



Amirkabir Dam Inflow Prediction Using Teleconnection Patterns and Machine Learning Models

Ehsan Vasheghani Farahani¹ | Alireza Massah Bavani^{2✉} | Abbas Roozbahani³ |
Farhad Behzadi⁴ | Misagh Bidabadi⁵

1. Department of Water Engineering, Faculty of Agricultural Technology, University College of Agriculture & Natural Resources, University of Tehran, Tehran, Iran. E-mail: ehsan.farahani@ut.ac.ir
2. Corresponding Author, Department of Water Engineering, Faculty of Agricultural Technology, University College of Agriculture & Natural Resources, University of Tehran, Tehran, Iran. E-mail: armassah@ut.ac.ir
3. Department of Water Engineering, Faculty of Agricultural Technology, University College of Agriculture & Natural Resources, University of Tehran, Tehran, Iran. E-mail: roozbahany@ut.ac.ir
4. Department of Water Engineering, Faculty of Agricultural Technology, University College of Agriculture & Natural Resources, University of Tehran, Tehran, Iran. E-mail: farhadbehzadi76@gmail.com
5. Department of Irrigation and Reclamation Engineering, Faculty of Agriculture, University College of Agriculture & Natural Resources, University of Tehran, Tehran, Iran. E-mail: misagh.bidabadi@ut.ac.ir

Article Info

Article type:

Research Article

Article history:

Received: 30 January 2023

Received in revised form:

3 April 2023

Accepted: 6 June 2023

Published online: 2 July 2023

Keywords:

ANFIS,

ANN,

BNN,

Inflow Prediction,

Teleconnection Patterns.

ABSTRACT

The demand for freshwater is increasing, while the limited water resources are subject to over-harvesting, pollution, and climate change, which require improving water resource management to distribute it equitably and achieve It highlights the goals of sustainable development. A low-cost option to support better water management strategies is to develop models capable of predicting available water amounts, especially amounts related to precipitation and river flow. Climatic diversity and climate changes are basic assumptions for hydro climatological predictions. One of the remarkable aspects of this issue is the correlation between large-scale atmospheric-oceanic phenomena or Teleconnection patterns with hydrological processes on a local scale, and these patterns can also affect the inflow to the dams. This study uses three machine learning models, an artificial neural network, a Bayesian neural network, and an adaptive neuro-fuzzy inference system to predict dam inflow and evaluate their efficiency. For this purpose, 12 scenarios consisting of rainfall variables, inflow to the dam, and nine climatic indicators with a delay of up to six-time steps were designed to investigate the effect of using long-term models as predictive variables of the flow one month later in Amirkabir Dam. to be placed The analysis of the results of this research showed that the use of the Nino3.4 index with one-time step delay as well as the PDO index with two-time step delays can increase the accuracy of the model compared to the scenarios in which only station variables are used. to be According to the results, the Nino 3.4 index was found to be the most effective index on the inflow to Amirkabir Dam, and the scenario in which the mentioned index along with the rainfall and flow data of one and two months before was used as input, in all three The model recorded the highest accuracy. Also, the performance of the ANFIS model for the mentioned scenario (scenario 9), with RMSE and R2 values, equal to 5.69 and 0.79 cubic meters per second, respectively, was better than the ANN and BNN models, so the value of the R2 index for the best scenario consisting of station variables (scenario 5), it increased by 0.15 and the value of RMSE index decreased by 0.78 cubic meters.

Cite this article: Vasheghani Farahani, E., Massah Bavani, A., Roozbahani, A., Behzadi, F., & Bidabadi, M. (2023). Amirkabir Dam Inflow Prediction Using Teleconnection Patterns and Machine Learning Models. *Journal of Water and Irrigation Management*, 13 (2), 451-469. DOI: <https://doi.org/10.22059/jwim.2023.354198.1044>



پیش‌بینی جریان ورودی سد امیر کبیر با استفاده از الگوهای دورپیوند اقلیمی و مدل‌های یادگیری ماشین

احسان واشقانی فراهانی^۱ | علیرضا مساح بوانی^۲ | عباس روزبهانی^۳ | فرهاد بهزادی^۴ | میثاق بیدآبادی^۵

۱. گروه مهندسی آب، دانشکده فناوری کشاورزی، دانشکدگان کشاورزی و منابع طبیعی، دانشگاه تهران، تهران، ایران. رایانامه: ehsan.farahani@ut.ac.ir
۲. نویسنده مسئول، گروه مهندسی آب، دانشکده فناوری کشاورزی، دانشکدگان کشاورزی و منابع طبیعی، دانشگاه تهران، تهران، ایران. رایانامه: armassah@ut.ac.ir
۳. گروه مهندسی آب، دانشکده فناوری کشاورزی، دانشکدگان کشاورزی و منابع طبیعی، دانشگاه تهران، تهران، ایران. رایانامه: roozbahany@ut.ac.ir
۴. گروه مهندسی آب، دانشکده فناوری کشاورزی، دانشکدگان کشاورزی و منابع طبیعی، دانشگاه تهران، تهران، ایران. رایانامه: farhadbehzadi76@gmail.com
۵. گروه مهندسی آبیاری و آبادانی، دانشکده کشاورزی، دانشکدگان کشاورزی و منابع طبیعی، دانشگاه تهران، تهران، ایران. رایانامه: misagh.bidabadi@ut.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله: مقاله پژوهشی

تقاضا برای آب شیرین به‌طور فزاینده‌ای در حال افزایش است، درحالی‌که منابع محدود آب، در معرض اضافه‌برداشت، آلودگی و تغییرات اقلیمی هستند که این موارد نیاز به بهبود مدیریت منابع آب را به‌منظور توزیع عادلانه و دستیابی به اهداف توسعه پایدار برجسته می‌کند. یک گزینه کم‌هزینه برای حمایت از استراتژی‌های مدیریت بهتر آب، توسعه مدل‌هایی با قابلیت پیش‌بینی مقادیر آب در دسترس، به‌ویژه مقادیر مربوط به بارش و جریان رودخانه‌هاست. تنوع اقلیمی و تغییرات آب‌وهوایی، یک فرض اساسی برای پیش‌بینی‌های هیدروکلیماتولوژیکی است. یکی از جنبه‌های قابل توجه این موضوع، همبستگی بین پدیده‌های بزرگ‌مقیاس جوی-اقیانوسی یا الگوهای دورپیوند با فرایندهای هیدرولوژیکی در مقیاس محلی است که این الگوها می‌توانند بر جریان ورودی به سدها نیز اثرگذار باشند. در این مطالعه از سه مدل یادگیری ماشین شبکه عصبی مصنوعی، شبکه عصبی بیزین و سیستم استنتاج عصبی-فازی سازگار برای پیش‌بینی جریان ورودی به سدها بهره گرفته شده است تا کارایی آن‌ها مورد ارزیابی قرار بگیرد. بدین منظور ۱۲ سناریو متشکل از متغیرهای بارش، جریان ورودی به سد و نه شاخص اقلیمی با تأخیر تا شش گام زمانی، طراحی شد تا تأثیر استفاده از الگوهای دورپیوند به‌عنوان متغیرهای پیش‌بینی‌کننده جریان یک ماه بعد سد امیرکبیر، مورد بررسی قرار بگیرد. تحلیل نتایج این پژوهش نشان داد که استفاده از شاخص $Nino3.4$ با یک گام زمانی تأخیر و هم‌چنین شاخص PDO با دو گام زمانی تأخیر، می‌توانند باعث افزایش دقت مدل نسبت به سناریوهای که در آن‌ها تنها از متغیرهای ایستگاهی استفاده شده است، شوند. طبق نتایج، شاخص $Nino3.4$ مؤثرترین شاخص بر جریان ورودی به سد امیرکبیر شناخته شد و سناریویی که در آن از شاخص نام‌برده به همراه داده‌های بارش و جریان یک و دو ماه قبل به‌عنوان ورودی استفاده شده بود، در هر سه مدل، بالاترین دقت را به ثبت رساند. هم‌چنین عملکرد مدل ANFIS برای سناریوی نام‌برده (سناریوی ۹)، با مقادیر $RMSE$ و R^2 ، به‌ترتیب معادل با $5/69$ مترمکعب بر ثانیه و $0/79$ ، نسبت به دو مدل ANN و BNN بهتر بود، به‌طوری‌که مقدار شاخص R^2 برای بهترین سناریوی متشکل از متغیرهای ایستگاهی (سناریوی ۵)، به میزان $0/15$ افزایش یافته و مقدار شاخص $RMSE$ نیز به میزان $0/78$ مترمکعب کاهش یافته‌است.

کلیدواژه‌ها:

الگوهای دورپیوند،
پیش‌بینی جریان،
شبکه عصبی مصنوعی،
شبکه عصبی بیزین،
ANFIS.

استناد: واشقانی فراهانی، احسان؛ مساح بوانی، علیرضا؛ روزبهانی، عباس؛ بهزادی، فرهاد و بیدآبادی، میثاق (۱۴۰۲). پیش‌بینی جریان ورودی سد امیر کبیر با استفاده از الگوهای دورپیوند اقلیمی و مدل‌های یادگیری ماشین. نشریه مدیریت آب و آبیاری، ۱۳ (۲)، ۴۵۱-۴۶۹.

DOI: <https://doi.org/10.22059/jwim.2023.354198.1044>



۱. مقدمه

تقاضا برای آب شیرین به‌طور فزاینده‌ای در حال افزایش است، درحالی‌که منابع محدود آب، در معرض اضافه‌بردداشت، آلودگی و تغییرات اقلیمی هستند که این موارد نیاز به بهبود مدیریت منابع آب را به‌منظور توزیع عادلانه و دستیابی به اهداف توسعه پایدار برجسته می‌کند. یک گزینه کم‌هزینه برای حمایت از استراتژی‌های مدیریت بهتر آب، توسعه مدل‌هایی با قابلیت پیش‌بینی مقادیر آب در دسترس، به‌ویژه مقادیر مربوط به بارش و جریان رودخانه‌هاست (Block, 2016). تنوع اقلیمی و تغییرات آب‌وهوایی، یک فرض اساسی برای پیش‌بینی‌های هیدروکلیماتولوژیکی است. یکی از جنبه‌های قابل‌توجه این موضوع، همبستگی بین پدیده‌های بزرگ‌مقیاس جوی-اقیانوسی یا الگوهای دورپیوند با فرایندهای هیدرولوژیکی در مقیاس محلی است (Alessandro, 2018). با توجه به اثرگذاری الگوهای دورپیوند بر متغیرهای هیدرولوژیکی و هواشناسی، این الگوها بر جریان ورودی به سدها نیز می‌توانند اثرگذار باشند؛ بنابراین انتخاب یک مدل پیش‌بینی مناسب که تا حد امکان از عدم قطعیت‌های موجود در پیش‌بینی رواناب بکاهد و تغییرات آب‌وهوایی را نیز در نظر بگیرد، ضروری به‌نظر می‌رسد. در سال‌های اخیر، روش‌های یادگیری ماشین و هوش مصنوعی، عملکرد قابل‌قبولی را در زمینه پیش‌بینی‌های هیدرولوژیکی به‌ویژه پیش‌بینی جریان رودخانه‌ها، از خود نشان داده‌اند.

در این زمینه، Kumar *et al.* (2015) از پنج مدل ترکیبی متشکل از رویکردهای آنالیز موجک، شبکه عصبی و بوت‌استرپ، به‌منظور پیش‌بینی روزانه جریان ورودی به مخزن یک سد در هند و همچنین بازه عدم قطعیت آن، پرداختند. طبق نتایج، مدل موجک-عصبی بهترین عملکرد را از خود نشان داد. Ahmadi *et al.* (2016) به پیش‌بینی جریان روزانه رودخانه باراندوزچای ارومیه به دو روش برنامه‌ریزی ژنتیک (GP) و شبکه بیزین (BN) پرداختند؛ به‌طوری‌که برای ورودی هر دو مدل، پنج الگو از داده‌های ایستگاه هیدرومتری با تأخیرهای زمانی یک تا پنج روز استفاده شده است. طبق نتایج، دقت مدل‌سازی تا تأخیر سوم رو به بهبود بوده و از آن به بعد کاهش می‌یابد. Misaghi (2016)، در پژوهشی با استفاده از اطلاعات روزانه، هفتگی، ۱۰ روزه و ماهانه جریان آب ورودی به سد علویان در شمال غرب ایران، به پیش‌بینی جریان ورودی به مخزن با به‌کارگیری سیستم تطبیقی فازی-عصبی بهینه‌شده اقدام کرده است. نتایج حاکی از عملکرد مناسب مدل در برآورد جریان بوده و طبق آنالیز حساسیت، مؤثرترین متغیر ورودی در همه مدل‌ها، دبی جریان در گام زمانی قبلی است. Kim *et al.* (2018)، از ترکیب مدل شبکه بیزین بر مبنای کاپولا و شاخص آبدی استانداردشده، جهت پیش‌بینی جریان فصلی ورودی به مخازن استفاده کردند. نتایج بیانگر دقت قابل‌قبول این رویکرد در پیش‌بینی جریان ورودی در شرایط خشکسالی بود. Samadi and Fathabadi (2019)، با استفاده از داده‌های یک ایستگاه هیدرومتری با دوره آماری ۴۷ سال و سه مدل سری‌زمانی، شبکه عصبی و ماشین‌بردار پشتیبان، اقدام به پیش‌بینی دبی ورودی به سد گرگان نمودند. طبق نتایج، مدل ماشین‌بردار پشتیبان در برآورد جریان ماهانه بهترین عملکرد را داشت. Babaei *et al.* (2019)، به بررسی عملکرد مدل‌های ANN و SVM در پیش‌بینی جریان ورودی به سد زاینده‌رود پرداختند. بدین منظور نه الگوی مختلف از ورودی‌ها برای پیش‌بینی استفاده شده‌اند که عبارتند از جریان ورودی به سد و بارش ماهانه ایستگاه قلعه شاهرخ با تأخیرهای یک تا شش ماه و همچنین جریان ورودی و بارش ماهانه با یک سال تأخیر. مقایسه نتایج نشان داد، الگوی نهم که شامل تمامی ورودی‌های مذکور است در هر دو مدل بهترین عملکرد را داراست و مدل SVM دقت بیشتری نسبت به مدل ANN داشت. Wagena *et al.* (2020)، از مدل‌های رگرسیون خودکار با میانگین متحرک (ARMA)، ANN و SWAT-VSA و یک مدل ترکیبی بیزین که از نتایج سه مدل نامبرده استفاده می‌کند، به‌منظور پیش‌بینی کوتاه‌مدت جریان ورودی به سد در پنسیلوانیا در کشور آمریکا استفاده کردند. براساس نتایج عملکرد مدل‌های SWAT-VSA و ANN در برآورد کل جریان و دبی بیشینه بهتر از سایر مدل‌ها بود. با

این حال، این مدل‌ها جریان‌های کمینه را کم‌تر از مقدار واقعی تخمین زده‌اند. Noorbeh *et al.* (2020)، در پژوهشی به بررسی قابلیت مدل شبکه‌های بیزین در پیش‌بینی جریان ماهانه و سالانه ورودی به سد زاینده‌رود پرداختند. بدین منظور ۴۴ الگو از پیش‌بینی‌کننده‌ها برای ورود به مدل تعیین و در نهایت سناریوهای برگزیده انتخاب شدند که نشان‌دهنده قابلیت مدل در پیش‌بینی جریان ورودی به سد زاینده‌رود بود. Zhang *et al.* (2020)، از یک مدل ترکیبی متشکل از سه مدل SVM، ANFIS و ANN به منظور برآورد ۱۰ روزه جریان ورودی به مخزن سد Huanren در چین، استفاده کردند. پیش‌بینی‌کننده‌های مورد استفاده در این پژوهش عبارتند از بارش (P)، دبی (Q)، رطوبت نسبی (H)، حداکثر دما (Tmin)، حداکثر دما (Tmax) و بارش پیش‌بینی شده (F). طبق نتایج، سناریوی متشکل از متغیرهای P، Q و F دقت بالایی را نشان داد و اضافه کردن سه متغیر دیگر موجب افزایش چشم‌گیری در دقت مدل نشد. Latif *et al.* (2021) از الگوریتم‌های یادگیری عمیق برای توسعه سه مدل حافظه کوتاه‌مدت طولانی (LSTM)، ANN و SVM به منظور پیش‌بینی جریان روزانه ورودی به سدی در کشوری مالزی پرداختند. طبق نتایج، مدل LSTM نسبت به دو مدل دیگر عملکرد بهتری داشت.

علاوه بر پیش‌بینی جریان ورودی، هدف دیگر این پژوهش آزمایش و تعیین قابلیت پیش‌بینی الگوهای دورپیوند در ترکیب با متغیرهای هیدرولوژیکی به منظور برآورد جریان ورودی به مخازن سدهاست؛ چراکه در پژوهش‌های متعددی، اثرگذاری این الگوها بر متغیرهای هیدرولوژیکی و هواشناسی در ایران (Farajzade *et al.*, 2013; Babaei and) و سایر نقاط جهان (Fatahi, 2015; Khosravi and Mesgari, 2016; Esmaili *et al.*, 2020; Sabziparvar *et al.*, 2020 Salighe and Sayadi, 2017; Banihabib *et al.*, 2018; Maryanji *et al.*, 2019; Rasouli *et al.*,) (2020) به اثبات رسیده است. به منظور افزایش دقت مدل‌های پیش‌بینی، ممکن است بتوان آن دسته از الگوهای دورپیوند اقلیمی را که بر هیدرولوژی منطقه مورد مطالعه تأثیرگذارند شناسایی و از آن‌ها استفاده کرد. در این راستا، Ruigar and Gulian (2016)، با استفاده از مدل ANN و شاخص‌های اقلیمی فشار سطح دریا (SLP) و دمای سطح دریا (SST)، به پیش‌بینی حداکثر بارش یک روزه ماهانه، در حوضه آبریز سد گلستان پرداختند. Yang *et al.* (2017)، با استفاده از داده‌های بارش، تبخیر، جریان و ۱۷ شاخص اقلیمی به عنوان ورودی به مدل‌های یادگیری ماشین SVM، ANN و RF، به پیش‌بینی جریان ورودی به مخزن دو سد در کشور آمریکا و چین پرداختند. نتایج حاکی از قابلیت شاخص‌های اقلیمی و همچنین مدل‌های نام‌برده در پیش‌بینی جریان بود و مدل RF بهترین عملکرد را نسبت به سایر مدل‌ها از خود نشان داد. Kim *et al.* (2019) در پژوهشی به پیش‌بینی جریان ماهانه ورودی به مخزن سه سد در کره جنوبی، با لحاظ متغیرهای اقلیمی پرداختند. نتایج نشان داد که استفاده از شاخص‌های اقلیمی پتانسل افزایش دقت مدل‌های پیش‌بینی‌کننده را داراست. Wang *et al.* (2020) پس از ایستاکردن سری زمانی جریان ورودی به سدی در کشور چین، با استفاده از شاخص‌های اقلیمی و مدل ANN به پیش‌بینی جریان ماهانه پرداختند. سناریوهای پیش‌بینی شامل مقدار جریان و مقادیر ۱۵ شاخص اقلیمی با یک تا ۱۲ ماه تأخیر بودند. در نهایت مشخص شده که کدام شاخص‌ها و با چه تأخیر زمانی، باعث افزایش دقت در پیش‌بینی شده‌اند. Lee *et al.* (2020) از یک مدل Ensemble که از ترکیب مدل‌های داده‌کاوی ANN، MLR و SVM ساخته شده است، با بهره‌گیری از الگوهای دورپیوند، به پیش‌بینی جریان ورودی به مخزن سدی در کره جنوبی، طی دوره خشک، پرداختند. براساس نتایج، الگوهای دورپیوند پتانسیل استفاده به عنوان ابزاری برای پیش‌بینی خشکسالی‌ها را دارند. Panahi *et al.* (2021) از مدل‌های MLP، BMA و CBMA و با در نظر گرفتن الگوهای دورپیوند ENSO، PDO، SOI، NAO و خانواده ENSO، به پیش‌بینی جریان چهار رودخانه در کشور مالزی پرداختند. Linh *et al.* (2021) با در نظر گرفتن شاخص‌های بزرگ مقیاس خانواده‌های SLP و STT به پیش‌بینی

بیشینه جریان ماهانه در حوضه آبریز Madarsoo پرداختند. نتایج بیانگر قابلیت شاخص‌های اقلیمی در پیش‌بینی بیشینه جریان ماهانه بود. Chu *et al.* (2022) با به‌کارگیری مدل LSTM و الگوهای دورپیوند، به پیش‌بینی روزانه تراز آب زیرزمینی در دو منطقه با اقلیم متفاوت در کشور آمریکا پرداختند. نتایج نشان داد که بهترین پیش‌بینی‌کننده‌ها برای منطقه خشک، شاخص‌های AO، PNA، Nino 3،4، Nino 1+2 و تراز آب در روزهای گذشته و برای منطقه مرطوب، AO، Nino 3،4 و Nino 1+2 و بارش هستند. Helali *et al.* (2022) در یک پژوهش به ارزیابی ۴۰ الگوی دورپیوند و چهار رویکرد یادگیری ماشین GRNN، MLP، LSSVM و MLR در پیش‌بینی و شبیه‌سازی بارش فصلی در شش حوضه اصلی در کشور ایران پرداختند. نتایج نشان داد بارش فصل‌های پاییز، زمستان و بهار به‌ترتیب با مقادیر الگوهای دورپیوند در یک تا چهار، چهار تا شش و یک تا چهار ماه گذشته، بیش‌ترین همبستگی را دارند.

با توجه به پژوهش‌های پیشین، مهم‌ترین الگوهای دور پیوند که می‌توانند کشور ایران را تحت تأثیر قرار دهند عبارتند از NAO، شاخص‌های خانواده ENSO، SCAND، EA/WR، DMI و SOI (Ahmadi *et al.*, 2019). همچنین یافته‌های پژوهشی با موضوع بررسی اثر الگوهای دورپیوند بر بارش در ایران (Farajzadeh *et al.*, 2013) و مطالعه دیگری در راستای تحلیل ارتباط میان الگوهای دورپیوند با دمای ماهانه در شمال غرب ایران (Khosravi and Mesgari, 2015)، اثرگذاری شاخص‌های نام‌برده بر کشور ایران را تأیید می‌کنند. با این‌حال، اثرگذاری تمامی شاخص‌های اقلیمی بر مناطق مختلف کشور همچنان به‌روشنی مشخص نیست و کشف نوع و شدت تأثیرگذاری این شاخص‌ها بر متغیرهای هیدرولوژیکی می‌تواند به افزایش دقت مدل‌های پیش‌بینی کمک کند. در این پژوهش به‌منظور پیش‌بینی جریان ورودی به سد امیرکبیر، از متغیرهای بارش، جریان ورودی و شاخص‌های اقلیمی مبتنی بر الگوهای دورپیوند با تأخیر تا شش ماه گذشته به‌عنوان ورودی سه مدل یادگیری ماشین شبکه عصبی مصنوعی (ANN)، شبکه عصبی بیزین (BNN) و سامانه استنتاج عصبی-فازی سازگار (ANFIS) استفاده شده است. در ادامه نتایج تأثیر شاخص‌های اقلیمی بر دقت مدل‌های پیش‌بینی جریان با مدل‌های نام‌برده ارزیابی و مناسب‌ترین پیش‌بینی‌کننده‌ها معرفی شده‌اند. بنابراین فرضیه اصلی این پژوهش عبارتست از این که الگوهای دورپیوند بر جریان ورودی به سدها مؤثر بوده و به‌کارگیری آن‌ها به‌عنوان متغیرهای پیش‌بینی‌کننده جریان قابلیت افزایش دقت مدل را داراست.

۲. مواد و روش‌ها

۲-۱. الگوهای دورپیوند^۱ (TP)

اساساً تغییرات آب‌وهوایی^۲، تفاوت میان آب‌وهوای واقعی (مشاهداتی) و میانگین موردانتظار آن است که ممکن است بر هر متغیر هیدرولوژیکی، از بارندگی و دما گرفته تا فشار هوا و بسیاری دیگر تأثیر بگذارد و عموماً به‌دلیل نوسانات طبیعی است. طبق مطالعات صورت‌گرفته، اغلب این تغییرات در سراسر جهان، ناشی از الگوهای دورپیوند هستند (Belteram and Carbonin, 2013; Salehizade *et al.*, 2015; Steirou *et al.*, 2017). الگوی دورپیوند به یک الگوی تکرارشونده، پیوسته و در مقیاس بزرگ از تغییرات فشار و گردش عمومی جو اشاره دارد که مناطق جغرافیایی وسیعی را در بر می‌گیرد. اگرچه این الگوها معمولاً چند هفته تا چند ماه دوام می‌آورند، اما گاهی اوقات می‌توانند برای چندین سال متوالی ادامه داشته باشند؛ بنابراین بخش مهمی از تغییرپذیری بین سالانه و بین دهه‌ای گردش جو را منعکس می‌کنند. بسیاری از الگوهای دورپیوند نیز در مقیاس سیاره‌ای ماهیت دارند و کل حوزه‌های اقیانوسی و قاره‌ها را در بر می‌گیرند. منطقه تحت نفوذ الگوهای دور پیوند متفاوت است. بعضی از الگوها تمام کره زمین را در بر می‌گیرد، در حالی که بعضی از الگوها مناطق شمالی اقیانوس اطلس، بعضی مناطق اوراسیا و بعضی مناطق شرق آمریکای شمالی تا مراکز اروپا را تحت

تأثیر قرار می‌دهند (NOAA, 2023). اثرگذاری این الگوها بر متغیرهای هیدرولوژیکی مانند بارش و دما توسط پژوهش‌های گذشته بررسی شده و به اثبات رسیده است، اما در مطالعات پیشین به نوع و شدت تأثیر این الگوها بر جریان ورودی به سد‌ها پرداخته نشده است. بنابراین در پژوهش حاضر قابلیت این الگوها در پیش‌بینی جریان در حوزه سد امیرکبیر مورد ارزیابی قرار گرفته است. در این پژوهش داده‌های مربوط به نه الگوی دورپیوند از سامانه آزمایشگاه علوم فیزیک سازمان ملی جوی-اقیانوسی جمع‌آوری شده که در جدول (۱) قابل مشاهده است.

Table 1. The names of the indices used in the present study

Teleconnection Index	Full Name
NAO	North Atlantic Oscillation
PDO	Pacific Decadal Oscillation
PNA	Pacific North American Index
WP	Western Pacific Index
NAO (Jones)	North Atlantic Oscillation (Jones <i>et al.</i> , 1997)
EA/WR	Eastern Atlantic/Western Russia
DMI	Dipole Mode Index
ONI	Oceanic Niño Index
Nino 3.4	East Central Tropical Pacific SST

یکی از برجسته‌ترین الگوهای دورپیوند در تمام فصول، نوسان اطلس شمالی (NAO) است (Barnston and Livezey, 1987). NAO متشکل از دو قطبی شمال-جنوب از ناهنجاری‌ها است که یک مرکز آن بر فراز گرینلند و مرکز مخالف بین عرض‌های جغرافیایی مرکزی اقیانوس اطلس شمالی (۳۵ تا ۴۰ درجه) قرار دارد. بنابراین مقدار این شاخص، برگرفته از ناهنجاری فشار سطح دریا بین جزایر آزور در پرتغال و جزیره ایسلند است. نوسان ده‌گانه‌ی اقیانوس آرام (PDO) یک نوسان طولانی‌مدت دمای سطح آب در اقیانوس آرام است. PDO تقریباً هر ۲۰ تا ۳۰ سال یک‌بار افزایش یا کاهش می‌یابد. PDO بین فازهای مثبت و منفی در نوسان است. فاز مثبت با دمای پایین‌تر از معمول سطح آب در شمال هاوایی و دمایی بالاتر از دمای معمولی سطح دریا در امتداد سواحل غربی آمریکای شمالی مشخص می‌شود. الگوی دورپیوند اقیانوس آرام / آمریکای شمالی (PNA)، یکی از برجسته‌ترین حالت‌های تغییرپذیری کم‌فرکانس در مناطق فراگرمسیری نیم‌کره شمالی است. فاز مثبت الگوی PNA دارای ارتفاعات ژئوپتانسیل بالاتر از حد متوسط در مجاورت هاوایی بر روی منطقه بین کوهستانی آمریکای شمالی و ارتفاعات ژئوپتانسیل کم‌تر از حد متوسط واقع در جنوب جزایر آلتوتی و بر فراز جنوب شرقی ایالات متحده قرار دارد. در طول زمستان و بهار، الگوی غرب اقیانوس آرام (WP) شامل یک دو قطبی شمالی-جنوبی از ناهنجاری‌هاست، که یک مرکز آن بر روی شبه‌جزیره کامچاتکا قرار دارد و یک مرکز گسترده دیگر با علامت مخالف، بخش‌هایی از جنوب شرقی آسیا و نیمه گرمسیری غربی اقیانوس آرام شمالی را پوشش می‌دهد. شاخص NAO پیش‌تر تعریف شد. با استفاده از ایستگاهی در بخش جنوب غربی شبه‌جزیره ایبری در جبل الطارق، می‌توان نسخه توسعه‌یافته این شاخص را برای نیمه زمستانی سال به‌دست آورد (Hurrell, 1995). برای زمستان، تفاوت فشار نرمال شده سطح دریا در جبل الطارق و فشار نرمال شده سطح دریا در جنوب غربی ایسلند، شاخص مفیدی برای نشان‌دادن قدرت NAO است. Jones *et al.* (1997)، از داده‌های ابزاری اولیه برای گسترش این شاخص تا سال ۱۸۲۳ استفاده کردند. الگوی اقیانوس اطلس شرقی / روسیه غربی (EATL/WRUS)، یکی از سه الگوی دورپیوند برجسته است که اوراسیا را در طول سال تحت تأثیر قرار می‌دهد. الگوی اقیانوس اطلس شرقی / روسیه غربی از چهار مرکز اصلی ناهنجاری تشکیل شده است. این الگو از میانگین اختلاف ارتفاع ژئوپتانسیل مثبت بین غرب اروپا و شمال چین و اختلاف ارتفاع ژئوپتانسیل منفی بین آتلانتیک شمالی و شمال دریای خزر محاسبه می‌شود. این الگو تقریباً در تمامی سال فعال بوده و دارای فاز مثبت و منفی است. دو قطبی اقیانوس هند (IOD)، یک نوسان نامنظم دمای سطح دریا و گردش جوی

مرتبط با آن در اقیانوس هند است. IOD دارای فازهای مثبت و منفی است. شدت IOD با گرادیان دمای سطح دریا بین غرب اقیانوس هند استوایی و جنوب شرقی اقیانوس هند استوایی نشان داده می‌شود. این گرادیان به‌عنوان شاخص حالت دوقطبی (DMI) نام‌گذاری شده است. هنگامی که DMI مثبت باشد، پدیده IOD مثبت و هنگامی که DMI منفی باشد، پدیده IOD منفی تلقی می‌شود (Saji and Yamagata., 2003). چندین شاخص برای پیش‌بخش استوایی اقیانوس آرام وجود دارند که همه آن‌ها براساس میانگین ناهنجاری‌های دمای سطح آب در یک منطقه معین هستند. معمولاً ناهنجاری‌ها نسبت به یک دوره پایه ۳۰ ساله محاسبه می‌شوند. شاخص Nino3.4 و ONI رایج‌ترین شاخص‌هایی هستند که برای تعریف رویدادهای ال‌نینو و لالینا استفاده می‌شوند. ناهنجاری‌های Nino3.4 نشان‌دهنده میانگین دمای سطح آب بخش استوایی اقیانوس آرام است که از حدود خط تاریخ (خط فرضی که دنباله نصف‌النهار مبدأ است و از اقیانوس آرام می‌گذرد) تا سواحل آمریکای جنوبی در نظر گرفته می‌شود.

۲-۲. مدل شبکه عصبی مصنوعی^۳ (ANN)

مدل‌های شبکه عصبی مصنوعی، سیستم‌هایی هستند که از فرایندهای عصبی در موجودات زنده الهام گرفته‌اند. شبکه‌های عصبی به‌طور گسترده‌ای به‌عنوان برآوردکننده، در بسیاری از سیستم‌های پیچیده مورد استفاده قرار گرفته‌اند در نوع پرسپترون چندلایه^۴، هدف، یادگیری نگاشت ورودی-خروجی با انتشار ورودی‌ها از طریق دنباله‌ای از لایه‌های پنهان متشکل از تبدیل‌های غیرخطی وزن دار، است. خروجی‌های یک شبکه رگرسیون با یک گره خروجی را می‌توان به‌صورت روابط (۳) و (۴) تعریف کرد:

$$f_k(x) = b_k + \sum_j v_{jk} h_j(x) \quad \text{رابطه ۳}$$

$$h_j(x) = \tanh \left(a_j + \sum_i w_{ij} x_i \right) \quad \text{رابطه ۴}$$

که در آن، w_{ij} رابط وزنی برای ورودی i ام به لایه پنهان j ام و v_{jk} رابطه وزنی بین لایه پنهان j ام و خروجی k ام است که در این مثال $k=1$ می‌باشد. تابع فعال‌ساز^۵ \tanh ، محیط غیرخطی مورد نیاز برای برآورد توابع غیرخطی پیچیده را فراهم می‌کند. توابع فعال‌ساز انواع مختلفی دارند که در سه گروه باینری (صفر و یکی)، خطی و غیرخطی دسته‌بندی می‌شوند. انتخاب نوع این توابع، از جمله پارامترهایی است که باید کالیبره شود. برای پیاده‌سازی مدل ANN از نرم‌افزار MATLAB استفاده شده است.

۲-۳. مدل شبکه عصبی بیزین^۶ (BNN)

پارامترهای مدل شبکه عصبی که پیش‌تر توضیح داده شد را می‌توان به‌منظور ایجاد فرض‌های احتمالی در مورد داده‌ها، تنظیم نمود. در این پژوهش، از چارچوب بیزین برای تنظیم این پارامترها استفاده شده است. چارچوب بیزین، امکان استفاده از یک شرایط اولیه را برای توزیع وزن‌های شبکه، فراهم می‌کند. ای شرایط را می‌توان به‌صورت منحصر به فرد و یا برای تمام وزن‌های موجود در شبکه تعریف کرد. اساس چارچوب بیزین، قضیه بیز است که توزیع پسین پارامترها را با توجه به داده‌ها و فرض توزیع پیشین، تعریف می‌کند. برای یک مدل شبکه عصبی با ساختار H (ورودی، لایه‌های پنهان و خروجی)، وزن‌های w و داده‌های آموزش D ، فرمول بیز به‌صورت رابطه (۵) تعریف می‌شود:

$$P(w|D.H) = \frac{P(D|w.H) P(w|H)}{P(D|H)} \quad \text{رابطه ۵}$$

که در این رابطه، $P(w|D.H)$ خوانده می‌شود؛ احتمال وقوع w به شرط وقوع همزمان D و H عبارتست از احتمال پسین وزن‌ها با در نظر گرفتن داده‌های آموزش و ساختار مدل. $P(D|w.H)$ عبارتست از احتمال درست‌نمایی داده‌های مورد استفاده برای آموزش مدل. $P(w|H)$ بیانگر توزیع اولیه یا پیشین وزن‌ها است. $P(D|H)$ احتمال داده‌های مورد استفاده در مدل است که از آن با عنوان شواهد یا مشاهدات یاد می‌شود. مراحل ساخت مدل BNN که در ادامه تشریح می‌شوند با زبان برنامه‌نویسی پایتون و در محیط Visual Studio کدنویسی و اجرا شده‌اند.

۲-۴. احتمال درست‌نمایی^۲

احتمال درست‌نمایی عبارتست از احتمال این که یک سری از پارامترهای محاسبه‌شده، بتوانند یک سری از داده‌های مشاهداتی را تولید نمایند. در مدل‌های یادگیری ماشین، ما سعی داریم پارامترهایی را به دست بیاوریم که بیانگر الگوی موجود در داده‌ها باشند. داده‌ها ثابت هستند؛ حال آن که پارامترها طی فرایند آموزش تغییر می‌کنند. در فرمول‌نویسی احتمالاتی، تابع خطایی که در رابطه (۵) تعریف شده را به عنوان منفی لگاریتم درست‌نمایی به مدل نوین معرفی می‌کنیم. اگر از مدل نوین گوسین با پارامتر β استفاده کنیم، درست‌نمایی به شکل رابطه (۶) تعریف خواهد شد:

$$P(D|w.\beta.H) = \frac{1}{Z_D(\beta)} \exp(-\beta E_D) \quad \text{رابطه ۶}$$

$$= \frac{1}{Z_D(\beta)} \exp\left(-\frac{\beta}{2} \sum_{i=1}^N (t^{(i)} - y(X^{(i)}; w))^2\right)$$

۲-۵. توزیع پیشین^۳

انتخاب یک توزیع اولیه، قیدها و محدودیت‌هایی را برای انتخاب وزن‌های شبکه اعمال می‌کند. معمولاً تابع گوسین با میانگین صفر و ضریب دقت α ، به عنوان توزیع اولیه وزن‌ها در نظر گرفته می‌شود که عبارتست از:

$$P(w|\alpha.H) = \frac{1}{Z_w(\alpha)} \exp(-\alpha E_w) \quad \text{رابطه ۷}$$

$$= \frac{1}{Z_w(\alpha)} \exp\left(-\frac{\alpha}{2} \sum_{i=1}^N w_i^2\right)$$

به طور مشابه $Z_w(\alpha)$ ثابت نرمال‌سازی است و E_w می‌تواند لگاریتم توزیع احتمالاتی پیشین وزن‌ها، در نظر گرفته شود.

۲-۶. توزیع پسین^۴

توزیع پسین وزن‌ها از رابطه (۸) به دست خواهد آمد که عبارتست از:

$$P(w|\alpha.\beta.H) = \frac{1}{Z(\alpha.\beta)} \exp(-(\alpha E_w + \beta E_D)) = \frac{1}{Z_M(\alpha.\beta)} \exp(-M(w)) \quad \text{رابطه ۸}$$

با انتخاب مقادیر مشخص برای α و β می‌توان بهترین وزن‌ها را به وسیله کمینه‌سازی لگاریتم احتمال پسین $M(w)$ و با استفاده از الگوریتم پس‌انتشار خطا، پیدا کرد (Mubvha et al., 2017). در شکل (۱)، ساختار مدل‌های ANN و BNN قابل مشاهده است.

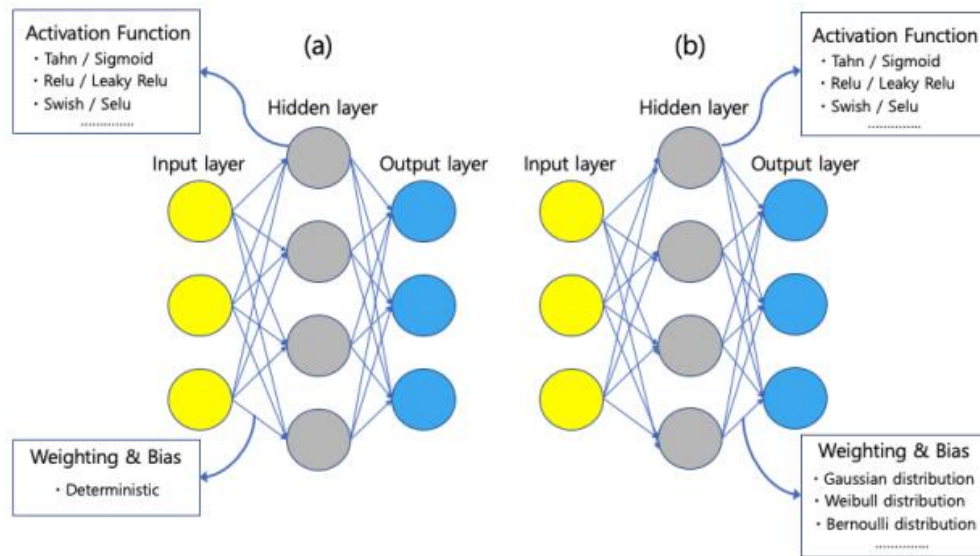


Figure 1. Architecture of (a) neural networks (NNs) and (b) Bayesian neural network (BNNs).

۲-۷. سامانه استنتاج عصبی - فازی سازگار^{۱۰} (ANFIS)

استنتاج فازی روشی است که مقادیر موجود در بردار ورودی را براساس مجموعه‌ای از قوانین به مقادیری در بردار خروجی تبدیل می‌کند. در این رویکرد بر خلاف رویکرد باینری، به یک گزاره درجه‌ای از عضویت اطلاق می‌شود. استنتاج فازی فرایند فرمول‌بندی نگاشت از یک ورودی به یک خروجی با استفاده از منطق فازی است. با استفاده از این رویکرد می‌توان بسیاری از مسائل تشخیص الگو، طبقه‌بندی و پیش‌بینی استفاده کرد. فرایند استنتاج فازی شامل توابع عضویت، عملگردهای منطقی و قوانین اگر-آنگاه می‌باشد (Rubaai *et al.*, 2008). به‌طور کلی دو نوع سیستم استنتاج فازی (FIS) وجود دارد که این دو عبارتند از سیستم استنتاج فازی ممدانی و سیستم استنتاج فازی سوگنو که در این پژوهش از سیستم سوگنو استفاده شده است. در سیستم استنتاج فازی سوگنو تاکاگی، تابع عضویت خروجی خطی و یا ثابت است. در این رویکرد خروجی هر قاعده به‌صورت رابطه (۹) می‌باشد:

$$\text{If } x \text{ is } A \text{ and } y \text{ is } B \text{ Then } z = px + qy + r \quad (\text{رابطه } ۹)$$

که در آن، A و B مجموعه‌های فازی (توابع عضویت)، z خروجی قاعده و p ، q و r ضرایب ثابت هستند. در مدل ANFIS به‌منظور تعیین وزن هر قاعده از قابلیت شبکه عصبی مصنوعی (ANN) بهره گرفته شده است تا وزن‌ها به‌صورت بهینه انتخاب و تعیین شوند. در واقع واژه سازگار از این جهت در مدل ANFIS گنجانده شده است که با هر ورودی خاص، وزن‌ها در سیستم استنتاجی مدل تغییر می‌یابد تا مدل بتواند به‌طور دقیق‌تر خروجی را پیش‌بینی کند تا در نهایت وزن بهینه هر قاعده تعیین شود. در شکل ۲، نمونه‌ای از یک مدل ANFIS از نوع سوگنو با پنج لایه نشان داده شده است.

در لایه اول فازی‌سازی داده‌ها با استفاده از توابع عضویت صورت می‌گیرد. در این لایه تمامی گره‌ها تطبیقی بوده و خروجی‌های این لایه درجه عضویت ورودی‌ها می‌باشد. لایه دوم، لایه مربوط به قوانین است که گره‌های این لایه ثابت هستند. این گره‌ها با نماد Π نشان داده شده‌اند. این گره‌ها دو سیگنال ورودی را در هم ضرب کرده و حاصل را به‌عنوان خروجی تحویل شبکه می‌دهد. سیگنال‌های ورودی این گره‌ها در واقع میزان سازگاری ورودی با هر یک از توابع عضویت و خروجی آن‌ها وزن مربوط به هر یک از قوانین است.

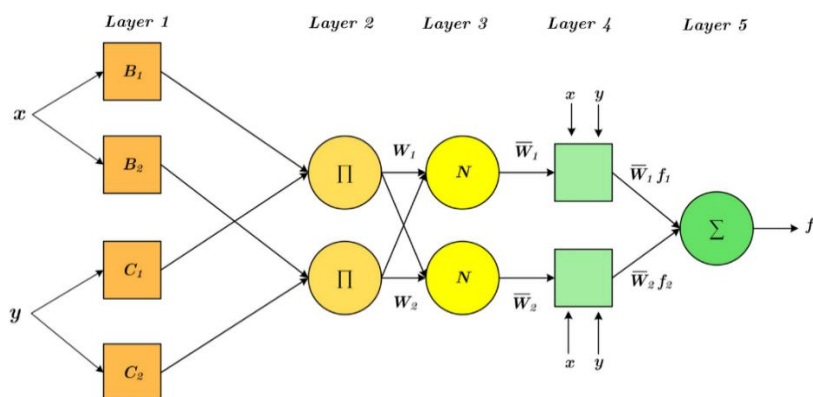


Figure 2. ANFIS structure derived from two inputs-one output first-order Sugeno FIS

گره‌های لایه سوم (نرمال‌سازی) نیز ثابت هستند. گره‌های این لایه با نماد N نشان داده شده‌اند. وظیفه این گره‌ها محاسبه وزن استاندارد شده هر یک از قوانین فازی است. گره‌های لایه چهارم وزن نرمال شده هر یک از قوانین فازی را در خروجی بخش مؤخره آن قانون ضرب می‌کنند. لایه پنجم یا لایه خروجی تنها یک گره دارد و ثابت است و با نماد S نشان داده شده است. در این لایه سیگنال‌های خروجی از لایه چهارم جمع شده و به‌عنوان خروجی تحویل شبکه داده می‌شود. برای پیاده‌سازی مدل ANFIS از نرم‌افزار MATLAB استفاده شده است.

۲-۸. معرفی الگوهای پیش‌بینی جریان

در رابطه با انتخاب الگوهای دورپیوند، به‌دلیل تعداد بالای این الگوها، تلاش شده تا مؤثرترین الگوها بر کشور ایران با توجه تحقیقات پیشین، مورد استفاده قرار بگیرند. در این راستا، نه شاخص اقلیمی به همراه داده‌های بارش و جریان ورودی به سد با تأخیر تا شش گام زمانی، به‌کار گرفته شده است. برای انتخاب مناسب‌ترین پیش‌بینی‌کننده‌ها از روش همبستگی تقاطعی^{۱۱} بهره گرفته شده که نتایج آن در جدول ۲ آمده است. در این روش میزان همبستگی هر یک از پارامترها با جریان ورودی به سد در ماه آینده، محاسبه شده است که نشان می‌دهد که در میان داده‌های ایستگاهی، بارش و جریان در یک و دو ماه گذشته بیش‌ترین همبستگی را با جریان ماه بعد دارند. در میان شاخص‌های اقلیمی نیز، شاخص PDO با دو گام زمانی تأخیر، شاخص Jones NAO با چهار گام زمانی تأخیر، شاخص ONI با شش گام زمانی تأخیر و شاخص Nino3.4 ماه قبل، بیش‌ترین همبستگی را با داده‌های جریان ماه آینده نشان دادند.

Table 2. Results of the Cross-Correlation

Time	Rainfall				Inflow			Teleconnection indices						
	Sira	Shahrstank	Nesa	Average	Sira	NAO	PDO	PNA	WP	Jones	NAO	EA/WR	DMI	ONI
t	0.40	0.45	0.42	0.45	0.71	0.03	0.22	0.03	0.02	-0.09	-0.01	0.07	0.04	0.40
t-1	0.47	0.46	0.47	0.48	0.36	0.05	0.27	0.07	0.03	0.02	0.05	0.04	0.06	0.36
t-2	0.42	0.38	0.44	0.43	-0.10	0.00	0.21	0.05	0.04	0.16	0.06	0.01	0.08	0.20
t-3	0.39	0.28	0.33	0.34	-0.29	0.03	0.15	0.05	0.05	0.21	0.04	0.01	0.08	0.02
t-4	0.30	0.23	0.27	0.27	-0.33	0.00	0.07	0.09	0.02	0.20	0.07	0.04	0.08	0.08
t-5	0.20	0.18	0.21	0.20	-0.31	0.03	-0.01	0.08	0.02	0.11	0.09	0.06	0.15	0.10

با توجه به نتایج همبستگی تقاطعی، شاخص مؤثر انتخاب و سناریوهای پیش‌بینی جریان طبق جدول (۳) طراحی شدند. به‌طور کلی برای ارزیابی اثر الگوهای دورپیوند بر جریان ورودی به سدها، سه دسته سناریو در نظر گرفته شده است که عبارتند از:

- سناریوهایی که تنها از متغیرهای ایستگاهی (بارش و دبی ایستگاه هیدرومتری) استفاده می‌کنند (بدون الگوهای دورپیوند).
- سناریوهایی که در آن‌ها فقط از یک الگوی دورپیوند استفاده شده است (الگوی دورپیوند منفرد).
- سناریوهایی که در آن‌ها از ترکیب الگوهای دورپیوند استفاده شده است (ترکیب الگوهای دورپیوند).

Table 3. Scenarios of Dam Inflow Prediction

Scenario	Type	Average Rainfall	Inflow	PDO	Jones NAO	ONI	Nino3.4
1			t				
2			t , t-1				
3	without TP	t	t				
4		t	t , t-1				
5		t , t-1	t , t-1				
6		t , t-1	t , t-1	t-1			
7	Individual TP	t , t-1	t , t-1		t-3		
8		t , t-1	t , t-1			t-5	
9		t , t-1	t , t-1				t
10		t , t-1	t , t-1	t-1			t
11	Multiple TPs	t , t-1	t , t-1	t-1	t-3		t
12		t , t-1	t , t-1	t-1	t-3	t-5	t

۹-۲. واسنجی و اعتبارسنجی مدل‌ها

در این پژوهش، ۸۰ درصد از داده‌ها برای مرحله واسنجی و ۲۰ درصد مابقی برای مرحله اعتبارسنجی استفاده شده است. به منظور جلوگیری از بیش‌برازش داده‌ها^{۱۲}، از انتخاب تصادفی داده‌ها برای مراحل آموزش و آزمون بهره گرفته شده است. رویکردی که برای آموزش مدل استفاده شده، رویکرد نزول گرادیان تصادفی^{۱۳} نام دارد. در این رویکرد لازم است تا دو پارامتر برای مدل تعریف شود. پارامتر Epoch و پارامتر Batch_size که در ادامه به توضیح هر یک پرداخته شده است.

الگوریتم نزول گرادیان تصادفی، یک الگوریتم بهینه‌سازی است که برای آموزش الگوریتم‌های یادگیری ماشین، به‌ویژه شبکه‌های عصبی مصنوعی مورد استفاده در یادگیری عمیق، استفاده می‌شود. وظیفه این الگوریتم، یافتن مجموعه‌ای از پارامترهای مدل داخلی است که در برابر برخی معیارهای ارزیابی عملکرد مانند میانگین مربعات خطا عملکرد خوبی دارند. اصولاً در این روش، کل داده‌ها به دسته‌هایی با اندازه مشخص تقسیم می‌شوند که به این دسته‌ها Batch گفته می‌شود. این پارامتر می‌تواند اندازه‌ای بین یک تا حجم کل نمونه اختیار کند. برای مثال، اگر ۳۲۰ نمونه داده داشته باشیم، مقدار پارامتر Batch می‌تواند از عدد یک تا عدد ۳۲۰ متغیر باشد. اگر برای مثال مقدار این پارامتر عدد ۳۲ در نظر گرفته شود، داده‌ها به ۱۰ دسته ۳۲ تایی تقسیم می‌شوند و با یک بار اجرای مدل در واقع ۱۰ مرتبه از داده‌ها استفاده می‌شود تا مدل آموزش ببیند. Epoch عبارتست از تعداد دفعاتی که تمام داده‌ها برای آموزش مدل استفاده می‌شوند. در کنار تعریف پارامترهای مذکور برای آموزش مدل، از تکنیک Shuffle استفاده شده است. با استفاده از این تکنیک بعد از هر بار اجرای کامل مدل (یک Epoch) ترتیب داده‌ها تغییر می‌کند تا داده‌های موجود در هر دسته نیز تغییر کرده و مدل دوباره آموزش ببیند. یعنی با هر بار اجرای مدل، داده‌ها دوباره به دسته‌های آموزش و صحت‌سنجی تقسیم می‌شوند که تکنیک Shuffle قبل از این دسته‌بندی پیاده‌سازی می‌شود. تکرار این روند باعث می‌شود تا داده‌ها در جایگشت‌های مختلفی برای آموزش مدل استفاده شوند و از آنجاکه با هر بار اجرای مدل داده‌های جدیدی برای آموزش استفاده می‌شوند، از بیش‌برازش مدل برای یک مجموعه داده خاص، جلوگیری می‌شود.

۱۰-۲. منطقه مورد مطالعه

محدوده مطالعاتی حوضه بالادست سد کرج (امیرکبیر) از لحاظ موقعیت سیاسی و اقتصادی اهمیت ویژه‌ای برخوردار است، زیرا حجم قابل توجهی از آب شرب و برق مورد نیاز استان‌های تهران و البرز از این سد تأمین می‌شود. حجم مخزن این سد چند منظوره ۱۰۱ میلیون مترمکعب می‌باشد و طول دریاچه پشت آن ۱/۱ کیلومتر است. حوضه آبریز سد کرج در مسافت ۱۰ تا ۹۰ کیلومتری شمال غرب تهران و در محدوده جغرافیایی ۵۰ درجه و ۳۰ دقیقه تا ۵۰ درجه و ۳۵ دقیقه و عرض جغرافیایی شمالی و ۳۵ درجه و ۱۱ دقیقه تا ۳۵ درجه و ۵۳ دقیقه طول شرقی گسترده است. وسعت حوضه مورد مطالعه در این پژوهش ۸۴۱ کیلومترمربع است و رودخانه‌های کرج، شهرستانک، آزادبار، ولایت رود، وارنگ رود و سیرا مهم‌ترین جریان‌های سطحی حوضه را تشکیل می‌دهند. با توجه به طول دوره آماری داده‌های ایستگاه هیدرومتری سیرا (سال آبی ۶۰-۱۳۵۹ تا سال آبی ۹۴-۱۳۹۳)، از داده‌های سه ایستگاه باران سنجی نسا، شهرستانک، سیرا و میانگین سه ایستگاه نام برده استفاده شده است. تمامی داده‌ها از سامانه دفتر مطالعات پایه منابع آب شرکت مدیریت منابع آب ایران استخراج شده است. مشخصات مربوط به ایستگاه‌های مورد استفاده در پژوهش حاضر در جدول ۴ قابل مشاهده است.

Table 4. Information of the Selected Stations

Station Name	Type	Latitude (°)	Longitude (°)	Elevation (m)	Selected Variable
Sira		51.15	36.03	1790	
Shahrestanak	Rain Gage	51.35	35.97	2150	Precipitation (mm)
Nesa		51.33	36.01	2300	
Sira	Hydrometer	51.12	36.01	1790	Discharge (m ³ /s)

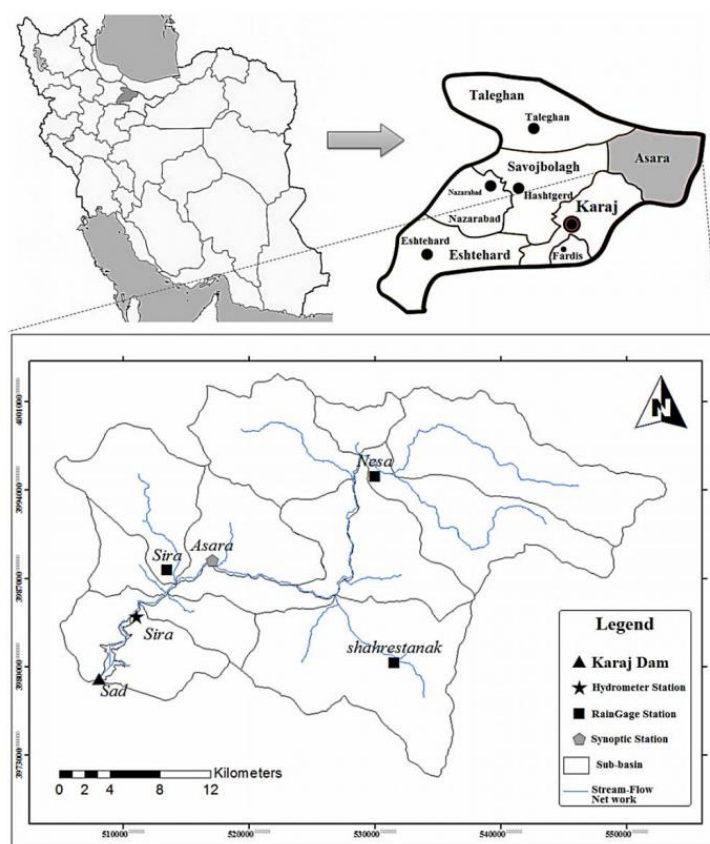


Figure 3. The study Area (Upstream catchment of Amirkabir Dam)

۳. نتایج و بحث

پس از اجرای ۱۲ سناریوی طراحی شده برای هر سه مدل، نتایج به دست آمده توسط شاخص‌های R^2 و RMSE ارزیابی شدند که در جدول (۳)، مقادیر آن‌ها آورده شده است. طبق جدول (۳)، سناریوهای شماره ۹، ۱۱ و ۵ به ترتیب بهترین عملکرد را داشته‌اند. رنگ سبز در این جدول نشان‌دهنده دقت بالاتر و رنگ قرمز بیانگر دقت پایین‌تر مدل‌ها می‌باشد. تنها تغییر سناریوی ۹ نسبت به سناریوی ۵، اضافه کردن شاخص Nino3.4 است، که نشان می‌دهد این شاخص بر جریان ورودی به سد امیرکبیر مؤثر بوده و می‌تواند موجب افزایش دقت پیش‌بینی شود. بیش‌ترین دقت پیش‌بینی متعلق به مدل ANFIS است که ضریب تبیین آن برای مراحل آموزش و آزمون به ترتیب برابر است با ۰/۸۶ و ۰/۷۹. در شکل (۴)، نتایج مدل ANFIS برای بهترین سناریو آورده شده است. همچنین نتایج مدل‌های ANN و BNN برای بهترین سناریو در شکل‌های (۵) و (۶) قابل مشاهده است.

Table 5. Comparison of models by performance indicators

Scenario	Test						Train					
	ANN		BNN		ANFIS		ANN		BNN		ANFIS	
	R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE
1	0.56	8.48	0.48	9.70	0.45	8.49	0.58	7.54	0.52	15.51	0.61	7.25
2	0.71	5.95	0.63	5.90	0.62	6.08	0.71	5.29	0.69	5.71	0.76	5.89
3	0.71	5.50	0.68	7.01	0.63	6.97	0.72	4.89	0.64	8.66	0.76	5.6
4	0.71	7.49	0.69	5.65	0.66	6.31	0.71	6.66	0.68	6.43	0.83	4.65
5	0.73	5.98	0.73	6.34	0.64	6.47	0.75	5.32	0.69	5.71	0.83	4.65
6	0.72	7.92	0.76	5.80	0.72	5.35	0.75	7.05	0.69	5.52	0.79	5.16
7	0.66	8.42	0.69	7.14	0.59	8.17	0.66	7.50	0.68	6.4	0.79	4.95
8	0.62	7.92	0.72	5.11	0.60	8.09	0.63	7.05	0.66	7.4	0.81	4.84
9	0.77	5.46	0.77	6.01	0.79	5.69	0.80	4.86	0.71	4.82	0.86	4.00
10	0.70	6.18	0.76	5.96	0.68	6.95	0.76	5.50	0.68	5.42	0.85	4.22
11	0.75	5.51	0.73	6.23	0.72	5.82	0.82	4.90	0.69	5.23	0.86	4.27
12	0.70	5.85	0.7	5.63	0.67	6.46	0.69	5.20	0.67	5.89	0.84	4.44

در شکل (۴)، نتایج مدل ANFIS برای بهترین سناریو آورده شده است. همچنین نتایج مدل‌های ANN و BNN برای بهترین سناریو در شکل‌های (۵) و (۶) قابل مشاهده است.




Figure 4. Comparison of Actual data and Predicted data by ANFIS in Test (A) and Train (B) stages of 9th Scenario




Figure 5. Comparison of Actual data and Predicted data by ANN in Test (A) and Train (B) stages of 9th Scenario

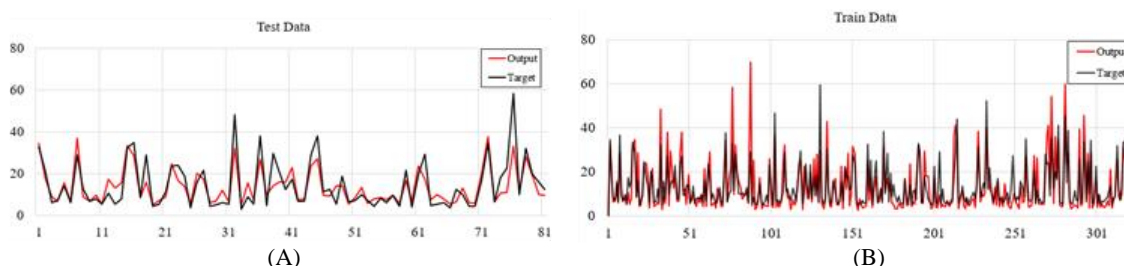


Figure 6. Comparison of Actual data and Predicted data by BNN in Test (A) and Train (B) stages of 9th Scenario

با این که نتایج هر سه مدل بسیار نزدیک به هم هستند، اما عمده خطای مدل BNN در مرحله آموزش از نوع بیش‌برآورد دبی‌های پیشینه است، درحالی‌که در مدل‌های ANFIS و ANN بخش عمده خطا در مرحله آموزش مربوط به کم‌برآورد کردن دبی‌های پیشینه است. هم‌چنین هر سه مدل قابلیت مناسبی در برآورد دبی‌های کمینه و متوسط در مراحل آموزش و آزمون دارند.

مطالعه پژوهش‌های پیشین نشان داد که اغلب پژوهش‌ها به بررسی اثر الگوهای دورپیوند بر بارش و دما در نقاط مختلف کشور پرداخته‌اند و در پژوهش‌های محدودی اثر این الگوهای روی جریان ورودی به سدها دیده شده است. بنابراین در ادامه تلاش شده تا به مقایسه یافته‌های پژوهش‌های حاضر با نتایج مطالعات پیشین، که اثر الگوهای دورپیوند را بر تغییرات آب‌وهوایی کشور ایران بررسی کرده‌اند، پرداخته شود. هم‌چنین عملکرد مدل‌های ANFIS، ANN و BNN تحت سناریوهای تدوین‌شده در پژوهش حاضر، با عملکرد سایر مدل‌های پیش‌بینی که برای پیش‌بینی جریان ورودی به سد امیرکبیر به کارگرفته شده‌اند، مقایسه شده است.

تعدادی از پژوهش‌ها به بررسی الگوهای دورپیوند بر آب‌وهوای کل کشور پرداخته‌اند و در نهایت تأثیرگذارترین شاخص‌ها را معرفی کرده‌اند. Yarahmadi and Azizi (2008)، در مقاله‌ای ضمن بررسی ارتباط بین الگوهای دورپیوند و بارش ۲۵ ایستگاه در سراسر کشور به این نتیجه رسیدند که بیش‌ترین اثرات در فصل پاییز و زمستان وجود دارد و شاخص Nino3.4 بالاترین ارتباط را دارا می‌باشد. طبق نتایج پژوهش Talebi (2012)، به‌طور کلی بارش و دمای کشور متأثر از شاخص NAO است؛ اگرچه این تأثیرپذیری در مناطق مختلف از شدت و ضعف برخوردار است، اما در مجموع تأثیر شاخص NAO بر غرب و شمال‌غرب کشور بیش‌تر از مرکز کشور است. Azizi *et al.* (2014) اثرگذاری شاخص‌های NAO و SOI را بر کل کشور ایران بررسی کردند که نتایج نشان داد ارتباط معنی‌داری بین این شاخص‌ها و بارش فصل پاییز وجود دارد. Ahmadi *et al.* (2019) با استفاده از داده‌های ۳۶ ایستگاه سینوپتیک، به بررسی اثر ۳۴ شاخص اقلیمی بر بارش کشور ایران پرداختند که نتایج نشان داد شاخص‌های Nino3.4، AMO و AO به‌ترتیب مؤثرترین شاخص‌ها بر بارش کشور هستند. بنا بر نتایج پژوهش‌های پیشین، به‌طور کلی بیش‌ترین تأثیرپذیری اقلیم ایران از شاخص‌های نوسان اطلس شمالی (NAO) و نوسان جنوبی (خانواده ENSO) است، که با یافته‌های پژوهش حاضر هم‌خوانی دارد؛ چراکه مطابق جدول (۵)، شاخص Nino3.4 به‌عنوان مؤثرترین شاخص بر رواناب ورودی به سدها شناخته شده است.

در زمینه پیش‌بینی جریان ورودی به سد امیرکبیر، Mohammadi *et al.* (2005)، به مقایسه عملکرد مدل‌های ANN و ARIMA در پیش‌بینی رواناب ورودی به این سد در فصل بهار پرداختند که مدل ANN دقت بالاتری در برآورد جریان داشت. مقدار شاخص RMSE برای بهترین سناریو پیش‌بینی که دربرگیرنده متغیرهای بارش، دبی و آب معادل برف در فصل زمستان بود، برابر است با ۱۷/۶۳ که در مقایسه با مقادیر به‌دست‌آمده در پژوهش حاضر

که برای مدل‌های ANN، BNN و ANFIS به ترتیب برابرند با ۵/۴۶، ۶/۰۱ و ۵/۶۹، دقت کم‌تری دارد. Sohrabi and Bozorg Haddad (2007)، با استفاده از شبکه عصبی مصنوعی سه لایه، به پیش‌بینی جریان ماهانه ورودی به سد امیرکبیر، طی یک دوره ۲۹ ساله، پرداختند. بالاترین مقدار شاخص R^2 به دست آمده از معماری‌های مختلف شبکه عصبی در این پژوهش برابر است با ۰/۶۴ که در مقایسه با بهترین خروجی از مدل‌های ANN، BNN و ANFIS که شاخص R^2 آن‌ها به ترتیب برابر است با ۰/۷۷، ۰/۷۷ و ۰/۷۹، دقت پایین‌تری دارد. می‌توان نتیجه گرفت، استفاده از الگوهای دورپیوند می‌تواند باعث افزایش دقت مدل‌های پیش‌بینی شوند، اما همچنان کشف نوع و زمان اثرگذاری این شاخص‌ها بر متغیرهای هیدرولوژیکی نیازمند پژوهش‌های گسترده‌تری است. بنابراین لازم است تا تأثیر الگوهای دورپیوند به تفکیک مناطق، ماه‌ها و فصول مختلف بررسی شوند تا بتوان درک بهتری از نحوه اثرگذاری این الگوها بر متغیرهای هیدرولوژیکی و هواشناسی در کشور به دست آورد.

۴. نتیجه‌گیری

در این پژوهش به منظور بررسی تأثیر الگوهای دورپیوند بر جریان ورودی به سد امیرکبیر از سه مدل یادگیری ماشین شامل شبکه عصبی مصنوعی، شبکه عصبی بیزین و سامانه استنتاج عصبی-فازی سازگار استفاده شد. به منظور انتخاب بهترین متغیرهای پیش‌بینی‌کننده از روش همبستگی تقاطعی بهره گرفته شد و طبق نتایج آن سناریوهای پیش‌بینی جریان تدوین شد. نتایج ارزیابی مدل‌ها با شاخص‌های ریشه میانگین مربعات خطا و نیز ضریب تبیین نشان داد که سناریوی شماره ۹ که متغیرهای پیش‌بینی‌کننده در آن عبارتند از بارش یک و دو ماه قبل، دبی ورودی به سد در یک و دو ماه قبل و شاخص Nino3.4 در ماه قبل، در هر سه مدل بالاترین دقت را داراست که تأثیرگذاری شاخص Nino3.4 را تأیید می‌کند. همچنین مدل ANFIS با مقادیر $RMSE=5/69$ مترمکعب بر ثانیه و $R^2=0/79$ ، در مرحله صحت‌سنجی، دقت بالاتری را نسبت به مدل‌های ANN و BNN به ثبت رساند. می‌توان نتیجه گرفت که به کارگیری الگوهای دورپیوند به عنوان پیش‌بینی‌کننده می‌تواند موجب افزایش دقت پیش‌بینی جریان در ماه‌های آینده شود. همچنین با توجه به شاخص‌های ارزیابی، هر سه مدل ANN، BNN و ANFIS از عملکرد قابل‌قبولی برای پیش‌بینی جریان برخوردارند. امروزه عموماً از الگوریتم‌های بهینه‌سازی برای بالابردن دقت برآورد و تنظیم مقادیر پارامترهای مدل‌های هوش مصنوعی استفاده می‌شود. از آنجاکه در این پژوهش از الگوریتم‌های بهینه‌سازی برای دستیابی به بهترین مقادیر پارامترهای مدل‌های به کار گرفته شده، استفاده نشده است، پیشنهاد می‌شود که برای ارزیابی دقیق‌تر این مدل‌ها، از این الگوریتم‌ها برای بهینه‌کردن پارامترها استفاده شده و نتایج حاصل با سایر مدل‌ها مقایسه شود. با توجه به اهمیت جریان ورودی در به‌روزرسانی و تدوین یک منحنی فرمان مناسب برای سدها، نتایج این پژوهش می‌تواند با هدف برنامه‌ریزی سدهای مورد مطالعه به منظور تخصیص به پایین دست به مصارف مختلف، به‌ویژه کشاورزی، به منظور حل مشکلات تأمین آب و دیگر اهداف مدنظر، نظیر قراردادهای فروش آب، انرژی برقی و آمادگی مقابله با خشکسالی و سیلاب با بیش‌ترین میزان اطمینان‌پذیری، به کار گرفته شود. محدودیت‌های اصلی این پژوهش، مواردی از جمله در دست نبودن داده‌های ایستگاهی بلندمدت برای متغیر برف و هم‌چنین عدم وجود داده‌های پوشش گیاهی، جنس خاک و کاربری اراضی را شامل می‌شود که پیشنهاد می‌شود در پژوهش‌های آتی این داده‌های از تصاویر ماهواره‌ای استخراج و مورد استفاده قرار بگیرند.

۵. پی‌نوشت‌ها

1. Teleconnection Patterns
2. Climate Variability
3. Artificial Neural Network
4. Multilayer Perceptron
5. Activation
6. Bayesian Neural Network
7. Likelihood
8. Prior Distribution
9. Posterior Distribution
10. Adaptive Neuro-Fuzzy Inference System
11. Cross-Correlation
12. Overfitting
13. Stochastic Gradient Descent

۶. تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

۷. منابع

- Banihabib, M. E., & Jamali, F. S. (2011). Comparison of Dynamic Artificial Neural Network and Multivariate Linear Regression Models for Inflow Forecasting Using Remote Sensing Data, 20(2), 173. (In Persian)
- Barnston, A. G., & Livezey, R. E. (1987). Classification, seasonality, and persistence of low-frequency atmospheric circulation patterns. *Monthly weather review*, 115(6), 1083-1126.
- Hurrell, J. W. (1995). Decadal trends in the North Atlantic Oscillation: Regional temperatures and precipitation. *Science*, 269(5224), 676-679.
- Jones, P. D., Jónsson, T., & Wheeler, D. (1997). Extension to the North Atlantic Oscillation using early instrumental pressure observations from Gibraltar and southwest Iceland. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 17(13), 1433-1450.
- Saji, N. H., & Yamagata, T. J. C. R. (2003). Possible impacts of Indian Ocean dipole mode events on global climate. *Climate Research*, 25(2), 151-169.
- Mohammadi, K., Eslami, H. R., & Dayyani, D. S. (2005). Comparison of regression, ARIMA, and ANN models for reservoir inflow forecasting using snowmelt equivalent (a case study of Karaj). *Journal of Agriculture-Science-Technology*, 7, 17-30. (In Persian)
- Sohrabi, S., & Bozorg Haddad, O. (2007). The artificial neural network model in predicting the inflow to the reservoirs of dams, the fourth national conference of watershed science and engineering of Iran, watershed management, Karaj. (In Persian)
- Rubaai, A., Castro-Sitiriche, M. J., & Ofoli, A. R. (2008). Design and implementation of parallel fuzzy PID controller for high-performance brushless motor drives: an integrated environment for rapid control prototyping. *IEEE Transactions on Industry Applications*, 44(4), 1090-1098.
- Yarahmadi, D., & Azizi, Gh. (2008). Multivariate analysis of relationship between seasonal rainfall in Iran with climate indices. *Geographical Research Quarterly*, 39(62), 161-174. (In Persian)
- Talebi, Z. (2012). The effect of Teleconnection pattern of the North Atlantic Oscillation (NAO) on reference evapotranspiration in the western regions of the Iran. Thesis. (In Persian)

- Farajzadeh, M., Ahmadi, M., Alijani, B., Qavidel Rahimi, Y., Mofidi, A., & Babaeian, I. (2013). Study on Variation of Major Teleconnection Patterns (MTP) associated with Iran's Precipitation. *Journal of Climate Research*, 1392(15), 31-45. (In Persian)
- Beltram, L., & Carbonin, D. (2013). ENSO teleconnection patterns on large-scale water resources systems. Thesis.
- Kumar, S., Tiwari, M. K., Chatterjee, C., & Mishra, A. (2015). Reservoir inflow forecasting using ensemble models based on neural networks, wavelet analysis, and bootstrap method. *Water resources management*, 29(13), 4863-4883.
- Azizi, G., Chehreara, T., & Safarrad, T. (2014). Simultaneous Effects of NAO and SOI Phases on Iran's Climate. *Geography and Environmental Sustainability*, 4(3), 43-56. (In Persian)
- Salehzade, A. A., Rahmanian, M., Farajzadeh, M., & Ayoubi, A. (2015). Analysis of temperature changes on electricity consumption in Fars Province. *Mediterranean Journal of Social Sciences*, 6(3 S2), 610.
- Block, P. (2016). Tailoring seasonal climate forecasts for hydropower operations. *Meteorology and Energy Security: Simulations, Projections, and Management*, 179.
- Babae Fini, O., & Fattahi, E. (2015). Seasonal Prediction of Discharge Entering into Uremia Lake by Using Climatic Large Scale Signals. *Geography and Development*, 13(40), 109-124. (In Persian)
- Ahmadi, F., Radmanesh, F., & Mir Abbasi Najaf Abadi, R. (2016). Application of Bayesian Networks and Genetic Programming for Predicting Daily River Flow (Case Study: Barandoozchay River). *Irrigation Sciences and Engineering*, 39(4), 213-223. (In Persian)
- Sedighi, F., Vafakhah, M., & Javadi, M. R. (2016). Application of Artificial Neural Network for Snowmelt-Runoff (Case Study: Latyan Dam Watershed). *Journal of Watershed management research*. 6 (12):43-54. (In Persian)
- Khosravi, D., & Mesgari, E. (2016). Spatial Analysis of Relationship Between Teleconnection Patterns and Monthly Temperature of Northwest Iran. *Geography and Territorial Spatial Arrangement*, 6(21), 203-214. (In Persian)
- Misaghi, F. (2016). Forecasting of the Alavian Dam Inflow Water Using Optimized Adaptive Neuro-Fuzzy Inference System (OANFIS). *Iranian Journal of Soil and Water Research*, 47(3), 439-448. (In Persian)
- Ruigar, H., & Golian, S. (2016). Prediction of precipitation in Golestan dam watershed using climate signals. *Theoretical and applied climatology*, 123(3), 671-682.
- Mbuvha, R., Jonsson, M., Ehn, N., & Herman, P. (2017, November). Bayesian neural networks for one-hour ahead wind power forecasting. In *2017 IEEE 6th International Conference on Renewable Energy Research and Applications (ICRERA)* (pp. 591-596). IEEE.
- Mohammadi, M., Karami, H., Farzin, S., & Farokhi, A. (2017). Prediction of Monthly Precipitation Based on Large-scale Climate Signals Using Intelligent Models and Multiple Linear Regression (Case Study: Semnan Synoptic Station). *Iranian Journal of Ecohydrology*, 4(1), 201-214. (In Persian)
- Saligheh, M., & Sayadi, F. (2017). Summer precipitation determinant factors of Iran's South-East. *Natural Environment Change*, 3(1), 59-70. (In Persian)
- Steirou, E., Gerlitz, L., Apel, H., & Merz, B. (2017). Links between large-scale circulation patterns and streamflow in Central Europe: A review. *Journal of Hydrology*, 549, 484-500.
- Yang, T., Asanjan, A. A., Welles, E., Gao, X., Sorooshian, S., & Liu, X. (2017). Developing reservoir monthly inflow forecasts using artificial intelligence and climate phenomenon information. *Water Resources Research*, 53(4), 2786-2812.
- Alessandro, G. (2018). Informing water reservoir operations with climate teleconnections. Thesis.

- Kim, K., Lee, S., & Jin, Y. (2018). Forecasting quarterly inflow to reservoirs combining a copula-based Bayesian network method with drought forecasting. *Water*, 10(2), 233.
- Banihabib, M. E., Ahmadian, A., & Valipour, M. (2018). Hybrid MARMA-NARX model for flow forecasting based on large-scale climate signals, sea-surface temperatures, and rainfall. *Hydrology Research*, 49(6), 1788-1803.
- Ahmadi, M., Salimi, S., Hosseini, S. A., Poorantiyosh, H., & Bayat, A. (2019). Iran's precipitation analysis using synoptic modeling of major teleconnection forces (MTF). *Dynamics of Atmospheres and Oceans*, 85, 41-56.
- Babaei, M., Moeini, R., & Ehsanzadeh, E. (2019). Artificial neural network and support vector machine models for inflow prediction of dam reservoir (Case study: Zayandehroud dam reservoir). *Water Resources Management*, 33(6), 2203-2218.
- Samadi, M., & Fathabadi, A. (2019). Application of Time Series, ANN, and SVM Models in Forecasting the Gorgan Dam Inflow Rate. *Environment and Water Engineering*, 4(4), 299-309. (In Persian)
- Esmaili, K., Gandomkar, A., & Khodagholi, M. (2020). Identifying the Trend of Temperature Changes in the South Iranian Coasts and its Relationship with Teleconnections. *Physical Geography Quarterly*, 13(49), 1-22. (In Persian)
- Sabziparvar, A., Firoozmand, Z., & Varshavian, V. (2020). The Impact of Teleconnection Phenomena on Shifting the Date of First Autumn and Last Spring Frost Events: *Physical Geography Research Quarterly*, 52(2), 295-311. (In Persian)
- Maryanaji, Z., Tapak, L., & Hamidi, O. (2019). Climatic and atmospheric indices teleconnection impact the characteristics of frost season in western Iran. *Journal of Water and Climate Change*, 10(2), 391-401.
- Noorbeh, P., Roozbahani, A., & Kardan Moghaddam, H. (2020). Annual and monthly dam inflow prediction using Bayesian networks. *Water Resources Management*, 34(9), 2933-2951.
- Rasouli, K., Nasri, B. R., Soleymani, A., Mahmood, T. H., Hori, M., & Haghighi, A. T. (2020). Forecast of streamflows to the Arctic Ocean by a Bayesian neural network model with snow cover and climate inputs. *Hydrology Research*, 51(3), 541-561.
- Wagena, M. B., Goering, D., Collick, A. S., Bock, E., Fuka, D. R., Buda, A., & Easton, Z. M. (2020). Comparison of short-term streamflow forecasting using stochastic time series, neural networks, process-based, and Bayesian models. *Environmental Modelling & Software*, 126, 104669.
- Wang, J., Wang, X., hui Lei, X., Wang, H., hua Zhang, X., jun You, J., feng Tan, Q., & lian Liu, X. (2020). Teleconnection analysis of monthly streamflow using ensemble empirical mode decomposition. *Journal of Hydrology*, 582, 124411.
- Zhang, X., Wang, H., Peng, A., Wang, W., Li, B., & Huang, X. (2020). Quantifying the uncertainties in data-driven models for reservoir inflow prediction. *Water Resources Management*, 34(4), 1479-1493.
- Lee, D., Kim, H., Jung, I., & Yoon, J. (2020). Monthly reservoir inflow forecasting for the dry period using teleconnection indices: a statistical ensemble approach. *Applied Sciences*, 10(10), 3470.
- Linh, N. T. T., Ruigar, H., Golian, S., Bawoke, G. T., Gupta, V., Rahman, K. U., Sankaran, A., & Pham, Q. B. (2021). Flood prediction based on climatic signals using wavelet neural network. *Acta Geophysica*, 69(4), 1413-1426.
- Latif, S. D., Ahmed, A. N., Sathiamurthy, E., Huang, Y. F., & El-Shafie, A. (2021). Evaluation of deep learning algorithm for inflow forecasting: a case study of Durian Tunggal Reservoir, Peninsular Malaysia. *Natural Hazards*, 109(1), 351-369.

- Panahi, F., Ehteram, M., Ahmed, A. N., Huang, Y. F., Mosavi, A., & El-Shafie, A. (2021). Streamflow prediction with large climate indices using several hybrid multilayer perceptrons and copula Bayesian model averaging. *Ecological Indicators*, 133, 108285.
- Behzadi, F., Javadi, S., Yousefi, H., & Moridi, A. (2022). Investigation and analysis of the effect of drought on groundwater aquifers in Iran (Case study: Shahrekord plain): *Journal of Water and Irrigation Management*, 12(2), 327-348. (In Persian)
- Chu, H., Bian, J., Lang, Q., Sun, X., & Wang, Z. (2022). Daily Groundwater Level Prediction and Uncertainty Using LSTM Coupled with PMI and Bootstrap Incorporating Teleconnection Patterns Information. *Sustainability*, 14(18), 11598.
- Helali, J., Ghaleni, M. M., Hosseini, S. A., Siraei, A. L., Saeidi, V., Safarpour, F., Mirzaei, M., & Lotfi, M. (2022). Assessment of machine learning model performance for seasonal precipitation simulation based on teleconnection indices in Iran. *Arabian Journal of Geosciences*, 15(15), 1-24.
- NOAA. (2023). NOAA's National Weather Service Climate Prediction Center. <https://www.cpc.ncep.noaa.gov/data/teledoc/teleintro.shtml>. Accessed 1/12/2023.
- NOAA. (2023). NOAA's National Weather Service Glossary. <https://w1.weather.gov/glossary>. Accessed 1/12/2023.