

Evaluation of CANESM2 Temperature Bias Correction Using NARX (Case Study: Yazd Synoptic Station, Central Iran)

Mohammad Amin Asadi Zarch ^{1*}, Somayeh Ghaznavi ²

1. Assistant Professor, Faculty of Natural Resources and Desert Studies, Yazd University, Yazd, Iran

2. Ph.D. Student in Watershed Science and Engineering, Yazd University, Yazd, Iran

*Corresponding Author: amin.asadi@yazd.ac.ir

Received date: 31/07/2026

Accepted date: 28/09/2026



[10.22034/jdmal.2026.2096224.1535](https://doi.org/10.22034/jdmal.2026.2096224.1535)

Abstract

General Circulation Models (GCMs) are the primary tools for simulating climate change at the global scale, but systematic biases in their outputs limit their ability to reproduce local climatic conditions. This study aimed to correct temperature biases in CANESM2 model outputs using a Nonlinear AutoRegressive with eXogenous inputs (NARX) neural network at Yazd Synoptic Station from 2006 to 2020. The proposed NARX approach uses GCM-simulated temperatures as exogenous inputs and lagged observed temperatures as autoregressive inputs. This allows the network to learn nonlinear relationships and temporal dependencies between simulated and observed temperature series, improving systematic bias correction in climate model outputs. Monthly GCM temperature outputs and corresponding observations were used to train the NARX model. Its performance was evaluated using Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and Mean Absolute Error (MAE). Results showed that CANESM2 had considerable errors in reproducing monthly temperatures at Yazd, with MSE, RMSE, and MAE values of 35.83, 5.99, and 5.45, respectively. After NARX correction, these metrics fell to 5.21, 2.28, and 1.84, respectively, with MSE decreasing by more than 85%. Error histograms and response plots indicated good generalization and no overfitting. Monthly and seasonal analyses showed that NARX effectively corrected systematic biases in CANESM2 outputs, particularly during the cold season, and substantially reduced the dispersion of prediction errors. Overall, NARX offers an effective framework for correcting biases in climate-model temperature outputs and has considerable potential to improve climate data in arid regions such as central Iran.

Keywords: Machine learning; General circulation models; Climate change; Time series.

How to cite this article

Asadi Zarch, MA and Ghaznavi, S. (2026). Evaluation of CANESM2 Temperature Bias Correction Using NARX (Case Study: Yazd Synoptic Station, Central Iran). *Desert Management*, 14(1), 103-24. DOI: [10.22034/jdmal.2026.2096224.1535](https://doi.org/10.22034/jdmal.2026.2096224.1535)



Extended Abstract

Introduction

Climate change is one of the most critical environmental challenges of the twenty-first century. Rising greenhouse gas concentrations are driving long-term changes in temperature and precipitation and increasing the frequency and intensity of extreme climate events (11). Even modest temperature increases can substantially raise the likelihood of severe heatwaves (25), underscoring the need for reliable climate projections to inform water resource management, agriculture, infrastructure planning, and climate adaptation. Although Global Climate Models (GCMs) provide essential projections of future climate under different emission scenarios, their coarse spatial resolution and systematic biases limit their usefulness at local and regional scales (6). Statistical downscaling and bias-correction techniques are therefore essential for producing climate information suited to local decision-making (9). These challenges are especially significant in arid and semi-arid regions, where rising temperatures, declining precipitation, and recurrent droughts have increased environmental and socioeconomic vulnerabilities (16, 17). Recent advances in machine learning offer powerful tools for addressing the nonlinear characteristics of climate data and improving GCM output accuracy. Among these methods, the Nonlinear Autoregressive Network with Exogenous Inputs (NARX) has shown a strong ability to learn temporal dependencies and correct systematic model errors (15, 28). Using NARX as a bias-correction framework therefore offers a promising way to improve the reliability of local-scale temperature projections and support more effective climate adaptation and resource management in vulnerable dry regions.

Materials and Methods

This study used long-term temperature observations from the Yazd synoptic station (Table 1). Daily observations were quality-controlled and examined before being converted into monthly mean temperatures, the target variable. Monthly mean temperatures from the CanESM2 climate model were used as the exogenous input to the NARX network. The study period (1966–2020) was divided into a development period (1966–2005), used to train the network, and an independent evaluation period (2006–2020), used to assess its performance. Before entering the network, the input and target data were normalized to the range (-1,1) using the mapminmax function (Equation 1). Normalization parameters were calculated using only the development period (1966–2005) and then applied unchanged to the independent evaluation period (2006–2020). Therefore, the evaluation data were not used to determine the normalization parameters. Systematic biases in simulated temperatures were corrected using a Nonlinear Autoregressive Network with Exogenous Inputs (NARX). The general form of the NARX model is given in equation 2, while the hidden-layer and output relationships are calculated using equations 3 and 4, respectively.

During training, a Series-Parallel architecture was used because the observed target values were available. In this configuration, the actual previous target values were fed back into the network. The NARX relationship, input vector, and network output were defined by equations 5, 6, and 7, respectively (24). After training, the network was converted to the Parallel configuration for independent prediction, with each predicted output fed back as the input at the next time step. Thus, observed temperature values from the independent evaluation period were not used as feedback during prediction. The GDX learning algorithm optimized the network weights to reduce prediction error, and the weight-update procedure was defined by equations 8 and 9.

Model performance was evaluated using the mean squared error (MSE), root squared error (RMSE), and mean absolute error (MAE), calculated using Equations 10 and 12, respectively. These error measures for the NARX-corrected results were also compared with those for the raw CanESM2 outputs to assess the reduction in systematic bias.

Results

This study assessed the ability of the CANESM2 global climate model and a Nonlinear Autoregressive Network with Exogenous Inputs (NARX) to improve monthly mean temperature simulations at the Yazd synoptic station in Iran. Long-term observations (1966–2020) showed a gradual warming trend, particularly after 2000, while retaining the seasonal temperature cycle (Fig. 1a). Although raw CANESM2 simulations reproduced the general seasonal variability in temperature during 1966–2005, they showed noticeable biases, especially in cold seasons and during extreme temperature events, highlighting the need for systematic bias correction (Figs. 1 b and 2). To address these shortcomings, a NARX neural network with 10 hidden neurons was developed to learn the nonlinear relationship between observed and simulated temperatures (Fig. 3). Training converged rapidly, within approximately ten epochs, and showed stable validation performance

with no evidence of overfitting, indicating strong learning efficiency and generalization capability (Fig. 4 a). Error histogram, regression, and response analyses further supported the model's robustness: error distributions were centered around zero, predicted and observed values agreed closely, and predictive performance was strong across the training, validation, and testing datasets (Figs. 4 b, 5, 6). Correlation coefficients were 0.98, 0.97, 0.97, and 0.98 for the training, validation, testing, and overall datasets, respectively (Fig 5). Prediction- error comparisons showed that NARX substantially reduced error magnitude and variability relative to CANESM 2, yielding a more symmetric error distribution and minimizing systematic temporal biases (Figs. 7a, 7 b). As a result, the corrected temperature series closely matched observed monthly variability throughout 2006–2020 (Fig. 8). Quantitative evaluation confirmed substantial improvement after bias correction: MSE decreased from 35.3583 to 5.21, MAE from 5.45 to 1.84, and RMSE from 5.99 to 2.28 (Table 2). Monthly and seasonal analyses also showed that NARX effectively removed CANESM 2's persistent positive bias across all months and seasons- particularly in winter and spring- while substantially reducing error variability (Figs. 9 a, 9b). Overall, these findings demonstrate that NARX- based bias correction offers a reliable and efficient framework for improving the local- scale accuracy of GCM temperature projections, supporting more reliable climate change impact assessments and adaptation planning in arid regions.

Discussion and Conclusions

The results show that the NARX neural network effectively corrects systematic biases in CANESM2 temperature simulations for the arid region of Yazd. Compared with the raw GCM outputs, the bias-corrected series improved substantially across all statistical performance metrics, including RMSE, MAE, and MSE; RMSE, for example, decreased from 35.83 to 5.49. The corrected data also agreed closely with observed temperature records, with correlation coefficients above 0.98 and error distributions centered around zero. Monthly and seasonal analyses further confirmed that the NARX model reduced CANESM2's persistent warm bias, especially in winter and spring, while preserving seasonal temperature variability. These results are consistent with previous studies showing the effectiveness of machine-learning approaches in climate downscaling and bias correction (15, 28). They also align with recent investigations reporting that advanced deep-learning models can substantially reduce systematic GCM biases while preserving the temporal characteristics of climate variables (8, 14). The present results show that the relatively simple NARX architecture can achieve comparable improvements in temperature bias correction with lower computational complexity. Consequently, the proposed approach offers a practical way to generate high-quality climate information to support drought assessment, water resource management, agricultural planning, and climate adaptation strategies in vulnerable arid and semi-arid regions.

Keywords: Machine learning; General circulation models; Climate change; Time series.

Table 1. characteristics of the Yazd Synoptic Station

Establishment Year	County	Elevation (m)	Longitude	Latitude
1961	Yazd	1230	54°17'	56°53'

$$x_n = 2 \left(\frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) - 1 \quad \text{Equation (1)}$$

$$\hat{y}(t+1) = f(\hat{y}(t), \hat{y}(t-1), \dots, \hat{y}(t-n_y), u(t), u(t-1), \dots, u(t-n_u)) \quad \text{Equation (2)}$$

$$z_j(t) = \sum_{i=1}^m w_{ji} x_i(t) + b_j \quad \text{Equation (3)}$$

$$h_j(t) = \phi(z_j(t)) \quad \text{Equation (4)}$$

$$\hat{y}(t+1) = f(y(t), y(t-1), \dots, y(t-n_y), u(t), u(t-1), \dots, u(t-n_u)) \quad \text{Equation (5)}$$

$$X(t) = [y(t), y(t-1), \dots, y(t-n_y), u(t), u(t-1), \dots, u(t-n_u)] \quad \text{Equation (6)}$$

$$\hat{y}(t+1) = F(X(t)) \quad \text{Equation (7)}$$

$$\Delta w(t) = \alpha \Delta w(t-1) - \eta \frac{\partial E}{\partial w} \quad \text{Equation (8)}$$

$$w(t+1) = w(t) + \Delta w(t) \quad \text{Equation (9)}$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2 \quad \text{Equation (10)}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad \text{Equation (11)}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - x_i| \quad \text{Equation (12)}$$

x : is the original value, x_n : normalized value, x_{min} and x_{max} : minimum and maximum reference values used for normalization. f : Nonlinear function learned by the neural network, $u(t)$: Exogenous input at time t , $y(t)$: Actual target variable at time t , $\hat{y}(t)$: Predicted output at time t , n_y : Number of output delays, n_u : Number of input delays, w_{ji} : Connection weight between input i and neuron j , b_j : Neuron bias, z_j : Weighted sum of inputs to neuron j , ϕ : Network activation function, F : Function learned by the neural network, η : Learning rate, α : Momentum coefficient, E : Network error, y_i : Observed monthly mean temperature, x_i : NARX bias-corrected monthly mean temperature, n : Number of observations.




Fig. 1. Monthly mean air temperature at the Yazd Synoptic Station, 1966–2020: (a) Simulated monthly mean temperature at the station during the historical period (1966–2005), using the CANESM2 climate model; (b)

Table 2. Error metrics comparing observed and simulated monthly mean temperatures from the CANESM2 and NARX bias-corrected models at Yazd synoptic station during the validation period (2006–2020).

	RMSE	MAE	MSE
CANESM2	35.83	5.99	5.45
NARX	5.21	2.28	1.84




Fig. 2. Comparison of observed and simulated monthly mean temperatures at Yazd synoptic station from the CANESM2 model during 2006–2020.




Fig. 3. Structure of the NARX neural network used in this study.




Fig. 4. NARX neural network training performance based on the Mean Squared Error (MSE) criterion (a) and error histogram during training (b).




Fig. 5. Linear regression between target values and NARX network outputs.




Fig. 6. NARX neural network error response plot.




Fig. 7. Distribution of temperature prediction errors for the CANESM2 model and the NARX neural network-corrected model. (a) Temporal analysis of temperature errors from the CANESM2 model and the NARX bias-corrected model. (b)




Fig. 8. Comparison of observed, CANESM2-simulated, and NARX bias-corrected monthly mean temperatures at the Yazd synoptic station over the validation period (2006–2020).





Fig. 9. (a) Comparison of monthly mean temperature prediction errors for the CANESM2 model and the NARX bias-corrected model; (b) Comparison of seasonal mean temperature prediction errors for the CANESM2 and NARX models.



ارزیابی قابلیت NARX برای تصحیح خطای دمای داده‌های CANESM2 در ایستگاه همدیدی یزد

محمد امین اسدی^{۱*}، سمیه غزنوی^۲

۱. استادیار، دانشکده منابع طبیعی و کویرشناسی، دانشگاه یزد.

۲. دانشجوی دکتری علوم و مهندسی آبخیزداری، دانشگاه یزد.

* نویسنده مسئول: amin.asadi@yazd.ac.ir

تاریخ پذیرش: ۱۴۰۵/۰۷/۰۶

تاریخ دریافت: ۱۴۰۵/۰۵/۰۹



[10.22034/jdmal.2026.2096224.1535](https://doi.org/10.22034/jdmal.2026.2096224.1535)

چکیده

مدل‌های گردش عمومی جو ابزارهای اصلی برای شبیه‌سازی تغییر اقلیم در مقیاس جهانی هستند، اما خروجی آنها معمولاً دارای خطاهای نظامی (سیستماتیک) است و در بازتولید مقدارهای واقعی متغیرهای اقلیمی در مقیاس محلی، با محدودیت‌هایی مواجه است. هدف پژوهش حاضر، تصحیح خطای خروجی دمای مدل CANESM2 با بهره‌گیری از شبکه عصبی NARX در ایستگاه همدیدی یزد طی دوره ۲۰۰۶ تا ۲۰۲۰ است. مزیت اصلی روش پیشنهادی مبتنی بر شبکه عصبی NARX، بهره‌گیری همزمان از خروجی‌های دمایی مدل GCM به‌عنوان ورودی‌های برون‌زا و مقدارهای گذشته دمای مشاهده‌ای به‌عنوان ورودی‌های خودبازگشتی است. این ساختار امکان یادگیری همزمان روابط غیرخطی و وابستگی‌های زمانی بین داده‌های شبیه‌سازی‌شده و مشاهدات محلی را فراهم می‌کند و در نتیجه، دقت تصحیح خطاهای نظام‌مند خروجی مدل اقلیمی را افزایش می‌دهد. در پژوهش حاضر، داده‌های خروجی مدل GCM و داده‌های مشاهده‌ای به‌صورت ماهانه تهیه شد و پس از آموزش مدل NARX، ارزیابی عملکرد مدل در تصحیح خطا، براساس شاخص‌های آماری MSE، RMSE و MAE انجام شد. نتایج نشان داد که مدل CANESM2 دارای خطای قابل توجهی در بازتولید دمای ماهانه ایستگاه یزد است؛ به‌طوری که MSE برابر با ۳۵/۸۳، RMSE برابر با ۵/۹۹ و MAE برابر با ۵/۴۵ محاسبه شد. پس از اعمال شبکه NARX، مقدارهای خطا به‌ترتیب به ۲/۲۸، ۵/۲۱ و ۱/۸۴ کاهش یافت که بیانگر کاهش بیش از ۸۵٪ در خطای MSE است. تحلیل هیستوگرام خطا و نمودارهای پاسخ، نشان‌دهنده تعمیم‌پذیری مناسب و عدم بیش‌برازش مدل بود. تحلیل‌های ماهانه و فصلی نشان‌داد که شبکه NARX توانسته است خطاهای سیستماتیک خروجی‌های مدل CANESM2 را، به‌ویژه در ماه‌های سرد سال، برطرف کرده و پراکندگی خطا را به‌طور معناداری کاهش دهد. شبکه NARX برای اصلاح خطای داده‌های اقلیمی در مناطق خشک مانند ایران مرکزی می‌تواند کاربرد مؤثر داشته باشد.

واژگان کلیدی: یادگیری ماشین؛ مدل‌های گردش عمومی جو؛ تغییر اقلیم؛ سری زمانی

استناد به این مقاله

اسدی، محمدامین و غزنوی، سمیه. (۱۴۰۵). ارزیابی قابلیت NARX برای تصحیح خطای دمای داده‌های CANESM2 در ایستگاه همدیدی یزد. مدیریت بیابان، ۱۴(۱)، ۱۰۳-۱۲۴. DOI: [10.22034/jdmal.2026.2093286.1532](https://doi.org/10.22034/jdmal.2026.2093286.1532)



■ مقدمه

تغییر اقلیم در دهه‌های اخیر با افزایش میانگین دما و تغییر در فراوانی و شدت رخداد‌های حدی، به یکی از چالش‌های مهم محیط‌زیستی تبدیل شده است (۱۱، ۲۵). این مسئله در مناطق خشک و نیمه‌خشک اهمیت بیشتری دارد؛ زیرا محدودیت منابع آب، تبخیر زیاد و حساسیت فعالیت‌های کشاورزی و انسانی، آسیب‌پذیری این مناطق را در برابر تغییرات اقلیمی افزایش می‌دهد (۱۶، ۱۷، ۱۸). در چنین شرایطی، دستیابی به برآوردهای قابل‌اعتماد از تغییرات دمایی در مقیاس محلی برای ارزیابی پیامدهای تغییر اقلیم و برنامه‌ریزی منابع ضروری است.

مدل‌های اقلیمی جهانی در چارچوب پروژه‌های مقایسه‌ای بین‌مدل‌ها، از جمله CMIP^۱، برای شبیه‌سازی و ارزیابی تغییر سامانه اقلیم در مقیاس‌های مختلف به‌کار گرفته شده‌اند (۶). از این بین، مدل‌های گردش عمومی اقلیم^۲ (GCM) از ابزارهای اصلی شبیه‌سازی اقلیم گذشته و آینده هستند، اما به‌دلیل وضوح مکانی به‌نسبت کم و محدودیت در بازنمایی برخی فرایندهای محلی، ممکن است خروجی آنها در مقیاس ایستگاهی دارای سوگیری باشند (۹). این خطاها می‌توانند قابلیت استفاده مستقیم از خروجی مدل‌های اقلیمی را در بررسی‌های محلی کاهش دهند. بنابراین در بررسی منطقه‌ای و ایستگاهی، تصحیح خطا خروجی GCM ضروری است. روش‌های آماری یکی از رویکردهای متداول برای کاهش این سوگیری‌ها هستند و می‌توانند اختلاف میان توزیع داده‌های شبیه‌سازی شده و مشاهده‌شده را کاهش دهند (۲۱، ۲۶).

در میان روش‌های تصحیح آماری، نگاشت چارکی^۳ به‌دلیل توانایی در اصلاح توزیع آماری متغیرهای اقلیمی، یکی از روش‌های پرکاربرد برای تصحیح خروجی مدل‌های اقلیمی است. نشان داده شده است که روش‌های تصحیح آماری می‌توانند شبیه‌سازی میانگین و دامنه دمایی روزانه، از جمله دمای حداقل و حداکثر، را بهبود دهند (۲۱). همچنین، عملکرد روش‌های نگاشت چارکی را در اصلاح چارک‌ها و بازنمایی مقدارهای حدی بررسی شده‌است (۳).

در ایران نیز کاربرد روش نگاشت چارکی برای کاهش سوگیری داده‌های اقلیمی و خروجی‌های CMIP^۴ بررسی شده‌است (۲۳). این بررسی‌ها نشان می‌دهند که تصحیح آماری نقش مؤثری در افزایش قابلیت استفاده از داده‌های مدل‌های اقلیمی برای بررسی‌های محلی دارد.

در کنار روش‌های آماری، روش‌های یادگیری ماشین به‌دلیل توانایی در شناسایی روابط غیرخطی و وابستگی‌های زمانی پیچیده، در مدل‌سازی و پیش‌بینی سری‌های زمانی اقلیمی و هیدرولوژیک مورد توجه قرار گرفته‌اند (۴، ۷، ۱۲، ۱۳، ۳۰). مدل NARX^۵ نیز با استفاده از مقدارهای گذشته متغیر هدف و ورودی‌های برون‌زا، قابلیت مدل‌سازی روابط غیرخطی و پویایی‌های زمانی سری‌های زمانی را دارد (۲، ۵، ۳۱). کاربرد NARX در پیش‌بینی متغیرهای اقلیمی و محیطی در بررسی‌های پیشین گزارش شده است (۱۵). به‌طور مشخص، عملکرد شبکه NARX را در پیش‌بینی دمای خاک بررسی کردند و قابلیت این شبکه در بازنمایی وابستگی‌های زمانی دما نشان داده شده‌است (۳۱). همچنین، مدل توجه‌محور^۶ نیز برای تصحیح سوگیری زمانی^۷ داده‌های اقلیمی ارائه شد که با هدف بهبود بازنمایی ویژگی‌های زمانی رویدادهای گرمایی به کار گرفته شد (۱۹). در سال‌های اخیر، کاربرد روش‌های یادگیری ماشین و یادگیری عمیق در بررسی‌های هواشناسی و اقلیم، از جمله تصحیح سوگیری خروجی مدل‌های اقلیمی، گسترش یافته است (۸، ۱۹، ۲۰، ۲۹). برخی بررسی‌ها نیز با تمرکز بر وابستگی‌های زمانی، قابلیت روش‌های یادگیری ماشین را در اصلاح سوگیری‌های زمانی خروجی مدل‌های اقلیمی بررسی کرده‌اند (۱۹، ۱۴).

با وجود پیشرفت‌های حاصل‌شده در استفاده از روش‌های آماری و یادگیری ماشین، کاربرد شبکه‌های عصبی بازگشتی، به‌ویژه NARX، برای تصحیح خطای خروجی دمای مدل‌های اقلیمی جهانی در مقیاس ایستگاهی و در شرایط اقلیمی خشک ایران کمتر مورد

^۴ Coupled Model Intercomparison Project Phase 6^۵ Nonlinear AutoRegressive with eXogenous inputs (NARX)^۶ Attention-based^۷ Temporal Bias^۱ Coupled Model Intercomparison Project^۲ General Circulation Models (GCM)^۳ Quantile Mapping

توجه قرار گرفته است. اگرچه بررسی‌های پیشین قابلیت NARX را در مدل‌سازی وابستگی‌های زمانی و روابط غیرخطی متغیرهای اقلیمی و محیطی نشان داده‌اند، شواهد مربوط به استفاده از این ساختار برای تصحیح خطای دمای خروجی مدل‌های اقلیمی جهانی و ارزیابی آن در برابر داده‌های مشاهده‌شده ایستگاهی، به‌ویژه در مناطق خشک ایران، محدود است. افزون بر این، عملکرد روش‌های تصحیح خطا به شرایط اقلیمی و جغرافیایی منطقه وابسته است و نتایج حاصل از یک منطقه لزوماً قابل تعمیم به مناطق دیگر نیست. از این رو، بررسی عملکرد NARX در یک ایستگاه واقع در محیط خشک می‌تواند شواهد مشخص‌تری درباره قابلیت این شبکه در کاهش سوگیری دمایی خروجی مدل اقلیمی فراهم کند (۱۷، ۱۸)

ایستگاه همدیدی یزد به‌دلیل قرارگیری در منطقه خشک و برخورداری از ویژگی‌های اقلیمی خاص، نمونه مناسبی برای بررسی عملکرد یک روش داده‌محور در تصحیح خطای دمای خروجی مدل اقلیمی است. بنابراین استفاده از داده‌های بلندمدت مشاهده‌شده این ایستگاه، همراه با خروجی مدل CANESM2^۱، امکان ارزیابی عملکرد شبکه NARX را در شرایط اقلیمی خشک و امکان نزدیک‌کردن آن به داده‌های مشاهده‌شده را فراهم می‌کند. هدف پژوهش حاضر، ارزیابی عملکرد شبکه NARX در اصلاح خطای دمای خروجی مدل اقلیمی CANESM2 برای ایستگاه همدیدی یزد است. در پژوهش حاضر، شبکه با استفاده از داده‌های دوره ۱۹۶۶ تا ۲۰۰۵ (۱۳۴۵ تا ۱۳۸۴) توسعه و آموزش داده شد و عملکرد پایانی آن با استفاده از داده‌های مستقل دوره ۲۰۰۶ تا ۲۰۲۰ (۱۳۸۵ تا ۱۳۹۹) ارزیابی شد.

■ مواد و روش‌ها

معرفی منطقه مورد بررسی و داده‌های مورد استفاده

ایستگاه سینوپتیک یزد با بیش از ۶۰ سابقه آماری، از ایستگاه‌های دارای دوره آماری بلندمدت در استان یزد است. این ایستگاه در شهرستان یزد و در ارتفاع ۱۲۳۰m

از سطح دریا قرار دارد (جدول ۱). در پژوهش حاضر، داده‌های دمایی مشاهده‌شده ایستگاه یزد در مقیاس روزانه دریافت و پس از کنترل، بررسی و آماده‌سازی، به مقیاس ماهانه تبدیل شدند. سپس، دمای متوسط ماهانه به‌عنوان متغیر هدف در مدل‌سازی مورد استفاده قرار گرفت. خروجی دمای میانگین ماهانه مدل اقلیمی CANESM2 نیز به‌عنوان متغیر ورودی خارجی در نظر گرفته شد. دوره زمانی مورد استفاده در پژوهش حاضر شامل سال‌های ۱۹۶۶ تا ۲۰۲۰ (۱۳۴۵ تا ۱۳۹۹) بود. این دوره به دو بخش تقسیم شد: دوره ۱۹۶۶ تا ۲۰۰۵ (۱۳۴۵ تا ۱۳۸۴) برای توسعه شبکه NARX و دوره ۲۰۰۶ تا ۲۰۲۰ (۱۳۸۵ تا ۱۳۹۹) برای ارزیابی مستقل عملکرد شبکه مورد استفاده قرار گرفت. داده‌های دوره ۱۹۶۶ تا ۲۰۰۵ (۱۳۴۵ تا ۱۳۸۴) با حفظ توالی زمانی به سه مجموعه شامل ۷۰٪ آموزش، ۱۵٪ اعتبارسنجی و ۱۵٪ آزمون داخلی تقسیم شدند. مجموعه آموزش برای تنظیم وزن‌ها و بایاس‌های شبکه، مجموعه اعتبارسنجی برای پایش فرآیند یادگیری و کنترل بیش‌برازش، و مجموعه آزمون داخلی برای ارزیابی عملکرد شبکه پس از فرآیند آموزش مورد استفاده قرار گرفت. دوره ۲۰۰۶ تا ۲۰۲۰ (۱۳۸۵ تا ۱۳۹۹) نیز شامل ۱۸۰ مشاهده ماهانه بود و بدون دخالت در فرآیند آموزش، اعتبارسنجی و تنظیم شبکه، برای ارزیابی مستقل نهایی مدل مورد استفاده قرار گرفت.

نرمال‌سازی داده‌ها

به‌منظور کاهش اثر اختلاف مقیاس داده‌ها و بهبود پایداری فرآیند آموزش شبکه، داده‌های ورودی و هدف پیش از ورود به شبکه NARX نرمال‌سازی شدند. در پژوهش حاضر، از روش نگاشت حداقل-حداکثر با استفاده از تابع mapminmax استفاده شد. پارامترهای مورد نیاز برای نرمال‌سازی، تنها از داده‌های دوره توسعه مدل، یعنی ۱۹۶۶ تا ۲۰۰۵ (۱۳۴۵ تا ۱۳۸۴)، استخراج شدند. سپس همان پارامترهای به‌دست‌آمده از دوره توسعه برای نرمال‌سازی داده‌های دوره ارزیابی مستقل ۲۰۰۶ تا ۲۰۲۰ (۱۳۸۵ تا ۱۳۹۹) مورد استفاده قرار گرفتند. بنابراین، داده‌های دوره ارزیابی مستقل در تعیین پارامترهای

¹ Canadian Earth System Model version 2 (CanESM2)

مقدارهای گذشته خروجی، از متغیرهای ورودی برونزا نیز استفاده می‌کند. برخلاف مدل‌های خطی ARX، مدل NARX قادر است روابط غیرخطی میان متغیرهای ورودی و خروجی را با استفاده از یک شبکه عصبی یادگیری کند. فرم کلی مدل NARX به صورت رابطه (۲) بیان شد:

(۲)

$$\hat{y}(t+1) = f(\hat{y}(t), \hat{y}(t-1), \dots, \hat{y}(t-n_y), u(t), u(t-1), \dots, u(t-n_u))$$

که در آن f تابع غیرخطی یادگیری شده توسط شبکه، u متغیر ورودی خارجی و $\hat{y}$ متغیر هدف است. در پژوهش حاضر، دمای متوسط ماهانه خروجی مدل CANESM2 به عنوان ورودی خارجی و دمای متوسط ماهانه مشاهده شده در ایستگاه همدیدی یزد به عنوان متغیر هدف در نظر گرفته شد. همچنین n_y و n_u به ترتیب تعداد تأخیرهای خروجی و ورودی هستند. در پژوهش حاضر، تأخیرهای ورودی و بازخوردی در بازه ۱ تا ۲ گام زمانی تعریف شدند؛ بنابراین، $(n_u = 2)$ و $(n_y = 2)$ در نظر گرفته شد. با توجه به ماهانه بودن داده‌ها، این تأخیرها بیانگر استفاده از اطلاعات دو ماه گذشته متغیر ورودی و متغیر هدف در ساختار شبکه بودند. در پژوهش حاضر، تابع غیرخطی f با استفاده از یک شبکه عصبی پیش‌خور^۱ تقریب زده شد. ساختار کلی شبکه عصبی شامل لایه ورودی، یک یا چند لایه پنهان و لایه خروجی بود. خروجی هر نورون در لایه پنهان شبکه به صورت روابط (۳) و (۴) محاسبه شد:

$$z_j(t) = \sum_{i=1}^m w_{ji}x_i(t) + b_j \quad (3)$$

$$h_j(t) = \phi(z_j(t)) \quad (4)$$

در آن w_{ji} وزن اتصال بین ورودی i و نورون j ؛ b_j بایاس نورون^۲، z_j مجموع وزنی ورودی‌ها و ϕ تابع فعال‌سازی شبکه بود. در پژوهش حاضر، وزن‌ها و بایاس‌های شبکه طی فرایند آموزش تعیین شدند و رابطه غیرخطی بین خروجی مدل اقلیمی و داده‌های مشاهده شده بازسازی شد.

نرمال‌سازی دخالت داده نشدند. تبدیل داده‌ها به بازه (۱، ۱-) به صورت رابطه (۱) انجام شد:

$$x_n = 2 \left(\frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) - 1 \quad (1)$$

که در آن x مقدار اولیه، (x_n) مقدار نرمال شده و $x_{\min}$ و $x_{\max}$ حداقل و حداکثر مقدارهای مرجع مورد استفاده در فرآیند نرمال‌سازی بودند. پس از تولید خروجی شبکه، مقدارهای پیش‌بینی شده با استفاده از همان پارامترهای نرمال‌سازی به مقیاس اصلی دما بازگردانده شدند.

داده‌های مدل اقلیمی CANESM2 و سناریو RCP8.5

برای شبیه‌سازی اقلیم آینده، خروجی مدل سیستم اقلیمی کانادا (CANESM2) با سناریوی انتشار RCP8.5 مورد استفاده قرار گرفت (۲۷). CANESM2 یکی از مدل‌های سامانه زمینی مورد استفاده در شبیه‌سازی اقلیم است و توسعه و ارزیابی نسخه‌های مختلف آن در بررسی مربوط به مدل‌سازی سامانه زمین گزارش شده است (۱). داده‌های مدل برای متغیر دمای متوسط ماهانه دریافت و با داده‌های مشاهده شده ایستگاه همدیدی یزد هم‌مقیاس شدند. در پژوهش حاضر، داده‌های مدل در دوره تاریخی برای آموزش شبکه NARX و داده‌های مربوط به دوره آینده برای تولید دمای تصحیح شده مورد استفاده قرار گرفتند. سناریوی RCP8.5 نیز به عنوان مسیر انتشار با شدت زیاد در نظر گرفته شد و خروجی مدل CANESM2 تحت این سناریو برای بررسی تغییرات دمایی و اصلاح خطای نظام‌مند مدل اقلیمی به کار گرفته شد.

معرفی مدل NARX

مدل شبکه عصبی خودبازگشتی غیرخطی با ورودی‌های خارجی (NARX) تعمیم غیرخطی مدل‌های خودبازگشتی با ورودی خارجی (ARX) است که برای مدل‌سازی سیستم‌های دینامیکی غیرخطی و سری‌های زمانی پیچیده مورد استفاده قرار گرفت (۲، ۵). تفاوت اصلی NARX با شبکه NAR در آن است که در NAR، پیش‌بینی متغیر هدف تنها بر اساس مقدارهای گذشته همان متغیر انجام می‌شود، درحالی‌که NARX علاوه بر

^۱ Feed-forward Neural Network

^۲ Neuron Bias

جدول ۱. اطلاعات مربوط به ایستگاه همدیدی یزد

نام ایستگاه	نوع ایستگاه	سال تاسیس	شهرستان	ارتفاع	طول جغرافیایی	عرض جغرافیایی
یزد	همدیدی	۱۳۴۰ (۱۹۶۱)	یزد	۱۲۳۰	۵۴° ۱۷'	۵۶° ۵۳'

طراحی و آموزش شبکه NARX

در پژوهش حاضر، شبکه NARX با یک لایه پنهان شامل ۱۰ نورون طراحی شد. این ساختار با هدف تأمین ظرفیت مناسب برای یادگیری روابط غیرخطی بین متغیرهای ورودی و خروجی و جلوگیری از افزایش غیرضروری پیچیدگی شبکه در نظر گرفته شد. در شبکه NARX، استفاده از مقادیرهای گذشته متغیر خروجی موجب ایجاد حافظه زمانی در مدل شد. در مرحله آموزش، به دلیل در دسترس بودن مقادیرهای واقعی دمای مشاهده شده، از ساختار سری-موازی^۱ استفاده شد. در این ساختار، مقادیرهای واقعی خروجی در زمان‌های گذشته، یعنی $y(t-1)$ و $y(t-2)$ ، به عنوان ورودی‌های بازخوردی به شبکه داده شدند (شکل ۳)؛ بنابراین، شبکه در هر گام زمانی رابطه بین مقادیرهای گذشته مشاهده شده، مقادیرهای گذشته ورودی خارجی و مقدار هدف در زمان جاری را یاد گرفت. استفاده از مقادیرهای واقعی در مسیر بازخورد، امکان آموزش پایدار شبکه و یادگیری رابطه بین داده‌های CANESM2 و دمای مشاهده شده را فراهم کرد (۱۰).

پس از پایان آموزش و در مرحله پیش‌بینی مستقل، ساختار شبکه به حالت موازی^۲ تبدیل شد. در این حالت، مقادیرهای واقعی دما در دوره پیش‌بینی به شبکه داده نشدند و خروجی پیش‌بینی شده شبکه در هر گام زمانی به عنوان ورودی بازخوردی برای گام بعدی مورد استفاده قرار گرفت. در نتیجه، شبکه در دوره مستقل ارزیابی به صورت بازگشتی از خروجی‌های پیش‌بینی شده خود استفاده کرد و دمای تصحیح شده را بدون استفاده از مقادیرهای مشاهده شده دوره ۱۳۸۵ تا ۱۳۹۹ (۲۰۰۶ تا ۲۰۲۰) تولید کرد. به این ترتیب، تفاوت میان دو ساختار در پژوهش حاضر به این صورت بود که در مرحله آموزش از مقادیرهای واقعی خروجی برای بازخورد استفاده شد، در حالیکه در مرحله پیش‌بینی مستقل، خروجی‌های

پیش‌بینی شده شبکه در مسیر بازخورد قرار گرفتند. در ساختار سری-موازی مورد استفاده در مرحله آموزش، رابطه NARX به صورت رابطه (۵) محاسبه شد (۲۴):

(۵)

$$\hat{y}(t+1) = f(y(t), y(t-1), \dots, y(t-n_y), u(t), u(t-1), \dots, u(t-n_u))$$

که در آن y نشان‌دهنده خروجی واقعی سیستم یعنی دمای مشاهده شده ایستگاه یزد در زمان t ، بود.

برای ساختار سری-موازی مورد استفاده در مرحله آموزش، بردار ورودی شبکه به صورت رابطه (۶) تعریف شد:

(۶)

$$X(t) = [y(t), y(t-1), \dots, y(t-n_y), u(t), u(t-1), \dots, u(t-n_u)]$$

و خروجی شبکه به صورت تابعی از این بردار ورودی محاسبه شد (رابطه ۷):

(۷)

$$\hat{y}(t+1) = F(X(t))$$

که در آن F تابع یادگیری شده توسط شبکه عصبی بود.

فرآیند آموزش شبکه با هدف کاهش اختلاف بین خروجی واقعی و خروجی پیش‌بینی شده انجام شد و وزن‌ها و بایاس‌های شبکه به گونه‌ای تنظیم شدند که خطای آموزش به حداقل برسد.

برای بهینه‌سازی وزن‌ها و کاهش مقدار خطا، از خوارزمیک (الگوریتم) GDX^3 استفاده شد. در این خوارزمیک، تغییر وزن‌ها با در نظر گرفتن جهت گرادیان خطا و مقدار مومنوم قبلی مطابق روابط ۸ و ۹ انجام شد:

$$\Delta w(t) = \alpha \Delta w(t-1) - \eta \frac{\partial E}{\partial w} \quad (۸)$$

$$w(t+1) = w(t) + \Delta w(t) \quad (۹)$$

که در آن η نرخ یادگیری، α ضریب مومنوم و E تابع خطای شبکه بود. استفاده هم‌زمان از مومنوم و نرخ یادگیری تطبیقی باعث افزایش سرعت همگرایی و بهبود

³ Gradient descent with momentum and adaptive learning rate backpropagation (GDX)

¹ Series-Parallel Architecture

² Parallel

تا ۲۰۰۵ (۱۳۴۵ تا ۱۳۸۴) در شکل ۱ ارائه شده است. داده‌های مشاهده‌شده نشان دادند که چرخه فصلی دما در طول دوره‌ی مورد بررسی، حفظ شده است و در بخش پایانی دوره، به‌ویژه پس از سال ۲۰۰۰، افزایش تدریجی دمای متوسط ماهانه مشاهده شد (شکل ۱- الف). این روند افزایشی در نوسان دمایی مناطق خشک، به‌ویژه در فصل تابستان، می‌تواند موجب افزایش تنش گرمایی شود (۲۵). افزایش دما و تغییر اقلیم نیز می‌تواند با افزایش تبخیر و تشدید فشار بر منابع آب همراه باشد. تحلیل چنین داده‌هایی نقش زیادی در ارزیابی آسیب‌پذیری بخش‌های کشاورزی و محیط‌زیستی دارد و می‌تواند به‌عنوان داده پایه در مدل‌های پیش‌بینی اقلیم آینده استفاده شود. این یافته‌ها مؤید آن است که منطقه یزد نیز همچون بسیاری از نواحی خشک دنیا در معرض روندهای دمایی شدیدتری قرار گرفته است. در برخی سال‌ها، از جمله سال‌های ۲۰۰۸ (۱۳۸۷) و ۲۰۱۰ (۱۳۸۹)، نوسان کوتاه‌مدت دما مشاهده شد که به‌احتمال ناشی از پدیده‌های اقلیمی خاص مانند تغییرات ناگهانی جریان‌های جوی بوده است (۱۱).

در مقابل، روند شبیه‌سازی‌شده دمای میانگین ماهانه ایستگاه همدیدی یزد توسط مدل اقلیمی CANESM2 در دوره ۲۰۰۵-۱۹۶۶ (۱۳۴۵-۱۳۸۴) بررسی شد (شکل ۱- ب). نتایج نشان داد که مدل اقلیمی CANESM2 توانست الگوی کلی تغییرات فصلی دما را در دوره تاریخی بازتولید کند؛ اما در برخی دوره‌ها، به‌ویژه در مقدارهای حدی و ماه‌های سرد سال‌های ۱۹۷۰ (۱۳۴۹) و ۱۹۸۶ (۱۳۶۵)، اختلاف‌هایی میان مقدارهای شبیه‌سازی‌شده و مشاهده‌شده وجود داشت. این اختلاف نشان داد که استفاده مستقیم از خروجی خام مدل اقلیمی در مقیاس ایستگاهی می‌تواند با خطای قابل‌توجه همراه باشد و ضرورت تصحیح سوگیری پیش از استفاده در بررسی منطقه‌ای را مطرح می‌کند. مطالعات پیشین نیز نشان داده‌اند که تصحیح سوگیری می‌تواند خطاهای نظامند خروجی مدل‌های اقلیمی را کاهش دهد و داده‌های مناسب‌تری برای بررسی تأثیرهای اقلیمی فراهم کند (۲۱، ۲۸).

مقایسه مقدارهای دمای متوسط ماهانه مشاهده‌شده و شبیه‌سازی‌شده توسط مدل CANESM2 در ایستگاه

عملکرد شبکه در یادگیری روابط غیرخطی می‌شود. بررسی‌های پیشین، نشان داده‌اند که خوارزمیک GDX عملکرد مناسبی در آموزش شبکه‌های پویا (دینامیک) مانند NARX دارد (۱۰).

در پژوهش حاضر، خروجی دمای میانگین ماهانه مدل اقلیمی CANESM2 به‌عنوان ورودی خارجی $u(t)$ و دمای مشاهده‌شده ایستگاه همدیدی یزد به‌عنوان خروجی واقعی $y(t)$ در نظر گرفته‌شد. بنابراین، شبکه NARX برای یادگیری رابطه غیرخطی و وابستگی زمانی بین این دو متغیر و اصلاح خطای سیستماتیک خروجی مدل اقلیمی به‌کار گرفته‌شد.

ارزیابی عملکرد مدل

به‌منظور ارزیابی عملکرد مدل NARX در تصحیح خطای خروجی دمای مدل اقلیمی، از سه معیار میانگین مربعات خطا (MSE)، ریشه میانگین مربعات خطا (RMSE) و میانگین قدرمطلق خطا (MAE) استفاده شد. این معیارها به‌ترتیب با استفاده از روابط ۱۰ تا ۱۲ محاسبه شدند:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2 \quad (10)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad (11)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - x_i| \quad (12)$$

که در آن x_i و y_i به‌ترتیب نشان‌دهنده مقدارهای دمای متوسط مشاهده‌شده، مقدارهای دمای متوسط تصحیح‌شده توسط مدل NARX و تعداد مشاهدات مورد استفاده هستند. به‌منظور تعیین میزان بهبود حاصل از تصحیح، شاخص‌های مذکور برای خروجی خام مدل CANESM2 نیز محاسبه و با مقدارهای به‌دست‌آمده از شبکه NARX مقایسه شدند. کاهش مقدارهای MSE، RMSE و MAE به‌عنوان نشانه بهبود عملکرد مدل در بازتولید دمای مشاهده‌شده در نظر گرفته شد.

■ نتایج و بحث


روند تغییر دمای متوسط ماهانه ایستگاه همدیدی یزد در دوره ۱۹۶۶ تا ۲۰۲۰ (۱۳۴۵ تا ۱۳۹۹) و تغییر دمای شبیه‌سازی‌شده توسط مدل CANESM2 در دوره ۱۹۶۶

مقدارهای گذشته دمای مشاهده شده به عنوان ورودی بازخوردی شبکه در نظر گرفته شد. بنابراین، شبکه قادر بود رابطه غیرخطی میان خروجی مدل اقلیمی و دمای مشاهده شده و همچنین وابستگی زمانی این متغیرها را یاد بگیرد (۱۰، ۱۵، ۳۱).


ساختار شبکه NARX مورد استفاده در پژوهش حاضر شامل ورودی برونزا، مسیر بازخوردی خروجی، لایه پنهان و لایه خروجی بود. در این ساختار، مقدارهای گذشته دمای مدل CanESM2 و مقدارهای گذشته دمای مشاهده شده از طریق تأخیرهای زمانی در فرآیند پیش‌بینی مورد استفاده قرار گرفتند. استفاده همزمان از ورودی برونزا و مسیر بازخوردی، امکان در نظر گرفتن رابطه بین خروجی مدل اقلیمی و دمای مشاهده شده و همچنین وابستگی زمانی سری دما را فراهم کرد (شکل ۳).

همدیدی یزد طی دوره ۲۰۲۰-۲۰۰۶ (۱۳۹۹-۱۳۸۵) در شکل ۲ ارائه شد. در این دوره، اختلاف میان مقدارهای شبیه‌سازی شده و مشاهده شده در ماه‌های مختلف مشاهده شد و دامنه این اختلاف‌ها در برخی ماه‌های سرد و مقدارهای حدی افزایش یافت. همچنین، خروجی مدل در بخش‌هایی از دوره مقدارهای کمتری از دمای مشاهده شده را نشان داد. این الگوی اختلاف، وجود سوگیری در خروجی CANESM2 را در مقیاس ایستگاه همدیدی یزد نشان داد و ضرورت اصلاح این سوگیری پیش از استفاده از داده‌های مدل در تحلیل‌های دمایی را تأیید کرد (۲۲، ۲۶).

برای تصحیح خطای خروجی مدل CANESM2، شبکه عصبی خودبازگشتی غیرخطی با ورودی‌های خارجی (NARX) به کار گرفته شد. در پژوهش حاضر، خروجی دمای مدل CANESM2 به عنوان ورودی برونزا و



شکل ۱. تغییرات دمای متوسط ماهانه ایستگاه همدیدی یزد (الف) دمای مشاهده شده در دوره ۱۹۶۶-۲۰۲۰ (۱۳۹۹-۱۳۴۵)، (ب) دمای شبیه‌سازی شده توسط مدل CANESM2 در دوره ۱۹۶۶-۲۰۰۵ (۱۳۸۴-۱۳۴۵)




شکل ۲. مقایسه دمای متوسط ماهانه مشاهده شده و شبیه‌سازی شده توسط مدل CANESM2 در ایستگاه همدیدی یزد در دوره ۲۰۲۰-۲۰۰۶ (۱۳۹۹-۱۳۸۵)

اعتبارسنجی با مقدار ۳,۱۹۶۸ در دوره ۴۲ به دست آمد. پس از این مرحله، تغییرات خطای اعتبارسنجی محدود بود، درحالی که خطای آموزش روند کاهشی خود را ادامه داد. با توجه به رفتار نسبتاً مشابه منحنی های آموزش، اعتبارسنجی و آزمون و نبود افزایش محسوس خطای اعتبارسنجی پس از بهبود عملکرد، نشانه آشکاری از بیش برآزش در فرآیند آموزش مشاهده نشد (شکل ۴-الف).



توزیع خطاهای شبکه در مجموعه های آموزش، اعتبارسنجی و آزمون نشان داد که بخش عمده خطاها در محدوده نزدیک به صفر متمرکز بود. با افزایش فاصله خطا از صفر، فراوانی نمونه ها کاهش یافت و خطاهای با دامنه بزرگ سهم کمتری از توزیع را تشکیل دادند (شکل ۴-ب). تمرکز خطاها در اطراف صفر نشان داد که اختلاف میان خروجی شبکه و مقدارهای هدف در بخش قابل توجهی از نمونه های آموزشی و ارزیابی محدود بوده است و شبکه توانسته است در مرحله یادگیری، بخش عمده ای از الگوی تغییرات دمای مشاهده شده را بازتولید کند.

در مرحله آموزش، شبکه در ساختار سری-موازی (Series-Parallel؛ حلقه باز) به کار گرفته شد؛ به این صورت که مقدارهای واقعی دمای مشاهده شده در گام های زمانی گذشته به عنوان سیگنال بازخوردی وارد شبکه شدند. پس از آموزش، برای ارزیابی مستقل، ساختار شبکه به ساختار موازی (Parallel؛ حلقه بسته) تبدیل شد و خروجی پیش بینی شده هر گام زمانی برای تولید خروجی گام بعدی به عنوان بازخورد استفاده شد. در نتیجه، در دوره ارزیابی مستقل ۲۰۲۰-۲۰۰۶، مقدارهای مشاهده شده این دوره به عنوان بازخورد شبکه وارد نشدند و ارزیابی عملکرد NARX به صورت مستقل و خارج از نمونه انجام گرفت. استفاده از شبکه های NARX برای مدل سازی روابط غیرخطی و سری های زمانی نیز در مطالعات پیشین گزارش شده است (۱۰، ۳۱).

عملکرد شبکه NARX در مراحل آموزش، اعتبارسنجی و آزمون در شکل ۴ ارائه شده است. با افزایش دوره های آموزش، مقدار میانگین مربعات خطا (MSE) در هر سه مجموعه به طور محسوس کاهش یافت و بهترین عملکرد



شکل ۳. ساختار شبکه NARX مورد استفاده




شکل ۴. ارزیابی عملکرد شبکه NARX: (الف) روند میانگین مربعات خطا در مجموعه های آموزش، اعتبارسنجی و آزمون و (ب) توزیع خطا در مجموعه های آموزش، اعتبارسنجی و آزمون.

بخش‌های مختلف سری زمانی تغییرات مقدارهای هدف را دنبال کرد. در بخش پایین نمودار، نیز خطای حاصل از اختلاف بین خروجی شبکه و مقدارهای هدف نمایش داده شد. مقدارهای خطا در بخش عمده سری زمانی در محدوده نسبتاً کوچکی در اطراف صفر قرار گرفتند و تغییر آنها در طول سری زمانی مشاهده شد (شکل ۶). این نتایج بیانگر آن بود که شبکه توانست بخش عمده تغییرات زمانی دما را در مرحله توسعه مدل بازنمایی کند.

توزیع و تغییرات زمانی خطاهای دمای خروجی خام مدل CANESM2 و خروجی تصحیح‌شده با شبکه NARX مورد مقایسه قرار گرفت (شکل ۷). در توزیع خطاهای خروجی خام CANESM2، دامنه گسترده‌تر و پراکندگی بیشتری مشاهده شد و بخش قابل‌توجهی از خطاها در اطراف مقدار مثبت متمرکز بود. در مقابل، تمرکز بیشتری در اطراف مقدار صفر و کاهش دامنه پراکندگی خطاها در خروجی تصحیح‌شده با NARX مشاهده شد. همچنین، چند مقدار خطای منفی دورافتاده در توزیع خطاهای NARX مشاهده شد (شکل ۷-الف). نتایج نشان داد که در مجموع، اندازه و پراکندگی خطاهای خروجی مدل اقلیمی پس از اعمال شبکه NARX کاهش داشته است.

نمودارهای رگرسیون خطی بین خروجی‌های شبکه NARX و مقدارهای هدف برای چهار مجموعه شامل آموزش، اعتبارسنجی، آزمون و کل داده‌ها ارائه شد. در هر نمودار، نقاط داده، خط رگرسیون و خط خروجی ایده‌آل نمایش داده شدند. ضریب همبستگی (R) برای مجموعه آموزش برابر با ۰/۹۸، برای مجموعه اعتبارسنجی برابر با ۰/۹۷، برای مجموعه آزمون برابر با ۰/۹۷ و برای کل داده‌ها برابر با ۰/۹۸۲ به دست آمد. مقدارهای بالای R در هر چهار بخش نشان داد که بین خروجی شبکه و مقدارهای هدف همبستگی قوی وجود دارد. همچنین، شیب خطوط رگرسیون در هر چهار مجموعه به مقدار یک نزدیک بود و عرض از مبدأ مقدار نسبتاً کمی داشت؛ بنابراین، خروجی‌های شبکه از نظر روند و مقدار، تطابق مناسبی با مقدارهای هدف نشان دادند (شکل ۵).


نمودار پاسخ خروجی شبکه NARX در برابر مقدارهای هدف برای سری زمانی مورد استفاده در فرآیند آموزش و ارزیابی مستقل در شکل (۶) ارائه شد. در این نمودار، داده‌های آموزش، اعتبارسنجی و آزمون با علائم و رنگ‌های متفاوت نمایش داده شدند و خروجی شبکه در مقایسه با مقدارهای هدف ترسیم شد. خروجی شبکه در




شکل ۵. رگرسیون خطی بین مقدارهای هدف و خروجی شبکه NARX در مجموعه‌های آموزش، اعتبارسنجی، آزمون و کل داده‌ها

مقایسه سری‌های دمای میانگین ماهانه مشاهده‌شده، خروجی خام CANESM2 و خروجی تصحیح‌شده شبکه NARX در دوره ۲۰۰۶ تا ۲۰۲۰ (۱۳۸۵ تا ۱۳۹۹) نشان داد که سری تصحیح‌شده در مقایسه با خروجی خام، تطابق بیشتری با تغییرات زمانی داده‌های مشاهده‌شده داشت (شکل ۸). این بهبود، به‌طور مشخص در دوره‌های با بیشترین میزان سوگیری (Bias) مدل CanESM2 نسبت به مشاهدات، نمایان است. بنابراین استفاده از NARX موجب کاهش فاصله میان خروجی CANESM2 و داده‌های مشاهده‌شده ایستگاه در دوره ارزیابی شد.

تغییرات زمانی خطاها در دوره ارزیابی مستقل ۲۰۰۶ تا ۲۰۲۰ (۱۳۸۵ تا ۱۳۹۹) نیز مورد بررسی قرار گرفت. دامنه نوسان CANESM2 بیشتر از مدل تصحیح‌شده NARX بود، درحالی‌که خطاهای NARX در محدوده کوچکتری پیرامون صفر تغییر کردند. در مجموع، کاهش دامنه نوسان و پراکندگی خطاها در بخش‌های مختلف دوره ارزیابی مشاهده شد (شکل ۷-ب). کاهش پراکندگی خطا و تمرکز بیشتر آن در اطراف صفر با نتایج بررسی روش‌های یادگیری ماشین برای تصحیح سوگیری خروجی مدل‌های اقلیمی، همخوانی داشت (۲۱، ۲۸).



شکل ۶. نمودار پاسخ خطای شبکه NARX



شکل ۷. مقایسه خطاهای دمای خروجی مدل CANESM2 و مدل تصحیح‌شده با شبکه NARX (الف) توزیع خطا و (ب) تغییرات زمانی خطا در دوره ۲۰۰۶ تا ۲۰۲۰ (۱۳۸۵ تا ۱۳۹۹)


خام قرار گرفت که بیانگر مقدار محدودی بیش تصحیح بود؛ با اینحال، دامنه‌ی خطا پس از تصحیح، همچنان کمتر از خروجی خام باقی ماند.

در مقیاس فصلی نیز روند مشابهی مشاهده شد. میانگین خطای خروجی خام CANESM2 در فصل‌های مختلف از مقدار صفر فاصله بیشتری داشت، در حالی که پس از تصحیح با NARX، میانگین خطا به صفر نزدیک‌تر شد و پراکندگی آن کاهش یافت. بیشترین خطای خروجی خام و در نتیجه بیشترین میزان بهبود پس از تصحیح، در فصل‌های سرد مشاهده شد؛ در مقابل، در پاییز مقدار محدودی بیش تصحیح مشاهده شد (شکل ۹-ب).

در مجموع، مقایسه شکل‌های ۹-الف و ۹-ب نشان داد که NARX در هر دو مقیاس ماهانه و فصلی توانست خطای سیستماتیک خروجی دمای CANESM2 را کاهش داده و میانگین خطا را به مقدار صفر نزدیک کند. اگرچه میزان بهبود در ماه‌ها و فصل‌های مختلف یکسان نبود، الگوی کلی، نشان‌دهنده عملکرد مؤثر NARX در کاهش خطای سیستماتیک دمای شبیه‌سازی شده بود (شکل ۹).

شاخص‌های کمی ارزیابی نیز این بهبود را تأیید کردند (جدول ۲). مقدار MSE از $35/83$ در خروجی خام CANESM2 به $5/21$ در خروجی تصحیح‌شده NARX کاهش یافت. مقدار RMSE نیز از $5/99$ به $2/28$ و مقدار MAE از $5/45$ به $1/84$ رسید. بر این اساس، کاهش نسبی MSE حدود $85/5\%$ ، RMSE حدود $61/9\%$ و MAE حدود $66/2\%$ محاسبه شد. کاهش همزمان هر سه شاخص نشان داد که خروجی تصحیح‌شده NARX اختلاف کمتری با داده‌های مشاهده‌شده داشته‌است. در بررسی‌های مربوط به تصحیح سوگیری مدل‌های اقلیمی نیز استفاده از روش‌های آماری و داده‌محور برای کاهش اختلاف میان خروجی مدل و مشاهدات پیشنهاد شده‌است (۲۱، ۲۳).

بررسی میانگین ماهانه خطا نشان داد که پس از به‌کارگیری NARX، مقدار میانگین خطا در بیشتر ماه‌ها به صفر نزدیک‌تر شد و پراکندگی خطا نیز کاهش یافت (شکل ۹-الف). این الگو بیانگر کاهش خطای سیستماتیک در مقیاس ماهانه و بهبود یکنواختی عملکرد مدل در طول سال بود. در برخی ماه‌ها، به‌ویژه در پاییز، خطای NARX اندکی در جهت مخالف مقدار خطای مدل





شکل ۸. مقایسه مقدارهای دمای متوسط ماهانه مشاهده‌شده، خروجی خام مدل CANESM2 و خروجی تصحیح‌شده با شبکه NARX در ایستگاه همدیدی یزد در دوره ۲۰۰۶-۲۰۲۰ (۱۳۹۹ - ۱۳۸۵)

جدول ۲: معیارهای ارزیابی خطا بین مقدارهای واقعی دما و مقدارهای پیش‌بینی شده توسط مدل CANESM2 و اصلاح خطا

شده توسط مدل NARX در ایستگاه همدیدی یزد در دوره ۲۰۰۶-۲۰۲۰ (۱۳۹۹ - ۱۳۸۵)

	MSE	RMSE	MAE
CANESM2	$35/83$	$5/99$	$5/45$
NARX	$5/21$	$2/28$	$1/84$



شکل ۹. مقایسه خطای پیش‌بینی دما توسط مدل‌های CANESM2 و NARX
(الف) میانگین خطای ماهانه و (ب) میانگین خطای فصلی.

تأخیرهای زمانی و ویژگی‌های داده‌های آموزشی می‌تواند بر عملکرد روش اثرگذار باشد؛ از این رو، استفاده از این رویکرد در شرایط اقلیمی متفاوت نیازمند ارزیابی و تنظیم متناسب با ویژگی‌های هر منطقه است.

از دیدگاه تصمیم‌گیری و سیاست‌گذاری، پیشنهاد می‌شود داده‌های اقلیمی تصحیح‌شده پیش از استفاده در برنامه‌ریزی منابع آب، مدیریت خشکسالی و ارزیابی پیامدهای تغییر اقلیم مورد توجه قرارگیرند؛ زیرا کاهش سوگیری خروجی مدل‌های اقلیمی می‌تواند به افزایش قابلیت اتکای اطلاعات اقلیمی مورد استفاده در تصمیم‌گیری‌های محلی و منطقه‌ای کمک کند. همچنین، استفاده از نتایج مدل‌های تصحیح‌شده در کنار داده‌های مشاهده‌ای و سایر منابع اقلیمی می‌تواند از اتکای صرف به یک مدل اقلیمی یا یک روش تصحیح جلوگیری کند.

برای پژوهش‌های آینده، بررسی عملکرد NARX در چند ایستگاه با شرایط اقلیمی متفاوت، استفاده از مدل‌ها و سناریوهای اقلیمی مختلف و مقایسه‌ی مستقیم آن با روش‌های متداول تصحیح سوگیری، از جمله روش‌های نگاشت چارکی، پیشنهاد می‌شود. همچنین، بررسی اثر تعداد تأخیرهای زمانی و معماری شبکه می‌تواند به تعیین ساختار مناسب NARX برای تصحیح خطای سایر متغیرهای اقلیمی کمک کند.

■ سپاسگزاری

بدین‌وسیله نویسندگان، مراتب سپاس و قدردانی صمیمانه خود را از سازمان هواشناسی کشور به‌دلیل

این بهبود با شواهد نموداری، کاهش پراکندگی خطا و کاهش شاخص‌های MSE، RMSE و MAE مشاهده شد. از آنجا که دوره ۱۳۸۵ تا ۱۳۹۹ (۲۰۰۶ تا ۲۰۲۰) در آموزش و تنظیم شبکه استفاده نشده بود، نتایج به‌دست‌آمده شواهدی از توانایی NARX در تصحیح خروجی مدل برای داده‌های مستقل از فرآیند توسعه، فراهم کرد. با اینحال، این یافته‌ها به یک ایستگاه، یک مدل اقلیمی و شرایط مورد بررسی در پژوهش حاضر محدود است و تعمیم آنها به دیگر مناطق و مدل‌ها نیازمند ارزیابی مستقل است.

■ نتیجه‌گیری

پژوهش حاضر با هدف ارزیابی قابلیت شبکه عصبی NARX در تصحیح خطای دمای خروجی مدل اقلیمی CANESM2 در ایستگاه همدیدی یزد انجام شد. یافته‌های پژوهش حاضر نشان داد که رویکرد مبتنی بر NARX می‌تواند با بهره‌گیری از وابستگی‌های زمانی و روابط غیرخطی موجود در داده‌های دما، کیفیت خروجی مدل اقلیمی را در مقیاس ایستگاهی بهبود دهد. بنابراین، استفاده از روش‌های داده‌محور می‌تواند راهکار مناسبی برای کاهش سوگیری خروجی مدل‌های اقلیمی در مطالعات محلی باشد.

از دیدگاه کاربردی، داده‌های دمایی تصحیح‌شده می‌توانند به‌عنوان ورودی مناسب‌تری در مطالعات محلی تغییر اقلیم، خشکسالی و برنامه‌ریزی منابع آب مورد استفاده قرارگیرند. با این‌حال، انتخاب ساختار شبکه، تعداد

فراهم کردن داده‌های هواشناسی مورد استفاده در پژوهش
حاضر، اعلام می‌دارند. همچنین، از سردبیر محترم و داوران
مقاله به دلیل صرف وقت برای مطالعه دقیق، ارائه نظرات
سازنده و پیشنهادهای ارزشمند که در بهبود کیفیت این
مقاله مؤثر بود، صمیمانه تشکر و قدردانی می‌شود.

■ References

- Arora, V. K., Scinocca, J. F., Boer, G. J., Christian, J. R., Denman, K. L., Flato, G. M., Kharin, V. V., Lee, W. G., & Merryfield, W. J. (2011). Carbon emission limits required to satisfy future representative concentration pathways of greenhouse gases. *Geophysical Research Letters*, 38(5), L05805, 1-6. doi: 10.1029/2010GL046270
- Boussaada, Z., Curea, O., Remaci, A., Camblong, H., & Mrabet Bellaaj, N. (2018). A nonlinear autoregressive exogenous (NARX) neural network model for the prediction of the daily direct solar radiation. *Energies*, 11(3), 620. doi: 10.3390/en11030620
- Cannon, A. J., Sobie, S. R., & Murdock, T. Q. (2015). Bias correction of GCM precipitation by quantile mapping: How well do methods preserve changes in quantiles and extremes? *Journal of Climate*, 28(17), 6938-6959. doi: 10.1175/JCLI-D-14-00754.1
- Chen, L., Han, B., Wang, X., Zhao, J., Yang, W., & Yang, Z. (2023). Machine learning methods in weather and climate applications: A survey. *Applied Sciences*, 13(21), 12019. doi: 10.3390/app132112019
- Chen, S., Billings, S. A., & Grant, P. M. (1990). Non-linear system identification using neural networks. *International Journal of Control*, 51(6), 1191-1214. doi: 10.1080/00207179008934126
- Eyring, V., Bony, S., Meehl, G. A., Senior, C. A., Stevens, B., Stouffer, R. J., & Taylor, K. E. (2016). Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. *Geoscientific Model Development*, 9(5), 1937-1958. doi: 10.5194/gmd-9-1937-2016
- Hagan, M. T., Demuth, H. B., Beale, M. H., & De Jesús, O. (2014). *Neural Network Design* (2nd ed.). Martin Hagan.
- Hess, P., Lange, S., Schötz, C., & Boers, N. (2023). Deep learning for bias-correcting CMIP6-class earth system models. *Earth's Future*, 11(10), e2023EF004002. doi: 10.1029/2023EF004002
- Hewitson, B. C., Daron, J., Crane, R. G., Zermoglio, M. F., & Jack, C. (2014). Interrogating empirical-statistical downscaling. *Climatic Change*, 122(4), 539-554. doi: 10.1007/s10584-013-1021-z
- Huo, F., & Poo, A. N. (2013). Nonlinear autoregressive network with exogenous inputs based contour error reduction in CNC machines. *International Journal of Machine Tools and Manufacture*, 67, 45-52. doi: 10.1016/j.ijmachtools.2012.12.007
- Intergovernmental Panel on Climate Change. (2021). Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press (IPCC). doi: 10.1017/9781009157896
- Khashei, M., & Bijari, M. (2010). An artificial neural network (p, d, q) model for time series forecasting. *Expert Systems with Applications*, 37(1), 479-489. doi: 10.1016/j.eswa.2009.05.044
- Kronenberg, R., Barfus, K., Franke, J., & Bernhofer, C. (2013). On the downscaling of meteorological fields using recurrent networks for modelling the water balance in a meso-scale catchment area of Saxony, Germany. *Atmospheric and Climate Sciences*, 3(4), 552-561. doi: 10.4236/acs.2013.34058
- Lyu, R., Wang, L., Sun, Y., Bai, H., & Lu, C. T. (2024, December). Downscaling precipitation with bias-informed conditional diffusion model. In *2024 IEEE International Conference on Big Data (BigData)*, 8768-8770. doi: 10.1109/BigData62323.2024.10825056
- Magallanes-Quintanar, R., Galván-Tejada, C. E., Galván-Tejada, J. I., Méndez-Gallegos, S. D. J., García-Domínguez, A., & Gamboa-Rosales, H. (2022). Narx neural networks models for prediction of standardized precipitation index in Central Mexico. *Atmosphere*, 13(8), 1254. doi: 10.3390/atmos13081254
- Mukherjee, S., Mishra, A., & Trenberth, K. E. (2018). Climate change and drought: a perspective on drought indices. *Current Climate Change Reports*, 4(2), 145-163. doi: 10.1007/s40641-018-0098-x
- Najafi, M. S., & Alizadeh, O. (2023). Climate zones in Iran. *Meteorological Applications*, 30(5), e2147. doi: 10.1002/met.2147
- Niu, H., Sun, W., Huai, B., Wang, Y., Chen, R., Han, C., Wang, Y., Zhou, J., & Wang, L. (2024). Causes of

- increased compound temperature and precipitation extreme events in the arid region of Northwest China from 1961 to 2100. *Remote Sensing*, 16(17), 3111. [doi: 10.3390/rs16173111](https://doi.org/10.3390/rs16173111)
19. Nivron, O., Wischik, D. J., Vrac, M., Shuckburgh, E., & Archibald, A. T. (2024). A temporal stochastic bias correction using a machine learning attention model. *Environmental Data Science*, 3, e36. 1-40. [doi: 10.1017/eds.2024.42](https://doi.org/10.1017/eds.2024.42)
 20. Pasula, A., & Subramani, D. N. (2025). Global climate model bias correction using deep learning. *Machine Learning: Earth*, 1(1), 015001. [doi: 10.1088/3049-4753/ade9c3](https://doi.org/10.1088/3049-4753/ade9c3)
 21. Piani, C., Weedon, G. P., Best, M., Gomes, S. M., Viterbo, P., Hagemann, S., & Haerter, J. O. (2010). Statistical bias correction of global simulated daily precipitation and temperature for the application of hydrological models. *Journal of Hydrology*, 395(3-4), 199-215. [doi: 10.1016/j.jhydrol.2010.10.024](https://doi.org/10.1016/j.jhydrol.2010.10.024)
 22. Pierce, D. W., Barnett, T. P., Hidalgo, H. G., Das, T., Bonfils, C., Santer, B. D., Bala, G., Dettinger, M. D., Cayan, D. R., Mirin, A., Wood, A. W., & Nozawa, T. (2008). Attribution of declining western US snowpack to human effects. *Journal of Climate*, 21(23), 6425-6444. [doi: 10.1175/2008JCLI2405.1](https://doi.org/10.1175/2008JCLI2405.1)
 23. Raeesi, M., Zolfaghari, A. A., Kaboli, S. H., Rahimi, M., de Vente, J., & Eekhout, J. P. (2024). Using quantile mapping and random forest for bias-correction of high-resolution reanalysis precipitation data and CMIP6 climate projections over Iran. *International Journal of Climatology*, 44(12), 4495-4514. [doi: 10.1002/joc.8593](https://doi.org/10.1002/joc.8593)
 24. Schwalm, C. R., Glendon, S., & Duffy, P. B. (2020). RCP8. 5 tracks cumulative CO2 emissions. *Proceedings of the National Academy of Sciences*, 117(33), 19656-19657. [doi: 10.1073/pnas.2007117117](https://doi.org/10.1073/pnas.2007117117)
 25. Sun, Y., Zhang, X., Zwiers, F. W., Song, L., Wan, H., Hu, T., Yin, H., & Ren, G. (2014). Rapid increase in the risk of extreme summer heat in Eastern China. *Nature Climate Change*, 4(12), 1082-1085. [doi: 10.1038/nclimate2410](https://doi.org/10.1038/nclimate2410)
 26. Teutschbein, C., & Seibert, J. (2012). Bias correction of regional climate model simulations for hydrological climate-change impact studies: Review and evaluation of different methods. *Journal of Hydrology*, 456-457, 12-29. [doi: 10.1016/j.jhydrol.2012.05.052](https://doi.org/10.1016/j.jhydrol.2012.05.052)
 27. Van Vuuren, D. P., Edmonds, J., Kainuma, M., Riahi, K., Thomson, A., Hibbard, K., Hurtt, G. C., Kram, T., Krey, V., Lamarque, J. F., Masui, T., Meinshausen, M., Nakicenovic, N., Smith, S. J., & Rose, S. K. (2011). The representative concentration pathways: an overview. *Climatic Change*, 109(1-2), 5-31. [doi: 10.1007/s10584-011-0148-z](https://doi.org/10.1007/s10584-011-0148-z)
 28. Wang, F., & Tian, D. (2024). Multivariate bias correction and downscaling of climate models with trend-preserving deep learning. *Climate Dynamics*, 62(10), 9651-9672. [doi: 10.1007/s00382-024-07406-9](https://doi.org/10.1007/s00382-024-07406-9)
 29. Yang, R., Hu, J., Li, Z., Mu, J., Yu, T., Xia, J., Li, X., Dasgupta, A., & Xiong, H. (2024). Interpretable machine learning for weather and climate prediction: A review. *Atmospheric Environment*, 338, 120797. [doi: 10.1016/j.atmosenv.2024.120797](https://doi.org/10.1016/j.atmosenv.2024.120797)
 30. Zahirpour, P., Javadi, S., Jamali, F. S., & Mohammadi, A. (2024). Development of a nonlinear hybrid model for forecasting monthly reservoirs inflow based on hydro climate parameters and basin vegetation cover (Case study: Dez dam). *Iranian Journal of Eco Hydrology*, 11(1), 26-45. [doi: 10.22059/ije.2024.373165.1797](https://doi.org/10.22059/ije.2024.373165.1797). [In Persian]
 31. Zeng, C., Liu, X., Chen, L., He, X., & Kang, Z. (2024). Enhanced Short-Term Temperature Prediction of Seasonally Frozen Soil Subgrades Using the NARX Neural Network. *Applied Sciences*, 14(22), 10257. [doi: 10.3390/app142210257](https://doi.org/10.3390/app142210257)