลอง Random forest เทียบกับวิธีอย่างง่าย (Naive Method) ที่ทำการพยากรณ์ค่าพารามิเตอร์บ่งรูปร่างโดยผลที่ได้จากการวิเคราะห์สรุปได้ว่ามีตัวแปรทางสภาพภูมิอากาศและข้อมูลเชิงพื้นที่ส่งผลต่อการเปลี่ยนแปลงของพารามิเตอร์บ่งรูปร่าง และแบบจำลองแบบใหม่ที่ได้เทียบกับแบบจำลองเดิมที่ค่าความแม่นยำสูงขึ้น 20% เมื่อใช้พารามิเตอร์บ่งที่เกิดจากการพยากรณ์ด้วยแบบจำลอง Random forest (Hristos et al. 2019) ในปีเดียวกันนี้ Haniyeh และคณะ ได้สร้างแบบจำลอง น้ำฝน-น้ำท่า ด้วยดัชนีเชื่อมโยงทางอุทกวิทยา (Index of Connectivity : IC) เป็นดัชนีที่บ่งบอกปริมาณและเส้นทางการไหลของน้ำท่าและ ดัชนีผลต่างพืชพรรณแบบนอร์มัลไลซ์ (Normalized Difference Vegetation Index : NDVI) เป็นดัชนีที่บ่งบอกระดับความหนาแน่นและความอุดมสมบูรณ์ของพืชพรรณ โดยใช้แบบจำลองโครงข่ายประสาทเทียม (ANN) พบว่าแบบจำลองมีประสิทธิภาพ 97% เมื่อใช้กับแม่น้ำ Houghton ในประเทศออสเตรเลีย (Haniyeh et al. 2019) และ (Tanutdech and Teerawong, 2019) ได้ศึกษาเกี่ยวกับ ดัชนี NDVI เพื่อความสัมพันธ์กับปริมาณน้ำฝนที่ได้จากสถานีตรวจวัดของกรมอุตุนิยมวิทยา พบว่า มีค่าอยู่ระหว่าง 80-97 ในพื้นที่ภาคตะวันออกเฉียงเหนือตอนล่างของประเทศไทย จากพารามิเตอร์บ่งรูปร่าง (Shape parameter) ของการแจกแจงค่าสุดขีดน้อยทั่วไป (GEV) สามารถแบ่งประเภทของการแจกแจงได้ 3 ลักษณะคือ เมื่อพารามิเตอร์บ่งรูปร่างเข้าใกล้ 0 เรียกว่า การแจกแจงกัมเบล (Gumbel Distribution) เมื่อมากกว่า 0 เรียกว่า การแจกแจงฟรีเชท (Fréchet Distribution) และ น้อยกว่า 0 เรียกว่า การแจกแจงไวบูลล์ (Weibull Distribution) (Coles, 2001; Busababodhin, 2018) ดังนั้นจากงานวิจัยข้างต้นทำให้ผู้วิจัยสนใจที่จะศึกษาการเปลี่ยนแปลงของสภาพภูมิอากาศจากข้อมูลสถานีตรวจวัดและภาพถ่ายดาวเทียมที่ส่งผลต่อพารามิเตอร์บ่งรูปร่าง ของการแจกแจง GEV เพื่อนำมาสร้างแบบจำลองพยากรณ์ค่าพารามิเตอร์บ่งรูปร่าง ด้วยวิธี โครงข่ายประสาทเทียม (Artificial Neural Network : ANN) และหาค่าระดับการเกิดซ้ำ (Return level) ของแบบจำลองเพื่อคาดการณ์พื้นที่ที่เสี่ยงต่อการเกิดอุทกภัย

วิธีการดำเนินการวิจัย

ในการดำเนินการวิจัยผู้วิจัยมีขั้นตอนทั้งหมด 7 ขั้นตอน รายละเอียดดังต่อไปนี้

1. การเตรียมข้อมูลในการวิเคราะห์มี 2 แบบ ดังนี้

1.1 ข้อมูลภาพถ่ายดาวเทียมโดยจะใช้ข้อมูลดัชนี NDVI และ ปริมาณน้ำฝนซึ่งเป็นข้อมูลภาพถ่ายดาวเทียมจากดาวเทียม Terra ระบบ MODIS จากผลิตภัณฑ์ MOD13Q1 Vegetation Indices (USGS, 2011)

1.2 ข้อมูลจากสถานีตรวจวัด กรมอุตุนิยมวิทยา ประกอบด้วยข้อมูล ปริมาณน้ำฝน อุณหภูมิ ความเร็วลม ความชื้นสัมพัทธ์ และกรมชลประทาน ประกอบด้วยข้อมูล ปริมาณน้ำท่า ปริมาณน้ำในเขื่อน ปริมาณการไหลของกระแสน้ำ เป็นต้น

1.3 การจัดการกับข้อมูลสูญหาย (missing)

1.3.1 ใช้หลักการ Multivariate Imputation by Chained Equations (MICE) ในการจัดการกับข้อมูลสูญหาย ซึ่งทำได้โดย การนำข้อมูลที่มีค่าในวันที่ตรงกันกับข้อมูลที่สูญหายในทุกปีมารวมกันแล้วหาค่าเฉลี่ยนำมาแทนค่าใส่ในข้อมูลที่มี missing ในวันที่เดียวกันของแต่ละปี และใช้แพ็คเกจ “missForest” และ “mice” ในโปรแกรม R ในการวิเคราะห์

1.3.2 ใช้การประมาณค่า IDW (Inverse Distance Weight) ในแพ็คเกจ การประมาณค่าในช่วง (Interpolation) โดยใช้ Q-GIS ซึ่งเป็นการประมาณค่าโดยทำการสุ่มจุดตัวอย่างแต่ละจุดจากตำแหน่งที่สามารถส่งผลกระทบไปยังเซลล์ที่ติดกองประมาณค่าได้ ซึ่งจะมีผลกระทบ น้อยลงเรื่อย ๆ ตามระยะทางที่ไกลออกไปเหมาะกับตัวแปรที่อ้างอิงกับระยะทางในการคำนวณ ยิ่งใกล้ยิ่งมีอิทธิพลมาก

2. ประมาณพารามิเตอร์รูปร่างของการแจกแจง GEV ด้วยวิธี MLE จากข้อมูลปริมาณน้ำฝนรายเดือน
3. หาค่าสหสัมพันธ์ (Correlation) ระหว่างพารามิเตอร์รูปร่าง (Shape parameter) กับข้อมูลตัวแปรอิสระเพื่อดูความสัมพันธ์ของตัวแปรอิสระ
4. สร้างแบบจำลองเพื่อหาค่าประมาณพารามิเตอร์รูปร่างของการแจกแจง GEV จากตัวแปรอิสระที่มีค่าสหสัมพันธ์ (Correlation) สูงกับพารามิเตอร์รูปร่าง ด้วย แบบจำลองโครงข่ายประสาทเทียม
5. การเปรียบเทียบประสิทธิภาพของแบบจำลองด้วยค่า MSE RMSE และ NSE โดยคำนวณจากค่าความผิดพลาดของแบบจำลอง
6. หาค่าระดับการเกิดซ้ำของแบบจำลองค่าสุดขีดและสร้างแผนที่ระดับการเกิดซ้ำ
7. สรุปผลและอภิปรายผล

ทฤษฎีที่เกี่ยวข้อง

1. การแจกแจงค่าสุดขี้นัยทั่วไป (Generalized Extreme Value Distribution: GEV)

การแจกแจง GEV ถูกพัฒนาขึ้นใน ค.ศ. 1955 โดย Jenkinson สามารถเขียนฟังก์ชันการแจกแจงค่าสุดขีดได้ 3 รูปแบบ ได้แก่ การแจกแจงกัมเบล (Gumbel Distribution) การแจกแจงฟรีเชท (Fréchet Distribution) และการแจกแจงไวบูลล์ (Weibull Distribution) (Coles, 2001; Busabodhin, 2018)

กำหนดให้ X_i เมื่อ $i = 1, 2, \dots, n$ เป็นตัวแปรสุ่มที่อิสระต่อกันและมีฟังก์ชันการแจกแจงสะสม $F(x; \theta)$ แบบเดียวกัน ค่าสูงสุดของตัวแปรสุ่ม คือ $X_{(n)} = \text{Max}(X_1, X_2, \dots, X_n)$ ซึ่งจะประยุกต์ใช้ในรูปแบบของการแจกแจงค่าสุดขีดวงนัยทั่วไปที่มีพารามิเตอร์ 3 พารามิเตอร์ ได้แก่ μ แทนพารามิเตอร์บอกตำแหน่ง (Location parameter) σ แทนพารามิเตอร์บอกขนาด (Scale parameter) และ ξ แทนพารามิเตอร์บอกรูปร่าง (Shape parameter) สามารถเขียนแทนด้วย $X \sim \text{GEV}(\mu, \sigma, \xi)$

2. แบบจำลองกระบวนการคงที่ (Stationary Process)

พิจารณาจากกระบวนการที่ไม่มีการเปลี่ยนแปลงของพารามิเตอร์ ดังนั้นค่าประมาณพารามิเตอร์ที่ได้จะเป็นค่าคงที่สำหรับ GEV ที่ประมาณค่าพารามิเตอร์ด้วยวิธี MLE จะมีโครงสร้างฟังก์ชันการแจกแจงความน่าจะเป็น (Probability Distribution Function: pdf) ดังนี้

$$f(x; \mu, \sigma, \xi) = \frac{1}{\sigma} \left[1 + \xi \left(\frac{x - \mu}{\sigma} \right) \right]^{\left(\frac{-1}{\xi} \right) - 1} \exp \left\{ - \left(1 + \xi \frac{x - \mu}{\sigma} \right)^{-1/\xi} \right\} \quad (1)$$

3. แบบจำลองกระบวนการไม่คงที่ (Non-stationary Process)

พิจารณาจากกระบวนการที่มีการเปลี่ยนแปลงของพารามิเตอร์ในรูปแบบเชิงเส้นตรง หรือไม่เชิงเส้นตรง ก็ได้ ดังนั้นค่าประมาณพารามิเตอร์ที่ได้จะอยู่ในรูปของฟังก์ชัน ในการศึกษาผู้วิจัยได้สร้างแบบจำลองนี้ด้วยวิธี โครงข่ายประสาทเทียม (ANN) เพื่อประมาณค่าพารามิเตอร์รูปร่าง สามารถสร้างฟังก์ชันการแจกแจงความน่าจะเป็น (Probability Distribution Function: pdf) ของ GEV ภายใต้กระบวนการไม่คงที่ (Non-stationary Process) ได้ดังนี้

$$f(x; \mu, \sigma, \xi(\text{ANN})) = \frac{1}{\sigma} \left[1 + \xi(\text{ANN}) \left(\frac{x - \mu}{\sigma} \right) \right]^{\left(\frac{-1}{\xi(\text{ANN})} \right) - 1} \exp \left\{ - \left(1 + \xi(\text{ANN}) \left(\frac{x - \mu}{\sigma} \right) \right)^{-1/\xi(\text{ANN})} \right\} \quad (2)$$

โดยที่ $\xi(ANV)$ คือ พารามิเตอร์รูปร่างที่ได้จากการประมาณค่าด้วยแบบจำลองโครงข่ายประสาทเทียม และสำหรับ $1 + \xi \left(\frac{x_i - \mu}{\sigma} \right) > 0$ ทั้งนี้ไม่ว่าจะเป็นการประมาณค่าพารามิเตอร์จากกระบวนการใดก็ตาม สามารถเขียนฟังก์ชันการแจกแจงค่าสุดขีดน้อยทั่วไปได้ 3 ลักษณะจากการพิจารณาค่าประมาณพารามิเตอร์รูปร่างร่วมกับช่วงความเชื่อมั่นของพารามิเตอร์รูปร่างสรุปได้ว่า เมื่อช่วงความเชื่อมั่นของพารามิเตอร์รูปร่างครอบคลุม 0 จะเรียกว่าการแจกแจงกัมเบล (Gumbel Distribution) เมื่อช่วงความเชื่อมั่นครอบคลุมค่าบวก เรียกว่า การแจกแจงฟรีเชต (Fréchet Distribution) และเมื่อช่วงความเชื่อมั่นครอบคลุมช่วงลบ เรียกว่า การแจกแจงไวบูลล์ (Weibull Distribution) (Coles, 2001; Busababodhin, 2018)

4. วิธีภาวน่าจะเป็นสูงสุด (Maximum Likelihood Estimation: MLE)

การประมาณค่าพารามิเตอร์จะใช้วิธีภาวน่าจะเป็นสูงสุด (Maximum Likelihood Estimation : MLE) ซึ่งมีขั้นตอนดังนี้ (Coles, 2001; Busababodhin, 2018)

ขั้นตอนที่ 1 พิจารณาฟังก์ชันการแจกแจงความน่าจะเป็น (Probability Density Function : PDF) จากสมการที่ 2

ขั้นตอนที่ 2 สร้างฟังก์ชันภาวน่าจะเป็น (Likelihood Function) ของฟังก์ชันการแจกแจงความน่าจะเป็น (Probability Density Function : PDF) ของ GEV ได้

$$L(\mu, \sigma, \xi) = \frac{1}{\sigma^n} \prod_{i=1}^n \left(1 + \xi \left(\frac{x - \mu}{\sigma} \right) \right)^{-\frac{1}{\xi} - 1} \exp \left(- \sum_{i=1}^n \left(1 + \xi \left(\frac{x - \mu}{\sigma} \right) \right)^{-\frac{1}{\xi}} \right) \quad (3)$$

ขั้นตอนที่ 3 สร้างฟังก์ชันลอกลักษณะน่าจะเป็น (Log-likelihood Function) ของฟังก์ชันการแจกแจงความน่าจะเป็น (Probability Density Function : PDF) ของ GEV ที่ได้จากขั้นตอน ได้ดังนี้

$$l(\mu, \sigma, \xi) = n \log \sigma - \left(1 - \frac{1}{\xi} \right) \sum_{i=1}^n \log \left(1 - \xi \left(\frac{x - \mu}{\sigma} \right) \right) - \sum_{i=1}^n \left(1 + \xi \left(\frac{x - \mu}{\sigma} \right) \right)^{-\frac{1}{\xi}} \quad (4)$$

ขั้นตอนที่ 4 นำฟังก์ชันลอกลักษณะน่าจะเป็น ที่ได้ไปหา Partial Derivation เทียบกับพารามิเตอร์แต่ละตัว แล้วกำหนดให้ มีค่าเป็นศูนย์ จากนั้นแก้สมการเพื่อหาค่าประมาณพารามิเตอร์

5. ระดับการเกิดซ้ำ (Return Level)

สำหรับการคาดการณ์การเกิดปริมาณน้ำฝนสูงสุดซ้ำในรอบปีการเกิดซ้ำต่าง ๆ ด้วยทฤษฎีค่าสุดขีด คือการคำนวณระดับการเกิดซ้ำ (Z_p) ซึ่งหมายถึงการหาข้อมูล ณ ตำแหน่ง p นั่นเอง เมื่อ p คือ ความน่าจะเป็นของเหตุการณ์ที่ $Z > \hat{Z}_p$ ดังนั้น ระดับการเกิดซ้ำ คือ ค่าคาดหวังที่จะเกิดเหตุการณ์ $Z > \hat{Z}_p$ อย่างน้อย 1 ครั้ง ใน ทุก ๆ T ปี 1 เมื่อ T คือ รอบปีการเกิดซ้ำที่มีความสัมพันธ์กับความน่าจะเป็นของเหตุการณ์ โดยที่ $T = 1/p$ สำหรับการแจกแจงค่าสุดขีดวงน้อยทั่วไป จะมีสมการระดับการเกิดซ้ำดังนี้ (Coles, 2001; Busababodhin, 2018)

$$\hat{Z}_T = \mu - \frac{\sigma}{\xi} \left\{ 1 - \left[-\log \left(1 - \frac{1}{T} \right) \right]^{-\xi} \right\} \quad (5)$$

6. โครงข่ายประสาทเทียม (Artificial Neural Networks - ANN)

โครงข่ายประสาทเทียมเป็นการสร้างแบบจำลองทางคณิตศาสตร์ที่ใช้การเรียนรู้จากประสบการณ์ด้วยข้อมูลในอดีต มาใช้สอนให้ระบบโครงข่ายเกิดการรู้จำ ซึ่งเป็นแนวคิดที่ถูกออกแบบให้ทำงานเช่นเดียวกับสมองมนุษย์ ที่ประกอบไปด้วย หน่วยประมวลผล (Processing Elements) ที่มีเซลล์หลายๆ ตัวที่ทำหน้าที่คล้ายกับเซลล์สมองของมนุษย์ โดยที่แต่ละเซลล์จะโยงใยติดต่อกันโดยส่งสัญญาณออกเป็นเอาต์พุต (Output) ของส่วนที่เรียกว่า เดนไดรต์ (Dendrites) และเมื่อผ่านกระบวนการประมวลผลจะได้เอาต์พุตออกมาในส่วนที่เรียกว่าแอกซอน (Axon) ในแต่ละเซลล์จะรับรู้ข้อมูลจากหลายทาง แล้วส่งต่อไปยังเซลล์อื่นๆ โดยใช้หลักการ Synaptic Strength ของการเชื่อมโยงเซลล์สมอง ส่วนวิธีการประมวลผลภายใน โดยเซลล์ประสาทแต่ละเซลล์จะมีจุดเชื่อมโยงระหว่างการทำงานเป็น 2 ลักษณะ คือ ลักษณะการกระตุ้น (Excitatory) เป็นการทำให้สัญญาณที่ส่งผ่านเข้ามามีความถี่ลดลง ซึ่งแบบจำลองของ ANN จะมีอัตราขยายหรือหดได้เมื่อกำหนดด้วยค่าถ่วงน้ำหนัก (Weights) สำหรับความสัมพันธ์ระหว่าง เซลล์ประสาทกับเซลล์ประสาทเทียมสามารถเขียนสมการได้ดังนี้ (Royal Irrigation Department, 2017)

$$Output = \left[\left(\sum_{i=1}^n (w_i x_i) + B \right) v_i \right] \varphi \quad (6)$$


โดยที่ x_i คือ ข้อมูลนำเข้า (Inputs data)

w_i คือ ค่าถ่วงน้ำหนักของแต่ละโหนดของปลายประสาท

B คือ ค่าความลำเอียง (Bias)

v_i คือ ค่าถ่วงน้ำหนักของ (Summing junction)

φ คือ ค่าสัมประสิทธิ์ฟังก์ชันกระตุ้น (Activation function)



รูปที่ 2 โครงสร้างของระบบโครงข่ายประสาทเทียม

7. สัมประสิทธิ์สหสัมพันธ์เพียร์สัน (Pearson product-moment correlation coefficient)

สัมประสิทธิ์สหสัมพันธ์เพียร์สัน เป็นวิธีที่ใช้วัดความสัมพันธ์ระหว่างตัวแปร หรือข้อมูล 2 ชุด โดยที่ ตัวแปร หรือข้อมูล 2 ชุดนั้นจะต้องอยู่ในรูปของข้อมูลในมาตราอันตรภาค (Interval scale) หรืออัตราส่วน (Ratio scale) และมีค่าตั้งแต่ -1 ถึง 1 ดังสมการที่ (8) (Pearson, 1920).

$$r = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 \sum (y - \bar{y})^2}} \quad (7)$$

โดยที่ ถ้า r มีค่าเข้าใกล้ 1 แสดงว่า มีความสัมพันธ์เชิงบวกและมีความสัมพันธ์มาก

ถ้า r มีค่าเข้าใกล้ -1 แสดงว่า มีความสัมพันธ์เชิงลบและมีความสัมพันธ์มาก

และถ้า เข้าใกล้ 0 แสดงว่าความสัมพันธ์กันน้อย

8. การเปรียบเทียบประสิทธิภาพของแบบจำลอง

การวิจัยครั้งนี้ได้เปรียบเทียบประสิทธิภาพของแบบจำลองด้วยสถิติ 3 ชนิด โดยที่แบบจำลองที่เหมาะสมที่สุดจะมีค่าที่คำนวณได้จากสมการที่ (9) และ (10) น้อย ในขณะที่แบบจำลองที่เหมาะสมที่สุดจะมีค่าที่คำนวณได้จากสมการที่ (10) เข้าใกล้ 1 รายละเอียดสถิติทั้ง 3 ชนิดเป็นดังนี้

8.1 ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean squared error : MSE)

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (8)$$

8.2 รากที่สองค่าเฉลี่ยความผิดพลาดกำลังสอง (Root mean squared error : RMSE)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (9)$$

8.3 การประเมินความเหมาะสมของแบบจำลองด้วยสัมประสิทธิ์ Nash-Sutcliffe (NSE)

ในปี 1970 Nash และ Sutcliffe ประเมินความเหมาะสมของแบบจำลองด้วย NSE ซึ่งเป็นการบอกความแม่นยำของแบบจำลอง (Model Accuracy) หรือประสิทธิภาพของแบบจำลอง (Model Performance) ซึ่งค่า NSE อยู่ในช่วงตั้งแต่ 0 ถึงค่ามากที่สุด คือ 1 โดยจะเปรียบเทียบค่าข้อมูลกับค่าพยากรณ์โดยใช้ตำแหน่งควอนไทล์เดียวกัน (Nash and Sutcliffe, 1970)

$$NSE = 1 - \frac{\sum_{x=1}^X (Q_x - Q_x^{pred})^2}{\sum_{x=1}^X (Q_x - \bar{Q}_x)^2} \quad (10)$$

โดยที่ Q_x หมายถึง ข้อมูลจริงที่ตำแหน่งควอนไทล์

Q_x^{pred} หมายถึง ค่าพยากรณ์ที่ตำแหน่ง ควอนไทล์

$\bar{Q}_x$ หมายถึง ค่าเฉลี่ยของข้อมูลจริง

X หมายถึง จำนวนข้อมูล

ผลการวิจัย

ในการศึกษาวิจัยการสร้างตัวแบบจำลองเพื่อหาค่าประมาณพารามิเตอร์บ่งรูปร่างของการแจกแจง GEV จากตัวแปรอิสระที่มีความสัมพันธ์กับพารามิเตอร์บ่งรูปร่าง ด้วย แบบจำลองโครงข่ายประสาทเทียม เนื่องจากเป็นแบบจำลองที่มีประสิทธิภาพสูงและเหมาะสมกับข้อมูลที่มีจำนวนมากอีกทั้งยังสามารถใช้ได้กับแบบจำลองเชิงเส้นและไม่เป็นเชิงเส้น โดยใช้ข้อมูล จากสถานีตรวจอากาศ อุตุณิยมวิทยา กรมอุตุนิยมวิทยา ข้อมูลน้ำท่าจาก กรมชลประทาน และข้อมูลภาพถ่ายดาวเทียม Terra-MODIS MOD13Q1 package (NDVI) ในระหว่างปี พ.ศ.2553 - 2564 โดยเลือกพื้นที่ลุ่มน้ำชีเป็นพื้นที่ศึกษา


1. การเตรียมข้อมูล คัดกรองข้อมูลตัวแปร เพื่อทำการวิเคราะห์

ตารางที่ 1 กำหนดชื่อตัวแปรและความหมายของตัวแปร ที่ใช้ในการวิเคราะห์


ตัวแปร	ความหมาย
LAT	พิกัดละติจูด (Latitude)
LONG	พิกัดลองจิจูด (Longitude)
xi	ค่าประมาณพารามิเตอร์บ่งรูปร่าง (Shape parameter)
mu	ค่าประมาณพารามิเตอร์บ่งตำแหน่ง (Location parameter)
sigma	ค่าประมาณพารามิเตอร์บ่งขนาด (Scale parameter)
rain_max	ปริมาณน้ำฝนสูงสุด
rain_average	ปริมาณน้ำฝนเฉลี่ย
rain_sum	ปริมาณน้ำฝนสะสม
wind_max	ความเร็วลมสูงสุด
wind_average	ความเร็วลมเฉลี่ย
Temp_max	อุณหภูมิสูงสุด
Temp_min	อุณหภูมิต่ำสุด
Temp_average	อุณหภูมิเฉลี่ย
RH_average	ความชื้นสัมพัทธ์เฉลี่ย
RH_max	ความชื้นสัมพัทธ์สูงสุด
NDVI	ดัชนีผลต่างพืชพรรณแบบนอนัลไลซ์เฉลี่ย (NDVI)
Runoff_max	ปริมาณน้ำท่าสูงสุด
Runoff_average	ปริมาณน้ำท่าเฉลี่ย
Runoff_sum	ปริมาณน้ำท่าสะสม

2. การประมาณค่าพารามิเตอร์บ่งรูปร่าง (Shape parameter)

สำหรับการประมาณค่าพารามิเตอร์ของการแจกแจงค่าสุดขีดน้อยทั่วไป (GEV) จากปริมาณน้ำฝนสูงสุดรายเดือน ด้วยวิธีที่น่าจะเป็นสูงสุด (MLE) จะเป็นการสร้างพารามิเตอร์ตั้งต้นที่จะนำไปคำนวณค่าประมาณค่าพารามิเตอร์บ่งรูปร่าง (Shape parameter) ทั้งนี้ผู้วิจัยได้คำนวณค่าประมาณของพารามิเตอร์บ่งรูปร่าง ตามสถานีตรวจวัดโดยอ้างอิงจากแหล่งที่มาของข้อมูลในลุ่มน้ำชี รายละเอียดดังรูปที่ 3 และ 4



รูปที่ 3 ค่าประมาณพารามิเตอร์รูปร่าง (Shape parameter) รายสถานี จากข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน




รูปที่ 4 กราฟฮิสโตแกรมค่าประมาณพารามิเตอร์รูปร่าง (Shape parameter) ของทั้ง 92 สถานี

จากรูปที่ 3-4 พบว่าค่าประมาณพารามิเตอร์รูปร่าง (Shape parameter) ของข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของทั้ง 92 สถานีในกลุ่มน้ำชี พบว่ามีค่าอยู่ระหว่าง -0.28 ถึง 0.28 มีค่าเฉลี่ยเท่ากับ 0.077 และมีลักษณะเบ้ไปทางซ้ายซึ่งค่าเหล่านี้จะนำไปใช้เป็นพารามิเตอร์ตั้งต้นในการหาความสัมพันธ์กับตัวแปรอื่นๆ และนำไปใช้ในการสร้างแบบจำลองโครงข่ายประสาทเทียม

3. การวิเคราะห์ความสัมพันธ์ของตัวแปรเพื่อหาตัวแปรที่ส่งผลต่อพารามิเตอร์บ่งรูปร่าง

การวิเคราะห์หาความสัมพันธ์ระหว่างตัวแปรโดยใช้การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สัน (Pearson correlation coefficient) เป็นการวิเคราะห์เพื่อหาความสัมพันธ์ระหว่างพารามิเตอร์บ่งรูปร่าง กับทั้ง 18 ตัวแปรว่ามีความสัมพันธ์กันหรือไม่ โดยผู้วิจัยได้วิเคราะห์ความสัมพันธ์ระหว่างตัวแปรได้ผลดังรูปที่ 5




รูปที่ 5 ความสัมพันธ์ที่คำนวณจากค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สันของพารามิเตอร์บ่งรูปร่างกับตัวแปรอื่นๆ

จากรูปที่ 5 พบว่าค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สันระหว่างค่าประมาณพารามิเตอร์บ่งรูปร่าง กับตัวแปรอื่นๆ พบว่ามีตัวแปรที่มีความสัมพันธ์กับ xi มีดังนี้ mu, sigma, LAT, NDVI, RH_max, rain_max, Temp_min และ RH_average โดยมีค่าสัมประสิทธิ์สหสัมพันธ์เป็น -0.46, -0.38, -0.43, 0.31, -0.31, 0.28, -0.23 และ 0.23 ตามลำดับ

4. แบบจำลองโครงข่ายประสาทเทียม (ANN)


ผู้วิจัยได้พัฒนาแบบจำลองโครงข่ายประสาทเทียมในการประมาณพารามิเตอร์บ่งรูปร่าง และได้ใช้สัดส่วนของการแบ่งข้อมูลในการ การสร้างแบบจำลอง (Train model) และทดสอบแบบจำลอง (Test model) เป็น 70% และ 30% โดยมีโครงสร้างของแบบจำลองประกอบด้วยชั้นรับข้อมูล (Input Layer) ชั้นแฝง (Hidden Layer) และชั้นแสดงผล (Output Layer)



รูปที่ 6 กราฟแผนภูมิแท่งเปรียบเทียบประสิทธิภาพของแบบจำลองโดยใช้ MSE RMSE และ NSE

ผลการวิเคราะห์พบว่าโครงสร้างแบบจำลองโครงข่ายประสาทเทียม (ANN) ในการประมาณค่าพารามิเตอร์ จากชุดข้อมูลทั้งหมด 4 ข้อมูลคือ ข้อมูลเชิงพื้นที่ (พิกัด Lat, Long) ข้อมูลทางอุทกวิทยา ข้อมูลอุตุณิยมวิทยา และ ข้อมูลจากภาพถ่ายดาวเทียม ได้ผลของการสร้างแบบจำลองที่เหมาะสมที่จะนำมาประมาณค่าพารามิเตอร์รูปร่าง (shape parameter) ทั้งหมด 11 แบบจำลองที่ดีที่สุดคือ ANN-7 ซึ่งมีค่า MSE เท่ากับ 0.0034 RMSE เท่ากับ 0.05831 และ NSE เท่ากับ 0.6545 และรองลงมาเป็นแบบจำลอง ANN-10 และ ANN-3 ตามลำดับ สามารถเขียนรูปแบบและสมการที่เหมาะสมในการสร้างแบบจำลองได้ดังนี้


$$\text{แบบจำลอง ANN-3 (5-9-1) ได้ดังนี้ } \xi(ANN-3) = \sum_{j=1}^9 \left[\left(\sum_{i=1}^5 (w_j X_i) + B_j \right) v_j \right] \varphi$$



รูปที่ 7 โครงสร้างแบบจำลองโครงข่ายประสาทเทียมของแบบจำลอง ANN-3 (5-6-1)

จากรูปที่ 7 เป็นการแสดงโครงสร้างของแบบจำลอง ANN-3 และค่าพารามิเตอร์ของโครงข่ายแต่ละเส้นโดยประกอบด้วย ตัวแปรนำเข้าทั้งหมด 5 ตัวแปร ชั้น Hidden 6 เส้น และตัวแปรผลลัพธ์ 1 ตัวแปร


$$\text{แบบจำลอง ANN-7 (9-5-1) ได้ดังนี้ } \xi(ANN-7) = \sum_{j=1}^5 \left[\left(\sum_{i=1}^9 (w_j X_i) + B_j \right) v_j \right] \varphi$$



รูปที่ 8 โครงสร้างแบบจำลองโครงข่ายประสาทเทียมของแบบจำลอง ANN-7 (9-5-1)

จากรูปที่ 8 เป็นการแสดงโครงสร้างของแบบจำลอง ANN-7 และค่าพารามิเตอร์ของโครงข่ายแต่ละเส้นโดยประกอบด้วย ตัวแปรนำเข้าทั้งหมด 9 ตัวแปร ชั้น Hidden 5 เส้น และตัวแปรผลลัพธ์ 1 ตัวแปร

$$\text{แบบจำลอง ANN-10 (16-10-1) ได้ดังนี้ } \xi(ANN-10) = \sum_{j=1}^{10} \left[\left(\sum_{i=1}^{16} (w_j X_i) + B_j \right) v_j \right] \varphi$$




รูปที่ 9 โครงสร้างแบบจำลองโครงข่ายประสาทเทียมของแบบจำลอง ANN-10 (16-10-1)

จากรูปที่ 9 เป็นการแสดงโครงสร้างของแบบจำลอง ANN-10 และค่าพารามิเตอร์ของโครงข่ายแต่ละเส้นโดยประกอบด้วยตัวแปรนำเข้าทั้งหมด 16 ตัวแปร ชั้น Hidden 10 เส้น และตัวแปรผลลัพธ์ 1 ตัวแปร

5. เปรียบเทียบประสิทธิภาพของแบบจำลอง


จากการเปรียบเทียบประสิทธิภาพของแบบจำลองภายใต้กระบวนการคงที่ และกระบวนการไม่คงที่ ด้วยการประเมินความเหมาะสมของแบบจำลองด้วย NSE ผลการศึกษาแบบจำลองที่ประยุกต์ใช้กับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนพบว่า แบบจำลองที่เหมาะสมกับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน ส่วนใหญ่เป็นแบบจำลองภายใต้กระบวนการไม่คงที่ทั้งหมด 59 สถานี ได้แก่ แบบจำลอง ANN-7 17 สถานี แบบจำลอง ANN-10 27 สถานี และ แบบจำลอง ANN-3 15 สถานี และแบบจำลองภายใต้กระบวนการคงที่ที่เหมาะสมกับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน มีทั้งหมด 33 สถานี แสดงภาพรวมแบบจำลองที่เหมาะสมรายละเอียดดังรูปที่ 10



รูปที่ 10 แผนที่แสดงแบบจำลองที่เหมาะสมของแต่ละสถานีของทั้ง 92 สถานีในกลุ่มน้ำชี

6. ประมาณค่าระดับการเกิดซ้ำของแบบจำลองค่าสุดขีดและการสร้างแผนที่ระดับการเกิดซ้ำสำหรับรอบปีการเกิดซ้ำต่าง ๆ

ค่าระดับการเกิดซ้ำของปริมาณน้ำฝนสูงสุดรายเดือนจากแบบจำลองที่เหมาะสมของแต่ละสถานีในแต่ละรอบปีการเกิดซ้ำ 2 5 10 20 50 และ 100 ปี ดังรูปที่ 10 แสดงให้เห็นว่า จังหวัดที่มีปริมาณน้ำฝนสูงรายเดือนได้แก่ จังหวัดที่อยู่ชายขอบตอนล่างของกลุ่มน้ำชี และเมื่อนำมาสร้างเป็นแผนที่ระดับการเกิดซ้ำของปริมาณน้ำฝนสูงสุดรายเดือนของพื้นที่ที่ทำการศึกษพบว่า พื้นที่ที่มีแถบระดับสีสูงสุดจะเป็นพื้นที่ตอนล่างของกลุ่มน้ำชี ซึ่งประกอบด้วยจังหวัด ชัยภูมิ อุบลราชธานี ร้อยเอ็ด กาฬสินธุ์ และมหาสารคาม



รูปที่ 11 แผนที่ระดับการเกิดซ้ำของปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีการเกิดซ้ำ 2 5 10 20 50 และ 100 ปี

สรุปผลและวิจารณ์ผลการวิจัย

การศึกษาการสร้างแบบจำลองพารามิเตอร์บ่งชี้รูปร่างของการแจกแจงค่าสุดขีดน้อยทั่วไปจากข้อมูลน้ำฝน-น้ำท่าและข้อมูลภาพถ่ายดาวเทียม โดยใช้วิธี โครงข่ายประสาทเทียม สอดคล้องกับงานวิจัยของ Hristos Tyralis และคณะ (2562) ที่พบว่าพารามิเตอร์บ่งชี้รูปร่างมีความสัมพันธ์กับ สภาพอากาศ และ ลักษณะของภูมิประเทศ อีกทั้งยังพบว่า ค่าดัชนี NDVI ก็เป็นอีกหนึ่งตัวแปรที่ส่งผลต่อพารามิเตอร์บ่งชี้รูปร่าง นอกจากนี้ยังสอดคล้องกับงานวิจัยของ Haniyeh Asadi และคณะ 2562 ที่พัฒนาแบบจำลองโครงข่ายในการพยากรณ์ปริมาณน้ำฝน-น้ำท่า โดยใช้ดัชนีพืชพรรณ (NDVI) และปัจจัยด้านภูมิอากาศและอุทกวิทยา ปัจจัยการพัฒนาโครงข่ายประสาทเทียม (ANN) ซึ่งทำให้ประสิทธิภาพของแบบจำลอง ANN ดียิ่งขึ้น

จากผลการวิจัย พบว่า เมื่อเพิ่มตัวแปรด้านดัชนีพืชพรรณ (NDVI) ในการพัฒนาแบบจำลอง ตัวแปรนี้ทำให้ประสิทธิภาพของแบบจำลองดีขึ้นจากเดิมที่มีแต่ตัวแปรทางสภาพภูมิอากาศและตัวแปรเชิงพื้นที่ โดยเปรียบเทียบจากแบบจำลอง ANN-3 ที่ประกอบด้วย 5 ตัวแปรประกอบด้วย คือ ปริมาณน้ำฝนสูงสุด ปริมาณน้ำฝนสะสม ปริมาณน้ำฝนเฉลี่ย ความเร็วลมสูงสุด ความเร็วลมเฉลี่ย ซึ่งเป็นตัวแปรทางสภาพภูมิอากาศ และเมื่อเพิ่มตัวแปรด้านดัชนีพืชพรรณ (NDVI) ไปในแบบจำลอง ANN-7 ให้ทำให้ประสิทธิภาพของแบบจำลองเพิ่มขึ้น 26.06% เปรียบเทียบจากค่า NSE ของแต่ละแบบจำลอง นอกจากนั้นจากการศึกษาแบบจำลองทั้งสองรูปแบบ ได้แก่ ภายใต้กระบวนการคงที่ (Stationary Process) และภายใต้กระบวนการไม่คงที่ (Non-stationary Process) ของแบบจำลองค่าสุดขีดน้อยทั่วไป พบว่า ข้อมูลส่วนใหญ่มีลักษณะเกิดขึ้นภายใต้กระบวนการไม่คงที่ซึ่งอาจจะเกิดขึ้นจากปัจจัยธรรมชาติหลายอย่าง ทั้งนี้ปัจจัยหลักที่ส่งผลอย่างชัดเจน ได้แก่ การเปลี่ยนแปลงทางสภาพภูมิอากาศและลักษณะของภูมิประเทศ มีผลต่อการสร้างแบบจำลองภายใต้กระบวนการไม่คงที่ ซึ่งส่งผลต่อการสร้างแบบจำลองภายใต้กระบวนการคงที่มีประสิทธิภาพลดลงและขาดความแม่นยำของแบบจำลอง ดังนั้นการพัฒนาแบบจำลองภายใต้กระบวนการไม่คงที่จึงเป็นแบบจำลองที่เหมาะสมกับสภาพแวดล้อมของโลกที่มีการเปลี่ยนแปลงอยู่ตลอดเวลา

กิตติกรรมประกาศ

ขอขอบพระคุณคณาจารย์ภาควิชาคณิตศาสตร์ มหาวิทยาลัยมหาสารคาม ที่ช่วยประสิทธิ์ ประสาทความรู้ ข้อเสนอแนะ และคำสั่งสอนต่าง ๆ และขอขอบพระคุณโครงการวิจัยพัฒนามันดาศึกษาของสำนักงานการวิจัยแห่งชาติ (วช.) ประจำปีงบประมาณ 2564 ที่ได้สนับสนุนงบประมาณในการดำเนินการวิจัยในครั้งนี้

เอกสารอ้างอิง

- Asadi, H., Shahedi, K., Jarihani, B., & Sidle, R. C. (2019). Rainfall-runoff modelling using hydrological connectivity index and artificial neural network approach. *Water*, 11(2), 212. <https://doi/10.3390/w11020212>
- Busababodhin, P. (2017). Modeling on Maximum Rainfall and Temperature based on Extreme Value Copula Analysis. *Abstract Proceeding of 10th Conference on Extreme Value Analysis (EVA2017), Delft, Netherlands, 26-30 June 2017*, 14.
- Busababodhin, P. (2018). *Extreme value analysis*. Maha Sarakham Rajabhat University Press, Maha Sarakham. (in Thai)
- Busababodhin, P., & Keawmun, A. (2015). Extreme Values Statistics, *The Journal of KMUTNB*, 25(2), 55-65. (in Thai)
- Coles, S., Bawa, J., Trenner, L., & Dorazio, P. (2001). *An introduction to statistical modeling of extreme values*. London: Springer.
- Guarnieri, R. A., Pereira, E. B., & Chou, S. C. (2006). *Solar radiation forecast using artificial neural networks in South Brazil. Proceedings of the 8th ICSHMO*, 24-28.
- Lian, Y., Chan, I. C., Singh, J., Demissie, M., Knapp, V., & Xie, H. (2007). Coupling of hydrologic and hydraulic models for the Illinois River Basin. *Journal of hydrology*, 344(3-4), 210-222
- Meteorological Department of Thailand. (2020). <https://www.tmd.go.th> (in Thai)
- Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I—A discussion of principles. *Journal of hydrology*, 10(3), 282-290. [https://doi.org/10.1016/0022-694\(70\)90255-6](https://doi.org/10.1016/0022-694(70)90255-6)
- Pearson, K. (1920). Notes on the history of correlation. *Biometrika*, 13(1), 25-45.
- Royal Irrigation Department. (2017). *Use Artificial Neural Networks (ANN)*. Bureau of Water Management and Hydrology.
- Thaipublica. (2019). *30 year Drought-Flood*. <https://thaipublica.org/2020/02/statistics-of-drought-flood-30-years/>
- Tyralis, H., Papacharalampous, G., & Tantanee, S. (2019). How to explain and predict the shape parameter of the generalized extreme value distribution of streamflow extremes using a big dataset. *Journal of Hydrology*, 574, 628-645. <https://doi.org/10.1016/j.jhydrol.2019.04.070>
- USGS. (2011). *MOD13Q1*. https://lpdaac.usgs.gov/products/modis_products_table/mod13q1