

## پیش‌بینی کوتاه‌مدت خشک‌سالی هیدرولوژیکی با استفاده از روش مبتنی بر یادگیری عمیق

عباس نوری نژاد<sup>۱</sup>، فرهاد هوشیاری پور<sup>۲\*</sup>، مجید دهقانی<sup>۳</sup>

<sup>۱</sup> فارغ التحصیل کارشناسی ارشد، دانشکده عمران، معماری و هنر، واحد علوم تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.  
<sup>۲\*</sup> دانشکده عمران، معماری و هنر، واحد علوم تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. (نویسنده مسوول: hooshyariyor@srbiau.ac.ir)

<sup>۳</sup> دانشیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه ولی عصر (عج) رفسنجان، رفسنجان، ایران

تاریخ دریافت: ۱۴۰۱/۱۱/۰۱

تاریخ اصلاح: ۱۴۰۲/۰۶/۰۹

تاریخ پذیرش: ۱۴۰۲/۰۶/۲۲

### چکیده

خشک‌سالی هیدرولوژیکی بر تخصیص آب و تولید برق‌آبی تأثیر می‌گذارد. از این جهت پیش‌بینی خشک‌سالی می‌تواند به مدیریت بهینه منابع آب کمک نماید. در این مقاله، خشک‌سالی هیدرولوژیکی کوتاه‌مدت بر اساس یادگیری عمیق پیش‌بینی شد. برای این منظور، شاخص استاندارد خشک‌سالی هیدرولوژیکی (SHDI) در بازه‌های یک، سه و شش ماه محاسبه شد. سپس، سه حالت کلی برای پیش‌بینی SHDI و ترکیب ورودی-خروجی استخراج شدند. در مرحله بعد، الگوریتم‌های مختلف بهینه‌سازی، از جمله الگوریتم بهینه‌سازی ملخ، الگوریتم ازدحام نمک، بهینه‌سازی مبتنی بر جغرافیای زیستی، و بهینه‌سازی ازدحام ذرات ترکیب‌شده با ANN برای پیش‌بینی SHDI مورد استفاده قرار گرفتند. در این تحقیق ۷۰٪ داده‌ها برای آموزش و ۳۰٪ برای آزمایش مدل‌ها در نظر گرفته شدند. در نهایت عملکرد شبکه عصبی عمیق (DNN) در مقایسه با نتایج مدل‌های ترکیبی و ANN نشان داد که مدل‌های ترکیبی عملکرد بهتری داشته‌اند ولی در مقایسه با یادگیری عمیق توانایی آنها کم‌تر است. یادگیری عمیق بدون نیاز به تعریف ترکیب ورودی‌ها، توانست مقدار RMSE را به ۰/۳۲ کاهش دهد.

**واژگان کلیدی:** خشک‌سالی هیدرولوژیکی، یادگیری عمیق، پیش‌بینی، شاخص استاندارد خشک‌سالی هیدرولوژیکی

### Short-Term Prediction Of Hydrological Drought Using Deep Learning-Based Method

Abbas Noorinejad<sup>1</sup>, Farhad Hooshyari<sup>2\*</sup>, Majid Dehghani<sup>3</sup>

<sup>1</sup>MSc Graduated, Faculty of Civil Engineering, Architecture and Art, Sciences and Research Branch, Islamic Azad University, Tehran, Iran.

<sup>2\*</sup> Faculty of Civil Engineering, Architecture and Art, Sciences and Research Branch, Islamic Azad University,

Tehran, Iran. (Corresponding author: hooshyaripor@srbiau.ac.ir)

<sup>3</sup>Associate Professor, Technical and Engineering Department, Faculty of Civil Engineering, Vali-e-Asr University of Rafsanjan, Rafsanjan, Iran

Received: 21/01/2023

Revised: 31/08/2023

Accepted: 13/09/2023

## Abstract

plays an essential role in water resources management. Hydrological drought affects water allocation and hydropower generation. Therefore, hydrological drought prediction can help for optimal water resources management. In this paper, short-term hydrological drought was predicted using deep learning. Doing so, Standardized Hydrological Drought Index (SHDI) was calculated in one, three and six months periods. Then, 36 combinations and three different modes of input variables were considered to predict SHDI. In the next step, various optimization algorithms, including grasshopper optimization algorithm, salt swarm algorithm, biogeography-based optimization, and particle swarm optimization combined with ANN were used to predict SHDI. Here, 70% of the data were considered for training and the remaining 30% for test. Finally, the performance of deep learning (DNN) compared to the combined ANN-SSA, -BBO, -PSO and -GOA were discussed. The results of ANN compared to the combined models showed that the combined models performed better, but they are less compatible to DNN. In the DNN on one hand does not need to define the input combination, and on the other hand could reduce the value of RMSE to 0.32.

**Keywords:** Hydrologic Drought, Deep Learning, Prediction, Standardized Hydrologic Drought Index

معمولاً بر منطقه وسیعی تأثیر می‌گذارد (Cui et al., 2021). بارندگی ناکافی یا تبخیر بیش از حد پایدار در یک دوره زمانی طولانی می‌تواند منجر به خشک‌سالی هواشناسی شود. خشک‌سالی هیدرولوژیکی با سطح ناکافی و منابع آب زیرسطحی تعریف می‌شود؛ به این ترتیب، رواناب ناکافی منجر به خشک‌سالی هیدرولوژیکی خواهد شد. شواهد زیادی وجود دارد که خشک‌سالی می‌تواند به‌طور فزاینده‌ای بر جوامع انسانی و همچنین عملکرد اکوسیستم تأثیر بگذارد (Hooshyaripor et al. 2022). با این حال، پیش‌بینی دقیق خشک‌سالی هنوز یک چالش است و محققان به دنبال جنبه‌های مختلفی هستند که می‌تواند واقعیت زمین را منعکس کند. از آنجایی که تعریف خشک‌سالی مهم است، شاخص‌ها بر اساس متغیرهای خاص و وابستگی آن‌ها به نوع خشک‌سالی در حال تجزیه و تحلیل توسعه یافتند (Salimi et al., 2021). امروزه پیش‌بینی خشک‌سالی برای برنامه‌ریزی‌های آینده در زمینه‌های طبیعی و انسانی از اهمیت بالایی برخوردار است. از جمله می‌توان به پیش‌بینی خشک‌سالی و سیل و... اشاره کرد که در این صورت می‌توان با برنامه‌ریزی مدون

## ۱- مقدمه

خشک‌سالی و سیلاب دو پدیده اقلیمی حدی هستند که پیامدهای ناگواری برای جامعه انسانی، اکوسیستم، کشاورزی و منابع آبی دارند (Hooshyaripor and Yazdi, 2017; Williams et al., 2020). پیش‌بینی می‌شود که وقوع خشک‌سالی شدید در سراسر جهان افزایش یابد (Vicente-Serrano et al., 2015). خشک‌سالی‌ها در دهه‌های اخیر به دلیل تأثیرات انسان بر تغییرات جوی، شدیدتر، مکرر و گسترده‌تر شده‌اند (Khan et al., 2020). خشک‌سالی بر اساس ماهیت کمبود به چهار دسته تقسیم می‌شود: هواشناسی، هیدرولوژیکی کشاورزی و اجتماعی-اقتصادی (Heim Jr, 2002). خشک‌سالی هیدرولوژیکی به دلیل پیامدهای فاجعه باری که برای منابع آب‌های زیرزمینی و سطحی دارد، بیشترین توجه دولت‌ها، سهامداران، محققان و عموم مردم را به خود جلب می‌کند. خشک‌سالی هیدرولوژیکی از طریق کاهش میزان ذخیره آب دریاچه‌ها، پایین رفتن سطوح آب‌های زیرزمینی و کاهش دبی جریان رودخانه‌های تشخیص داده می‌شود و

از خسارات احتمالی کاست (Hooshyaripor et al. 2022). علوی نیا و همکاران (۱۳۹۰) با استفاده از آمار بلندمدت ایستگاه‌های بارانسنجی و هیدرومتری حوضه آبریز کارون یک و با بهره‌گیری از شاخص بارش استاندارد شده<sup>۱</sup> (SPI) و شاخص خشکسالی آبهای سطحی، یک مدل تجربی برای پیش‌بینی خشکسالی هیدرولوژیکی ارائه کردند.

کرمی و برهانی داریان (۱۳۹۳) روش‌های جیره‌بندی برای مدیریت مخازن در شرایط خشکسالی را ارزیابی کردند. اقتداری و همکاران (۱۳۹۵) خشکسالی هیدرولوژیک حوضه‌ی آبریز کرخه را با استفاده از شاخص استاندارد شده دبی<sup>۲</sup> (SDI) و زنجیره مارکف نایستا، پیش‌بینی کردند. در حالی که همبستگی بین دو شاخص SDI و SPI ضعیف بود، نتایج همبستگی و ارتباط بین مقادیر SDI در دوره‌های مرجع مختلف نشان داد که با اطمینان بسیار بالایی می‌توان در پیش‌بینی وضعیت خشکسالی هیدرولوژیک از شاخص SDI (شش ماهه (مهر-اسفند) استفاده نمود. کواکبی و همکاران (۱۳۹۹) مدلی برای پیش‌بینی ریسک خشکسالی در زیر حوضه آبریز افین ارائه کردند. ایشان از شاخص‌های خشکسالی استاندارد شده بارش-تبخیر و تعرق<sup>۳</sup> (SPEI) و eRDI و شاخص خشکسالی هیدرولوژیک SRI استفاده کرده و به‌منظور بررسی تأثیر تغییر اقلیم بر این پدیده، دو سناریوی انتشار خوش‌بینانه و بدبینانه را تحلیل کردند. نتایج حاکی از کاهش نسبی دفعات وقوع خشکسالی در ۲۷ ساله آینده نزدیک است. مشایخی و ذاکری نیری (۱۳۹۹) با هدف تعیین موجد مادر بهینه، اقدام به پیش‌بینی خشکسالی هیدرولوژیک در تهران کردند. بدین منظور به ترتیب از داده‌های بارش روزانه، دبی روزانه و تصاویر ماهواره‌ای برای محاسبه‌ی سری زمانی خشکسالی هیدرولوژیکی استفاده شد. نتایج نشان داد که موجد مادر haar برای پیش‌بینی خشکسالی هیدرولوژیک عملکرد قابل قبولی دارد.

یکی از روش‌های پیش‌بینی خشکسالی، استفاده از مدل جعبه سیاه مثل شبکه عصبی مصنوعی<sup>۴</sup> (ANN) است (Rivera et al., 2021). پردازش موازی، توانایی کار با اطلاعات ناقص، کار با داده‌های پرسروصدا و توانایی آن در یادگیری الگوها از عوامل اصلی محبوبیت ANN در

مدل‌سازی منابع آب هستند.

با توجه به ماهیت غیرخطی، عدم قطعیت و عدم صراحت زیاد و ویژگی‌های متغیر زمانی و مکانی در خشکسالی، هیچ‌یک از مدل‌های آماری و مفهومی پیشنهادشده به‌منظور پیش‌بینی کوتاه‌مدت خشکسالی نتوانسته‌اند به‌تنهایی مدل برتر و توانا شناخته شوند و این مسئله همواره از پیچیدگی‌های ویژه‌ای برخوردار است. در پیش‌بینی خشکسالی به دلیل چندلایه بودن، تعداد پارامترهای زیاد و لزوم پردازش این داده‌ها یکی از روش‌های مهم و کاربردی استفاده از الگوریتم‌های بهینه‌سازی تکاملی بجای روش‌های ریاضی مرسوم در مرحله آموزش شبکه است. در چنین مدل ترکیبی، ANN به‌عنوان مدل اصلی شبیه‌سازی و GA به‌عنوان ابزار بهینه‌سازی برای بهینه‌سازی بایاس و وزن ANN استفاده شده است. هدف از این روش حذف محدودیت‌های روش‌های مبتنی بر شیب نزولی و ایجاد الگوریتمی برای همگرایی دائمی در مدل است (Eghbali et al., 2017). از مدل‌های ترکیبی در زمینه‌های مختلف مدیریت منابع آب استفاده شده است. Eghbali و همکاران (۲۰۱۷) برای پیش‌بینی دبی سیلاب ناشی از شکست سد از مدل ترکیبی شبکه عصبی-الگوریتم ژنتیک<sup>۵</sup> (ANN-GA) استفاده کردند. Dehghani و همکاران (۲۰۱۹) از مدل ترکیبی شبکه عصبی-نرو فازی-الگوریتم گرگ خاکستری برای پیش‌بینی تولید برقی در سد مخزنی دز استفاده کردند. Heidarpanah و همکاران (۲۰۲۳) مدل هیبرید ANN-GA برای پیش‌بینی قیمت برق روزانه در بازار برق ایران استفاده کردند. قیمت برق همانند خشکسالی، یک سری زمانی پیوسته است و بر اساس نتایج گزارش شده، مدل ترکیبی به خوبی توانست قیمت برق را پیش‌بینی نماید.

از آن طرف یادگیری عمیق<sup>۶</sup> (DL) بخشی از روش‌های یادگیری ماشین است که بر روش‌هایی تمرکز دارد که مبتنی بر شبکه‌های عصبی مصنوعی هستند. یادگیری عمیق به رایله‌ها می‌آموزد آنچه را که به‌طور طبیعی برای انسان انجام می‌شود، انجام دهند (Yu et al., 2021). این مدل‌ها برای توسعه راه‌هایی به‌منظور بازنمایی داده‌ها مفید هستند. یک داده می‌تواند یک کلمه، پیکسل، فرکانس

... غیره باشد و ممکن است معنای کمی به خودی خود داشته باشد، اما ترکیب این داده‌ها می‌تواند چیز سودمندی را نمایش دهد. به خودی خود یادگیری عمیق برای سناریوهای خیلی خاص مفید بود است و نیازمند استفاده از مدل‌های یادگیری ماشین و فن‌های دیگر برای ایجاد نتایج معنی‌دار بیشتر است. در سال‌های اخیر، شبکه‌های عصبی مصنوعی عمیق (از جمله شبکه‌های بازگشتی) فاتح رقابت‌های متعددی در زمینه‌های تشخیص الگو و یادگیری ماشینی شده‌اند (Nabipour et al., 2020). با توجه به قابلیت‌های یادگیری عمیق در مطالعات گذشته و موفقیت این روش در زمینه‌های تحقیقاتی مختلف، در این مقاله از این روش برای پیش‌بینی خشکسالی هیدرولوژیک استفاده می‌شود. در این مقاله قابلیت روش یادگیری عمیق در مقایسه با چندین روش هیبرید جدید که اخیراً در کارهای تحقیقاتی معرفی شده اند مقایسه می‌شود. اگرچه روش‌های ترکیبی مشابه با روش‌های مورد استفاده در این تحقیق بعضاً در پیش‌بینی خشکسالی هواشناسی استفاده شده است، لیکن روش‌های مورد استفاده و روش بکارگرفته شده در این تحقیق، هیچ سابقه قبلی در حوزه پیش‌بینی خشکسالی هیدرولوژیک ندارد.

## ۲- مواد و روش‌ها

### ۲-۱- حوضه آبریز رودخانه دز

حوضه آبریز رودخانه دز به‌عنوان یک حوضه درجه ۳، زیرمجموعه‌ای از حوضه کارون بزرگ محسوب می‌شود و در تقسیم‌بندی بزرگ‌تر در زیرمجموعه حوضه خلیج فارس و دریای عمان قرار می‌گیرد. از شهرهای مهم موجود در این حوضه می‌توان به دزفول، اندیمشک و شوش اشاره کرد. در ارتفاعات دامنه‌های غربی و جنوب‌غربی زاگرس که جزء مناطق پرباران کشور به‌شمار می‌روند، بخش عمده بارش‌های جوی در فصل‌های پاییز و زمستان به‌صورت برف است و آب‌شدن آن‌ها از اواخر فصل زمستان تا اواخر بهار، بخش عمده آب سالانه رواناب‌های سطحی این حوضه را تأمین می‌کند (Dehghani et al., 2019).

سزار و بختیاری دوشاخه اصلی رودخانه دز هستند. رود سزار در شمالی‌ترین قسمت حوضه دز جریان دارد و از

سه‌شاخه ماربره، تیره و سبزه تشکیل شده است. پیوستن آبراهه‌های متعدد و از جمله رودخانه ازنا در منطقه الیگودرز، رودخانه ماربره را پدید می‌آورند و این رودخانه در جهت غرب به‌طرف شهر درود در استان لرستان جریان می‌یابد. این رودخانه، حوضه آبریز مرتفع ولی با شیبی متوسط را زهکش می‌نماید. شاخه دیگر رودخانه سزار، رودخانه تیره نام دارد که از شاخه‌های فرعی کله‌رود، سیلاخور، آبسرد و بیاتون تشکیل می‌شود. سرچشمه رودخانه تیره از منطقه بروجرد است و سپس این رودخانه در جهت شرق به سمت درود جریان می‌یابد و در این محل، دو رودخانه تیره و ماربره به هم می‌پیوندند. از این نقطه به بعد، جهت جریان آب عموماً از شمال به جنوب و جنوب‌غربی است. در ۲۰ کیلومتری جنوب درود، رود سبزه که از دامنه‌های جنوبی و غربی اشترانکوه سرچشمه می‌گیرد، به این جریان متصل شده و رودخانه سزار تشکیل می‌شود. در حدود ۲۵ کیلومتری جنوب‌غربی این نقطه، رود واسک و به فاصله کمی رود از ساحل چپ به رود سزار پیوسته و جریان در جهت جنوب‌غربی ادامه می‌یابد. رودخانه کوچک سرخاب نیز از ساحل راست به رودخانه سزار متصل می‌شود (Felfelani et al., 2013).

رودخانه بختیاری دومین شاخه اصلی رودخانه دز است که در ۴۰ کیلومتری جنوب اتصال رود سرخاب، به رودخانه سزار می‌پیوندد. رود بختیاری از ارتفاعات جنوبی اشترانکوه سرچشمه گرفته و در ابتدا به نام رود دره‌دایی در جهت عمومی شمال‌غرب به جنوب‌شرق جریان یافته و پس از اتصال با رودخانه گلستان که از فلات مرتفع جنوب الیگودرز سرچشمه می‌گیرد، به جهت جنوب متمایل شده و با رود وهرگان که از جنوب‌شرق به شمال‌غرب جریان دارد، همگام می‌گردد. سپس با دریافت آب شاخه‌های کوچک‌تر، رودخانه به سمت غرب تغییر جهت داده و در این بخش به نام زالکی شناخته می‌شود. سپس با شاخه نسبتاً بزرگی که از شمال به آن می‌پیوندد، جمع شده و به رود سزار متصل می‌شود. از این پس، این رودخانه دز است که جریان می‌یابد (Felfelani et al., 2013).

شکل ۱ موقعیت حوضه آبریز دز را در کشور ایران نشان می‌دهد. مساحت کل حوضه بالغ بر ۲۱۷۲۰ کیلومتر مربع و متوسط ارتفاع حوضه حدود ۱۶۰۰ متر است. محدوده


هیدرولوژیک<sup>۷</sup> (SHDI) طی سال‌های زراعی (۱۳۵۸-۱۳۹۹) استفاده شد. داده‌های مورد استفاده از شرکت مدیریت منابع آب ایران و سازمان آب و برق خوزستان دریافت شد.

پس از حذف داده‌های پرت و پردازش و اصلاح و بازسازی داده‌ها، با اجرای آزمون‌های آماری دوره آماری ۳۰ ساله به‌عنوان دوره آماری مشترک برای تمامی ایستگاه‌ها در نظر گرفته شد. آزمون‌های آماری با نرم‌افزار SPSS صورت پذیرفت.

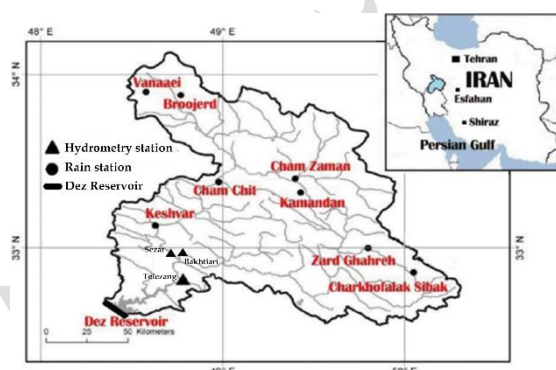
جدول ۱- مشخصات ایستگاه‌های هیدرومتری و باران‌سنجی واقع در محدوده مطالعاتی (عظیمی و همکاران، ۱۳۸۹).

ردیف	نام ایستگاه	ارتفاع	طول جغرافیایی	عرض جغرافیایی
۱-۳	تله زنگ	۴۴۰	۴۸/۷۷	۳۲/۸۱
	تنگ پنج سزار	۶۰۰	۴۸/۷۵	۳۲/۹۳
	تنگ پنج بختیاری	۶۰۰	۴۸/۷۷	۳۲/۹۳
	زردقهره	۲۰۰۰	۴۹/۸	۳۳
۴-۱۰	چرخ فلک سبک	۲۴۹۰	۵۰/۰۵	۳۲/۸۶
	بروجرد	۱۵۲۰	۴۸/۷۷	۳۳/۸۸
	ونائی (گله‌رود)	۲۰۰۰	۴۸/۵۸	۳۳/۹
	کمندان	۱۹۳۰	۴۹/۴۳	۳۳/۲۳
	چم‌زمان	۱۸۳۰	۴۹/۴	۳۳/۴
	چم‌چیت (آب‌سبز)	۱۲۹۰	۴۸/۹۸	۳۳/۳۸
	کشور	۷۷۰	۴۸/۶۳	۳۳/۱۳
۱۱				

در شکل ۲ دبی جریان سالانه در ایستگاه‌های هیدرومتری حوضه آمده است.



مورد مطالعه در این تحقیق حوضه آبریز دز در بالادست سد دز است که مساحت آن حدود ۵ کیلومترمربع است. پوشش گیاهی در ارتفاعات پایین حوضه کم بوده و با افزایش ارتفاع، تراکم این پوشش زیادتر می‌شود. متوسط بارش سالانه در نواحی شمال و شرق حوضه دز نسبت به سایر مناطق حوضه بیشتر است. از نظر توزیع زمانی بارش نیز ۴۸/۸ درصد از بارش سالانه در زمستان، ۳۰/۶ درصد در فصل پائیز، ۲۰/۴ درصد در بهار و تنها ۰/۲ درصد از بارش در فصل تابستان رخ می‌دهد (Malekmohammadi et al. 2011).



شکل ۱- حوضه آبریز رودخانه دز و ایستگاه‌های باران‌سنجی و هیدرومتری (Felfelani et al., 2013)

سد دز و برای تولید برق، آبیاری، کنترل سیلاب و تأمین آب طراحی و ساخته شده است. حدود ۱۲۵۰۰۰ هکتار از سطح زیردست کشاورزی سد دز از آب خارج شده از سد آبیاری می‌شود. همچنین ۵۲۰ مگاوات برق توسط نیروگاه‌های آبی نصب شده در پایین دست سد تولید می‌شود. جریان ورودی سد در ایستگاه تله زنگ واقع در بالادست سد اندازه‌گیری می‌شود. چهار ایستگاه هواشناسی در حوضه آبریز دز و ۱۰ ایستگاه در اطراف حوضه وجود دارد. داده‌های هیدرومتری و بارش از شرکت مدیریت منابع آب ایران و سازمان هواشناسی کشور جمع‌آوری می‌شود (Dehghani et al., 2019).

## ۲-۲ داده‌های مطالعه

در این تحقیق از آمار بارندگی ایستگاه باران‌سنجی زرد قهره برای محاسبه شاخص SPI و ایستگاه هیدرومتری تله زنگ برای محاسبه شاخص استاندارد شده خشکسالی


شکل و مقیاس هستند (Dehghani et al., 2019). سپس توزیع احتمال تجمعی آن از طریق تبدیل مساوی به توزیع نرمال با میانگین صفر و انحراف استاندارد واحد تبدیل می‌شود. مقادیر تبدیل‌شده، SPI هستند. این روش را می‌توان برای هر مقیاس زمانی انجام داد. مقادیر مثبت و منفی SPI به ترتیب مقدار بیشتر و کمتر از میانگین بارش را نشان می‌دهند. دهقانی و همکاران SHDI را با جایگزینی بارندگی با تخلیه توسعه دادند (Dehghani et al., 2014). شاخص SHDI، مشابه نمایه SPI است با این تفاوت که در آن به جای متغیر بارش از مقادیر جریان رودخانه استفاده شده است (مفیدی پور و همکاران، ۱۳۹۱).

جدول ۲- طبقه‌بندی خشکسالی با شاخص‌های SPI و SHDI (Dehghani et al., 2017).

کلاس	SHDI	کلاس	SPI
-	-	فوق‌العاده مرطوب	۲ به بالا
-	-	به شدت مرطوب	۱/۵ تا ۱/۹۹
فاقد خشکسالی	$\geq 0$ SHDI	نسبتاً مرطوب	۱ تا ۱/۴۹
خشکسالی ملایم	۰ تا -۱	نرمال	-۱ تا ۱
خشکسالی متوسط	-۱ تا -۱/۵	نسبتاً خشک	-۱/۵ تا -۱
خشکسالی شدید	-۱/۵ تا -۲	به شدت خشک	-۱/۹۹ تا -۱/۵

#### ۴-۲ متغیرهای موثر در پیش‌بینی خشکسالی

بر اساس مطالعات انجام شده در گذشته خشکسالی هیدرولوژیکی، بارش و خشکسالی هواشناسی در ماه‌های گذشته می‌تواند پیش‌بینی‌کننده مناسبی برای خشکسالی هیدرولوژیک دوره‌های آتی باشد. بنابراین، در این مقاله، بهترین متغیرهای پیش‌بینی‌کننده از میان این پارامترهای مختلف توسط مدل انتخاب می‌شوند. در جدول ۳ حالت‌های مختلف پیش‌بینی‌کننده‌ها آمده است. مطابق جدول ۳، سه حالت کلی برای این کار در نظر گرفته شده است. در حالت I برای پیش‌بینی SHDI در بازه‌های زمانی یک ماهه (SHDI-1)، سه ماهه (SHDI-3) و شش ماهه (SHDI-6) در زمان  $t$ ، از مقادیر SHDI در



شکل ۲- دبی جریان سالانه در ایستگاه الف) تله زنگ، ب) تنگ پنج بختیاری و ج) تنگ پنج سزار.

#### ۳-۲ شاخص‌های خشکسالی SPI و SHDI

جهت ارزیابی و تحلیل خشکسالی از دو شاخص خشکسالی SPI و SHDI استفاده شد چندین شاخص خشکسالی هواشناسی توسط محققان در دهه‌های گذشته پیشنهاد شده است؛ که در بین همه آن‌ها، SPI مورد توجه زیادی قرار گرفته است و به‌طور گسترده‌ای برای پیش‌بینی خشکسالی در کشورهای مختلف استفاده می‌شود (Dehghani et al., 2019). از آنجایی که SPI فقط بر اساس بارش محاسبه می‌شود، یک شاخص خشکسالی ساده است و به دلیل نرمال بودن، امکان استفاده از آن در مقایسه مکانی و زمانی وجود دارد. برای محاسبه SPI، ابتدا یک تابع توزیع احتمال مناسب (تابع پیش‌فرض گاما) به یک داده بلندمدت (حداقل ۳۰ ساله) برازش داده می‌شود.

(۱)

$$g(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-\frac{x}{\beta}} \quad \text{for } x > 0, \alpha, \beta > 0$$

$$\Gamma(\alpha) = \int_0^\infty y^{\alpha-1} e^{-y} dy$$

که در آن  $\Gamma(\alpha)$  تابع گاما و  $\alpha$  و  $\beta$  به ترتیب پارامترهای

$$y' = \text{purelin} \left\{ \sum_{j=1}^M \left[ \tan \text{sig} \left( \sum_{i=1}^{N_{in}} x_i \times W_{ij} + b_j \right) \times W'_j + b' \right] \right\} \quad (2)$$

که در آن purelin و tansig تابع انتقال در لایه پنهان و لایه خروجی،  $y'$  و  $x_i$  به ترتیب مقدار پیش بینی شده و متغیر پیش بینی کننده،  $N_{in}$  و  $M$  به ترتیب تعداد متغیرهای پیش بینی کننده و تعداد نرون در لایه پنهان است. در این مقاله برای یافتن مقادیر بهینه وزن‌ها و بایاس‌ها از الگوریتم‌های بهینه‌سازی استفاده شده است. تابع هدف استفاده شده در این الگوریتم‌ها کمینه سازی مجموع مربع خطای پیش بینی (SE) است که به صورت معادله (۳) تعریف می‌شود:

$$\text{Min} : SE = \sum_{i=1}^n (y'_i - y_i)^2 \quad (3)$$

که در آن  $y$  مقدار مشاهداتی و  $n$  تعداد داده‌ها است. در این مقاله از ۴ الگوریتم فراابتکاری استفاده می‌شود.

- بهینه‌سازی ازدحام ذرات<sup>۹</sup> (PSO)

PSO یک الگوریتم فراابتکاری است؛ که توسط ابره‌ارت و کندی (Eberhart & Kennedy, 1995) برای بهینه‌سازی جهانی پیشنهاد شده است. این روش یک الهام از حیواناتی مانند پرندگان و ماهی‌ها است.

- بهینه‌سازی مبتنی بر جغرافیای زیستی<sup>۱۰</sup> (BBO)  
BBO بر اساس مفهوم جغرافیای زیستی توسط سیمون (Simon, 2008) توسعه یافت.

- بهینه‌سازی ازدحام نمک<sup>۱۱</sup> (SSA)

SSA یک الگوریتم بهینه‌سازی فراابتکاری الهام گرفته از طبیعت است که توسط میرجلیلی و همکاران ارائه شده است (Mirjalili et al., 2017).

- الگوریتم بهینه‌سازی ملخ<sup>۱۲</sup> (GOA)

GOA یک الگوریتم فراابتکاری است که توسط میرجلیلی و همکاران ارائه شده است. GOA یک روش مبتنی بر جمعیت است که از رفتار دسته‌های ملخ و تعامل اجتماعی آنها تقلید می‌کند.

### ۳-۵-۲- روند انجام مدل‌سازی

در این مقاله برای پیش بینی خشکسالی، مراحل زیر طی می‌شوند:

۱. محاسبه SPI و SHDI در بازه زمانی‌های مختلف

زمان‌های گذشته (t-1، t-3 و t-6) استفاده می‌شود و حالت‌های مختلفی مورد توجه قرار می‌گیرد. به همین ترتیب در حالت II، مقادیر بارش (P) در زمان‌های گذشته نیز به ورودی‌ها اضافه می‌شود. در حالت III نیز علاوه بر SHDI و P از شاخص خشکسالی هواشناسی SPI در بازه‌های زمانی ۱، ۳ و ۶ ماهه نیز استفاده می‌شود. همانطور که دیده می‌شود در هر حالت، ۱۲ مدل ورودی (M1..M12) و در مجموع ۳۶ نوع، مدل ورودی مورد ارزیابی قرار می‌گیرد.

## ۵-۲ مدل پیش‌بینی خشکسالی

### ۱-۵-۲- شبکه یادگیری عمیق

مانند یادگیری ماشینی، یادگیری عمیق نیز طیف وسیعی از رویکردها را برای یادگیری از داده‌ها در بر می‌گیرد. معماری سلسله مراتبی شبکه‌های عصبی عمیق<sup>۸</sup> (DNN) را می‌توان به روش‌های مختلفی برای حل مسائل مختلف مورد استفاده قرار داد. در این مقاله از روش یادگیری نظارت شده یادگیری عمیق استفاده می‌شود. در این روش، هر لایه از تعدادی نرون تشکیل شده است؛ که یک سلسله مراتب را تشکیل می‌دهند. خروجی لایه قبلی به ورودی لایه بعدی و غیره تبدیل می‌شود. هر لایه بعدی الگوهای پیچیده‌تری را در داده‌های ورودی یاد می‌گیرد. لایه‌های پایین‌تر معمولاً ویژگی‌های سطح پایین را یاد می‌گیرند، در حالی که لایه‌های عمیق‌تر انتزاعات سطح بالا را در داده‌ها یاد می‌گیرند. یادگیری عمیق از نظر ساختار ساده‌ترین هستند؛ زیرا آن‌ها شبکه‌های عصبی پیشرو با لایه‌های زیادی هستند.

### ۲-۵-۲ مدل ترکیبی شبکه عصبی و الگوریتم‌های

#### بهینه‌سازی

در این مقاله، برای ارزیابی دقت روش یادگیری عمیق، نتایج بدست آمده با نتایج مدل شبکه عصبی مصنوعی مقایسه می‌شود. در اینجا از الگوریتم آموزش پس انتشار خطا استفاده می‌شود. مسئله چالش برانگیز اصلی در مدل‌سازی ANN، اختصاص وزن‌ها (W) و بایاس‌های (b) مناسب است؛ که در طول فرآیند تکرار تعیین می‌شوند. تابع کلی شبکه عصبی مورد استفاده در این مقاله به صورت معادله (۲) است.

۳ و ۶ ماهه.

لازم به ذکر است که در روش DNN نیازی به بررسی تمام حالات و مدل‌های عنوان‌شده نیست و خود شبکه عصبی عمیق ورودی مناسب را از بین تمام پارامترهای ورودی کشف می‌کند. در شکل ۳، روند نمای انجام تحقیق به طور خلاصه آمده است.

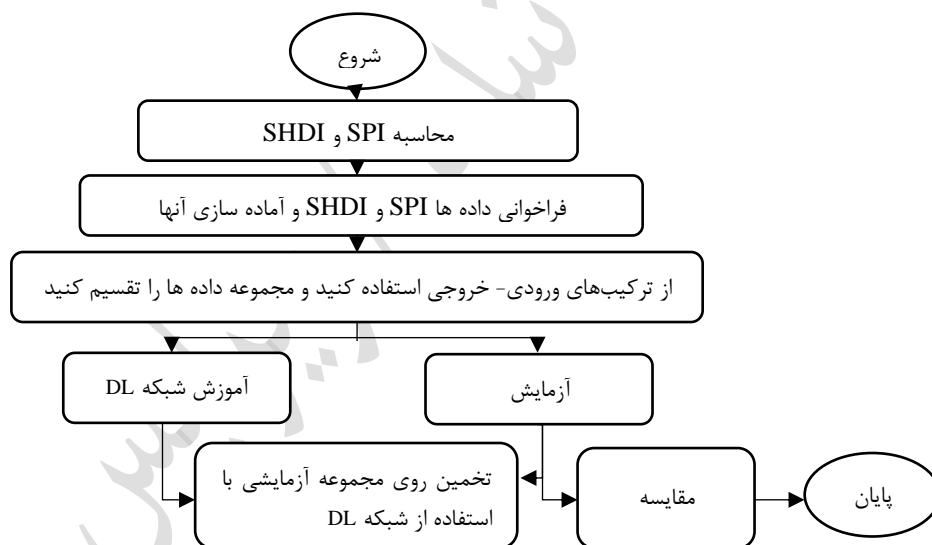
۲. ایجاد معماری DNN ابتدایی
۳. آموزش شبکه و صحت‌سنجی نتایج پیش‌بینی
۴. اجرای مدل‌های ترکیبی شبکه عصبی مصنوعی
۵. مقایسه نتایج روش DNN با نتایج سایر الگوریتم‌ها

جدول ۳- ترکیب ورودی در پیش‌بینی خشکسالی هیدرولوژیکی

پارامترهای ورودی (پیش‌بینی کننده‌ها)	مدل	متغیر پیش‌بینی شونده	
SHDI-1(t-1)	۱	SHDI-1(t)	حالت I
SHDI-1(t-1), SHDI-1(t-2)	۲		
SHDI-1(t-1), SHDI-1(t-2), SHDI-1(t-3)	۳		
SHDI-3(t-3)	۴	SHDI-3(t)	
SHDI-3(t-3), SHDI-3(t-2)	۵		
SHDI-3(t-3), SHDI-3(t-2), SHDI-3(t-1)	۶		
SHDI-3(t-6)	۷	SHDI-6(t)	
SHDI-3(t-6), SHDI-3(t-5)	۸		
SHDI-3(t-6), SHDI-3(t-5), SHDI-3(t-4)	۹		
SHDI-3(t-6), SHDI-3(t-5), SHDI-3(t-4), SHDI-3(t-3)	۱۰		
SHDI-3(t-6), SHDI-3(t-5), SHDI-3(t-4), SHDI-3(t-3), SHDI-3(t-2)	۱۱		
SHDI-3(t-6), SHDI-3(t-5), SHDI-3(t-4), SHDI-3(t-3), SHDI-3(t-2), SHDI-3(t-1)	۱۲		
P(t-1), SHDI-1(t-1)	۱	SHDI-1(t)	حالت II
P(t-1), P(t-2), SHDI-1(t-1), SHDI-1(t-2)	۲		
P(t-1), P(t-2), P(t-3), SHDI-1(t-1), SHDI-1(t-2), SHDI-1(t-3)	۳		
P3(t-1), SHDI-3(t-1)	۴	SHDI-3(t)	
P3(t-1), P3(t-2), SHDI3(t-1), SHDI3(t-2)	۵		
P3(t-1), P3(t-2), P3(t-3), SHDI3(t-1), SHDI3(t-2), SHDI3(t-3)	۶		
P6(t-6), SHDI-6(t-6)	۷	SHDI-6(t)	
P6(t-6), P6(t-5), SHDI-6(t-6), SHDI-3(t-5)	۸		
P3(t-6), P3(t-5), P3(t-4), SHDI-3(t-6), SHDI-3(t-5), SHDI-3(t-4)	۹		
P3(t-6), P3(t-5), P3(t-4), P3(t-3), SHDI-3(t-6), SHDI-3(t-5), SHDI-3(t-4), SHDI-3(t-3)	۱۰		
P3(t-6), P3(t-5), P3(t-4), P3(t-3), P3(t-2), SHDI-3(t-6), SHDI-3(t-5), SHDI-3(t-4), SHDI-3(t-3), SHDI-3(t-2)	۱۱		
P3(t-6), P3(t-5), P3(t-4), P3(t-3), P3(t-2), P3(t-1), SHDI-3(t-6), SHDI-3(t-5), SHDI-3(t-4), SHDI-3(t-3), SHDI-3(t-2), SHDI-3(t-1)	۱۲		
SPI-1(t-1), SHDI-1(t-1)	۱	SHDI-1(t)	حالت III
SPI-1(t-1), SPI-1(t-2), SHDI-1(t-1), SHDI-1(t-2)	۲		



پارامترهای ورودی (پیش بینی کننده ها)	مدل	متغیر پیش بینی شونده
SPI-1(t-1), SPI-1(t-2), SPI-1(t-3), SHDI-1(t-1), SHDI-1(t-2), SHDI-1(t-3)	۳	SHDI-3(t)
SPI-3(t-1), SHDI-3(t-1)	۴	
SPI-3(t-1), SPI-3(t-2), SHDI-3(t-1), SHDI-3(t-2)	۵	SHDI-6(t)
SPI-3(t-1), SPI-3(t-2), SPI-3(t-3), SHDI-3(t-1), SHDI-3(t-2), SHDI-3(t-3)	۶	
SPI-6(t-6), SHDI-6(t-6)	۷	
SPI-6(t-6), SPI-6(t-5), SHDI-6(t-6), SHDI-3(t-5)	۸	
SPI-6(t-6), SPI-6(t-5), SPI-6(t-4), SHDI-3(t-6), SHDI-3(t-5), SHDI-3(t-4)	۹	SHDI-6(t)
SPI-6(t-6), SPI-6(t-5), SPI-6(t-4), SPI-6(t-3), SHDI-3(t-6), SHDI-3(t-5), SHDI-3(t-4), SHDI-3(t-3)	۱۰	
SPI-6(t-6), SPI-6(t-5), SPI-6(t-4), SPI-6(t-3), SPI-6(t-2), SHDI-3(t-6), SHDI-3(t-5), SHDI-3(t-4), SHDI-3(t-3), SHDI-3(t-2)	۱۱	
SPI-6(t-6), SPI-6(t-5), SPI-6(t-4), SPI-6(t-3), SPI-6(t-2), SPI-6(t-1), SHDI-6(t-6), SHDI-6(t-5), SHDI-6(t-4), SHDI-6(t-3), SHDI-6(t-2), SHDI-6(t-1)	۱۲	




شکل ۳- چارچوب الگوریتم پیشنهادی

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y'_i - y_i)^2}{n}}$$


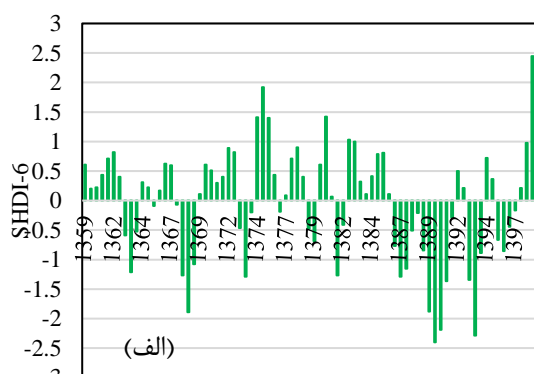
(۴)

### ۲-۶- معیارهای ارزیابی


برای ارزیابی قابلیت الگوریتم مورد استفاده در پیش بینی خشکسالی هیدرولوژیکی، از شاخص های آماری ضریب تعیین<sup>۱۳</sup> ( $R^2$ ) و ریشه میانگین مربعات خطا<sup>۱۴</sup> (RMSE)، استفاده شد.



شکل ۴- مقادیر شاخص ۱۲ ماهه الف) SHDI-12 ایستگاه تله زنگ و ب) SPI-12 ایستگاه زردقهره.



شکل ۵- مقادیر شاخص ۶ ماهه الف) SHDI ایستگاه تله زنگ و ب) SPI ایستگاه زردقهره.




$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i' - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

که در آن  $y$  و  $\bar{y}$  به ترتیب مقادیر مشاهداتی و متوسط آنها،  $y'$  مقادیر پیش بینی شده و  $n$  تعداد داده‌ها است.

### ۳- نتایج و بحث

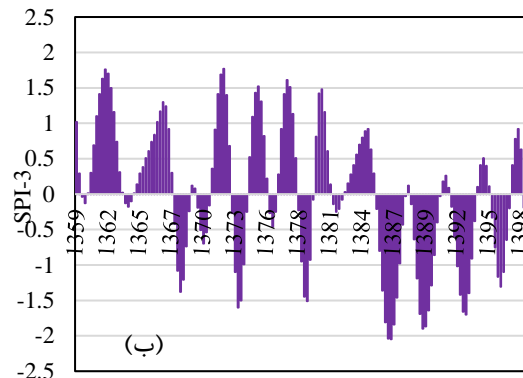
در این بخش ابتدا نتایج محاسبه شاخص SPI و SHDI در دو ایستگاه مهم حوضه (هیدرومتری تله زنگ و باران سنجی زرد قهره) نشان داده می‌شود. بر این اساس مقادیر SPI و SHDI در بازه‌های ۱۲، ۶ و ۳ ماهه به ترتیب در شکل ۴، ۵ و ۶ نشان داده شده است. این نمودارها به ما در فهم دوره‌های خشکسالی و بزرگی آن کمک می‌کند. با توجه به جدول ۳، SPI بین -۱ تا -۱/۵ شرایط نسبتاً خشک را نشان می‌دهد و کم‌تر از -۱/۵ بسیار خشک را عنوان می‌کند. بنابراین با توجه به شکل ۴، سال ۷۳، ۸۶، ۸۹ و ۹۳ از جمله سال‌های با خشکسالی شدید و سال‌های ۶۸، ۷۹، ۸۷، ۹۱ و ۹۶ از جمله سال‌های نسبتاً خشک قلمداد می‌شود. از آن طرف مطابق شکل ۴ الف، در سال‌های آبی ۶۸، ۸۹، ۸۸ و ۹۳ خشکسالی شدید هیدرولوژیک و سال‌های ۶۳، ۷۳، ۸۱ و ۸۷ در زمره سال‌های با خشکسالی نسبتاً شدید هیدرولوژیک هستند. نتایج شکل ۴ الف نشان می‌دهد که در سال‌های اخیر (۱۳۸۵ تا ۱۳۹۷) یک خشکسالی طولانی مدت ۱۲ ساله رخ داده است. شدیدترین خشکسالی نیز در همین دوره در سال ۱۳۹۳ رخ داده است. روند مشابهی در دوره‌های زمانی ۶ ماهه (شکل ۵) و ۳ ماهه (شکل ۶) قابل مشاهده است.



هیبریدی است. ارزیابی دقیق نشان می‌دهد که برای M1 تا M3 بهترین مدل‌ها بیشتر در حالت دو هستند. به این معنی که برای پیش‌بینی خشکسالی هیدرولوژیکی در مقیاس زمانی ماهانه که به صورت SHDI1 نشان داده می‌شود، بارش و SHDI در ماه‌های گذشته بهترین ورودی‌ها هستند. برای M4 تا M6، دو تا از بهترین مدل‌ها در حالت سه هستند و یکی از آن‌ها در حالت یک است؛ بنابراین، می‌توان گفت که برای پیش‌بینی SHDI3، حالت سه که شامل SPI و SHDI در مراحل قبل به عنوان ورودی است بهترین به حساب می‌آید. برای M7 تا M12، پنج تا از بهترین مدل‌ها در حالت دو هستند که نشان می‌دهد همان M1 تا M3، بارش و SHDI در ماه‌های قبل بهترین ورودی هستند.

نتایج نشان می‌دهد که مدل‌های هیبریدی نسبت به ANN معمولی در همه حالت‌های M1 تا M12 برتری دارند. RMSE و  $R^2$  تقریباً در تمام ترکیبات ورودی-خروجی بین ۰/۱ و ۰/۲ بهبود یافته‌اند. این بدان معنی است که ترکیبی با الگوریتم‌های بهینه‌سازی الهام گرفته از طبیعت نتایج را به شدت بهبود می‌دهد. بر این اساس امکان مقایسه وجود دارد. الگوریتم بهینه‌سازی برای پیش‌بینی خشکسالی هیدرولوژیکی الگوریتم‌های SSA، BBO، PSO و GOA در ترکیب با ANN بهترین نتایج را به ترتیب در مورد دو، سه، پنج و دو برای M1 تا M12 ایجاد کردند. با توجه به این واقعیت، PSO بر سایرین برتری دارد. SSA به عنوان بهترین الگوریتم در M10 و M11، BBO بهترین نتایج را در M3، M7، M9، M2، M5، M6، M8 و M12 و GOA در M1 و M4 تولید کرد؛ بنابراین، برای پیش‌بینی SHDI6 بهترین است در حالی که BBO برای SHDI1 و SHDI6، GOA برای SHDI1 و SHDI3 و PSO برای همه آن‌ها. مجدداً می‌توان نتیجه گرفت که PSO بهترین الگوریتم برای ترکیب با ANN برای پیش‌بینی خشکسالی هیدرولوژیکی است.

در نهایت، امکان ارزیابی ترکیب‌های ورودی در پیش‌بینی خشکسالی هیدرولوژیکی وجود دارد. بر اساس نتایج، M1 تا M3 برای پیش‌بینی SHDI1 در حالی که M4 تا M6 و M7 تا M12 به ترتیب برای پیش‌بینی SHDI3 و SHDI6 استفاده شده‌اند.



شکل ۶- مقادیر شاخص ۳ ماهه الف) SHDI ایستگاه تله زنگ و ب) SPI ایستگاه زردقهره.

### ۲-۳- نتایج مدل پیش‌بینی SHDI

در این قسمت از تحقیق ۷۰٪ داده‌های سری زمانی برای آموزش و ۳۰٪ برای اعتبارسنجی مدل‌ها در نظر گرفته شد. داده‌ها در هر حالت که در جدول ۳-۳ نشان داده شده است حاکی از یک بازه خاص است؛ به عنوان مثال پیش‌بینی در مدل‌های یک تا سه، یک ماهه، چهار تا شش، سه ماهه و هفت تا ۱۲، شش ماهه است. در این بخش، عملکرد مدل یادگیری عمیق و مدل ترکیبی ANN با الگوریتم‌های بهینه‌سازی SSA، BBO، PSO و GOA مورد بحث قرار می‌گیرد. در ابتدا نتایج الگوریتم‌های رقیب در حالات مختلف جدول ۳ ارائه می‌شود.


نتایج را می‌توان از چند جنبه مقایسه کرد. بر اساس حالت‌ها، تنها یکی از بهترین مدل‌های ترکیبی در حالت I قرار دارد؛ در حالی که هفت و چهار بهترین مدل به ترتیب در حالت دو و حالت سه قرار دارند. برای ANN معمولی، پنج و هفت بهترین مدل به ترتیب در حالت دو و حالت سه قرار گرفتند. نشان می‌دهد که حالت یک برای مدل‌سازی مناسب نیست. این بدان معناست که اگرچه SHDI همبستگی قوی با تأخیرهای قبلی خود دارد، اما تنها تابعی از مقادیر قبلی آن نیست. عوامل دیگری مانند بارندگی یا خشکسالی هواشناسی که قبل از اتصال خشکسالی هیدرولوژیکی با SHDI در تأخیرهای قبلی اتفاق می‌افتد می‌تواند نتایج را به طور قابل توجهی بهبود بخشد. همچنین، بارش همراه با مقادیر SHDI در ماه‌های گذشته، پیش‌بینی‌کننده بهتری برای پیش‌بینی SHDI نسبت به SPI مشترک با SHDI، به ویژه در مدل‌های

و پنجاه گره کمترین RMSE را تولید می‌کند و از همه مدل‌های قبلی بهتر است.

جدول ۴- نتایج حاصل از شبکه عصبی عمیق

تکرار	۳۰	۶۰	۹۰	۱۲۰	۱۵۰
لایه‌های پنهان	۳	۵	۷	۹	۱۱
گره‌ها	۲۰	۳۰	۴۰	۵۰	۶۰
RMSE	۰/۴۳	۰/۴۱	۰/۳۹	۰/۳۲	۰/۳۸

در شکل ۷ خطای پیش‌بینی مدل‌های مختلف شامل DNN و بهترین مدل ترکیبی به ازای بهترین ورودی‌ها ارائه شده است.



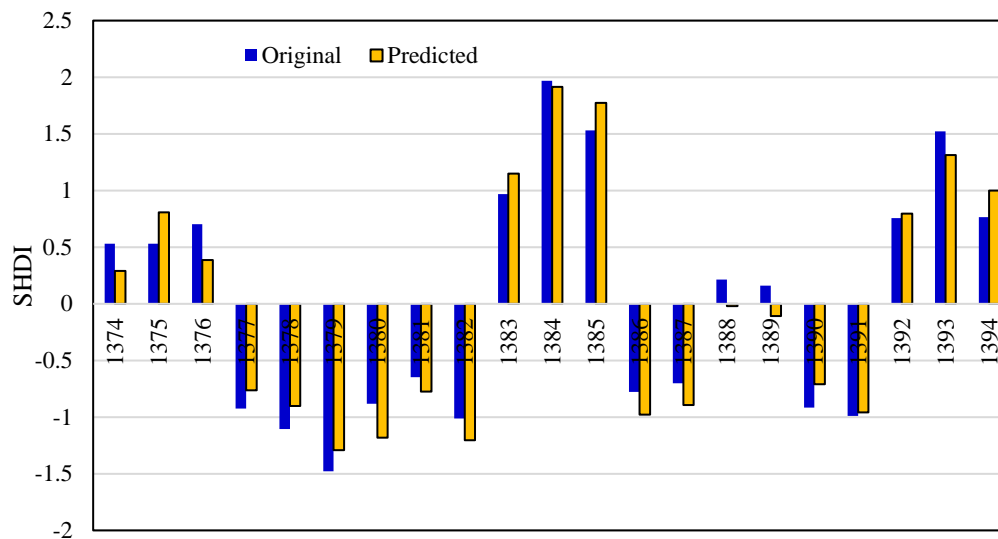
شکل ۷- مقایسه RMSE مدل‌های مختلف برای بهترین روش ترکیبی شبکه عصبی در مقایسه با یادگیری عمیق.

بر اساس نتایج شکل ۷، روش مبتنی بر شبکه عصبی عمیق خطای کمتری دارد و این به دلیل توان محاسباتی بالای این روش در پیش‌بینی خشکسالی هیدرولوژیکی است. در شکل ۸ مقایسه‌ای بین نتایج بدست آمده از روش DNN و مقادیر واقعی SHDI ۱۲ ماهه آمده است. در این شکل می‌توان خطای مدل را در هر سال برآورد کرد.

بر اساس نتایج، M2 در حالت دو به عنوان بهترین مدل برای پیش‌بینی SHDI عمل کرد. این نشان می‌دهد که بارش و SHDI در یک و دو ماه گذشته بهترین پیش‌بینی‌شده برای پیش‌بینی SHDI است. M6 در حالت سه بهترین عملکرد را برای پیش‌بینی SHDI3 نشان می‌دهد؛ بنابراین، مقادیر SPI و SHDI در سه ماه گذشته بهترین پیش‌بینی‌شده برای پیش‌بینی SHDI3 هستند. باین‌حال، شایان‌ذکر است که نتایج M4 در حالت سه در برخی جنبه‌ها از نتایج M6 ارزشمندتر است.

در حالت اول، مدل نیاز به دو پیش‌بینی کننده دارد؛ درحالی‌که در M6، مدل به شش پیش‌بینی کننده نیاز دارد. همچنین در M4 مقادیر SPI و SHDI سه ماه قبل پیش‌بینی کننده هستند؛ به این معنی که مدل SHDI را برای یک فصل آینده پیش‌بینی می‌کند. باین‌حال، M6 از مقادیر SHDI3 در ماه گذشته به عنوان پیش‌بینی کننده استفاده می‌کند، به این معنی که به‌طور کلی، دوسوم از اطلاعاتی که باید پیش‌بینی شود در پیش‌بینی‌ها موجود است. بر اساس این حقایق، نتایج M6 دقیق‌تر هستند؛ درحالی‌که نتایج M4 ارزشمندتر هستند. این واقعیتی است که برای M7 تا M12 صادق است. M12 در حالت سه دقیق‌ترین مدل است؛ درحالی‌که نتایج M7 ارزشمندتر است.

پس از تحلیل الگوریتم‌های رقیب نوبت به بررسی توانایی الگوریتم DNN می‌رسد؛ بدین گونه که اطلاعات کامل در اختیار شبکه عصبی عمیق قرار می‌گیرد و وظایف تحلیل به خود الگوریتم یادگیری واگذار می‌شود. مدل با مقادیر مختلف لایه‌ها و گره‌های پنهان برای هر لایه پنهان آموزش و اعتبارسنجی شدند. پیش‌بینی در روش یادگیری عمیق با استفاده از SPI در بازه شش‌ماهه انجام می‌شود. جدول ۴ نتایج حاصل از شبکه عصبی عمیق را در حالات مختلف نشان می‌دهد؛ که در ۱۲۰ تکرار با لایه‌های پنهان نه تایی



شکل ۸- مقایسه SHDI-12 واقعی و SHDI-12 تخمینی توسط یادگیری عمیق در ایستگاه تله‌زنگ.

روش‌های رقیب خطای کم‌تری داشته است. نتایج این تحقیق می‌تواند در جهت مدیریت بهینه‌ی منابع آبی و برنامه‌ریزی‌های عرضه و تقاضای آب مفید باشد و مدیران و برنامه‌ریزان و کارشناسان را قادر سازد تا به‌موقع تمهیدات لازم را تدارک دیده و راهکارهای عملی را ارائه دهند.

#### ۴- نتیجه‌گیری

در این مقاله، از الگوریتم یادگیری عمیق برای پیش‌بینی خشکسالی هیدرولوژیک کوتاه‌مدت در حوضه آبریز سد دز استفاده شد. برای پیش‌بینی خشکسالی هیدرولوژیک، از شاخص SHDI استفاده گردید. متغیرهایی که به عنوان ورودی مدل در نظر گرفته شدند شامل بارش، شاخص خشکسالی هواشناسی SPI و مقادیر SHDI در دوره‌های زمانی گذشته بود که با آنالیز حساسیت، بهترین ترکیب آنها استخراج گردید. علاوه بر DNN از مدل ترکیبی شبکه عصبی با الگوریتم‌های بهینه‌سازی SSA، BBO، PSO و GOA برای مقایسه نتایج با روش DNN به کار گرفته شد. نتایج نشان داد که مدل‌های ترکیبی عملکرد بالاتری نسبت به ANN دارند و این مدل‌ها قادر به پیش‌بینی خشکسالی هیدرولوژیک در مقیاس‌های زمانی مختلف هستند. بر اساس نتایج، مقادیر SHDI در ماه‌های قبل، ورودی کافی برای پیش‌بینی خشکسالی هیدرولوژیک نیست و سایر پارامترها مانند SPI و بارش در ماه‌های قبل می‌توانند نتایج پیش‌بینی را به میزان قابل توجهی بهبود بخشند. همچنین، در بین همه الگوریتم‌های بهینه‌سازی، PSO در ترکیب با ANN عملکرد بهتری داشت. شایان‌ذکر است که برای SHDI-6، پیش‌بینی دقیق SHDI، اطلاعات SHDI در دو ماه اخیر نقش بسزایی در پیش‌بینی SHDI6 ایفا می‌کند. بر اساس نتایج بدست آمده، شبکه عصبی عمیق نسبت به تمام

#### پی‌نوشت‌ها

- ۱- Standardized Preipitation Index
- ۲- Standardized Discharge Index
- ۳- Standardized Precipitation-Evaporation Index
- ۴- Artificial Neural Networks
- ۵- Genetic Algorithm
- ۶- Deep Learning
- ۷- Standardized Hydrologic Drought Index
- ۸- Deep Neural Network
- ۹- Particle Swarm Optimization
- ۱۰- Biogeography-based optimization
- ۱۱- Salt Swarm Algorithm
- ۱۲- Grasshopper optimization algorithm
- ۱۳- Determination coefficient
- ۱۴- Root Mean Square Error

#### منابع

اقتداری، م.، بذرافشان، ج.، شفیع، م. و حجابی، س. (۱۳۹۵). "پیش‌بینی خشکسالی جریان رودخانه با استفاده از شاخص SPI"

- Dehghani, M., Riahi-Madvar, H., Hooshyaripor, F., Mosavi, A., Shamshirband, S., Zavadskas, E. K., and Chau, K.-w. (2019). "Prediction of hydropower generation using grey wolf optimization adaptive neuro-fuzzy inference system". *Energies*, 12(2), 289. <https://doi.org/10.3390/en12020289>
- Dehghani, M., Saghafian, B., Nasiri Saleh, F., Farokhnia, A., and Noori, R. (2014). "Uncertainty analysis of streamflow drought forecast using artificial neural networks and Monte-Carlo simulation". *International Journal of Climatology*, 34(4), 1169-1180. <https://doi.org/10.1002/joc.3754>
- Dehghani, M., Saghafian, B., Rivaz, F., and Khodadadi, A. (2017). "Evaluation of dynamic regression and artificial neural networks models for real-time hydrological drought forecasting". *Arabian Journal of Geosciences*, 10(12), 1-13. DOI: <https://doi.org/10.1007/s12517-017-2990-4>
- Eberhart, R., and Kennedy, J. (1995). "A new optimizer using particle swarm theory". MHS'95. Proceedings of the sixth international symposium on micro machine and human science. DOI: 10.1109/MHS.1995.494215
- Eghbali, A. H., Behzadian, K., Hooshyaripor, F., Farmani, R., and Duncan, A. P. (2017). "Improving prediction of dam failure peak outflow using neuroevolution combined with K-means clustering". *Journal of Hydrologic Engineering*, 22(6), 04017007. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.000150](https://doi.org/10.1061/(ASCE)HE.1943-5584.000150)
- Felfelani, F., Movahed, A. J., and Zarghami, M. (2013). "Simulating hedging rules for effective reservoir operation by using system dynamics: a case study of Dez Reservoir, Iran". *Lake and reservoir management*, 29(2), 126-140. <https://doi.org/10.1080/10402381.2013.801542>
- Heidarpanah, M., Hooshyaripor, F. and Fazeli, M. (2023). "Daily electricity price forecasting using artificial intelligence models in the Iranian electricity market", *Energy*, 263, 126011. <https://doi.org/10.1016/j.energy.2022.126011>
- Heim Jr, R. R. (2002). "A review of twentieth-century drought indices used in the United States". *Bulletin of the American Meteorological Society*, 83(8), 1149-1166. <https://doi.org/10.1175/1520-0477-83.8.1149>
- Hooshyaripor, F. and Yazdi, J. (2017). "A new methodology for surcharge risk management in urban areas (case study: Gonbad-e-Kavus city)". *Water Science and Technology*, 75(4), 823-832. <https://doi.org/10.2166/wst.2016.567>
- Hooshyaripor, F., Sardari, J., Dehghani, M. and Noori, R. (2022). "A new concept of drought feeling against the meteorological drought". *و زنجیره مارکف در حوزه آبریز کرخه*، مجله پژوهش‌های حفاظت آب و خاک، ۲۳(۲)، ۱۱۵-۱۳۰. doi: 10.22069/jwfst.2016.3058
- عظیمی، م.، تجریشی، م.، و ابریشمچی، ا. (۱۳۸۹). "پیش بینی آورد فصلی سد دز با استفاده از سیگنال‌های بزرگ مقیاس اقلیمی"، *نهمین کنفرانس هیدرولیک ایران*، تهران، دانشگاه تربیت مدرس <https://civilica.com/doc/96235>
- علوی نیا، س.، ساداتی نژاد، س.ج. و عبدالمی، خ. (۱۳۹۰). "ارائه مدلی برای پیش بینی خشکسالی هیدرولوژیکی در حوضه کارون یک"، *پژوهش‌های فرسایش محیطی*، ۱(۱)، ۴۵-۵۵. SID. <https://sid.ir/paper/223061/fa>
- علیجانی، ر. و وفاخواه، م. (۱۳۹۷). "پیش بینی خشکسالی هیدرولوژیکی با استفاده از سری‌های زمانی"، *مهندسی اکوسیستم بیابان*، ۲(۲)، ۴۵-۵۶. <https://sid.ir/paper/397507/fa>
- کریمی، ف. و برهانی داریان، ع. (۱۳۹۳). "مقایسه روش‌های جیره‌بندی در مدیریت مخازن در شرایط خشکسالی". *مجله آب و فاضلاب*، ۲۵(۳)، ۷۶-۸۵.
- کواکبی، غ.، موسوی بایگی، م.، علیزاده، ا.، مساعدی، ا. و جباری نوقابی، م. (۱۳۹۹). "ارائه مدل پیش‌بینی ریسک خشکسالی هواشناسی و هیدرولوژیکی با روش‌های آماری تحت تأثیر تغییرات اقلیمی (مطالعه موردی: زیرحوضه آبریز افین)". *جغرافیا و مخاطرات محیطی*، ۱(۱)، ۱۳۷-۱۱۷. doi: 10.22067/GEO.V9I1.84991
- مشایخی، م.ج. و ذاکری نیری، م. (۱۳۹۹). "پیش بینی خشکسالی هواشناسی، هیدرولوژیکی و کشاورزی مبتنی بر روش موجک در تهران"، *تحقیقات منابع آب ایران*، ۱۶(۳)، ۱۳۲-۱۲۰. [20.1001.1.17352347.1399.16.3.9.7](https://doi.org/10.1001.1.17352347.1399.16.3.9.7)
- مفیدی پور، ن.، بردی شیخ، و. و اوفق، م. و سعدالدین، ا. (۱۳۹۱). بررسی رابطه خشکسالی هواشناسی و هیدرولوژیکی در حوزه آبخیز اترک"، *پژوهشنامه مدیریت حوزه آبخیز*، ۳(۵)، ۲۶-۱۶. URL: <http://jwmr.sanru.ac.ir/article-1-52-en.html>
- Agana, N. A., and Homaifar, A. (2017). "A deep learning based approach for long-term drought prediction". *SoutheastCon 2017*, 1-8. DOI: [10.1109/SECON.2017.7925314](https://doi.org/10.1109/SECON.2017.7925314)
- Aghelpour, P., Bahrami-Pichaghchi, H., and Varshavian, V. (2021). "Hydrological drought forecasting using multi-scalar streamflow drought index, stochastic models and machine learning approaches, in northern Iran". *Stochastic Environmental Research and Risk Assessment*, 35(8), 1615-1635. DOI: <https://doi.org/10.1007/s00477-020-01949-z>
- Cui, A., Li, J., Zhou, Q., Zhu, R., Liu, H., Wu, G., and Li, Q. (2021). "Use of a multiscale GRACE-based standardized terrestrial water storage index for assessing global hydrological droughts". *Journal of Hydrology*, 603, 126871. <https://doi.org/10.1016/j.jhydrol.2021.126871>

anomalies for the Canadian landmass using deep learning and land surface model". *International Journal of Applied Earth Observation and Geoinformation*, 102, 102404. <https://doi.org/10.1016/j.jag.2021.102404>.

- Scientific Reports*, 12(1), 16711. <https://doi.org/10.1038/s41598-022-21181-9>
- Khan, N., Sachindra, D., Shahid, S., Ahmed, K., Shiru, M. S., and Nawaz, N. (2020). "Prediction of droughts over Pakistan using machine learning algorithms". *Advances in Water Resources*, 139, 103562. <https://doi.org/10.1016/j.advwatres.2020.103562>
- Malekmohammadi, B., Zahraie, B. and Kerachian, R. (2011). "Ranking solutions of multi-objective reservoir operation optimization models using multi-criteria decision analysis". *Expert Syst Appl.*, 38(6), 7851-7863. <https://doi.org/10.1016/j.eswa.2010.12.119>
- Mirjalili, S., Gandomi, A. H., Mirjalili, S. Z., Saremi, S., Faris, H., and Mirjalili, S. M. (2017). "Salp Swarm Algorithm: A bio-inspired optimizer for engineering design problems". *Advances in engineering software*, 114, 163-191. <https://doi.org/10.1016/j.advengsoft.2017.07.002>
- Nabipour, N., Dehghani, M., Mosavi, A., and Shamshirband, S. (2020). "Short-term hydrological drought forecasting based on different nature-inspired optimization algorithms hybridized with artificial neural networks". *IEEE Access*, 8, 15210-15222. DOI: 10.1109/ACCESS.2020.2964584
- Rivera, J. A., Otta, S., Lauro, C., and Zazulie, N. (2021). "A decade of hydrological drought in Central-Western Argentina". *Frontiers in Water*, 3, 28. <https://doi.org/10.3389/frwa.2021.640544>
- Salimi, H., Asadi, E., and Darbandi, S. (2021). "Meteorological and hydrological drought monitoring using several drought indices". *Applied Water Science*, 11(2), 1-10. <https://doi.org/10.1007/s13201-020-01345-6>
- Simon, D. (2008). "Biogeography-based optimization". *IEEE transactions on evolutionary computation*, 12(6), 702-713. DOI: 10.1109/TEVC.2008.919004
- Vicente-Serrano, S. M., Van der Schrier, G., Beguería, S., Azorin-Molina, C., and Lopez-Moreno, J.-I. (2015). "Contribution of precipitation and reference evapotranspiration to drought indices under different climates". *Journal of Hydrology*, 526, 42-54. <https://doi.org/10.1016/j.jhydrol.2014.11.025>
- Williams, A. P., Cook, E. R., Smerdon, J. E., Cook, B. I., Abatzoglou, J. T., Bolles, K., Baek, S. H., Badger, A. M., and Livneh, B. (2020). "Large contribution from anthropogenic warming to an emerging North American megadrought". *Science*, 368(6488), 314-318. DOI: 10.1126/science.aaz9
- Yu, Q., Wang, S., He, H., Yang, K., Ma, L., and Li, J. (2021). "Reconstructing GRACE-like TWS

پذیرفته شده / ویرایش نشده