


ตัวแบบสำหรับการพยากรณ์น้ำท่วมในภาคตะวันออกเฉียงเหนือตอนล่างของประเทศไทย

วิทยานิพนธ์
ของ
พงศกร มลสิน

เสนอต่อมหาวิทยาลัยมหาสารคาม เพื่อเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการจัดการสถิติ
มกราคม 2567


ลิขสิทธิ์เป็นของมหาวิทยาลัยมหาสารคาม

ตัวแบบสำหรับการพยากรณ์น้ำท่วมในภาคตะวันออกเฉียงเหนือตอนล่างของประเทศไทย



ลิขสิทธิ์เป็นของมหาวิทยาลัยมหาสารคาม

Flood Forecasting Model in the Lower Northeast of Thailand



Pongsakorn Molsin

A Thesis Submitted in Partial Fulfillment of Requirements
for Master of Science (Statistical Management Science)

January 2024

Copyright of Mahasarakham University



คณะกรรมการสอบวิทยานิพนธ์ ได้พิจารณาวิทยานิพนธ์ของนายพงศกร มลสิน แล้ว
เห็นสมควรรับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชา
วิทยาการจัดการสถิติ ของมหาวิทยาลัยมหาสารคาม

คณะกรรมการสอบวิทยานิพนธ์

ประธานกรรมการ

(ผศ. ดร. อาทิตย์ อภิโชติธนกุล)

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

(รศ. ดร. อรวิชัย กุมพล)

กรรมการ

(ผศ. ดร. ไรจน์ หอมขาลี)

กรรมการ

(รศ. ดร. นิภาพร ชุตินันต์)

มหาวิทยาลัยอนุมัติให้รับวิทยานิพนธ์ฉบับนี้ เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญา วิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการจัดการสถิติ ของมหาวิทยาลัยมหาสารคาม

(ศ. ดร. ไพโรจน์ ประมวล)

คณบดีคณะวิทยาศาสตร์

(รศ. ดร. กริสน์ ชัยมูล)

คณบดีบัณฑิตวิทยาลัย

ชื่อเรื่อง ตัวแบบสำหรับการพยากรณ์น้ำท่วมในภาคตะวันออกเฉียงเหนือตอนล่างของ
ประเทศไทย

ผู้วิจัย พงศกร มลสิน

อาจารย์ที่ปรึกษา รองศาสตราจารย์ ดร. อรุณชัย กุมพล

ปริญญา วิทยาศาสตรมหาบัณฑิต **สาขาวิชา** วิทยาการจัดการสถิติ

มหาวิทยาลัย มหาวิทยาลัยมหาสารคาม **ปีที่พิมพ์** 2567

บทคัดย่อ

ในงานวิจัยนี้ มีวัตถุประสงค์คือสร้างแบบจำลองที่เหมาะสมสำหรับการพยากรณ์น้ำท่วมจากข้อมูลทางอุตุนิยมวิทยา และข้อมูลอุทกวิทยา ได้แก่ ปริมาณฝนรายวัน อุณหภูมิต่ำสุดรายวัน อุณหภูมิสูงสุดรายวัน อัตราการระเหยรายวัน และอัตราการไหลรายวัน ตั้งแต่ปี 2551 ถึง 2565 ด้วยแบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) แบบจำลอง Long Short-Term Memory (LSTM) และ แบบจำลอง Physics-Guided Long Short-Term Memory (PG-LSTM) ทำการเปรียบเทียบประสิทธิภาพของแบบจำลองพิจารณาจากค่าสัมประสิทธิ์ประสิทธิภาพของแนช-ซัทคลิฟฟ์ (Nash–Sutcliffe Efficiency: NSE) ค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Squared Error: RMSE) และร้อยละความเอนเอียง (Percentage Bias: PBIAS) ผลการศึกษา พบว่า มีค่า NSE เฉลี่ยของแต่ละแบบจำลองมากกว่า 0.75 และ ค่า PBIAS เฉลี่ยของแต่ละแบบจำลองอยู่ระหว่าง -10 ถึง 10 สามารถใช้ในการพยากรณ์ได้ ซึ่งแบบจำลอง ANN ให้ผลลัพธ์ที่ดีที่สุด รองลงมาคือแบบจำลอง LSTM และ แบบจำลอง PG-LSTM ตามลำดับ

คำสำคัญ : การเรียนรู้ของเครื่องด้วยตัวนำทางกายภาพ, อัตราการไหล, ภาคตะวันออกเฉียงเหนือตอนล่าง, น้ำท่วม

พจนัน ปณ จิตโต ชีเว

TITLE Flood Forecasting Model in the Lower Northeast of Thailand
AUTHOR Pongsakorn Molsin
ADVISORS Associate Professor Orawich Kumphon , Ph.D.
DEGREE Master of Science **MAJOR** Statistical Management
Science
UNIVERSITY Mahasarakham **YEAR** 2024
University

ABSTRACT

The objective of this research is to evaluate the optimized models to predict flooding from a daily meteorological and hydrological data -viz. precipitation, minimum temperature, maximum temperature, evapotranspiration, and discharge from the years 2008 to 2022. Three models as Artificial Neural Network (ANN), Long Short-Term Memory (LSTM), and Physics-Guided Long Short-Term Memory (PG-LSTM) were considered, and the performances measured via Nash-Sutcliffe Efficiency (NSE), Root Mean Squared Error (RMSE), and Percentage Bias (PBIAS). The results with a higher value of mean NSE ($> 75\%$) and PBIAS between ± 10 from three models can be used for forecasting. As a result, the performances of ANN, LSTM and PG-LSTM perform the suitable for forecasting, respectively.

Keyword : Physics-guided Machine Learning, Discharge, Lower Northeast, Flood

พหุ ประถมศึกษา

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จได้ด้วยความรู้และความกรุณาและได้รับความช่วยเหลืออย่างสูงยิ่งจาก รongศาสตราจารย์ อรุณชัย กุมพล ที่ให้คำแนะนำและให้แนวคิด ในการศึกษาหาข้อมูล การวิเคราะห์ ตลอดจนการแก้ไขปรับปรุงข้อบกพร่องต่างๆ ที่ทำให้วิจัยสมบูรณ์มากยิ่งขึ้น ขอขอบพระคุณประธาน กรรมการสอบ และกรรมการสอบวิทยานิพนธ์ รวมทั้งขอขอบพระคุณคณาจารย์ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยมหาสารคาม ที่ช่วยให้คำแนะนำ ข้อเสนอแนะ คำสั่งสอนต่างๆ รวมทั้ง การช่วยประสิทธิ์ประสาทความรู้ในเรื่องการเรียนและการใช้ชีวิต และขอกราบขอบพระคุณบิดา มารดา และญาติพี่น้อง รวมถึงพี่ๆ น้องๆ ทุกคนในภาควิชาคณิตศาสตร์ที่คอยให้กำลังใจและความช่วยเหลือ ด้วยดีเสมอมา หากมีข้อบกพร่องด้วยประการใด ผู้วิจัยขอน้อมรับไว้ด้วยความขอบคุณยิ่ง

พงศกร มลสิน




สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ณ
สารบัญภาพ	ญ
บทที่ 1	1
บทนำ.....	1
1.1 หลักการและเหตุผล	1
1.2 วัตถุประสงค์	3
1.3 ขอบเขตของการวิจัย	3
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	4
1.5 นิยามศัพท์	4
บทที่ 2	5
เอกสารและงานวิจัยที่เกี่ยวข้อง	5
2.1 พื้นที่ศึกษา.....	5
2.2 อุทกภัยและสาเหตุการเกิด	7
2.3 สภาพการไหลของกลุ่มน้ำมูลและกลุ่มน้ำชีกับประวัติการเกิดอุทกภัยในพื้นที่ภาค ตะวันออกเฉียงเหนือตอนล่าง	9
2.4 ทฤษฎีที่เกี่ยวข้อง.....	11
2.5 งานวิจัยที่เกี่ยวข้อง	22

บทที่ 3	27
วิธีดำเนินการ.....	27
3.1. ขอบเขตของการศึกษา.....	27
3.2. การวิเคราะห์ข้อมูล.....	27
บทที่ 4	32
ผลการวิจัย	32
4.1 การเตรียมข้อมูล และการเลือกตัวแปร.....	32
4.2 การสร้างแบบจำลองการพยากรณ์อัตราการใช้.....	44
4.3 การคาดการณ์น้ำท่วม	53
บทที่ 5	65
สรุปและอภิปรายผล.....	65
5.1 สรุปผล.....	65
5.2 อภิปรายผล.....	66
5.3 ข้อเสนอแนะ	68
บรรณานุกรม.....	69
ภาคผนวก.....	74
ประวัติผู้เขียน.....	81



สารบัญตาราง

	หน้า
ตารางที่ 1 การแปลความหมายค่า NSE และ PBIAS	22
ตารางที่ 2 กรอบแนวคิดตัวแปรที่ทำการศึกษา.....	26
ตารางที่ 3 สถานีอุตุนิยมวิทยา ที่เก็บรวบรวมข้อมูล	27
ตารางที่ 4 สถานีวัดน้ำท่า ที่เก็บรวบรวมข้อมูล	28
ตารางที่ 5 รายละเอียดของสถานีอุตุนิยมวิทยาที่ใช้ในการสร้างแบบจำลอง.....	33
ตารางที่ 6 ข้อมูลพื้นฐานของอัตราการไหล สถานีวัดน้ำท่า ของกรมอุทกวิทยา (ลูกบาศก์เมตรต่อวินาที : ลบ.ม/วินาที).....	34
ตารางที่ 7 ข้อมูลพื้นฐานของสถานีอุตุนิยมวิทยา ของกรมอุตุนิยมวิทยา.....	39
ตารางที่ 8 โครงสร้างของแบบจำลองวิธี ANN, LSTM และ PG-LSTM มีค่า Hyperparameter สำหรับแบบจำลอง ค่า Weights และ พารามิเตอร์สำหรับเหตุการณ์ฝนที่ตกต่อเนื่อง	44
ตารางที่ 9 ประสิทธิภาพของแบบจำลองของแต่ละสถานี ด้วยค่า RMSE, NSE และ PBIAS โดยใช้ อัตราการไหลย้อนหลัง 1 วัน	45
ตารางที่ 10 ประสิทธิภาพของแบบจำลองของแต่ละสถานี ด้วยค่า RMSE, NSE และ PBIAS โดยใช้ อัตราการไหลย้อนหลัง 3 วัน	46
ตารางที่ 11 ประสิทธิภาพของแบบจำลองของแต่ละสถานี ด้วยค่า RMSE, NSE และ PBIAS โดยใช้ อัตราการไหลย้อนหลัง 7 วัน	47
ตารางที่ 12 ประสิทธิภาพและแบบจำลองที่เหมาะสมของการใช้ข้อมูลอัตราการไหลย้อนหลัง	48
ตารางที่ 13 แบบจำลองของแต่ละสถานีที่มีประสิทธิภาพแต่ละวิธีการที่ (จำนวนวันของการใช้ อัตราการไหลย้อนหลัง).....	52


สารบัญภาพ

	หน้า
ภาพที่ 1 ภาพแสดงพื้นที่ลุ่มน้ำมูลและลุ่มน้ำชี.....	7
ภาพที่ 2 ผังปริมาณน้ำที่เฝ้าระวังลุ่มน้ำชี-มูล.....	9
ภาพที่ 3 โครงสร้างแบบจำลอง Artificial Neural Network.....	11
ภาพที่ 4 กราฟของ Activation Function.....	16
ภาพที่ 5 โครงสร้างแบบจำลอง Long Short Term Memory networks.....	17
ภาพที่ 6 แสดงขั้นตอนของ Forget Gate Layer.....	18
ภาพที่ 7 แสดงขั้นตอนของ Input Gate Layer.....	18
ภาพที่ 8 แสดงขั้นตอนของ Output Gate Layer.....	19
ภาพที่ 9 ที่ตั้งสถานีวัดน้ำท่าและสถานีตรวจอากาศ ที่ทำการศึกษาในพื้นที่ที่ศึกษา.....	33
ภาพที่ 10 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรม ของสถานี M.2A.....	34
ภาพที่ 11 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรม ของสถานี M.4.....	35
ภาพที่ 12 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรม ของสถานี M.5.....	35
ภาพที่ 13 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรม ของสถานี M.6A.....	35
ภาพที่ 14 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรม ของสถานี M.7.....	36
ภาพที่ 15 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรม ของสถานี M.9.....	36
ภาพที่ 16 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรม ของสถานี M.173.....	36

ภาพที่ 17 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรม ของสถานี M.176.....	37
ภาพที่ 18 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรม ของสถานี M.184.....	37
ภาพที่ 19 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรม ของสถานี E.18.....	37
ภาพที่ 20 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรม ของสถานี E.20A.....	38
ภาพที่ 21 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรม ของสถานี E.92.....	38
ภาพที่ 22 ฮิสโตแกรมของปริมาณน้ำฝน 7 สถานี.....	40
ภาพที่ 23 ฮิสโตแกรมของอุณหภูมิต่ำสุด 7 สถานี.....	41
ภาพที่ 24 ฮิสโตแกรมของอุณหภูมิสูงสุด 7 สถานี.....	42
ภาพที่ 25 ฮิสโตแกรมของอัตราการระเหย 7 สถานี.....	43
ภาพที่ 26 ประสิทธิภาพของแบบจำลองของแต่ละสถานี ด้วยค่า NSE, RMSE และ PBIAS โดยใช้ อัตราการไหลย้อนหลัง 1 วัน.....	49
ภาพที่ 27 ประสิทธิภาพของแบบจำลองของแต่ละสถานี ด้วยค่า NSE, RMSE และ PBIAS โดยใช้ อัตราการไหลย้อนหลัง 3 วัน.....	50
ภาพที่ 28 ประสิทธิภาพของแบบจำลองของแต่ละสถานี ด้วยค่า NSE, RMSE และ PBIAS โดยใช้ อัตราการไหลย้อนหลัง 7 วัน.....	51
ภาพที่ 29 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.2A	53
ภาพที่ 30 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.4.	54
ภาพที่ 31 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.5.	54
ภาพที่ 32 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.6A	55

ภาพที่ 33 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.7	55
ภาพที่ 34 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.9	56
ภาพที่ 35 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.173	56
ภาพที่ 36 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.176	57
ภาพที่ 37 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.184	57
ภาพที่ 38 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี E.18	58
ภาพที่ 39 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี E.20A	58
ภาพที่ 40 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี E.92	59
ภาพที่ 41 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.2A	60
ภาพที่ 42 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.4	60
ภาพที่ 43 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.5	60
ภาพที่ 44 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.6A	61
ภาพที่ 45 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.7	61
ภาพที่ 46 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.9	61
ภาพที่ 47 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.173	62

ภาพที่ 48 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.176.....	62
ภาพที่ 49 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.184.....	62
ภาพที่ 50 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี E.18	63
ภาพที่ 51 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี E.20A.....	63
ภาพที่ 52 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี E.92	63



บทที่ 1

บทนำ

1.1 หลักการและเหตุผล

การเปลี่ยนแปลงของสภาพภูมิอากาศโลกเป็นประเด็นที่ทั่วโลกให้ความสนใจ และเป็นปัจจัยที่ส่งผลกระทบต่อภูมิภาคในท้องถิ่น เช่น ภัยน้ำท่วม ภัยแล้ง ประเทศไทยตั้งอยู่กลางคาบสมุทรอินโดจีนในเอเชียตะวันออกเฉียงใต้ และอยู่บนคาบสมุทรมาลายู ซึ่งตั้งอยู่ในเขตร้อนใกล้เส้นศูนย์สูตร มีสภาพอากาศส่วนใหญ่เป็นภูมิอากาศร้อนชื้นเขตร้อน ประเทศไทยอยู่ภายใต้อิทธิพลของลมมรสุมตะวันตกเฉียงใต้ที่พัดจากมหาสมุทรอินเดียทำให้เกิดฤดูฝน และลมมรสุมตะวันออกเฉียงเหนือที่พัดจากทะเลจีนใต้ทำให้เกิดฤดูหนาวในทุกภูมิภาคยกเว้นภาคใต้ แต่ปัจจุบันสภาพอากาศมีความแปรปรวนไปจากในอดีตเป็นอย่างมาก ที่ส่งผลมาจากการแปรปรวนไปของภูมิอากาศโลก (พิมพ์พลชัย ปรีयर และคณะ, 2564) ประเทศไทยได้ชื่อว่าเป็นประเทศเกษตรกรรม น้ำฝนจึงมีความสำคัญในการเพาะปลูก ดังนั้น เกษตรกรเมื่อเริ่มฤดูเพาะปลูกพืชจะมีการกักเก็บน้ำไว้ใช้ในฤดูแล้ง ในช่วงฤดูฝนเป็นช่วงพฤษภาคมของทุกปีไปจนถึงสิ้นเดือนตุลาคม และปริมาณน้ำฝนเป็นปัจจัยที่ไม่สามารถควบคุมได้ หากมีการเพิ่มขึ้นหรือลดลงเกินกว่าปกติก็จะส่งผลกระทบ ทำให้เกิดความเสียหายทั้งทางพืชผลทางการเกษตร สังคม เศรษฐกิจ และสิ่งแวดล้อมของประเทศ อันเนื่องมาจากภัยแล้ง แผ่นดินถล่ม และน้ำท่วมฉับพลัน (ณพฐ์ โสภีพันธ์, 2558)

ในปัจจุบัน สภาพอากาศมีการเปลี่ยนแปลงอย่างต่อเนื่อง ส่งผลต่อการคาดการณ์และการบริหารจัดการน้ำในสภาวะวิกฤติเป็นไปได้ยาก พื้นที่ภาคตะวันออกเฉียงเหนือมักจะได้รับอิทธิพลจากพายุโซนร้อน เมื่อมีพายุพัดผ่านส่งผลให้เกิดน้ำท่วมฉับพลันในหลายจังหวัด ในปี พ.ศ. 2554 ประเทศไทยได้เกิดอุทกภัยครั้งใหญ่ มีพื้นที่น้ำท่วมขังทั่วประเทศ 15,996,150 ไร่ มีมูลค่าความเสียหายสูงถึง 1.44 ล้านล้านบาท มีพื้นที่ได้รับความเสียหายอย่างมาก ซึ่งเป็นพื้นที่เกษตรกรรมและอุตสาหกรรมใน 65 จังหวัด 684 อำเภอ ประชาชนได้รับความเดือดร้อน 4,086,138ครัวเรือน 13,595,192 คน บ้านเรือนเสียหายทั้งหลัง 2,329 หลัง บ้านเรือนเสียหายบางส่วน 96,833 หลัง พื้นที่การเกษตรคาดว่าจะได้รับความเสียหาย 11.20 ล้านไร่ นอกจากนี้ ปี พ.ศ. 2564 และในปี พ.ศ. 2565 เกิดอุทกภัยมีพื้นที่น้ำท่วมขังทั่วประเทศจำนวน 5,648,252 ไร่ และ 5,331,739 ไร่ ตามลำดับ เมื่อเปรียบเทียบกับปี พ.ศ. 2554 พบว่าปริมาณน้ำท่วมขังในปัจจุบันยังห่างอยู่ 3 เท่าตัว (BBC NEWS ไทย, 2565) ปี พ.ศ. 2564 มีมูลค่าความเสียหาย 15,000 ล้านบาท ในพื้นที่ 31 จังหวัด 190 อำเภอ 956 ประชาชนได้รับผลกระทบ 227,470 ครัวเรือน พื้นที่ทั้งหมดเกษตรพื้นที่

3,939,515 ไร่ (PPTV Online, 2564) และ ปี พ.ศ.2565 คาดการณ์ความเสียหายรวมทั้งประเทศ ประมาณ 5,000 – 10,000 ล้านบาท (PPTV Online, 2565)

สาเหตุของการเกิดอุทกภัยในพื้นที่ภาคตะวันออกเฉียงเหนือตอนล่างที่มีลุ่มน้ำมูล และลุ่มน้ำชีไหลผ่าน สภาพการเกิดอุทกภัยในลุ่มน้ำทั้งสองมีลักษณะที่แตกต่างกันในแต่ละพื้นที่ ขึ้นอยู่กับลักษณะทางภูมิศาสตร์ และที่ตั้ง โดยจังหวัดสุรินทร์ บุรีรัมย์ และศรีสะเกษ เป็นจังหวัดที่มีลำน้ำสาขาในลุ่มน้ำมูลไหลผ่าน เป็นพื้นที่ที่มีสาเหตุของการเกิดน้ำท่วมจากการที่ฝนตกหนักเป็นเวลานาน และมีการระบายน้ำไม่ทันจึงส่งผลให้เกิดน้ำล้นตลิ่งและน้ำท่วมขัง พื้นที่จังหวัดนครราชสีมาเป็นพื้นที่มีลำน้ำสาขาไหลมาบรรจบกันหลายสายทำให้มักจะมีการระบายน้ำไม่ทันส่งผลให้เกิดน้ำล้นตลิ่ง พื้นที่จังหวัดยโสธร เป็นพื้นที่ที่อยู่ในรอยต่อของลุ่มน้ำมูลกับลุ่มน้ำชี มีลำน้ำสาขาหลายสายของทั้งสองลุ่มน้ำไหลมาบรรจบกัน และจังหวัดอุบลราชธานีเป็นจังหวัดที่มักเกิดน้ำท่วมบ่อยครั้ง เนื่องจากพื้นที่ตั้งอยู่บริเวณได้รับอิทธิพลทั้งจากแม่น้ำชีและแม่น้ำมูลที่เป็นลำน้ำหลักไหลมาบรรจบกัน ดังนั้นการบริหารจัดการน้ำในลุ่มน้ำ และการที่ทราบแบบจำลองการพยากรณ์น้ำท่วมจะสามารถคาดการณ์ความเสี่ยงที่จะเกิดน้ำท่วมได้ เพื่อลดและป้องกันผลกระทบที่เกิดขึ้น ใช้เป็นเครื่องมือช่วยในการวางแผนรับมือกับเหตุการณ์น้ำท่วม

ในปัจจุบันการเรียนรู้เชิงลึก (Deep Learning) ได้รับความนิยมอย่างมาก และได้มีบทบาทในส่วนอุทกวิทยา แต่แบบจำลองทางอุทกวิทยาส่วนใหญ่ในประเทศไทยได้มีการประยุกต์ใช้แบบจำลองทางคณิตศาสตร์เพื่อพยากรณ์ปริมาณน้ำ แบบจำลองที่มีการใช้แพร่หลาย ได้แก่ MIKE11 (ปรียาพร โกษา และคณะ, 2565; เมธัส ใจปิ่นตา และ จิระวัฒน์ กณะสุด, 2556) SWAT (หริส ประสารจำ และคณะ, 2565) และ HEC-RAS (เสาวนิต ปราบนคร และคณะ, 2565; ชีรเมธ หิรัญพัฒนานนท์ และ วรพงษ์ โล่ที่ไพศาลกุล, 2563) ซึ่งแบบจำลองที่กล่าวมามีความแม่นยำสูงแต่ก็มีความยากและซับซ้อนในการใช้งาน และบางแบบจำลองมีค่าใช้จ่ายสูง จึงได้เสนอการใช้แบบจำลองโครงข่ายประสาทเทียมในการพยากรณ์ปริมาณน้ำ (ทวี ชัยพิมลผลิน, 2561; ยุพิน ไชยสมภาร, 2560) Le และคณะ (2019) ได้พยากรณ์อัตราการไหล ในแม่น้ำแดง ประเทศเวียดนาม จากข้อมูลอัตราการไหลย้อนหลัง 3 วันในการสร้างแบบจำลอง Long Short-term Memory จากผลการศึกษาเห็นว่าแบบจำลองสามารถใช้สร้างระบบเตือนภัยน้ำท่วมตามเวลาจริงได้ Ahmad และคณะ (2022) ได้สร้างแบบจำลองการพยากรณ์อัตราการไหล ด้วยแบบจำลองโครงข่ายประสาทเทียม ร่วมกับการพิจารณาปริมาณน้ำฝน อุณหภูมิ และอัตราการระเหย โดยการเปรียบเทียบกับแบบจำลอง NAM พบว่า แบบจำลองโครงข่ายประสาทเทียมมีประสิทธิภาพน้อยกว่าแบบจำลอง NAM อย่างไรก็ตามการนำแบบจำลองกล่องดำ “Black-box Model” มาใช้งานยังมีข้อจำกัดทางกายภาพ ซึ่งแบบจำลองสามารถอธิบายความสัมพันธ์ระหว่างตัวแปรได้เท่านั้น (Karpatne A, et al., 2017) Zheng และคณะ (2022) ได้เสนอแบบจำลอง Physics-Guided Long Short-Term

Memory ในการพยากรณ์อัตราการไหล ใช้ข้อมูลอัตราการไหลและระดับน้ำในการสร้างแบบจำลองจากการใช้แบบจำลองพบว่า แบบจำลองสามารถพยากรณ์อัตราการไหลได้อย่างมีประสิทธิภาพ ดังนั้น ในงานวิจัยได้ศึกษาเทคนิคการเรียนรู้เชิงลึกโดยสนใจข้อมูลปริมาณน้ำฝน อุณหภูมิ และอัตราการระเหย เพื่อใช้พยากรณ์อัตราการไหล ในพื้นที่ภาคตะวันออกเฉียงเหนือของประเทศไทย จากแบบจำลอง 3 แบบ คือ แบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) แบบจำลอง Long Short-Term Memory (LSTM) และ Physics-Guided Long Short-Term Memory (PG-LSTM) โดยเปรียบเทียบประสิทธิภาพของแบบจำลองด้วย สัมประสิทธิ์ประสิทธิภาพของแนช-สัทคลิฟฟ์ (Nash–Sutcliffe Efficiency: NSE) รากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Squared Error: RMSE) และร้อยละความเอนเอียง (Percentage Bias: PBIAS)

1.2 วัตถุประสงค์

1.2.1 เพื่อศึกษาสภาพการไหลในลำน้ำ ในพื้นที่ลุ่มน้ำมูลและลุ่มน้ำชี ในพื้นที่ภาคตะวันออกเฉียงเหนือตอนล่าง

1.2.2 เพื่อสร้างแบบจำลองที่เหมาะสมกับการพยากรณ์น้ำท่วม ในภาคตะวันออกเฉียงเหนือตอนล่าง ของประเทศไทย

1.3 ขอบเขตของการวิจัย

1.3.1 พื้นที่ที่ทำการศึกษาลุ่มน้ำมูลและลุ่มน้ำชีในภาคตะวันออกเฉียงเหนือตอนล่าง

1.3.2 ข้อมูลที่ใช้ คือ ข้อมูลหตุยภูมิจาก กรมอุตุนิยมวิทยา ศูนย์อุทกวิทยาชลประทานภาคตะวันออกเฉียงเหนือตอนบน และศูนย์อุทกวิทยาชลประทานภาคตะวันออกเฉียงเหนือตอนล่าง กรมชลประทาน ประกอบด้วย ข้อมูลปริมาณน้ำฝนรายวัน ข้อมูลอุณหภูมิสูงสุดรายวัน ข้อมูลอุณหภูมิต่ำสุดรายวัน ข้อมูลอัตราการระเหยรายวัน และข้อมูลอัตราการไหลรายวัน

1.3.3 วิธีการศึกษา 3 วิธี ได้แก่

- 1) Artificial Neural Network (ANN)
- 2) Long Short-Term Memory (LSTM)
- 3) Physics-guided Long Short-Term Memory (PG-LSTM)

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1.5.1 ได้แบบจำลองที่เหมาะสมกับการพยากรณ์น้ำท่วม ในภาคตะวันออกเฉียงเหนือตอนล่าง ของประเทศไทย

1.5.2 ทราบแนวโน้มของการเกิดน้ำท่วมในอนาคตที่ศึกษา และใช้เป็นแนวทางในการวางแผนรับมือในอนาคต


1.5 นิยามศัพท์

1.5.1 Physics-guided Machine Learning (PG-ML) คือ การประยุกต์ใช้ Machine Learning (ML) โดยเฉพาะการเรียนรู้เชิงลึก เพื่อกระตุ้นให้เกิดการเรียนรู้ที่จะจัดการกับความสามารถทั่วไปของวิธีการอนุมานทางสถิติในวิทยาศาสตร์ฟิสิกส์

1.5.2 Discharge คือ ปริมาณการไหล หรือ อัตราการไหลในลำน้ำ มีหน่วยเป็น ลูกบาศก์เมตรต่อวินาที

1.5.3 Lower Northeast คือ กลุ่มจังหวัดภาคตะวันออกเฉียงเหนือตอนล่าง ประกอบด้วย จังหวัดนครราชสีมา ชัยภูมิ บุรีรัมย์ สุรินทร์ ยโสธร ศรีสะเกษ อำนาจเจริญ และอุบลราชธานี

1.5.4 Flood คือ น้ำท่วมที่เกิดขึ้นจากปริมาณน้ำจำนวนมากที่เกิดจากฝนหนักต่อเนื่อง ที่ไหลลงสู่ลำน้ำ หรือแม่น้ำมีปริมาณมากจนระบายลงสู่ลุ่มน้ำด้านล่างหรือออกสู่ปากน้ำไม่ทัน



บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

การวิจัยเรื่อง ตัวแบบสำหรับการพยากรณ์น้ำท่วมในภาคตะวันออกเฉียงเหนือตอนล่างของประเทศไทย ผู้วิจัยได้ศึกษาเอกสารและงานวิจัยที่เกี่ยวข้อง ดังนี้

- 2.1 พื้นที่ศึกษา
- 2.2 อุทกภัยและสาเหตุการเกิด
- 2.3 สภาพการไหลในพื้นที่ศึกษา
- 2.4 ทฤษฎีที่เกี่ยวข้อง
- 2.5 งานวิจัยที่เกี่ยวข้อง

2.1 พื้นที่ศึกษา

พื้นที่ที่ศึกษาอยู่ในภาคตะวันออกเฉียงเหนือตอนล่าง พื้นที่ครอบคลุม 8 จังหวัด ได้แก่ จังหวัดนครราชสีมา ชัยภูมิ บุรีรัมย์ สุรินทร์ ศรีสะเกษ ยโสธร อำนาจเจริญ และ อุบลราชธานี (สถาบันพระปกเกล้า, 2559) ซึ่งพื้นที่อยู่ในขอบเขตของกลุ่มน้ำมูลและลุ่มน้ำชีตอนล่าง และจังหวัดร้อยเอ็ดซึ่งมีแม่น้ำชีไหลผ่านที่มีผลต่อแม่น้ำชีในจังหวัดยโสธร ลุ่มน้ำทั้งสองมีรายละเอียดดังนี้

2.1.1 ลุ่มน้ำมูล

สภาพภูมิประเทศ

ลุ่มน้ำมูล มีแม่น้ำมูลเป็นแม่น้ำสายหลักของภาคตะวันออกเฉียงเหนือของประเทศไทย มีความยาวประมาณ 640 กิโลเมตร ขนาดพื้นที่ลุ่มน้ำประมาณ 69,701 ตร.กม. ตั้งอยู่ระหว่างเส้นรุ้งที่ $14^{\circ} 7'$ เหนือ ถึงเส้นรุ้งที่ $16^{\circ} 20'$ เหนือ และระหว่างเส้นแวงที่ $101^{\circ} 17'$ ตะวันออก ถึงเส้นแวงที่ $105^{\circ} 40'$ ตะวันออก มีเทือกเขาบรรทัดและพนมดงรักเป็นแนวยาวอยู่ทางทิศใต้ ซึ่งเป็นต้นกำเนิดของแม่น้ำมูลและลำน้ำสาขาต่างๆ จากนั้นพื้นที่ค่อยๆ ลาดต่ำลงมาทางทิศเหนือสู่แม่น้ำมูล ทำให้เป็นแม่น้ำมูลที่มีปริมาณน้ำมากที่สุดของภาคอีสาน ไหลจากต้นน้ำจากบริเวณเขื่อนมูลบน อำเภอครบุรี จังหวัดนครราชสีมา ไปสู่ จังหวัดบุรีรัมย์ สุรินทร์ ศรีสะเกษ และไปบรรจบกับแม่น้ำโขงที่จังหวัดอุบลราชธานี พื้นที่ส่วนใหญ่ครอบคลุม 10 จังหวัด รวม 118 อำเภอ 19 กิ่งอำเภอในภาคอีสานตอนล่าง และบางส่วนของภาคอีสานตอนกลาง มีอาณาเขตติดต่อ ดังนี้

- ทิศเหนือ ติดกับลุ่มน้ำชีและลุ่มน้ำโขงอีสาน
- ทิศใต้ ติดกับลุ่มน้ำปราจีนบุรี ลุ่มน้ำโตนเลสาปและประเทศกัมพูชา
- ทิศตะวันออก ติดกับลุ่มน้ำโขงและประเทศสาธารณรัฐประชาธิปไตยประชาชนลาว
- ทิศตะวันตก ติดกับ ลุ่มน้ำป่าสักและลุ่มน้ำบางปะกง

พื้นที่ลุ่มน้ำมูล สามารถแบ่งพื้นที่ลุ่มน้ำมูลออกเป็น 3 ส่วน ดังนี้

ลุ่มน้ำมูลส่วนที่ 1 มีพื้นที่ของลุ่มน้ำประมาณ 19,586 ตร.กม. ประกอบด้วยลุ่มน้ำสาขาลำน้ำมูลตอนบน ลำแซะ ลำพระเพลิง ลำตะคอง ลำเชิงไกร ลำจักรราช ลำนางรอง ลำปะเทีย และลำปลายมาศ

ลุ่มน้ำมูลส่วนที่ 2 มีพื้นที่ของลุ่มน้ำประมาณ 25,490 ตร.กม. ประกอบด้วยลุ่มน้ำสาขาลำน้ำมูลส่วนที่ 2 ห้วยเอ็ก ลำสะแทด ลำพังชู ห้วยตาคง ลำชี ลำลับพลา ลำเตา ลำเสียวน้อย ลำเสียวใหญ่ และห้วยทับทัน

ลุ่มน้ำมูลส่วนที่ 3 มีพื้นที่ของลุ่มน้ำประมาณ 25,996 ตร.กม. ประกอบด้วยลุ่มน้ำสาขาลำน้ำมูลส่วนที่ 3 ห้วยสำราญ ห้วยทา ห้วยขยุง ห้วยโงง ลำเซบาย ลำเซ ลำโดมใหญ่ ลำน้ำมูลตอนล่าง ห้วยตุงสูง และลำโดมน้อย

พื้นที่ประสบอุทกภัย มีลักษณะที่แตกต่างกันของแต่ละในพื้นที่ขึ้นอยู่กับภูมิศาสตร์ และที่ตั้งในพื้นที่ที่มีความรุนแรงไม่มากนัก มักเกิดจากปริมาณฝนตกที่ต่อเนื่องในพื้นที่ทำให้เกิดน้ำล้นตลิ่ง น้ำท่วมขัง และบริเวณที่เกิดน้ำท่วมบ่อยครั้งเกิดในจังหวัดอุบลราชธานี เนื่องจากตั้งอยู่ในบริเวณที่ได้รับอิทธิพลทั้งจากแม่น้ำชีและแม่น้ำมูล นอกจากนี้ ยังได้รับผลกระทบจากสภาพเกาะแก่งธรรมชาติในลำน้ำมูลบริเวณท้ายอำเภอบึงสามพัน ซึ่งกีดขวางการไหลของน้ำ

2.1.2 ลุ่มน้ำชี

สภาพภูมิประเทศ


ลุ่มน้ำชี มีพื้นที่ของลุ่มน้ำประมาณ 49,130 ตร.กม. ลุ่มน้ำชีตั้งอยู่ระหว่างเส้นรุ้งที่ 15° 30' เหนือถึงเส้นรุ้งที่ 17° 30' เหนือ และอยู่ระหว่างเส้นแวงที่ 101° 30' ตะวันออก ถึงเส้นแวงที่ 104° 30' ตะวันออก สภาพโดยทั่วไปเป็นเทือกเขาสูง ทางทิศตะวันออกและทิศเหนือคือเทือกเขาภูพาน ทิศตะวันตกคือเทือกเขาตองพญาเย็น ซึ่งเป็นต้นกำเนิดของแม่น้ำชีและแม่น้ำสาขาที่สำคัญหลายสาย ส่วนพื้นที่ตอนกลางเป็นที่ราบถึงลูกคลื่นลอน และมีเนินเล็กน้อยทางตอนใต้ของลุ่มน้ำ ครอบคลุมพื้นที่ 16 จังหวัด ได้แก่ จังหวัดกาฬสินธุ์ ขอนแก่น ชัยภูมิ นครราชสีมา เพชรบูรณ์ มหาสารคาม มุกดาหาร ยโสธร ร้อยเอ็ด ลพบุรี เลย ศรีสะเกษ สกลนคร หนองบัวลำภู อุดรธานี และอุบลราชธานี มีอาณาเขตติดต่อ ดังนี้

- ทิศเหนือติดกับลุ่มน้ำโขง
- ทิศใต้ติดกับลุ่มน้ำมูล
- ทิศตะวันออกติดกับลุ่มน้ำโขงและลุ่มน้ำมูล
- ทิศตะวันตกติดกับลุ่มน้ำป่าสัก

ลำน้ำสายหลัก คือ แม่น้ำชี ซึ่งมีต้นกำเนิดมาจากยอดเขาในแนวเทือกเขาเพชรบูรณ์ ในเขตอำเภอกษัตริย์สมบูรณ จังหวัดชัยภูมิ ลุ่มน้ำชี ประกอบด้วยลุ่มน้ำสาขา 20 สาขา และ ลำน้ำสาขาที่สำคัญ คือ น้ำพรม น้ำพอง น้ำเชิญ ลำปาว และน้ำยัง

ในเขตภาคตะวันออกเฉียงเหนือตอนล่าง จะอยู่ในพื้นที่ลุ่มน้ำสาขาลำน้ำชีตอนล่าง มีพื้นที่ 2,718 ตร.กม. พื้นที่ลุ่มน้ำส่วนใหญ่เป็นที่ราบน้ำท่วมถึง ด้านทิศเหนือติดกับลุ่มน้ำสาขาลำน้ำยัง ด้านทิศตะวันออกติดลุ่มน้ำโขง และด้านทิศใต้ติดกับลุ่มน้ำมูล ด้านต้นน้ำพื้นที่จะกว้างแล้วแคบลง พื้นที่ลุ่มน้ำเริ่มต้นบริเวณอำเภอเสลภูมิ จังหวัดร้อยเอ็ด ผ่านจังหวัดยโสธรแล้วไปสิ้นสุด เมื่อบรรจบกับแม่น้ำมูลก่อนถึงตัวเมืองอุบลราชธานี

พื้นที่ประสบอุทกภัย สภาพการเกิดอุทกภัยในลุ่มน้ำชี โดยส่วนใหญ่มักเกิดขึ้นปีละ 2-3 ครั้ง ในหลายรูปแบบ ได้แก่ น้ำท่วมขัง น้ำไหลล้นตลิ่ง น้ำป่าไหลหลาก และดิน/โคลนถล่ม โดยพื้นที่ที่ประสบอุทกภัยประเภทน้ำท่วมขัง ได้แก่ จังหวัดร้อยเอ็ด กาฬสินธุ์ ขอนแก่น ประเภทน้ำป่าไหลหลาก ได้แก่ จังหวัดชัยภูมิ ขอนแก่น ร้อยเอ็ด ประเภทน้ำล้นตลิ่ง ได้แก่ จังหวัดชัยภูมิ กาฬสินธุ์ ขอนแก่น ร้อยเอ็ด และอุบลราชธานี ส่วนพื้นที่ที่ประสบภัยดิน/โคลนถล่ม ได้แก่ จังหวัดกาฬสินธุ์ และชัยภูมิ



ภาพที่ 1 ภาพแสดงพื้นที่ลุ่มน้ำมูลและลุ่มน้ำชี

2.2 อุทกภัยและสาเหตุการเกิด

อุทกภัย คือ ภัยธรรมชาติที่เกิดขึ้นเนื่องจากมีน้ำเป็นสาเหตุ ในสภาพน้ำท่วม น้ำท่วมฉับพลัน น้ำป่า หรือน้ำไหลเอ่อล้นฝั่งแม่น้ำลำธารทางน้ำ เข้าท่วมพื้นที่ซึ่งปกติไม่ได้อยู่ใต้ระดับน้ำ หรือเกิดจากการสะสมน้ำบนพื้นที่ที่ระบายออกไม่ทัน ทำให้พื้นที่นั้นปกคลุมไปด้วยน้ำ การเกิดอุทกภัยมาจากหลายสาเหตุ ทั้งโดยทางธรรมชาติและเกิดจากฝีมือมนุษย์ ซึ่งอาจเกิดจากฝนตกหนักต่อเนื่องกันเป็นเวลานาน น้ำฝนที่มีปริมาณมากจะไหลเข้าสู่พื้นที่ที่ต่ำกว่า ทำให้เกิดน้ำท่วมฉับพลัน ในบางครั้งอาจทำให้เกิดแผ่นดินถล่ม การเกิดอุทกภัยจากน้ำทะเลหนุน เขื่อนพัง ก็เป็นสาเหตุทำให้เกิดอุทกภัย

ได้ ซึ่งอุทกภัยทำให้เกิดความเสียหายทั้งต่อชีวิต ทรัพย์สินและสิ่งแวดล้อมตามธรรมชาติ รวมไปถึงความเสียหายทางด้านเศรษฐกิจด้วย (ศูนย์เตือนภัยพิบัติแห่งชาติ, 2561)

ลักษณะของอุทกภัย เป็นภัยธรรมชาติมีความรุนแรง และรูปแบบต่าง ๆ กันออกไป ขึ้นอยู่กับลักษณะภูมิประเทศ และสิ่งแวดล้อมของแต่ละพื้นที่โดยมีลักษณะดังนี้

น้ำท่วมฉับพลัน (Flash Flood) หรือน้ำป่าไหลหลาก มักจะเกิดขึ้นในที่ราบต่ำหรือที่ราบลุ่มบริเวณใกล้ ภูเขาต้นน้ำ อันเกิดขึ้นเนื่องจากฝนตกหนักเหนือภูเขาต่อเนื่องเป็นเวลานาน ทำให้จำนวนน้ำสะสมมีปริมาณมากจนพื้นดินและต้นไม้ดูดซับไม่ไหว ทำให้น้ำไหลบ่าลงสู่ที่ราบต่ำเบื้องล่างอย่างรวดเร็ว มีอำนาจทำลายล้างอย่างรุนแรง ทำให้บ้านเรือนพังเสียหายและอาจทำให้เกิดอันตรายถึงชีวิตได้


น้ำท่วมหรือน้ำท่วมขัง (Drainage floods) เป็นลักษณะอุทกภัยที่เกิดขึ้นจากปริมาณน้ำสะสมจำนวนมากที่ ไหลบ่าในแนวระนาบจากที่สูงไปยังที่ต่ำ เข้าท่วมอาคารบ้านเรือน เรือกสวนไร่นาได้รับความเสียหาย หรือ เป็นสภาพน้ำท่วมขังในเขตเมืองใหญ่ ที่เกิดจากฝนตกหนักต่อเนื่องเป็นเวลานาน มีสาเหตุมาจากระบบการระบายน้ำไม่ดีพอ มีสิ่งกีดขวางทางระบายน้ำ หรือเกิดจากน้ำล้นตลิ่ง เกิดขึ้นจากปริมาณน้ำจำนวนมากที่เกิดจากฝนหนักต่อเนื่อง ที่ไหลลงสู่ลำน้ำ หรือแม่น้ำ มีปริมาณมากจนระบายลงสู่ลุ่มน้ำด้านล่างหรือออกสู่ปากน้ำไม่ทัน ทำให้เกิดสภาวะน้ำล้นตลิ่งเข้าท่วม เรือกสวนไร่นาตามสองฝั่งน้ำ จนได้รับความเสียหาย ถนนหรือสะพานอาจชำรุดทางคมนาคมถูกตัดขาดได้

น้ำท่วมบริเวณปากแม่น้ำ เป็นสภาพน้ำท่วมตามปกติของแม่น้ำต่างๆ บริเวณปากแม่น้ำสภาพน้ำท่วมลักษณะนี้เกิดในระยะน้ำนองของแม่น้ำ ขณะเมื่อน้ำนองจะไหลหลากลงสู่ทะเลบริเวณปากแม่น้ำ ซึ่งในช่วงน้ำทะเลหนุนสูงแต่ละวันนั้น ปริมาณน้ำของแม่น้ำที่ไหลหลากลงมาจะถูกน้ำทะเลหนุน ทำให้เกิดน้ำล้นตลิ่ง บริเวณที่ต่ำของแม่น้ำและคลองที่เชื่อมต่อกับแม่น้ำ

ดินถล่มหรือโคลนถล่ม (Land Slide) คือ การเคลื่อนที่ของมวลดินและหินลงมาตามลาดเขาด้วยอิทธิพลของแรงโน้มถ่วงโลก และจะมีน้ำเข้ามาเกี่ยวข้องโดยน้ำจะเป็นตัวลดแรงต้านทานในการเคลื่อนที่ของมวลดินและน้ำจะเป็นตัวที่ทำให้คุณสมบัติของดินที่เป็นของแข็งเปลี่ยนไปเป็นของไหลได้ ดินถล่มมักเกิดตามมาหลังจากน้ำป่าไหลหลาก ในขณะที่เกิดพายุฝนตกหนักรุนแรงต่อเนื่อง หรือหลังการเกิดแผ่นดินไหว และในบางครั้งอาจเกิดดินยุบตัวได้เช่นกัน

2.3 สภาพการไหลของกลุ่มน้ำมูลและลุ่มน้ำชีกับประวัติการเกิดอุทกภัยในพื้นที่ภาคตะวันออกเฉียงเหนือตอนล่าง

รายละเอียดสภาพการไหลของกลุ่มน้ำมูลและลุ่มน้ำชีกับประวัติการเกิดอุทกภัยที่มีน้ำท่วมในพื้นที่ของภาคตะวันออกเฉียงเหนือตอนล่างของประเทศไทย โดยมีลุ่มน้ำมูลครอบคลุมพื้นที่ส่วนใหญ่ โดยมีแม่น้ำมูลเป็นแม่น้ำสายหลักในพื้นที่ แม่น้ำมูลมีทิศทางการไหลจากทิศตะวันตกไปทางทิศตะวันออก การจะไหลมาบรรจบกับแม่น้ำโขงที่ อำเภोजงเจียม จังหวัดอุบลราชธานี ส่วนลุ่มน้ำชีจะอยู่ในพื้นที่ของลุ่มน้ำชีตอนล่างมีแม่น้ำชีไหลจากทิศตะวันตกเฉียงเหนือไปทางทิศตะวันออกเฉียงใต้ และจะไหลมาบรรจบแม่น้ำมูลที่อำเภวารินชำราบ จังหวัดอุบลราชธานี โดยตลอดแนวของแม่น้ำทั้งสองมีการติดตั้งสถานีตรวจวัดน้ำท่า และที่ฝักระวังลุ่มน้ำชีและลุ่มน้ำมูล ดังภาพที่ 2



ภาพที่ 2 ฝักระวังน้ำที่ฝักระวังลุ่มน้ำชี-มูล

ที่มา: ศูนย์อุทกวิทยาชลประทานภาคตะวันออกเฉียงเหนือตอนล่าง กรมชลประทาน. ฝักระวังน้ำตามสถานการณ์น้ำ ลุ่มน้ำชี-มูลตอนล่าง. จาก <https://hydro-4.rid.go.th/>

โดยปกติในพื้นที่ลุ่มน้ำมูลและลุ่มน้ำชีจะมีฝนตกหนักในช่วงเดือนกันยายนและเดือนตุลาคม ในการเกิดอุทกภัยในลุ่มน้ำชีจะมีฝนตกหนักเกือบทั้งลุ่มน้ำ ส่วนลุ่มน้ำมูลโดยเฉลี่ยจะมีฝนตกหนักที่จังหวัดนครราชสีมา (ฉลอง เกิดพิทักษ์ และ ชัยวัฒน์ ขยันการนาวิ, 2557) โดยในพื้นที่ภาคตะวันออกเฉียงเหนือตอนล่าง แม่น้ำชีที่ไหลผ่านจังหวัดยโสธรเมื่อเกิดฝนตกหนักจะส่งผลให้มีความเสี่ยงที่น้ำในแม่น้ำชีล้นตลิ่งเข้าท่วมพื้นที่ที่อยู่ติดกับแม่น้ำและเกิดการกัดเซาะของตลิ่ง เนื่องจาก

ลักษณะของแม่น้ำชีตอนล่างพื้นที่ส่วนใหญ่เป็นที่ราบน้ำท่วมถึง พื้นที่ต้นน้ำจะมีลักษณะกว้างแล้วแคบลง ส่วนแม่น้ำมูลมีต้นน้ำในจังหวัดนครราชสีมาและมีลำตะคองลำน้ำสาขาที่จะไหลมาบรรจบกับแม่น้ำมูลในพื้นที่ต้นน้ำเมื่อฝนที่ตกหนักทำให้มีปริมาณน้ำรวมกับลำน้ำที่มีความคดเคี้ยวทำให้เกิดน้ำล้นตลิ่ง และพื้นที่จังหวัดบุรีรัมย์ สุรินทร์ ร้อยเอ็ด ศรีสะเกษ และอุบลราชธานี มักมีน้ำล้นตลิ่งจากแม่น้ำมูลที่เกิดจากน้ำไหลผ่านในช่วงน้ำหลาก โดยเฉพาะจังหวัดอุบลราชธานีเป็นจังหวัดที่มีน้ำท่วมบ่อยเนื่องจากได้รับอิทธิพลจากแม่น้ำมูลและแม่น้ำชี

ประวัติการเกิดน้ำท่วมในภาคตะวันออกเฉียงเหนือตอนล่าง


- ปี พ.ศ. 2551 ช่วงเดือนกันยายน มีร่องความกดอากาศต่ำและมรสุม ที่มีค่อนข้างกำลังแรง พาดผ่านบริเวณภาคกลาง ภาคตะวันออก ภาคเหนือ และภาคตะวันออกเฉียงเหนือ ทำให้มีฝนตกหนักและติดต่อกันครอบคลุมพื้นที่เป็นบริเวณกว้างพื้นที่ได้รับผลกระทบหนัก ได้แก่ จังหวัดนครราชสีมา ขอนแก่น บุรีรัมย์ อุบลราชธานี และบุรีรัมย์
- ปี พ.ศ. 2552 ช่วงปลายเดือนกันยายน มีร่องความกดอากาศต่ำพาดผ่านอยู่ก่อน แล้วมีพายุดีเปรสชันกิสนาจะเคลื่อนที่เข้าสู่ประเทศไทยในวันที่ 30 กันยายน ทำให้เกิดฝนตกหนักซ้ำและเกิดน้ำท่วมเป็นบริเวณกว้าง ได้แก่ จังหวัดศรีสะเกษ อุบลราชธานี บุรีรัมย์ และนครราชสีมา
- ปี พ.ศ. 2553 ช่วงเดือนกันยายน มีร่องมรสุมกำลังแรงพาดผ่านภาคเหนือและภาคตะวันออกเฉียงเหนือประกอบกับมีลมมรสุมตะวันตกเฉียงใต้พัดปกคลุมทะเลอ่าวไทย ทำให้มีฝนตกชุกหนาแน่นและส่งผลทำให้เกิดน้ำท่วมในอำเภอเมืองนครราชสีมา จังหวัดนครราชสีมา
- ปี พ.ศ. 2556 ช่วงเดือนกันยายนถึงตุลาคม มีอิทธิพลของร่องมรสุมที่พาดผ่านบริเวณประเทศไทยตอนบน และมรสุมตะวันตกเฉียงใต้ที่พัดปกคลุมทะเลอันดามัน และอ่าวไทย ประเทศไทย ทำให้มีฝนตกหนักอย่างต่อเนื่องส่งผลให้เกิดน้ำท่วมเป็นบริเวณกว้างในหลายจังหวัด ได้แก่ จังหวัดสุรินทร์ ศรีสะเกษ อุบลราชธานี อำนาจเจริญ บุรีรัมย์ ยโสธร ชัยภูมิ และมุกดาหาร
- ปี พ.ศ. 2557 ช่วงเดือนตุลาคม มีอิทธิพลจากไต้ฝุ่น “รามสูร” พัดผ่าน ส่งผลให้มรสุมตะวันตกเฉียงใต้ที่พัดปกคลุมทะเลอันดามัน และอ่าวไทย ประเทศไทย ทำให้บริเวณประเทศไทยตอนบนมีฝนกระจาย เกิดน้ำท่วมฉับพลันในหลายพื้นที่ของกลุ่มน้ำมูลและลุ่มน้ำชี
- ปี พ.ศ. 2560 ตลอดเดือนตุลาคม ประเทศไทยได้รับอิทธิพลจากร่องมรสุมที่พาดผ่านตลอดทั้งเดือน มีมรสุมได้พาดผ่านบริเวณตอนบนของประเทศ นอกจากนี้ยังได้รับอิทธิพลจากพายุ “depression-02” ทำให้ฝนตกหนักกระจายตัวเป็นบริเวณกว้างส่งผลทำให้น้ำในลำน้ำเพิ่มขึ้นจนล้นตลิ่งเข้าท่วมในหลายพื้นที่ ได้แก่ จังหวัดร้อยเอ็ด อุบลราชธานี
- ปี พ.ศ. 2563 ในช่วงเดือนกันยายนประเทศไทยได้รับอิทธิพลของพายุโซนร้อน “โนอึล” เริ่มส่งผลทำให้เกิดฝนตกหนักในหลายพื้นที่ของภาคตะวันออกเฉียงเหนือทำให้มีฝนตกหนักถึงหนักมากในหลายพื้นที่ ได้แก่ จังหวัดสุรินทร์ อุบลราชธานี บุรีรัมย์ ศรีสะเกษ ยโสธร นครราชสีมาและชัยภูมิ

- ปี พ.ศ. 2564 ประเทศไทยได้รับอิทธิพลพายุโซนร้อน ‘เตี้ยนหมู่’ ที่เคลื่อนปกคลุมประเทศไทยตอนบนตั้งแต่วันที่ 23 กันยายน จนถึงเดือนตุลาคมทำให้มีฝนตกหนักถึงหนักมาก และเกิดน้ำท่วมฉับพลัน น้ำป่าไหลหลากในพื้นที่ ได้แก่ จังหวัดนครราชสีมา อุบลราชธานี

2.4 ทฤษฎีที่เกี่ยวข้อง

2.4.1 Artificial Neural Network (ANN)

โครงข่ายประสาทเทียม (Neural Network) เป็นศาสตร์แขนงหนึ่งทางด้านปัญญาประดิษฐ์ (Artificial Intelligence: AI) ที่สามารถนำไปประยุกต์ใช้กับงานหลายด้านได้อย่างมีประสิทธิภาพ เช่น การจำแนกรูปแบบ การทำนาย การจัดกลุ่ม เป็นต้น มีหลักการสำคัญ คือ การที่จะลอกเลียนแบบการทำงานของเซลล์ประสาทในสมองมนุษย์เพื่อทำงานได้อย่างมีประสิทธิภาพ ลักษณะทั่วไปของโครงข่ายประสาทเทียม คือ การที่โหนด (Node) ต่าง ๆ จำลองมาจากไซแนปส์ (Synapse) ของเซลล์ประสาทระหว่างเดนไดรต์ (Dendrite) และแอกซอน (Axon) โดยมีฟังก์ชันเป็นตัวกำหนดสัญญาณส่งออก (Activation Function or Transfer Function) (ธนา วุฒิ ประกอบผล, 2552) การที่เป็นเทคนิคการคำนวณที่ได้รับแรงบันดาลใจจากการเชื่อมต่อทางชีวภาพของเซลล์ประสาท เช่นเดียวกับโครงสร้างเซลล์ประสาททางชีวภาพ โครงข่ายประสาทเทียมกำหนดเซลล์ประสาทเป็นหน่วยประมวลผลกลาง ซึ่งดำเนินการทางคณิตศาสตร์เพื่อสร้างผลลัพธ์ของข้อมูลชุดนำเข้า ดังภาพที่ 3



ภาพที่ 3 โครงสร้างแบบจำลอง Artificial Neural Network
ที่มา: ไกรศักดิ์ เกษร (2564)

จากภาพที่ 3 จะได้สมการฟังก์ชันผลรวมที่เป็นผลรวมของผลลัพธ์ที่ออกมาจากแต่ละโหนด ดังนี้

$$S_i = \sum_{i=1}^a x_i w_{ji}$$

โดยที่ x_i คือ ค่าข้อมูลนำเข้า

w_{ij} คือ น้ำหนักที่เกี่ยวข้องกับแต่ละการเชื่อมต่อเข้าสู่เซลล์ประสาทจากหน่วยที่ i ไปยังหน่วยที่ j

จากภาพโครงสร้างแบบจำลองโครงข่ายประสาทเทียมจะประกอบด้วยส่วนที่สำคัญ 5 ส่วน ได้แก่ ข้อมูลนำเข้า (Input) ข้อมูลส่งออก (Output) ค่าน้ำหนัก (Weights) ฟังก์ชันผลรวม (Summation Function) และ ฟังก์ชันการแปลง (Transfer Function) และจะแบ่งการเชื่อมต่อโหนดออกเป็นกลุ่มย่อย ได้ 3 ชั้น ดังนี้ ชั้นแรกจะเป็นชั้นนำเข้าข้อมูลเข้า (Input Layer) ชั้นที่สองจะเป็นชั้นที่อยู่ตรงกลางเป็นชั้นที่รับข้อมูลเข้าและส่งออกข้อมูล เรียกว่า ชั้นซ่อน (Hidden Layer) และชั้นสุดท้ายเป็นชั้นที่ส่งออกข้อมูล (Output Layer)

เซลล์ประสาทแต่ละเซลล์ประกอบด้วยฟังก์ชันการแปลงที่เปิดใช้งาน หรือบางครั้งอาจเรียกฟังก์ชันการแปลงเป็นฟังก์ชันกระตุ้น (Activation Function) จะแบ่งได้ 2 ประเภท ได้แก่

1.) ฟังก์ชันการแปลงเชิงเส้น (Linear Transfer Function)

การใช้งานฟังก์ชันการแปลงเชิงเส้น จะเรียกว่า ไม่มีการเปิดใช้งานฟังก์ชัน (no Activation) หรือ เป็นฟังก์ชันเอกลักษณ์ (Identity Function) ฟังก์ชันไม่ได้ทำอะไรกับผลรวมค่าถ่วงน้ำหนักของตัวแปรนำเข้า แค่แยกค่าที่ได้รับออกมา มีสมการดังนี้

$$f(x) = x$$

ฟังก์ชันการแปลงเชิงเส้นมีปัญหาหลักสองประการ

- ไม่สามารถใช้การแพร่ย้อนกลับ (Backpropagation) ได้เนื่องจากอนุพันธ์ของฟังก์ชันเป็นค่าคงที่และไม่มีความสัมพันธ์กับตัวแปรนำเข้า
- ชั้นทั้งหมดของโครงข่ายประสาทเทียมจะยุบรวมเป็นชั้นเดียวหากใช้ฟังก์ชันการแปลงเชิงเส้น ไม่ว่าชั้นในโครงข่ายประสาทเทียมจะมีจำนวนเท่าใดก็ตาม ชั้นสุดท้ายจะยังคงเป็นฟังก์ชันเชิงเส้นของชั้นแรก โดยพื้นฐานแล้ว ฟังก์ชันการแปลงเชิงเส้นจะเปลี่ยนโครงข่ายประสาทเทียมให้เป็นเพียงชั้นเดียว

2.) ฟังก์ชันการแปลงไม่ใช่เชิงเส้น (Non-linear Transfer Function) มี 12 แบบ ได้แก่

2.1) Sigmoid Function หรือ Logistic Activation Function

ฟังก์ชันนี้ค่าผลลัพธ์ช่วงระหว่าง 0 ถึง 1 มีรูปทรง S ตัวแปรนำเข้าที่มีค่ามาก (ค่าบวกมาก) ค่าผลลัพธ์จะเข้าใกล้ 1 มากขึ้น ผลลัพธ์ยิ่งเล็ก (ค่าลบมาก) ค่าผลลัพธ์ก็จะเข้าใกล้ 0 เป็นฟังก์ชันเหมาะกับ ฟังก์ชันนี้เหมาะที่จะใช้เมื่อต้องการทำนายความน่าจะเป็น (Probability) ของข้อมูลส่งออก และฟังก์ชันนี้เป็นหนึ่งในฟังก์ชันที่ใช้กันอย่างแพร่หลาย มีสมการดังนี้

$$f(x) = \frac{1}{1 + e^{-x}}$$

ข้อจำกัดของฟังก์ชัน จากการหาอนุพันธ์ของฟังก์ชันข้างต้นจะได้ค่าความชันที่มีนัยสำคัญอยู่ในช่วง -3 ถึง 3 ซึ่งค่าที่น้อยกว่า -3 หรือมากกว่า 3 ค่าความชันที่ได้จะน้อยมากและเข้าใกล้ 0 ทำให้เกิดปัญหา Vanishing Gradient ทำให้การฝึกอบรมแบบจำลองยากขึ้นและไม่เสถียร

2.2) Hyperbolic Tangent Function (Tanh Function)

ฟังก์ชัน Tanh คล้ายกับฟังก์ชัน Sigmoid หรือ Logistic Activation มาก และยังมีรูปทรง S เหมือนกัน โดยมีความแตกต่างของช่วงผลลัพธ์ที่ -1 ถึง 1 การใช้ฟังก์ชันการเปิดใช้งานนี้คือ ค่าของผลลัพธ์ของฟังก์ชันที่การเปิดใช้งาน Tanh จะอยู่กึ่งกลาง ดังนั้น เราจะสามารถจัดค่าผลลัพธ์เป็นค่าลบ เป็นค่าที่อยู่ตรงกลาง หรือเป็นค่าบวกได้ง่ายขึ้น โดยปกติจะใช้ในชั้นซ่อนอยู่ของโครงข่ายประสาทเทียมเนื่องจากค่าอยู่ระหว่าง -1 ถึง 0 ดังนั้น ค่าเฉลี่ยของชั้นที่ซ่อนอยู่จึงเป็น 0 หรือใกล้เคียงมาก ช่วยในการจัดกึ่งกลางข้อมูลและทำให้การเรียนรู้สำหรับชั้นถัดไปง่ายขึ้นมาก โดยมีสมการดังนี้

$$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$$

ข้อจำกัดของฟังก์ชันคล้ายกับฟังก์ชัน sigmoid

2.3) Rectified Linear Unit Function (ReLU Function)

Rectified Linear Unit มีความคล้ายฟังก์ชันเชิงเส้น แต่ ReLU มีฟังก์ชันเชิงอนุพันธ์และช่วยให้สามารถใช้การแพร่ย้อนกลับได้ ฟังก์ชัน ReLU ไม่ได้เปิดใช้งานโหนดทั้งหมดในเวลาเดียวกัน โหนดจะถูกปิดใช้งานก็ต่อเมื่อผลลัพธ์ของการแปลงเชิงเส้นมีค่าน้อยกว่า 0 โดยมีสมการดังนี้

$$f(x) = \max(0, x)$$

ข้อจำกัดของฟังก์ชัน จากการหาอนุพันธ์ของฟังก์ชัน ค่าลบของกราฟทำให้ค่าความชันเป็นศูนย์ ด้วยเหตุผลนี้ในระหว่างกระบวนการ backpropagation น้ำหนักและความเอนเอียงของโหนดบางตัวจึงไม่ได้รับการอัปเดต ทำให้เกิดการสร้างโหนดที่ไม่เคยเปิดใช้งาน ค่าตัวแปรนำเข้าที่เป็นลบทั้งหมดจะกลายเป็นศูนย์ทันที เรียกว่า ปัญหา Dying ReLU ซึ่งปัญหานี้จะลดความสามารถของแบบจำลองในการปรับหรือการเรียนรู้จากข้อมูลอย่างเหมาะสม

2.4) Leaky Rectified Linear Unit Function (Leaky ReLU Function)

Leaky ReLU เป็นเวอร์ชันปรับปรุงของฟังก์ชัน ReLU เพื่อแก้ปัญหา Dying ReLU เนื่องจากมีความชันเป็นบวกเล็กน้อยในพื้นที่ลบจึงให้ผลลัพธ์ที่เป็นค่าลบได้ เพื่อแก้ปัญหาเซลล์ประสาทที่ตาย หรือ โหนดที่ไม่ถูกเปิดใช้งาน มีสมการดังนี้

$$f(x) = \max(0.1x, x)$$

ข้อจำกัดของฟังก์ชัน การคาดคะเนอาจไม่สอดคล้องกันสำหรับค่าตัวแปรนำเข้าเชิงลบ และ Gradient สำหรับค่าลบเป็นค่าเล็กน้อยที่ทำให้การเรียนรู้พารามิเตอร์แบบจำลองใช้เวลานาน

2.5) Parametric Rectified Linear Unit Function (Parametric ReLU Function)

Parametric ReLU เป็นอีกหนึ่งตัวแปรของ ReLU ที่มีจุดมุ่งหมายเพื่อแก้ปัญหา Dying ReLU ฟังก์ชันนี้ให้ความชันของส่วนลบของฟังก์ชันเป็นพารามิเตอร์ a โดยการทำ backpropagation จะได้ค่า a ที่เหมาะสมที่สุด มีสมการดังนี้

$$f(x) = \max(ax, x)$$

โดยที่ a คือ พารามิเตอร์ความชันสำหรับค่าลบ

ฟังก์ชัน ReLU แบบกำหนดพารามิเตอร์จะใช้เมื่อฟังก์ชัน Leaky ReLU ยังคงล้มเหลวในการแก้ปัญหาเซลล์ประสาทที่ตาย และข้อมูลที่เกี่ยวข้องไม่ถูกส่งไปยังชั้นถัดไปได้ ข้อจำกัดของฟังก์ชันนี้คือการทำงานอาจแตกต่างกันสำหรับปัญหาต่างๆ ขึ้นอยู่กับค่าของพารามิเตอร์ความชัน

2.6) Exponential Linear Units Function (ELU Function)

ฟังก์ชัน ELU เป็นตัวแปรของ ReLU ที่ปรับเปลี่ยนความชันของส่วนลบของฟังก์ชัน ELU ใช้เส้นโค้งบันทึกเพื่อกำหนดค่าลบซึ่งแตกต่างจากฟังก์ชัน Leaky ReLU และ Parametric ReLU ด้วยเส้นตรง มีสมการดังนี้

$$f(x) = \begin{cases} x & ; x \geq 0 \\ \alpha(e^x - 1) & ; x < 0 \end{cases}$$

ELU จะปรับให้เรียบขึ้นอย่างช้าๆ จนกระทั่งผลลัพธ์เท่ากับ $-\alpha$ ข้อจำกัดของฟังก์ชัน ELU คือ การเพิ่มเวลาในการคำนวณเนื่องจากการดำเนินการแบบเอกซ์โพเนนเชียลรวมอยู่ด้วย ไม่มีการเรียนรู้ค่า α เกิดขึ้น และปัญหา Exploding Gradient

2.7) Softmax Function

Softmax Function คือ ฟังก์ชันที่รับตัวแปรนำเข้าเป็น Vector ของ Logit จำนวนจริง แล้ว Normalize ออกมาเป็นความน่าจะเป็น (Probability) ที่ผลรวมเท่ากับ 1 โดยทั่วไปจะใช้เป็นฟังก์ชันเปิดใช้งานสำหรับชั้นสุดท้ายของโครงข่ายประสาทเทียมในกรณีของการจำแนกประเภทหลายประเภท มีสมการดังนี้

$$\text{softmax}(z)_i = \frac{e^{z_i}}{\sum_{k=1}^K e^{z_k}}$$

เมื่อ $i = 1, 2, \dots, K$ และ $z = (z_1, \dots, z_K) \in \mathbb{R}^K$

2.8) Self-Gated Function (Swish)

เป็นฟังก์ชันการเปิดใช้งานแบบปิดตัวเองที่พัฒนาโดยนักวิจัยของ Google

Swish จับคู่อย่างสม่ำเสมอหรือมีประสิทธิภาพดีกว่าฟังก์ชัน ReLU บนโครงข่ายประสาทเทียมเชิงลึก (Deep Neural Networks) ที่ใช้กับโดเมนที่ท้าทายต่างๆ เช่น การจัดประเภทรูปภาพ การแปลด้วยคอมพิวเตอร์ เป็นต้น ฟังก์ชันนี้มีขอบเขตด้านล่างแต่ไม่มีขอบเขตด้านบน มีสมการดังนี้

$$f(x) = x \times \text{sigmoid}(x)$$

2.9) Gaussian Error Linear Unit Function (GELU)

ฟังก์ชัน GELU คือ $x\Phi(x)$ เมื่อ $\Phi(x)$ ฟังก์ชันการกระจายสะสมแบบเกาส์มาตรฐาน ตัวแปรนำเข้า น้ำหนัก เป็นความไม่เชิงเส้นของ GELU ตามเปอร์เซ็นต์ไทล์ แทนที่จะป้อนค่า Input Gate ด้วยเครื่องหมายเหมือนใน ReLU ($x1_{x>0}$) ดังนั้น GELU จึงถูกมองว่าเป็น ReLU ปรับให้เรียบ

$$f(x) = xP(X \leq x) = x\Phi(x) = 0.5x \left(1 + \tanh \left[\sqrt{2/\pi} (x + 0.044715x^3) \right] \right)$$

2.10) Scaled Exponential Linear Unit Function (SELU)

SELU ถูกกำหนดไว้ในโครงข่ายการทำให้เป็นมาตรฐานในตัวเองและดูแลการทำให้เป็นมาตรฐานภายใน ซึ่งหมายความว่าแต่ละชั้นจะรักษาค่าเฉลี่ยและความแปรปรวนจากชั้นก่อนหน้า SELU เปิดใช้งานการทำให้เป็นมาตรฐานนี้โดยการปรับค่าเฉลี่ยและความแปรปรวน มีสมการดังนี้

$$f(x) = \lambda \begin{cases} x & ; x \geq 0 \\ \alpha(e^x - 1) & ; x < 0 \end{cases}$$

อีกประเภทของ Activation Function จากที่กล่าวมา คือ Binary Step Function เป็นฟังก์ชันที่ขึ้นอยู่กับค่าเกณฑ์ (Threshold) ที่กำหนดว่าไหนควรเปิดใช้งานหรือไม่ ตัวแปรนำเข้าที่ป้อนให้กับฟังก์ชันการเปิดใช้งานจะถูกเปรียบเทียบกับเกณฑ์ที่กำหนด ถ้าผลลัพธ์มากกว่าไหนด์จะทำงาน มิฉะนั้นจะถูกปิดใช้งาน หมายความว่าผลลัพธ์จะไม่ถูกส่งต่อไปยังชั้นที่ซ่อนอยู่ถัดไป มีฟังก์ชันดังนี้

$$f(x) = \begin{cases} 1 & ; x \geq 0 \\ 0 & ; x < 0 \end{cases}$$

ข้อจำกัดของฟังก์ชัน คือ ไม่สามารถให้ผลลัพธ์หลายค่าได้ นั่นคือ ไม่สามารถใช้สำหรับปัญหาจำแนกประเภทแบบหลายประเภทได้ และความชันของฟังก์ชัน step เป็นศูนย์ ซึ่งทำให้เป็นปัญหาในกระบวนการ backpropagation

การเลือกฟังก์ชันการแปลง สำหรับ Output Layer ตามประเภทของปัญหา ดังนี้

- Regression (การถดถอย) เหมาะกับ ฟังก์ชัน Linear
- Binary classification (การจำแนกแบบ 2 กลุ่ม) เหมาะกับ ฟังก์ชัน Sigmoid
- Multi-Class Classification (การจำแนกประเภทหลายกลุ่ม) เหมาะกับ ฟังก์ชัน Softmax

- Multi-Label Classification (การจำแนกประเภทหลายประเภท) เหมาะกับ ฟังก์ชัน Sigmoid โดยทั่วไปแล้ว ฟังก์ชันการแปลงใช้ในชั้นที่ซ่อนอยู่จะถูกเลือกตามประเภทของสถาปัตยกรรมโครงข่ายประสาทเทียม
- Convolutional Neural Network (CNN) เหมาะกับ ฟังก์ชัน ReLU
- Recurrent Neural Network (RNN) เหมาะกับ ฟังก์ชัน Tanh และ/หรือ Sigmoid




ภาพที่ 4 กราฟของ Activation Function

ที่มา: Baheti, P. Activation Functions in Neural Networks [12 Types & Use Cases] from <https://www.v7labs.com/blog/neural-networks-activation-functions>

2.4.2 Long-Short Term Memory networks (LSTM)

Long-Short Term Memory networks (LSTM) ได้รับการเสนอโดย Hochreiter & Schmidhuber ในปี ค.ศ. 1997 และได้รับการพัฒนาอย่างต่อเนื่องและได้รับความนิยมอย่างมากในการประยุกต์ใช้การปัญหาต่างๆ มากมาย และปัจจุบันมีการใช้กันอย่างแพร่หลาย

LSTM เป็นโครงข่ายประสาทเทียมแบบวนกลับชนิดพิเศษ เป็นโครงข่ายประสาทเทียมอีกรูปแบบหนึ่ง ซึ่งถูกพัฒนามาจาก Recurrent Neural Network (RNN) โดยจะสามารถใช้กับข้อมูลที่มีจำนวนชั้นหรือลำดับที่ต่อเนื่องกันมากได้ นอกจากนี้ LSTM ยังสามารถเลือกที่จะจดจำข้อมูลหรือการทำข้อมูลในอดีตหรือ Hidden State ก่อนหน้าได้ โดยกระบวนการทำงานของ LSTM มี 5 ส่วน ได้แก่ การลืม การเขียน การอัปเดต การอ่านค่า และการส่งออก ตามลำดับ




ภาพที่ 5 โครงสร้างแบบจำลอง Long Short Term Memory networks

ที่มา: Olah, C. Understanding LSTM Networks. from <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

หลักการทำงานของ LSTM จะมีฟังก์ชันที่มีหน้าหน้าคล้าย ประตู (Gate) ที่คอยควบคุมข้อมูลที่จะเข้ามาในโหนด ประกอบด้วย 3 ส่วน ได้แก่ Forget Gate, Input Gate และ Output Gate มีลำดับขั้นตอนดังนี้


ขั้นตอนแรกเป็นส่วนของ Forget Gate มีหน้าที่กำหนดข้อมูลเข้าแล้วทำการตัดสินใจว่าทั้งข้อมูล หรือจะเก็บข้อมูล โดยตัดสินใจจะผ่านฟังก์ชัน Sigmoid เรียกว่า " Forget Gate Layer " โดยที่ h_{t-1} และ x_t จะกำหนดโดยฟังก์ชัน f_t ดังภาพที่ 5



ภาพที่ 6 แสดงขั้นตอนของ Forget Gate Layer

ที่มา: Olah, C. Understanding LSTM Networks. from <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

ขั้นตอนต่อไปเป็นส่วนของ Input Gate ข้อมูลที่รับเข้ามาใหม่จะตัดสินใจว่าจะบันทึกข้อมูลหรือ เขียน (Write) ลงในโน้ต จะมีสองส่วนในการทำงาน ส่วนแรก จะดำเนินการผ่านฟังก์ชัน Sigmoid เรียกว่า Input Gate Layer จะตัดสินใจว่าจะอัปเดตค่าใน Cell State (Update Cell State) หรือไม่ ถัดไป Tanh Layer จะสร้างเวกเตอร์ของค่าตัวเลือก (Candidate values: g_t) ใหม่ขึ้นมา ที่สามารถเพิ่มลงใน Cell State ในขั้นตอนถัดไป จะรวมที่อัปเดตกับค่าตัวเลือกเข้าด้วยกันเพื่อสร้างการอัปเดต State ดังภาพที่ 6




ภาพที่ 7 แสดงขั้นตอนของ Input Gate Layer

ที่มา: Olah, C. Understanding LSTM Networks. from <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

การอัปเดต Cell State เซลล์เก่า c_{t-1} แล้ว ส่งออกเซลล์ใหม่ c_t ที่มาจากโหนดก่อนและขั้นตอนก่อนหน้านี้ได้ตัดสินใจแล้วว่าทำอะไร นำค่าที่ตัดสินใจจาก Gate Layer มาคูณ State เก่า ด้วย f_t สิ่งสิ่งที่ตัดสินใจที่จะลืมก่อนหน้านี้ จากนั้นก็รวมกับฟังก์ชัน i_t (การเขียน) คูณกับค่าตัวเลือก (g_t) ในกรณีนี้ คือการทิ้งข้อมูลเกี่ยวโหนดเก่าและเพิ่มข้อมูลใหม่ตามที่ตัดสินใจในขั้นตอนก่อนหน้านี้

ขั้นตอนสุดท้ายเป็นส่วนของ Output Gate ต้องตัดสินใจว่าจะส่งออกอะไร หรือ เป็นขั้นตอนของการเตรียมข้อมูลก่อนส่งออก ผลลัพธ์จะขึ้นอยู่กับ Cell State ที่ผ่านกระบวนการคำนวณแล้ว โดยผ่านฟังก์ชัน Sigmoid ซึ่งจะตัดสินใจว่าส่วนใดของ Cell State ที่จะส่งออก จากนั้นใส่ Cell State ผ่าน Tanh (เพื่อหาค่าให้อยู่ระหว่าง -1 ถึง 1) และคูณด้วยผลลัพธ์ของ Sigmoid Layer เพื่อตั้งค่า Weight และส่งออกเฉพาะส่วนที่ตัดสินใจ ดังภาพที่ 7



ภาพที่ 8 แสดงขั้นตอนของ Output Gate Layer

ที่มา: Olah, C. Understanding LSTM Networks. from <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

จากข้างต้นสามารถลำดับสมการ ดังนี้

$$f_t = \sigma(W_{x^f}x_t + W_{h^f}h_{t-1} + b_f)$$

$$i_t = \sigma(W_{x^i}x_t + W_{h^i}h_{t-1} + b_i)$$

$$g_t = \tanh(W_{x^g}x_t + W_{h^g}h_{t-1} + b_g)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t$$

$$o_t = \sigma(W_{x^o}x_t + W_{h^o}h_{t-1} + b_o)$$

$$h_t = o_t \odot \tanh(c_t)$$

โดยที่ x_t เวกเตอร์นำเข้าของหน่วย LSTM

W คือ เมทริกซ์น้ำหนัก

b คือ เวกเตอร์พารามิเตอร์ bias

f_t คือ ฟังก์ชันเวกเตอร์การเปิดใช้งานสำหรับ Forget Gate

i_t คือ ฟังก์ชันเวกเตอร์การเปิดใช้งานสำหรับ Input Gate

o_t คือ ฟังก์ชันเวกเตอร์การเปิดใช้งานสำหรับ Output Gate

h_t คือ เวกเตอร์ hidden state

c_t แสดงถึง Cell State ได้รับการปรับปรุงโดย g_t (Update Gate)

2.4.3 Physics Guided Machine Learning

การประยุกต์ใช้แบบจำลองของ Machine Learning มีความสำเร็จในการใช้งานในหลายด้าน แต่ในการใช้งานแบบจำลองรูปแบบยังมีข้อจำกัดในการเข้าใจกระบวนการพื้นฐานทางกายภาพของตัวแปร ดังนั้น Physics Guided Machine Learning (PGML) เป็นการประยุกต์ใช้ Machine Learning ให้มีความสามารถในการจัดการกับกลไกทางฟิสิกส์ (Pawar S, et al., 2020) กรอบแนวคิดของการเอาวิธีการทางฟิสิกส์มาใช้ในการเรียนรู้ของเครื่องมืออยู่สองลักษณะที่สำคัญ คือ

- 1) การสร้างแบบจำลองผสมผสานระหว่างแบบจำลองทางฟิสิกส์และการเรียนรู้ของเครื่องที่เรียกว่า แบบจำลองข้อมูลทางฟิสิกส์แบบไฮบริด (Hybrid-Physics Data: HPD)
- 2) ใช้ความรู้ทางวิทยาศาสตร์เป็นฟังก์ชันการสูญเสียตามฟิสิกส์ (Physics-based Loss Functions)

การใช้ฟังก์ชันการสูญเสียตามฟิสิกส์ โดยที่ PGML (Daw A, et al., 2019) เป็นแนวคิดของการเรียนรู้ของเครื่อง ที่พิจารณาการสูญเสีย (Loss) ของการทำนายค่าเป้าหมาย Y และวัดการฝ่าฝืนหลักการทางฟิสิกส์ในผลลัพธ์ของแบบจำลอง $\hat{Y}$ ซึ่งแทนเป็น Loss ตามหลักฟิสิกส์ในวัตถุประสงค์ของ PGML ตามสมการ ดังนี้

$$\arg \min \text{Loss}(Y, \hat{Y}) + \lambda_{PHY} \text{PHY.LOSS}(\hat{Y})$$

โดยที่ λ_{PHY} เป็น ไฮเปอร์พารามิเตอร์การแลกเปลี่ยน (Trade-off Hyper Parameter) ที่ตัดสินความสำคัญสัมพัทธ์ของการลดความไม่สอดคล้องทางฟิสิกส์ให้น้อยที่สุดเมื่อเทียบกับค่าการสูญเสียเชิงประจักษ์ (Loss) และ ค่าความสูญเสียของความซับซ้อนของแบบจำลอง (PHY.LOSS) ด้วยการใช้การสูญเสียตามฟิสิกส์ PGML จำกัดพื้นที่การค้นหาของน้ำหนักใน Machine Learning ให้เป็นตัวเลือกที่สอดคล้องกันทางฟิสิกส์

2.4.4 การประเมินประสิทธิภาพของแบบจำลอง

การประเมินแบบจำลอง ใช้ค่าทางสถิติเป็นเกณฑ์ในการวัดความประสิทธิภาพของแบบจำลอง มี 3 ค่า ดังนี้

1.) ค่าสัมประสิทธิ์ประสิทธิภาพของแนช-ซัทคลิฟฟ์ (Nash-Sutcliffe Efficiency: NSE)

NSE คือ ค่าที่แสดงถึงความแม่นยำของแบบจำลอง หรือประสิทธิภาพของการพยากรณ์ของแบบจำลอง ซึ่งมีค่าระหว่าง $-\infty$ ถึง 1

$$NSE = 1 - \frac{\sum_{t=1}^N (Q_{obs,t} - Q_{sim,t})^2}{\sum_{t=1}^N (Q_{obs,t} - \bar{Q}_{obs})^2}$$

2.) รากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Squared Error: RMSE)

RMSE คือ ค่าที่แสดงถึงความแตกต่างระหว่างค่าที่พยากรณ์โดยแบบจำลองหรือตัวประมาณ และค่าจริงที่สังเกตได้ เป็นค่าประเมินค่าความคลาดเคลื่อนของความผิดพลาดเกิดขึ้นของแบบจำลอง

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (Q_{obs,t} - Q_{sim,t})^2}$$

3.) ร้อยละความเอนเอียง (Percentage Bias: PBIAS)

PBIAS เป็นการวัดแนวโน้มเฉลี่ยของแบบจำลอง ว่าความคลาดเคลื่อนใหญ่หรือเล็กกว่าในคู่ที่สังเกต ค่าที่เหมาะสมคือ 0 ค่าบวกบ่งชี้ว่าแบบจำลองมีค่าความคลาดเคลื่อนต่อการประเมินค่าต่ำเกินไป ในขณะที่ค่าลบบ่งชี้ว่ามีค่าความคลาดเคลื่อนต่อการประเมินค่าสูงเกินไป (Gupta H.V. et al, 1999)

$$PBIAS = \frac{\sum_{t=1}^N (Q_{obs,t} - Q_{sim,t})}{\sum_{t=1}^N Q_{obs,t}} \times 100$$

เมื่อ	$Q_{obs,t}$	คือ	ค่าสังเกตของข้อมูลที่เวลาที่ t
	$Q_{sim,t}$	คือ	ค่าผลลัพธ์จากแบบจำลองที่เวลาที่ t
	$\bar{Q}_{obs}$	คือ	ค่าเฉลี่ยของค่าสังเกตของข้อมูล
	N	คือ	จำนวนข้อมูลทั้งหมดที่พิจารณา

ตารางที่ 1 การแปลความหมายค่า NSE และ PBIAS

คะแนนการวัดประสิทธิภาพ	NSE	PBIAS
ดีมาก	$0.75 < \text{NSE} < 1.00$	$\text{PBIAS} < \pm 10$
ดี	$0.65 < \text{NSE} < 0.75$	$\pm 10 < \text{PBIAS} < \pm 15$
พอใช้ได้	$0.50 < \text{NSE} < 0.65$	$\pm 15 < \text{PBIAS} < \pm 25$
แย่	$\text{NSE} < 0.50$	$\text{PBIAS} > \pm 25$

ที่มา: Moriasi D. N. et al. (2007).

จากตารางที่ 1 สามารถอธิบายความหมายของค่า NSE และ PBIAS ได้ดังนี้ ค่า NSE คือ ค่าของความแม่นยำของแบบจำลอง (Model Accuracy) โดยค่าที่เข้าใกล้ 1 หมายความว่าแบบจำลองสามารถพยากรณ์หรือคาดการณ์ได้โดยไม่มีข้อผิดพลาด (Perfect Fit) ค่า NSE มากกว่า 0.75 หมายความว่าแบบจำลองสามารถพยากรณ์หรือคาดการณ์ได้ดีมาก ถ้าค่า NSE มากกว่า 0.50 อยู่ในเกณฑ์ที่พอรับได้ และค่า PBIAS คือค่าส่วนเบี่ยงเบนของค่าพยากรณ์ที่แสดงในรูปแบบของร้อยละ โดยค่า PBIAS ที่อยู่ระหว่าง -10 ถึง 10 อยู่ในเกณฑ์ที่ดีมาก ถ้าค่า PBIAS อยู่ในช่วงระหว่าง -25 ถึง 25 อยู่ในเกณฑ์ที่พอรับได้

2.5 งานวิจัยที่เกี่ยวข้อง

รักษัณณา ภูสีเขียว และสุรณพรีร์ ภูมิวุฒิสาร (2565) ทำการศึกษาโค่งข่ายประสาทเทียมเชิงลึกในการสร้างแบบจำลองเพื่อใช้ในการพยากรณ์มีแนวคิดหลักคือการสร้างคุณลักษณะ (Feature) ที่เกี่ยวข้องกับแบบจำลอง เมื่อมีข้อมูลที่จำกัดการที่จะทำให้การพยากรณ์ปริมาณน้ำฝนมีประสิทธิภาพที่ดีนั้นอาจไม่เพียงพอ จึงพัฒนาและเปรียบเทียบประสิทธิภาพของแบบจำลองที่ถูกสร้างขึ้น โดยมีวัตถุประสงค์คือ 1) การเปรียบเทียบประสิทธิภาพของตัวแบบที่มีการเพิ่มตัวแปรคุณลักษณะที่เกี่ยวข้องว่ามีความถูกต้องแม่นยำดีขึ้นหรือไม่เมื่อเทียบกับแบบจำลองที่ไม่ได้มีการเพิ่มตัวแปรคุณลักษณะในสภาพแวดล้อมที่เทียบเท่ากัน และ 2) การเปรียบเทียบประสิทธิภาพในการพยากรณ์ปริมาณน้ำฝนสะสมของแบบจำลองที่สนใจศึกษา ได้แก่ ARIMA ARIMAX RNN LSTM และ GRU ข้อมูลที่นำมาใช้ในงานวิจัยนี้เป็นข้อมูลสภาพอากาศและปริมาณน้ำฝนสะสมที่รวบรวมมาจากพื้นที่สนามบินสุวรรณภูมิ พบว่าการเพิ่มตัวแปรคุณลักษณะสามารถเพิ่มประสิทธิภาพในการพยากรณ์ได้ โดยแบบจำลอง GRU ให้ประสิทธิภาพในการพยากรณ์ได้ดีที่สุด

ทวี ชัยพิมลผลิน (2561) ได้ศึกษาแบบจำลอง ANN ในการพยากรณ์ระดับน้ำสูงสุด ในพื้นที่ลุ่มน้ำยมตอนล่าง ณ สถานี Y.19 อ.บางระกำ ใช้ข้อมูลจากแบบจำลองสภาพภูมิอากาศ WRF-ECAM5 เปรียบเทียบวิธีการใช้ข้อมูล กริดน้ำฝน ทั้งหมด 3 วิธี และเปรียบเทียบกระบวนการเรียนรู้ระหว่าง Levenberg-Marquardt (ML) กับ Bayesian Regularization (BR) นอกจากนั้นเปรียบเทียบจำนวนโหนดในชั้นซ่อนเร้น 3 ค่า แบ่งเป็นร้อยละ 50 75 และ 100 โดยอ้างอิงจากจำนวนตัวแปรนำเข้าสรุปได้ว่า กระบวนการเรียนรู้แบบ LM จำนวนโหนดร้อยละ 50 มีความแม่นยำและเหมาะสมที่สุดสำหรับการพยากรณ์ระดับน้ำสูงสุด

Mumtaz Ahmad และคณะ (2022) ได้ศึกษาและเปรียบเทียบ แบบจำลองการคาดการณ์อัตราการไหลด้วย Artificial Neural Networks (ANN) กับวิธีการดั้งเดิมของแบบจำลองปริมาณน้ำฝน-น้ำท่า ของแบบจำลอง NAM ที่ถูกนำมาใช้มากขึ้นสำหรับระบบเตือนภัยน้ำท่วม ในงานวิจัยนี้ได้ประเมินเทคนิคการเรียนรู้ของเครื่องแบบต่างๆ ได้แก่ Random forest และ Decision tree สำหรับแม่น้ำเวซูปี เมืองนีซ ประเทศฝรั่งเศส เครื่องข่ายแบบจำลองได้รับการฝึกอบรมและทดสอบโดยใช้ข้อมูลการปล่อยน้ำ ปริมาณน้ำฝน อุณหภูมิ และการระเหยของไอน้ำเป็นเวลาประมาณ 4 ปี (พ.ศ. 2554-2557) มีการดำเนินการตรวจสอบเปรียบเทียบเพื่อประเมินประสิทธิภาพของแบบจำลอง โดย รากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE), ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) และค่าสัมประสิทธิ์สหสัมพันธ์ (R^2) จากผลที่ได้ แบบจำลอง Feed Forward Neural Network (FFNN) มีประสิทธิภาพน้อยกว่าแบบจำลอง NAM ค่าสัมประสิทธิ์สหสัมพันธ์ของพารามิเตอร์ความแม่นยำของ ANN คือ 0.58 และสำหรับโมเดล NAM คือ 0.76 สำหรับชุดข้อมูล การตรวจสอบความถูกต้อง ในแบบจำลองการเรียนรู้ของเครื่องทั้งหมด Decision tree ที่ทำงานได้ดีที่สุดมีค่าสัมประสิทธิ์สหสัมพันธ์เท่ากับ 0.99 การคาดคะเนข้อมูลการตรวจสอบความถูกต้องของ ANN นั้นดีเมื่อเทียบกับการฝึกอบรม ซึ่งตรงกันข้ามกับแบบจำลอง NAM แบบจำลอง ANN สามารถปรับปรุงได้โดยการเพิ่มตัวแปรนำเข้าให้มากขึ้นในชุดข้อมูลการฝึกเป็นระยะเวลานาน

Binxiao Liu และคณะ (2022) ได้ศึกษาการส่งผลให้เกิดวิกฤตการณ์ด้านทรัพยากรน้ำและความเสี่ยงจากน้ำท่วมในลุ่มแม่น้ำล้านช้าง-แม่โขง (LMRB) ในการศึกษาได้พัฒนาระเบียบวิธีทาง hybrid physics-data (HPD) สำหรับการทำนายกระแสน้ำและการทำนายน้ำท่วมภายใต้กรอบการสร้างแบบจำลองโครงข่ายประสาทเทียมที่นำทางด้วยฟิสิกส์ วิธีการของ HPD ใช้ประโยชน์จากข้อมูลการจำลองจากแบบจำลองตามกระบวนการ เช่น VIC-CaMa-Flood พร้อมกับข้อมูลบังคับทางอุทกนิยมนิเทศ ได้แก่ ปริมาณน้ำฝน อุณหภูมิสูงสุด อุณหภูมิต่ำสุด และความเร็วลมเพื่อจำลองชุดกระแสน้ำรายวันและเหตุการณ์น้ำท่วม โดยใช้โครงข่ายประสาทหน่วยความจำระยะสั้นระยะยาว (LSTM) วิธีการ HPD นี้มีประสิทธิภาพสูงกว่าแบบจำลอง VIC-CaMa-Flood ที่ใช้กระบวนการบริสุทธิ์หรือแบบจำลอง LSTM ที่ใช้ข้อมูลเชิงสังเกตล้วนๆ โดยมีขอบเขตขนาดใหญ่ ชี้ให้เห็นถึง


ประโยชน์ของการแนะนำการปรับสภาพทางกายภาพให้เป็นมาตรฐานในการสร้างแบบจำลองที่ขับเคลื่อนด้วยข้อมูล และความจำเป็นของการแก้ไขข้อผิดพลาดที่รับจากการสังเกต สำหรับแบบจำลองตามกระบวนการ ได้พัฒนา Gradient Boosting Tree Method เพื่อวัดการมีส่วนร่วมของข้อมูลจากการจำลองแบบจำลองตามกระบวนการและข้อมูลบังคับทางอุทกนิยมนิเทศในวิธีการ HPD ของเรา ผลลัพธ์แสดงให้เห็นว่าการจำลองแบบจำลองตามกระบวนการมีส่วนช่วยประมาณ 30% ให้กับผลลัพธ์ของ HPD ซึ่งมากกว่าการให้ข้อมูลจากตัวแปรบังคับทางอุทกนิเทศแต่ละตัว (<20%) วิธีการ HPD ของเราสืบทอดกลไกทางกายภาพของแบบจำลองตามกระบวนการ และความสามารถในการคาดการณ์สูงของแบบจำลอง LSTM ซึ่งนำเสนอวิธีการใหม่ในการใช้ความเข้าใจทางกายภาพที่ไม่สมบูรณ์ และข้อมูลไม่เพียงพอ เพื่อปรับปรุงกระแสและการคาดการณ์น้ำท่วม

Yalian Zheng และคณะ (2022) ได้ศึกษาพื้นที่อ่างเก็บน้ำ น้ำตกชิงเจียง ประเทศจีน โดยศึกษาอ่างเก็บน้ำควบคุมการไหลตามธรรมชาติเพื่อใช้ทรัพยากรน้ำอย่างครอบคลุม การขาดเหมืองข้อมูลการดำเนินงานอ่างเก็บน้ำขนาดใหญ่ที่มีอยู่เพื่ออธิบายพฤติกรรมการทำงานของมนุษย์เป็นสิ่งที่ท้าทาย เพื่อแก้ไขปัญหานี้ จึงใช้วิธีการที่ขับเคลื่อนด้วยข้อมูล Long short-term Memory (LSTM) เพื่อจำลองการไหลออกของอ่างเก็บน้ำโดยการป้อนข้อมูลในอดีต แบบจำลอง Physics-Guided LSTM ซึ่งมีข้อสันนิษฐานว่า PG-LSTM ถูกสร้างขึ้นโดยใช้ตัวอย่างน้ำท่วมสังเคราะห์และข้อจำกัดทางกายภาพของความสมดุลของน้ำ ขอบเขต และความเข้าใจที่ชัดเจน PG-LSTM สามารถจำลองการไหลออกในอดีตด้วยการเปลี่ยนแปลงตามฤดูกาล หรือทำนายการไหลออกโดยไม่เกิดความล่าช้าได้เปรียบเทียบกับ LSTM แบบดั้งเดิม Gradient Boosting Regression tree และ Conventional Reservoir Operation PG-LSTM สามารถปรับปรุงประสิทธิภาพของอ่างเก็บน้ำโดยค่าประสิทธิภาพของอ่างเก็บน้ำแบบเรียงซ้อนในระหว่างช่วงทดสอบจาก 0.50, 0.20 และ 0.17 เป็น 0.54 ในสถานการณ์จำลอง และจาก 0.84, 0.26 และ 0.17 ถึง 0.85 ในสถานการณ์จำลองการทำนายด้วยวิธีการตรวจสอบข้ามห้าครั้ง PG-LSTM มีประโยชน์ในการอธิบายพฤติกรรมการทำงานของมนุษย์ในอ่างเก็บน้ำ

Kang Xie และคณะ (2021) ได้ศึกษาโครงข่ายการเรียนรู้เชิงลึกโดยใช้กลไกทางกายภาพสามอย่าง ดังต่อไปนี้: (1) ฝนตกหนักมากเมื่อน้ำในดินอิ่มตัว (2) เหตุการณ์ที่ไม่มีฝนตกเป็นเวลานานเมื่อน้ำในดินหมดไป และ (3) ความสัมพันธ์เชิงเดียวระหว่างปริมาณน้ำฝนและน้ำท่า ด้วยแบบจำลอง Long Short-Term Memory (LSTM) ที่ใช้ระบบฟิสิกส์นำทาง ซึ่งมีชื่อเรียกสั้นๆ ว่า PHY-LSTM จะได้รับการคิดค้นขึ้น เครือข่าย PHY-LSTM ได้รับการฝึกอบรมบนชุดข้อมูล Catchment Attributes and Meteorology for Large-sample Studies (CAMELS) จำนวน 531 กลุ่มน้ำ ซึ่งบ่งชี้ว่าประสิทธิภาพการทำงานดีขึ้นอย่างมากเมื่อเทียบกับ LSTM แบบเดิม โดยเฉพาะอย่างยิ่ง ค่าเฉลี่ยของ Nash-Sutcliffe Efficiency (NSE) ปรับปรุงจาก 0.52 เป็น 0.61 จากการจำลองรายวันในช่วงการ

ทดสอบในแบบจำลองท้องถิ่น แสดงให้เห็นว่าตัวอย่างสังเคราะห์สามารถปรับปรุงการจำลองจุดสูงสุดของน้ำท่วมได้อย่างมีประสิทธิภาพ และลดจำนวนของกระแสน้ำเชิงลบ และความเป็นโมโนโทนิกสูง ยังคงรักษาไว้ได้ แม้ว่าจะมีการรบกวนเล็กน้อยในชุดข้อมูลการฝึกก็ตาม PHY-LSTM ที่เสนอแสดงให้เห็นว่ากลไกทางกายภาพมีประโยชน์อย่างมากในการปรับปรุงประสิทธิภาพของแบบจำลองปริมาณน้ำฝน-น้ำท่าที่ขับเคลื่อนด้วยข้อมูล

Xuan-Hien Le และคณะ (2019) ได้สร้างแบบจำลอง Deep Neural Network (DNN) ในการทำนายน้ำท่วมแบบเรียลไทม์ นำไปใช้ในการพยากรณ์อัตราการไหลล่วงหน้า 1 2 และ 3 วันล่วงหน้า ที่สถานีอุทกวิทยา Son Tay บนแม่น้ำแดง ประเทศเวียดนาม ข้อมูลนำเข้าของแบบจำลองคือชุดข้อมูลการระบายที่สังเกตได้จากสถานีวัด 5 แห่งบนระบบแม่น้ำแดง โดยไม่ต้องใช้ข้อมูลปริมาณน้ำฝน ระดับน้ำ และลักษณะภูมิประเทศ ผลการวิจัยระบุว่าแบบจำลอง DNN มีประสิทธิภาพสูงสำหรับการพยากรณ์น้ำท่วมแม้ว่าจะต้องใช้ข้อมูลเพียงเล็กน้อยก็ตาม เมื่อคาดการณ์ล่วงหน้าหนึ่งและสองวัน Nash-Sutcliffe Efficiency (NSE) สูงถึง 0.993 และ 0.938 ตามลำดับ ผลการศึกษานี้ชี้ให้เห็นว่าแบบจำลอง DNN สามารถใช้สร้างระบบเตือนภัยน้ำท่วมตามเวลาจริงในแม่น้ำแดงและสำหรับลุ่มแม่น้ำอื่น ๆ ในเวียดนาม



ตารางที่ 2 กรอบแนวคิดตัวแปรที่ทำการศึกษา

ตัวแปร	รักษันดา กุสึเซีย และ สุรณทีร์ ภูมิพิสาร (2565)	M Ahmad et al. (2022)	B Liu et al. (2022)	Y Zheng et al (2022)	K Xie et al. (2021)	XH Le, HV Ho, G Lee. (2019)	ทวี ชัยพิมลสิน (2561)	ความถี่
ปริมาณน้ำฝน (Precipitation)	/	/	/		/			4
อุณหภูมิ (Temperature)	/	/	/		/			3
อัตราการระเหย (Evapotranspiration)		/			/			2
อัตราการไหล (Discharge)		/		/		/		3
ระดับน้ำ (Water Level)				/			/	2
ความชื้นสัมพัทธ์ (Relative humidity)	/							1
ความเร็วลม (Wind speed)			/					1
ความกดอากาศ (Atmospheric pressure)	/				/			2
รังสีอาทิตย์ (Solar Radiation)					/			1
สิ่งปกคลุมที่ดิน (land cover)			/					1
รูปแบบการพยากรณ์ น้ำท่วม	ปริมาณน้ำฝน (Box-Jenkins, RNN)	อัตราการไหล (ANN, Reg, DT, RF, NAM)	อัตราการไหล (LSTM, VIC-CaMa- Flood)	อัตราการไหล (LSTM, PG-LSTM, CRO, GBRT)	อัตราการไหล (LSYM, PHY-LSTM)	อัตราการไหล LSTM	ระดับน้ำ ANN	

บทที่ 3

วิธีดำเนินการ

การวิจัยเรื่อง ตัวแบบสำหรับการพยากรณ์น้ำท่วมในภาคตะวันออกเฉียงเหนือตอนล่าง ประเทศไทย ผู้วิจัยได้ดำเนินการ ดังนี้

3.1 ขอบเขตของการศึกษา

3.2 การวิเคราะห์ข้อมูล

3.1. ขอบเขตของการศึกษา

งานวิจัยนี้ใช้ข้อมูลทุติยภูมิ (Secondary Data) ที่รวบรวมจากกรมอุตุนิยมวิทยา ศูนย์อุทกวิทยา ชลประทานภาคตะวันออกเฉียงเหนือตอนบน และศูนย์อุทกวิทยาชลประทานภาคตะวันออกเฉียงเหนือตอนล่าง ประกอบด้วย ข้อมูลปริมาณน้ำฝนรายวัน ข้อมูลอุณหภูมิต่ำสุดรายวัน ข้อมูลอุณหภูมิต่ำสุดรายวัน ข้อมูลอัตราการระเหยรายวัน และข้อมูลอัตราการไหลรายวัน ตั้งแต่วันที่ 1 เมษายน 2551 ถึง 31 มีนาคม 2565

3.2. การวิเคราะห์ข้อมูล

3.2.1. ข้อมูลทางด้านอุตุนิยมวิทยาและอุทกวิทยาของพื้นที่ศึกษา

ข้อมูลปริมาณน้ำฝน ข้อมูลอุณหภูมิต่ำสุด ข้อมูลอัตราการระเหย จากสถานีอุตุนิยมวิทยา ของกรมอุตุนิยมวิทยาประกอบด้วยสถานี 13 สถานี และข้อมูลปริมาณน้ำฝน ข้อมูลอัตราการไหล จากสถานีวัดน้ำท่าในพื้นที่ลุ่มน้ำมูล และลุ่มน้ำชีตอนล่าง จำนวน 31 สถานี ในตารางที่ 3 และ ตารางที่ 4

ตารางที่ 3 สถานีอุตุนิยมวิทยา ที่เก็บรวบรวมข้อมูล

ลำดับที่	รหัสสถานี	ชื่อสถานี	จังหวัด
1	405201	สถานีอุตุนิยมวิทยาร้อยเอ็ด	ร้อยเอ็ด
2	405301	สถานีอุตุนิยมวิทยาเกษตรร้อยเอ็ด	ร้อยเอ็ด
3	407301	สถานีอุตุนิยมวิทยาเกษตรอุบลราชธานี	อุบลราชธานี
4	407501	ศูนย์อุตุนิยมวิทยาอุบลราชธานี	อุบลราชธานี
5	409301	สถานีอุตุนิยมวิทยาเกษตรศรีสะเกษ	ศรีสะเกษ
6	431201	สถานีอุตุนิยมวิทยานครราชสีมา	นครราชสีมา

ตารางที่ 3 สถานีอุตุนิยมวิทยา ที่เก็บรวบรวมข้อมูล (ต่อ)

ลำดับที่	รหัสสถานี	ชื่อสถานี	จังหวัด
7	431301	สถานีอุตุนิยมวิทยาเกษตรปากช่อง	นครราชสีมา
8	431401	สถานีอุตุนิยมวิทยาอุทกโชคชัย	นครราชสีมา
9	432201	สถานีอุตุนิยมวิทยาสุรินทร์	สุรินทร์
10	432301	สถานีอุตุนิยมวิทยาเกษตรสุรินทร์	สุรินทร์
11	432401	สถานีอุตุนิยมวิทยาอุทกท่าตูม	สุรินทร์
12	436201	สถานีอุตุนิยมวิทยาบุรีรัมย์	บุรีรัมย์
13	436401	สถานีอุตุนิยมวิทยาอุทกนางรอง	บุรีรัมย์

ตารางที่ 4 สถานีวัดน้ำท่า ที่เก็บรวบรวมข้อมูล

ลำดับที่	ลำน้ำ	รหัสสถานี	สถานี	อำเภอ	จังหวัด
1	มูล	M.2A	บ้านด่านตะกา	เฉลิมพระเกียรติ	นครราชสีมา
2	มูล	M.4	บ้านพงสวาย	ท่าตูม	สุรินทร์
3	มูล	M.5	บ้านเมืองคง	ราษีไศล	ศรีสะเกษ
4	มูล	M.6A	บ้านสตึก	สตึก	บุรีรัมย์
5	มูล	M.7	สะพานเสรีประชาธิปไตย	วารินชำราบ	อุบลราชธานี
6	ห้วยสำราญ	M.9	ชุมชนสะพานขาว	เมือง	ศรีสะเกษ
7	ห้วยทับทัน	M.42	บ้านห้วยทับทัน	ห้วยทับทัน	ศรีสะเกษ
8	ลำเซบก	M.69	บ้านท่าบ่แบง	ตะการพิซผล	อุบลราชธานี
9	ลำตะคอง	M.89	สะพานอาคารเซิร์ม	ปากช่อง	นครราชสีมา
10	ลำเสียวใหญ่	M.95	บ้านดอนยาง	สุวรรณภูมิ	ร้อยเอ็ด
11	ลำพระเพลิง	M.145	บ้านวังกะโล	ปากช่อง	นครราชสีมา
12	ชี	M.159	บ้านหลุมดิน	จอมพระ	สุรินทร์
13	ลำตะคอง	M.164	ตำบลในเมือง	เมือง	นครราชสีมา
14	ลำโดมใหญ่	M.170	บ้านคำสำราญ	เดชอุดม	อุบลราชธานี

ตารางที่ 4 สถานีวัดน้ำท่า ที่เก็บรวบรวมข้อมูล (ต่อ)

ลำดับที่	ลำน้ำ	รหัสสถานี	สถานี	อำเภอ	จังหวัด
15	ลำพระเพลิง	M.171	บ้านโนนไธ	วังน้ำเขียว	นครราชสีมา
16	มูล	M.173	บ้านโนนสะอาด	โชคชัย	นครราชสีมา
17	ห้วยขะยุง	M.176	บ้านโนนศรีโค	กันทรารมย์	ศรีสะเกษ
18	ลำตะคอง	M.177	บ้านโนนสว่าง	สีคิ้ว	นครราชสีมา
19	ลำเซบาย	M.179A	บ้านปากอ	เขื่องใน	อุบลราชธานี
20	ลำพระเพลิง	M.180	บ้านท่าเยี่ยม	ปักธงชัย	นครราชสีมา
21	มูล	M.182	บ้านสีฐาน	กันทรารมย์	ศรีสะเกษ
22	ห้วยหินลับ	M.183A	บ้านหินเพิง	ปากช่อง	นครราชสีมา
23	มูล	M.184	บ้านซิม	พิมาย	นครราชสีมา
24	ลำปายมาศ	M.185	บ้านหินโคน	ลำปายมาศ	บุรีรัมย์
25	ลำจักราช	M.186	บ้านโนนคอย	จักราช	นครราชสีมา
26	ลำเชียงไกร	M.188	บ้านเพิ่ม	โนนสูง	นครราชสีมา
27	ห้วยสำราญ	M.190	บ้านขาว	อุทุมพรพิสัย	ศรีสะเกษ
28	ลำตะคอง	M.191	บ้านโคกกรวด	เมือง	นครราชสีมา
29	ชี	E.18	บ้านท่าสะแบง	ทุ่งเขาหลวง	ร้อยเอ็ด
30	ชี	E.20A	บ้านหยาดฟ้า	มหาชนะชัย	ยโสธร
31	ยัง	E.92	บ้านท่างาม	เสลภูมิ	ร้อยเอ็ด

3.2.2. การออกแบบแบบจำลอง ANN, LSTM และ PG-LSTM

การสร้างแบบจำลอง ANN, LSTM และ PG-LSTM โดยตัวแปรนำเข้าเป็นข้อมูลรายวัน ได้แก่ ข้อมูลปริมาณน้ำฝน ข้อมูลอุณหภูมิสูงสุด ข้อมูลอุณหภูมิต่ำสุด ข้อมูลอัตราการระเหย และข้อมูลอัตราการไหลย้อนหลัง เพื่อใช้พยากรณ์อัตราการไหล และข้อมูลพยากรณ์จะใช้ความจุของลำน้ำ เป็นเกณฑ์ในการใช้บอกลักษณะการเกิดน้ำท่วม มีขั้นตอนดังนี้

- 1) เลือกสถานีที่จะทำการพยากรณ์อัตราการไหลรายวัน และเลือกเลือกสถานีอุตุนิยมวิทยา
- 2) ทำการจัดแบ่งข้อมูลปริมาณน้ำฝนรายวัน ข้อมูลอุณหภูมิสูงสุดรายวัน ข้อมูลอัตราการระเหยรายวัน และอัตราการไหลรายวันย้อนหลัง ข้อมูลตั้งแต่วันที่ 1 เมษายน พ.ศ. 2551 ถึง

24 กุมภาพันธ์ พ.ศ. 2563 เป็นข้อมูลเรียนรู้ (Training Set) และข้อมูลตั้งแต่วันที่ 25 กุมภาพันธ์ พ.ศ. 2563 ถึง 31 มีนาคม พ.ศ. 2565 เป็นข้อมูลทดสอบ (Test Set)

- 3) กำหนดสถาปัตยกรรมของแบบจำลอง
- 4) นำข้อมูลเรียนรู้มาสร้างแบบจำลอง จำนวนข้อมูลนำเข้า (Input) ประกอบด้วย ข้อมูลปริมาณน้ำฝนรายวัน ข้อมูลอุณหภูมิสูงสุดรายวัน ข้อมูลการระเหยรายวัน และอัตราการไหลย้อนหลัง ที่มีอิทธิพลเทียบกับระยะเวลาย้อนหลัง
- 5) นำข้อมูลทดสอบมาทดสอบแบบจำลองและเปรียบเทียบประสิทธิภาพของแบบจำลอง

3.2.3. การออกแบบ Loss Function ของแบบจำลอง PG-LSTM

ข้อจำกัดทางกายภาพในฟังก์ชันสูญเสียที่กำหนดฟังก์ชันสำหรับฝนที่ตกต่อเนื่อง และเหตุการณ์ที่ไม่มีฝน โดยความสมดุลของน้ำ (Water balance) คือ ความสมดุลระหว่างปัจจัยการไหลเข้าและการไหลออก กับการเปลี่ยนแปลงของความชื้นในดิน มีสมการของความสมดุลน้ำทั่วไป คือ

$$Q_t = P_t + E_t + \Delta S_t$$

โดยที่	P_t	คือ ปริมาณฝน
	Q_t	คือ ปริมาณอัตราการไหล
	E_t	คือ การระเหย
	ΔS_t	คือ การเพิ่มขึ้นของความชื้นในดินระยะแรก
	t	คือ ช่วงเวลาที่พิจารณา

เมื่อ เหตุการณ์ที่ฝนตกหนักติดต่อกันเป็นเวลานาน ความชื้นในดินเพิ่มขึ้นจากปริมาณน้ำในดินเริ่มต้น จนเมื่อฝนหยุดตก ความชื้นในดินเกิดการอิ่มตัวส่งผลให้ปริมาณอัตราการไหลจะเท่ากับปริมาณฝนที่ตก จะได้

$$Q_t = P_t - E_t \approx P_t \quad \text{เมื่อ} \quad P_t \rightarrow P^\infty, S_t = S_m$$

จะได้ ฟังก์ชันสำหรับฝนที่ตกต่อเนื่อง

$$\hat{Q}_t = f[X_t, \tau] = f[X_{t-\tau}, X_{t-\tau+1}, \dots, X_{t-1}, X_t]$$

$$f[P_{t,i}^\infty, \tau] - P_{t,i}^\infty = 0 \quad t > t_F$$

ในช่วงที่มีเหตุการณ์ที่ไม่มีฝนตกส่งผลให้ความชื้นในดินหมดลงและปริมาณอัตราการไหลจะมีค่าเข้าใกล้หรือเท่ากับศูนย์ กับสถานการณ์ฝนไม่ตกเป็นเวลานาน จะได้ฟังก์ชันสำหรับฝนที่ไม่ตก

$$f[P_{t,i}^0, \tau] = 0 \quad \text{เมื่อ} \quad P_t^0 = 0, t \rightarrow \infty$$

ดังนั้น จะได้ฟังก์ชัน Loss กับเงื่อนไขในทางกายภาพ คือ

$$Loss = \lambda_{data} loss_{data} + \lambda_{\infty} loss_{\infty} + \lambda_0 loss_0$$

เมื่อ

$$loss_{data} = \frac{1}{N} \sum_{i=1}^N (\hat{Q}_i - Q_i)^2$$

$$loss_{\infty} = \frac{1}{N_u N_{\infty}} \sum_{t=1}^{N_u} \sum_{i=1}^{N_{\infty}} \{f(P_{t,i}^{\infty}, \tau) - P_{t,i}^{\infty}\}^2$$

$$loss_0 = \frac{1}{N_l} \sum_{l=1}^{N_l} \{f(P_{t,i}^0, \tau)\}^2$$

โดยที่ $loss_{data}$ คือ ค่าความคลาดเคลื่อนกำลังสองเฉลี่ยของค่าจริงกับค่าพยากรณ์

$loss_{\infty}$ คือ ค่าฟังก์ชันการสูญเสียของเหตุการณ์ที่มีฝนตกต่อเนื่อง

$loss_0$ คือ ค่าฟังก์ชันการสูญเสียของเหตุการณ์ที่ไม่มีฝนตกเป็นเวลานาน

λ_{data} คือ ค่าสัมประสิทธิ์น้ำหนักของอัตราการไหล

λ_{∞} คือ ค่าสัมประสิทธิ์น้ำหนักของเหตุการณ์ที่มีฝนตกต่อเนื่อง

λ_0 คือ ค่าสัมประสิทธิ์น้ำหนักของเหตุการณ์ที่ไม่มีฝนตกเป็นเวลานาน

$P_{t,i}^{\infty}$ คือ ค่าปริมาณน้ำฝนของเหตุการณ์ที่มีฝนตกต่อเนื่อง ณ เวลาที่ t

ตามลำดับนำเข้าไปที่ i

$P_{t,i}^0$ คือ ค่าปริมาณน้ำฝนของสถานการณ์ฝนไม่ตกเป็นเวลานาน ณ เวลาที่ t

ตามลำดับนำเข้าไปที่ i

f คือ ฟังก์ชันเอาต์พุตของแบบจำลอง

τ คือ ลำดับของข้อมูลนำเข้า

N_{∞} คือ จำนวนวันที่มีฝนตกต่อเนื่องในช่วงเวลาตามลำดับที่นำเข้า

N_u คือ จำนวนวันที่มีฝนตกต่อเนื่องทั้งหมด

N_l คือ จำนวนวันที่ไม่มีฝนตกเป็นเวลานานทั้งหมด

บทที่ 4

ผลการวิจัย

ในการศึกษาการสร้างตัวแบบเพื่อพยากรณ์น้ำท่วมในภาคตะวันออกเฉียงเหนือตอนล่างของประเทศไทย โดยการพยากรณ์อัตราการไหล ด้วยแบบจำลอง Artificial Neural Networks, Long Short-Term memory และ Physics-Guided Long Short-Term memory โดยใช้ข้อมูลจากสถานีสถานีอุตุนิยมวิทยา กรมอุตุนิยมวิทยา และสถานีวัดน้ำท่า ศูนย์อุทกวิทยาชลประทานภาคตะวันออกเฉียงเหนือตอนบน และศูนย์อุทกวิทยาชลประทานภาคตะวันออกเฉียงเหนือตอนล่าง ในระหว่างวันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 พื้นที่ที่ทำการศึกษา คือพื้นที่ภาคตะวันออกเฉียงเหนือตอนล่าง มีรายละเอียดดังนี้


- 4.1 การเตรียมข้อมูล และการเลือกตัวแปร
- 4.2 การสร้างแบบจำลองการพยากรณ์อัตราการไหล
- 4.3 การคาดการณ์การน้ำท่วม

4.1 การเตรียมข้อมูล และการเลือกตัวแปร

ผู้วิจัยได้ศึกษาและเลือกข้อมูลจากสถานีวัดน้ำท่า ศูนย์อุทกวิทยาชลประทานภาคตะวันออกเฉียงเหนือตอนบน และศูนย์อุทกวิทยาชลประทานภาคตะวันออกเฉียงเหนือตอนล่าง ในการสร้างตัวแบบเพื่อพยากรณ์น้ำท่วม จากข้อมูลปริมาณน้ำฝน ข้อมูลอุทกภูมิ ข้อมูลอัตราการระเหย ของสถานีอุตุนิยมวิทยา ของกรมอุตุนิยมวิทยา และทำการเลือกข้อมูลที่จะใช้ในพื้นที่ที่ศึกษา โดยเลือกสถานีวัดน้ำท่าที่ใช้ในการพยากรณ์อัตราการไหล ซึ่งเลือกจากจุดเผ่าระวังน้ำท่วมฉับพลัน น้ำป่าไหลหลาก น้ำล้นตลิ่ง ที่เกิดจากฝนตกหนัก และมีรายละเอียดการข้อมูลในการสร้างแบบจำลองที่ใช้พยากรณ์อัตราการไหล ดังนี้

M.2A	บ้านด่านตะกา	อำเภอเฉลิมพระเกียรติ	จังหวัดนครราชสีมา
M.173	บ้านโนนสะอาด	อำเภอโชคชัย	จังหวัดนครราชสีมา
M.184	บ้านซิม	อำเภอพิมาย	จังหวัดนครราชสีมา
M.6A	บ้านสตึก	อำเภอสตึก	จังหวัดบุรีรัมย์
M.4	บ้านพงสวาย	อำเภอท่าตูม	จังหวัดสุรินทร์
M.5	บ้านเมืองคง	อำเภอราศีไสล	จังหวัดศรีสะเกษ
M.9	ชุมชนสะพานขาว	อำเภอเมือง	จังหวัดศรีสะเกษ
M.176	บ้านโนนศรีโค	อำเภอกันทรารมย์	จังหวัดศรีสะเกษ
M.7	สะพานเสรีประชาธิปไตย	อำเภวารินชำราบ	จังหวัดอุบลราชธานี

E.92	บ้านท่างาม	อำเภอเสลภูมิ	จังหวัดร้อยเอ็ด
E.18	บ้านท่าสะแบง	อำเภอทุ่งเขาหลวง	จังหวัดร้อยเอ็ด
E.20 A	บ้านหยาตฟ้า	อำเภอมหาชนะชัย	จังหวัดยโสธร



ภาพที่ 9 ที่ตั้งสถานีวัดน้ำท่าและสถานีตรวจอากาศ ที่ทำการศึกษาในพื้นที่ที่ศึกษา

จากรูปที่ 9 เป็นสถานีวัดน้ำท่าและสถานีอุตุนิยมวิทยาที่ใช้ในการสร้างแบบจำลองในการพยากรณ์อัตราการไหลในพื้นที่ภาคตะวันออกเฉียงเหนือตอนล่าง สร้างรูปสามเหลี่ยมธีเอสเซน (Thiessen Polygon) เพื่อพิจารณาพร้อมกับการเลือกสถานีอุตุนิยมวิทยาที่ใกล้กับสถานีวัดน้ำท่า ใช้เป็นตัวแปรในการสร้างแบบจำลอง รายละเอียดของสถานีแต่ละแห่ง และข้อมูลพื้นฐานด้านอุตุนิยมวิทยาและอุทกวิทยาของพื้นที่ศึกษา มีดังนี้


ตารางที่ 5 รายละเอียดของสถานีอุตุนิยมวิทยาที่ใช้ในการสร้างแบบจำลอง

สถานีวัดน้ำท่า	สถานีอุตุนิยมวิทยา	สถานีวัดน้ำท่า	สถานีอุตุนิยมวิทยา
M.2A	431201	M.173	431401
M.4	432401	M.176	407501
M.5	409301	M.184	431201
M.6A	432401	E.18	405201
M.7	407301	E.20A	405201
M.9	409301	E.92	405201


ตารางที่ 6 ข้อมูลพื้นฐานของอัตราการไหล สถานีวัดน้ำท่า ของกรมอุทกวิทยา (ลูกบาศก์เมตรต่อวินาที : ลบ.ม/วินาที)

สถานีวัดน้ำท่า	ค่าต่ำสุด	ค่าควอไทล์ที่ 1	ค่ามัธยฐาน	ค่าเฉลี่ย	ค่าควอไทล์ที่ 3	ค่าสูงสุด
M.2A	0.00	0.36	4.30	18.04	16.00	357.20
M.4	0.00	1.68	14.50	137.76	118.30	1817.50
M.5	0.00	3.13	15.50	196.50	139.00	3066.00
M.6A	0.00	0.08	4.00	106.63	75.00	1793.90
M.7	0.00	25.31	93.50	541.50	618.20	5134.00
M.9	0.00	0.00	1.08	50.13	15.20	1930.00
M.173	0.00	1.55	4.20	16.42	12.30	787.80
M.176	0.00	1.80	7.30	38.23	37.20	669.60
M.184	0.00	0.00	5.62	25.19	27.10	417.00
E.18	0.00	19.00	92.00	218.50	264.70	1446.60
E.20A	0.10	18.00	97.40	281.90	347.00	2662.50
E.92	0.00	0.64	5.00	32.82	21.00	688.00


ตารางที่ 6 แสดงข้อมูลพื้นฐานของอัตราการไหล จากสถานีวัดน้ำท่า ของกรมอุทกวิทยา 12 สถานี โดยแสดงค่า ค่าต่ำสุด ค่าควอไทล์ที่ 1 ค่ามัธยฐาน ค่าเฉลี่ย ค่าควอไทล์ที่ 3 และค่าสูงสุด ทั้ง 12 สถานี โดยทั้ง 12 สถานี มีค่าต่ำสุดอยู่ระหว่าง 0 - 0.1 ลบ.ม/วินาที ค่าควอไทล์ที่ 1 อยู่ระหว่าง 0 - 25.31 ลบ.ม/วินาที ค่ามัธยฐานอยู่ระหว่าง 1.08 - 97.4 ลบ.ม/วินาที ค่าเฉลี่ยอยู่ระหว่าง 16.42 - 541.5 ลบ.ม/วินาที ค่าควอไทล์ที่ 3 อยู่ระหว่าง 3 - 12.3 ลบ.ม/วินาที และค่าสูงสุดอยู่ระหว่าง 357.2 - 5134 ลบ.ม/วินาที มีลักษณะข้อมูลที่เกิดขึ้นของแต่ละสถานีและฮิสโตแกรม ดังนี้




ภาพที่ 10 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรมของสถานี M.2A




ภาพที่ 11 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรมของสถานี M.4




ภาพที่ 12 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรมของสถานี M.5




ภาพที่ 13 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรมของสถานี M.6A




ภาพที่ 14 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรมของสถานี M.7




ภาพที่ 15 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรมของสถานี M.9




ภาพที่ 16 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรมของสถานี M.173




ภาพที่ 17 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรมของสถานี M.176




ภาพที่ 18 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรมของสถานี M.184



ภาพที่ 19 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรมของสถานี E.18



ภาพที่ 20 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรม
ของสถานี E.20A



ภาพที่ 21 อัตราการไหล วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรม
ของสถานี E.92

จากภาพที่ 10 – 21 แสดงข้อมูลอัตราการไหลรายวัน ตั้งแต่วันที่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ. 2565 และฮิสโตแกรมของสถานีวัดน้ำท่าของทั้ง 12 สถานี จากฮิสโตแกรมแต่ละสถานีมีลักษณะการกระจายเบ้ขวา ซึ่งหมายความว่าอัตราการไหลส่วนใหญ่จะมีค่าน้อย สอดคล้องกับกราฟที่แสดงข้อมูลอัตราการไหลที่ส่วนใหญ่จะมีค่าน้อยและมีการเปลี่ยนแปลงของข้อมูลที่เพิ่มขึ้นซ้ำ ๆ ในแต่ละช่วงปี

ข้อมูลจากสถานีอุตุนิยมวิทยา ที่ใช้สร้างแบบจำลองมีรายละเอียดและข้อมูลพื้นฐาน วาดดังนี้


รหัสสถานี 405201	สถานีอุตุนิยมวิทยาร้อยเอ็ด	จังหวัดร้อยเอ็ด
รหัสสถานี 407301	สถานีอุตุนิยมวิทยาเกษตรอุบลราชธานี	จังหวัดอุบลราชธานี
รหัสสถานี 407501	ศูนย์อุตุนิยมวิทยาอุบลราชธานี	จังหวัดอุบลราชธานี
รหัสสถานี 409301	สถานีอุตุนิยมวิทยาเกษตรศรีสะเกษ	จังหวัดศรีสะเกษ
รหัสสถานี 431201	สถานีอุตุนิยมวิทยานครราชสีมา	จังหวัดนครราชสีมา
รหัสสถานี 431401	สถานีอุตุนิยมวิทยาอุทกโชคชัย	จังหวัดนครราชสีมา
รหัสสถานี 432401	สถานีอุตุนิยมวิทยาอุทกท่าตูม	จังหวัดสุรินทร์

ตารางที่ 7 ข้อมูลพื้นฐานของสถานีอุตุนิยมวิทยา ของกรมอุตุนิยมวิทยา

รหัสประจำ สถานี	ตัวแปร	ค่าต่ำสุด	ค่าควอ ไทล์ที่ 1	ค่ามัธย ฐาน	ค่าเฉลี่ย	ค่าควอ ไทล์ที่ 3	ค่าสูงสุด
405201	ปริมาณฝน (มม.)	0.00	0.00	0.00	3.76	0.60	172.20
	อุณหภูมิต่ำสุด (°C)	10.10	21.30	24.30	23.24	25.70	30.20
	อุณหภูมิสูงสุด (°C)	17.50	31.20	33.00	32.97	34.80	42.30
	อัตราการระเหย (มม.)	0.00	3.70	4.60	4.62	5.50	62.30
407301	ปริมาณฝน (มม.)	0.00	0.00	0.00	4.44	1.20	200.80
	อุณหภูมิต่ำสุด (°C)	9.50	20.80	23.40	22.41	24.50	29.10
	อุณหภูมิสูงสุด (°C)	17.80	32.00	33.53	33.53	35.20	42.40
	อัตราการระเหย (มม.)	0.10	3.50	4.39	4.39	5.20	9.80
407501	ปริมาณฝน (มม.)	0.00	0.00	0.00	4.72	1.30	190.00
	อุณหภูมิต่ำสุด (°C)	10.50	21.30	23.80	22.99	25.20	30.10
	อุณหภูมิสูงสุด (°C)	17.50	32.10	33.60	33.60	35.20	42.60
	อัตราการระเหย (มม.)	0.10	3.40	4.30	4.37	5.20	64.80
409301	ปริมาณฝน (มม.)	0.00	0.00	0.00	3.87	0.70	170.70
	อุณหภูมิต่ำสุด (°C)	2.00	21.50	24.20	23.11	25.30	29.20
	อุณหภูมิสูงสุด (°C)	18.50	31.50	33.10	33.13	35.00	42.30
	อัตราการระเหย (มม.)	0.00	3.70	4.34	4.34	4.90	30.80
431201	ปริมาณฝน (มม.)	0.00	0.00	0.00	3.30	0.40	152.80
	อุณหภูมิต่ำสุด (°C)	4.40	22.50	24.40	23.61	25.40	28.70
	อุณหภูมิสูงสุด (°C)	0.30	3.90	4.84	4.84	5.70	55.30
	อัตราการระเหย (มม.)	0.30	3.90	4.84	4.84	5.70	55.30
431401	ปริมาณฝน (มม.)	0.00	0.00	0.00	3.04	0.50	122.80
	อุณหภูมิต่ำสุด (°C)	10.00	21.80	24.00	23.04	25.00	28.70
	อุณหภูมิสูงสุด (°C)	17.90	31.80	33.60	33.46	35.30	42.50
	อัตราการระเหย (มม.)	0.10	3.40	4.30	4.35	5.20	49.70
432401	ปริมาณฝน (มม.)	0.00	0.00	0.00	3.44	0.40	177.70
	อุณหภูมิต่ำสุด (°C)	19.60	31.50	33.09	33.09	34.80	42.00
	อุณหภูมิสูงสุด (°C)	10.50	21.70	24.10	23.05	25.10	29.40
	อัตราการระเหย (มม.)	0.20	4.30	5.00	4.98	5.60	11.00

จากตารางที่ 7 แสดงค่าข้อมูลพื้นฐานของสถานีสถานีอุตุนิยมวิทยาที่ใช้ในการวิเคราะห์ แสดงค่าปริมาณน้ำฝน (มิลลิเมตร) อุณหภูมิต่ำสุดกับค่าอุณหภูมิสูงสุดค่า (องศาเซลเซียส) อัตราการระเหย (มิลลิเมตร) โดยแสดงค่าต่ำสุด ค่าควอไทล์ที่ 1 ค่ามัธยฐาน ค่าเฉลี่ย ค่าควอไทล์ที่ 3 ค่าสูงสุด ทั้ง 7 สถานี และมีลักษณะของข้อมูล เป็นดังนี้


ปริมาณน้ำฝนมีค่าต่ำสุด ค่าควอไทล์ที่ 1 และค่ามัธยฐานอยู่ระหว่าง 0.00 – 0.00 มม. ค่าเฉลี่ยอยู่ระหว่าง 3.04 - 4.72 มม.ค่าควอไทล์ที่ 3 อยู่ระหว่าง 0.40 - 1.30 มม. และค่าสูงสุดอยู่ระหว่าง 122.80 - 200.80 มม.



ภาพที่ 22 ฮิสโตแกรมของปริมาณน้ำฝน 7 สถานี

จากภาพที่ 22 จะได้ว่าข้อมูลปริมาณน้ำฝนมีลักษณะการกระจายของข้อมูลที่มีลักษณะเบ้ขวา ค่าปริมาณน้ำฝนส่วนใหญ่ที่เกิดขึ้นจะมีค่าน้อย ช่วงของข้อมูลส่วนใหญ่อยู่ระหว่าง 0 -150 มม ยกเว้น สถานี 407301 สถานีอุตุนิยมวิทยาเกษตรอุบลราชธานี และสถานี 431401 สถานีอุตุนิยมวิทยา ไซค์ชัย ที่มีช่วงของข้อมูลส่วนใหญ่อยู่ระหว่าง 0 -200 มม. และ 0-120 มม. ตามลำดับ

อุณหภูมิต่ำสุด มีค่าต่ำสุดอยู่ระหว่าง 2.00 – 19.60 °C ค่าควอไทล์ที่ 1 อยู่ระหว่าง 20.80 – 31.50 °C ค่ามัธยฐานอยู่ระหว่าง 23.40 – 33.09 °C ค่าเฉลี่ยอยู่ระหว่าง 22.41 – 33.09 °C ค่าควอไทล์ที่ 3 อยู่ระหว่าง 24.50 – 34.80 °C และค่าสูงสุดอยู่ระหว่าง 28.70 – 42.00 °C




ภาพที่ 23 ฮิสโตแกรมของอุณหภูมิต่ำสุด 7 สถานี

จากภาพที่ 23 จะได้ว่าข้อมูลอุณหภูมิต่ำสุดมีลักษณะการกระจายของข้อมูลที่มีลักษณะเบ้ซ้าย ค่าอุณหภูมิต่ำสุดที่มีความหนาแน่นมากจะอยู่ระหว่าง 20 – 30 °C และมีช่วงของข้อมูลส่วนใหญ่อยู่ระหว่าง 10 -30 °C ยกเว้น สถานี 409301 สถานีอุดุนิยมวิทยาเกษตรศรีสะเกษ ที่มีช่วงของข้อมูลส่วนใหญ่อยู่ระหว่าง 5 -30 °C

อุณหภูมิสูงสุด มีค่าต่ำสุดอยู่ระหว่าง 0.30 - 18.50 °C ค่าควอไทล์ที่ 1 อยู่ระหว่าง 3.90 - 32.10 °C ค่ามัธยฐานอยู่ระหว่าง 4.84 - 33.60 °C ค่าเฉลี่ยอยู่ระหว่าง 4.84 - 33.60 °C ค่าควอไทล์ที่ 3 อยู่ระหว่าง 5.70 - 35.30 °C ค่าสูงสุดอยู่ระหว่าง 29.40 - 55.30 °C






ภาพที่ 24 ฮิสโตแกรมของอุณหภูมิสูงสุด 7 สถานี

จากภาพที่ 24 จะได้ว่าข้อมูลอุณหภูมิสูงสุดมีลักษณะการกระจายของข้อมูลที่มีลักษณะเบ้ซ้าย ค่าอุณหภูมิสูงสุดมีความหนาแน่นมากที่สุดอยู่ระหว่าง 30 – 37 °C และมีช่วงของข้อมูลส่วนใหญ่อยู่ระหว่าง 20 -45 °C ยกเว้น สถานี 407301 สถานีอุดุนิยมวิทยาเกษตรอุบลราชธานี และ สถานี 431401 สถานีอุดุนิยมวิทยาโขชัย ที่มีช่วงของข้อมูลส่วนใหญ่อยู่ระหว่าง 15 - 45 °C

อัตราการระเหยมีค่าต่ำสุดอยู่ระหว่าง 0.00 - 0.30 มม. ค่าควอไทล์ที่ 1 อยู่ระหว่าง 3.40 - 4.30 มม. ค่ามัธยฐานอยู่ระหว่าง 4.30 - 5.00 มม. ค่าเฉลี่ยอยู่ระหว่าง 4.34 - 4.98 มม.ค่าควอไทล์ที่ 3 อยู่ระหว่าง 4.90 - 5.70 มม. ค่าสูงสุดอยู่ระหว่าง 9.80 - 64.80 มม.

พูน ปณ ทิโต ชเว



ภาพที่ 25 ฮิสโตแกรมของอัตราการระเหย 7 สถานี

จากภาพที่ 25 ข้อมูลอัตราการระเหยมีลักษณะการกระจายของข้อมูลที่มีลักษณะเบ้ขวา สถานี 409301 มีช่วงของข้อมูลที่กว้างมากจากภาพจะเห็นได้ว่ามีลักษณะที่เบ้ขวามากที่สุด และมีสถานี 405201 สถานี 407301 และ สถานี 432401 ขวาเพียงเล็กน้อยเกือบจะมีลักษณะที่สมมาตร

จากตรวจสอบข้อมูลพื้นฐานหากพบว่ามีข้อมูลสูญหายทำการแทนค่าข้อมูลสูญหายด้วยวิธีการประมาณค่าด้วยค่าเฉลี่ย (Mean Imputation: MI) ซึ่งลักษณะข้อมูลที่สูญหายเกิดจากการเก็บรวบรวมข้อมูลที่ไม่สมบูรณ์ ที่ไม่ใช่กรณีที่ค่าข้อมูลเป็น 0 มีลักษณะเกิดแบบสุ่มโดยที่ข้อมูลที่ขาดหายไปไม่ได้ขึ้นกับตัวแปรใดตัวแปรหนึ่ง



4.2 การสร้างแบบจำลองการพยากรณ์อัตราการไหล

สำหรับการสร้างแบบจำลองได้ใช้ 3 วิธีการได้แก่ ANN, LSTM และ PG-LSTM จากข้อมูลปริมาณน้ำฝน อุณหภูมิสูงสุด อุณหภูมิต่ำสุด อัตราการระเหย และอัตราการไหลย้อนหลัง 1, 3 และ 7 วัน ทั้งนี้ในการสร้างแบบจำลอง ตามสถานีตรวจวัดที่เลือกในพื้นที่ภาคตะวันออกเฉียงเหนือตอนล่าง โดยแบ่งข้อมูลเป็นข้อมูลเรียนรู้ (Training Set) เป็นข้อมูลตั้งแต่วันที่ 1 เมษายน พ.ศ. 2551 ถึง 24 กุมภาพันธ์ พ.ศ. 2563 และข้อมูลทดสอบ (Test Set) เป็นข้อมูลตั้งแต่วันที่ 25 กุมภาพันธ์ พ.ศ. 2563 ถึง 31 มีนาคม พ.ศ. 2565 และได้กำหนดโครงสร้างของแบบจำลอง ดังแสดงในตารางที่ 8

ตารางที่ 8 โครงสร้างของแบบจำลองวิธี ANN, LSTM และ PG-LSTM มีค่า Hyperparameter สำหรับแบบจำลอง ค่า Weights และ พารามิเตอร์สำหรับเหตุการณ์ฝนที่ตกต่อเนื่อง

Moel		ANN	LSTM	PG-LSTM
Hyperparameter	Epoch	100 - 300	100 - 300	100 - 300
	Hidden size	10 - 300	10 - 300	10 - 300
	Hidden layer	1 - 2	1 - 2	1 - 2
	Dropout out	0.2	0.2	0.2
	Batch size	512	512	512
	Normalization	Min - Max	Min - Max	Min - Max
Weights	λ_{data}	0.01	0.01	0.01
	λ_{∞}	-	-	0.01
	λ_0	-	-	0.01
พารามิเตอร์สำหรับเหตุการณ์ฝนที่ตกต่อเนื่อง	ปริมาณฝนตกต่อเนื่อง (มม.)	-	-	มากกว่า 35 มม.
	จำนวนวันที่ฝนตกต่อเนื่อง (วัน)	-	-	มากกว่า 4 วัน

จากตารางที่ 8 แสดงพารามิเตอร์ที่กำหนดในการสร้างแบบจำลอง และในการเลือกปริมาณน้ำฝนเมื่อปริมาณฝนที่ตกมากกว่า 35 มิลลิเมตรซึ่งใช้เกณฑ์การตรวจวัดฝนของกรมอุตุนิยมวิทยา และจำนวนวันที่ฝนตกต่อเนื่องจะกำหนดให้มากกว่า 4 วัน กรณีที่แบบจำลองมีประสิทธิภาพในการพยากรณ์อยู่ในเกณฑ์ที่ต่ำจะปรับพารามิเตอร์ Batch size ลง และได้ประสิทธิภาพของแบบจำลองดังนี้

ตารางที่ 9 ประสิทธิภาพของแบบจำลองของแต่ละสถานี ด้วยค่า RMSE, NSE และ PBIAS โดยใช้
อัตราการไหลย้อนหลัง 1 วัน

สถานี	แบบจำลอง	Hidden Layers	Hidden sizes	Epochs	Train			Test		
					RMSE	NSE	PBIAS	RMSE	NSE	PBIAS
M.2A	ANN	2	100	300	6.77	0.9627	-2.16	6.60	0.9803	-4.58
	LSTM	2	100	300	8.09	0.9467	1.45	7.89	0.9718	0.58
	PG-LSTM	2	100	300	10.93	0.9026	-3.17	11.37	0.9415	0.07
M.4	ANN	2	250	300	20.67	0.9940	-0.85	18.40	0.9955	-5.75
	LSTM	2	100	290	39.08	0.9787	1.60	31.80	0.9864	-7.85
	PG-LSTM	2	50	250	67.78	0.9359	-3.97	72.56	0.9294	-11.93
M.5	ANN	2	100	290	65.27	0.9751	1.52	58.50	0.9742	-6.92
	LSTM	2	100	280	66.29	0.9743	1.11	60.27	0.9727	-7.30
	PG-LSTM	2	100	300	69.43	0.9718	0.35	66.42	0.9668	-7.46
M.6A	ANN	2	200	300	24.49	0.9885	-2.66	22.65	0.9924	-6.86
	LSTM	2	100	290	40.13	0.9692	0.39	33.28	0.9836	-6.55
	PG-LSTM	1	100	240	65.22	0.9186	-14.42	67.50	0.9324	-18.36
M.7	ANN	2	250	300	68.56	0.9945	-1.82	63.49	0.9933	-4.80
	LSTM	2	100	290	121.16	0.9828	1.98	96.97	0.9844	-3.82
	PG-LSTM	2	100	300	122.19	0.9826	0.52	100.07	0.9834	-5.51
M.9	ANN	2	250	280	27.67	0.9817	-4.85	18.66	0.8233	-33.26
	LSTM	2	200	300	24.07	0.9861	4.77	14.01	0.9004	-0.58
	PG-LSTM	2	100	260	35.09	0.9706	6.01	23.20	0.7268	-4.63
M.173	ANN	2	250	300	10.77	0.9328	-5.82	12.27	0.9275	-0.52
	LSTM	1	300	250	20.26	0.7624	-38.12	27.70	0.6305	0.92
	PG-LSTM	1	150	300	23.18	0.6890	-36.36	30.97	0.5381	3.89
M.176	ANN	2	250	300	12.82	0.9694	-0.19	11.51	0.9713	-10.26
	LSTM	2	100	280	17.81	0.9410	2.17	15.43	0.9484	-14.67
	PG-LSTM	2	100	140	27.02	0.8642	1.87	27.56	0.8353	-13.60
M.184	ANN	2	250	290	6.23	0.9820	0.54	5.17	0.9905	-0.16
	LSTM	2	100	250	11.04	0.9435	-0.23	10.38	0.9617	-0.07
	PG-LSTM	2	50	300	14.07	0.9082	-1.93	13.55	0.9348	-0.13
E.18	ANN	2	50	300	44.42	0.9794	-0.27	39.54	0.9793	-5.68
	LSTM	2	100	160	48.63	0.9753	3.55	42.96	0.9756	-2.42
	PG-LSTM	2	150	290	38.89	0.9842	0.63	34.09	0.9846	-3.92
E.20A	ANN	2	200	250	51.60	0.9848	0.70	44.92	0.9788	-0.05
	LSTM	2	150	300	53.24	0.9839	-0.21	51.84	0.9717	-0.06
	PG-LSTM	2	150	260	56.36	0.9819	0.30	52.57	0.9709	0.00
E.92	ANN	2	250	300	18.18	0.9487	-2.37	14.33	0.8964	3.94
	LSTM	2	250	300	22.39	0.9222	-11.14	18.69	0.8237	-0.86
	PG-LSTM	2	100	300	24.65	0.9057	-11.15	21.55	0.7658	-0.51

ตารางที่ 10 ประสิทธิภาพของแบบจำลองของแต่ละสถานี ด้วยค่า RMSE, NSE และ PBIAS โดยใช้
อัตราการไหลย้อนหลัง 3 วัน

สถานี	แบบจำลอง	Hidden Layers	Hidden sizes	Epochs	Train			Test		
					RMSE	NSE	PBIAS	RMSE	NSE	PBIAS
M.2A	ANN	2	150	290	4.89	0.9805	0.39	4.63	0.9903	-0.41
	LSTM	2	100	300	8.99	0.9342	1.34	8.94	0.9638	-2.04
	PG-LSTM	2	50	300	11.84	0.8859	5.33	11.81	0.9369	0.57
M.4	ANN	2	150	290	25.86	0.9907	0.14	23.06	0.9929	-4.22
	LSTM	2	100	280	37.33	0.9806	0.41	29.99	0.9879	-7.29
	PG-LSTM	2	50	250	45.19	0.9715	-0.02	34.24	0.9843	-9.73
M.5	ANN	2	100	300	68.14	0.9728	-0.95	57.63	0.9750	-9.29
	LSTM	2	100	280	71.22	0.9703	-0.24	59.92	0.9730	-8.59
	PG-LSTM	2	50	260	109.63	0.9296	-1.60	109.59	0.9096	-9.03
M.6A	ANN	2	200	300	21.32	0.9913	-1.53	19.66	0.9943	-4.73
	LSTM	2	100	260	42.76	0.9650	-1.60	32.42	0.9844	-7.06
	PG-LSTM	2	100	280	44.84	0.9615	-3.12	33.87	0.9830	-9.11
M.7	ANN	2	300	300	64.66	0.9951	0.62	59.76	0.9941	-0.76
	LSTM	2	100	300	106.29	0.9868	1.83	88.87	0.9869	-1.48
	PG-LSTM	2	100	230	119.62	0.9833	-0.36	99.18	0.9837	-5.25
M.9	ANN	2	300	270	22.57	0.9878	0.49	15.23	0.8822	-19.20
	LSTM	2	150	300	26.61	0.9831	5.19	11.29	0.9353	0.84
	PG-LSTM	2	100	260	30.45	0.9778	7.28	14.53	0.8928	3.87
M.173	ANN	2	150	290	9.40	0.9488	-0.99	12.17	0.9286	-0.38
	LSTM	2	150	300	18.32	0.8056	-6.25	21.86	0.7699	12.45
	PG-LSTM	2	150	270	17.48	0.8231	-10.80	21.34	0.7807	9.91
M.176	ANN	2	200	300	11.17	0.9768	0.75	8.46	0.9845	-8.80
	LSTM	2	100	300	20.39	0.9227	1.47	16.83	0.9386	-12.22
	PG-LSTM	2	100	280	21.38	0.9150	-0.15	18.57	0.9252	-13.64
M.184	ANN	2	200	300	4.82	0.9893	-1.26	4.65	0.9923	-0.86
	LSTM	2	100	300	10.31	0.9507	0.96	9.52	0.9678	-3.95
	PG-LSTM	2	50	230	13.83	0.9113	0.94	12.87	0.9412	-5.14
E.18	ANN	2	250	300	21.00	0.9954	0.39	19.56	0.9949	0.19
	LSTM	2	100	300	37.39	0.9854	0.62	32.98	0.9856	-1.68
	PG-LSTM	2	150	220	40.10	0.9832	0.48	35.40	0.9834	-2.84
E.20A	ANN	2	200	280	40.85	0.9905	-0.11	34.42	0.9875	0.03
	LSTM	2	150	260	64.18	0.9766	0.28	52.81	0.9707	0.01
	PG-LSTM	2	50	280	72.21	0.9703	1.41	57.12	0.9657	0.08
E.92	ANN	2	250	300	18.21	0.9486	-5.80	14.33	0.8964	-0.32
	LSTM	2	300	300	23.05	0.9176	-9.42	20.49	0.7881	0.56
	PG-LSTM	2	50	270	34.49	0.8154	-6.98	27.96	0.6056	1.93

ตารางที่ 11 ประสิทธิภาพของแบบจำลองของแต่ละสถานี ด้วยค่า RMSE, NSE และ PBIAS โดยใช้
อัตราการไหลย้อนหลัง 7 วัน

สถานี	แบบจำลอง	Hidden Layers	Hidden sizes	Epochs	Train			Test		
					RMSE	NSE	PBIAS	RMSE	NSE	PBIAS
M.2A	ANN	2	100	300	5.43	0.9760	-0.36	5.58	0.9859	-0.87
	LSTM	2	100	290	8.92	0.9353	1.65	8.77	0.9652	-1.03
	PG-LSTM	2	100	280	8.43	0.9421	1.78	8.27	0.9690	-1.05
M.4	ANN	2	150	300	23.54	0.9923	1.96	19.73	0.9948	-2.20
	LSTM	2	100	300	38.72	0.9791	0.29	34.39	0.9842	-5.25
	PG-LSTM	2	100	290	42.10	0.9753	-0.63	36.06	0.9826	-7.31
M.5	ANN	2	150	300	45.26	0.9880	1.34	41.45	0.9871	-3.43
	LSTM	2	100	290	76.91	0.9654	-0.94	67.56	0.9657	-8.93
	PG-LSTM	2	100	300	74.73	0.9673	0.07	64.26	0.9689	-8.04
M.6A	ANN	2	150	300	22.61	0.9902	0.92	17.96	0.9952	-2.33
	LSTM	2	100	300	41.40	0.9672	-0.46	33.23	0.9836	-4.74
	PG-LSTM	2	50	300	52.48	0.9473	-2.59	40.95	0.9752	-8.43
M.7	ANN	1	250	270	69.57	0.9943	1.83	65.90	0.9928	0.29
	LSTM	2	100	290	121.80	0.9827	1.21	106.15	0.9814	-1.47
	PG-LSTM	2	100	300	130.53	0.9801	0.57	112.14	0.9792	-2.90
M.9	ANN	2	250	300	22.43	0.9880	-0.88	13.84	0.9029	-22.04
	LSTM	2	100	270	25.30	0.9847	5.81	13.09	0.9132	-0.50
	PG-LSTM	2	50	290	27.54	0.9819	4.79	16.04	0.8696	1.35
M.173	ANN	2	200	280	9.10	0.9521	1.43	10.64	0.9455	-0.02
	LSTM	2	250	300	15.40	0.8628	-5.19	18.49	0.8355	5.50
	PG-LSTM	1	100	280	19.61	0.7776	-20.44	21.55	0.7767	-0.04
M.176	ANN	2	200	220	12.77	0.9697	3.56	9.27	0.9814	-7.08
	LSTM	2	100	300	18.04	0.9395	0.24	14.45	0.9548	-14.10
	PG-LSTM	2	50	240	30.22	0.8303	2.74	27.67	0.8342	-13.29
M.184	ANN	2	200	280	5.51	0.9859	1.61	5.78	0.9881	0.19
	LSTM	2	100	300	9.78	0.9557	-1.73	9.64	0.9670	-5.81
	PG-LSTM	2	100	280	15.44	0.8896	-0.46	14.09	0.9295	-7.33
E.18	ANN	2	250	240	24.49	0.9937	0.68	23.47	0.9927	0.27
	LSTM	2	100	300	40.57	0.9828	0.42	35.92	0.9830	-1.18
	PG-LSTM	2	150	270	41.89	0.9817	-0.04	38.02	0.9809	-2.72
E.20A	ANN	2	250	300	32.95	0.9938	-0.52	27.73	0.9919	-0.18
	LSTM	2	100	220	66.45	0.9749	0.18	51.48	0.9721	-0.03
	PG-LSTM	2	100	200	66.94	0.9745	0.52	52.90	0.9706	0.15
E.92	ANN	2	200	300	15.78	0.9614	-3.88	13.47	0.9084	0.30
	LSTM	2	100	190	27.51	0.8827	-8.46	23.11	0.7307	0.90
	PG-LSTM	2	50	200	39.58	0.7572	-6.70	30.09	0.5436	1.87

ตารางที่ 12 ประสิทธิภาพและแบบจำลองที่เหมาะสมของการใช้ข้อมูลอัตราการไหลย้อนหลัง


สถานี	อัตราการไหลหลัง	แบบจำลอง	RMSE	NSE	PBIAS
M.2A	1 วัน	ANN	44.92	0.9788	-0.05
	3 วัน	ANN	34.42	0.9875	0.03
	7 วัน	ANN	27.73	0.9919	-0.18
M.4	1 วัน	ANN	14.33	0.8964	3.94
	3 วัน	ANN	14.33	0.8964	-0.32
	7 วัน	ANN	13.47	0.9084	0.30
M.5	1 วัน	ANN	6.60	0.9803	-4.58
	3 วัน	ANN	4.63	0.9903	-0.41
	7 วัน	ANN	5.58	0.9859	-0.87
M.6A	1 วัน	ANN	18.40	0.9955	-5.75
	3 วัน	ANN	23.06	0.9929	-4.22
	7 วัน	ANN	19.73	0.9948	-2.20
M.7	1 วัน	ANN	63.49	0.9933	-4.80
	3 วัน	ANN	59.76	0.9941	-0.76
	7 วัน	ANN	65.90	0.9928	0.29
M.9	1 วัน	LSTM	14.01	0.9004	-0.58
	3 วัน	LSTM	11.29	0.9353	0.84
	7 วัน	LSTM	13.09	0.9132	-0.50
M.173	1 วัน	ANN	12.27	0.9275	-0.52
	3 วัน	ANN	12.17	0.9286	-0.38
	7 วัน	ANN	10.64	0.9455	-0.02
M.176	1 วัน	ANN	11.51	0.9713	-10.26
	3 วัน	ANN	8.46	0.9845	-8.80
	7 วัน	ANN	9.27	0.9814	-7.08
M.184	1 วัน	ANN	5.17	0.9905	-0.16
	3 วัน	ANN	4.65	0.9923	-0.86
	7 วัน	ANN	5.78	0.9881	0.19
E.18	1 วัน	PG-LSTM	34.09	0.9846	-3.92
	3 วัน	ANN	19.56	0.9949	0.19
	7 วัน	ANN	23.47	0.9927	0.27
E.20A	1 วัน	ANN	44.92	0.9788	-0.05
	3 วัน	ANN	34.42	0.9875	0.03
	7 วัน	ANN	27.73	0.9919	-0.18
E.92	1 วัน	ANN	14.33	0.8964	3.94
	3 วัน	ANN	14.33	0.8964	-0.32
	7 วัน	ANN	13.47	0.9084	0.30

จากตารางที่ 9 แสดงประสิทธิภาพแบบจำลองโดยใช้ข้อมูลอัตราการไหลย้อนหลัง 1 วัน มีค่าประสิทธิภาพของแบบจำลองส่วนใหญ่อยู่ในเกณฑ์ดีมาก โดยค่า NSE ส่วนใหญ่มากกว่า 0.75 มีค่า NSE ที่มากกว่า 0.65 อยู่ในเกณฑ์ดี ได้แก่ สถานี M.9 และ M.173 ซึ่งเป็นแบบจำลอง PG-LSTM และ LSTM ตามลำดับ ค่า NSE ที่มากกว่า 0.50 อยู่ในเกณฑ์พอรับได้ ได้แก่ สถานี M.173 แบบจำลอง PG-LSTM พิจารณา ค่า PBIAS ส่วนใหญ่อยู่ในเกณฑ์ดีมากอยู่ระหว่างช่วง -10 ถึง 10 มีสถานีที่ค่า PBIAS อยู่ในช่วง -15 ถึง 15 ได้แก่ สถานี M.176 เป็นแบบจำลองทั้ง 3 วิธีการ และ สถานี M.4 เป็นแบบจำลอง PG-LSTM และค่า PBIAS อยู่ในนอกช่วงของ -15 ถึง 15 ได้แก่ สถานี M.9 เป็นแบบจำลอง ANN และพิจารณา ค่า RMSE ส่วนใหญ่จะมากกว่า 10 ส่วนใหญ่ทุกสถานี ยกเว้น สถานี M.2A เป็นแบบจำลอง ANN และ LSTM สถานี M.184 เป็นแบบจำลอง ANN ที่มี RMSE ค่าต่ำกว่า 10 ประสิทธิภาพของแบบจำลองทั้งหมดจากการ Training และ Test ค่าประสิทธิภาพของแบบจำลองที่ได้มีความสอดคล้องกันสำหรับค่า NSE และ RMSE ยกเว้นค่า PBIAS ที่ Training น้อยกว่า Test ที่แสดงดังภาพที่ 26




ภาพที่ 26 ประสิทธิภาพของแบบจำลองของแต่ละสถานี ด้วยค่า NSE, RMSE และ PBIAS โดยใช้อัตราการไหลย้อนหลัง 1 วัน

จากตารางที่ 10 แสดงประสิทธิภาพแบบจำลองโดยใช้ข้อมูลอัตราการไหลย้อนหลัง 3 วัน มีค่าประสิทธิภาพของแบบจำลองส่วนใหญ่อยู่ในเกณฑ์ดีมาก พิจารณาค่า NES ส่วนใหญ่มากกว่า 0.75 อยู่ในเกณฑ์ดีมาก มีสถานี E.92 แบบจำลอง PG-LSTM ที่มีค่า NSE มีค่ามากกว่า 0.65 อยู่ในเกณฑ์ดี พิจารณาค่า PBIAS ส่วนใหญ่อยู่ในช่วง -10 ถึง 10 อยู่ในเกณฑ์ดีมาก มีสถานีที่ค่า PBIAS อยู่ในช่วง -15 ถึง 15 ได้แก่ สถานี M.176 แบบจำลอง LSTM และ PG-LSTM อยู่ในเกณฑ์ดีและค่า PBIAS อยู่ในช่วงของ -25 ถึง 25 ได้แก่ สถานี M.9 แบบจำลอง ANN อยู่ในเกณฑ์พอรับได้ และพิจารณาค่า RMSE ส่วนใหญ่จะมากกว่า 10 ส่วนใหญ่ทุกสถานี ยกเว้น สถานี M.2A กับ M.184 แบบจำลอง LSTM และ ANN สถานี M.176 แบบจำลอง ANN ที่มีค่า RMSE ต่ำกว่า 10 ประสิทธิภาพของแบบจำลองทั้งหมดจากการ Training และ Test ค่าประสิทธิภาพของแบบจำลองที่ได้มีความสอดคล้องกันสำหรับค่า NSE และ RMSE ยกเว้นค่า PBIAS ที่ Training น้อยกว่า Test ที่แสดงดังภาพที่ 27



ภาพที่ 27 ประสิทธิภาพของแบบจำลองของแต่ละสถานี ด้วยค่า NSE, RMSE และ PBIAS โดยใช้อัตราการไหลย้อนหลัง 3 วัน

จากตารางที่ 11 แสดงประสิทธิภาพแบบจำลองโดยใช้ข้อมูลอัตราการไหลย้อนหลัง 7 วัน มีค่าประสิทธิภาพของแบบจำลองอยู่ในเกณฑ์ดีมาก พิจารณาค่า NES ส่วนใหญ่มากกว่า 0.75 อยู่ในเกณฑ์ดีมาก ได้แก่ สถานี E.92 แบบจำลอง LSTM และสถานี M.9 แบบจำลอง ANN มีค่า NES มากกว่า 0.65 อยู่ในเกณฑ์ดี ได้แก่ สถานี E.92 แบบจำลอง PG-LSTM ค่า NES มีค่ามากกว่า 0.50 อยู่ในเกณฑ์พอรับได้ พิจารณาค่า PBIAS ส่วนใหญ่อยู่ในช่วง -10 ถึง 10 เป็นเกณฑ์ดีมาก ได้แก่ สถานี M.176 แบบจำลอง LSTM และ PG-LSTM ที่ค่า PBIAS อยู่ในช่วง -15 ถึง 15 อยู่ในเกณฑ์ดี สถานี M.9 แบบจำลอง ANN อยู่ในช่วง -25 ถึง 25 และพิจารณาค่า RMSE ส่วนใหญ่จะมากกว่า 10 ส่วนใหญ่ทุกสถานี ยกเว้น สถานี M.2A ของทั้ง 3 แบบจำลอง สถานี M.176 แบบจำลอง ANN และสถานี M.184 เป็นแบบจำลอง ANN และ LSTM ที่มีค่า RMSE ต่ำกว่า 10 ประสิทธิภาพของแบบจำลองทั้งหมดจากการ Training และ Test ค่าประสิทธิภาพของแบบจำลองที่ได้มีความสอดคล้องกันสำหรับค่า NES และ RMSE ยกเว้นค่า PBIAS ที่ Training น้อยกว่า Test ที่แสดงดังภาพที่ 28



ภาพที่ 28 ประสิทธิภาพของแบบจำลองของแต่ละสถานี ด้วยค่า NES, RMSE และ PBIAS โดยใช้ข้อมูลอัตราการไหลย้อนหลัง 7 วัน

เมื่อพิจารณาจากแบบจำลองทั้งหมดจากตารางที่ 9 - 11 แบบจำลองทั้ง 3 วิธี โดยมีสถานี M.9 ที่ปรับ Batch size เป็น 128 ของแบบจำลอง LSTM และ PG-LSTM ทำให้ของแบบจำลองทั้ง 3 วิธี มีประสิทธิภาพอยู่ในเกณฑ์ดีมาก เมื่อพิจารณาจากค่าประสิทธิภาพโดยเฉลี่ยของแบบจำลองทั้ง 3 วิธี โดย ANN, LSTM และ PG-LSTM มีค่า NES เฉลี่ยของแต่ละแบบจำลองมากกว่า 0.75 มีค่า 0.9610, 0.9333 และ 0.8939 ตามลำดับ ค่า PBIAS เฉลี่ยของแต่ละแบบจำลองอยู่ระหว่าง -10 ถึง 10 มีค่า -4.68, -3.05 และ -4.12 ตามลำดับ และมีค่า RMSE เฉลี่ยของแต่ละแบบจำลอง 23.73, 33.71 และ 40.55 ตามลำดับ นั่นคือแบบจำลองที่ได้สามารถใช้ในการพยากรณ์ได้

จากตารางที่ 12 จะพบว่าเมื่อเพิ่มตัวแปรอัตราการไหลย้อนหลังเข้าไปในแบบจำลองทำให้แบบจำลองนั้นมีค่าประสิทธิภาพของแบบจำลองดีขึ้น โดยมีค่า NSE เพิ่มขึ้น ค่า PBIAS เข้าใกล้ 0 มากขึ้น และ ค่า RMSE ลดลง ทำให้ประสิทธิภาพของแบบจำลองเพิ่มขึ้น และแต่ละสถานีมีแบบจำลองที่มีประสิทธิภาพแต่ละวิธีการ ดังนี้

ตารางที่ 13 แบบจำลองของแต่ละสถานีที่มีประสิทธิภาพแต่ละวิธีการที่ (จำนวนวันของการใช้อัตราการไหลย้อนหลัง)

สถานี	แบบจำลอง			สถานี	แบบจำลอง		
M.2A	ANN(3)	LSTM(1)	PG-LSTM(7)	M.173	ANN(7)	LSTM(7)	PG-LSTM(7)
M.4	ANN(7)	LSTM(7)	PG-LSTM(7)	M.176	ANN(7)	LSTM(3)	PG-LSTM(3)
M.5	ANN(7)	LSTM(3)	PG-LSTM(7)	M.184	ANN(7)	LSTM(3)	PG-LSTM(7)
M.6A	ANN(7)	LSTM(7)	PG-LSTM(7)	E.18	ANN(3)	LSTM(3)	PG-LSTM(3)
M.7	ANN(3)	LSTM(3)	PG-LSTM(3)	E.20A	ANN(7)	LSTM(7)	PG-LSTM(1)
M.9	ANN(3)	LSTM(3)	PG-LSTM(7)	E.92	ANN(7)	LSTM(1)	PG-LSTM(1)

ตารางที่ 13 แสดงแบบจำลองแต่ละวิธีที่มีประสิทธิภาพของแต่ละสถานี โดยใช้อัตราการไหลย้อนหลังในแบบจำลอง 1 วัน 3 วัน และ 7 วัน จากแบบจำลองในตารางที่ 13 ในเลือกแบบจำลองที่ดีที่สุดของแต่ละสถานีแสดง ซึ่งแบบจำลองที่ให้ผลลัพธ์ที่ดีที่สุดส่วนใหญ่เป็นแบบจำลอง ANN เว้นสถานี M.9 แบบจำลอง LSTM ซึ่งใช้แบบจำลองข้อมูลอัตราการไหลย้อนหลัง 3 วัน คือสถานี M.2A, M.7, M.9 และ E.18 แบบจำลองที่ใช้ข้อมูลอัตราการไหลย้อนหลัง 7 วัน คือสถานี M.4, M.5, M.6A, M.173, M.176, E.20A และ E.92

4.3 การคาดการณ์น้ำท่วม

จากแบบจำลองของทั้ง 3 วิธีการใช้คาดการณ์การเหตุการณ์น้ำท่วม โดยใช้ความจุของลำน้ำใช้เป็นเกณฑ์การวัด โดยใช้เกณฑ์ของกรมชลประทาน ดังนี้

น้ำท่วม คือ อัตราการไหลปัจจุบันสูงกว่าค่าความจุลำน้ำ (ที่ระดับน้ำท่วมถึง)


น้ำมาก คือ อัตราการไหลปัจจุบันสูงกว่าร้อยละ 70.1 ของความจุลำน้ำ

น้ำปกติ คือ อัตราการไหลปัจจุบันสูงกว่าร้อยละ 30.1 ถึง ร้อยละ 70 ของความจุลำน้ำ

น้ำน้อย คือ อัตราการไหลปัจจุบันน้อยกว่าร้อยละ 30 ของความจุลำน้ำ


จากแบบจำลองแต่ละวิธีของแต่ละสถานี ได้เปรียบเทียบข้อมูลทดสอบเทียบกับข้อมูลอัตราการไหลจริง ดังนี้

M.2A




ภาพที่ 29 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.2A


พูน ปณ ทิโต ชีเว




ภาพที่ 30 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.4




ภาพที่ 31 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.5




ภาพที่ 32 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.6A




ภาพที่ 33 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.7




ภาพที่ 34 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.9




ภาพที่ 35 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.173




ภาพที่ 36 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.176




ภาพที่ 37 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี M.184



ภาพที่ 38 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี E.18



ภาพที่ 39 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี E.20A




ภาพที่ 40 ข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM ของสถานี E.92

จากภาพที่ 29 - 40 แสดงข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง โดยที่ แสดงค่าของอัตรา การไหลข้อมูลทดสอบกับผลลัพธ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับเวลา เส้นตรงที่ ขนานกับแนวแกนนอน คือ ความจุลำนํ้าของแต่ละสถานี และค่าที่แสดงทางด้านขวาของแกนตั้ง คือ ปริมาณน้ำฝนที่ใช้ในการสร้างแบบจำลอง โดยความจุของลำนํ้าแต่ละสถานี เป็นดังนี้


M.2A	200	ลบ.ม./วินาที	M.173	290	ลบ.ม./วินาที
M.4	1,040	ลบ.ม./วินาที	M.176	500	ลบ.ม./วินาที
M.5	1,670	ลบ.ม./วินาที	M.184	132	ลบ.ม./วินาที
M.6A	1,170	ลบ.ม./วินาที	E.18	1,050	ลบ.ม./วินาที
M.7	2,300	ลบ.ม./วินาที	E.20A	1,100	ลบ.ม./วินาที
M.9	230	ลบ.ม./วินาที	E.92	180	ลบ.ม./วินาที

จากแบบจำลองสามารถพยากรณ์ข้อมูลได้ถึงจุดสูงสุด เมื่อมีปริมาณน้ำฝนจำส่งผลให้มีอัตรา การไหลเกิดขึ้น และใช้แบบจำลองทำการพยากรณ์ล่วงหน้า ได้ผลลัพธ์ดังนี้


(ข)




ภาพที่ 41 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.2A




ภาพที่ 42 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.4




ภาพที่ 43 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.5




ภาพที่ 44 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.6A




ภาพที่ 45 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.7




ภาพที่ 46 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี M.9




ภาพที่ 47 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง
ของสถานี M.173




ภาพที่ 48 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง
ของสถานี M.176




ภาพที่ 49 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง
ของสถานี M.184



ภาพที่ 50 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี E.18



ภาพที่ 51 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี E.20A



ภาพที่ 52 การพยากรณ์จากแบบจำลอง ANN, LSTM และ PG-LSTM กับข้อมูลจริง ของสถานี E.92

จากภาพที่ 41 - 52 แสดงผลลัพธ์ของการพยากรณ์ล่วงหน้าของแบบจำลองทั้ง 3 วิธีการของแต่ละสถานี ผลลัพธ์ของการพยากรณ์ 2 เดือน (ช่วงเดือนเมษายน ถึง พฤษภาคม ปี พ.ศ. 2565) พบว่า ค่าพยากรณ์ของอัตราการไหลที่ได้มีความใกล้เคียงกับค่าอัตราการไหลจริง พบว่าแบบจำลอง ANN สามารถพยากรณ์ได้ใกล้เคียงที่สุด ถัดมาคือแบบจำลอง LSTM และ แบบจำลอง PG-LSTM ตามลำดับ ใน สถานี M.5 และ M.9 ไม่มีข้อมูลจริงของอัตราการไหล ในการพยากรณ์ของทั้งสองสถานีใช้ค่าพยากรณ์ที่ได้ มาเป็นตัวแปรที่ใช้พยากรณ์วันถัดไป ซึ่งผลลัพธ์ที่ได้จึงทำให้ค่าพยากรณ์ของทั้งสองสถานีมีลักษณะที่เป็นเส้นตรง เมื่อมีปริมาณฝนจะทำให้ค่าพยากรณ์นั้นสูงขึ้น ที่แสดงในภาพที่ 43 และ 46

จากการใช้แบบจำลองที่ได้ในการใช้พยากรณ์อัตราการไหลเพื่อใช้ในการคาดการณ์น้ำท่วม พบว่า ช่วงฤดูฝนระหว่างกลางเดือนพฤษภาคมถึงกลางเดือนตุลาคม เป็นช่วงที่มีฝนตกส่งผลให้มีอัตราการไหลในแม่น้ำสูงขึ้น และในช่วงของเดือนกันยายนถึงเดือนตุลาคม เป็นช่วงที่มีฝนตกอย่างต่อเนื่องจากภาพที่ 29 - 40 จะเห็นได้ว่ามีอัตราการไหลในช่วงเดือนกันยายนถึงเดือนตุลาคมมีสูงมาก และเกินความจุของลำน้ำทำให้ในช่วงเวลาดังกล่าวมีเหตุการณ์น้ำท่วม น้ำล้นตลิ่ง จากอัตราการไหลในแม่น้ำที่เพิ่มขึ้น



บทที่ 5

สรุปและอภิปรายผล

ในงานวิจัยเรื่อง ตัวแบบสำหรับการพยากรณ์น้ำท่วมในภาคตะวันออกเฉียงเหนือตอนล่างของประเทศไทย สร้างแบบจำลองในการพยากรณ์อัตราการไหล เพื่อใช้ในการคาดการณ์น้ำท่วมในพื้นที่ภาคตะวันออกเฉียงเหนือตอนล่าง ซึ่งมีวัตถุประสงค์หลักเพื่อสร้างแบบจำลองที่เหมาะสมกับการพยากรณ์น้ำท่วม ในภาคตะวันออกเฉียงเหนือตอนล่าง ของประเทศไทย จากข้อมูลปริมาณน้ำฝน ข้อมูลอุณหภูมิต่ำสุด ข้อมูลอุณหภูมิสูงสุด ข้อมูลอัตราการระเหย และข้อมูลอัตราการไหล ข้อมูลที่ใช้เป็นข้อมูลรายวันตั้งแต่ปี พ.ศ.2551 ถึง พ.ศ.2563 โดยใช้ แบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) แบบจำลอง Long Short-Term Memory (LSTM) และแบบจำลอง Physics-Guided Long Short-Term Memory (PG-LSTM) สรุปผลได้ดังนี้

5.1 สรุปผล

ในพื้นที่ภาคตะวันออกเฉียงเหนือตอนล่างมีลุ่มน้ำที่สำคัญคือลุ่มน้ำชี และลุ่มน้ำมูล โดยส่วนใหญ่ของพื้นที่มีแม่น้ำมูลเป็นแม่น้ำหลักของพื้นที่ในภาคตะวันออกเฉียงเหนือตอนล่าง โดยแม่น้ำมูลมีสภาพการไหลจากทิศตะวันตกมายังทิศตะวันออก ไหลผ่านจังหวัดนครราชสีมา บุรีรัมย์ สุรินทร์ ศรีสะเกษ และไปบรรจบกันแม่น้ำโขงที่จังหวัดอุบลราชธานี และในพื้นที่ภาคตะวันออกเฉียงเหนือตอนล่างจะมีแม่น้ำชีที่ไหลผ่าน ซึ่งเป็นแม่น้ำชีที่อยู่ในลุ่มน้ำชีตอนล่าง แม่น้ำชีมีทิศทางการไหลจากตะวันตกเฉียงเหนือไปทางทิศตะวันออกเฉียงใต้และไหลผ่านจังหวัดร้อยเอ็ด ยโสธร และไหลมาบรรจบกันในพื้นที่จังหวัดอุบลราชธานี พื้นที่ที่แม่น้ำชีกับแม่น้ำมูลไหลมาบรรจบกันนั้นทำให้พื้นที่ส่วนนี้มักเกิดปัญหาน้ำท่วมบ่อยครั้ง ในงานวิจัยนี้ได้ศึกษาอัตราการไหลในลำน้ำ ซึ่งลักษณะของอัตราการไหลที่เกิดจะสูงขึ้นในช่วงของเดือนพฤษภาคมถึงเดือนตุลาคม และสูงที่สุดในช่วงเดือนกันยายนของทุกปี จากการสร้างแบบจำลองในการพยากรณ์อัตราการไหล โดยการใช้แบบจำลอง 3 วิธี ได้แก่ แบบจำลอง ANN แบบจำลอง LSTM และแบบจำลอง PG -LSTM เพื่อหาตัวแบบที่เหมาะสมในการพยากรณ์ ในการสร้างแบบจำลอง ใช้ตัวแปรปริมาณน้ำฝน อุณหภูมิสูงสุด อุณหภูมิต่ำสุด อัตราการระเหย และอัตราการไหลย้อนหลัง โดยใช้ข้อมูลย้อนหลัง 1 วัน 3 วัน และ 7 วัน ในการสร้างแบบจำลองแบ่งข้อมูลเป็นข้อมูลเรียนรู้ (Training Set) เป็นข้อมูลตั้งแต่วันที่ 1 เมษายน พ.ศ. 2551 ถึง 24 กุมภาพันธ์ พ.ศ. 2563 และข้อมูลทดสอบ (Test Set) เป็นข้อมูลตั้งแต่วันที่ 25 กุมภาพันธ์ พ.ศ. 2563 ถึง 31 มีนาคม พ.ศ. 2565 วัดประสิทธิภาพของแบบจำลองโดยใช้เกณฑ์การวัดประสิทธิภาพ 3 ค่า ได้แก่

สัมประสิทธิ์ประสิทธิภาพของแนช-ซัทคลิฟฟ์ (Nash–Sutcliffe Efficiency: NSE) รากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Squared Error: RMSE) และร้อยละความเอนเอียง (Percentage Bias: PBIAS) ได้เลือกสถานีในการสร้างแบบจำลอง เป็นดังนี้ ในลุ่มน้ำชี จำนวน 3 สถานี ได้แก่ สถานี E.18, E.92 จังหวัดร้อยเอ็ด สถานี E.20A จังหวัดยโสธร ในลุ่มน้ำมูล จำนวน 9 สถานี ได้แก่ สถานี M.173, M.184 และ M.2A จังหวัดนครราชสีมา สถานี M.6A จังหวัดบุรีรัมย์ สถานี M.4 จังหวัดสุรินทร์ สถานี M.5 และ M.9 จังหวัดศรีสะเกษ สถานี M.176 และ M.7 จังหวัดอุบลราชธานี ซึ่งเป็นจุดเฝ้าระวังน้ำท่วมฉับพลัน น้ำป่าไหลหลาก น้ำล้นตลิ่ง ที่เกิดจากฝนตกหนัก ผลที่ได้เมื่อเพิ่มอัตราการไหลย้อนในแบบจำลอง พบว่า แบบจำลองนั้นมีค่าวัดประสิทธิภาพที่ดีขึ้น และแบบจำลองที่เหมาะสมของสถานีส่วนใหญ่ คือ แบบจำลอง ANN ยกเว้น สถานี M.9 เป็นแบบจำลอง LSTM โดยแบบจำลอง LSTM ได้มีการปรับ Batch size ลงทำให้ประสิทธิภาพของแบบจำลองดีขึ้น และแบบจำลองที่มีประสิทธิภาพนั้นใช้ข้อมูลอัตราการไหลย้อนหลัง 3 และ 7 วัน โดยเปรียบเทียบประสิทธิภาพของแบบจำลองทั้งหมดที่เหมาะสม และแบบจำลองที่มีความเหมาะสมมากที่สุดส่วนใหญ่ คือ แบบจำลอง ANN รองลงมาคือแบบจำลอง LSTM และ แบบจำลอง PG-LSTM ตามลำดับ โดยมีค่า NSE เฉลี่ยของแต่ละแบบจำลองมากกว่า 0.75 ค่า PBIAS เฉลี่ยของแต่ละแบบจำลองอยู่ระหว่าง -10 ถึง 10 และค่า RMSE แต่ละแบบจำลองมีค่าน้อย จากการเทียบข้อมูลทดสอบกับข้อมูลจริงสามารถพยากรณ์อัตราการไหลได้ใกล้เคียงกับข้อมูลจริง และสามารถพยากรณ์ได้จนถึงค่าสูงสุด รวมถึงค่าวัดประสิทธิภาพของแบบจำลองทั้ง 3 แบบจำลองที่อยู่ในเกณฑ์ดีมาก เหมาะที่จะใช้ในการพยากรณ์น้ำท่วมโดยใช้ความจุของลำน้ำเป็นเกณฑ์ในพยากรณ์การน้ำท่วม จึงสรุปได้ว่า แบบจำลองเหมาะสมในการใช้งาน และในการพยากรณ์ล่วงหน้าปริมาณฝนเป็นตัวแปรที่สำคัญโดยระยะเวลาที่เกิดอัตราการไหลสูงสุดเกิดจากการเปลี่ยนแปลงของปริมาณฝนซึ่งส่งผลต่ออัตราการไหลของน้ำในแม่น้ำ

5.2 อภิปรายผล

จากการศึกษาตัวแบบสำหรับการพยากรณ์น้ำท่วมในภาคตะวันออกเฉียงเหนือตอนล่าง โดยศึกษาพื้นที่อยู่ในภาคตะวันออกเฉียงเหนือตอนล่างที่มีลุ่มน้ำมูล มีแม่น้ำมูลเป็นแม่น้ำสายหลัก มีต้นน้ำจากจังหวัดนครราชสีมา และมาบรรจบกับแม่น้ำโขงที่จังหวัดอุบลราชธานี ลักษณะของลำน้ำมูลมีความคดเคี้ยวทำให้เวลาที่ฝนตกหนักอย่างต่อเนื่องทำให้เกิดน้ำท่วม น้ำล้นตลิ่งในพื้นที่ราบลุ่ม และลุ่มน้ำชีตอนล่าง ไหลผ่านจากร้อยเอ็ด มาบรรจบกับแม่น้ำมูลในจังหวัดอุบลราชธานี ทำให้พื้นที่ที่มีแม่น้ำมูลและแม่น้ำชีมาบรรจบกันเกิดท่วมบ่อยครั้ง จากการสร้างแบบจำลองในการพยากรณ์อัตราการไหล เพื่อใช้ในการพยากรณ์น้ำท่วม ได้ใช้ตัวแปรทางอุทกวิทยา และ

อุตุนิยมวิทยา ได้แก่ ข้อมูลปริมาณน้ำฝน อุณหภูมิต่ำสุด อุณหภูมิสูงสุด อัตราการเหย และ อัตราการไหลย้อนหลัง ได้ศึกษาแบบจำลอง 3 วิธีการ ได้แก่ แบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) แบบจำลอง Long Short-Term Memory (LSTM) และ แบบจำลอง Physics-Guided Long Short-Term Memory (PG-LSTM) โดยแต่ละวิธีการได้เพิ่ม อัตราการไหลย้อนหลัง 1 วัน 3 วัน และ 7 วัน เป็นตัวแปรนำเข้าและเปรียบเทียบประสิทธิภาพของการเพิ่มอัตราการไหลย้อนหลัง พบว่า การเพิ่มค่าอัตราการไหลย้อนหลังมากขึ้น ทำให้แบบจำลอง ทั้ง 3 วิธี มีค่าประสิทธิภาพของแบบจำลองเพิ่มขึ้น สอดคล้องการงานวิจัยของ Mumtaz Ahmad (2565) และคณะ ได้สร้างแบบจำลอง ANN ที่ได้เสนอว่าในการเพิ่มประสิทธิภาพของแบบจำลองโดยการเพิ่มตัวแปรให้มากขึ้นหรือใช้ค่าย้อนหลังเพิ่มขึ้น นอกจากนี้ จากงานวิจัยของ K.E Arunkumar (2564) ที่ใช้แบบจำลอง Deep layer Recurrent Neural Networks ในการพยากรณ์การระบาดของ Covid-19 ซึ่งแบบจำลอง LSTM ที่เข้ามาแก้ปัญหาการเรียนรู้ของแบบจำลอง ANN เพื่อให้การเรียนรู้มีประสิทธิภาพเพิ่มมากขึ้น และจากวิจัยของ Yalian Zhang และ คณะ (2565) ที่พัฒนาแบบจำลอง PG-LSTM และพบว่าเมื่อแยกพิจารณาตามสถานการณ์ที่มีฝนเกิดขึ้นจะทำให้พยากรณ์ค่าสูงสุดได้ดีขึ้น ในงานวิจัยนี้จึงได้เปรียบเทียบ 3 แบบจำลอง ได้แก่ แบบจำลอง ANN แบบจำลอง LSTM และ แบบจำลอง PG-LSTM โดยเปรียบเทียบประสิทธิภาพของแบบจำลองทั้ง 3 วิธี โดยใช้เกณฑ์การวัดประสิทธิภาพ ได้แก่ สัมประสิทธิ์ประสิทธิภาพของแบบจำลองแนช-ซัทคลิฟฟ์ (Nash–Sutcliffe Efficiency: NSE) รากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Squared Error: RMSE) และร้อยละความเอนเอียง (Percentage Bias: PBIAS) พบว่า แบบจำลอง ANN มีค่าประสิทธิภาพของแบบจำลองได้ดีกว่า ถัดมาคือแบบจำลอง LSTM และแบบจำลอง PG-LSTM ซึ่งแบบจำลอง ANN มีการประมวลผลที่มีจำนวนพารามิเตอร์น้อยกว่าแบบจำลอง LSTM และแบบจำลอง PG-LSTM และในกระบวนการประมวลผลแบบจำลองทั้ง 2 แบบจำลอง ที่มีการเชื่อมโยงระหว่างข้อมูลนำเข้าก่อนหน้ากับข้อมูลส่งออกทั้งหมดในกระบวนการจำของแบบจำลองทำให้มีประสิทธิภาพที่น้อยกว่า และด้วยลักษณะของข้อมูลที่มีค่าน้อยเป็นจำนวนมาก และข้อมูลที่มีการเปลี่ยนแปลงของแนวโน้มอย่างรวดเร็วในช่วงที่เป็นฤดูน้ำหลาก ทำให้แบบจำลอง ANN มีความเหมาะสมในการพยากรณ์มากกว่า ซึ่งสอดคล้องกับ Byeongmo Seo และคณะ ได้ศึกษาตัวแบบที่เหมาะสมสำหรับระบบ HVAC โดยเปรียบเทียบแบบจำลอง ANN และ แบบจำลอง LSTM พบว่า แบบจำลอง ANN มีประสิทธิภาพมีประสิทธิภาพดีกว่า แบบจำลอง LSTM เนื่องจากข้อมูลที่มีการเปลี่ยนแปลงของแนวโน้มอย่างรวดเร็ว ดังนั้น การพยากรณ์น้ำท่วมแบบจำลอง ANN จึงเป็นแบบจำลองที่มีความเหมาะสม โดยใช้เกณฑ์ความจุของลำน้ำเป็นตัวกำหนดการพยากรณ์น้ำท่วม และแบบจำลองที่ได้มีความเหมาะสมในการใช้งาน เนื่องจากแบบจำลองทั้ง 3 วิธี สามารถพยากรณ์ถึงค่าสูงสุดได้ และมีค่าประสิทธิภาพของแบบจำลองที่ดีมาก

5.3 ข้อเสนอแนะ


งานวิจัยเรื่องตัวแบบสำหรับการพยากรณ์น้ำท่วมในภาคตะวันออกเฉียงเหนือตอนล่างของประเทศไทย โดยการวิจัยในครั้งนี้พยากรณ์อัตราการไหล จากข้อมูลปริมาณน้ำฝน ข้อมูลอุณหภูมิจากข้อมูลอัตราการระเหย และข้อมูลอัตราการไหลย้อนหลัง ข้อมูลที่ใช้เป็นข้อมูลรายวันตั้งแต่ 1 เมษายน พ.ศ. 2551 ถึง 31 มีนาคม พ.ศ.2563 ใช้ข้อมูลจากสถานีอุตุนิยมวิทยา กรมอุตุนิยมวิทยา และศูนย์อุทกวิทยาชลประทานภาคตะวันออกเฉียงเหนือตอนล่าง และศูนย์อุทกวิทยาชลประทานภาคตะวันออกเฉียงเหนือตอนบน

5.3.1 ข้อเสนอแนะในการทำวิจัยครั้งนี้


1. ข้อมูลที่นำมาใช้มีข้อมูลขาดหายไปบางสถานี มาจากการเก็บรวบรวมของหน่วยงานที่ทำการขอข้อมูลซึ่งเป็นเรื่องที่ยากที่การจัดกรการข้อมูล อาจเพิ่มวิธีการจัดการข้อมูลสูญหาย
2. การสร้างแบบจำลองปรับพารามิเตอร์โดยการกำหนดค่าเป็นคงที่ แล้วรันแบบจำลองซ้ำเพื่อดูประสิทธิภาพยังอยู่ในเกณฑ์เดิม

5.3.2 ข้อเสนอแนะในการทำวิจัยครั้งต่อไป

1. ตัวแปรทางด้านอุตุนิยมวิทยายังมีตัวแปรที่น่าสนใจอีกหลายตัว ที่สามารถนำมาเพิ่มในงานวิจัยได้ เช่น ข้อมูลความชื้นสัมพัทธ์ ความเร็วลม เป็นต้น
2. ศึกษา Loss Function ที่สามารถปรับเข้ากับรูปแบบของพื้นที่ที่ศึกษาให้เหมาะสม โดยการเพิ่ม Loss Function ที่เกี่ยวกับตัวแปรอื่น ๆ



บรรณานุกรม



กรมอุตุนิยมวิทยา (2565). หนังสืออุตุนิยมวิทยา. [ออนไลน์]. เข้าถึงได้จาก <https://www.tmd.go.th>

ไกรศักดิ์ เกษร (2564). วิทยาศาสตร์ข้อมูล (Data Science). ภาควิชาวิทยาการจัดการคอมพิวเตอร์และเทคโนโลยีสารสนเทศ คณะวิทยาศาสตร์ มหาวิทยาลัยนเรศวร.

คลังข้อมูลน้ำแห่งชาติ National Hydroinformatics Data Center (2563, 4 มีนาคม). บันทึกเหตุการณ์น้ำท่วม. <https://www.thaiwater.net/>

ฉลอง เกิดพิทักษ์, ชัยวัฒน์ ชัยการนาวิ (2557). การศึกษาเบื้องต้นของคลองชลประทานเพื่อลดระดับและเวลาน้ำท่วมตามลำน้ำชี – มูล. วารสารวิชาการราชภัฏตะวันตก, 8(2). 17-25.

ณพฐ์ โสภีพันธ์. (2558). ตัวแบบเชิงสถิติเพื่อการพยากรณ์ปริมาณน้ำฝนของจังหวัดนครราชสีมา. *Naresuan University Journal: Science and Technology*, 23(2), 56-65.

ทวี ชัยพิมลผลิน. (2561). แบบจำลองโครงข่ายประสาทเทียมสำหรับการพยากรณ์ระดับน้ำในลุ่มน้ำยมตอนล่างด้วยข้อมูลกริดน้ำฝนจากแบบจำลองสภาพภูมิอากาศ. *วารสารสังคมศาสตร์มหาวิทยาลัยศรีนครินทรวิโรฒ*, 21.

ธนาวุฒิ ประกอบผล (2552). โครงข่ายประสาทเทียม Artificial Neural Networks. *วารสาร มฉก. วิชาการ*, 24(12). 73-87.

ธีรเมธ หิรัญพัฒนานนท์, วรพงษ์ โล่ห์ไพศาลกฤช (2563) การสร้างแบบจำลองน้ำฝน-น้ำท่าสำหรับน้ำท่วมฉับพลันในพื้นที่เมืองบ้านไผ่ จังหวัดขอนแก่น. *การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ*, ครั้งที่ 25 <https://conference.thaince.org/index.php/ncce25/>

ปรียาพร โกษา, ถุภชัช ศรีวรรมาศ, ธนัช สุขวิลลเสรี, ธนภัทร อุทาสสวัสดิ์ (2565) การประเมินพื้นที่น้ำท่วมในจังหวัดอุบลราชธานีด้วยแบบจำลอง MIKE FLOOD. *การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ*, ครั้งที่ 27 <https://conference.thaince.org/index.php/ncce27/>

พิมพ์พลัญช์ ปรียกร, ปรีชาติ เวชยนต์, ชัยวัฒน์ เอกวัฒน์พานิชย์. (2564). ผลกระทบของปรากฏการณ์เอลนีโญต่อความแปรปรวนของปริมาณฝนในภาคตะวันออกเฉียงเหนือของประเทศไทย. *การประชุมทางวิชาการของ มหาวิทยาลัยเกษตรศาสตร์*, ครั้งที่ 59. (น. 15-23). <https://annualconference.ku.ac.th/>

เมธัส ใจปิ่นดา, จิระวัฒน์ กณะสุต (2556). การศึกษาแนวทางการป้องกันน้ำท่วมจังหวัดอุบลราชธานีในพื้นที่ลุ่มน้ำมูลตอนล่าง. *Journal of Science and Technology*, 2(2).73-85.

ยุพิน ไชยสมภาร, ทวี ชัยพิมลผลิน (2560). การพยากรณ์ระดับน้ำโดยแบบจำลองโครงข่ายประสาทเทียมด้วยข้อมูลปริมาณน้ำฝนจากแบบจำลอง WRF-ECHAM5. *วารสารมหาวิทยาลัยศรีนครินทรวิโรฒ (สาขาวิทยาศาสตร์และเทคโนโลยี)* 9(17). 83-90.

- รักษัณณา ภูสีเขียว, สุรณพิร์ ภูมิวุฒิสาร. (2565). การพยากรณ์ปริมาณน้ำฝนระยะสั้นในบริเวณพื้นที่
สนามบินสุวรรณภูมิด้วยโครงข่ายระบบประสาทแบบย้อนกลับ. *Journal of Information
Science and Technology*, Vol. 12 No. 1.
- ศูนย์เตือนภัยพิบัติแห่งชาติ - National Disaster Warning Center. (2561). รู้จักภัยจาก อุทกภัย
หรือ น้ำท่วม. http://ndwc.disaster.go.th/inner.ndwc-9.283/cms/menu_7525/4214.5/
- สถาบันพระปกเกล้า (King Prajadhipok's Institute) (2559). กลุ่มจังหวัด. <http://wiki.kpi.ac.th>
- สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน) (สสน.). (2561). รายงานข้อมูลพื้นฐาน 25 ลุ่มน้ำ
ลุ่มน้ำมูล. [https://www.senate.go.th/assets/portals/143/fileups/148/files/05-ลุ่มน้ำ
มูล.pdf](https://www.senate.go.th/assets/portals/143/fileups/148/files/05-ลุ่มน้ำมูล.pdf)
- สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน) (สสน.). (2561). รายงานข้อมูลพื้นฐาน 25 ลุ่มน้ำ
ลุ่มน้ำชี. [https://www.senate.go.th/assets/portals/143/fileups/148/files/04-ลุ่มน้ำชี.
pdf](https://www.senate.go.th/assets/portals/143/fileups/148/files/04-ลุ่มน้ำชี.pdf)
- เสาวนิต ปราบนคร, ศุภกร ศิริพจนกุล, สุกุม ลิปิเลิศ (2557) การจัดทำแผนที่น้ำท่วมในอำเภอเชียง
ขวัญ จังหวัดร้อยเอ็ด โดยใช้แบบจำลองคณิตศาสตร์ 1D/2D. *Journal of Engineering,
RMUTT (JERMUTT)*, 20(2).
- หริส ประสารฉ่ำ, วินัย เขาวนวิวัฒน์ สมพินิจ เหมเมืองทอง, กนกศรี ศรีนันทากร, สุรเจตส์
บุญญาอรุณเนตร (2565) การประเมินประสิทธิภาพแบบจำลองอุทกวิทยา SWAT สำหรับการ
จำลองปริมาณน้ำท่าโดยใช้เทคนิคการการปรับเทียบและสอบทานแบบหลายสถานีในพื้นที่ลุ่มน้ำ
มูล. *การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ*, ครั้งที่ 27 [https://conference.thaince.org/
index.php/ncce27/](https://conference.thaince.org/index.php/ncce27/)
- Ahmad, M. Mehedi, MA Al. Yazdan, MMS. Kumar, R. (2022) Development of Machine
Learning Flood Model Using Artificial Neural Network (ANN) at Var River. *Liquids
(MDPI)*, 2 , 147–160.
- BBC NEWS ไทย. (2565, 5 ตุลาคม). เทียบข้อมูลน้ำท่วม 2554 กับ 2565 หลังรัฐยืนยันไม่ซ้ำรอย.
<https://www.bbc.com/thai/articles/cx802845nxno>
- Baheti, P. (2023, March 2). Activation Functions in Neural Networks [12 Types & Use
Cases]. <https://www.v7labs.com/blog/neural-networks-activation-functions>
- Dongare, A. Kharde, R. Kachare D. (2012). Introduction to Artificial Neural Network.
International Journal of Engineering and Innovative Technology (IJEIT), 2, 189-
194.

- Gupta, H.V., Sorooshian, S., Yapo, P.O. (1999). Status of Automatic Calibration for Hydrologic Models: Comparison with Multilevel Expert Calibration. *Journal of Hydrologic Engineering*, 4, 135-143.
- Karpatne, A., Atluri, G., Faghmous, J.H., Steinbach, M., Banerjee, A., Ganguly, A., Shekhar, S., Samatova, N., Kumar, V., 2017a. Theory-guided data science: a new paradigm for scientific discovery from data. *IEEE Transactions on Knowledge and Data Engineering* 29 (10), 2318–2331. <https://doi.org/10.1109/TKDE.2017.2720168>.
- Daw, A. Thomas, R.Q. Carey, C.C. Read, J.S. Appling, A.P. Karpatne, A. (2019). Physics-Guided Architecture (PGA) of Neural Networks for Quantifying Uncertainty in Lake Temperature Modeling. arXiv:1911.02682.
- Le, XH. Ho, HV. Lee, G. (2019). River streamflow prediction using a deep neural network: a case study on the Red River, Vietnam. *Korean Journal of Agricultural Science*, 46. 843-856. <https://doi.org/10.7744/kjoas.20190068>
- Liu, B. Tang, Q. Zhao G. Gao, L. Shen, C. & Pan, B. (2022). Physics-Guided Long Short-Term Memory Network for Streamflow and Flood Simulations in the Lancang-Mekong River Basin. *Water (MDPI)*, 14, 1429. <https://doi.org/10.3390/w14091429>
- Moriasi, D. N. Arnold, J. G. Van Liew, M. W. Bingner, R. L. Harmel, R. D. Veith T. L. (2007). Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. *Transactions of the ASABE (American Society of Agricultural and Biological Engineers)*, 50(3). DOI:10.13031/2013.23153
- Mosavi, A. Ozturk, P. & Chau, K. (2018). Flood Prediction Using Machine Learning Models: Literature Review water. *Water (MDPI)*, 10(11). <https://doi.org/10.3390/w10111536>
- Olah, C. (2015, August 27) Understanding LSTM Networks. *colah's blog*. <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- Pearson, K. (1920). Notes on the history of correlation. *The Society of Biometricians and Mathematical Statisticians*, 13(1), 25-45.
- PPTV Online. (2564, 1 ตุลาคม). "น้ำท่วม 64 " ประเมินความเสียหาย กว่า 15,000 ล้านบาท. <https://www.pptvhd36.com/news/เศรษฐกิจ/157611>

PPTV Online. (2565, 5 ตุลาคม). น้ำท่วมทั่วประเทศเสียหาย "หมื่นล้าน" พร้อมคาดการณ์เป้าเศรษฐกิจโต 3.5%. <https://www.pptvhd36.com/news/เศรษฐกิจ/181943>


Sarafanov, M. Borisova, Y. Maslyayev, M. Revin, I. Maximov G. & Nikitin N.O. (2021). Short-Term River Flood Forecasting Using Composite Models and Automated Machine Learning: The Case Study of Lena River. *Water (MDPI)*, 13, 3482. <https://doi.org/10.3390/w13243482>


Seo, B. Yoon, Y. Lee, K.H. Cho, S. (2023). Comparative Analysis of ANN and LSTM Prediction Accuracy and Cooling Energy Savings through AHU-DAT Control in an Office Building, *Buildings*, 13(6).

Thuerey, N. Holl, P. Mueller, M. Schnell, P. Trost, F. & Um, K. (2022). Physics-based Deep Learning. <http://physicsbaseddeeplearning.org>

Xie, K. Liu, P. Zhang J. Han D. Wang, G. Shen, C. (2021) Physics-guided deep learning for rainfall-runoff modeling by considering extreme events and monotonic relationships. *Journal of Hydrology*, 603. <https://doi.org/10.1016/j.jhydrol.2021.127043>

Zheng, Y. Liu, P. Cheng, L. Xie, K. Lou, W. Li, X. Luo, X.Cheng, Q. Han, D. Zhang, W. (2022). Extracting operation behaviors of cascade reservoirs using physics-guided long-short term memory networks. *Journal of Hydrology: Regional Studies*, 40. <https://doi.org/10.1016/j.ejrh.2022.101034>





ตัวอย่าง โปรแกรมใช้ในการวิเคราะห์

ANN

```

import numpy as np
import pandas as pd
import tensorflow as tf
from tensorflow import keras
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, Layer
from tensorflow.python import train
from sklearn.preprocessing import MinMaxScaler,
from sklearn.metrics import mean_squared_error,

```

```
Y = data[varY].values
```

```
X = data[varX].values
```

```
scalerY = MinMaxScaler(feature_range=(0, 1))
```

```
scalerX = MinMaxScaler(feature_range=(0, 1))
```

```
y = scalerY.fit_transform(Y)
```

```
x = scalerX.fit_transform(X)
```

```
Hidden_size = [10,50,100,150,200,250,300]
```

```
Epoch = list(range(100,310,10))
```

```
hs, loop = [], []
```

```
Activation = 'sigmoid'
```

```
Optimize = "adam"
```

```
Batch_size = 512
```

```
n_input = X_train.shape[1]
```

```
for j in range(len(Hidden_size)):
```

```
    units = Hidden_size[j]
```

```

for k in range(len(Epoch)):
    epoch = Epoch[k]

    model = Sequential()
    model.add(Dense(units, input_dim=(n_input) ,activation = Activation))
    model.add(Dropout(0.2))
    model.add(Dense(units= units ,activation = Activation))
    model.add(Dropout(0.2))
    model.add(Dense(1, activation = Activation))
    model.compile(loss='mean_squared_error', optimizer=Optimize)

    model.fit(X_train, y_train, epochs= epoch, verbose=0, batch_size= Batch_size)

```

LSTM

```

import numpy as np
import pandas as pd
import tensorflow as tf
from tensorflow import keras
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, Layer, LSTM
from tensorflow import train
from sklearn.preprocessing import MinMaxScaler, StandardScaler

Y = data[varY].values
X = data[varX].values

scalerY = MinMaxScaler(feature_range=(0, 1))
scalerX = MinMaxScaler(feature_range=(0, 1))
y = scalerY.fit_transform(Y)
x = scalerX.fit_transform(X)

```



```

# reshape input to be [samples, time steps, features]
X_train = np.reshape(X_train, (X_train.shape[0],1, X_train.shape[1]))
X_test = np.reshape(X_test, (X_test.shape[0], 1, X_test.shape[1]))

Hidden_size = [10,50,100,150,200,250,300]
Epoch = list(range(100,310,10))
hs, loop = [], []
Activation = 'sigmoid'
Optimize = "adam"
Batch_size = 512
n_input = X_train.shape[2]

for j in range(len(Hidden_size)):
    units = Hidden_size[j]
    for k in range(len(EPOCH)):
        epoch = Epoch[k]

        model = Sequential()
        model.add(LSTM(units, input_shape=(1,input_shape),activation = Activation))
        model.add(Dropout(0.2))
        model.add(Dense(units=units,activation = Activation))
        model.add(Dropout(0.2))
        model.add(Dense(1, activation = Activation))
        model.compile(loss='mean_squared_error', optimizer=Optimize)
        model.fit(X_train, y_train, epochs=epoch, verbose=0, batch_size= Batch_size)

```

PG-LSTM

```
import numpy as np
import pandas as pd
import tensorflow as tf
from tensorflow import keras
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, Layer, LSTM
from tensorflow import train
from sklearn.preprocessing import MinMaxScaler, StandardScaler
from statistics import mean
from keras import backend as K
from keras.losses import mean_squared_error
```

#Loss function

```
def root_mean_squared_error(y_true, y_pred):
    return K.sqrt(K.mean(K.square(y_pred - y_true), axis=-1))
```

```
def rainfall_loss(y_true, y_pred):
    return K.mean(K.square(y_pred - Rain))
```

```
def dry_loss(y_true, y_pred):
    return K.mean(K.square(y_pred))
```

```
def combined_loss(params):
    Loss_in, Loss_0, lam = params
    def loss(y_true, y_pred):
        return mean_squared_error(y_true, y_pred) + lam *
        K.constant(value=Loss_in) + lam * K.constant(value=Loss_0)
    return loss
```

```
df = pd.DataFrame(X_all, columns = ['X1','X2','X3','X4','X5','P'])
```

```

# selecting rows based on rain Event
rain_strom = df[df['P'] == 1]
uX1 = rain_strom.to_numpy()

# selecting rows based on dry Event
dry_event = df[df['P'] == 1]
uX2 = rain_strom.to_numpy()

ux1 = np.reshape(uX1, (uX1.shape[0], 1, uX1.shape[1]))
ux2 = np.reshape(uX2, (uX2.shape[0], 1, uX2.shape[1]))

for j in range(len(Hidden_size)):
    units = Hidden_size[j]
    for k in range(len(Epoch)):
        Ep = Epoch[k]

        model = Sequential()
        model.add(LSTM(units, input_shape=(1,input_shape),activation = Activation
            ,return_sequences=True))
        model.add(Dropout(0.2))
        model.add(LSTM(units=units,activation = Activation))
        model.add(Dropout(0.2))
        model.add(Dense(1, activation = Activation))

# # Calculate loss function
uin1 = K.constant(value=ux1)
uin2 = K.constant(value=ux2)

lam = K.constant(value=lamda) # regularization hyper-parameter
out1 = model(uin1)
out2 = model(uin2)

```

```
Pin = uX1[0:len(uX1),1:2]
```

```
P0 = uX1[0:len(uX2),1:2]
```

```
Loss_in = rainfall_loss(Pin, out1)
```


```
Loss_0 = dry_loss(P0, out2)
```

```
totloss = combined_loss([Loss_in, Loss_0, lam])
```

```
# Compile the model with the custom conditional loss
```

```
model.compile(optimizer= Optimize, loss=totloss)
```

```
model.fit(X_train, y_train, epochs=epoch, verbose=0, batch_size= Batch_size)
```



ประวัติผู้เขียน

ชื่อ	พงศกร มลสิน
วันเกิด	24 กันยายน 2541
สถานที่เกิด	โรงพยาบาลหัวตะพาน อ.หัวตะพาน จ.อำนาจเจริญ
สถานที่อยู่ปัจจุบัน	72 หมู่ 2 ต.เคิ่งใหญ่ อ.หัวตะพาน จ.อำนาจเจริญ 37240
ตำแหน่งหน้าที่การงาน	นิสิตระดับบัณฑิตศึกษา
สถานที่ทำงานปัจจุบัน	ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยมหาสารคาม
ประวัติการศึกษา	พ.ศ. 2564 ปริญญาตรี วิทยาศาสตร์บัณฑิต (วท.บ.) สาขาวิชาสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยมหาสารคาม พ.ศ. 2566 ปริญญาโท วิทยาศาสตรมหาบัณฑิต (วท.ม.) สาขาวิทยาการจัดการสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยมหาสารคาม

