

การประมาณค่าน้ำในบรรยากาศจากข้อมูลอุตุนิยมวิทยาภาคพื้นระยะยาว โดยใช้แบบจำลองโครงข่ายประสาทเทียม Atmospheric Precipitable Water Estimation from Long-Term Ground-Based Meteorological Data using Artificial Neural Network Model

ศาสตรา ศิริแก้ว^{1*}, สุรภา วิชาเป้ง², พัชรินทร์ วิภาวตตันติ³ และ วิจิตรา กังวานวิทย์²

Sattra Sirikaew^{1*}, Surapa Wichapeng², Patcharin Wipawattanti³ and Wijittra Kangwanwit²

¹ศูนย์ปฏิบัติการฝนหลวงภาคตะวันออก ประเทศไทย

²ศูนย์ฝนหลวงหัวหิน ประเทศไทย

³ส่วนอากาศการบินราธิวาส หอบังคับการบินราธิวาส ประเทศไทย

¹Eastern Royal Rainmaking Operation Center, Thailand

²Hua Hin Royal Rainmaking Center, Thailand

³Narathiwat Aeronautical Meteorology Sub-division, Narathiwat Air Traffic Control Tower, Thailand

Received : 25 April 2025, Received in revised form : 10 October 2025, Accepted : 12 October 2025

Available online : 29 October 2025

บทคัดย่อ

วัตถุประสงค์และที่มา : น้ำเป็นหนึ่งในองค์ประกอบของบรรยากาศซึ่งพบมากที่ระดับผิวพื้นและมีปริมาณเล็กน้อยในบรรยากาศชั้นสตราโตสเฟียร์ โดยทั่วไปน้ำในบรรยากาศมีสถานะได้ทั้งของแข็ง ของเหลว และก๊าซ โดยน้ำในบรรยากาศที่อยู่ในสถานะก๊าซ เรียกว่า ไอน้ำ ซึ่งมีความสำคัญต่อกระบวนการเปลี่ยนแปลงทางกายภาพ ทางเคมี และกระบวนการต่าง ๆ ที่เกิดขึ้นในบรรยากาศ เช่น มีความสามารถในการดูดกลืนรังสีอาทิตย์ที่ส่งผ่านมายังพื้นโลก มีความสามารถในการดูดกลืนรังสีอินฟราเรดที่แผ่ออกมาจากพื้นโลก มีผลต่อขนาดและองค์ประกอบของอนุภาคละอองลอยที่ดูดความชื้น มีผลต่อคุณสมบัติเชิงแสงของละอองลอย และเป็นก๊าซเรือนกระจกที่เกิดขึ้นเองตามธรรมชาติ เป็นต้น นอกจากนี้ไอน้ำในบรรยากาศยังมีความสำคัญต่อกระบวนการเกิดเมฆและฝนซึ่งสามารถกำจัดก๊าซที่ละลายน้ำและละอองลอยในบรรยากาศได้ มีความสำคัญต่อกระบวนการเปลี่ยนแปลงพลังงานในชั้นบรรยากาศระหว่างภาคพื้นทวีปกับมหาสมุทร อีกทั้งยังมีความสำคัญต่อสมดุลของรังสีในภูมิภาคหรือพื้นที่ที่ไวต่อสภาพอากาศ ดังนั้นปริมาณน้ำในบรรยากาศจึงเป็นหนึ่งในตัวแปรที่มีความสำคัญต่ออุทกวิทยา ระบบนิเวศ สภาพภูมิอากาศ และการเปลี่ยนแปลงสภาพภูมิอากาศของโลก ด้วยเหตุนี้จึงจำเป็นต้องติดตาม ตรวจสอบ และศึกษาการเปลี่ยนแปลงปริมาณน้ำในบรรยากาศที่เกิดขึ้น โดยทั่วไปปริมาณน้ำในบรรยากาศสามารถบอกได้ในหลายรูปแบบ เช่น ความชื้นสัมบูรณ์ ความชื้นสัมพัทธ์ ความชื้นจำเพาะ อัตราส่วนผสมมวล อัตราส่วนผสมปริมาตร และปริมาณน้ำทั้งหมดที่ควบแน่นได้ในคอลัมน์บรรยากาศ เป็นต้น ซึ่งการบอกปริมาณน้ำดังกล่าวนี้ได้จากการวัดโดยตรงโดยใช้อุปกรณ์หรือเครื่องมือวัด หรือการวัดทางอ้อมโดยใช้แบบจำลองหรือการคำนวณจากตัวแปรอื่น ๆ ปัจจุบันพบว่าอุปกรณ์หรือเครื่องมือการตรวจวัดปริมาณน้ำในบรรยากาศยังคงมีราคาแพงซึ่งส่งผลให้พื้นที่การตรวจวัดมีจำกัดและมีค่าไม่ต่อเนื่อง ดังนั้นงานวิจัยนี้จึงมี

วัตถุประสงค์เพื่อประมาณค่าปริมาณน้ำในบรรยากาศเฉลี่ยรายเดือนจากข้อมูลอุตุนิยมวิทยาภาคพื้นระยะยาวโดยใช้แบบจำลองโครงข่ายประสาทเทียม

วิธีดำเนินการวิจัย : พื้นที่ดำเนินการวิจัยเป็นพื้นที่ที่มีการตรวจวัดปริมาณน้ำในบรรยากาศและตรวจวัดข้อมูลทางอุตุนิยมวิทยาภาคพื้นอย่างต่อเนื่องซึ่งประกอบด้วยศูนย์อุตุนิยมวิทยาภาคเหนือ จ.เชียงใหม่ (18.98N, 98.98E) ศูนย์อุตุนิยมวิทยาภาคตะวันออกเฉียงเหนือตอนล่าง จ.อุบลราชธานี (15.25N, 104.87E) และศูนย์อุตุนิยมวิทยาภาคใต้ฝั่งตะวันออก จ.สงขลา (7.20N, 100.60E) ข้อมูลที่ใช้ในการศึกษาวิจัยระหว่างปี ค.ศ. 2008 – 2024 ซึ่งประกอบด้วย (1) ปริมาณน้ำทั้งหมดที่ควบแน่นได้ในคอลัมน์บรรยากาศเฉลี่ยรายเดือนที่ตรวจวัดโดยเครื่องชั้นโฟโตมิเตอร์ของเครือข่ายการวัดฝุ่นละอองขององค์การนาซา (2) อุณหภูมิสิ่งแวดล้อมภาคพื้นเฉลี่ยรายวันที่ตรวจวัดโดยกรมอุตุนิยมวิทยา (3) ความชื้นสัมพัทธ์ภาคพื้นเฉลี่ยรายวันที่ตรวจวัดโดยกรมอุตุนิยมวิทยา (4) ความดันไอน้ำอิ่มตัวเฉลี่ยรายเดือนซึ่งคำนวณจาก Improved Magnus Formula โดยใช้อุณหภูมิและความชื้นสัมพัทธ์เฉลี่ยรายเดือน และ (5) ลำดับเดือนในรอบปี โดยอุณหภูมิสิ่งแวดล้อมภาคพื้นเฉลี่ยรายวันและความชื้นสัมพัทธ์ภาคพื้นเฉลี่ยรายวันที่มีจำนวนมากกว่าหรือเท่ากับ 15 วัน/เดือน จะนำไปหาค่าเฉลี่ยเพื่อใช้เป็นค่าเฉลี่ยรายเดือนของเดือนนั้น ๆ ขณะที่เดือนที่ข้อมูลดังกล่าวมีจำนวนน้อยกว่า 15 วัน/เดือน จะไม่ถูกพิจารณาจากนั้นวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรอินพุตกับตัวแปรเอาต์พุตและระหว่างตัวแปรอินพุตกับตัวแปรอินพุตด้วยสัมประสิทธิ์สหสัมพันธ์เพียร์สันโดยใช้การเขียนโปรแกรมภาษา Python ผ่าน Google Colaboratory โดยข้อมูลระหว่างปี ค.ศ. 2008 – 2021 ใช้สำหรับสร้างแบบจำลอง และข้อมูลระหว่างปี ค.ศ. 2022 – 2024 ใช้สำหรับทดสอบแบบจำลองซึ่งกระบวนการดังกล่าวใช้โปรแกรม WEKA จากนั้นประเมินสมรรถนะของแบบจำลองด้วยค่าความคลาดเคลื่อนเฉลี่ย (MBE) ค่ารากที่สองของความคลาดเคลื่อนยกกำลังสองเฉลี่ย (RMSE) และค่าสัมประสิทธิ์แสดงการตัดสินใจ (R^2) โดยใช้โปรแกรม Microsoft Excel

ผลการวิจัย : ผลการวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรอินพุต (อุณหภูมิสิ่งแวดล้อมภาคพื้นเฉลี่ยรายเดือน ความชื้นสัมพัทธ์ภาคพื้นเฉลี่ยรายเดือน ความดันไอน้ำอิ่มตัวเฉลี่ยรายเดือน และลำดับเดือนในรอบปี) กับตัวแปรเอาต์พุต (ปริมาณน้ำทั้งหมดที่ควบแน่นได้ในคอลัมน์บรรยากาศเฉลี่ยรายเดือน) พบว่าศูนย์ฯ จ.เชียงใหม่ ศูนย์ฯ จ.อุบลราชธานี และศูนย์ฯ จ.สงขลา สัมประสิทธิ์สหสัมพันธ์เพียร์สันมีค่าอยู่ในช่วง 0.36 – 0.64, 0.29 – 0.52 และ 0.17 – 0.44 ตามลำดับ ผลดังกล่าวแสดงให้เห็นว่าตัวแปรอินพุตกับตัวแปรเอาต์พุตมีความสัมพันธ์เชิงบวกและอยู่ในเกณฑ์ระดับต่ำถึงปานกลาง นอกจากนี้ยังพบว่าตัวแปรอินพุตกับตัวแปรอินพุตมีความสัมพันธ์ทั้งเชิงบวกและเชิงลบโดยมีค่าอยู่ในเกณฑ์ระดับต่ำถึงปานกลางเช่นเดียวกัน ผลการสร้างแบบจำลองโครงข่ายประสาทเทียมจากระดับความสัมพันธ์ดังกล่าวพบว่าแต่ละศูนย์ฯ ดังกล่าวมีจำนวนชั้นซ่อน 2 ชั้น แต่ละชั้นซ่อนมีจำนวนโหนดเท่ากับ 5 และ 2 สำหรับศูนย์ฯ จ.เชียงใหม่ มีจำนวนโหนดเท่ากับ 8 และ 5 สำหรับศูนย์ฯ จ.อุบลราชธานี และมีจำนวนโหนดเท่ากับ 8 และ 5 สำหรับศูนย์ฯ จ.สงขลา และผลการประเมินสมรรถนะแบบจำลองของศูนย์ฯ ดังกล่าวพบว่าแบบจำลองสามารถประมาณค่าปริมาณน้ำในบรรยากาศเฉลี่ยรายเดือนได้ที่ระดับความแม่นยำด้วยค่า MBE เท่ากับ -0.89% -1.23% และ 1.04% ตามลำดับ ค่า RMSE เท่ากับ 4.21% 4.85% และ 5.34% ตามลำดับ และค่า R^2 เท่ากับ 0.98 0.95 และ 0.81 ตามลำดับ

สรุปผลการวิจัย : จากการประมาณค่าปริมาณน้ำในบรรยากาศด้วยแบบจำลองโครงข่ายประสาทเทียม พบว่าภาพรวมของค่า MBE RMSE และ R^2 มีค่าเฉลี่ย -0.39% 4.83% และ 0.95 ตามลำดับ ผลการศึกษาวิจัยแสดงให้เห็นว่า เนื่องจากใช้ข้อมูลระยะยาว ความสัมพันธ์ระหว่างตัวแปรที่ระดับต่ำถึงปานกลางจึงยังคงทำให้แบบจำลองที่นำเสนอสามารถประมาณค่าปริมาณน้ำในบรรยากาศเฉลี่ยรายเดือนได้ที่ระดับความแม่นยำสูงเมื่อเทียบกับงานวิจัยอื่น ๆ ที่ใช้วิธีการคล้ายกัน (สถานที่และตัวแปร)

คำสำคัญ : แบบจำลอง ANN ; น้ำในบรรยากาศ ; การประมาณค่าน้ำในบรรยากาศ

Abstract

Background and Objectives: Water is one of the constituents of the atmosphere, being abundant at the surface and in small quantities in the stratosphere. Generally, atmospheric water vapor exists in solid, liquid, and gaseous states. The gaseous state known as water vapor is important to the physical, chemical, and various processes that occur in the atmosphere, such as its ability to absorb solar radiation transmitted to the earth, its ability to absorb infrared radiation emitted from the earth, its role in the size and composition of hygroscopic aerosol particles, affecting the optical properties of aerosols, and being naturally occurring greenhouse gas, and etc. Furthermore, atmospheric water vapor is vital for the formation of cloud and rain, as it can remove dissolved gases and aerosols from the atmosphere. It is also important for energy transformation processes in the atmosphere between continents and oceans for regional or climate-sensitive radiation balance. Therefore, the amount of atmospheric water vapor is a key variable for hydrology, ecosystem, climate, and global climate change. Thus, it is necessary to monitor, measure and study the changes in the amount of atmospheric water. Atmospheric water content can be expressed in several forms, such as absolute humidity, relative humidity, specific humidity, mass mixing ratio, volume mixing ratio, and total precipitable water in the atmospheric column, and etc. These quantities are derived from direct measurements using instruments or indirect methods employing models or calculations from other variables. Currently, instruments for measuring atmospheric water content remain expensive, leading to limited and discontinuous measurement coverage. Consequently, the objective of this study is to estimate monthly average atmospheric water from long-term ground-based meteorological data using Artificial Neural Network (ANN).

Methodology: The study area was defined as three locations with continuous measurement of atmospheric water and ground-based meteorological data: the northern meteorological center, Chiang Mai province (18.98N, 98.98E); the northeastern meteorological center (lower part), Ubon Ratchathani province (15.25N, 104.87E); and the southern-east coast meteorological center, Songkhla province (7.20N, 100.60E). The data utilized for the study, covering the period 2008 – 2024, include: (1) Monthly average TPW measured by ground-based sunphotometer of the Aerosol Robotic Network (AERONET), National Aeronautics and Space Administration (NASA); (2) daily average ground-level ambient air temperature measured by the Thai Meteorological Department (TMD); (3) daily average

ground-level ambient air relative humidity measured by the TMD; (4) monthly average saturated water vapor pressure calculated from the Improved Magnus Formula using monthly average ground-level ambient air temperatures and relative humidity; and (5) month of the year (as an ordinal variable). The daily average ground-level ambient air temperature and relative humidity with more than or equal to 15 days/month were averaged to be used as the monthly average of that month, while months with less than 15 days/month of such data were not considered. The relationship between input and output variables and between input variables were then analyzed using the Pearson correlation coefficient (or Pearson product-moment correlation coefficient, r) via Python programming language through Google Colaboratory. Data from 2008 – 2021 were used for model development and data from 2022 – 2024 for model testing using the WEKA software. Finally, the model performance was evaluated with the Mean Bias Error (MBE), Root Mean Squared Error (RMSE), and coefficient of determination (R^2) in Microsoft Excel.

Main Results: The analysis of the relationship between the input variables (monthly average ground-level ambient air temperature, monthly average ground-level ambient air relative humidity, monthly average saturated water vapor pressure, and month of the year (as an ordinal variable) and the output variables (monthly average TPW) showed that the Pearson correlation coefficients at Chiang Mai, Ubon Ratchathani, and Songkhla stations were in the range of 0.36 – 0.64, 0.29 – 0.52, and 0.17 – 0.44, respectively. This result showed that the input and output variables were a weak to moderate positive relationship. Moreover, the relationship between input variables also were a weak to moderate positive and negative relationship. The results of ANN model derived from these relationship levels showed that each station had 2 hidden layers. The number of nodes in the hidden layers were 5 and 2 for Chiang Mai, 8 and 5 for Ubon Ratchathani, and 8 and 5 for Songkhla. The results of the model performance evaluation of these stations found that the model can estimate the monthly average atmospheric water content with accuracy of MBE values of -0.89%, -1.23%, and 1.04%, respectively, RMSE values of 4.21%, 4.85%, and 5.34%, respectively, and R^2 values of 0.98, 0.95, and 0.81, respectively.

Conclusions: From the atmospheric water content estimation using the ANN model, it was found that the overall MBE, RMSE, and R^2 were -0.39%, 4.83%, and 0.95, respectively. The results of the study showed that, despite low to moderate correlation between variables, the utilization of long-term data allows the proposed model to estimate the monthly average atmospheric water content with high level of accuracy compared to other similar studies (in terms of location and variables).

Keywords: ANN model; atmospheric precipitable water; atmospheric precipitable water estimation

*Corresponding author. E-mail: sattra.sirikaew@gmail.com

Introduction

น้ำเป็นหนึ่งในองค์ประกอบของบรรยากาศซึ่งพบมากในบรรยากาศชั้นโทรโพสเฟียร์ (Troposphere) และมีปริมาณเล็กน้อยในบรรยากาศชั้นสตราโตสเฟียร์ (Stratosphere) ซึ่งมีสถานะได้ทั้งของแข็ง ของเหลว และก๊าซ น้ำในบรรยากาศที่อยู่ในสถานะก๊าซ เรียกว่า ไอน้ำ (Water vapour) ซึ่งมีความสำคัญต่อกระบวนการต่าง ๆ ที่เกิดขึ้นในบรรยากาศ โดยเฉพาะอย่างยิ่งมีความสำคัญต่อกระบวนการเกิดเมฆและฝน ดังนั้นปริมาณน้ำในบรรยากาศจึงเป็นตัวแปรที่มีความสำคัญต่อสภาพภูมิอากาศ อุทกวิทยา ระบบนิเวศ และการเปลี่ยนแปลงสภาพภูมิอากาศของโลก (Kämpfer, 2013) ด้วยเหตุนี้การศึกษาการเปลี่ยนแปลงและการประมาณค่าปริมาณน้ำในบรรยากาศ (Atmospheric precipitable water vapour, PW) จึงมีความสำคัญ ปัจจุบันการวัดหรือการประมาณค่าปริมาณน้ำในบรรยากาศ (PW) สามารถทำได้หลัก ๆ 2 วิธี คือ การวัดหรือการประมาณค่าจากข้อมูลที่ตรวจวัดด้วยอุปกรณ์ตรวจวัดภาคพื้น เช่น เครื่องไมโครเวฟเรดิโอมิเตอร์ (Microwave radiometer) เครื่องซันโฟโตมิเตอร์ (Sunphotometer) เครื่องไลดาร์ (Light detection and ranging, LiDAR) เป็นต้น และภาคอากาศ เช่น ดาวเทียม (Geostationary satellite หรือ Polar-orbiting satellite หรือ GPS satellite) เครื่องบิน (Aircraft) และวิทยุหิ้งอากาศ (Radiosonde) เป็นต้น (Buntoung, 2022; Kumar *et al.*, 2021; Baelen *et al.*, 2005) ทั้งนี้อุปกรณ์หรือเครื่องมือวัดดังกล่าวมีราคาค่อนข้างแพง จึงทำให้ตำแหน่งหรือบริเวณการตรวจวัดมีจำนวนจำกัดและไม่ต่อเนื่อง ดังนั้นการประมาณค่าปริมาณน้ำในบรรยากาศโดยใช้แบบจำลองจึงเป็นหนึ่งในวิธีการที่มีประสิทธิภาพ

ในช่วงหลายปีที่ผ่านมาได้มีการศึกษาการประมาณค่าปริมาณน้ำในบรรยากาศในหลายพื้นที่ทั่วโลก เช่น อินเดีย (Kongara & Punyasesudu, 2015) ตุรกี (Senkal *et al.*, 2012) กรีซ (Moustris *et al.*, 2011) อิหร่าน (Azadi & Sepaskhah, 2012) และที่ราบสูงทิเบต (Liu *et al.*, 2005) เป็นต้น โดยแบบจำลองทางคณิตศาสตร์ (Mathematical model) ที่แสดงความสัมพันธ์ระหว่างข้อมูลที่ส่งผลกระทบต่อปริมาณน้ำในบรรยากาศ (Okulov *et al.*, 2002; Adeyemi, 2009) และแบบจำลองการเรียนรู้ของเครื่อง (Machine learning) (Du *et al.*, 2024) จึงได้ถูกนำมาใช้ในการประมาณค่า ประเทศไทยมีรายงานการศึกษาการประมาณค่าปริมาณน้ำในบรรยากาศ โดย Phokate & Atyotha (2018) ศึกษาการประมาณค่าปริมาณน้ำในบรรยากาศชั้นโทรโพสเฟียร์เฉลี่ยรายเดือนโดยใช้แบบจำลองทางคณิตศาสตร์ กรณีศึกษา สถานีอุตุนิยมวิทยา จ.เชียงใหม่ สถานีอุตุนิยมวิทยา จ.อุบลราชธานี สถานีอุตุนิยมวิทยา จ.สงขลา และกรมอุตุนิยมวิทยา กรุงเทพฯ โดยข้อมูลที่ใช้ประกอบด้วยปริมาณน้ำในบรรยากาศจากผลตรวจอากาศชั้นบนด้วยวิทยุหิ้งอากาศที่ปล่อยขึ้นไปกับบอลลูน อุณหภูมิและความชื้นสัมพัทธ์จากการตรวจวัดภาคพื้น ผลการสร้างแบบจำลองทางคณิตศาสตร์โดยใช้ข้อมูลระหว่างปี ค.ศ. 1993 – 2014 และทดสอบแบบจำลองโดยใช้ข้อมูลในปี ค.ศ. 2015 พบว่าแบบจำลองดังกล่าวสามารถประมาณค่าปริมาณน้ำในบรรยากาศโดยมีค่ารากที่สองของความคลาดเคลื่อนยกกำลังสองเฉลี่ย (Root Mean Squared Error, RMSE) และค่าสัมประสิทธิ์แสดงการตัดสินใจ (Coefficient of determination, R^2) เท่ากับ 0.528 cm และ 0.851 ตามลำดับ นอกจากนี้ Buntoung *et al.*, (2021) ศึกษาการประมาณค่าปริมาณน้ำในบรรยากาศเฉลี่ยรายเดือนโดยใช้แบบจำลองโครงข่ายประสาทเทียม กรณีศึกษา สถานีอุตุนิยมวิทยา จ.เชียงใหม่ สถานีอุตุนิยมวิทยา จ.อุบลราชธานี สถานีอุตุนิยมวิทยา จ.สงขลา และมหาวิทยาลัยศิลปากร จ.นครปฐม โดยข้อมูลที่ใช้ประกอบด้วยปริมาณน้ำในบรรยากาศจากเครื่องซันโฟโตมิเตอร์ อุณหภูมิและความชื้นสัมพัทธ์จาก

การตรวจวัดภาคพื้น ผลการสร้างแบบจำลองโดยใช้ข้อมูลระหว่างปี ค.ศ. 2009 – 2013 และทดสอบแบบจำลองโดยใช้ข้อมูลระหว่างปี ค.ศ. 2014 – 2015 พบว่าแบบจำลองดังกล่าวสามารถประมาณค่าปริมาณน้ำในบรรยากาศโดยมีค่า MBE RMSE และ R^2 ของข้อมูลรวมเท่ากับ 0.1% 7.50% และ 0.91 ตามลำดับ

จากรายงานการศึกษาข้างต้นพบว่าแบบจำลองดังกล่าวสามารถประมาณค่าปริมาณน้ำในบรรยากาศได้ระดับความแม่นยำค่อนข้างสูงค่าหนึ่ง ดังนั้นเพื่อเพิ่มความแม่นยำของแบบจำลอง งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อศึกษาและพัฒนาแบบจำลองการประมาณค่าปริมาณน้ำในบรรยากาศจากข้อมูลอุตุนิยมวิทยาภาคพื้นระยะยาวโดยใช้แบบจำลองโครงข่ายประสาทเทียม กรณีศึกษา พื้นที่ภาคเหนือ ภาคตะวันออกเฉียงเหนือ และภาคใต้ ของประเทศไทย โดยผลการศึกษาจะสามารถประมาณค่าปริมาณน้ำในบรรยากาศได้อย่างแม่นยำยิ่งขึ้น รวมทั้งสามารถใช้เป็นแนวทางในการศึกษาเพื่อเพิ่มความแม่นยำของแบบจำลองในอนาคต

Methodology

พื้นที่ดำเนินการวิจัยและการรวบรวมข้อมูล

พื้นที่ดำเนินการวิจัยเป็นพื้นที่ที่มีการตรวจวัดปริมาณน้ำในบรรยากาศและตรวจวัดข้อมูลทางอุตุนิยมวิทยาภาคพื้น ดังนั้นคณะผู้วิจัยจึงเลือกพื้นที่ที่มีการตรวจวัดข้อมูลดังกล่าวอย่างต่อเนื่องซึ่งประกอบด้วยศูนย์อุตุนิยมวิทยาภาคเหนือ จ.เชียงใหม่ (18.98N, 98.98E) ศูนย์อุตุนิยมวิทยาภาคตะวันออกเฉียงเหนือตอนล่าง จ.อุบลราชธานี (15.25N, 104.87E) และศูนย์อุตุนิยมวิทยาภาคใต้ฝั่งตะวันออก จ.สงขลา (7.20N, 100.60E) แสดงดัง Figure 1




Figure 1 Installation of sunphotometer at meteorological centers in this study

ข้อมูลที่ใช้ในการศึกษาวิจัยประกอบด้วย (1) ปริมาณน้ำในบรรยากาศเฉลี่ยรายเดือนที่ตรวจวัดด้วยเครื่องชั้นโฟโตมิเตอร์ซึ่งเป็นเครื่องมือสำหรับวัดสเปกตรัมรังสีตรงจากดวงอาทิตย์และรังสีจากท้องฟ้า การวัดปริมาณน้ำในบรรยากาศด้วยเครื่องดังกล่าวจะอาศัยหลักการดูดกลืนรังสีที่ความยาวคลื่นต่าง ๆ ของไอน้ำ (Holben *et al.*, 1998) โดยข้อมูลที่ตรวจวัดได้จะอัปโหลดลงบนเว็บไซต์ <https://aeronet.gsfc.nasa.gov/> ของเครือข่ายการวัดฝุ่นละออง (Aerosol robotic network, AERONET) ซึ่งมีข้อมูลครอบคลุมทั่วโลก (Buntoung, 2022) สำหรับประเทศไทยเครื่องชั้นโฟโตมิเตอร์ติดตั้งและดูแลข้อมูลการตรวจวัดโดยภาควิชาฟิสิกส์ คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากร โดยตำแหน่งที่ตั้งเครื่องชั้นโฟโตมิเตอร์ที่ใช้ในการศึกษาค้นนี้แสดงดัง Figure 1 (2) ข้อมูลอุตุนิยมวิทยาภาคพื้นจากศูนย์อุตุนิยมวิทยาที่ตรวจวัดโดยกรมอุตุนิยมวิทยาซึ่งประกอบด้วยอุณหภูมิสิ่งแวดล้อมเฉลี่ยรายวันและความชื้นสัมพัทธ์เฉลี่ยรายวัน โดยข้อมูลตรวจวัดจะอัปโหลดลงบนเว็บไซต์ <http://aws-observation.tmd.go.th/> ทั้งนี้ข้อมูลการตรวจวัดเฉลี่ยรายวันดังกล่าวที่มีจำนวนมากกว่าหรือเท่ากับ 15 วัน/เดือน จะถูกนำไปหาค่าเฉลี่ยรายเดือนของเดือนนั้น ๆ เพื่อใช้เป็นข้อมูลเฉลี่ยรายเดือนสำหรับการศึกษาวิจัย ขณะที่เดือนที่ข้อมูลมีจำนวนน้อยกว่า 15 วัน/เดือน จะไม่ถูกพิจารณา (3) ความดันไอน้ำอิ่มตัวเฉลี่ยรายเดือนซึ่งคำนวณจากอุณหภูมิสิ่งแวดล้อมเฉลี่ยรายเดือนโดยใช้ Improved Magnus formula ดังสมการ (1) (Alduchov & Eskridge, 1996) และ (4) ลำดับเดือนในรอบปี

$$P_{\text{sat}} = 6.1094 \exp \left(\frac{17.625T}{243.04 + T} \right) \quad (1)$$

เมื่อ P_{sat} คือ ความดันไอน้ำอิ่มตัว (mbar หรือ hPa) และ T คือ อุณหภูมิสิ่งแวดล้อม (C)

คณะผู้วิจัยรวบรวมข้อมูลปริมาณน้ำในบรรยากาศเฉลี่ยรายเดือน อุณหภูมิสิ่งแวดล้อมเฉลี่ยรายเดือน ความชื้นสัมพัทธ์เฉลี่ยรายเดือน ความดันไอน้ำอิ่มตัวเฉลี่ยรายเดือน (ค่าจากการคำนวณ) และลำดับเดือนในรอบปี ระหว่างปี ค.ศ. 2008 – 2024 และวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรดังกล่าวในรูปสัมประสิทธิ์สหสัมพันธ์เพียร์สัน (Pearson's product moment correlation coefficient) โดยใช้วิธีการเขียนโค้ดคำสั่งภาษา Python ผ่าน Google Colaboratory สำหรับนำไปใช้ในการสร้างแบบจำลองเพื่อประมาณค่าปริมาณน้ำในบรรยากาศ

แบบจำลองโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (Artificial Neural Network, ANN) เป็นระบบทางคณิตศาสตร์ที่เขียนในรูปโปรแกรมคอมพิวเตอร์ที่สามารถจำลองการทำงานของระบบทางฟิสิกส์หรือวิศวกรรมต่าง ๆ โดยเลียนแบบการทำงานของสมองของมนุษย์ โดยทั่วไปโครงข่ายประสาทเทียมจะแสดงความสัมพันธ์ระหว่างตัวแปรอินพุตกับตัวแปรเอาต์พุตผ่านหน่วยย่อยที่เรียกว่า นิวรอน (Neural) ซึ่งความสัมพันธ์ดังกล่าวจะได้จากการฝึกสอนด้วยข้อมูลอินพุตกับข้อมูลเอาต์พุตที่ทราบค่า จากนั้นจะนำโครงข่ายประสาทเทียมที่ได้รับการฝึกสอนไปใช้หาค่าเอาต์พุตของระบบจากค่าอินพุตใหม่ ข้อดีของ

การใช้แบบจำลองโครงข่ายประสาทเทียมในการจำลองแบบการทำงานของระบบคือไม่จำเป็นต้องสร้างสมการในรูปแบบฟังก์ชันต่าง ๆ ที่แสดงความสัมพันธ์ระหว่างตัวแปรอินพุตกับตัวแปรเอาต์พุตของระบบ (Janjai, 2017)

ประสาทเทียมเป็นกระบวนการทางคอมพิวเตอร์ซึ่งทำหน้าที่เหมือนกับเซลล์ประสาทของสมองของมนุษย์ โดยแผนภูมิการทำงานของประสาทเทียมสามารถแสดงได้ดัง Figure 2 จาก Figure 2 ประสาทเทียม 1 หน่วย จะรับข้อมูลอินพุตต่าง ๆ เข้ามา จากนั้นจะคูณด้วยตัวถ่วงน้ำหนัก (w_i) และหาผลบวกของผลคูณของอินพุตกับตัวถ่วงน้ำหนักพร้อมกับบวกด้วยตัวแปรอคติความเอนเอียง (Bias parameter) จากนั้นจะส่งผลเข้าไปเป็นตัวแปรอิสระของฟังก์ชันกระตุ้น (Activation function) แล้วให้เอาต์พุตออกมาเพื่อส่งต่อไปให้ประสาทเทียมอื่น ๆ โดยเอาต์พุตที่ได้จากประสาทเทียมสามารถเขียนในรูปสมการได้ดังสมการ (2) (Janjai, 2017; Patterson, 1998)

$$y = f\left(b + \sum_i w_i x_i\right) \quad (2)$$

เมื่อ y คือ เอาต์พุตของประสาทเทียม b คือ ตัวแปรอคติความเอนเอียง x_i คือ ตัวแปรอินพุตที่ i ($i = 1, 2, 3, \dots, n$) และ w_i คือ ค่าถ่วงน้ำหนักสำหรับตัวแปรอินพุตที่ i




Figure 2 Structure of the feedforward neural network approach algorithm

ฟังก์ชันกระตุ้นมีได้หลายฟังก์ชัน เช่น ฟังก์ชันเชิงเส้น (Linear function) ฟังก์ชันขีดจำกัด (Threshold function) และ ฟังก์ชันซิกมอยด์ (Sigmoid function) เป็นต้น (Sharma *et al.*, 2017; Szandafa, 2021) ในการศึกษาครั้งนี้คณะผู้วิจัยเลือกใช้ ฟังก์ชันซิกมอยด์โดยสามารถเขียนได้ดังสมการ (3) (Patterson, 1998)

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

เมื่อ x คือ อินพุตของฟังก์ชัน

การนำประสาทเทียมมาเชื่อมต่อกันเป็นโครงข่ายประสาทเทียมสามารถทำได้หลายรูปแบบ โดยการศึกษาเลือกใช้รูปแบบเพอร์เซปตรอนแบบหลายชั้น (Multi-layer perceptron) ซึ่งเป็นโครงข่ายประสาทที่เชื่อมต่อกันเป็นระบบโดยประกอบด้วยชั้นอินพุต (Input layer) ชั้นซ่อน (Hidden layer) และชั้นเอาต์พุต (Output layer) แสดงดัง Figure 3




Figure 3 Structure of a multi-layer perceptron neural network

ระบบประสาทของมนุษย์มีการเรียนรู้และปรับตัวเพื่อตอบสนองต่อสิ่งเร้าต่าง ๆ โครงข่ายประสาทเทียมก็มีลักษณะเช่นเดียวกัน กล่าวคือต้องมีการเรียนรู้ก่อนการนำไปใช้เพื่อหาคำตอบต่าง ๆ การเรียนรู้ดังกล่าวเกิดจากการฝึกสอนโครงข่ายประสาทเทียมด้วยข้อมูลอินพุตและข้อมูลเอาต์พุตที่ทราบค่า การศึกษาเลือกใช้วิธีการฝึกสอนแบบย้อนกลับ (Back propagation algorithm) ซึ่งแผนภาพวิธีการฝึกสอนดังกล่าวแสดงดัง Figure 4 กล่าวคือเมื่อป้อนข้อมูลอินพุตเข้าไปในโครงข่ายประสาทเทียมแล้วโครงข่ายประสาทเทียมจะคำนวณค่าเอาต์พุตที่เป็นผลลัพธ์ออกมา จากนั้นเปรียบเทียบผลลัพธ์ที่ได้กับเป้าหมายซึ่งเป็นค่าที่ถูกต้องและนำค่าความคลาดเคลื่อน (Error) ส่งย้อนกลับเข้าไปในประสาทเทียมเพื่อปรับค่าถ่วงน้ำหนักของประสาทเทียมเพื่อคำนวณผลลัพธ์ใหม่ โดยทำวนซ้ำจนกระทั่งค่าความคลาดเคลื่อนอยู่ในเกณฑ์ที่ยอมรับได้จึงหยุดการฝึกสอน โดยโครงข่ายประสาทเทียมจะจดจำค่าถ่วงน้ำหนักค่าสุดท้ายที่ได้สำหรับนำไปประยุกต์ใช้งาน กล่าวคือขั้นตอนการนำโครงข่ายประสาทเทียมที่ได้รับการฝึกสอนแล้วไปหาผลลัพธ์ซึ่งได้จากข้อมูลอินพุตชุดใหม่ (Janjai, 2017)




Figure 4 Diagram of back propagation algorithm

โดยทั่วไปการสร้างแบบจำลองโครงข่ายประสาทเทียมสามารถทำได้หลัก ๆ 2 วิธี คือ (1) การสร้างโดยวิธีการเขียนโค้ดคำสั่งโปรแกรมคอมพิวเตอร์วิธีการดังกล่าวนี้ผู้ใช้ต้องมีความรู้ความเข้าใจเกี่ยวกับกลไกการทำงานของโครงข่ายประสาทเทียมและการเขียนโปรแกรมคอมพิวเตอร์เป็นอย่างดี และ (2) การสร้างโดยวิธีการใช้โปรแกรมสำเร็จรูป วิธีการดังกล่าวนี้ผู้ใช้มีความรู้ความเข้าใจเกี่ยวกับกลไกการทำงานของโครงข่ายประสาทเทียม รู้จักวิธีการกำหนดค่าและป้อนข้อมูลของแบบจำลองในโปรแกรมก็สามารถสร้างแบบจำลองได้ (Janjai, 2017) การศึกษานี้เลือกใช้วิธีการสร้างแบบจำลองโครงข่ายประสาทเทียมด้วยวิธีการใช้โปรแกรมสำเร็จรูป โดยข้อมูลระหว่างปี ค.ศ. 2008 – 2021 จะใช้สำหรับสร้างแบบจำลอง และข้อมูลระหว่างปี ค.ศ. 2022 – 2024 จะใช้สำหรับทดสอบแบบจำลอง ซึ่งการสร้างแบบจำลองและทดสอบแบบจำลองดำเนินการโดยใช้โปรแกรม WEKA (ย่อมาจาก Waikato Environment for Knowledge Analysis) ซึ่งเป็นซอฟต์แวร์เปิดอิสระ (Open source software of freeware) ที่พัฒนาโดยมหาวิทยาลัย Waikato ประเทศนิวซีแลนด์ เป็นซอฟต์แวร์ที่เน้นการใช้งานด้านการเรียนรู้ของเครื่องและการทำเหมืองข้อมูล (Data mining) ซึ่งใช้งานผ่านส่วนต่อประสานกราฟิกกับผู้ใช้หรือหน้าจอ GUI (Graphic user interface) (Frank *et al.*, 2016)

ในขั้นตอนการสร้างแบบจำลองด้วยโปรแกรม WEKA จะกำหนดชั้นซ่อนจำนวน 2 ชั้นซ่อน ทั้งนี้เพื่อลดความซับซ้อนในการสร้างและการนำแบบจำลองไปใช้งาน โดยแต่ละชั้นซ่อนจะแปรค่าจำนวนโหนดและจำนวนรอบที่ใช้ในการฝึกสอน (Training time) นอกจากนี้จะเลือกฟังก์ชันซิกมอยด์เป็นฟังก์ชันกระตุ้น ทั้งนี้เนื่องจากเข้าใจง่าย มีพื้นฐานทางคณิตศาสตร์ที่ชัดเจน ใช้ได้ดีกับข้อมูลที่มีขอบเขตจำกัด เหมาะสำหรับข้อมูลที่มีความซับซ้อนหรือไม่เชิงเส้น และมีอนุพันธ์ต่อเนื่องทุกค่าซึ่งส่งผลต่อการฝึกสอนแบบย้อนกลับและทำให้การปรับน้ำหนักมีความเสถียรและเรียนรู้ได้อย่างต่อเนื่อง ดังนั้นการปรับค่าตัวแปรควบคุม (Hyperparameters) ของแบบจำลองที่ทำให้แบบจำลองมีความแม่นยำด้วยค่าทางสถิติที่อยู่ในเกณฑ์ที่ยอมรับได้จะถูกเลือกเพื่อสร้างแบบจำลอง

การประเมินสมรรถนะของแบบจำลอง

การประเมินสมรรถนะของแบบจำลองเป็นการวิเคราะห์ความแม่นยำของแบบจำลองโดยพิจารณาเปรียบเทียบค่าที่ได้จากแบบจำลองกับค่าจากการวัดจริง เนื่องจากการศึกษาวิจัยนี้เป็นการสร้างแบบจำลองเพื่อประมาณค่าเป็นตัวเลข ดังนั้นจึงประเมินสมรรถนะของแบบจำลองโดยใช้ค่าความคลาดเคลื่อนเฉลี่ย (Mean Bias Error, MBE) ค่ารากที่สองของความคลาดเคลื่อนยกกำลังสองเฉลี่ย (Root Mean Squared Error, RMSE) และค่าสัมประสิทธิ์แสดงการตัดสินใจ (Coefficient of determination, R^2) คำนวณได้ดังสมการ (4) ถึง (6) ตามลำดับ (Shanmuganathan, 2016)

$$MBE = \frac{\frac{1}{N} \sum_{i=1}^N (PW_{est,i} - PW_{mea,i})}{\frac{1}{N} \sum_{i=1}^N PW_{mea,i}} \times 100 \quad (4)$$

$$RMSE = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (PW_{est,i} - PW_{mea,i})^2}}{\frac{1}{N} \sum_{i=1}^N (PW_{mea,i})} \times 100 \quad (5)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (PW_{est,i} - PW_{mea,i})^2}{\sum_{i=1}^N (PW_{mea,i} - PW_{mea})^2} \quad (6)$$

เมื่อ $PW_{est,i}$ คือ น้ำในบรรยากาศจากการประมาณของข้อมูลที่ i $PW_{mea,i}$ คือ น้ำในบรรยากาศจากการวัดของข้อมูลที่ i PW_{mea} คือ ค่าเฉลี่ยน้ำในบรรยากาศจากการวัด และ N คือ จำนวนข้อมูลทั้งหมด

Results

ผลการวิเคราะห์ปริมาณน้ำในบรรยากาศ

ผลการวิเคราะห์ปริมาณน้ำในบรรยากาศเฉลี่ยรายเดือนระหว่างปี ค.ศ. 2008 – 2024 ที่ตรวจวัดโดยเครื่องชั้นโฟโตมิเตอร์ พบว่าศูนย์ฯ จ.เชียงใหม่ (CM) ศูนย์ฯ จ.อุบลราชธานี (UB) และศูนย์ฯ จ.สงขลา (SK) มีค่าอยู่ในช่วง 1.47 – 5.31 cm, 1.63 – 5.77 cm และ 3.27 – 5.55 cm ตามลำดับ โดยมีค่าเฉลี่ยตลอดทั้งปี (ปี ค.ศ. 2008 – 2024) มีค่า 3.63 cm, 4.29 cm และ 4.59 cm ตามลำดับ แสดงดัง Figure 5 นอกจากนี้ จาก Figure 5 ยังแสดงให้เห็นว่าปริมาณน้ำในบรรยากาศที่ตรวจวัดจากศูนย์ฯ จ.เชียงใหม่ และศูนย์ฯ จ.อุบลราชธานี มีค่าต่ำในช่วงฤดูหนาว (ต.ค. – ม.ค.) และฤดูร้อน (ก.พ. – เม.ย.) และมีค่าสูงในช่วงฤดูฝน (พ.ค. – ก.ย.) ขณะที่ปริมาณน้ำในบรรยากาศที่ตรวจวัดจากศูนย์ฯ จ.สงขลา มีค่าใกล้เคียงกันตลอดทั้งปี ผลดังกล่าวนี้แสดงให้เห็นว่าลักษณะภูมิประเทศส่งผลต่อปริมาณน้ำในบรรยากาศอย่างชัดเจน ดังนั้นการสร้างแบบจำลองเพื่อประมาณค่าปริมาณน้ำในบรรยากาศจึงมีความจำเพาะกับข้อมูลในพื้นที่นั้น ๆ

ผลการวิเคราะห์ความสัมพันธ์ระหว่างตัวแปร

ผลการวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรอินพุตกับตัวแปรเอาต์พุตและระหว่างตัวแปรอินพุตกับตัวแปรอินพุตด้วยสัมประสิทธิ์สหสัมพันธ์เพียร์สันสามารถแสดงได้ด้วยแผนภาพ Heatmap ดัง Figure 6 พบว่าศูนย์ฯ จ.เชียงใหม่ ศูนย์ฯ จ.อุบลราชธานี และศูนย์ฯ จ.สงขลา สัมประสิทธิ์สหสัมพันธ์เพียร์สันระหว่างตัวแปรอินพุตกับตัวแปรเอาต์พุตมีความสัมพันธ์เชิงบวก (Positive correlation) โดยมีค่าอยู่ในช่วง 0.36 – 0.64, 0.29 – 0.52 และ 0.17 – 0.44 ตามลำดับ ซึ่งค่าดังกล่าวแสดงให้เห็นว่าตัวแปรอินพุตกับตัวแปรเอาต์พุตมีความสัมพันธ์อยู่ในเกณฑ์ระดับต่ำ (Weak correlation) ถึงปานกลาง (Moderate correlation) (Schober *et al.*, 2018) นอกจากนี้เมื่อพิจารณาความสัมพันธ์ระหว่างความดันไอน้ำอิ่มตัวกับอุณหภูมิสิ่งแวดล้อมพบว่ามีค่าเท่ากับ 1 ทั้งนี้เนื่องจากความดันไอน้ำอิ่มตัวเป็นฟังก์ชันของอุณหภูมิสิ่งแวดล้อมซึ่งคำนวณจากสมการ (1)




Figure 5 Monthly average PW during 2008 to 2024




Figure 6 Heatmap of Pearson's correlation coefficient matrix

ผลการสร้างแบบจำลองโครงข่ายประสาทเทียม

ผลการสร้างแบบจำลองโครงข่ายประสาทเทียมโดยใช้เพอร์เซปตรอนแบบหลายชั้นและใช้การฝึกสอนแบบย้อนกลับเมื่อกำหนดให้แต่ละศูนย์ฯ มีจำนวนชั้นซ่อน 2 ชั้น และแปรค่าจำนวนโหนดในแต่ละชั้นซ่อนและจำนวนรอบที่ใช้ในการฝึกสอนพบว่าศูนย์ฯ จ.เชียงใหม่ ชั้นซ่อนที่ 1 และ 2 มีจำนวนโหนดเท่ากับ 8 และ 5 โหนด ตามลำดับ ขณะที่ศูนย์ฯ จ.อุบลราชธานี และศูนย์ฯ จ.สงขลา ชั้นซ่อนที่ 1 และ 2 มีจำนวนโหนดเท่ากับ 5 และ 2 โหนด ตามลำดับ (Figure 7) ซึ่งโครงสร้างโครงข่ายประสาทเทียมดังกล่าวนี้สามารถประมาณค่าปริมาณน้ำในบรรยากาศโดยมีความแม่นยำของแบบจำลองที่อธิบายได้ในรูปตัวแปรทางสถิติ พบว่าค่า MBE ศูนย์ฯ จ.เชียงใหม่ มีค่า -0.035 cm หรือ -0.89% ศูนย์ฯ จ.อุบลราชธานี มีค่า -0.056 cm หรือ -1.23% และศูนย์ฯ จ.สงขลา มีค่า 0.049 cm หรือ 1.04% ขณะที่ค่า RMSE ของแต่ละศูนย์ฯ ดังกล่าวมีค่า 0.028 cm (4.21%) 0.048 cm (4.85%) และ 0.062 cm (5.34%) ตามลำดับ และ R^2 มีค่า 0.98 0.95 และ 0.81 ตามลำดับ แสดงดัง Table 1 นอกจากนี้สามารถแสดงการเปรียบเทียบการประมาณค่าปริมาณน้ำในบรรยากาศจากแบบจำลองโครงข่ายประสาทเทียมและจากการวัดจริงได้ดัง Figure 8




Figure 7 ANN model structure of CM (left), UB (right), and SK (right) from WEKA

Table 1 MBE, RMSE, and R^2 for ANN model

Stations	Train	Test		$N_{h,i}^*$	Activation Function	MBE		RMSE		R^2
	(year)	(year)	n			(cm)	(%)	(cm)	(%)	
Buntoung <i>et al.</i> , (2021)										
Chiang Mai (CM)	5	2	24	4, 3	Sigmoid	0.074	1.98	0.29	7.75	0.96
Ubon Ratchathani (UB)	5	2	19	4, 3	Sigmoid	-0.146	-3.26	0.31	7.01	0.92
Songkhla (SK)	5	2	19	4, 3	Sigmoid	-0.003	-0.06	0.34	7.11	0.57
This study										
Chiang Mai (CM)	14	3	25	8, 5	Sigmoid	-0.035	-0.89	0.028	4.21	0.98
Ubon Ratchathani (UB)	14	3	19	5, 2	Sigmoid	-0.056	-1.23	0.048	4.85	0.95
Songkhla (SK)	14	3	18	5, 2	Sigmoid	0.049	1.04	0.062	5.34	0.81
All stations	-	-	62	-	-	-0.017	-0.39	0.044	4.83	0.95

* stands for the number of nodes in ith hidden layer

Discussion

ผลการวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรอินพุตกับตัวแปรเอาต์พุตพบว่าสัมประสิทธิ์สหสัมพันธ์เพียร์สันมีค่าอยู่ในช่วง 0.17 – 0.64 ซึ่งค่าดังกล่าวอยู่ในเกณฑ์ระดับความสัมพันธ์ต่ำถึงปานกลาง และเมื่อพิจารณาความสัมพันธ์ระหว่างตัวแปรอินพุตกับตัวแปรอินพุตพบว่ามีค่าสหสัมพันธ์ทั้งเชิงบวกและเชิงลบโดยมีค่าอยู่ในเกณฑ์ระดับต่ำถึงปานกลางเช่นเดียวกัน ซึ่งระดับความสัมพันธ์ดังกล่าวนี้เป็นหนึ่งในตัวแปรที่ส่งผลต่อความแม่นยำของแบบจำลอง

ผลการสร้างแบบจำลองโครงข่ายประสาทเทียมเพื่อประมาณค่าปริมาณน้ำในบรรยากาศเฉลี่ยรายเดือน พบว่าแบบจำลองที่มีระดับความแม่นยำสูงสุดและต่ำสุด คือ ศูนย์ฯ จ.เชียงใหม่ และศูนย์ฯ จ.สงขลา ตามลำดับ ซึ่งผลดังกล่าวสอดคล้องกับระดับความสัมพันธ์ระหว่างตัวแปรอินพุตกับตัวแปรเอาต์พุตที่อธิบายด้วยค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สัน (Figure 6) ดังนั้นความสัมพันธ์ระหว่างตัวแปรอินพุตกับตัวแปรเอาต์พุตจึงส่งผลต่อระดับความแม่นยำของแบบจำลอง เมื่อพิจารณาภาพรวมของค่า MBE RMSE และ R^2 พบว่ามีค่าเฉลี่ย -0.39% 4.83% และ 0.95 ตามลำดับ (Table 1) ค่าดังกล่าวแสดงให้เห็นว่าแบบจำลองสามารถประมาณค่าปริมาณน้ำในบรรยากาศเฉลี่ยรายเดือนได้ที่ระดับความแม่นยำค่อนข้างสูง เมื่อพิจารณาการประมาณค่าปริมาณน้ำในบรรยากาศด้วยแบบจำลองโครงข่ายประสาทเทียมจากการศึกษาของ Buntoung *et al.*, (2021) ซึ่งใช้กรณีศึกษาเดียวกัน กล่าวคือพื้นที่ศึกษาศูนย์ฯ จ.เชียงใหม่ ศูนย์ฯ จ.อุบลราชธานี และศูนย์ฯ จ.สงขลา โดยการศึกษาดังกล่าวตัวแปรอินพุตประกอบด้วยอุณหภูมิสิ่งแวดล้อมเฉลี่ยรายเดือน ความชื้นสัมพัทธ์เฉลี่ยรายเดือน ความดันไอน้ำอ้อมตัวเฉลี่ยรายเดือน และลำดับเดือนในรอบปี ใช้แบบจำลองโครงข่ายประสาทเทียมที่มีฟังก์ชันซิกมอยด์เป็นฟังก์ชันกระตุ้นและกำหนดจำนวนโนดในแต่ละชั้นซ่อนเท่ากัน พบว่าการประมาณค่าปริมาณน้ำในบรรยากาศด้วย

แบบจำลองโครงข่ายประสาทเทียมจากทั้ง 3 ศูนย์ฯ ดังกล่าว MBE มีค่า 0.074 cm -0.146 cm และ -0.003 cm ตามลำดับ RMSE มีค่า 0.29 cm 0.31 cm และ 0.34 cm ตามลำดับ และ R^2 มีค่า 0.96 0.92 และ 0.57 ตามลำดับ ดังแสดงใน Table 1 นอกจากนี้การศึกษาของ Phokate & Atyotha (2018) ซึ่งใช้แบบจำลองทางคณิตศาสตร์ประมาณค่าปริมาณน้ำในบรรยากาศกรณีศึกษา ศูนย์ฯ จ.เชียงใหม่ ศูนย์ฯ จ.อุบลราชธานี กรมอุตุนิยมวิทยา กรุงเทพฯ และศูนย์ฯ จ.สงขลา พบว่าแบบจำลองทางคณิตศาสตร์ดังกล่าวสามารถประมาณค่าปริมาณน้ำในบรรยากาศโดยมีค่า RMSE และ R^2 เท่ากับ 0.528 cm และ 0.851 ตามลำดับ ดังนั้นผลการศึกษานี้แสดงให้เห็นว่าแบบจำลองโครงข่ายประสาทเทียมที่โครงสร้างของแบบจำลองจำเพาะกับข้อมูลในแต่ละพื้นที่สามารถประมาณค่าปริมาณน้ำในบรรยากาศได้ที่ระดับความแม่นยำสูงกว่าเมื่อเทียบกับการศึกษาดังกล่าวข้างต้น




Figure 8 Comparison between monthly average PW from multilayer perceptron ANN model and the Sunphotometer

Conclusions

การศึกษาการประมาณค่าปริมาณน้ำในบรรยากาศจากข้อมูลอุตุนิยมวิทยาภาคพื้นระยะยาวโดยใช้แบบจำลองโครงข่ายประสาทเทียม กรณีศึกษา ศูนย์อุตุนิยมวิทยาภาคเหนือ จ.เชียงใหม่ ศูนย์อุตุนิยมวิทยาภาคตะวันออกเฉียงเหนือตอนล่าง จ.อุบลราชธานี และศูนย์อุตุนิยมวิทยาภาคใต้ฝั่งตะวันออก จ.สงขลา ใช้ข้อมูลอินพุตที่ประกอบด้วยอุณหภูมิสิ่งแวดล้อมเฉลี่ยรายเดือน ความชื้นสัมพัทธ์เฉลี่ยรายเดือน ความดันไอน้ำอิ่มตัวเฉลี่ยรายเดือน และลำดับเดือนในรอบปี ขณะที่ข้อมูลเอาต์พุต คือ ปริมาณน้ำในบรรยากาศ (ปริมาณน้ำในคอลัมน์บรรยากาศที่ถูกควบแน่นทั้งหมด) เฉลี่ยรายเดือน ผลการสร้างแบบจำลองโดยใช้ข้อมูลระหว่างปี ค.ศ. 2008 – 2021 และทดสอบแบบจำลองโดยใช้ข้อมูลระหว่างปี ค.ศ. 2022 – 2024 พบว่าแบบจำลองที่มีโครงสร้างเพอร์เซปตรอนแบบหลายชั้นและการฝึกสอนแบบย้อนกลับ สามารถประมาณค่าปริมาณน้ำในบรรยากาศที่มีระดับความแม่นยำที่อธิบายได้ในรูป MBE มีค่าอยู่ในช่วง $-1.23\% - 1.04\%$ RMSE มีค่าอยู่ในช่วง $4.21\% - 5.34\%$ และ R^2 มีค่าอยู่ในช่วง $0.81 - 0.98$ ตามลำดับ และเมื่อพิจารณาความแม่นยำของแบบจำลองในภาพรวม (ทั้ง 3 ศูนย์ฯ) พบว่า MBE มีค่า -0.017 cm หรือ -0.39% RMSE มีค่า 0.044 cm หรือ 4.83% และ R^2 มีค่า 0.95 ผลการศึกษาดังกล่าวแสดงให้เห็นว่าแบบจำลองที่มีโครงสร้างที่จำเพาะกับข้อมูลที่ใช้ในการสร้างแบบจำลองในแต่ละพื้นที่และใช้ข้อมูลในปริมาณที่เพิ่มมากขึ้นส่งผลให้แบบจำลองมีความแม่นยำค่อนข้างสูงเมื่อเปรียบเทียบกับการศึกษาอื่น ๆ ที่ใช้พื้นที่ศึกษาเดียวกัน ดังนั้นผลการศึกษานี้จึงสามารถนำไปใช้ในการประมาณค่าปริมาณน้ำในบรรยากาศได้

อย่างไรก็ตาม เพื่อให้แบบจำลองมีความถูกต้องแม่นยำในการประมาณค่าเพิ่มมากขึ้น ควรศึกษาวิธีการหรือแนวทางอื่น ๆ เพิ่มเติม เช่น ใช้ข้อมูลที่มีความต่อเนื่องและละเอียดมากขึ้น เพิ่มหรือเลือกตัวแปรอินพุตที่มีความสัมพันธ์กับตัวแปรเอาต์พุตในระดับที่สูงขึ้น แยกพิจารณาหรือสร้างแบบจำลองในแต่ละช่วงเวลา ฤดูกาล หรือรายปี ปรับหรือกำหนดค่าต่าง ๆ ในแบบจำลอง (แปรค่าจำนวนชั้นซ่อน แปรค่า Learning rate และ Momentum หรือใช้และเปรียบเทียบฟังก์ชันกระตุ้นอื่น ๆ) หรือใช้แบบจำลองอื่น ๆ ที่มีความซับซ้อนมากยิ่งขึ้น เป็นต้น ซึ่งแนวทางดังกล่าวนี้ถือว่าเป็นประเด็นที่มีความท้าทายศึกษาวิจัยในอนาคต

Acknowledgments

ขอขอบคุณภาควิชาชีพिल्ส คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากร และกรมอุตุนิยมวิทยา ที่ติดตั้ง และดูแลเครื่องมือวัด ตลอดจนอุปโหลดข้อมูลการตรวจวัดที่สามารถดาวน์โหลดได้ฟรี และขอขอบคุณกรมฝนหลวงและการบินเกษตรที่ส่งเสริมและสนับสนุนให้บุคลากรทำงานวิจัย

References

- Adeyemi, B. (2009). Empirical Formulations for Inter-Layer Precipitable Water Vapor in Nigeria. *Asia-Pacific Journal of Science and Technology*, 10(2), 35-45.

- Alduchov, O. A., & Eskridge, R. E. (1996). Improved Magnus form Approximation of Saturation Vapor Pressure. *Journal of Applied Meteorology*, 35(4), 601-609.
- Azadi, S., & Sepaskhah, A. R. (2012). Annual Precipitation Forecast for West, Southwest, and South Provinces of Iran using Artificial Neural Networks. *Theoretical and applied climatology*, 109, 175-189.
- Buntoung, S., Pariyothon, J., & Detkhon, P. (2021). Estimation of Atmospheric Precipitable Water in Thailand using an Artificial Neural Network. *Asian Health, Science and Technology Reports*, 29(2), 11-20.
- Buntoung, S. (2022). *Introduction to Atmospheric Physics (1st ed)*. Thailand: Silpakorn University. (in Thai)
- Frank, E., Hall, M. A., & Witten, I. H. (2016). *The WEKA Workbench - Data Mining: Practical Machine Learning Tools and Techniques*. UAS: Morgan Kaufmann.
- Du, Z., Yao, Y., Zhang, B., & Zhao, Q. (2024). Precipitable Water Vapor Estimation from Himawari-8/AHI Observations using a Stacking Machine Learning Model. *Atmospheric Research*, 301, 107281.
- Holben, B. N., Eck, T. F., Slutsker, I. A., Tanre, D., Buis, J. P., Setzer, A., Vermote, E., Reagan, J. A., Kaufman, Y. J., Nakajima, J., Lavenu, F., Jnnkowiak, I., & Smirnov, A. (1998). AERONET—A federated Instrument Network and Data Archive for Aerosol Characterization. *Remote sensing of environment*, 66(1), 1-16.
- Janjai, S. (2017). *Solar Radiation (2nd ed)*. Thailand: Phetkasem Printing Group. (in Thai)
- Kämpfer, N. (2013). *Monitoring Atmospheric Water Vapour, Ground-Based Remote Sensing and In-situ Methods*. USA: Springer.
- Kongara, V. S., & Punyasesudu, D. (2015). Forecasting the Water Vapour Distribution Over India using Artificial Neural Networks. *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, 3(4), 1-12.
- Kumar, A., Kumar, S., Pratap, V., & Singh, A. K. (2021). Performance of Water Vapour Retrieval from MODIS and ECMWF and Their Validation with Ground Based GPS Measurements over Varanasi. *Journal of Earth System Science*, 130, 1-11.

- Liu, J., Sun, Z., Liang, H., Xu, X., & Wu, P. (2005). Precipitable Water Vapor on the Tibetan Plateau Estimated by GPS, Water Vapor Radiometer, Radiosonde, and Numerical Weather Prediction Analysis and Its Impact on the Radiation Budget. *Journal of Geophysical Research: Atmospheres*, 110(D17).
- Moustris, K. P., Larissi, I. K., Nastos, P. T., & Paliatsos, A. G. (2011). Precipitation Forecast using Artificial Neural Networks in Specific Regions of Greece. *Water resources management*, 25, 1979-1993.
- Okulov, O., Ohvril, H., & Kivi, R. (2002). Atmospheric Precipitable Water in Estonia, 1990–2001. *Boreal Environment Research*, 7(3), 291.
- Patterson, D. W. (1998). *Artificial Neural Networks: Theory and Applications*. New York: Prentice Hall PTR.
- Phokate, S., & Atyotha, V. (2018). Determination of the Amount of Water Vapor in the Troposphere over Thailand using Surface Data. *Kasem Bundit Engineering Journal*, 8, 364-372.
- Senkal, O., Yildiz, B. Y., Sahin, M., & Pestemalcı, V. (2012). Precipitable Water Modelling using Artificial Neural Network in Cukurova Region. *Environmental Monitoring and Assessment*, 184, 141-147.
- Shanmuganathan, S. (2016). *Artificial Neural Network Modelling: An Introduction*. Switzerland: Springer International Publishing.
- Sharma, S., Sharma, S., & Athaiya, A. (2017). Activation Functions in Neural Networks. *Towards Data Science*, 6(12), 310-316.
- Schober, P., Boer, C., & Schwarte, L. A. (2018). Correlation Coefficients: Appropriate Use and Interpretation. *Anesthesia & analgesia*, 126(5), 1763-1768.
- Szandata, T. (2021). Review and Comparison of Commonly Used Activation Functions for Deep Neural Networks. *Bio-inspired Neurocomputing*, 203-224.
- Van Baelen, J., Aubagnac, J. P., & Dabas, A. (2005). Comparison of Near-Real Time Estimates of Integrated Water Vapor Derived with GPS, Radiosondes, and Microwave Radiometer. *Journal of Atmospheric and Oceanic Technology*, 22(2), 201-210.