



Long-term precipitation forecasting for Ilam city using a hybrid machine learning model

Navid Moradpoor¹ , Mohsen Najarchi² , and Mohammad Mirhosseini Hezave³

1. Department of Civil Engineering, Arak Branch, Islamic Azad University, Arak, Iran. Email: navid.moradpoor@gmail.com

2. Corresponding author, Department of Civil Engineering, Arak Branch, Islamic Azad University, Arak, Iran. Email: mohsennajarchi@yahoo.com

3. Department of Civil Engineering, Arak Branch, Islamic Azad University, Arak, Iran. Email: mo.mirhosseini@iau.ac.ir

Article Info

Article type: Research Article

Article history:

Received 29 November 2024

Received in revised form 31

January 2025

Accepted 18 April 2025

Available online 22 June 2025

Keywords:

machine learning,

long-term rainfall,

Ilam city,

ORELM,

activation function.

ABSTRACT

Objective: In this study, we seek to predict long-term precipitation in Ilam city using artificial intelligence algorithms.

Method: In this study, the long-term precipitation of Ilam city over a 44-year period from 1980 to 2024 is simulated by a hybrid machine learning model.

Ilam Province has a special topographic situation with uneven precipitation distribution due to its location at different latitudes. In this study, after collecting data, the average number of months of rainfall for each of the studied stations for a certain period is obtained. A machine learning model is used for prediction. In the first step, the observed data are normalized and the best normalization coefficients are obtained for this study. Approximately 70% of the observed data are used to train the artificial intelligence models and the remaining 30% are used to test them. Subsequently, the optimal number of hidden layer neurons along with the best activation function of the ORELM model are selected by implementing a trial and error process. In this study, the regularization parameter of the ORELM model is also optimized. Also, using the autocorrelation function (ACF), the effective lags of time series data are identified and using them, fourteen WORELM models are developed.

Results: According to the simulation results, the correlation coefficient (R) values for the ELM and ORELM models are obtained as 0.618 and 0.952, respectively. While the NSC values for ELM and ORELM are estimated as -1.137 and -1.138, respectively. In other words, the ORELM model shows more accuracy compared to the ELM model. In addition, the ORELM hybrid learning machine model is identified as the best model for simulating precipitation values in Ilam city.

Conclusions: The results of the ORELM hybrid model were compared with the ELM and ORELM artificial intelligence models, which showed that the ORELM hybrid model performed better.

Cite this article: Moradpoor, N., Najarchi, M., & Mirhosseini Hezave, M. (2025). Long-term precipitation forecasting for Ilam city using a hybrid machine learning model. *Advanced Technologies in Water Efficiency*, 5 (2), 116-133. <https://doi.org/10.22126/atwe.2025.11698.1153>



© The Author(s)

<https://doi.org/10.22126/atwe.2025.11698.1153>

Publisher: Razi University.

Introduction

Precipitation is the most important hydrological phenomenon, the increase or decrease of which during different periods can cause noticeable changes in the ecosystem of the region and population change. In recent years, due to climate change, the amount of precipitation in different regions of Iran has undergone significant changes. Therefore, estimating and modeling precipitation in this arid and semi-arid country is of great importance. The great importance of precipitation has led climatologists to seek methods to express the characteristics of precipitation. In this study, we seek to predict long-term precipitation in Ilam city using artificial intelligence algorithms.

Method

In this study, the long-term precipitation of Ilam city over a 44-year period from 1980 to 2024 is simulated by a hybrid machine learning model.

Ilam Province has a special topographic situation with uneven precipitation distribution due to its location at different latitudes. In this study, after collecting data, the average number of months of rainfall for each of the studied stations for a certain period is obtained. A machine learning model is used for prediction. In the first step, the observed data are normalized and the best normalization coefficients are obtained for this study. Approximately 70% of the observed data are used to train the artificial intelligence models and the remaining 30% are used to test them. Subsequently, the optimal number of hidden layer neurons along with the best activation function of the ORELM model are selected by implementing a trial and error process. In this study, the regularization parameter of the ORELM model is also optimized. Also, using the autocorrelation function (ACF), the effective lags of time series data are identified and using them, fourteen WORELM models are developed.

Extreme Learning Machine (ELM)

The ELM is an easy-to-implement machine learning algorithm. It is designed to overcome the weaknesses of traditional learning methods such as training-based algorithms based on exchange-oriented models. The algorithm consists of three layers: input, hidden, and output. The ELM is a learning method for training an artificial neural network (ANN) that randomly generates input weights (w) and bias (b).

Outlier Robust Extreme Learning Machine (ORELM)

In the precipitation modeling, peak values are of considerable importance and, given that the number of peak points is less than other points, they are known as outliers. In fact, outliers comprise a very small percentage of the training samples and generally the focus of modeling using the ELM will be on other samples.

Results

In this section of the present study, the performances of the extreme learning machine (ELM) and outlier robust extreme learning machine (ORELM) models are compared. The results of the comparison of the calculated statistical indices for the ELM and ORELM models are depicted in Figure 1.




Figure 1. Comparison between the performance of different machine models such as ELM and ORELM for estimating precipitation.

According to the simulation results, the correlation coefficient (R) values for the ELM and ORELM models are obtained as 0.618 and 0.952, respectively. While the NSC values for ELM and ORELM are estimated as -1.137 and -1.138, respectively.

The comparison between the performance of different machine learning models such as ELM and ORELM for estimating precipitation values can be seen in Figure 1.

Based on the modeling results, the combined models display better performance compared to simple models. In other words, the ORELM model shows more accuracy compared to the ELM model. In addition, the ORELM hybrid learning machine model is identified as the best model for simulating precipitation values in Ilam city.

Conclusions

In this study, a hybrid learning machine model was developed to simulate long-term precipitation values of Ilam city over a long-term period of 44 years from 1980 to 2024. To define the artificial intelligence model, the ELM model and the outlier robust extreme learning machine (ORELM) were combined. Initially, the time series data were divided into two groups: training (70%) and test (30). Subsequently, the observed data were normalized. This normalization was performed to facilitate the simulation of rainfall values by the artificial intelligence model. The examination of different activation functions showed that tribas was the best activation function for simulating precipitation values of Ilam city by this hybrid learning machine. ORELM 9 model was introduced as the superior model and the VAF, R and NSC values for it were 157.93, 0.965 and 0.925, respectively. Also, lags number (t-1), (t-2), (t-3) and (t-10) were identified as the most effective lags of the precipitation time series data of Ilam city. Finally, the results of the ORELM hybrid model were compared with the ELM and ORELM artificial intelligence models, which showed that the ORELM hybrid model performed better.

Author Contributions

All authors contributed equally to the conceptualization of the article and writing of the original and subsequent drafts.

Data Availability Statement

Data Availability Statement

Ethical Considerations

The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Funding

Not applicable.

Conflict of Interest

The authors declare no conflict of interest.



پیش‌بینی بارش درازمدت شهر ایلام با کاربرد مدل ترکیبی ماشین یادگیری

نوید مرادپور^۱، محسن نجارچی^۲، و محمد میرحسینی هزاوه^۳

۱. گروه مهندسی عمران، واحد اراک، دانشگاه آزاد اسلامی، اراک، ایران. رایانامه: navid.moradpoor@gmail.com

۲. نویسنده مسئول، گروه مهندسی عمران، واحد اراک، دانشگاه آزاد اسلامی، اراک، ایران. رایانامه: mohsen.najarchi@iau.ac.ir

۳. گروه مهندسی عمران، واحد اراک، دانشگاه آزاد اسلامی، اراک، ایران. رایانامه: mo.mirhosseini@iau.ac.ir

چکیده

اطلاعات مقاله

هدف: هدف از این پژوهش، پیش‌بینی بارش درازمدت شهر ایلام با کاربرد مدل ترکیبی ماشین یادگیری است.

نوع مقاله: مقاله پژوهشی

روش پژوهش: در این مطالعه، بارندگی درازمدت شهر ایلام در یک بازه زمانی ۴۴ ساله از ۱۹۸۰ تا ۲۰۲۴ توسط یک مدل ترکیبی ماشین یادگیری شبیه‌سازی گردید. استان ایلام از لحاظ قرارگیری در عرض‌های مختلف جغرافیایی، وضعیت توپوگرافی خاص دارای پراکندگی بارش ناموزونی است. در این تحقیق بعد از جمع‌آوری داده‌ها ابتدا میانگین تعداد ماه‌های بارش برای هر کدام از ایستگاه‌های مورد مطالعه برای یک دوره‌ی به دست آمد. جهت پیش‌بینی از مدل ماشین یادگیری استفاده گردید. در گام نخست داده‌های مشاهداتی نرمال‌سازی شدند و بهترین ضرایب نرمال‌سازی برای این مطالعه بدست آمدند. تقریباً ۷۰ درصد داده‌های مشاهداتی برای آموزش مدل‌های هوش مصنوعی و مابقی ۳۰٪ نیز جهت آزمون آنها به کار گرفته شدند. در ادامه، تعداد بهینه نرون‌های لایه مخفی به همراه بهترین تابع فعال‌سازی مدل ORELM با اجرای یک پروسه سعی و خطا انتخاب شدند. در این مطالعه، پارامتر منظم‌سازی (regularization parameter) مدل ORELM نیز بهینه‌سازی گردید. همچنین، با استفاده از تابع خودهمبستگی (ACF) تاخیرهای موثر داده‌های سری زمانی شناسایی شدند و با استفاده از این تاخیرها، چهارده مدل ORELM توسعه داده شدند.

تاریخ دریافت: ۱۴۰۳/۰۹/۰۹

تاریخ بازنگری: ۱۴۰۳/۱۱/۱۲

تاریخ پذیرش: ۱۴۰۴/۰۱/۲۹

تاریخ انتشار: ۱۴۰۴/۰۴/۰۱

کلیدواژه‌ها:

ماشین یادگیری،
بارش درازمدت،
شهر ایلام،
ORELM،
تابع فعال‌سازی.

یافته‌ها: بررسی توابع فعال‌سازی مختلف نشان داد که tribas بهترین تابع فعال‌سازی جهت شبیه‌سازی بارش‌های شهر ایلام توسط این ماشین یادگیری ترکیبی بود. مدل 9 ORELM به‌عنوان مدل برتر معرفی شد و مقادیر R ، VAF و NSC برای آن به ترتیب برابر با ۰/۹۶۵، ۰/۹۲۵ و ۰/۹۳۱ بودند. همچنین، تاخیرهای شماره (t-1)، (t-2)، (t-3) و (t-10) به‌عنوان مؤثرترین تاخیرهای داده‌های سری زمانی بارش شهر ایلام شناسایی شدند. در انتها نتایج مدل ترکیبی ORELM با مدل‌های هوش مصنوعی ELM و ORELM مقایسه گردید که مقایسه مذکور نشان دهنده عملکرد بهتر مدل ترکیبی ORELM بود.

نتیجه‌گیری: با تجزیه و تحلیل نتایج مدل‌های ده‌گانه ORELM، بهترین مدل به همراه مؤثرترین تاخیرهای داده‌های سری زمانی معرفی گردید. در انتها نتایج مدل ترکیبی ORELM با سایر ماشین‌های یادگیری نیز مقایسه شد که این مقایسه حاکی از عملکرد بهتر مدل ORELM بود.

استناد: مرادپور، نوید؛ نجارچی، محسن؛ و میرحسینی هزاوه، محمد. (۱۴۰۴). پیش‌بینی بارش درازمدت شهر ایلام با کاربرد مدل ترکیبی ماشین یادگیری. فناوری

های پیشرفته در بهره وری آب، ۵ (۲)، ۱۱۶-۱۳۳.

<http://doi.org/10.22126/atwe.2025.11698.1153>



© نویسندگان

شر: دانشگاه رازی.

مقدمه

تعیین الگوی توزیع زمانی بارش به منظور برآورد سیلاب، تعیین پتانسیل سیل خیزی رگبارها و همچنین طراحی سیستم زهکشی از اهمیت ویژه‌ای برخوردارند. طراحی بیشتر تأسیسات مهندسی نیازمند درک جامع و کامل از میزان نزولات جوی به اضافه توزیع زمانی آن‌ها هست. یکی از اصلی‌ترین عوامل مورد نیاز در تهیه مدل و توسعه هیدرولوژیکی حوضه‌های آبریز شناخت توزیع زمانی بارش هست. باتوجه به اینکه ایران در منطقه‌ای خشک واقع شده است، تغییرات زمانی بارش در آن بسیار زیاد است. باینکه میانگین بارش سالانه ایران حدود ۲۵۰ میلی‌متر است و کمتر از ۱/۳ متوسط بارش جهانی است؛ اما در سال‌های پربارش تا ۳۸۰ میلی‌متر هم بارش دریافت کرده و در مقابل در سال‌های کم‌بارش، بارش دریافتی کشور از ۱۵۵ میلی‌متر هم کمتر بوده است. این تغییرات نه تنها در دوره‌های زمانی بلند بلکه در فواصل زمانی کوتاه نیز دیده می‌شوند. بر اساس نتایج بسیاری از طبقه‌بندی‌های آب‌وهوایی، این سرزمین دارای آب‌وهوایی خشک و نیمه‌خشک هست. پایین بودن میزان ریزش‌های جوی، تغییرپذیری بالا و نوسانات شدید بارندگی از سالی به سال دیگر، از ویژگی‌های بارز آب‌وهوایی ایران به شمار می‌رود. علاوه بر ویژگی‌های بارز آب‌وهوایی ایران به شمار می‌رود. علاوه بر ویژگی‌های فوق، توزیع فضایی بارش در این سرزمین نیز، همگون بوده و از غرب به شرق و از شمال به جنوب از میزان آن کاسته می‌شود (باساک^۱، ۲۰۱۷). علاوه بر توزیع زمانی نایک‌نواخت بارش، تفاوت‌های مکانی آن در ایران نیز بسیار زیاد است. این تفاوت‌ها از یک سو به طبیعت رفتار مکانی بارش بازمی‌گردد که اساساً متغیری سرکش است و تغییرات مکانی شدیدی از خود نشان می‌دهد. از سوی دیگر، تنوع منشأ بارش در نقاط مختلف ایران سبب شده است تا در هر منطقه مقدار ریزش‌های جوی و زمان بارش متفاوت باشد. به‌ویژه در سال‌هایی که کشور از بارش کمتری برخوردار است. این تفاوت‌های مکانی شدیدتر می‌شوند. همچنین در سال‌های پر بارش تفاوت‌های مکانی بارش نقاط مختلف ایران کاهش می‌یابد. لازم به ذکر است که مدل‌سازی پدیده بارش در بازه‌های زمانی درازمدت قادر خواهد بود که دید جامع‌تری به محققین و مهندسین هیدرولوژی و محیط‌زیست جهت بررسی الگوهای بارشی ارائه دهد. در مقابل، مدل‌سازی پدیده بارندگی توسط الگوریتم‌های مختلف هوش مصنوعی روبه‌روز در حال گسترش است؛ زیرا این مدل‌ها بسیار منعطف بوده و توانایی شبیه‌سازی پدیده‌های پیچیده و غیرخطی را دارند. علاوه بر این، مدل‌های هوش مصنوعی دارای دقت مناسبی هستند و استفاده از آنها باعث صرفه‌جویی در زمان و هزینه‌های مربوط به مطالعات میدانی خواهد شد.

شناخت شرایط آب‌وهوایی و چگونگی عمل پارامترهای شاخ: هواشناسی مانند دما و بارندگی در یک مکان از عواملی هستند که تعیین‌کننده‌ی آب‌وهوای آن منطقه در درازمدت هستند. این پارامترهای مهم آب‌وهوایی از عوامل جوی هستند که تغییرات آن‌ها از روند خاصی پیروی نمی‌کند و عوامل زیادی از قبیل شرایط همدیدی، وضعیت توپوگرافی، دوری و نزدیکی به منابع آب، عرض جغرافیایی و غیره در تغییرات آن‌ها دخیل هست. استان ایلام از لحاظ قرارگیری در عرضه‌ای مختلف جغرافیایی، وضعیت توپوگرافی و پراکندگی کوهستان‌ها و برخورداری از سامانه‌های سینوپتیک مختلف با اثرگذاری‌های متفاوت در فصول مختلف سال دارای پراکندگی بارش ناموزونی است. به همین خاطر مطالعه ابعاد مختلف ناموزونی بارش و شناسایی تأثیر عوامل جغرافیایی بر میزان بارش در استان و همچنین تحلیل مکانی بارش با استفاده از سیستم اطلاعات جغرافیایی و روش پهنه‌بندی کریجینگ انگیزه اصلی انجام این تحقیق هست. این مطالعه از لحاظ کاربرد پراکندگی بارش در مناطق مختلف برای مدیریت محیط از اهمیت زیادی برخوردار است. باتوجه به نتایج کاربردی استفاده از بارش‌های ماهانه که به مواردی از آن‌ها اشاره شد، در این مطالعه سعی خواهد شد از روش‌های آماری ذکر شده که عبارت از مدل‌ها و روش‌های استفاده شده که عبارت شبکه عصبی مصنوعی است، استفاده گردد. الگوهای زمانی بارش ماهانه در سطح استان ایلام تجزیه و تحلیل گردد.

بنابراین، در این مطالعه، مقادیر بارندگی شهر ایلام در یک بازه زمانی ۴۴ ساله از سال ۱۹۸۰ تا ۲۰۲۴ توسط یک مدل هوش مصنوعی ترکیبی بهینه‌سازی شده، شبیه‌سازی خواهد شد. برای تولید مدل هوش مصنوعی ترکیبی که اختصاراً با ORELM نشان

داده می‌شود، از ماشین آموزش نیرومند خارج از محدوده (ORELM)، سپس با استفاده از تابع خودهمبستگی تاخیرهای مؤثر مربوط به داده‌های سری زمانی شناسایی خواهند شد. در ادامه، ۱۰ مدل ORELM توسط این تأخیرها تعریف می‌گردند. با تجزیه و تحلیل نتایج مدل‌سازی‌ها، مدل‌های برتر به همراه مؤثرترین تاخیرهای ورودی معرفی خواهند شد.

مبانی نظری و پیشینه پژوهش

تخمین و پیش‌بینی الگوی بارش در نواحی مختلف جهان به‌ویژه در نواحی خشک و نیمه‌خشک کره زمین مانند کشور ایران از اهمیت بسزایی برخوردار است. علاوه بر آن روش‌های عددی مختلف مانند روش‌های هوش مصنوعی به دلیل دقت و سرعت بالا توانایی شبیه‌سازی پدیده بارش و موضوعات مشابه را دارد. استفاده از این روش‌ها نقش بسزایی در صرفه‌جویی در زمان و هزینه‌ها در مطالعات میدانی و آزمایشگاهی دارد؛ بنابراین، روزبه‌روز به کاربرد و محبوبیت تکنیک‌های متنوع هوش مصنوعی برای تخمین و شبیه‌سازی مسائل متفاوت مهندسی و مسائل واقعی افزوده می‌شود (امیری و همکاران^۱، ۲۰۲۳؛ امان جلیلی و همکاران^۲، ۲۰۲۳؛ عزیزی و همکاران^۳، ۲۰۲۳؛ مزرعه و همکاران^۴، ۲۰۲۴؛ شعبانلو و همکاران^۵، ۲۰۱۸؛ و فلاحی و همکاران^۶، ۲۰۲۳).

مکسود و همکاران^۷ (۲۰۰۴) با استفاده از روش‌های مختلف شبکه عصبی مصنوعی و مدل‌های رگرسیونی مبادرت به مدل‌سازی پارامترهای مختلف آب‌وهوایی نمودند و بیان کردند که مدل‌های شبکه عصبی مصنوعی مقادیر تابع هدف را با دقت بیشتری در مقایسه با مدل‌های رگرسیونی تخمین زدند. علاوه بر این، رید و همکاران^۸ (۲۰۰۴) توسط شبکه عصبی مصنوعی مقادیر بارش و رواناب در یک حوضه واقع در کشور مراکش را تخمین زدند. آنها با مقایسه نتایج مدل عددی خود با روابط رگرسیونی نشان دادند که مدل‌های هوش مصنوعی دارای دقت بیشتری هستند.

ناصری و همکاران^۹ (۲۰۰۸) شبکه عصبی مصنوعی را برای شبیه‌سازی پارامترهای هواشنایی توسط الگوریتم ژنتیک بهینه‌سازی کردند. آنها این مدل بهینه‌سازی شده را برای تخمین میزان بارندگی واقع در یک حوزه در کشور استرالیا استفاده کردند. همچنین مکانیک و همکاران^{۱۰} (۲۰۱۳) میزان بارش درازمدت ۱۱۰ ساله در یک ناحیه واقع در جنوب استرالیا را با استفاده از رگرسیون خطی چندگانه و شبکه عصبی مصنوعی شبیه‌سازی نمودند. آنها با ارزیابی نتایج مدل‌های عددی مذکور نشان دادند که شبکه عصبی مصنوعی دارای دقت بیشتری بود.

میسلان و همکاران^{۱۱} (۲۰۱۵) به‌وسیله مدل شبکه عصبی مصنوعی پسخور مقدار بارندگی ماهانه در شرق کشور اندونزی را پیش‌بینی کردند. آنها برای کنترل مقدار خطای مدل عددی خود از خطای مربع میانگین بهره گرفتند.

شیانگ و همکاران^{۱۲} (۲۰۱۸) توسط روش تجزیه تجربی گروهی و الگوریتم‌های هوش مصنوعی از قبیل شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان مقادیر بارش در یکی از استان‌های کشور چین را در بازه‌های زمانی کوتاه و بلندمدت تخمین زدند. نشان داده شد که شبکه عصبی مصنوعی مقادیر بارش در بازه زمانی درازمدت با دقت بهتری شبیه‌سازی کرد.

آزاد و همکاران^{۱۳} (۲۰۱۹) عملکرد شبکه ANFIS را برای تخمین بارش شهر اصفهان به‌وسیله چند روش بهینه‌سازی از قبیل الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات و بهینه‌سازی کلونی مورچه بهبود بخشیدند. آنها بیان کردند که مدل ترکیبی ANFIS بهینه‌سازی کلونی مورچه در مقایسه با سایر مدل‌ها از دقت بیشتری برخوردار بود. همچنین، مهر و همکاران^{۱۴} (۲۰۱۹) یک مدل

1. Amiri et al
2. Aman Jalili et al
3. Azizi et al
4. Mazraeh et al
5. Shabanlou et al
6. Fallahi et al
7. Maqsood et al
8. Riad et al
9. Nasseri et al
10. Mekanik et al
11. Mislan et al
12. Xiang et al
13. Azad et al
14. Mehr et al

ترکیبی بهینه‌یافته را برای تخمین مقادیر بارش درازمدت شهر تبریز و ارومیه توسعه دادند. آنها برای بهینه‌سازی مدل هوش مصنوعی رگرسیون بردار پشتیبان از الگوریتم کرم شبتاب بهره گرفتند.

شیرعلی و همکاران^۱ (۲۰۲۰) مقادیر بارش کوتاه مدت درون حوزه کارون ۴ واقع در جنوب غربی ایران را توسط شبکه عصبی مصنوعی و ماشین بردار پشتیبان (SVM) شبیه‌سازی کردند. این نویسندگان نشان دادند که مدل هوش مصنوعی SVM از عملکرد بهتری در مقایسه با سایر مدل‌ها از خود نشان داد.

محمد و همکاران^۲ (۲۰۲۱) با استفاده از تکنیک‌های مختلف هوش مصنوعی مقادیر بارش درون یک حوزه واقع در کشور پاکستان را پیش‌بینی کردند. آنها مدل ویولت را با یک مدل شبکه عصبی مصنوعی ترکیب کردند و نشان دادند که مدل ترکیبی توانایی قابل‌قبولی جهت تخمین مقادیر تابع هدف از خود نشان داد.

روش پژوهش

روش پژوهش حاضر، تحلیلی و کاربردی است. به جهت گردآوری اطلاعات از طریق جمع‌آوری داده‌های موردنیاز منطقه مورد مطالعه شامل داده‌های بارش ایستگاه‌های موجود، مشخصات فیزیکی شهر ایلام، اطلاعات و مشخصات و تعداد بارش‌ها و همچنین با بررسی مدل‌های شبیه‌سازی بارش - رواناب جهت تعیین هیدروگراف سیلاب و انتخاب مدل مناسب. بررسی مدل‌های شبیه‌سازی هیدرولوژیکی و هیدرولیکی بارش‌های درازمدت جهت تعیین هیدروگراف روندیابی شده سیلاب در موقعیت پایین دست رودخانه و انتخاب مدل مناسب. بررسی مدل‌های پیش‌بینی (نظیر شبکه عصبی مصنوعی فراابتکاری) که قادر باشد بر مبنای هیدروگراف بارش‌های قبلی به‌عنوان ورودی مدل، هیدروگراف بارش‌های درازمدت را پیش‌بینی نماید.

در این قسمت چگونگی طراحی و کاربرد شبکه‌های عصبی مصنوعی برای پیش‌بینی بارش در مقیاس‌های زمانی ماهانه و بخشی، مورد بررسی قرار می‌گیرد.

۱. ماشین آموزش نیرومند (ELM)

ELM یک الگوریتم machine learning با پیاده‌سازی آسان است که نخستین بار توسط هووانگ و همکاران^۳ (۲۰۰۶) ارائه شده است. این روش برای غلبه بر ضعف‌های روش‌های یادگیری سنتی مانند الگوریتم‌های آموزش‌محور مبتنی بر تبادل گرایان به وجود آمده است. این الگوریتم شامل سه لایه ورودی، پنهان و خروجی است. ELM در واقع نوعی روش یادگیری برای آموزش شبکه عصبی مصنوعی (ANN) است که به طور تصادفی وزن‌های ورودی (w) و بایاس (b) را تولید می‌کند. همچنین در این روش وطن خروجی در فاز آموزش تنظیم می‌شود. تفاوت‌های اساسی بین ELM و classical ANN آموزش‌دیده با استفاده از الگوریتم‌های گرادینانی عبارت‌اند از: (۱) در ورش ELM این امکان وجود دارد که از توابع غیرخطی و kernel استفاده شود، (۲) ELM به پارامترهای بهینه‌سازی در الگوریتم‌های کلاسیک مانند momentum و learning rate، نیاز ندارد و (۳) در ELM به دلیل اینکه فقط وزن‌های خروجی نیاز به تنظیم دارند، نسبت به روش ANN سریع‌تر عمل می‌کنند (محمودیان و همکاران^۴، ۲۰۱۹؛ حسنی و شعبانلو^۵، ۲۰۲۰؛ و جلیلیان و همکاران^۶، ۲۰۲۲). (۴) تعمیم‌پذیری (generalizability) روش ELM نسبت به شبکه‌ها عصبی کلاسیک نیز بیشتر است (غریب و همکاران^۷، ۲۰۲۰؛ شفیعی و همکاران^۸، ۲۰۲۰؛ و پورسعید و همکاران^۹، ۲۰۲۲، ۲۰۲۴):

1. Shirali et al
2. Hammad et al
3. Huang et al
4. Mahmodian et al
5. Hasani & Shabanlou
6. Jalilian et al
7. Gharib et al
8. Shafee et al
9. Poursaeid et al

با در نظر گرفتن تعداد N نمونه مختلف برای یک مسئله با n ورودی $x_i \in \mathbb{R}$ و یک خروجی $y_i \in \mathbb{R}$ اگر تعداد نرون های لایه مخفی را برابر با L در نظر بگیریم، ساختار کلی الگوریتم ELM جهت ایجاد نگاشت غیرخطی بین ورودی های مسئله و خروجی مورد نظر، به صورت زیر تعریف می شود:

$$\sum_{i=1}^L \beta_i g(w_i \cdot x_j + b_i) = y_j, j=1, 2, \dots, N \quad (۱)$$


در این رابطه، β ماتریس وزن های خروجی است که وظیفه اتصال لایه پنهان به لایه خروجی را بر عهده دارد، $g(\cdot)$ به عنوان تابع فعال سازی در نظر گرفته می شود که انواع مختلفی مانند hard-limit, triangular basis, radial basis, sine, sigmoid, tangent hyperbolic دارد، w ماتریس وزن ورودی است که به صورت تصادفی مقداردهی می شود و وظیفه آن اتصال لایه ورودی به لایه پنهان است، x ورودی مسئله است، b ماتریس بایاس های لایه پنهان است که مشابه به w به صورت تصادفی مقداردهی می شود و y پارامتر هدف است. فرم فشرده رابطه فوق را می توان به شکل زیر بیان کرد (هوآنگ و همکاران، ۲۰۰۶). به طوری که شامل N معادله و N مجهول مختلف است و طی یک فرایند خطی به سادگی قابل حل است:

$$H\beta = y \quad (۲)$$

در رابطه فوق، y خروجی های مسئله است $y = [y_1, \dots, y_N]^T$ که شامل N نمونه مختلف است در حالیکه β به عنوان وزن خروجی $\beta = [\beta_1, \dots, \beta_L]^T$ دارای L نمونه مختلف است ($L = \text{number of hidden neurons}$). علاوه بر این دو پارامتر، پارامتر H است که به عنوان ماتریس خروجی لایه پنهان شناخته می شود و به طورت زیر تعریف می شود. قابل ذکر است که جهت محاسبه این ماتریس که علاوه بر ورودی های مسئله x ، دارای دو ورودی دیگر شامل w and b است که هر دو به صورت تصادفی مقداردهی می شوند. در واقع این ماتریس قبل از شروع فرایند آموزش در ELM، قابل محاسبه است:

$$H(w_1, \dots, w_L, x_1, \dots, x_N, b_1, \dots, b_L) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_L \cdot x_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_L \cdot x_N + b_L) \end{bmatrix}_{N \times L} \quad (۳)$$

یک نمونه از ساختار ارائه شده برای ELM با N ورودی مختلف و یک خروجی، در شکل (۱) ارائه شده است:



شکل ۱. ساختار مدل ELM

به دلیل عدم مربعی بودن ماتریس H ، حل رابطه (۲) جهت محاسبه β به سادگی صورت نمی پذیرد. از این رو، محاسبه least square وزن خروجی (رابطه (۵)) با استفاده از loss function ارائه شده در رابطه (۴)، ساده ترین راه حل در محاسبه β است (هوآنگ و همکاران، ۲۰۰۶):

$$E_1 = \min \|y - H\beta\| \quad (4)$$

$$\hat{\beta} = H^+ y \quad (5)$$

در رابطه فوق، H^+ برابر است با معکوس تعمیم یافته مور - پنروس^۱ ماتریس H .

باتوجه به اینکه جهت جلوگیری از overfitting در ELM، تعداد نرون های لایه مخفی (L) عموماً از تعداد نمونه های در نظر گرفته شده جهت آموزش مدل (N) کمتر است، حل رابطه فوق جهت محاسبه وزن خروجی (β) به شکل زیر است:

$$\hat{\beta} = (H^T H)^{-1} H^T y \quad (6)$$

۲. ماشین آموزش نیرومند خارج از محدوده (ORELM)

در مدل سازی بارش، پیش بینی مقادیر peak از اهمیت قابل توجهی برخوردار است و باتوجه به اینکه تعداد نقاط peak نسبت به سایر نقاط کمتر است، به عنوان outlier شناخته می شوند. در واقع، outliers درصد بسیار کمی از training samples را شامل می شوند و عموماً تمرکز مدل سازی با استفاده از ELM بر روی سایر نمونه ها خواهد بود. به منظور افزایش عملکرد مدل سازی با استفاده از ELM، با در نظر گرفتن sparsity در training error (e)، نسبت افزایش عملکرد مدل سازی مبتنی بر ELM اقدام می شود؛ بنابراین، loss function تعریف شده در ORELM نسبت به ELM به شکل زیر اصلاح می شود:

$$E_{ORELM} = C \min_{\beta} \|e\|_0 + \|\beta\|_2^2 \text{subjected to } y - H\beta = e \quad (7)$$

در رابطه فوق، C به عنوان regularization parameter شناخته می شود و از این رو، تنها مجهول رابطه، ماتریس وزن خروجی β است. به منظور گارانتی کردن sparsity features، در رابطه فوق به جای ℓ_1 -norm از ℓ_0 -norm استفاده می شود به طوری که نه تنها sparsity features را ایجاد و حل می کند بلکه overall minimization را نیز به همراه دارد.

$$E_{ORELM} = \min_{\beta} \|e\|_1 + \frac{1}{C} \|\beta\|_2^2 \text{subjected to } y - H\beta = e \quad (8)$$

این رابطه که یک constrained convex optimization problem را می توان به فرم augmented Lagrange multiplier (ALM) بازنویسی کرد (ژانگ و لوو، ۲۰۱۵):

$$L(\beta, e, \lambda) = \|e\|_1 + \frac{1}{C} \|\beta\|_2^2 + \lambda^T (y - H\beta - e) + \frac{\mu}{2} \|y - H\beta - e\|_2^2 \quad (9)$$

در رابطه فوق، $\lambda \in R^n$ Lagrange multiplier vector است و μ نیز پارامتر جریمه است که به صورت $\mu = 2N\|y\|_1$ در نظر گرفته می شود (یانگ و ژانگ، ۲۰۱۱). در رابطه فوق، دو پارامتر β ، e مجهول می باشند. حل این رابطه به صورت زیر است (ژانگ و لوو، ۲۰۱۵):

$$\beta_{k+1} = (H^T H + 2/C\mu I)^{-1} H^T (y - e_k + \lambda_k/\mu) \quad (10)$$

$$\begin{aligned} e_{k+1} &= \text{shrink}(y - H\beta_{k+1} + \lambda_k/\mu, 1/\mu) \\ &\cong \max\{|y - H\beta_{k+1} + \lambda_k/\mu| - 1/\mu, 0\} \circ \text{sign}(y - H\beta_{k+1} + \lambda_k/\mu) \end{aligned} \quad (11)$$

۳. نکویی برازش

در این مطالعه، جهت ارزیابی عملکرد مدل های هوش مصنوعی استفاده شده در این پژوهش از شاخص های آماری ضریب همبستگی (R)، شاخص عملکرد (VAF)، خطای نسبی مطلق میانگین (MARE) و ضریب بهره وری نش ساتکلیف (NSC) استفاده شد (شعبانلو^۱، ۲۰۱۸؛ زارعی و همکاران، ۲۰۲۰؛ و مقدم و همکاران، ۲۰۲۲):

$$R = \frac{\sum_{i=1}^n (F_i - \bar{F})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (F_i - \bar{F})^2 \sum_{i=1}^n (O_i - \bar{O})^2}} \quad (12)$$

$$VAF = \left(1 - \frac{\text{var}(F_i - O_i)}{\text{var}(F_i)}\right) \times 100 \quad (13)$$

$$MARE = \frac{1}{n} \sum_{i=1}^n \left| \frac{F_i - O_i}{O_i} \right| \quad (14)$$

$$NSC = 1 - \frac{\sum_{i=1}^n (O_i - F_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (15)$$

در اینجا O_i مقادیر بارندگی یا رواناب مشاهداتی، F_i مقادیر مدل سازی شده، $\bar{O}$ میانگین مقادیر مشاهداتی و n برابر تعداد مقادیر مشاهداتی است. در بخش های بعدی به بررسی عملکرد مدل های هوش مصنوعی جهت شبیه سازی مقادیر بارش شهر ایلام پرداخته می شود. در این مطالعه، داده های سری زمانی بارش شهر ایلام در یک بازه ۴۴ ساله از ۱۹۸۰ تا ۲۰۲۴ جهت آموزش و آزمون ماشین های یادگیری WORELM استفاده می شوند. داده های مذکور به دو دسته آموزش (۷۰٪ کل داده ها) و آزمون (۳۰٪ باقیمانده) تقسیم می شوند. نتایج مهم پژوهش حاضر در بخش های بعدی ارائه خواهند شد.

۴. منطقه مطالعاتی

استان ایلام با وسعتی بالغ بر ۱۹۰۴۵ کیلومتر مربع در غرب کشور که از شمال به استان کرمانشاه، از شرق و جنوب شرقی به ترتیب با استانهای لرستان و خوزستان و از سمت غرب با کشور عراق همسایه است. استان ایلام دارای هفت شهرستان به نامهای: ایلام، مهران، دهلران، ایوان، آبدانان، دره شهر و سرابله است. این استان با متوسط بارندگی سالیانه ۴۲۷ میلیمتر و باتوجه به ویژگیهای زمین شناسی و توپوگرافی خاص از منابع آب سطحی و زیر زمینی قابل توجهی برخوردار است. نظر به شرایط ویژه استان از جمله وجود ارتفاعات کبیرکوه از سلسله جبال زاگرس پهنه استان ایلام از دو شرایط خاص آب و هوایی برخوردار است: قسمت جنوبی و غربی این رشته کوه شامل دشتهای پست با حداقل ارتفاع حدود ۶۰ متر از سطح دریا دارای شرایط آب و هوایی خشک و با حداکثر دمای بیش از ۵۲ درجه سانتی گراد و در ناحیه شمالی استان آب و هوایی معتدل حکمفرماست. متوسط تبخیر از سطح طشتک تبخیر ۲۵۶۷ میلیمتر در سال، متوسط تبخیر پتانسیل ۲۰۶۰۸ میلیمتر در سال و متوسط تبخیر واقعی ۱۴۴۲۶ میلیمتر در سال است. استان ایلام از نظر تقسیم بندی هیدرولوژیک و باتوجه به نقشه توپوگرافی و شبکه هیدروگرافی رودخانه ها و حوزه های آبریز به دو حوزه تقسیم می شود: حوزه های آبریز رودخانه های مرزی و حوزه های آبریز کرخه، رودخانه های حوزه مرزی اکثرآ از جنوب کبیر کوه سرچشمه گرفته و پس از مشروب نمودن دشتهای واقع در پایین دست حوزه های آبریز از مرز خارج شده و به طرف کشور عراق جریان پیدامی کنند. مهمترین این رودخانه ها از جنوب به شمال به ترتیب عبارتند از: دویرج، میمه، چنگوله، گاوی، کنجانچم، شور شیرین، گذار خوش، تلخاب و کنگیر. علاوه بر این رودخانه ها، مسیل های مهمی مانند: چخاب، فسیل، نصریان وجود دارد. رودخانه حوزه آبریز کرخه عبارتند از: سیمره، مولاب، سیاه گاو، ماژین، دره شهر، سیکان، کلم، شیروان، زنگوان، چناره و جزمان. که بر روی رودخانه های ذکر شده ۲۶ ایستگاه هیدرومتری درجه دو و یک وجود دارد.

۵. مقادیر واقعی بارندگی باران

برای این منظور ابتدا با استفاده از رگرسیون چندمتغیره به برآورد ضرایب رگرسیونی پرداختیم و مانند قبل داده‌های جمع‌آوری شده در مدت سال‌های ۱۳۹۵-۱۴۱۰ را به عنوان متغیرهای مستقل در نظر می‌گیریم. آنگاه ۴ سال آتی را با استفاده از معادله به دست آمده برای این مدل پیش‌بینی می‌کنیم. معادله و ضرایب رگرسیونی برای این برازش به صورت زیر است:

$$Y=X.B \quad (۱۶)$$

جدول ۱. جدول ضرایب رگرسیونی

B1	B2	B3	B4
-31558.0	-054.0	-94331.0	-71041.0
422623.0	505038.0	383514.0	-3739.0
-37819.0	-70144.0	-74118.0	117652.0
-0703.0	361226.0	-85264.0	032537.0
0	-1352.0	419.1.0	308962.0
-24496.0	-1372.0	-57508.0	-10597.0
-17474.0	0	0	-7073.0
35212.0	-17881.0	512987.0	731307.0
0	315068.0	026606.0	0

۷ سال را با استفاده از داده‌های در اختیار پیش‌بینی کردیم که نشان از برازش نامناسب است، زیرا اطلاعات به دست آمده مقادیر منفی هستند و هر چه به سال‌های بیشتری را پیش‌بینی کنیم داده‌های ما نامناسب می‌شود که متناقض با مقادیر بارندگی است. این مقادیر در جدول (۲) آورده شده است.

جدول ۲. مقادیر بارندگی برازش داده شده برای ۷ سال از سال ۱۳۹۴ الی ۱۴۰۰ بر حسب mm


سال و ماه	2016	2017	2018	2019	2020	2021	2022
April	11.67	-66.73	40.92	72.64	38.80	47.59	28.69
May	14.04	9.88	-6.42	42.18	27.99	6.16	21.87
June	-6.24	-21.65	26.30	20.71	13.45	-19.27	-18.06
July	4.88	-11.62	1.24	7.32	-1.66	12.20	2.70
August	-5.69	0.60	2.13	1.40	2.02	-9.98	-9.26
September	0.36	1.44	-5.62	-8.57	-1.33	11.97	5.31
October	0.81	6.21	28.05	0.21	1.84	-21.83	-10.63
November	8.83	25.40	-2.54	8.44	12.51	9.50	14.90
December	2.76	5.44	56.41	43.07	456	-6.50	4.99
January	11.78	0.85	2.47	16.90	7.15	-0.72	20.87
February	32.30	67.22	-33.72	-6.78	7.06	7.73	38.27
March	30.61	3.06	24.89	41.95	29.27	-13.80	22.80

۶. پیش‌بینی بارش ماهانه ایلام


برای پیش‌بینی بارش ماهانه و بخشی در این قسمت از پروژه، اطلاعات ایستگاه‌ها برای پیش‌بینی بارش ماهانه و برای پیش‌بینی بارش بخشی، تهیه گردید. هر فایل شامل، ۴۱۷ الگو است که از بین ۴۷۵ الگوی اول، هر ۱۴ الگو به یک ایستگاه و از الگوی ۵۷۵ تا ۴۱۷ هر ۱۰ الگو به یک ایستگاه تعلق دارد. هر ۱۴ الگو، بارش ماهانه یا بخشی ایستگاه‌ها را طی سال‌های ۱۹۶۰ تا ۲۰۰۰ و هر ۱۰ الگو بارش ماهانه یا بخشی ایستگاه‌ها، طی سال‌های ۲۰۰۱ تا ۲۰۱۰ را پیش‌بینی می‌کنند. از کل ۴۱۷ الگو ۸۰ درصد آن‌ها که شامل، ۴۷۵ الگو است و بارش ماهانه یا بخشی طی سال‌های ۱۹۶۰ تا ۲۰۰۰ را پیش‌بینی می‌کنند به‌عنوان الگوهای آموزش و ۲۰ درصد باقی‌مانده، یعنی ۴۰ الگو آخر که بارش ماهانه یا بخشی را طی سال‌های ۲۰۰۱ تا ۲۰۱۰ را پیش‌بینی می‌کنند، به‌عنوان الگوهای آزمون در نظر گرفته شدند. برای اختصاص مقادیر اولیه‌ی وزن اتصالات و بایاس نورون‌ها از تابع وزن تصادفی که در این حالت مقادیر تصادفی وزن‌ها را بین ± 1 و مقادیر اولیه‌ی نورون‌ها را صفر انتخاب می‌کند، استفاده شده است و از میان روش‌هایی که سریع‌تر به همگرایی می‌رسند و دقت بالاتری دارند، الگوریتم لوبنبرگ - مارکوارت^۱، برای انجام کار برگزیده شد. برای انتخاب تابع تحریک یا همان تابع انتقال یا تابع فعالیت، چون در روش پس انتشار، این توابع باید مشتق‌پذیر باشند و از طرفی خروجی‌های شبکه بین صفر و یک یا ۱- و ۱+ محدود هستند، توابع محدود، مثل تابع لجستیک یا تانژانت هایپربولیک که مانع از این می‌شوند تا وزن‌ها مقادیر خیلی بزرگ به خود بگیرند، ارجح‌ترند. از این‌رو با توجه به پیش‌پردازشی که روی داده‌ها برای ورود به شبکه (طبق رابطه‌ی (۱)) انجام گرفت، برای تابع انتقال بین لایه‌ی ورودی و لایه‌ی میانی، تابع تانژانت هایپربولیک و برای لایه‌ی میانی و لایه‌ی خروجی، تابع خطی به‌عنوان مناسب‌ترین توابع انتقال، انتخاب گردید. برای تمامی فایل‌های ماه‌های اکتبر تا مارس و فصول پاییز و زمستان، هشت پارامتر که همان تعداد نورون‌های ورودی در لایه‌ی اول را تشکیل می‌دهند و بارش ماهانه و بخشی به‌عنوان تنها نورون در لایه‌ی خروجی ثابت است. تعداد بهینه‌ی نورون‌ها در لایه‌های میانی (مخفی) باید به‌گونه‌ای انتخاب شوند که منجر به کمترین خطای داده‌های آموزش گردد. تعداد نورون‌های لایه‌ی میانی پس از سعی و خطای فراوان، پنج نورون در نظر گرفته شد. بنابراین با مدل ۱ - ۵ - ۸ در طی فرایند آموزش در شبکه‌ی عصبی، ساختاری از شبکه که مقدار مجموع مربعات خطا روی داده‌های آموزش در آن به پایین‌ترین مقدار ممکن خود برسد، ساختار بهینه و وزن‌های متناظر با آن به‌عنوان مقدار بهینه‌ی وزن‌ها در نظر گرفته شدند. در فرایند آموزش، مقدار خروجی محاسبه شده توسط شبکه با مقدار خروجی هدف که در مجموعه داده‌های آموزش تعریف شده، مقایسه و مجموع مربعات خطا روی کل الگوهای آموزشی برای نورون‌ها در لایه‌ی خروجی شبکه، محاسبه شده است. برای محاسبه‌ی مجموع مربعات خطا از رابطه‌ی (۱۷)، استفاده می‌شود.

$$SSE = \sum_{p=1}^N (t_p - Z_p)^2 \quad (17)$$

که در آن t_p و Z_p به ترتیب خروجی موردنظر و خروجی محاسبه شده‌ی واقعی برای الگوی p است. پس از به‌دست آوردن خروجی‌های شبکه و بازگرداندن آن‌ها از مقادیر بین ۱- و ۱ به مقادیر واقعی، به‌منظور ارزیابی عملکرد شبکه‌ی عصبی، از سه شاخص زیر کمک گرفته شد که این شاخص‌ها برای تمامی قسمت‌های پیش‌بینی بارش، مورد استفاده واقع شده و طبق روابط زیر محاسبه گردیده است. برای بررسی اثر پارامترهای موردبررسی بر بارش ماهانه و بخشی نمودارهای ضریب همبستگی آن‌ها در ادامه ارائه می‌شود. در تمام نمودارهای موجود در شکل‌های این بخش dew، برای دمای نقطه‌ی شبنم و شماره‌های ۱ و ۲ برای بارش سالانه‌ی یک و دو سال قبل، بکار برده شده است.



شکل ۲. نمودار ضرایب همبستگی پارامترها با بارش ماهانه ایلام



شکل ۳. نمودار ضرایب همبستگی پارامترها با بارش ماهانه و فصلی ایلام

با توجه شکل های (۲) و (۳) می توان تأثیر پارامترهای مورد بررسی بر بارش ماهانه را به شرح ذیل بیان کرد. شاخص *SOI* سه ماه قبل، در طی ماه های اکتبر تا مارس، به تدریج با کاهش ضریب همبستگی همراه بوده و بیشترین تأثیر را بر بارش ماه های اکتبر و نوامبر دارد. تأثیر دمای نقطه ی شبنم سه ماه قبل بر بارش ماهانه، در طی ماه های اکتبر و نوامبر بسیار ناچیز بوده و به جز در ماه فوریه بر بارش ماه های دسامبر، ژانویه و مارس، تأثیر نسبتاً خوبی داشته است. بارش ماه های مورد بررسی طی یک تا سه سال قبل به جز برای ماه های اکتبر و نوامبر، بر بارش ماه های دیگر به خصوص مارس، تأثیر خوبی داشته و بارش سالانه به جز برای ماه های ژانویه و تا حدودی اکتبر بر بارش ماه های دیگر به خصوص ماه مارس، تأثیر بسزایی داشته است و آخرین پارامتر یعنی میانگین رطوبت نسبی برای ماه مارس بیشترین تأثیر را داشته است و برای ماه های اکتبر و نوامبر با ضریب بسیار پایین تأثیر چندانی ندارد. بر طبق شکل (۵)، تأثیر پارامترها بر بارش بخشی را می توان به شرح ذیل به آن ها اشاره کرد. از میان پارامترها، بارش سالانه بیشترین تأثیر را به خصوص بر بارش بخش زمستان داشته و از لحاظ تأثیرگذاری در مرتبه ی بعد، شاخص *SOI* سه ماه قبل، برای بارش بخش پاییز و شاخص *NINO3,4* سه ماه قبل، برای بارش بخش زمستان قرار می گیرند. از بین دو پارامتر دیگر، میانگین دمای نقطه ی شبنم و میانگین رطوبت نسبی سه ماه قبل از شروع بارش بخشی، بر بارش بخش زمستان، تأثیر نسبتاً خوبی داشته اند، ولی این دو پارامتر برای بارش بخش پاییز با ضریب همبستگی بسیار ناچیزی همراه هستند. در تمامی بخش های این پروژه، به منظور بررسی بهتر نتایج حاصل از خروجی مدل ها، برای پیش بینی بارش ماهانه و بخشی، سعی شده پارامترهایی که به طور میانگین در تمامی فایل ها ضرایب همبستگی بالاتری دارند، به عنوان ورودی انتخاب شوند.

یافته‌های پژوهش

پس از اجرای مدل برای تمامی فایل‌های مربوط به ایلام، بهترین نتایج برای شش ماه و دو بخش در جدول (۳) آورده شده است.

جدول ۳. نتایج به‌دست‌آمده از مدل برای بارش ماهانه و بخشی ایلام

اکتبر	مدل	Sse train	Sse test	Rmse train	Rmse test	Cor train	Cor test	بایاس آموزش	بایاس آزمون
اکتبر	8-5-1	5.01	0.76	13.79	13.5	0.71	0.71	-1.52	-1.12
نوامبر	8-5-1	4.18	1.2	25.18	21.18	0.7	0.7	-1.63	-1.14
دسامبر	8-5-1	4.64	2.05	27.07	22	0.76	0.7	-2.46	-1.29
ژانویه	8-5-1	5.72	3.05	20.5	18	0.79	0.71	-2.01	-1.88
فوریه	8-5-1	6.4	1.98	25.2	22.6	0.7	0.71	-2.64	-1.37
مارس	8-5-1	5.5	1.9	21	18	0.81	0.7	-4.81	-4.61
پاییز	8-5-1	4.71	1.33	12.83	10	0.76	0.7	-1.02	-0.66
زمستان	8-5-1	6.25	1.68	17.03	16	0.7	0.7	-2.37	-1.92

جدول ۴. نتایج به‌دست‌آمده از مدل برای بارش ماهانه ایلام

اکتبر	میانۀ واقعی (آموزش)	میانۀ پیش بینی (آموزش)	میانۀ واقعی (آزمون)	میانۀ پیش بینی (آزمون)	انحراف معیار واقعی (آموزش)	انحراف معیار پیش بینی (آموزش)	انحراف معیار واقعی (آزمون)	انحراف معیار پیش بینی (آزمون)
اکتبر	0.40	5.05	0.1	3.2	19.55	14.21	14.69	11.04
نوامبر	7	14	10.45	39.3	31	17.7	23.47	14.15
دسامبر	20.3	28	28.7	28.8	36.02	23.28	39.49	22.4
ژانویه	17.1	20.4	22.9	23.1	33.15	26.37	34.24	31.96
فوریه	22.65	21.05	21.8	25.85	32	21	22.48	18.55
مارس	25.95	22.95	13.3	10.2	36.02	30.94	28.18	19.89
پاییز	14.9	16.75	15.8	19.45	19.97	16.10	17.97	10.22
زمستان	32.2	30.9	25.3	28.7	24.26	17.03	19.7	12.35


در جدول‌های (۳) و (۴)، مجموع مربعات خطا (SSE)، ریشه‌ی میانگین مربعی خطاها ($RMSE$)، ضرایب همبستگی ($CORR$) و بایاس، برای مراحل آموزش و آزمون و همچنین، میانۀ و انحراف معیار برای مقادیر واقعی و پیش‌بینی‌شده در مراحل آموزش و آزمون، آورده شده است و از آنجایی‌که نتایج مربوط به آزمون‌ها برای ما اهمیت بیشتری دارند. نزدیکی تقریبی مقادیر میانۀ و انحراف معیار برای مقادیر واقعی و پیش‌بینی‌شده و ضرایب همبستگی بالای ۷۰ درصد، حاکی از کارایی نسبتاً خوب مدل دارد بااین‌حال، مقادیر ریشه‌ی میانگین مربعی خطاها بالاست.

۱. نرمال سازی

جهت سهولت کار با مقادیر مشاهداتی، این داده ها نرمالایز شدند. برای نرمال سازی مقادیر بارندگی های مشاهداتی از رابطه زیر استفاده گردید:


$$x_n = a[(x - x_{\min}) / (x_{\max} - x_{\min})] + b \quad (18)$$

در اینجا، x_n مقدار نرمال شده، x مقدار مشاهداتی، $x_{\min}$ حداقل مقدار مشاهداتی، $x_{\max}$ حداکثر مقدار مشاهداتی، a و b نیز مقادیر ثابت هستند. در این مطالعه، برای مقادیر a و b سه مقدار مختلف از قبیل $a=1, b=0$ ، $a=2, b=-1$ و $a=0.6, b=0.2$ انتخاب شد و نتایج شبیه سازی برای شرایط بدون نرمال سازی نیز مورد ارزیابی قرار گرفت. نتایج شاخص های آماری محاسبه شده برای ضرایب نرمال سازی مختلف در قالب شکل (۳) قابل مشاهده است. بر اساس نتایج شبیه سازی ها، عملکرد مدل ماشین یادگیری در وضعیتی که ضرایب نرمال سازی مساوی با $a=1, b=0$ بدست آمد. به عنوان مثال، مقادیر R ، VAF و NSC برای مدل هوش مصنوعی در حالتی که ضرایب نرمال سازی مساوی با $a=1, b=0$ بود به ترتیب برابر با $۰/۹۶۵$ ، $۹۳/۱۵۷$ و $۰/۹۲۵$ محاسبه شدند.



شکل ۴. نتایج شاخص های آماری محاسبه شده برای ضرایب نرمال سازی مختلف


در شکل (۵) نیز مقادیر بارش های شبیه سازی شده برای ضرایب نرمال سازی مساوی با $a=1, b=0$ و مقادیر مشاهداتی با هم مقایسه شده است. همان طور که مشاهده می شود، مدل ماشین یادگیری استفاده شده در مطالعه حاضر توانست مقادیر بارش ها را در این وضعیت بادقت مناسبی تخمین بزند.



شکل ۵. مقایسه مقادیر بارش های شبیه سازی شده برای ضرایب نرمال سازی مساوی با $a=1, b=0$ و مقادیر مشاهداتی


۲. تابع فعال سازی

در این مطالعه، شش تابع فعال سازی مختلف از قبیل $\text{tangent hyperbolic (Tanh)}$ ، $\text{triangular basis (tribas)}$ ، sigmoid (sig) ، $\text{radial basis (radbas)}$ و sinusoidal (sin) استفاده شد. نتایج شاخص های آماری محاسبه شده برای این شش تابع فعال سازی در شکل (۶) قابل مشاهده است. همان طور که دیده می شود، تابع فعال سازی tribas دارای کمترین مقدار خطا و بیشترین دقت با مقادیر مشاهداتی بود. برای تابع فعال سازی tribas مقادیر NSC ، VAF و MARE به ترتیب برابر با $۰/۹۴۲$ ، $۹۴/۸۱۷$ و $۷/۳۱۱$ بدست آمدند؛ بنابراین، در ادامه برای شبیه سازی مقادیر بارندگی های شهر ایلام از تابع فعال سازی tribas استفاده گردید.



شکل ۶. نتایج شاخص های آماری محاسبه شده برای توابع فعال سازی مختلف

در شکل (۷) نیز نتایج بارش های شبیه سازی شده توسط تابع فعال سازی tribas با مقادیر مشاهداتی مقایسه شده است.




شکل ۷. مقایسه نتایج بارش های شبیه سازی شده توسط تابع فعال سازی tribas با مقادیر مشاهداتی

۳. مقایسه الگوریتم ها

در این قسمت از مطالعه حاضر، به مقایسه عملکرد مدل های $\text{extreme learning machine (ELM)}$ ، outlier robust ، $\text{extreme learning machine (ORELM)}$ و ELM پرداخته می شود. نتایج مقایسه شاخص های آماری محاسبه شده برای مدل های ORELM و ELM در شکل (۸) به تصویر کشیده شده است. با توجه به نتایج شبیه سازی ها، مقدار ضریب همبستگی (R) برای مدل های ELM و ORELM به ترتیب مساوی با $۰/۶۱۸$ و $۰/۹۵۲$ بدست آمدند. این در حالی است که مقدار NSC برای ELM و ORELM به ترتیب برابر با $-۱/۱۳۷$ و $-۱/۱۳۸$ تخمین زده شدند.

مقایسه بین عملکرد مدل های ماشین یادگیری مختلف از قبیل ELM و ORELM جهت تخمین مقادیر بارش ها در شکل (۸) قابل مشاهده است. بر اساس نتایج مدل سازی ها، مدل های ترکیبی عملکرد بهتری در مقایسه با مدل های ساده از خود نشان دادند. به عبارت دیگر مدل ORELM دقت بیشتری در مقایسه با مدل ELM از خود نشان داد. علاوه بر این، مدل ماشین یادگیری ترکیبی ORELM بهترین مدل جهت شبیه سازی مقادیر بارش های شهر ایلام شناسایی گردید.



شکل ۸. مقایسه بین عملکرد مدل های ماشین یادگیری مختلف از قبیل ELM و ORELM جهت تخمین مقادیر بارش ها

بحث

در این مطالعه، جهت شبیه سازی مقادیر بارندگی های درازمدت شهر ایلام در یک بازه زمانی درازمدت ۴۴ ساله از ۱۹۸۰ تا ۲۰۲۴، یک مدل ماشین یادگیری ترکیبی توسعه داده شد. برای تعریف مدل هوش مصنوعی، مدل ELM و ماشین یادگیری Outlier robust extreme learning machine (ORELM) با همدیگر ترکیب شدند. در ابتدا داده های سری زمانی به دو دسته آموزش (۷۰ درصد) و آزمون (۳۰) تقسیم شدند. در ادامه، داده های مشاهداتی نرمال سازی شدند. این نرمال سازی جهت سهولت شبیه سازی مقادیر بارش ها توسط مدل هوش مصنوعی اجرا گردید.

نتیجه گیری

بررسی توابع فعال سازی مختلف نشان داد که tribas بهترین تابع فعال سازی جهت شبیه سازی بارش های شهر ایلام توسط این ماشین یادگیری ترکیبی بود. مدل 9 ORELM به عنوان مدل برتر معرفی شد و مقادیر R ، VAF و NSC برای آن به ترتیب برابر با ۹۳/۱۵۷، ۰/۹۶۵ و ۰/۹۲۵ بودند. همچنین، تاخیرهای شماره (t-1)، (t-2)، (t-3) و (t-10) به عنوان مؤثرترین تاخیرهای داده های سری زمانی بارش شهر ایلام شناسایی شدند. در انتها نتایج مدل ترکیبی ORELM با مدل های هوش مصنوعی ELM و ORELM مقایسه گردید که مقایسه مذکور نشان دهنده عملکرد بهتر مدل ترکیبی ORELM بود.

ملاحظات اخلاقی

پیروی از اصول اخلاق پژوهش

نویسندگان اصول اخلاقی را در انجام و انتشار این پژوهش علمی رعایت نموده اند و این موضوع مورد تأیید همه آنهاست.

تعارض منافع

بنا بر اظهار نویسندگان این مقاله تعارض منافع ندارد.

References

- Aman Jalili, A., Najarchi, M., Shabanlou, S., & Jafarinia, R. (2023). Multiobjective optimization of water resources in real time based on integration of NSGA-II and support vector machines. *Environ Sci Pollut Res*, 30, 16464–16475. <https://doi.org/10.1007/s11356-022-22723-4>
- Amiri, S., Rajabi, A., Shabanlou, S., Yosefvand, F., & Izadbakhsh, M.A. (2023). Prediction of groundwater level variations using deep learning methods and GMS numerical model. *Earth Sci Inform*, 16, 3227–3241. <https://doi.org/10.1007/s12145-023-01052-1>
- Jalilian, A., Heydari, M., Azari, A., & Shabanlou, S. (2022). Extracting optimal rule curve of dam reservoir base on stochastic inflow. *Water Resour Manage*, 36, 1763–1782. <https://doi.org/10.1007/s11269-022-03087-3>
- Gharib, R., Heydari, M., Kardar, S., & Shabanlou, S. (2020). Simulation of discharge coefficient of side weirs placed on convergent canals using modern self-adaptive extreme learning machine. *Appl Water Sci*, 10, 50. <https://doi.org/10.1007/s13201-019-1136-0>
- Azad, A., Manoochchri, M., Kashi, H., Farzin, S., Karami, H., Nourani, V., & Shiri, J. (2019). Comparative evaluation of intelligent algorithms to improve adaptive neuro-fuzzy inference system performance in precipitation modelling. *Journal of Hydrology*, 571, 214–224. <http://dx.doi.org/10.1016/j.jhydrol.2019.01.062>
- Azizi, E., Yosefvand, F., Yaghoubi, B., Izadbakhsh, M.A., & Shabanlou, S. (2023) Modelling and prediction of groundwater level using wavelet transform and machine learning methods: A case study for the Sahneh Plain, Iran. *Irrigation and Drainage*, 72(3), 747–762. <https://doi.org/10.1002/ird.2794>
- Basak, A., Mengshoel, O.J., Kulkarni, C., Schmidt, K., Shastry, P., & Rapeta, R. (2017). Optimizing the decomposition of time series using evolutionary algorithms: soil moisture analytics. *The genetic and evolutionary computation conference*, Berlin, Germany. <http://dx.doi.org/10.1145/3071178.3071191>
- Fallahi, M.M., Shabanlou, S., Rajabi, A., Yosefvand, F., & IzadBakhsh, M.A. (2023). Effects of climate change on groundwater level variations affected by uncertainty (case study: Razan aquifer). *Appl Water Sci*, 13(143). <https://doi.org/10.1007/s13201-023-01949-8>
- Hammad, M., Shoaib, M., Salahudin, H., Baig, M. A. I., Khan, M. M., & Ullah, M. K. (2021). Rainfall forecasting in upper Indus basin using various artificial intelligence techniques. *Stochastic Environmental Research and Risk Assessment*, 35(1-2), 1–23. <https://link.springer.com/article/10.1007/s00477-021-02013-0>
- Hasani, F., and Shabanlou, S. (2021). Weighted regularized extreme learning machine to model the discharge coefficient of side slots. *Flow Measurement and Instrumentation*, 79, 101955. <https://doi.org/10.1016/j.flowmeasinst.2021.101955>
- Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70(1-3), 489–501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- Mahmodian, A.R., Rajabi, A., Izadbakhsh, M.A., & Shabanlou, S. (2019). Evaluation of side orifices shape factor using the novel approach self-adaptive extreme learning machine Model. *Earth Syst. Environ*, 5, 925–935. <https://doi.org/10.1007/s40808-019-00579-x>
- Maqsood, I., Khan, M.R., & Abraham, A. (2004). An ensemble of neural networks for weather forecasting. *Neural Computing & Applications*, 13(2), 112–122. <https://doi.org/10.1007/s00521-004-0413-4>
- Mazraeh, A., Bagherifar, M., Shabanlou, S., & Ekhlasmad, R. (2023). A Hybrid Machine Learning Model for Modeling Nitrate Concentration in Water Sources. *Water, Air, & Soil Pollution*, 234(11), 1–22. <http://dx.doi.org/10.1007/s11270-023-06745-3>

- Mazraeh, A., Bagherifar, M., Shabanlou, S., & Ekhlasmand, R. (2024). A novel committee-based framework for modeling groundwater level fluctuations: A combination of mathematical and machine learning models using the weighted multi-model ensemble mean algorithm. *Groundwater for Sustainable Development*, 24, 101062. <http://dx.doi.org/10.1016/j.gsd.2023.101062>
- Mehr, A. D., Nourani, V., Khosrowshahi, V. K., & Ghorbani, M. A. (2019). A hybrid support vector regression–firefly model for monthly rainfall forecasting. *International Journal of Environmental Science and Technology*, 16(1), 335-346. <http://dx.doi.org/10.1007/s13762-018-1674-2>
- Mekanik, F., Imteaz, M. A., Gato-Trinidad, S., & Elmahdi, A. (2013). Multiple regression and Artificial Neural Network for long-term rainfall forecasting using large scale climate modes. *Journal of Hydrology*, 503, 11-21. <https://doi.org/10.1016/j.jhydrol.2013.08.035>
- Mislan, H., Hardwinarto, S., & Sumaryono, M. A. (2015). Rainfall monthly prediction based on artificial neural network: a case study in Tenggara Station, East Kalimantan-Indonesia. *Procedia Computer Science*, 59, 142-151. <https://doi.org/10.1016/j.procs.2015.07.528>
- Moghadam, R.G., Yaghoubi, B., Rajabi, A. Shabanlou, S., & Izadbakhsh, M.A. (2022). Evaluation of discharge coefficient of triangular side orifices by using regularized extreme learning machine. *Appl Water Sci*, 12, 145. <https://doi.org/10.1007/s13201-022-01665-9>
- Nasseri, M., Asghari, K., & Abedini, M. J. (2008). Optimized scenario for rainfall forecasting using genetic algorithm coupled with artificial neural network. *Expert Systems with Applications*, 35(3), 1415-1421. <https://doi.org/10.1016/j.eswa.2007.08.033>
- Poursaeid, M., Poursaeed, A.H., & Shabanlou, S. (2022). Study of water resources parameters using artificial intelligence techniques and learning algorithms: a survey. *Appl Water Sci*, 12, 156. <https://doi.org/10.1007/s13201-022-01675-7>
- Poursaeid, M., Poursaeed, A.H., & Shabanlou, S. (2024). Water quality fluctuations prediction and Debi estimation based on stochastic optimized weighted ensemble learning machine. *Process Safety and Environmental Protection*, 188, 1160-1174. <https://doi.org/10.1016/j.psep.2024.05.146>
- Riad, S., Mania, J., Bouchaou, L., & Najjar, Y. (2004). Rainfall-runoff model using an artificial neural network approach. *Mathematical and Computer Modelling*, 40(7-8), 839-846. <https://doi.org/10.1016/j.mcm.2004.10.012>
- Shabanlou, S. (2018). Improvement of extreme learning machine using self-adaptive evolutionary algorithm for estimating discharge capacity of sharp-crested weirs located on the end of circular channels. *Flow Measurement and Instrumentation*, 59, 63-71. <https://doi.org/10.1016/j.flowmeasinst.2017.11.003>
- Shafiei, S., Najarchi, M., & Shabanlou, S. (2020). Prognostication of discharge coefficient of labyrinth weir using outlier robust extreme learning machine. *Flow Measurement and Instrumentation*, 71, 101681. <https://doi.org/10.1016/j.flowmeasinst.2019.101681>
- Shirali, E., Shahbazi, A. N., Fathian, H., Zohrabi, N., & Hassan, E. M. (2020). Evaluation of WRF and artificial intelligence models in short-term rainfall, temperature and flood forecast (case study). *Journal of Earth System Science*, 129(1), 1-16. <http://dx.doi.org/10.1007/s12040-020-01450-9>
- Xiang, Y., Gou, L., He, L., Xia, S., & Wang, W. (2018). A SVR–ANN combined model based on ensemble EMD for rainfall prediction. *Applied Soft Computing*, 73, 874-883. <https://doi.org/10.1016/j.asoc.2018.09.018>

- Yang, J., & Zhang, Y. (2011). Alternating approximation algorithms for ℓ_1 -problems in compress sensing. *SIAM J. Sci. Comput*, 33(1), 250-278. <https://doi.org/10.1137/090777761>
- Zarei, S., Yosefvand, F., & Shabanlou, S. (2020). Discharge coefficient of side weirs on converging channels using extreme learning machine modeling method. *Measurement*, 152, 107321. <https://doi.org/10.1016/j.measurement.2019.107321>
- Zhang, K., & Luo, M. (2015). Outlier-robust extreme learning machine for regression problems. *Neurocomputing*, 151, 1519-1527. <https://doi.org/10.1016/j.neucom.2014.09.022>