

Analyzing the Performance of Machine Learning Models in Detecting Teleconnection Signals Affecting Temperature and Precipitation in Northwest Iran

Saeed Armaghan Bostanabad^{1*}, Behrouz Sari Saraf², Majid Rezaei Banafshe Daragh², Ali mohammad Khorshiddoost²

¹ Department of Climatology, Faculty of Planning and Environmental Sciences, University of Tabriz, Tabriz, Iran, email: saeed.armaghan92@gmail.com

² Department of Climatology, Faculty of Planning and Environmental Sciences, University of Tabriz, Tabriz, Iran.

Article Info	ABSTRACT
Article type: Research Full Paper	This study aimed to develop an intelligent and interpretable modeling framework for the monthly prediction of precipitation and temperature at 24 synoptic stations in northwest Iran over a 30-year period. For this purpose, the performance of three different approaches was evaluated: statistical modeling (Multivariate Linear Regression, MLR), fuzzy inference (Adaptive Neuro-Fuzzy Inference System, ANFIS), and artificial intelligence (Multilayer Perceptron neural network, MLP). To overcome the limitations of classical methods in parameter optimization, a genetic algorithm (GA) was employed to design the optimal network architecture and determine the connection weights (resulting in the hybrid GA-MLP model). The results showed that the proposed GA-MLP hybrid model delivered the most efficient performance by reducing the RMSE (e.g., demonstrating a 30% improvement in temperature and 23.5% in precipitation compared to the MLR model) and successfully overcoming the non-convergence issue of the baseline MLP model. Specifically, it lowered the temperature prediction error at the Parsabad station to 1.3°C and the precipitation prediction error at the Jolfa station to 10.9 mm. Sensitivity analysis using a feature-importance approach revealed the key role of six-month time lags and teleconnections in the region's climatic fluctuations, confirming the model's ability to grasp the underlying physics of the problem. Furthermore, uncertainty assessment using a calibrated bootstrap method indicated a high coverage rate above 95%, ensuring the model's reliability for operational decision-making. Finally, topographic analysis demonstrated no significant correlation between model error and elevation, which attests to the spatial robustness of the proposed model across heterogeneous climates.
Article history: Received: 2026-5-23 Accepted: 2026-6-27	
Keywords: Teleconnection Hybrid Neural Network Genetic Algorithm Fuzzy Modeling Northwest Iran	

Cite this article: Armaghan Bostanabad, S., Sari Saraf, B., Rezaei Banafshe Daragh, M., Khorshiddoost, A.M. (2026). Analyzing the Performance of Machine Learning Models in Detecting Teleconnection Signals Affecting Temperature and Precipitation in Northwest Iran. Journal of the Climate Change research, 7 (26), 71-88.



تحلیل عملکرد مدل‌های یادگیری ماشین در آشکارسازی سیگنال‌های دورپیوندی مؤثر بر دما و بارش شمال غرب ایران

سعید ارمان بستان‌آباد^{۱*}، بهروز ساری صراف^۲، مجید رضایی بنفشه درق^۲، علی محمد خورشیددوست^۲

^۱ گروه آب و هواشناسی، دانشکده برنامه‌ریزی محیطی، دانشگاه تبریز، تبریز، ایران، رایانامه: saeed.armaghan92@gmail.com

^۲ گروه آب و هواشناسی، دانشکده برنامه‌ریزی محیطی، دانشگاه تبریز، تبریز، ایران

اطلاعات مقاله	چکیده
نوع مقاله: مقاله کامل علمی تاریخ دریافت: ۱۴۰۵/۳/۲ تاریخ پذیرش: ۱۴۰۵/۴/۶ واژه‌های کلیدی: اقلیم پیوند از دور شبکه عصبی هیبریدی الگوریتم ژنتیک مدل‌سازی فازی شمال غرب ایران	این پژوهش با هدف توسعه یک چارچوب مدل‌سازی هوشمند و تفسیرپذیر برای پیش‌بینی ماهانه بارش و دما در ۲۴ ایستگاه سینوپتیک شمال غرب ایران (طی دوره ۳۰ ساله) انجام شده است. بدین منظور، عملکرد سه رویکرد متفاوت شامل مدل‌سازی آماری رگرسیون چندمتغیره (MLR)، استنتاج فازی (ANFIS) و شبکه عصبی مصنوعی (MLP) مورد ارزیابی قرار گرفت. به منظور غلبه بر محدودیت‌های روش‌های کلاسیک در بهینه‌سازی پارامترها، از الگوریتم ژنتیک (GA) برای طراحی معماری بهینه و تعیین وزن‌های شبکه عصبی استفاده شد (مدل هیبریدی GA-MLP). نتایج نشان داد که مدل هیبریدی پیشنهادی GA-MLP با کاهش خطای RMSE (به عنوان نمونه بهبود ۳۰ درصدی در دما و ۲۳٫۵ درصدی در بارش نسبت به مدل MLR) و غلبه بر مشکل عدم همگرایی در مدل پایه MLP، کارآمدترین عملکرد را ارائه می‌دهد. این مدل توانست خطای پیش‌بینی دما را در ایستگاه پارس‌آباد به ۱٫۳ درجه سانتی‌گراد و خطای بارش را در ایستگاه جلفا به ۱۰٫۹ میلی‌متر کاهش دهد. تحلیل حساسیت با رویکرد اهمیت ویژگی، نقش کلیدی تأخیرهای زمانی ۶ ماهه و پیوندهای دور را در نوسانات اقلیمی منطقه آشکار ساخت که مؤید توانایی مدل در درک فیزیک مسئله است. همچنین، ارزیابی عدم قطعیت مدل با روش بوت‌استرپ کالیبره شده، پوشش بالای ۹۵ درصد را نشان داد که قابلیت اطمینان مدل را برای تصمیم‌گیری‌های عملیاتی تضمین می‌کند. در نهایت، تحلیل توپوگرافی عدم وجود همبستگی معنادار بین خطای مدل و ارتفاع را اثبات کرد که بیانگر استواری مکانی مدل پیشنهادی در اقلیم‌های ناهمگن است.

استناد: ارمان بستان‌آباد، سعید؛ ساری صراف، بهروز؛ رضایی بنفشه درق، مجید؛ خورشیددوست، علی محمد (۱۴۰۵). تحلیل

عملکرد مدل‌های یادگیری ماشین در آشکارسازی سیگنال‌های دورپیوندی مؤثر بر دما و بارش شمال غرب ایران.

نشریه پژوهش‌های تغییرات آب و هوایی، ۷ (۲۶)، ۷۱-۸۸.



مقدمه

اتمسفر زمین یک سیستم دینامیکی غیرخطی و آشوبناک است که در آن، تغییرات انرژی و جرم در مقیاس‌های زمانی و مکانی گوناگون رخ می‌دهد. شناخت سازوکارهای حاکم بر این سیستم، به‌ویژه برای پیش‌بینی متغیرهای کلیدی همچون دما و بارش، نقشی حیاتی در مدیریت منابع آب و کاهش ریسک بلایای طبیعی ایفا می‌کند (IPCC, 2021). در دهه‌های اخیر، پارادایم مطالعات اقلیمی از تمرکز صرف بر داده‌های محلی، به سمت درک الگوهای گردش عمومی جو تغییر جهت داده است. این الگوها که تحت عنوان الگوهای پیوند از دور^۱ شناخته می‌شوند، همچون پل‌های اتمسفری، ناهنجاری‌های اقلیمی را در فواصل دوردست به یکدیگر متصل می‌کنند (Wallace & Gutzler, 1981). مطالعات جهانی نشان داده‌اند که شاخص‌هایی نظیر نوسان اطلس شمالی (NAO) و نوسان جنوبی (ENSO) از طریق جابجایی رودبادها و مراکز فشار، کنترل‌کننده اصلی تغییرپذیری اقلیم در نیمکره شمالی هستند (Hurrell, 1995; Ropelewski & Halpert, 1987). با این وجود، ماهیت غیرایستا^۲ و پیچیده ارتباط میان این الگوها با بارش و دما، استفاده از روش‌های خطی سنتی را با محدودیت‌های جدی مواجه کرده است. روش‌های رگرسیونی معمولاً قادر به تبیین تأخیرهای زمانی^۳ و برهم‌کنش‌های غیرخطی میان اقیانوس و اتمسفر نیستند (Maier & Dandy, 2000). برای غلبه بر این چالش، رویکردهای مبتنی بر هوش مصنوعی و یادگیری ماشین^۴ توسعه یافته‌اند. مدل‌های شبکه عصبی مصنوعی و به‌ویژه سیستم استنتاج عصبی-فازی تطبیقی (ANFIS)، با الهام از ساختار یادگیری بیولوژیکی و استدلال منطقی، ابزاری قدرتمند برای مدل‌سازی این پیچیدگی‌ها محسوب می‌شوند (Jang, 1993; Kisi, 2005).

دما و بارش به عنوان مهم‌ترین متغیرهای آب و هوایی برای تأمین فعالیت‌های بیولوژیکی روی سیاره زمین در نظر گرفته می‌شوند و رابطه آن با الگوهای دورپیوندی در مقیاس بزرگ موضوع تحقیقات زیادی بوده است. لذا پیش‌بینی آنها در مقیاس بزرگ یکی از چالش‌های مدیریت منابع آب سطحی، زیرزمینی و کشاورزی است. یکی از مشکلات بارز در این نوع مطالعات فضایی، ارتباط بین الگوهای دورپیوندی و متغیرهای تحت تأثیر آن است، زیرا این مطالعات از نظر مقیاس فضایی متناسب نیستند و اگرچه اثر خرد اقلیم را در نظر می‌گیرند، اما نتایج متناقضی را در مناطق مجاور نشان می‌دهند (احمدی و همکاران، ۲۰۲۲). مطالعات جهانی نشان داده‌اند که الگوهای پیوند از دور به عنوان مدهای غالب تغییرپذیری، نقش تعیین‌کننده‌ای در بی‌هنجاری‌های دما و بارش دارند. بارنستون و لایوزی (۱۹۸۷) در طبقه‌بندی مرجع خود، الگوهای گردشی نیمکره شمالی نظیر نوسان اطلس شمالی (NAO)، نوسان قطبی (AO) و الگوهای تروپوسفریک نظیر اطلس شرقی (EA)، اطلس شرقی-روسیه غربی (EA/WR) و اسکاندیناوی (SCN) را شناسایی کردند. اهمیت الگوی EA/WR و SCN در این است که با تغییر موقعیت جت‌استریم قطبی و جنب‌حاره‌ای، مسیر طوفان‌های عرض میانی را به سمت مدیترانه و خاورمیانه تغییر می‌دهند (Ionita et al., 2015). در حوزه شاخص‌های اقیانوسی، پوراصغر و همکاران (۲۰۱۲) و همچنین وحید دوست (۲۰۱۷) نشان دادند که ناهنجاری‌های دمای سطح آب (SST) در اقیانوس آرام، به‌ویژه شاخص‌های ENSO (شامل نواحی نینو ۱، ۲، ۳، ۴ و ۴) و نوسان دهه‌ای آرام (PDO)، از طریق تغییر در گردش واکر و امواج راسبی، بر بارش‌های پاییزه عرض‌های میانی اثر می‌گذارند. وحید دوست (۲۰۱۷) اثبات کرد که شاخص PDO به دلیل ماهیت فرکانس پایین خود، بیشترین همبستگی را با بارش سالانه در حوضه‌هایی نظیر دریاچه ارومیه دارد و حتی بر اثرگذاری شاخص‌های فرکانس بالا مثل ENSO غالب است. همچنین در مقیاس‌های درون فصلی، ناظم‌السادات و

1. Teleconnections
2. Non-stationary
3. Time Lags
4. Machine Learning

همکاران (۲۰۲۰، ۲۰۱۷) نقش نوسان ماندن- جولیان (MJO) را برجسته کردند. یافته‌های آن‌ها نشان داد که فازهای ۱، ۲، ۷ و ۸ این شاخص با تقویت شار رطوبت از اقیانوس هند (که با شاخص‌هایی همچون IOBSST ردیابی می‌شود)، احتمال رخداد بارش‌های سنگین و سیل‌آسا را در جنوب غرب آسیا افزایش می‌دهند. با توجه به پیچیدگی و رفتار آشوبناک این الگوها، رویکرد جهانی به سمت استفاده از هوش مصنوعی تغییر کرده است. پاکدامن و همکاران (۲۰۲۲) و بامری و خالقی (۱۴۰۱) در مطالعاتی جامع نشان دادند که مدل‌های یادگیری ماشین نظیر شبکه عصبی مصنوعی (ANN)، جنگل تصادفی^۱ و گرادیان تقویتی، در صورت تغذیه با ورودی‌های دارای تأخیر زمانی قادرند روابط غیرخطی میان شاخص‌هایی نظیر WP، PNA و MEI را با متغیرهای اقلیمی شبیه‌سازی کنند. این مدل‌ها به ویژه در آشکارسازی اثرات ترکیبی (مثلاً همفازی ENSO و PDO) که روش‌های رگرسیونی قادر به درک آن نیستند، برتری دارند (Reichstein et al., 2019). توافق کلی پژوهشگران داخلی بر آن است که شاخص‌های اقیانوس اطلس شمالی نقش مسلطی در اقلیم زمستانه شمال غرب دارند. حضرتی (۱۳۸۲)، محمدخورشیددوست و همکاران (۱۳۸۶) و سبحانی و همکاران (۱۳۹۳) همگی تأیید کرده‌اند که فاز منفی NAO با تضعیف پرفشار آזור و هدایت عمیق‌تر چرخندهای مدیترانه‌ای، موجب ترسالی و تعدیل دما در منطقه می‌شود، در حالی که فاز مثبت آن با خشکسالی و سرما همراه است. در یک یافته کلیدی برای این پژوهش، خسروی و مسگری (۱۳۹۵) با بررسی ۱۷ شاخص، نشان داد که الگوی EA/WR مؤثرترین شاخص بر نوسانات دمایی شمال غرب ایران است و همبستگی آن حتی از NAO بالاتر است. این شاخص به همراه AO، کنترل‌کننده اصلی امواج هوای سرد و گرم در منطقه محسوب می‌شوند. همچنین قویدل رحیمی و همکاران (۱۳۹۳) الگوی NCP را به عنوان عامل کلیدی بارش‌های پاییزه معرفی کردند که

فاز مثبت آن با افزایش بارش در ایستگاه‌های شمال غرب (مانند تبریز و اهر) همراه است. مطالعات نواظم‌السادات (۱۳۷۸) و محمدخورشیددوست و قویدل (۱۳۸۵) نشان داده‌اند که پدیده ENSO (به ویژه شاخص چندمتغیره MEI و شاخص‌های نینو) بر بارش‌های پاییزه شمال غرب تأثیر مثبت دارد (ال‌نینو = ترسالی)، اما این رابطه در زمستان تضعیف می‌شود. علیزاده چوباری و نجفی (۲۰۱۸) نیز نشان دادند که اگرچه NAO تأثیر پیچیده‌ای بر بارش خاورمیانه دارد، اما فاز منفی آن با بارش‌های فراتر از نرمال در شمال غرب ایران و فاز مثبت آن با دماهای کمتر از نرمال در جنوب غرب آسیا مرتبط است. آن‌ها همچنین نقش AMO (نوسان چنددهه‌ای اطلس) را برجسته کرده و همبستگی مثبت آن (حدود ۰٫۵۰) با دمای شمال غرب ایران و افزایش خشکسالی‌ها در فاز گرم AMO را گزارش نمودند. مطالعاتی که به تأخیر زمانی نیز پرداخته‌اند: هلالی و همکاران (۲۰۲۰) در بررسی جامع ۴۰ شاخص دورپیوندی در حوضه‌های آبریز ایران، نشان دادند که شاخص‌های اقیانوسی نظیر TN، SOI و AMO در تأخیرهای زمانی ۱ تا ۳ ماهه بیشترین همبستگی را با بارش دارند. همچنین شاخص TPI نیز همبستگی معنی‌داری با بارش پاییزه این حوضه دارد که نشان‌دهنده لزوم بررسی شاخص‌های کمتر شناخته شده است. میرهاشمی و حسنوند (۱۴۰۲) نیز تفکیک جالبی ارائه دادند: الگوهای مبتنی بر اقیانوس اطلس (NAO, EA) عمدتاً در زمستان و الگوهای اقیانوس آرام (PDO, ENSO) در پاییز بر بارش منطقه اثرگذارند. فاتحی مرج و همکاران (۱۳۸۷) و بابایی فینی (۱۳۹۴) با استفاده از شبکه‌های عصبی و شاخص‌های PDO و PNA، موفق به پیش‌بینی جریان رودخانه‌ها با تأخیر ۶ ماهه شدند. وحید دوست (۲۰۱۷) با بررسی همزمان چندین شاخص شامل NAO, ENSO, AMO, AO، اثبات کرد که شاخص PDO، IOD و SAM، بیشترین تأثیر را بر بارش سالانه حوضه دریاچه ارومیه دارد و نوسانات IOD و SAM بیشتر در بخش‌های


مدل‌های مختلف یادگیری ماشین در آشکارسازی سیگنال‌های دورپیوندی مؤثر بر دما و بارش شمال غرب ایران پرداخته شد.

داده‌ها و روش تحقیق

محدوده و قلمرو پژوهش: منطقه مورد مطالعه پژوهش، شامل پنج استان آذربایجان شرقی و غربی، اردبیل، زنجان و کردستان در شمال غرب ایران است که در موقعیت جغرافیایی ۳۴ درجه و ۴۴ دقیقه الی ۳۹ درجه و ۴۷ دقیقه عرض شمالی و ۴۴ درجه و ۵ دقیقه الی ۴۹ درجه و ۵۲ دقیقه طول شرقی قرار دارد. در این پژوهش از داده‌های دمای و بارش ۲۵ ایستگاه همدیدی با پراکنش مناسب در سطح منطقه که دارای دوره آماری مشترک ۱۹۹۵ تا ۲۰۲۴ بودند، جهت ارزیابی و مدل‌سازی استفاده شد (شکل ۱).

شرقی حوضه مؤثرند. پاکدامن و همکاران (۱۴۰۳) و فرجی و همکاران (۱۴۰۳) با استفاده از روش‌های گرادیان تقویتی و پرسپترون چندلایه در شمال غرب ایران، نشان دادند که انتخاب ویژگی هوشمند (شامل شاخص WP با تأخیر ۳ ماهه) و استفاده از الگوریتم‌های غیرخطی، دقت پیش‌بینی بارش ماهانه و دما را به طرز چشمگیری نسبت به روش‌های خطی افزایش می‌دهد. عزیززاده و جوان (۱۳۹۸) نیز تأثیر شاخص‌های ترکیبی نظیر EP/NP را بر شاخص‌های فرین بارش در حوضه دریاچه ارومیه تأیید کردند.

موقعیت استراتژیک شمال غرب ایران در منطقه گذار بین سامانه‌های مدیترانه‌ای و بادهای غربی، سبب شده است تا اقلیم این منطقه واکنش شدیدی به فازهای الگوهای پیوند از دور نشان دهد. لذا با توجه به اهمیت موضوع در این پژوهش به تحلیل عملکرد



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه و ایستگاه‌های هواشناسی مورد بررسی

کشور دریافت شد. در ادامه به منظور مدل‌سازی و پیش‌بینی متغیرهای هیدرواقلمی (دما و بارش) با استفاده از الگوهای پیوند از دور، از سه روش رگرسیون خطی، شبکه عصبی و عصبی-فازی استفاده شد.

روش پژوهش: در گام نخست داده‌های ماهانه ۲۵ شاخص دورپیوندی (جدول ۱)، در دوره‌ی آماری بلندمدت ۳۰ ساله (۱۹۹۵-۲۰۲۴) از تارنمای سازمان جوی و اقیانوسی NOAA و داده‌های بارش و دما از سازمان هواشناسی کشور برای منطقه شمال غرب

جدول ۱- الگوهای دورپیوندی مورد بررسی در این پژوهش

ردیف	الگو	انگلیسی	فارسی
1	AMO	Atlantic Multidecadal Oscillation	نوسان چند دهه‌ای اقیانوس اطلس
2	AO	Arctic Oscillation	نوسان قطبی
3	EA	East Atlantic	شرق اقیانوس اطلس
4	EAWR	East Atlantic-West Russian	شرق اقیانوس اطلس - غرب روسیه
5	MEI	Multi ENSO Index	شاخص چندگانه انسو (ال نینو - نوسان جنوبی)
6	NAO	North Atlantic Oscillation	نوسان شمال اقیانوس اطلس
7	NCP	North Sea-Caspian Sea Pattern	الگوی دریای شمال - دریای خزر
8	Niño1.2	Extreme Eastern Tropical Pacific SST	دمای سطح دریا در شرق شدید اقیانوس آرام حاره‌ای
9	Niño3	Tropical Pacific SST	دمای سطح دریا در اقیانوس آرام حاره‌ای
10	Niño3.4	East Central Tropical Pacific SST	دمای سطح دریا در مرکز شرقی اقیانوس آرام حاره‌ای
11	Niño4	Central Tropical Pacific SST	دمای سطح دریا در مرکز اقیانوس آرام حاره‌ای
12	PDO	Pacific Decadal Oscillation	نوسان دهه‌ای اقیانوس آرام
13	PNA	Pacific North American	الگوی اقیانوس آرام-آمریکای شمالی
14	POL	Polar/Eurasia patterns	الگوهای قطبی / اوراسیا
15	QBO	Quasi Biannual Oscillation at 30 hPa	نوسان شبه دوساله در سطح ۳۰ هکتوپاسکال
16	SCN	Scandinavia Index	شاخص اسکاندیناوی
17	SOI	Southern Oscillation Index	شاخص نوسان جنوبی
18	TNA	Tropical North Atlantic	اطلس شمالی حاره‌ای
19	TNI	Trans Niño Index	شاخص ترانس نینو
20	TPI	SST Differ of North Pacific from South Pacific	تفاوت دمای سطح دریا بین شمال و جنوب اقیانوس آرام
21	TSA	Tropical South Atlantic	اطلس جنوبی حاره‌ای
22	TNH	Tropical/ Northern Hemisphere Pattern	الگوی حاره‌ای/نیمکره شمالی
23	MJO	Madden-Julian Oscillation	نوسان مادن-جولیان
24	WHWP	Western Hemisphere Warm Pool	استخر گرم نیمکره غربی
25	WP	West Pacific	غرب اقیانوس آرام

رگرسیون خطی چندمتغیره^۱: رگرسیون خطی

چندمتغیره (MLR) یکی از پرکاربردترین روش‌های آماری در اقلیم‌شناسی است که برای مدل‌سازی رابطه خطی میان یک متغیر وابسته (مانند بارش یا دما) و دو یا چند متغیر مستقل (شاخص‌های پیوند از دور) به کار می‌رود. هدف اصلی این روش، برازش یک مدل خطی است که مجموع مربعات خطای آن حداقل باشد (Montgomery et al., 2012).

ساختار کلی مدل MLR طبق رابطه (۱) تعریف می‌شود:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \epsilon \quad (1)$$

که در آن: Y : متغیر وابسته (پیش‌بینی‌شونده)، $X_1, X_2, \dots, X_n$: متغیرهای مستقل (شاخص‌های دورپیوندی ورودی)، β_0 : عرض از مبدأ^۲، $\beta_1, \dots, \beta_n$: ضرایب رگرسیونی (نشان‌دهنده میزان تأثیر هر شاخص)، ϵ : جمله خطا^۳ که نشان‌دهنده انحراف مقادیر واقعی از مقادیر پیش‌بینی شده است و فرض می‌شود دارای توزیع نرمال با میانگین صفر باشد (Draper & Smith, 1998).

2 . Intercept

3 . Error Term

1 . Multiple Linear Regression

شبکه عصبی پرسپترون چندلایه بهینه‌شده با الگوریتم ژنتیک (Hybrid GA-MLP): این مدل، هسته اصلی و نوآوری پژوهش حاضر است. شبکه عصبی MLP کلاسیک معمولاً در دام بهینه‌های محلی^{۱۱} گرفتار می‌شود. برای رفع این مشکل، از الگوریتم ژنتیک^{۱۲} به عنوان یک بهینه‌ساز سراسری^{۱۳} استفاده شد.

در این ساختار هیبریدی:

۱. کروموزوم‌ها: هر کروموزوم نشان‌دهنده برداری از وزن‌ها و بایاس‌های شبکه عصبی و همچنین تعداد نرون‌های لایه پنهان است.

۲. تابع برازش: خطای RMSE مدل در داده‌های آموزش به عنوان تابع هدف برای مینیمم‌سازی تعریف شد.

۳. عملگرها: از عملگرهای جهش و تقاطع برای جستجوی فضای پارامترها استفاده شد تا بهترین معماری شبکه که قادر به تعمیم الگوهای اقلیمی باشد، تکامل یابد.

به منظور تضمین تکرارپذیری نتایج و شفافیت فرآیند بهینه‌سازی، تنظیمات و پارامترهای الگوریتم ژنتیک به دقت پیکربندی شدند. در این پژوهش، اندازه جمعیت اولیه برابر با ۲۰ کروموزوم در نظر گرفته شد و فرآیند تکامل برای ۵ نسل متوالی (به عنوان شرط توقف) اجرا گردید. برای تولید نسل‌های جدید و جستجو در فضای پاسخ، از عملگر تقاطع یکنواخت^{۱۴} با احتمال ۰.۵ و عملگر جهش با نرخ ۰.۱ استفاده شد. همچنین، به منظور حفظ بهترین معماری‌های یافت‌شده در هر نسل و جلوگیری از همگرایی زودرس، مکانیزم انتخاب والدین بر اساس استراتژی تورنمنت انجام گرفت و از رویکرد نخبه‌گرایی^{۱۵} جهت انتقال مستقیم ۲ کروموزوم برتر به نسل بعدی بهره‌برداری شد. فضای جستجوی پارامترها (ژن‌ها) برای یافتن معماری بهینه شبکه به این شرح محدود گردید: تعداد نرون‌های

شبکه عصبی پرسپترون چند لایه با الگوریتم مارکوارت-لونبرگ: شبکه‌های عصبی مصنوعی (ANN) با الهام از سیستم عصبی بیولوژیکی انسان طراحی شده‌اند. مدل پرسپترون چندلایه^۱ یکی از پرکاربردترین انواع شبکه‌های عصبی پیش‌خور^۲ است که شامل سه لایه اصلی ورودی، پنهان و خروجی می‌باشد (Haykin, 2009).

در این پژوهش، برای آموزش شبکه و به‌روزرسانی وزن‌ها، از الگوریتم مارکوارت-لونبرگ^۳ استفاده شده است. این الگوریتم ترکیبی از روش‌های گرادیان نزولی^۴ و گوس-نیوتن^۵ است که سرعت همگرایی بسیار بالایی در مسائل تقریب تابع دارد (Hagan & Menhaj, 1994).

رابطه ریاضی خروجی هر نرون در لایه پنهان به صورت رابطه (۲) است:

$$y_j = f\left(\sum_{i=1}^m w_{ji}x_i + b_j\right) \quad (2)$$

که در آن x_i : ورودی‌ها، w_{ji} : وزن‌های اتصال^۶، b_j : بایاس^۷، f : تابع محرک^۸ که در این پژوهش از نوع تانژانت هیپربولیک^۹ استفاده شده است. قانون به‌روزرسانی وزن‌ها در الگوریتم مارکوارت-لونبرگ طبق رابطه (۳) انجام می‌شود:

$$\Delta W = -[J^T J + \mu I]^{-1} J^T e \quad (3)$$

در این رابطه، J ماتریس ژاکوبین (شامل مشتقات جزئی خطا نسبت به وزن‌ها)، e بردار خطا، I ماتریس همانی و μ پارامتر تعدیل^{۱۰} است. زمانی که μ بزرگ باشد، الگوریتم به سمت گرادیان نزولی و زمانی که کوچک باشد به سمت روش گوس-نیوتن متمایل می‌شود.

- 1 . Multi-Layer Perceptron
- 2 . Feed-forward
- 3 . Levenberg-Marquardt
- 4 . Gradient Descent
- 5 . Gauss-Newton
- 6 . Connection Weights
- 7 . Bias
- 8 . Activation Function
- 9 . Hyperbolic Tangent
- 10 . Damping Factor

11 . Local Minima

12 . Genetic Algorithm - GA

13 . Global Optimizer

14 . Uniform Crossover

15 . Elitism

۴. Defuzzification: محاسبه خروجی هر قانون بر

اساس پارامترهای نتیجه^۲ (رابطه ۷)

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad ۷$$

۵. Summation: جمع‌بندی نهایی خروجی‌ها

(رابطه ۸).

$$O_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad ۸$$

در فرآیند آموزش ANFIS، از روش ترکیبی^۳ استفاده می‌شود؛ به طوری که پارامترهای مقدم (توابع عضویت) با روش گرادیان نزولی و پارامترهای مؤخر (ضرایب خطی خروجی) با روش حداقل مربعات خطا بهینه می‌شوند (Kisi, 2005).

پیش‌پردازش داده‌ها: نرمال‌سازی و برگرداندن

داده‌ها: از آنجایی که متغیرهای اقلیمی دارای واحدها و مقیاس‌های متفاوتی هستند، ورود داده‌های خام به شبکه می‌تواند منجر به ناپایداری مدل و کاهش سرعت آموزش شود. بنابراین، پیش از ورود داده‌ها به مدل‌های هوشمند (ANFIS و MLP)، تمام داده‌ها با استفاده از روش مینیمم-ماکزیمم به بازه [0,1] منتقل می‌شوند (Patro & Sahu, 2015).

نرمال‌سازی و غیرنرمال‌سازی^۴

برای تبدیل داده‌های واقعی (x_{real}) به داده‌های نرمال (x_{norm})، از رابطه (۹) استفاده می‌شود:

$$x_{norm} = \frac{x_{real} - x_{min}}{x_{max} - x_{min}} \quad ۹$$

که در آن: x_{norm} : مقدار نرمال شده (بین ۰ و ۱)، x_{real} : مقدار واقعی مشاهده شده، x_{min} : کمترین مقدار در سری زمانی داده‌های آن متغیر، x_{max} : بیشترین مقدار در سری زمانی داده‌های آن متغیر پس از انجام محاسبات و گرفتن خروجی از مدل، برای مقایسه نتایج با داده‌های مشاهداتی و محاسبه خطاهای واقعی، داده‌های پیش‌بینی شده باید به

لایه پنهان اول در بازه ۱۰ تا ۱۰۰، تعداد نورون‌های لایه پنهان دوم در بازه ۵ تا ۵۰، پارامتر نرخ یادگیری در بازه ۰,۰۰۱ تا ۰,۰۱ و ضریب تنظیم شبکه در بازه ۰,۰۰۱ تا ۰,۱ تعیین شدند.

سیستم استنتاج عصبی-فازی تطبیقی (ANFIS)

مدل ANFIS یک سیستم هوشمند هیبریدی است که قابلیت یادگیری شبکه‌های عصبی را با قدرت استدلال منطق فازی در شرایط عدم قطعیت ترکیب می‌کند. ساختار پیشنهادی یانگ (Jang, 1993) برای ANFIS اغلب از پنج لایه تشکیل شده و بر اساس سیستم استنتاج فازی سوگنو (Takagi – Sugeno) عمل می‌کند.

اگر فرض شود سیستم دارای دو ورودی x و y و

یک خروجی f باشد، قوانین فازی ($If -$)

(Then Rules) به صورت زیر تعریف می‌شوند:

• قانون ۱: اگر x عضو A_1 و y عضو B_1 باشد، آنگاه

$$f_1 = p_1 x + q_1 y + r_1$$

• قانون ۲: اگر x عضو A_2 و y عضو B_2 باشد، آنگاه

$$f_2 = p_2 x + q_2 y + r_2$$

ساختار پنج لایه ANFIS به شرح زیر است:

۱. Fuzzification: درجه عضویت ورودی‌ها محاسبه

می‌شود (رابطه ۴).

$$O_{1,i} = \mu_{A_i}(x) \quad ۴$$

۲. Rule Weight: در این لایه، وزن قانون یا درجه

فعال‌سازی^۱ برای هر قانون محاسبه می‌شود. این

مقدار نشان می‌دهد که مقدمات هر قانون تا چه

حد با ورودی‌ها مطابقت دارند و از حاصل ضرب

درجات عضویت تولید می‌شوند (رابطه ۵).

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad ۵$$

۳. Normalization: نرمال‌سازی قدرت شلیک قوانین

(رابطه ۶)

$$\bar{w}_i = \frac{w_i}{w_1 + w_2} \quad ۶$$

2 . Consequent Parameters

3 . Hybrid

4 . Denormalization

1 . Firing Strength

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad 12$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \quad 13$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2 \quad 14$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad 15$$

علاوه بر شاخص‌های خطای ذکر شده، به منظور ارزیابی و اثبات معناداری آماری اختلاف عملکرد بین مدل‌های توسعه‌یافته، از آزمون ناپارامتریک ویلکاکسون استفاده گردید. با توجه به آنکه توزیع خطاهای پیش‌بینی در مدل‌های هیدرواقلمی لزوماً از توزیع نرمال پیروی نمی‌کند، استفاده از این آزمون ناپارامتریک بر روی سری زمانی خطاهای مطلق پیش‌بینی، امکان مقایسه دقیق و علمی عملکرد مدل هیبریدی نسبت به مدل‌های پایه را در سطح اطمینان ۹۵ درصد ($P - Value < 0.05$) فراهم می‌آورد.

مقیاس اصلی خود بازگردند. برای این کار از رابطه (۱۰) زیر استفاده می‌شود (Han et al., 2011):

$$x_{real} = x_{norm} \times (x_{max} - x_{min}) + x_{min} \quad 10$$

ارزیابی عدم قطعیت و استواری مدل^۱: برخلاف مطالعات متداول که تنها به معیارهای خطای قطعی^۲ اکتفا می‌کنند، این پژوهش دو لایه ارزیابی تکمیلی ارائه می‌دهد:

۱. کمی‌سازی عدم قطعیت^۳: با استفاده از روش بوت‌استرپینگ^۴، بازه‌های اطمینان ۹۵٪ برای پیش‌بینی‌ها تولید شد و شاخص‌های احتمال پوشش پیش‌بینی (PICP) و میانگین پهنای باند (MPIW) محاسبه گردیدند.

۲. تحلیل استواری توپوگرافی^۵: برای اطمینان از عملکرد مدل در شرایط مختلف جغرافیایی، همبستگی بین خطای مدل و پارامترهای توپوگرافی شامل ارتفاع، شیب و جهت شیب برای تمامی ۲۴ ایستگاه مورد تحلیل آماری قرار گرفت.

معیارهای ارزیابی عملکرد مدل‌ها: به منظور سنجش دقت و کارایی مدل‌های توسعه‌یافته (MLR, MLP, ANFIS) و مقایسه نتایج پیش‌بینی‌شده (P_i) با مقادیر مشاهده‌شده واقعی (O_i)، از پنج شاخص آماری استاندارد شامل ضریب همبستگی پیرسون (R)، ضریب تعیین (R^2)، میانگین خطای مطلق (MAE)، میانگین مربعات خطا (MSE) و ریشه میانگین مربعات خطا (RMSE) استفاده شده است که بر اساس روابط ۱۱ تا ۱۵ محاسبه می‌شوند.

در روابط فوق: O_i : مقادیر مشاهده‌شده، P_i : مقادیر پیش‌بینی‌شده، $\bar{O}$: میانگین مقادیر مشاهده‌شده، $\bar{P}$: میانگین مقادیر پیش‌بینی‌شده، n : تعداد کل داده‌ها

$$R = \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \quad 11$$


- 1 . Uncertainty and Robustness Analysis
- 2 . Deterministic
- 3 . Uncertainty Quantification
- 4 . Bootstrapping
- 5 . Topographic Robustness

نتایج و یافته‌های پژوهش

ارزیابی عملکرد مدل‌های مورد بررسی: در گام نخست، دقت پیش‌بینی مدل‌های توسعه‌یافته (MLR, ANFIS, GA-MLP) برای دو متغیر بارش و دما در مقیاس ماهانه مورد ارزیابی قرار گرفت. نتایج حاصل از شاخص‌های آماری ($RMSE$, MAE , R^2) نشان‌دهنده برتری مطلق مدل پیشنهادی (Hybrid GA-MLP) در هر دو فاز آموزش و آزمون است (شکل ۲).

مدل خطی MLR به عنوان حد پایه، کمترین دقت را ثبت کرد که بیانگر ماهیت غیرخطی و پیچیده سری‌های زمانی هیدرو-اقلیمی در منطقه شمال غرب است. مدل ANFIS با بهره‌گیری از قوانین فازی توانست بخشی از این غیرخطی بودن را پوشش دهد، اما همچنان در نقاط حادی دارای خطا بود. در مقابل، مدل هیبریدی GA-MLP با بهره‌گیری از الگوریتم ژنتیک برای یافتن وزن‌های بهینه شبکه، توانست از

دام بهینه‌های محلی عبور کرده و خطای پیش‌بینی را به طور معناداری کاهش دهد. برای متغیر دما، مدل GA-MLP توانست مقدار $RMSE$ را در ایستگاه نمونه (پارس‌آباد) به ۱,۳۳ درجه سانتی‌گراد برساند، در حالی که این مقدار برای مدل MLR حدود ۲,۵ درجه بود. ضریب تبیین ($R^2 > 0.97$) نشان می‌دهد که این مدل توانسته است روند فصلی و نوسانات دما را با دقت بسیار بالا شبیه‌سازی کند. و برای متغیر بارش، با توجه به ماهیت تصادفی و پرنوسان بارش، بهبود عملکرد مشهودتر است. مدل هیبریدی توانست خطای $RMSE$ را نسبت به مدل پایه به عنوان نمونه در ایستگاه پارس آباد از ۱,۹۱ (در MLR) به ۱,۳۲ درجه سلسیوس (در GA-MLP) با ۳۰ درصد بهبود و در جلفا از ۱۴,۲۱ به ۱۰,۸۷ میلی‌متر با ۲۳,۵ درصد بهبود کاهش دهد (شکل ۲).




شکل ۲. مقایسه معیارهای ریشه میانگین مربعات خطا ($RMSE$) برای مدل‌های رگرسیون خطی چندمتغیره (MLR)، سیستم استنتاج تطبیقی عصبی-فازی (ANFIS)، پرسپترون چند لایه (MLP) و ترکیبی GA-MLP.

که در شکل ۴ ترسیم شده است، نشان دهنده پایداری مکانی مدل پیشنهادی در سطح منطقه است. بررسی نقشه های RMSE و R^2 حاکی از آن است که اگرچه پیچیدگی های توپوگرافی بر الگوی توزیع خطا اثرگذار بوده اند، اما مدل GA-MLP توانسته است در تمامی پهنه های جغرافیایی، دقت قابل قبولی را حفظ کند. نکته حائز اهمیت، نقشه درصد بهبود مدل (شکل 3-c و 3-f) است؛ این نقشه به وضوح نشان می دهد که بیشترین میزان ارتقای دقت نسبت به مدل MLP، در نواحی کوهستانی و مرزی رخ داده است. تمرکز فضایی بهبود در این مناطق، اثبات می کند که مدل هوشمند دقیقاً در نقاطی که مدل های خطی به دلیل اثرات اوروگرافیک دچار ضعف مفرط بوده اند، توانسته است با درک روابط غیرخطی، خطای پیش بینی را به طرز چشمگیری کاهش دهد و توزیع خطای همگن تری را فراهم آورد.

همچنین، برای اطمینان از اینکه برتری مدل پیشنهادی تصادفی نبوده است، مقادیر خطای مدل ها تحت آزمون آماری ویلکاکسون قرار گرفت. نتایج این آزمون نشان داد که اختلاف عملکرد و کاهش خطای مدل هیبریدی GA-MLP در مقایسه با تک تک مدل های پایه MLP، MLR و ANFIS برای هر دو متغیر بارش و دما کاملاً معنادار است ($p\text{-value} < 0.001$). این دستاورد آماری، در کنار بهبود شاخص های قطعی همچون کاهش RMSE، نشان می دهد که به کارگیری رویکرد تکاملی ژنتیک توانسته است با موفقیت بر چالش عدم همگرایی مدل های کلاسیک غلبه کرده و استواری یادگیری شبکه عصبی را به شکل معناداری ارتقا بخشد.

تحلیل فضایی و پهنه بندی خطا: یکی از نوآوری های کلیدی این پژوهش، گذار از تحلیل نقطه ای به ارزیابی فضایی است. توزیع مکانی شاخص های آماری ($RMSE$, R^2) و درصد بهبود مدل



شکل ۳. توزیع مکانی خطای پیش بینی (ریشه میانگین مربعات خطا) و درصد بهبود مدل با استفاده از روش GA-MLP در شمال غرب ایران

منظور رمزگشایی از دینامیک درونی مدل GA-MLP و شناسایی عوامل موثر بر پیش بینی بارش و دما، از تحلیل حساسیت مبتنی بر روش حذف متغیر استفاده شد. در این الگوریتم، فرآیند ارزیابی بدین نحو است

تحلیل حساسیت و اهمیت متغیرها یکی از چالش های بنیادین در بکارگیری مدل های هوشمند داده محور، فقدان شفافیت در فرآیند وزن دهی به ورودی ها و ماهیت جعبه سیاه آنهاست (Shen, 2018)؛ از این رو، به

نهایت، توانایی مدل GA-MLP در تخصیص وزن هوشمندانه به تاخیرهای نزدیک و شاخص NAO، گواهی بر تفسیرپذیری مدل^۳ و برتری آن نسبت به مدل‌های کلاسیک است که نشان می‌دهد الگوریتم ژنتیک فراتر از کاهش ریاضی خطا، موفق به شبیه‌سازی ساختار فیزیکی حاکم بر اقلیم منطقه در معماری شبکه عصبی شده است.

تحلیل عدم قطعیت: اگرچه مدل هیبریدی GA-MLP دقت بالایی را در شبیه‌سازی متغیرهای اقلیمی ثبت کرده است، اما تصمیم‌گیری صرف بر مبنای تخمین‌های نقطه‌ای^۴ در سیستم‌های پیچیده هیدرولوژیکی می‌تواند گمراه‌کننده باشد؛ از این‌رو، با بکارگیری روش بوت‌استرپینگ^۵، عدم قطعیت مدل در قالب بازه‌های اطمینان ۹۵٪ کمی‌سازی شد. نتایج حاصل که بیانگر مقادیر شاخص احتمال پوشش پیش‌بینی (PICP) فراتر از ۹۵٪ برای اکثریت ایستگاه‌ها است، قابلیت اطمینان مدل را تایید می‌کند. بررسی دقیق‌تر رفتار مدل در سه سطح عملکردی متفاوت (شکل ۵) نشان می‌دهد که در ایستگاه‌های با بهترین عملکرد^۶ نظیر جلفا (بارش با $RMSE=10.87$ mm) و پارس‌آباد (دما با $RMSE=1.33$ °C)، مدل موفق به ارائه بازه‌های اطمینان بسیار باریک و منطبق بر مشاهدات شده است، در حالی که در ایستگاه‌های با عملکرد میانه همچون تکاب ($RMSE=23.27$ mm) و مهاباد ($RMSE=1.63$ °C) و حتی در چالش‌برانگیزترین ایستگاه‌ها مانند مهاباد (در بارش با $RMSE=106.05$ mm) و زنجان (در دما با $RMSE=2.02$ °C)، مدل با افزایش هوشمندانه پهنای باند عدم قطعیت، توانسته است ضمن حفظ پوشش آماری داده‌های پرت، تصویری واقع‌بینانه از ریسک پیش‌بینی و صداقت آماری مدل را به مدیران منابع آب ارائه دهد.

که در هر تکرار، یکی از متغیرهای ورودی از مجموعه داده‌ها حذف شده و مدل هیبریدی مجدداً آموزش و اجرا می‌گردد. سپس، میزان افت دقت مدل (افزایش خطای پیش‌بینی RMSE) نسبت به مدل پایه اندازه‌گیری می‌شود. هرچه میزان افزایش خطا پس از حذف یک متغیر بیشتر باشد، نشان‌دهنده اهمیت وزن بالاتر آن متغیر در پیش‌بینی شبکه عصبی است. به منظور یکپارچگی و امکان مقایسه، مقادیر اهمیت به‌دست‌آمده برای هر متغیر به صورت درصد (نرمال‌سازی شده نسبت به مجموع خطاها) محاسبه و گزارش شده‌اند. نتایج این واکاوی که در شکل (۴) ترسیم شده است، پرده از دو واقعیت فیزیکی مهم برمی‌دارد: نخست، خاصیت تداوم اقلیمی^۱ که با حساسیت بالای مدل نسبت به تاخیرهای زمانی ۱ ماهه (P_{t-1}, T_{t-1}) نمایان شده است؛ این یافته بیانگر خاصیت تداوم^۲ در سری‌های زمانی هیدرو-اقلیمی است که نشان می‌دهد وضعیت اقلیمی جاری وابستگی شدیدی به شرایط ماه قبل دارد، موضوعی که در ادبیات هیدرولوژی تصادفی به عنوان یک ویژگی ذاتی سری‌های زمانی شناخته می‌شود (Machado et al., 2011)؛ ضمن آنکه اهمیت تاخیر ۱۲ ماهه در دما، توانایی مدل در درک چرخه‌های فصلی را تایید می‌کند. دوم، نقش سیگنال‌های اقلیمی بزرگ‌مقیاس است، به‌طوری‌که شاخص نوسان اطللس شمالی (NAO) به عنوان موثرترین سیگنال دورپیوند بر بارش منطقه شمال غرب شناسایی شده است. این نتیجه با واقعیت‌های سینوپتیکی منطقه همخوانی دارد، زیرا سامانه‌های بارشی این ناحیه عمدتاً از توده‌های هوای غربی و مدیترانه‌ای تغذیه می‌شوند که مسیر و شدت آن‌ها تحت کنترل فازهای مثبت و منفی NAO قرار دارد، یافته‌ای که با مطالعات پوراصغر و همکاران (۲۰۱۲) و تبری (۲۰۱۴) در خصوص شمال غرب ایران مطابقت دارد. پس از آن، شاخص‌های SOI و MEI در مراتب بعدی اثرگذاری قرار می‌گیرند که نشان‌دهنده تاثیر غیرمستقیم اما قابل توجه پدیده انسو بر رژیم رطوبتی خاورمیانه است که پیش‌تر توسط ناظم‌السادات و کوردی (۲۰۰۰) اثبات شده بود. در

3 . Model Interpretability


4 . Point Estimation

5 . Bootstrapping


6 . Best Performance

1 . Climate Memory


2 . Persistence



شکل ۴. میانگین اهمیت نسبی متغیرهای ورودی کل ایستگاه‌های مورد مطالعه (تأخیرهای زمانی و شاخص‌های پیوند از دور) برگرفته از تحلیل حساسیت مدل GA-MLP.



شکل ۵- نتایج تحلیل عدم قطعیت در برخی ایستگاه‌های مورد مطالعه



شکل ۶. تحلیل همبستگی بین عوامل توپوگرافی (ارتفاع/شیب) و RMSE مدل.

این، تحلیل جهت شیب (شکل ۶c و ۶f) توزیع متوازن خطا در جهات مختلف جغرافیایی را تایید می‌کند که نشان‌دهنده عدم وجود بایاس جهتی^۲ در ساختار یادگیری مدل است

نتیجه‌گیری

پژوهش حاضر با هدف گذر از محدودیت‌های مدل‌سازی کلاسیک و توسعه یک سامانه هوشمند و تفسیرپذیر برای پیش‌بینی ماهانه متغیرهای هیدرو-اقلیمی (بارش و دما) در شمال غرب ایران اجرا گردید. یافته‌های حاصل از ارزیابی جامع مدل هیبریدی پیشنهادی (GA-MLP) در مقایسه با مدل‌های رگرسیونی (MLR) و فازی (ANFIS)، نشان از برتری قاطع رویکرد تکاملی دارد؛ به‌طوری‌که این مدل موفق شد با بهبود ۲۰ تا ۳۰ درصدی در ایستگاه‌های منتخب و حل مشکل عدم همگرایی در مدل‌های پایه در هر دو متغیر، عملکردی پایدار و بهتر ارائه دهد. ریشه این ارتقای چشمگیر را می‌توان در دو عامل کلیدی جستجو کرد: نخست، بهره‌گیری از بهینه‌سازی

به منظور راستی‌آزمایی فیزیکی مدل و بررسی توانایی آن در مدیریت پیچیدگی‌های ژئومورفولوژیک منطقه، ارتباط بین خطای پیش‌بینی (RMSE) و پارامترهای توپوگرافی شامل ارتفاع، شیب و جهت شیب مورد واکاوی قرار گرفت. نتایج تحلیل همبستگی پیرسون که در شکل ۶ نمایش داده شده است، بیانگر استواری قابل توجه مدل هیبریدی GA-MLP در برابر ناهمگونی‌های مکانی است. همانطور که در نمودارهای پراکنش شکل ۶a و ۶d مشاهده می‌شود، همبستگی میان خطای بارش با ارتفاع ($r = 0.07$) و شیب ($r = 0.13$) بسیار ناچیز است؛ این یافته نشان می‌دهد که مدل پیشنهادی فارغ از تراز ارتفاعی ایستگاه‌ها (از دشت مغان تا ارتفاعات زرینه) و توپوگرافی منطقه، عملکردی یکنواخت و تعمیم‌پذیر دارد. همچنین در خصوص متغیر دما (شکل ۶b)، اگرچه همبستگی مثبت ضعیفی ($r = 0.38$) با ارتفاع مشاهده شد، اما این افزایش جزئی خطا با توجه به پدیده نرخ کاهش دما^۱ و نوسانات شدیدتر دمایی در مناطق کوهستانی قابل توجیه بوده و از نظر آماری معنادار نیست. علاوه بر

2 . Directional Bias

1 . Lapse Rate

سراسری تکاملی^۱، چرا که الگوریتم ژنتیک با جستجوی هوشمند در فضای پاسخ و اجتناب از تله‌های مینیمم محلی (که چالش بنیادین روش‌های آموزش کلاسیک مبتنی بر گرادیان نظیر پس‌انتشار خطا است)، ساختاری بهینه و مقاوم در برابر بیش‌برازش^۲ را برای شبکه عصبی فراهم آورده است. دوم، تفسیرپذیری ورودی‌ها^۳ و درک فیزیک مسئله است؛ تحلیل حساسیت و اهمیت ویژگی‌ها توانسته است با شناسایی صحیح دینامیک فیزیکی حاکم بر اقلیم منطقه از جمله وزن‌دهی بالا به خاصیت تداوم (تاخیرهای ۱ تا ۳ ماهه) و تشخیص شاخص نوسان اطلس شمالی (NAO) به عنوان مهم‌ترین سیگنال اقلیمی تطابق کاملی با واقعیت‌های هیدرولوژیکی و سینوپتیکی را نشان دهد. علاوه بر دقت و تفسیرپذیری، ثبات مکانی مدل در برابر ناهمگونی‌های

توپوگرافی بود؛ چنان‌که تحلیل همبستگی نشان داد دقت مدل وابستگی معناداری به تغییرات ارتفاع و شیب ایستگاه‌ها ندارد. نهایتاً، ارزیابی عدم قطعیت با روش بوت‌استرپ که پوشش آماری بالای ۹۵ درصد را برای پیش‌بینی‌ها نشان داد، مدل GA-MLP را به ابزاری قابل‌اعتماد و عملیاتی تبدیل می‌کند. با توجه به پتانسیل بالای مدل پیشنهادی، توصیه می‌شود در پژوهش‌های آینده، این ساختار هیبریدی با مدل‌های گردش عمومی جو (GCMs) تلفیق شود تا امکان پیش‌بینی‌های بلندمدت تحت سناریوهای تغییر اقلیم نیز فراهم گردد. همچنین بررسی اثرات نوسانات اقلیمی جدیدتر (مانند نوسان قطبی) بر دقت مدل می‌تواند افق‌های جدیدی را در پیش‌بینی‌های هیدرولوژیکی بگشاید.

1 . Evolutionary Global Optimization
2 . Overfitting
3 . Input Interpretability

منابع

۱. بابایی فینی، ا.، فتاحی، ا. ۱۳۹۴. پیش آگاهی فصلی دبی ورودی به دریاچه ارومیه با استفاده از سیگنال های بزرگ مقیاس اقلیمی. نشریه جغرافیا و توسعه، شماره ۴۰، ص ۱۲۴-۱۰۹.
۲. حضرتی یادکوری، ش. ۱۳۸۲. بررسی ارتباط تراز دریاچه ارومیه با شاخصهای اقلیمی ENSO و NAO. پایان نامه کارشناسی ارشد، دانشگاه صنعتی شریف.
۳. خسروی، م.، مسگری، ا. ۱۳۹۵. تحلیل فضایی روابط الگوهای پیوند از دور با دمای ماهانه شمال غرب ایران. نشریه جغرافیا و آمایش شهری- منطقه ای، شماره ۲۱.
۴. محمدخورشید دوست، ع.، قویدل رحیمی، ی. ۱۳۸۵. ارزیابی اثر پدیده انسو بر تغییر پذیری بارش های فصلی استان آذربایجان شرقی با استفاده از شاخص چند متغیره انسو. نشریه پژوهش های جغرافیایی- شماره ۵۷، صص ۲۶-۱۵.
۵. محمدخورشید دوست، ع.، قویدل رحیمی، ی.، یساری، ط. و نوری، ح. ۱۳۸۶. تحلیل نقش پدیده NAO در نوسانات سالانه بارش حوضه آبریز دریاچه ارومیه. فضای جغرافیایی دوره ۷، شماره ۱۹، صص ۸۶-۶۳.
۶. سیحانی، ب.، صلاحی، ب.، گل دوست، ا. ۱۳۹۳. ارتباط شاخص اقلیمی NAO با مقادیر میانگین حداکثر و حداقل دمای ماهانه شمال غرب ایران. نشریه تحقیقات کاربردی علوم جغرافیایی، سال چهاردهم، شماره ۳۳، صص ۹۰-۷۵.
۷. عزیززاده، م. ر.، جوان، خ. ۱۳۹۸. تحلیل روند شاخص های حدی بارش در حوضه دریاچه ارومیه و ارتباط آن با الگوهای پیوند از دور. نشریه علمی جغرافیا و برنامه ریزی، سال ۲۳، شماره ۷۰، صص ۲۴۷-۲۲۷.
۸. فاتحی مرج، ا.، داودی، م. و آرمان، ن. ۱۳۸۷. پیش بینی خشکسالی با استفاده از SOI و NINO3,4 و شبکه عصبی، راهکاری برای مقابله با آن. پنجمین همایش ملی علوم و مهندسی آبریزداران ایران (مدیریت پایدار بلایای طبیعی).
۹. قویدل رحیمی، ی.، فرج زاده، م. و کاکاپور، س. ۱۳۹۳. بررسی اثر الگوهای پیوند از دور شمال خزر بر نوسانات بارش های پاییزی مناطق غرب و شمال غرب ایران. نشریه پژوهشی جغرافیا و برنامه ریزی، سال ۱۸، شماره ۴۹، صص ۲۱۷-۲۳۰.
۱۰. میرهاشمی، ح.، حسونوند، ز. (۱۴۰۱). تأثیر الگوهای پیوند از دور بر بارش های ماهانه ایستگاه های شهر خرم آباد و کرمانشاه. مدل سازی و مدیریت آب و خاک، ۳ (۴): ۱۵۱-۱۳۳.
۱۱. ناظم السادات، س. ۱۳۷۸. بررسی پدیده النینو - نوسانات جنوبی (ENSO) بر بارندگی پاییزه ایران. کنفرانس منطقه ای تغییر اقلیم تهران: سازمان هواشناسی کشور.
12. Ahmadi, M., Kamangar, M., Salimi, S. et al. A new approach in evaluation impacts of teleconnection indices on temperature and precipitation in Iran. *Theor Appl Climatol* 150, 15-33 (2022). <https://doi.org/10.1007/s00704-022-04138-w>
13. Barnston, A. G., & Livezey, R. E. (1987). Classification, seasonality and persistence of low-frequency atmospheric circulation patterns. *Monthly Weather Review*, 115(6), 1083-1126.
14. Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? - Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247-1250. <https://doi.org/10.5194/gmd-7-1247-2014>
15. Ghasemi, A. R., & Khalili, D. (2006). The influence of the North Atlantic Oscillation on the winter precipitation of Iran. *Theoretical and Applied Climatology*, 85(3-4), 149-165. <https://doi.org/10.1007/s00704-005-0187-y>
16. Gupta, H. V., Kling, H., Yilmaz, K. K., & Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology*, 377(1-2), 80-91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>
17. Hagan, M. T., & Menhaj, M. B. (1994). Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, 5(6), 989-993. <https://doi.org/10.1109/72.329697>

18. Han, J., Pei, J., & Tong, H. (2011). *Data Mining: Concepts and Techniques* (3rd ed.). Morgan Kaufmann. <https://doi.org/10.1016/C2009-0-61819-5>
19. Haykin, S. (2009). *Neural Networks and Learning Machines* (3rd ed.). Pearson Education.
20. Helali, J. & Salimi, S. & Lotfi, M. & Hosseini, A. & Bayat, A. & Ahmadi, M. & Naderizarneh, S. (2020). Investigation of the effect of large-scale atmospheric signals at different time lags on the autumn precipitation of Iran's watersheds, *Arabian Journal of Geosciences*, 2020, 13:932. <https://doi.org/10.1007/s12517-020-05840-7>.
21. Hurrell, J. W. (1995). Decadal trends in the North Atlantic Oscillation: regional temperatures and precipitation. *Science*, 269(5224), 676-679.
23. IPCC. (2021). *Climate Change 2021: The Physical Science Basis*. Cambridge University Press.
24. Jang, J. S. (1993). ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665-685. <https://doi.org/10.1109/21.256541>
25. Jang, J.-S. R. (1993). ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665-685. <https://doi.org/10.1109/21.256541>
26. Kisi, O. (2005). Suspended sediment estimation using neuro-fuzzy and neural network approaches. *Hydrological Sciences Journal*, 50(4), 683-696. <https://doi.org/10.1623/hysj.2005.50.4.683>
27. Kisi, O. (2005). Suspended sediment estimation using neuro-fuzzy and neural network approaches. *Hydrological Sciences Journal*, 50(4), 683-696.
28. Koutsoyiannis, D. (2003). Climate change, the Hurst phenomenon, and hydrological statistics. *Hydrological Sciences Journal*, 48(1), 3-24. <https://doi.org/10.1623/hysj.48.1.3.43481>
29. Maier, H. R., & Dandy, G. C. (2000). Neural networks for the prediction and forecasting of water resources variables. *Environmental Modelling & Software*, 15(1), 101-124.
30. 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*, 50(3), 885-900. <https://doi.org/10.13031/2013.23153>
31. Nazemosadat M. J., Shahgholian, K. (2017) Heavy precipitation in southwest of Iran: association with the Madden-Julian Oscillation and synoptic scale analysis. *Climate Dynamics*, 49: 3091-3109
32. Nazemosadat M. J., Shahgholian, K., Ghaedamin, H., Nazemosadat, E. (2020) Introducing new climate indices for identifying wet/dry spells within a Madden-Julian oscillation phase. *International Journal of Climatology*, 41, E1686-E1699.
33. Nazemosadat, M. J., & Cordery, I. (2000). On the relationships between ENSO and autumn rainfall in Iran. *International Journal of Climatology*, 20(1), 47-61. [https://doi.org/10.1002/\(SICI\)1097-0088\(200001\)20:1<47::AID-JOC461>3.0.CO;2-W](https://doi.org/10.1002/(SICI)1097-0088(200001)20:1<47::AID-JOC461>3.0.CO;2-W)
34. Nazemosadat, M. J., A. R. Ghasemi and I. Cordery. 2003. The linkage between precipitation in Iran and NSW Australia. *The Proceeding of the Third Regional and First National Conference on Climate Change*, Isfahan, Iran.
35. Pakdaman, M., Babaeian, I., & Fathian, F. (2024). Monthly precipitation forecasting in the northwest of Iran using machine learning methods and teleconnection indices. *Journal of Climate Research*, 15(57), 1-16. <https://doi.org/10.22031/cr.2024.101235.1098>
36. Pakdaman, M., Babaeian, I., Javanshiri, Z., and Falamarzi, Y., 2022b, European multi model ensemble (EMME): A new approach for monthly forecast of precipitation. *Water Resources Management*, 36(2), 611-623.
37. Pakdaman, M., Falamarzi, Y., Babaeian, I., and Javanshiri, Z., 2020, Post-processing of the North American multi-model ensemble for monthly forecast of precipitation based on neural network models: Theoretical and Applied Climatology, 141(1-2), 405-41

38. Patro, S. G., & Sahu, K. K. (2015). Normalization: A preprocessing stage. *International Journal of Advanced Research in Computer Science and Software Engineering*, 5(3), 122–125. <https://doi.org/10.17148/IJARCCE.2016.5327>
39. Pourasghar F, Tozuka T, Jahanbakhsh S, Sari Sarraf B, Ghaemi H, Yamagata T (2012) The interannual precipitation variability in the southern part of Iran as linked to large-scale climate modes. *Climate Dynamics*, 39:2329-2341.
40. Pourasghar, F., Toofan, S., & Eslami, H. (2012). The relationship between North Atlantic Oscillation (NAO) and winter precipitation in Northwest Iran. *Theoretical and Applied Climatology*, 110(1–2), 85–93. <https://doi.org/10.1007/s00704-012-0594-2>
41. Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N., & Prabhat, F. (2019). Deep learning and process understanding for data-driven Earth system science. *Nature*, 566(7743), 195-204. <https://doi.org/10.1038/s41586-019-0912-1>
42. Ropelewski, C. F., & Halpert, M. S. (1987). Global and regional scale precipitation patterns associated with the El Niño/Southern Oscillation. *Monthly Weather Review*, 115(8), 1606-1626.
43. Seber, G. A. F., & Wild, C. J. (2003). *Nonlinear Regression*. Wiley-Interscience. <https://doi.org/10.1002/0471725315>
44. Shen, C. (2018). A transdisciplinary review of deep learning research and its relevance for water resources scientists. *Water Resources Research*, 54(11), 8558–8593. <https://doi.org/10.1029/2018WR022643>
45. Sola, J., & Sevilla, J. (1997). Importance of input data normalization for the application of neural networks to complex industrial problems. *IEEE Transactions on Nuclear Science*, 44(3), 1464–1468. <https://doi.org/10.1109/23.589532>
46. Tabari, H., Hosseinzadeh Talaei, P., Shifteh Some'e, B. and Willems, P., 2014. Possible influences of North Atlantic Oscillation on winter reference evapotranspiration in Iran, *Global and Planetary Change*, v.117, p.28-39.
47. Tabari, H., Hosseinzadeh Talaei, P., Shifteh Some'e, B., Willems, P. (2014), Possible influences of North
48. Vaheddoost, B., Aksoy, H. (2017). Structural characteristics of annual precipitation in Lake Urmia basin. *Theoretical and Applied Climatology* 128(3-4): 919–932.
49. Wallace, J. M., & Gutzler, D. S. (1981). Teleconnections in the geopotential height field during the Northern Hemisphere winter. *Monthly Weather Review*, 109(4), 784-812.
50. Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79–82. <https://doi.org/10.3354/cr030079>