



مدیریت آب و آبیاری (نشریه علمی)

دوره ۱۱ ■ شماره ۲ ■ تابستان ۱۴۰۰

صفحه‌های ۱۸۸-۱۷۳

DOI: 10.22059/jwim.2021.318390.859

مقاله پژوهشی:

کاربرد مدل ترکیبی شبکه عصبی مصنوعی و الگوریتم‌های بهینه‌سازی فرا ابتکاری در پیش‌بینی شاخص خشک‌سالی SPEI₁₂

پوریا قاسمی^۱، مسعود کرباسی^{۲*}، علیرضا زمانی نوری^۳، مهدی سرائی تبریزی^۴
۱. دانشجوی دکتری، گروه علوم و مهندسی آب، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.
۲. دانشیار، گروه مهندسی آب، دانشگاه زنجان، زنجان، ایران.
۳. گروه مهندسی عمران، واحد شهرقدس، دانشگاه آزاد اسلامی، تهران، ایران.
۴. استادیار، گروه علوم و مهندسی آب، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.
تاریخ دریافت مقاله: ۱۳۹۹/۱۱/۱۸ تاریخ پذیرش مقاله: ۱۴۰۰/۰۳/۲۹

چکیده

خشک‌سالی یکی از مهم‌ترین بلاای طبیعی می‌باشد که در همه رژیم‌های آب‌وهوایی رخ می‌دهد. بنابراین، پیش‌بینی و مقابله با آن از اهمیت بالایی برخوردار است. در پژوهش حاضر از سه الگوریتم‌های بهینه‌سازی هوشمند (الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری (TLBO)، الگوریتم بهینه‌سازی علف‌های هرز (IWO)، الگوریتم ازدحام ذرات (PSO)) و الگوریتم متداول لونبرگ-مارکوات به منظور آموزش شبکه عصبی مصنوعی چند لایه، برای پیش‌بینی شاخص خشک‌سالی SPEI₁₂ یک الی سه ماه آینده در ۷۹ ایستگاه سینوپتیک کشور استفاده گردید. با توجه به تعداد زیاد ایستگاه‌های سینوپتیک، ایستگاه‌ها با توجه به سری‌های زمانی خشک‌سالی و با استفاده از روش K-means به پنج خوشه C1 تا C5 تقسیم شدند. نتایج با توجه به قرارگیری ایستگاه‌ها در خوشه‌ها مورد مقایسه قرار گرفتند و دقت مدل‌ها براساس آماره‌های (RMSE و R2) داده‌های آزمون، مورد ارزیابی قرار گرفتند. نتایج به‌دست‌آمده از این پژوهش نشان داد که در هر سه مدل پیش‌بینی با افزایش مقیاس زمانی پیش‌بینی دقت مدل‌ها کاهش یافته است. مقایسه بین سه الگوریتم بهینه‌سازی ذکر شده و الگوریتم لونبرگ-مارکوات به‌عنوان یک الگوریتم پرکاربرد در بهینه‌سازی وزن‌های شبکه عصبی، نشان‌دهنده برتری قابل‌توجه الگوریتم‌های بهینه‌سازی فراابتکاری است. مقایسه بین سه الگوریتم TLBO، IWO و PSO نشان داد که الگوریتم TLBO اندکی بهتر از سایر الگوریتم‌ها عمل می‌کند و نتایج دقیق‌تری را ارائه می‌کند. بهترین پیش‌بینی مدل‌های ذکر شده و بیش‌ترین مقادیر R2 در خوشه یک (شرق، نوار جنوب و جنوب‌شرقی ایران) و بیش‌ترین مقادیر RMSE و کم‌ترین دقت مدل‌ها در خوشه پنج (نوار شمالی کشور) مشاهده شد.

کلیدواژه‌ها: الگوریتم‌های بهینه‌سازی هوشمند، خشک‌سالی، شاخص بارش-تبخیر و تعرق استاندارد شده، یادگیری ماشین.

Application of Combined Artificial Neural Network Model and meta-heuristic Optimization Algorithms in Predicting SPEI₁₂ Drought Index

Porya Ghasemi¹, Masoud Karbasi^{2*}, Alireza Zamani Nouri³, Mahdi Sarai Tabrizi⁴

1. Ph.D. Candidate, Department of Water Engineering and Sciences, Science and Research Branch, Islamic Azad University, Tehran, Iran.

2. Associate Professor, Water Engineering Department, University of Zanjan, Zanjan, Iran.

3. Department of Civil Engineering, Shar-e-Qods Branch, Islamic Azad University, Tehran, Iran.

4. Assistant Professor, Department of Water Engineering and Sciences, Science and Research Branch, Islamic Azad University, Tehran, Iran.

Received: February, 06, 2021

Accepted: June, 19, 2021

Abstract

Drought is one of the most important and damaging natural disasters in the field of water resources that occurs in all climatic regimes of the country. Therefore, predicting and dealing with it is very important. In the present study, 79 synoptic stations in Iran were selected as the study. Three meta-heuristic optimization algorithms TLBO, IWO, PSO and the conventional Levenberg-Marquadt algorithm were used to train the multilayer artificial neural network to predict the SPEI₁₂ drought index for the next one to three months. Due to the large number of synoptic stations, the stations were divided into five clusters C1 to C5 according to the time series of the drought using the K-means method. The results were compared with respect to the location of the stations in the clusters and the accuracy of the models was evaluated based on the RMSE and R2 indices of the test data. Showed that in all three prediction models, the accuracy of the models decreased with increasing prediction time. Comparison between the three optimization algorithms mentioned and Levenberg-Marquadt algorithm as a widely used algorithm in optimizing neural network weights, showed the better performance of meta-heuristic algorithms. The comparison between the three TLBO, IWO and PSO algorithms showed that the TLBO algorithm performed slightly better than the other algorithms and provided more accurate results. R2 was observed in cluster one (eastern regions, southern strip and southeastern regions of Iran) and the highest RMSE values and the lowest accuracy of the models were observed in cluster five (northern strip strip of the country).

Keywords: Drought, Intelligence optimization algorithms, Machine learning, Standardized precipitation evapotranspiration index.

مقدمه

وقایع خشک‌سالی پیامد اجتناب‌ناپذیر نوسانات آب‌وهوایی محسوب می‌شوند. از زمان‌های گذشته همواره کمبود آب و خشک‌سالی از چالش‌های جدی جوامع بشری بوده‌اند، اما خشک‌سالی‌های اخیر به سبب افزایش شدت و مدت پدیده‌هایی نامتعارف شده‌اند (Govindaraju, 2013). خشک‌سالی به‌عنوان یکی از زیان‌بارترین مخاطرات طبیعی هر ساله به‌طور متوسط شش میلیارد دلار خسارت در مقیاس جهانی به بخش‌های مختلف وارد می‌کند و نسبت به سایر مخاطرات طبیعی افراد بیش‌تری را تحت تأثیر قرار می‌دهد (Keyantash & Dracup, 2004). ساده‌ترین تعریف خشک‌سالی عبارتست از کمبود آب نسبت به شرایط عادی را خشک‌سالی گویند (Sheffield & Wood, 2011). کشور ما، ایران نیز از اثرات مخرب این پدیده در امان نمانده و خسارت فراوانی را متحمل شده است. در سال‌های اخیر بسیاری از نواحی کشور تحت تأثیر خشک‌سالی‌های شدید و جبران‌ناپذیری قرار گرفته‌اند. به‌عنوان مثال، خشک‌سالی‌های به‌وقوع پیوسته در سال آبی ۱۳۷۷-۱۳۷۸ خسارتی معادل ۱۰۰۰۰ میلیارد ریال و در سال آبی ۱۳۷۹-۱۳۸۰ خسارتی معادل ۲۱۰۰۰ میلیارد ریال را در بخش کشاورزی تحمیل کرده‌اند (Davaranpanah et al., 2002). لذا با توجه به میزان بالای خسارت‌های ناشی از این پدیده، پایش و پیش‌بینی این پدیده حائز اهمیت بوده و به مدیریت این پدیده جهت کاهش اثرات و شدت خسارت‌های آن در سطوح مختلف جامعه کمک فراوانی خواهد نمود.

برای پیش‌بینی خشک‌سالی، روش‌های مختلفی هم‌چون سری‌های زمانی، زنجیره مارکف و روش‌های مبتنی بر هوش مصنوعی توسط پژوهش‌گران استفاده شده است، که می‌توان به موارد زیر اشاره نمود. بسیاری از این مطالعات نشان‌دهنده عملکرد مناسب و مطلوب روش‌های

مبتنی بر هوش مصنوعی به‌ویژه شبکه‌های عصبی مصنوعی^۱ (ANNs) در پیش‌بینی خشک‌سالی بوده است. Aghelpour et al. (2021) در پژوهشی تحت عنوان پیش‌بینی خشک‌سالی هیدرولوژیکی با استفاده از شاخص خشک‌سالی جریان^۲ (SDI) در شمال ایران، به پیش‌بینی خشک‌سالی هیدرولوژیکی با استفاده از مدل‌های روش گروهی مدل‌سازی داده^۳ (GMDH) و سیستم استنتاج فازی-عصبی تطبیقی^۴ (ANFIS) پرداختند و گزارش نمودند که دقت مدل‌های مورد استفاده تقریباً مشابه بوده و از طرفی مدل‌های خطی علاوه بر ساده‌گی، به‌طور قابل‌توجهی دقیق‌تر بوده‌اند. Nabipour et al. (2020) به پیش‌بینی خشک‌سالی هیدرولوژیکی کوتاه‌مدت براساس بهینه‌سازی‌های مختلف با الهام از طبیعت الگوریتم‌های ترکیبی مصنوعی با شبکه‌های عصبی پرداختند نتایج نشان داد که مدل ترکیبی نسبت به مدل ANN معمولی بهتر عمل کرده است. Komasi et al. (2018) از الگوریتم ماشین بردار پشتیبان^۵ (SVM) برای پیش‌بینی شاخص بارش استاندارد شده^۶ (SPI) در حوضه دریاچه ارومیه استفاده کردند و از طرفی از یک روش مبتنی بر جستجوی فاخته^۷ (CS) نیز برای بهینه‌سازی رگرسیون بردار پشتیبان (SVM) نیز بهره بردند. نتایج نشان داد که روش CS-SVM عملکرد بهتری نسبت به (SVM) دارد. Mehdizadeh et al. (2020) مدل‌سازی خشک‌سالی را با استفاده از سری زمانی کلاسیک و بیان ژن ترکیبی موجک مدل‌های برنامه‌نویسی مورد بررسی قرار دادند که شاخص بارش-تبخیر و تعرق استاندارد شده^۸ (SPEI) را در سه سطح زمانی یعنی (SPEI-3، SPEI-6 و SPEI-12) برای شش ایستگاه هواشناسی ترکیه محاسبه کردند و در مجموع از ۲۹ مدل در این مطالعه استفاده کردند. Kisi et al. (2019) به پیش‌بینی خشک‌سالی با استفاده از روش‌های جدید اکتشافی در مناطق نیمه‌خشک استان سمنان پرداختند. در

این پژوهش با استفاده از روش‌های سیستم‌های فازی و بهینه‌سازی (ANFIS-PSO)، الگوریتم ژنتیک^۹ (ANFIS- GA)، الگوریتم تکاملی کلونی مورچگان^{۱۰} (ANFIS- ACO) و الگوریتم بهینه‌سازی پروانه‌ای^{۱۱} (ANFIS- BOA) به پیش‌بینی شاخص خشک‌سالی SPI پرداختند. نتایج حاکی از برتری و بهتر بودن روش‌های فازی تکاملی نسبت به روش‌های ANFIS بود. Shafiei et al. (2011) در پژوهشی که برای پیش‌بینی شدت خشک‌سالی کشاورزی شاخص خشک‌سالی پالمر با استفاده از روش‌های سری زمانی باکس و جینکینس در ایستگاه سینوپتیک مشهد مورد بررسی قرار گرفته است. نتایج نشان داد که در سال‌های اخیر شدت خشک‌سالی افزایش یافته است و هم‌چنین مشخص شد که مدل انتخاب‌شده در منطقه مورد نظر، تنها تا دو ماه آینده را می‌تواند با دقت مناسب پیش‌بینی کند.

در پژوهشی توسط Erogluer & Apaydin (2020) تحت عنوان استفاده از روش‌های شبکه‌های عصبی مصنوعی (ANNs) برای پیش‌بینی شاخص خشک‌سالی جریان (SDI) بوده که در منطقه آنکارا- نالیحان انجام شده است و با استفاده از نتایج به‌دست‌آمده در هشت ایستگاه مختلف در این مطالعه، پیش‌بینی شد که در آینده ممکن است خشک‌سالی شدید در منطقه مورد مطالعه رخ دهد. پیشنهاد کردند برای کنترل خشک‌سالی در منطقه اقدامات احتیاطی و برنامه عملیاتی تهیه شود.

Shamshirband et al. (2020) در تحقیقی با استفاده از مدل‌های رگرسیون بردار پشتیبان (SVR)، برنامه ریزی بیان ژن^{۱۲} (GEP) و درخت تصمیم^{۱۳} (MT) به پیش‌بینی سه شاخص شاخص بارش استاندارد شده (SPI)، شاخص استاندارد جریان^{۱۴} (SSI) و شاخص بارش- تبخیر و تعرق استاندارد شده (SPEI)، پرداختند. نتایج نشان داد پیش‌بینی شاخص بارش استاندارد شده (SPI) از دقت بالاتری برخوردار است و هم‌چنین مدل (MT) با موفقیت برای آموزش مدل‌های ANN استفاده شده‌اند. نتایج نشان می‌دهد که این تکنیک‌ها عملکرد شبکه‌های عصبی مرسوم را بهبود می‌بخشند (Chen et al., 2015; Düğenci et al., 2015; Kayarvizhy et al., 2013; Cheng et al., 2008) و هم‌چنین، نتایج انواع الگوریتم‌های مورد اشاره نسبت به الگوریتم یادگیری پس انتشار خطا^{۱۵} (BP) بهتر و برتر بودند. هدف پژوهش حاضر استفاده از الگوریتم‌های بهینه‌سازی هوشمند (الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری^{۱۶} (TLBO)، الگوریتم بهینه‌سازی علف‌های هرز^{۱۸} (IWO)، الگوریتم ازدحام ذرات^{۱۹} (PSO) و الگوریتم متداول لونیبرگ- مارکوات^{۲۰} (LM) در پیش‌بینی یک الی سه ماه آینده شاخص خشک‌سالی SPEI₁₂ در کشور ایران است. مرور مطالعات گذشته نشان می‌دهد که تاکنون ترکیب الگوریتم‌های هوشمند TLBO و IWO با شبکه عصبی مصنوعی پرسپترون چند لایه^{۲۱} (MLP) در پیش‌بینی خشک‌سالی به‌کار گرفته نشده است و تاکنون پژوهشی نیز کل کشور ایران و تعداد ۷۹ ایستگاه سینوپتیک را در موضوع پیش‌بینی خشک‌سالی در نظر نگرفته است. در پژوهش حاضر با ارائه نقشه‌هایی دقت مدل‌های مورد استفاده به‌صورت مکانی نیز مشخص شده است. هم‌چنین دیگر نوآوری پژوهش حاضر استفاده از روش خوشه‌بندی k-means در خوشه‌بندی ایستگاه‌های سینوپتیک ایران براساس سری زمانی شاخص خشک‌سالی

این پژوهش با استفاده از روش‌های سیستم‌های فازی و بهینه‌سازی (ANFIS-PSO)، الگوریتم ژنتیک^۹ (ANFIS- GA)، الگوریتم تکاملی کلونی مورچگان^{۱۰} (ANFIS- ACO) و الگوریتم بهینه‌سازی پروانه‌ای^{۱۱} (ANFIS- BOA) به پیش‌بینی شاخص خشک‌سالی SPI پرداختند. نتایج حاکی از برتری و بهتر بودن روش‌های فازی تکاملی نسبت به روش‌های ANFIS بود. Shafiei et al. (2011) در پژوهشی که برای پیش‌بینی شدت خشک‌سالی کشاورزی شاخص خشک‌سالی پالمر با استفاده از روش‌های سری زمانی باکس و جینکینس در ایستگاه سینوپتیک مشهد مورد بررسی قرار گرفته است. نتایج نشان داد که در سال‌های اخیر شدت خشک‌سالی افزایش یافته است و هم‌چنین مشخص شد که مدل انتخاب‌شده در منطقه مورد نظر، تنها تا دو ماه آینده را می‌تواند با دقت مناسب پیش‌بینی کند.

در پژوهشی توسط Erogluer & Apaydin (2020) تحت عنوان استفاده از روش‌های شبکه‌های عصبی مصنوعی (ANNs) برای پیش‌بینی شاخص خشک‌سالی جریان (SDI) بوده که در منطقه آنکارا- نالیحان انجام شده است و با استفاده از نتایج به‌دست‌آمده در هشت ایستگاه مختلف در این مطالعه، پیش‌بینی شد که در آینده ممکن است خشک‌سالی شدید در منطقه مورد مطالعه رخ دهد. پیشنهاد کردند برای کنترل خشک‌سالی در منطقه اقدامات احتیاطی و برنامه عملیاتی تهیه شود.

Shamshirband et al. (2020) در تحقیقی با استفاده از مدل‌های رگرسیون بردار پشتیبان (SVR)، برنامه ریزی بیان ژن^{۱۲} (GEP) و درخت تصمیم^{۱۳} (MT) به پیش‌بینی سه شاخص شاخص بارش استاندارد شده (SPI)، شاخص استاندارد جریان^{۱۴} (SSI) و شاخص بارش- تبخیر و تعرق استاندارد شده (SPEI)، پرداختند. نتایج نشان داد پیش‌بینی شاخص بارش استاندارد شده (SPI) از دقت بالاتری برخوردار است و هم‌چنین مدل (MT) با موفقیت برای آموزش مدل‌های ANN استفاده شده‌اند. نتایج نشان می‌دهد که این تکنیک‌ها عملکرد شبکه‌های عصبی مرسوم را بهبود می‌بخشند (Chen et al., 2015; Düğenci et al., 2015; Kayarvizhy et al., 2013; Cheng et al., 2008) و هم‌چنین، نتایج انواع الگوریتم‌های مورد اشاره نسبت به الگوریتم یادگیری پس انتشار خطا^{۱۵} (BP) بهتر و برتر بودند. هدف پژوهش حاضر استفاده از الگوریتم‌های بهینه‌سازی هوشمند (الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری^{۱۶} (TLBO)، الگوریتم بهینه‌سازی علف‌های هرز^{۱۸} (IWO)، الگوریتم ازدحام ذرات^{۱۹} (PSO) و الگوریتم متداول لونیبرگ- مارکوات^{۲۰} (LM) در پیش‌بینی یک الی سه ماه آینده شاخص خشک‌سالی SPEI₁₂ در کشور ایران است. مرور مطالعات گذشته نشان می‌دهد که تاکنون ترکیب الگوریتم‌های هوشمند TLBO و IWO با شبکه عصبی مصنوعی پرسپترون چند لایه^{۲۱} (MLP) در پیش‌بینی خشک‌سالی به‌کار گرفته نشده است و تاکنون پژوهشی نیز کل کشور ایران و تعداد ۷۹ ایستگاه سینوپتیک را در موضوع پیش‌بینی خشک‌سالی در نظر نگرفته است. در پژوهش حاضر با ارائه نقشه‌هایی دقت مدل‌های مورد استفاده به‌صورت مکانی نیز مشخص شده است. هم‌چنین دیگر نوآوری پژوهش حاضر استفاده از روش خوشه‌بندی k-means در خوشه‌بندی ایستگاه‌های سینوپتیک ایران براساس سری زمانی شاخص خشک‌سالی

تدریج از شمال و شمال غرب کشور با بارندگی بالا به مناطق جنوب شرق کشور با بارندگی کم متغیر است، در حالی که میزان درجه حرارت و دمای هوا از مناطق شمال کشور به جنوب کشور در حال افزایش است. با توجه به تنوع آب و هوایی و این که خشک سالی نقش مهمی در اقتصاد ملی و معیشت مردم دارد، مقیاس مطالعه در سطح ۷۹ ایستگاه سینوپتیک کشور (شکل ۱) انتخاب شد و این ایستگاه‌ها به دلیل کامل بودن داده‌های آماری در طی دوره آماری و هم‌چنین سیطره کاملی از اقلیم‌های کشور را شامل می‌شوند انتخاب شدند، داده‌های مورد استفاده در این پژوهش شامل سری‌های زمانی بارش ماهانه، دمای حداکثر و حداقل طی یک دوره آماری از ابتدای سال ۱۹۸۹ تا انتهای سال ۲۰۱۹ است.

SPEI₁₂ است. دلیل استفاده از شاخص SPEI₁₂ ذکر همبستگی بالای آن با شاخص‌های خشک سالی هیدرولوژیکی در برخی مراجع می‌باشد (Mirakbari *et al.*, 2018; Cheraghalizadeh *et al.*, 2018).

مواد و روش‌ها منطقه مورد مطالعه

کشور ایران در منطقه جنوب غرب آسیا بین طول جغرافیایی ۴۴ و ۶۳ شرقی و عرض جغرافیایی ۲۵ و ۴۰ شمالی واقع شده است و طیف گسترده‌ای از توپوگرافی (ارتفاع در مناطق کوهستانی ۵۵۰۰ متر در غرب کشور و ۲۴- متر در سواحل شمالی کشور متفاوت است) و اقلیم‌های آب و هوایی متفاوت دارد. مقدار بارندگی به

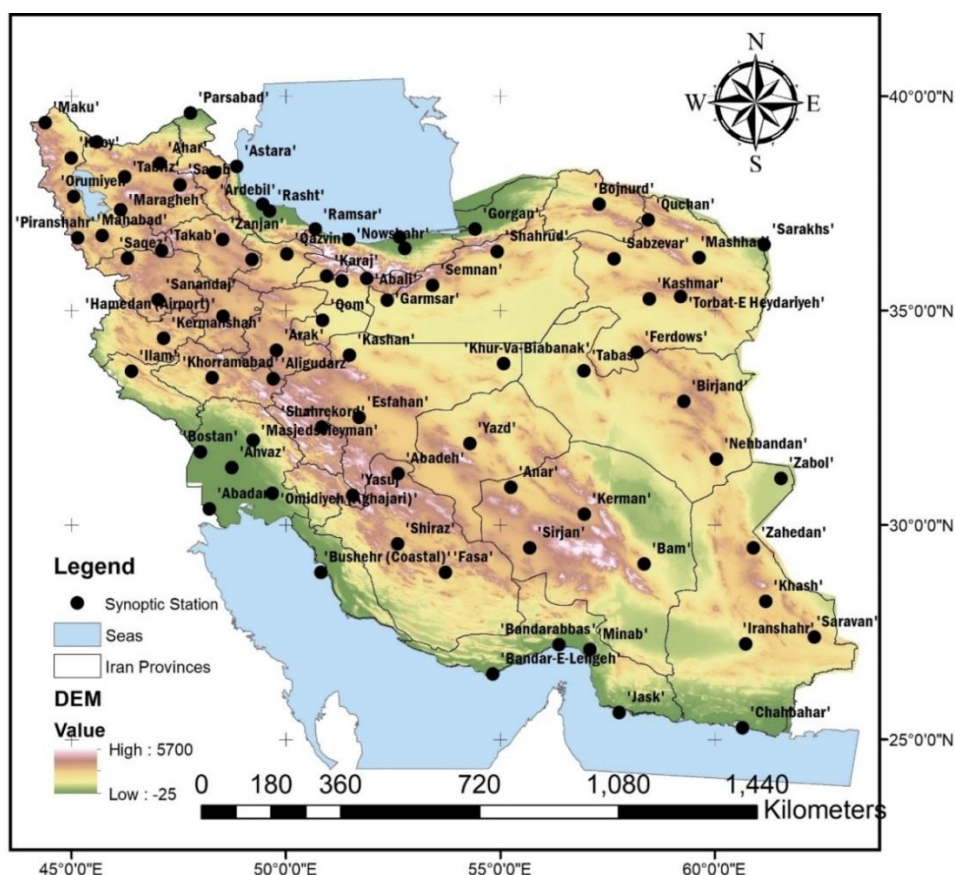


Figure 1. The location of the stations used in the study

$$W = \sqrt{-\ln(P)} \quad \text{for } P \ll 0.5 \quad (6)$$

$$P = 1 - F(x) \quad (7)$$

ضرایب ثابت فوق، به صورت زیر ارائه می‌شود.

$$\begin{cases} C_0 = 2.515517 \\ C_1 = 0.802853 \\ C_3 = 0.010328 \end{cases} \quad \begin{cases} D_1 = 1.432788 \\ D_2 = 0.189269 \\ D_3 = 0.001308 \end{cases} \quad (8)$$

هم‌چنین تقسیم‌بندی کلاس‌ها و طبقات شدت خشک‌سالی مانند شاخص SPI است، که این طبقه‌بندی اولین بار توسط Edwards & McKee (1997) برای شاخص SPI ارائه شد. در این پژوهش برای محاسبه تبخیر و تعرق از روش هارگریوز-سامانی (HS) استفاده شده است. عملکرد روش هارگریوز اصلاح‌شده برای محاسبه تبخیر و تعرق پتانسیل ماهانه در مقایسه با سایر روش‌ها چشم‌گیر است و نیاز کم داده در این روش، آن را به یک روش جذاب در مواقع دقت کم داده‌های اندازه‌گیری شده بدل می‌کند (Droogers & Allen, 2002).

الگوریتم بهینه‌سازی

در این مطالعه از سه الگوریتم‌های بهینه‌سازی هوشمند TLBO, JWO, PSO و الگوریتم متداول لونیگ-مارکوات به منظور آموزش شبکه عصبی مصنوعی چند لایه، برای پیش‌بینی شاخص خشک‌سالی SPEI₁₂ یک تا سه ماه آینده استفاده می‌شود.

الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری

TLBO دارای دو فاز است. فاز اول آموزش (TP)^{۲۲} و فاز دوم یادگیری (LP)^{۲۳}.

الگوریتم مذکور با الهام از آموزش و یادگیری در کلاس، به صورت یک الگوریتم بهینه‌سازی توسط Rao et al. (2011) ارائه شد، که برای بهینه‌سازی یک تابع پیوسته غیر خطی استفاده شد.

شاخص خشک‌سالی SPEI

این نمایه توسط Vicente-Serrano et al. (2010) شاخص بارش-تبخیر و تعرق استاندارد شده ارائه گردید. در این شاخص همزمان هم به متغیرهای بارش و تبخیر و تعرق توجه می‌شود. طی چند سال گذشته، شاخص بارش-تبخیر و تعرق استاندارد شده (SPEI) گسترده‌ترین کاربرد را برای پایش خشک‌سالی پیدا کرده است (Beguería et al., 2014).

$$D_i = P_i - PET_i \quad (1)$$

محاسبه این شاخص نیازمند برآورد مقادیر احتمال تجمعی مقادیر D_i می‌باشد. Vicente-Serrano et al. (2010) با بررسی توابع مختلف سه پارامتری، تابع چگالی احتمال لوگ لوجستیک سه پارامتری را دارای بهترین برآزش بر مقادیر مختلفی بر سری‌های زمانی در مقیاس‌های مختلف زمانی D_i تشخیص دادند. فرم کلی تابع چگالی احتمال به صورت رابطه زیر است:

$$f(x) = \frac{\beta}{\alpha} \left(\frac{x-\gamma}{\alpha} \right)^{\beta-1} \left[1 + \left(\frac{x-\gamma}{\alpha} \right)^{\beta} \right]^{-2} \quad (2)$$

$$\gamma > D < \infty \quad (3)$$

α و β و γ پارامترهای مقیاس، شکل و اصلی می‌باشند. تابع احتمال تجمعی لوگ-لوجستیک سه پارامتری به صورت زیر است.

$$F(x) = \left[1 + \left(\frac{\alpha}{x-\gamma} \right)^{\beta} \right]^{-1} \quad (4)$$

در مرحله بعد احتمال تجمعی به متغیر نرمال استاندارد با میانگین صفر و واریانس ۱ تبدیل می‌شود، که برابر با شاخص SPEI است. تابع کلاسیک Abramowitz & Stegun (1965)، با استفاده از مقادیر تابع $F(x)$ تخمینی برای مقادیر شاخص SPEI می‌باشد. که اگر مقدار P بزرگ‌تر از ۰/۵ باشد. آن‌گاه مقدار P با $1-P$ جایگزین خواهد شد.

$$SPEI = W - \frac{C_0 + C_1W + C_2W^2}{1 + d_1w + d_2w^2 + d_3w^3} \quad (5)$$

فاز آموزش

فرض کنید که در هر تکرار μ_i میانگین و T_i معلم کلاس باشد. T_i تلاش خواهد نمود که میانگین μ_i را به سطح خودش نزدیک کند، در نتیجه کلاس دارای میانگین جدید و مطلوب برابر μ_{new} به دست آمده توسط آموزش اعمال شده توسط T_i که با دانش معلم برابر است و بهترین عضو جمعیت می باشد. r_i بردار رندومی بین $[0,1]$ است.

$$T = \text{Teacher} \quad \mu_{new} = T \quad (9)$$

$$X_{i_{new}} = X_i + r(\mu_{new} - Tf\mu) \quad (10)$$

$$TF = \text{Teaching Factor} \in \{1,2\} \quad (11)$$

فاز یادگیری

در فاز یادگیری که با تعامل بین دانش آموزان، دانش انتقال داده می شود. برای هر پاسخ مانند X_i یک پاسخ دیگر X_j به صورت تصادفی انتخاب می کنیم.

اگر X_j بهتر باشد

$$X_{i_{new}} = X_i + r(X_j - X_i) \quad (12)$$

اگر X_i بهتر باشد

$$X_{i_{new}} = X_i + r(X_i - X_j) \quad (13)$$

در نهایت با بررسی شرایط خاتمه در صورت برآورده نشدن شرایط، اجرای الگوریتم از ابتدا ادامه می یابد و در غیر این صورت خاتمه می یابد.

می کند و برای گیاهان زراعی مفید، آفت جدی می باشد و جلوی رشد آن ها را می گیرد. علف های هرز گیاهانی هستند که رشد هجوم آورنده و شدید آن ها تهدید مهمی برای گیاهان زراعی محسوب می شود و بسیار پایدار و تطابق پذیر در مقابل تغییرات محیط می باشند. بنابراین استفاده از خصوصیات آن ها می تواند منجر به یک الگوریتم بهینه سازی قوی شود. این الگوریتم تلاش می کند که از قدرت تطابق پذیری و تصادفی بودن جمعیت علف های هرز به طور ساده اما مؤثر، تقلید کند. این الگوریتم در عین سادگی، در یافتن نقاط بهینه بسیار مؤثر و سریع می باشد و براساس ویژگی های اولیه و طبیعی علف های هرز مانند تولید بذر، رشد و تنازع برای بقا در یک کلونی عمل می کند. این الگوریتم یک تعداد متنه ای از علف های هرز است هر علف هرز، علف های هرز جدیدی را بسته به سازگاری و شرایط خود تولید می کند. علف های هرز تولید شده در فضای جستجو به صورت تصادفی با توزیع نرمال تقسیم بندی می شوند. این روند تا رسیدن به حداکثر تعداد علف های هرز ادامه پیدا می کند. فقط علف های هرز با سازگاری بهتر می توانند زنده بمانند و تولید دانه کنند و دیگران حذف می شوند این روند ادامه پیدا می کند تا زمانی که علف هرز با بهترین سازگاری باقی بماند که نزدیک به راه حل بهینه است.

الگوریتم بهینه سازی ازدحام ذرات

الگوریتم بهینه سازی ازدحام ذرات (PSO) یکی از روش های بهینه سازی الهام گرفته از طبیعت است، که برای حل مسائل بهینه سازی عددی با فضای جستجوی بسیار بزرگ، بدون نیاز به اطلاع از گرادیان تابع هدف است. این روش که اولین بار توسط Kennedy & Eberhart (1995) ابداع و نتایج آن منتشر شده است، موجودات در ازدحام ذرات، رفتار ساده ای را دنبال می کنند و آن تقلید از موفقیت

الگوریتم بهینه سازی علف های هرز

یکی از روش های بهینه سازی جدید، الگوریتم بهینه سازی علف های هرز می باشد. این روش اولین بار توسط Mehrabian & Lucas (2006) با الهام از یک پدیده شایع در کشاورزی یعنی رشد علف های هرز در قالب مقاله ای مطرح شده است. طبق تعریف علف هرز گیاهی است که در مکان های ناخواسته، وابسته به شرایط تولید و رشد

در روش MLP تعیین تعداد نرون‌های بهینه در لایه پنهان است، بدین منظور روش آزمون و خطا مورد استفاده قرار می‌گیرد و تعداد نرون یک تا ۱۰ با توجه به متوسط خطای RMSE در کلیه ایستگاه‌ها مورد ارزیابی قرار خواهد گرفت.

خوشه‌بندی

خوشه‌بندی^{۲۴} نوعی روش آموزش غیر نظارت‌شده می‌باشد یعنی نیازی به داده آموزشی برچسب‌دار اولیه به‌عنوان داده یادگیری نمی‌باشد. در این روش‌ها داده‌هایی که به هم شباهت دارند در دسته‌های یکسان قرار می‌گیرند. در این پژوهش از روش خوشه‌بندی K-mean استفاده شده است. خوشه‌بندی K-mean یکی از روش‌های بسیار مرسوم و مورد توجه بسیاری از پژوهش‌گران و کارشناسان است (Farris, 1969). این الگوریتم بین ۱۰ الگوریتم برتر خوشه‌بندی قرار دارد (Hartigan, 1975). K در K-mean بیانگر تعداد خوشه‌هایی است که کل داده‌ها در آن تقسیم‌بندی یا جزءبندی می‌شود. خوشه‌ها بر مبنای مراکز آن‌ها تعیین می‌شود. بر مبنای این ایده که هر نمونه باید حداقل فاصله را نسبت به مرکز خود نسبت به سایر مراکز داشته باشد (Mucherino et al., 2009).

در این روش ابتدا به تعداد خوشه‌های موردنیاز نقاطی به‌صورت تصادفی انتخاب می‌شود. سپس در داده‌ها با توجه به میزان نزدیکی (شباهت)، به یکی از این خوشه‌ها نسبت داده می‌شوند و به این ترتیب خوشه‌های جدیدی حاصل می‌شود. با تکرار همین روال می‌توان در هر تکرار با میانگین‌گیری از داده‌ها مراکز جدیدی برای آن‌ها محاسبه کرد و دوباره داده‌ها را به خوشه‌های جدید نسبت داد. این روند تا زمانی ادامه پیدا می‌کند که دیگر تغییری در داده‌ها حاصل نشود. نظر به تعداد زیاد ایستگاه‌ها با توجه به رفتار شاخص خشک‌سالی SPEI₁₂، ایستگاه‌های هواشناسی به خوشه‌های

موجودات همسایه و موفقیت خودشان است. نتیجه چنین رفتاری، یافتن نواحی بهینه در فضای جستجو با ابعاد بالا می‌باشد. یک الگوریتم PSO گروهی از ذرات را نگهداری می‌کند که هر ذره نمایش‌دهنده یک راه حل می‌باشد. مراحل الگوریتم بهینه‌سازی ازدحام ذرات به‌صورت زیر ارائه می‌شود.

- ۱- تولید ذرات اولیه
- ۲- محاسبه تابع هدف
- ۳- به‌روز رسانی Pbest
- ۴- به‌روز رسانی Gbest
- ۵- به‌روز رسانی سرعت
- ۶- به‌روز رسانی مقدار ذره
- ۷- جهش ذره
- ۸- تکرار مراحل ۱ تا ۷
- ۹- پاسخ نهایی Gbest

حرکت هر ذره به سه عامل وابسته است (موقعیت فعلی ذره، بهترین موقعیتی که تاکنون ذره داشته است Pbest، بهترین موقعیتی که تاکنون کل ذرات داشته‌اند Gbest) موقعیت جدید هر ذره از رابطه زیر حاصل می‌شود.

$$V_j(i) = w(i)V_j(i-1) + c_1r_1[P_{best,j} - X_j(i-1)] + c_2r_2[G_{best} - X_j(i-1)] \quad (14)$$

که در آن r تابع تصادفی است که اعداد تصادفی در بازه [0,1] تولید می‌کند. w ضریب اینرسی، C_1 و C_2 ضرایب تأثیر نامیده می‌شوند.

شبکه عصبی مبتنی بر الگوریتم لونیبرگ-مارکوات
الگوریتم لونیبرگ-مارکوات برای آموزش شبکه و توابع فعال‌ساز سیگموئید و خطی به‌ترتیب برای لایه‌های ورودی و خروجی در نظر گرفته می‌شود. مهم‌ترین بخش

به‌عنوان داده‌های آزمون مدنظر قرار گرفتند و دقت مدل‌ها براساس شاخص‌های آماری RMSE و R2 داده‌های آزمون مورد ارزیابی قرار گرفت. داده‌های ورودی هر ایستگاه با توجه به نمودارهای ACF^{۲۵} و PACF^{۲۶} به‌دست آمده‌اند. به این ترتیب که تأخیرهای معنی‌دار در هر دو نمودار به‌عنوان تأخیر برای ساخت مدل استفاده شده‌اند. تأخیرهایی که به‌عنوان ورودی مدل‌ها استفاده شده‌اند از یک تا ۱۲ ماه بسته به ایستگاه متغیر است. نظر به تعداد زیاد ایستگاه‌ها با توجه به رفتار شاخص خشک‌سالی SPEI₁₂، ۷۹ ایستگاه هواشناسی به پنج خوشه C1 تا C5 تقسیم شدند و نتایج با توجه به قرارگیری ایستگاه‌ها در خوشه‌ها مورد مقایسه قرار گرفتند. برای تعیین تعداد بهینه خوشه‌ها از شاخص Calinski-Harabasz (روش خوشه‌بندی K-mean) استفاده شده است. این شاخص اعتبار خوشه را براساس میانگین خوشه‌ای و ماتریس کوواریانس ارزیابی می‌کند. با استفاده از مقدار K در شاخص Calinski - Harabasz مقداری به‌دست می‌آید که به برآورد تعداد بهینه خوشه‌ها اشاره دارد (Harabasz & Caliński, 1974). طبق جدول (۱) بیش‌ترین مقدار در تعداد پنج خوشه مشاهده شده است و بنابراین، به‌عنوان بهترین تعداد خوشه انتخاب می‌شود.

نتایج حاصل از خوشه‌بندی، در شکل (۲) نمایش داده شده است. با توجه به شکل مشخص است که رفتارها و روند شاخص خشک‌سالی SPEI₁₂ بیش‌تر وابسته به مکان قرارگیری ایستگاه‌ها است و ایستگاه‌های یک خوشه اکثراً در یک منطقه قرار گرفته‌اند. به‌طور مثال در منطقه شمال‌غرب و غرب در خوشه (۵)، جنوب‌غرب در خوشه (۳) و جنوب و جنوب‌شرق در خوشه (۱) قرار گرفته‌اند. پارامترهای آماری RMSE و R² متوسط ایستگاه قرار گرفته در یک خوشه مورد ارزیابی و مقایسه قرار گرفتند.

م تفاوت تقسیم‌بندی شده و نتایج با توجه به قرارگیری ایستگاه‌ها در خوشه‌ها مورد مقایسه قرار خواهند گرفت.

معیارهای ارزیابی مدل‌ها

به‌منظور ارزیابی عملکرد و مقایسه روابط و مدل‌های پیشنهادی مختلف بالا از دو آماره خط‌اسنجی شامل ریشه میانگین مربعات خطا (RMSE) و ضریب تبیین خطا (R²) استفاده شده است. مطابق آزمون‌های نیکویی برازش، مدلی بهتر است که مقدار R² آن نزدیک به عدد یک باشد و مقدار (RMSE) نزدیک به صفر باشد.

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

$$R^2 = \frac{(\sum_{i=1}^N (O_i - \bar{O}_i)(P_i - \bar{P}_i))^2}{\sum_{i=1}^N (O_i - \bar{O}_i)^2 \sum_{i=1}^N (P_i - \bar{P}_i)^2} \quad (16)$$

که در آن O_i مقدار اندازه‌گیری شده (مقدار واقعی)، P_i مقدار پیش‌بینی شده، \bar{O}_i متوسط مقدار اندازه‌گیری شده، \bar{P}_i متوسط مقدار پیش‌بینی شده، N تعداد داده‌ها، RMSE متوسط اختلاف بین مقدار پیش‌بینی شده و مقدار اندازه‌گیری شده را توصیف می‌کند. ضریب تعیین R² میزان ارتباط بین مقادیر پیش‌بینی شده و اندازه‌گیری را شرح می‌دهد.

نتایج و بحث

در پژوهش حاضر از روش شبکه عصبی MLP بهینه‌شده توسط مدل لوبنرگ-مارکوات و سه روش بهینه‌سازی تکاملی PSO، IWO و TLBO به‌منظور پیش‌بینی شاخص خشک‌سالی سالانه (۱۲ ماهه) SPEI₁₂ در بازه‌های یک تا سه ماه آینده در کشور ایران (۷۹ ایستگاه سینوپتیک دارای بیش از ۳۰ سال آماری) در بازه ۱۹۸۸-۲۰۱۹ استفاده شد. در تمامی ایستگاه‌ها ۲۲ سال ابتدایی سری زمانی (۱۹۸۸-۲۰۰۹) به‌عنوان داده‌های آموزش و ۱۰ سال پایانی (۲۰۱۰-۲۰۱۹)

Table 1. Calinski-Harabasz index values for different number of clusters (K)

| Number of clusters (K) | 2 | 3 | 4 | 5 | 6 | 7 | 8 |
|-------------------------|-------|-------|-------|-------|-------|-------|------|
| Calinski-Harabasz value | 11.13 | 12.14 | 13.23 | 14.95 | 13.98 | 12.78 | 12.6 |

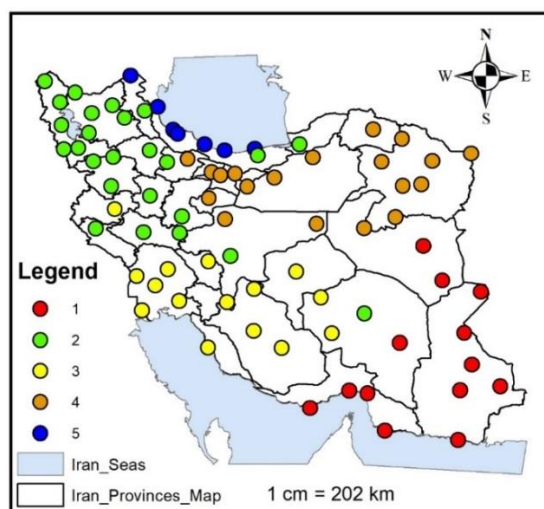


Figure 2. The clustering of synoptic stations based on SPEI₁₂ drought index

($RMSE=0/354$) و بیش‌ترین مقدار متوسط $RMSE$ مربوط به الگوریتم لونیبرگ- مارکوات (LM) است ($RMSE=0/457$). بیش‌ترین و کم‌ترین مقدار R^2 نیز به‌ترتیب مربوط به الگوریتم‌های TLBO ($R^2=0/834$) و LM ($R^2=0/808$) هستند. در خوشه (۱) کم‌ترین مقدار $RMSE$ مربوط به الگوریتم IWO است ($RMSE=0/306$). در خوشه (۲) دو الگوریتم TLBO و IWO کم‌ترین مقدار $RMSE$ را دارا می‌باشند ($RMSE=0/336$) و در خوشه (۳) نیز الگوریتم TLBO کم‌ترین مقدار $RMSE$ را ارائه کرده است ($RMSE=0/348$).

الگوریتم TLBO در خوشه (۴) نیز دارای کم‌ترین مقدار ($RMSE=0/384$) و در نهایت در خوشه (۵) الگوریتم PSO ($RMSE=0/393$) بهترین نتیجه ارائه کرده است. در هر پنج خوشه الگوریتم لونیبرگ- مارکوات ضعیف‌ترین نتایج را نسبت به سایر مدل‌ها ارائه کرده است. تغییرات مقادیر R^2 نیز مطابق با تغییرات مقادیر $RMSE$ است و بیش‌ترین مقادیر R^2 و کم‌ترین $RMSE$ را نتیجه داده است. در پیش‌بینی دو ماه آینده کم‌ترین مقدار متوسط $RMSE$ در کل خوشه توسط الگوریتم TLBO به‌دست آمده است ($RMSE=0/511$) و ($R^2=0/663$).

الگوریتم‌های بهینه‌سازی فرا ابتکاری هر یک دارای پارامترهای تنظیم مخصوص به‌خود هستند، که در هر الگوریتم متفاوت هستند. در جدول (۲) مقادیر پارامترهای هر الگوریتم با استفاده از روش آزمون و خطا به‌دست آمده‌اند. پارامترهای بهینه هر الگوریتم براساس بیش‌ترین دقت در کلیه ایستگاه‌ها به‌دست آمده است. بدین مفهوم که میانگین معیار $RMSE$ در مجموع ۷۹ ایستگاه کم‌ترین شود. تغییر پارامترهای الگوریتم‌ها تأثیر چندانی بر عملکرد آنها در بازه‌های پیش‌بینی یک تا سه ماه آینده نداشت. مطابق جدول، الگوریتم TLBO به‌جز مقادیر تکرار و جمعیت اولیه دارای پارامتر تنظیم دیگری نمی‌باشد که خود یک مزیت برای این الگوریتم محسوب می‌شود. الگوریتم IWO بیش‌ترین تعداد پارامترهای تنظیم را دارا می‌باشد و الگوریتم بهینه‌سازی PSO دارای چهار پارامتر تنظیم می‌باشد.

جدول (۳) مقادیر متوسط $RMSE$ و R^2 را در هر یک از الگوریتم‌های بهینه‌سازی شبکه عصبی مصنوعی را برای پنج خوشه مختلف نشان می‌دهد. نتایج برای پیش‌بینی یک تا سه ماه آینده ارائه شده است. در پیش‌بینی یک ماه آینده به‌طور متوسط کم‌ترین مقدار $RMSE$ مربوط به الگوریتم TLBO

Table 2. Set parameters values for three models of TLBO, IWO and PSO

| Algorithm setting parameters TLBO | Algorithm setting parameters IWO | PSO Algorithm setting parameters |
|---|---|---|
| Max iteration = 300 Population size = 50 | Max iteration = 300 Initial population size = 20 Maximum population size = 100 Minimum number of seeds = 0 Maximum number of seeds = 5 Variance reduction exponent = 2 Initial value of std = 1 Final value of std = 0.001 | Max iteration = 300 Swarm size = 50 Cognition coefficient = 2 Social coefficient = 2 |

Table 3. Results of RMSE and R² in forecasting 1 to 3 months ahead SPEI12 drought index

| Forecasting | Cluster | RMSE | | | | R ² | | | |
|----------------|---------|-------|-------|-------|-------|----------------|-------|-------|-------|
| | | LM | TLBO | IWO | PSO | LM | TLBO | IWO | PSO |
| 1 Month ahead | C1 | 0.437 | 0.308 | 0.306 | 0.316 | 0.811 | 0.844 | 0.845 | 0.836 |
| | C2 | 0.424 | 0.336 | 0.336 | 0.341 | 0.797 | 0.840 | 0.840 | 0.836 |
| | C3 | 0.555 | 0.348 | 0.354 | 0.358 | 0.783 | 0.825 | 0.820 | 0.817 |
| | C4 | 0.410 | 0.384 | 0.387 | 0.397 | 0.838 | 0.854 | 0.853 | 0.848 |
| | C5 | 0.459 | 0.394 | 0.394 | 0.393 | 0.812 | 0.805 | 0.804 | 0.803 |
| Mean | | 0.457 | 0.354 | 0.355 | 0.361 | 0.808 | 0.834 | 0.832 | 0.828 |
| 2 Months ahead | C1 | 0.488 | 0.455 | 0.458 | 0.456 | 0.635 | 0.670 | 0.667 | 0.668 |
| | C2 | 0.573 | 0.486 | 0.490 | 0.483 | 0.554 | 0.681 | 0.676 | 0.684 |
| | C3 | 0.694 | 0.526 | 0.525 | 0.527 | 0.585 | 0.620 | 0.623 | 0.618 |
| | C4 | 0.556 | 0.539 | 0.539 | 0.551 | 0.643 | 0.723 | 0.724 | 0.702 |
| | C5 | 0.842 | 0.550 | 0.550 | 0.549 | 0.492 | 0.623 | 0.624 | 0.623 |
| Mean | | 0.631 | 0.511 | 0.512 | 0.513 | 0.582 | 0.663 | 0.663 | 0.659 |
| 3 Months ahead | C1 | 0.600 | 0.565 | 0.570 | 0.561 | 0.475 | 0.513 | 0.504 | 0.514 |
| | C2 | 0.609 | 0.591 | 0.590 | 0.589 | 0.503 | 0.546 | 0.546 | 0.543 |
| | C3 | 0.666 | 0.632 | 0.645 | 0.621 | 0.455 | 0.469 | 0.463 | 0.477 |
| | C4 | 0.786 | 0.658 | 0.650 | 0.650 | 0.527 | 0.596 | 0.604 | 0.602 |
| | C5 | 0.914 | 0.657 | 0.654 | 0.652 | 0.496 | 0.473 | 0.476 | 0.478 |
| Mean | | 0.715 | 0.621 | 0.622 | 0.615 | 0.491 | 0.519 | 0.519 | 0.523 |

پیش‌بینی‌های یک و دو ماه آینده، الگوریتم LM کم‌ترین دقت را داشته است (RMSE=۰/۷۱۵). تحلیل نتایج در خوشه‌های مختلف هم نشان می‌دهد که الگوریتم PSO در هر پنج خوشه مورد بررسی بالاترین دقت را داشته است، درحالی‌که الگوریتم LM کم‌ترین دقت را ارائه کرده است. برتری الگوریتم‌های بهینه‌سازی فراابتکاری در بهینه‌سازی وزن‌های شبکه عصبی مصنوعی نسبت به الگوریتم‌های بهینه‌سازی معمول شبکه عصبی توسط محققین متعددی گزارش شده است. Alizadeh et al. (2017) در مدل‌سازی ضریب پخشیدگی طولی رودخانه‌ها گزارش نمودند که الگوریتم‌های فرا ابتکاری شامل الگوریتم رقابت استعماری^{۳۷} ICA، الگوریتم زنبور عسل BA و الگوریتم فاخته CS نسبت به دو الگوریتم لوبگر-مارکوات و الگوریتم ژنتیک عملکرد بهتری در بهینه‌سازی وزن‌های شبکه عصبی مصنوعی دارند. Dang et al.

ضعیف‌ترین نتایج را الگوریتم LM ارائه کرده است (RMSE=۰/۶۳۱) و (R²=۰/۵۸۲). الگوریتم‌های PSO و IWO اختلاف کمی با الگوریتم TLBO دارند. در خوشه (۱) الگوریتم TLBO بهترین نتیجه را ارائه کرده است (RMSE=۰/۴۵۵). در خوشه (۲) الگوریتم PSO (RMSE=۰/۴۸۳)، در خوشه (۳) الگوریتم IWO (RMSE=۰/۵۲۵)، در خوشه (۴) دو الگوریتم TLBO و IWO (RMSE=۰/۵۳۹) و در خوشه (۵) نیز الگوریتم PSO (RMSE=۰/۵۴۹) بهترین نتیجه را ارائه کرده‌اند. اختلاف الگوریتم‌های TLBO، IWO و PSO بسیار اندک می‌باشد. ضعیف‌ترین دقت در هر پنج خوشه را الگوریتم LM ارائه کرده است. در پیش‌بینی سه ماه آینده به‌طور متوسط الگوریتم PSO بیش‌ترین دقت را داشته است. (RMSE=۰/۶۲۱) و الگوریتم‌های TLBO و IWO با اختلاف کمی در رده‌های بعدی قرار گرفته‌اند. همانند

شکل (۳) نمودارهای سری زمانی مقادیر واقعی شاخص خشک‌سالی را در مقابل مقادیر پیش‌بینی شده آن برای پنج ایستگاه منتخب از خوشه‌های به‌دست‌آمده در بخش قبل ارائه شده است. با توجه به برتری نسبی الگوریتم TLBO در آموزش شبکه عصبی مصنوعی از نتایج این الگوریتم استفاده شده است. با توجه به شکل (۳) با افزایش بازه پیش‌بینی از یک به سه ماه، تطابق داده‌های واقعی و مدل‌سازی شده کم‌تر شده است. که این نتیجه با نتایج Ghamghami & Bazrafshan (2012)، Hosseini-Moghari & Araghinejad (2015) و Kousari *et al.* (2017) در مورد کاهش دقت پیش‌بینی خشک‌سالی از یک به سه ماه در همه مدل‌ها مطابقت دارد.

(2019) نیز نشان دادند که ترکیب شبکه عصبی مصنوعی با الگوریتم‌های PSO و الگوریتم کرم شب تاب^{۲۸} FA نسبت به الگوریتم لوبنرگ-مارکوات قابلیت بالاتری در برآورد عمق آبستگي در پایه پل دارند. یکی از مزایای مهم الگوریتم بهینه‌سازی TLBO نسبت به سایر الگوریتم‌های فراابتکاری عدم نیاز آن به پارامترهای تنظیم است (Toghan., 2012). Rao *et al.* (2012) نشان دادند که الگوریتم TLBO نسبت به سایر الگوریتم‌های فراابتکاری معمول (GA, PSO, ABC, ACO) بهتر عمل می‌کند. در پژوهش حاضر نیز نتیجه به‌دست‌آمده نشان‌دهنده برتری نسبی الگوریتم TLBO در بهینه‌سازی وزن‌های شبکه عصبی مصنوعی است. نتیجه به‌دست‌آمده با نتایج Stapaty *et al.* (2012) و Gao *et al.* (2019) مطابقت دارد.

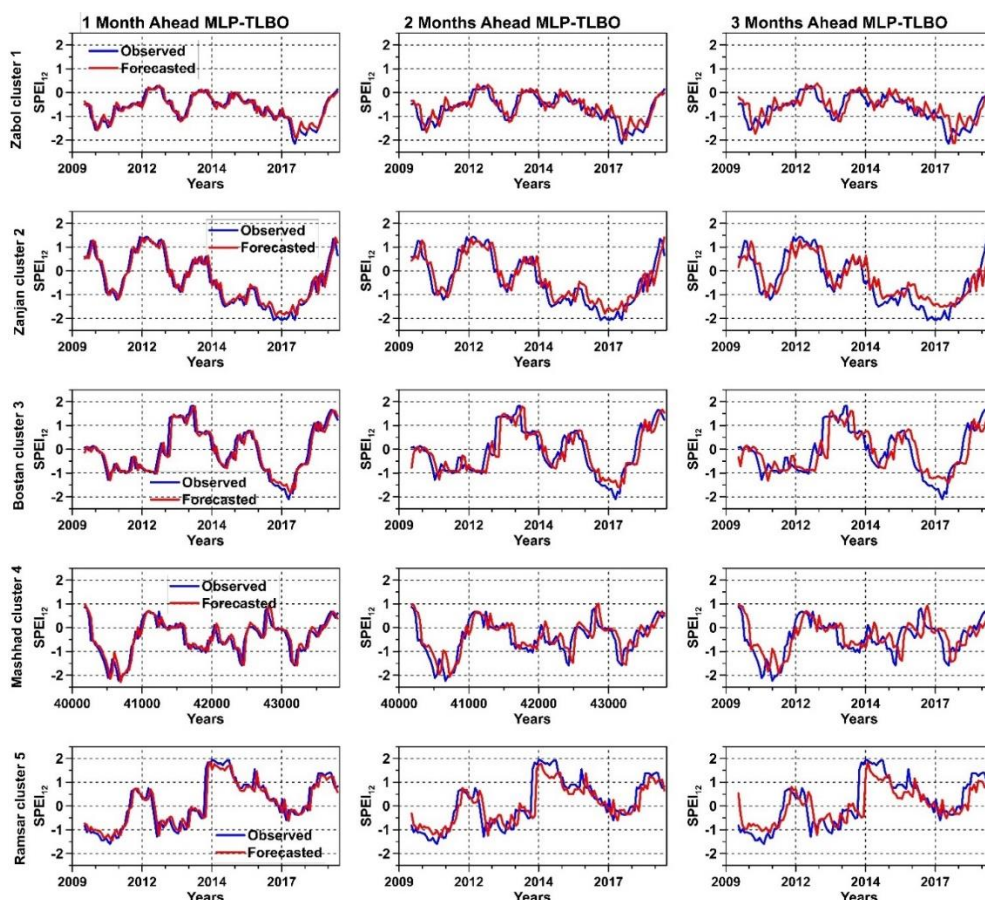


Figure 3. Time series of observed and forecasted values of SPEI₁₂ drought index at five clusters for MLP-TLBO model

نتایج پیش‌بینی الگوریتم LM دارای تغییرات زیادی می‌باشد و در پیش‌بینی یک ماه آینده در نقاط مرکزی ایران (خور و بیابانک، یزد و رفسنجان) عملکرد مناسبی نداشته است و مقدار RMSE بالاتر از یک بوده است. در ایستگاه‌های نهبندان (شرق ایران) و ماکو (شمال‌غرب) نیز نتایج مشابهی مشاهده می‌شود. این الگوریتم در مناطق جنوب شرق (سیستان و بلوچستان)، شمال شرق (خراسان رضوی) و استان‌های تهران و کردستان عملکرد مناسبی داشته است ($RMSE < 0.35$).

به منظور ارزیابی دقت الگوریتم‌های بهینه‌سازی وزن‌های شبکه عصبی مصنوعی در مکان‌های مختلف ایران اقدام به تهیه نقشه‌های میان‌یابی شده RMSE گردید. شکل (۴) مقادیر میان‌یابی شده RMSE را با استفاده از روش IDW در کل پهنه ایران نشان می‌دهد. نتایج هر چهار الگوریتم بهینه‌سازی در پیش‌بینی یک تا سه ماه آینده ارائه شده است. به طور مشخص در هر چهار الگوریتم با افزایش بازه پیش‌بینی از یک به سه ماه، دقت مدل‌ها کاهش یافته است. نتایج الگوریتم LM در ردیف اول نشان داده شده است. با توجه به شکل

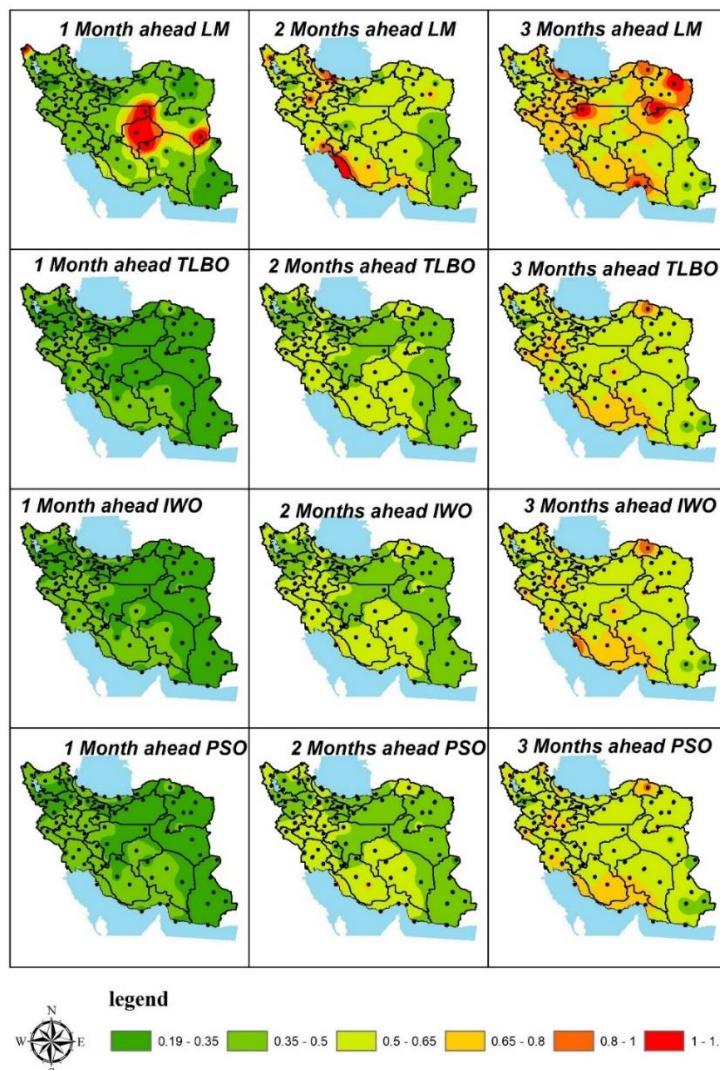


Figure 4. RMSE Interpolation maps for four models of LM, TLBO, IWO and PSO in 1 to 3 months ahead at Iran

ایشان گزارش نمودند که در استرالیا، پیش‌بینی خشک‌سالی در مناطق مرطوب نسبت به مناطق خشک دارای دقت بیشتری است. نتایج به‌دست‌آمده در این پژوهش حاضر با نتایج Park *et al.* (2016) مطابقت داشت. نتایج آن‌ها در پیش‌بینی خشک‌سالی نشان داده بود که دقت مدل‌های یادگیری ماشین در مناطق خشک آمریکا بیش‌تر از نقاط مرطوب است.

نتیجه‌گیری

خشک‌سالی پدیده‌ای است خزنده و زیان‌بار که پیش‌بینی صحیح آن می‌تواند در مدیریت منابع آب بسیار مفید باشد. هدف پژوهش حاضر پیش‌بینی شاخص خشک‌سالی SPEI₁₂ در ۷۹ ایستگاه سینوپتیک ایران که دارای بیش از ۳۰ سال اطلاعات هواشناسی (بازه ۱۹۸۷ الی ۲۰۱۹) هستند بود. ترکیب مدل شبکه عصبی مصنوعی با الگوریتم‌های فراابتکاری TLBO، IWO و PSO برای پیش‌بینی سری زمانی خشک‌سالی در مناطق ذکرشده با استفاده از روش K-means به پنج خوشه تقسیم شدند و پارامترهای آماری RMSE و R² برای خوشه‌ها به‌صورت جداگانه مورد ارزیابی قرار گرفتند. نتیجه این پژوهش نشان‌دهنده این موضوع است که در هر سه مدل پیش‌بینی با افزایش بازه زمانی پیش‌بینی، دقت مدل‌ها کاهش یافت. مقایسه بین سه الگوریتم بهینه‌سازی ذکرشده و الگوریتم لونیبرگ-مارکوات به‌عنوان یک الگوریتم بر کاربرد در بهینه‌سازی وزن‌های شبکه عصبی نشان‌دهنده برتری قابل‌توجه الگوریتم‌های بهینه‌سازی فراابتکاری است. مقایسه بین سه الگوریتم TLBO، IWO و PSO نشان داد که الگوریتم TLBO اندکی بهتر از سایر الگوریتم‌ها عمل می‌کند و نتایج دقیق‌تری را ارائه می‌کند. یک از مزایای مهم الگوریتم TLBO تعداد کم‌تر پارامترهای تنظیم است که موجب سرعت بیش‌تر در تعیین مدل بهینه می‌شود. مدل MLP آموزش‌یافته توسط الگوریتم لونیبرگ-مارکوات نسبت به سه

در پیش‌بینی دو ماه نیز در الگوریتم LM مقادیر RMSE تغییرات زیادی دارد و کم‌ترین مقادیر آن در سواحل خلیج فارس و استان گیلان و همدان مشاهده می‌شود. الگوریتم LM در مناطق شرقی و جنوب‌شرقی (استان‌های سیستان و بلوچستان و خراسان جنوبی) عملکرد بهتری ارائه کرده است. در سایر نقاط مقادیر RMSE بین ۰/۵ تا ۰/۸ تغییر می‌کند. در پیش‌بینی سه ماه بعد نیز نتایج ضعیف در سواحل خلیج فارس - مناطق شمال‌شرق و مرکزی مشاهده می‌شود و بهترین نتایج الگوریتم LM در مناطق جنوب‌شرق به‌دست آمده است. سه الگوریتم بهینه‌سازی هوشمند IWO، TLBO، PSO و نتایج به‌طور نسبی مشابهی را ارائه کرده‌اند. Kisi *et al.* (2019) و Aghelpour *et al.* (2021) نیز نشان دادند که ترکیب الگوریتم‌های PSO قابلیت بالاتری نسبت به سایر الگوریتم‌ها در پیش‌بینی خشک‌سالی دارند. هرچند که دو الگوریتم TLBO و IWO تا حدودی نسبت به PSO بهتر عمل کرده‌اند و در تمام مناطق مقدار (RMSE < ۰/۳۵) می‌باشد. ضعیف‌ترین عملکرد مدل‌ها در مناطق ساحل خلیج فارس، مناطق غرب و جنوب‌غرب و حاشیه شمال‌غربی کشور می‌باشد. نتایج در مناطق شمال‌شرق، شرق، جنوب‌شرق و مرکزی دقت بالایی دارند (RMSE < ۰/۳). در پیش‌بینی دو و سه ماه آینده نیز تقریباً هر سه الگوریتم هوشمند نتایج مشابهی داشته‌اند. در هر دو بازه پیش‌بینی در منطقه جنوب بیش‌ترین دقت به‌دست‌آمده است و سواحل خلیج فارس و مناطق جنوبی دارای دقت کم‌تری هستند.

در هر سه بازه پیش‌بینی، بیش‌ترین مقدار RMSE مربوط به خوشه (۵) (مناطق مرطوب ایران با بیش‌ترین بارش سالانه) می‌باشد. بیش‌ترین دقت و کم‌ترین مقادیر RMSE در خوشه (۱) که مناطق جنوب‌شرق ایران است، حادث شده است. این نقاط جزو مناطق کم‌بارش ایران هستند و مقدار تبخیر- تعرق پتانسیل در آن‌ها بالا می‌باشد. نتیجه به‌دست‌آمده متناقض با نتایج Feng *et al.* (2019) است.

6. Standardized Precipitation Index
7. Cuckoo Search
8. Standardized Precipitation Evapotranspiration Index
9. Genetic Algorithm
10. Ant Colony Optimization
11. Butterfly Optimization Algorithm
12. Gene Expression Programming
13. Models Tree
14. Standardized Streamflow Index
15. Bee Algorithm
16. Back Propagation
17. Teaching learning based optimization
18. Invasive Weed Optimization
19. Particle Swarm Optimization
20. Levenberg – Marquardt
21. Multilayer perceptron
22. Teaching Phase
23. learner Phase
24. Clustering
25. Autocorrelation Function
26. Partial Autocorrelation Function
27. Imperialist Competitive Algorithm
28. Firefly Algorithm

تعارض منافع

هیچ گونه تعارض منافع توسط نویسندگان وجود ندارد.

منابع

1. Abramowitz, M., & Stegun, I. (1965). *Handbook of mathematical functions: with formulas, graphs, and mathematical tables*, (9th ed.). New York, NY: Dover Publications.
2. Aghelpour, P., Bahrami-Pichaghchi, H., & Varshavian, V. (2021). Hydrological drought forecasting using multi-scalar streamflow drought index, stochastic models & machine learning approaches, in northern Iran. *Stochastic Environmental Research and Risk Assessment*, 1-21.
3. Aghelpour, P., Bahrami-Pichaghchi, H., & Kisi, O. (2020). Comparison of three different bio-inspired algorithms to improve ability of neuro fuzzy approach in prediction of agricultural drought, based on three different indexes. *Computers and Electronics in Agriculture*, 170(3), 1-12.
4. Alizadeh, M. J., Shabani, A., & Kavianpour, M. R. (2017). Predicting longitudinal dispersion coefficient using ANN with metaheuristic training algorithms. *International Journal of Environmental Science and Technology*, 14(11), 2399-2410.

مدل MLP آموزش یافته توسط الگوریتم‌های فراابتکاری، نتایج ضعیف‌تری را ارائه کرده است که می‌توان آن را به حساسیت مدل نسبت به تعداد نرون در لایه مخفی نسبت داد. نتیجه ذکر شده توسط پژوهش‌گران مختلف تأیید شده است. مدل‌های ذکر شده بهترین پیش‌بینی را (با توجه به مقادیر RMSE) در خوشه (۱) داشتند که بیش‌تر شامل مناطق جنوب‌شرقی ایران می‌باشد. در این مناطق حتی پیش‌بینی سه ماه آینده نیز نتایج خوبی را ارائه کرد. دلیل این موضوع را می‌توان وقوع خشک‌سالی در منطقه جنوب‌شرق در سال‌های اخیر و نوسانات کم‌تر شاخص خشک‌سالی بیان نمود. بیش‌ترین مقادیر RMSE و دقت کم‌تر مدل‌ها در خوشه (۵) مناطق شمالی ایران (سواحل دریای خزر) مشاهده شد. بنابراین توصیه می‌شود در استفاده از مدل‌های ذکر شده به‌ویژه در پیش‌بینی‌های دو و سه ماه آینده احتیاط بیش‌تری شود. دلیل دقت کم‌تر مدل‌ها در خوشه (۵) را می‌توان به تغییرات زیاد بارش در سال‌های متوالی و شیف‌ت ناگهانی شاخص از خشک‌سالی به ترسالی و بالعکس بیان نمود (ایستگاه رامسر در شکل ۳). هم‌چنین مناطق جنوبی کشور نیز نتایج ضعیف‌تری را نسبت به سایر نقاط ارائه کرده‌اند. در پایان پیشنهاد می‌شود در کلیه مناطق کشور ارتباط خشک‌سالی‌های هواشناسی با هیدرولوژیکی بررسی شود تا بهترین شاخص خشک‌سالی هواشناسی برای بررسی تأثیر آن بر منابع آب مشخص شود. هم‌چنین پیشنهاد می‌شود از سایر روش‌های هوشمند جدید نظیر الگوریتم‌های یادگیری تجمعی و یادگیری عمیق نیز جهت پیش‌بینی خشک‌سالی استفاده شود.

پی‌نوشت

1. Artificial Neural Networks
2. Streamflow Drought Index
3. Group Method of Data Handling
4. Adaptive-Network-based Fuzzy Inference Systems
5. Support vector machines

5. Beguería, S., Vicente-Serrano, S. M., Reig, F., & Latorre, B. (2014). Standardized precipitation evapotranspiration index (SPEI) revisited. parameter fitting, evapotranspiration models, tools, datasets and drought monitoring. *International Journal of Climatology*, 34(10), 3001-3023.
6. Caliński, T., & Harabasz, J. (1974) A dendrite method for cluster analysis. *Communications in Statistics-theory and Methods*, 3(1), 1-27.
7. Chen, X., Chau, K. & Busari, A. (2015). A comparative study of population based optimization algorithms for downstream river flow forecasting by a hybrid neural network model. *Engineering Applications of Artificial Intelligence*, 46(2), 258-268.
8. Cheng, C.T., Wang W.C., Xu D.M., & Chau, K. (2008). Optimizing hydropower reservoir operation using hybrid genetic algorithm and chaos. *Water Resources Management*, 22(7), 895-909.
9. Cheraghalizadeh, M., Nazi-Ghameshloo, A., & Bazrafshan, J. (2018). Integrated monitoring of hydro-meteorological droughts in kasilian's basin (Mazandaran Province). *Journal of the Earth and Space Physics*, 44(2), 463-477. (In Persian)
10. Dang, N. M., Anh, D. T., & Dang, T. D. (2019). ANN optimized by PSO and Firefly algorithms for predicting scour depths around bridge piers. *Engineering with Computers*, 37, 293-303.
11. Davarpanah, G., (2002). The investigation of the most important economic and drought and government assistance methods in reducing these effects. *Firist National Confrence on Water Crisis*, 9 March, Zabol University, Zabol, Iran, 1-23. (In Persian).
12. Droogers, P., & Allen, R. G. (2002). Estimating reference evapotranspiration under inaccurate data conditions. *Irrigation and Drainage Systems*, 16(1), 33-45.
13. Dugenci, M., Aydemir, A., Esen, I., & Aydın, M.E. (2015). Creep modelling of polypropylenes using artificial neural networks trained with Bee algorithms. *Engineering Applications of Artificial Intelligence*, 45, 71-79.
14. Edwards, D.C., & McKee, T.B. (1997). Characteristics of 20th century drought in the United States at multiple time scales. *Atmospheric Science Paper*, 634, 1-30.
15. Eroğluer, T.A., & Apaydin, H. (2020). Estimation of drought by streamflow drought index (sdi) and artificial neural networks (anns) in ankara-nallihan region. *Turkish Journal of Agriculture-Food Science and Technology*, 8(2), 348-357.
16. Farris, J. S. (1969). On the copenetic correlation coefficient. *Systematic Zoology*, 18(3), 279-285.
17. Feng, P., Wang, B., Li Liu, D., & Yu, Q. (2019). Machine learning-based integration of remotely-sensed drought factors can improve the estimation of agricultural drought in South-Eastern Australia. *Agricultural Systems*, 173, 303-316.
18. Gao, W., Karbasi, M., Derakhsh, A. M., & Jalili, A. (2019). Development of a novel soft-computing framework for the simulation aims. a case study. *Engineering with Computers*, 35(1), 315-322.
19. Ghamghami, M., & Bazrafshan, J. (2012). Prediction of meteorological drought conditions in Iran using Markov chain model. *Journal of Soil and Water Resources Conservation*, 1(3), 1-12. (In Persian)
20. Govindaraju, R. S. (2013). Special issue on data-driven approaches to droughts. *Journal of Hydrologic Engineering*, 18, 735-736.
21. Hartigan, J. A. (1975). *Clustering algorithms*, New York: John Wiley & Sons, Inc.
22. Hosseini-Moghari, S. M., & Araghinejad, S. (2015). Monthly and seasonal drought forecasting using statistical neural networks. *Environmental Earth Sciences*, 74(1), 397-412.
23. Kayarvizhy, N., Kanmani, S., & Uthariaraj, R. (2013). Improving fault prediction using ANN-PSO in object oriented systems. *International Journal of Computer Applications*, 73, 18-25.
24. Kennedy, J., & Eberhart, R.C. (1995). Particle swarm optimization. *In Proceedings of the 1995 IEEE International Conference on Neural Networks*. Perth, Australia. *IEEE Service Center. Piscataway*, 4, 1942-1948.
25. Keyantash, J. A., & Dracup, J. A. (2004). An aggregate drought index. Assessing drought severity based on fluctuations in the hydrologic cycle and surface water storage. *Water Resources Research*, 40(9), 1-13.
26. Kisi, O., Gorgij, A. D., Zounemat-Kermani, M., Mahdavi-Meymand, A., & Kim, S. (2019). Drought forecasting using novel heuristic methods in a semi-arid environment. *Journal of Hydrology*, 578(11), 1-11.
27. Komasi, M., Sharghi, S., & Safavi, H. R. (2018). Wavelet & cuckoo search-support vector machine conjugation for drought forecasting using Standardized Precipitation

- Index (case study: Urmia Lake, Iran). *Journal of Hydroinformatics*, 20(4), 975-988
28. Kousari, M. R., Hosseini, M. E., Ahani, H., & Hakimelahi, H. (2017). Introducing an operational method to forecast long-term regional drought based on the application of artificial intelligence capabilities. *Theoretical and applied climatology*, 127(1-2), 361-380.
 29. Mehdizadeh, S., Ahmadi, F., Mehr, A. D., & Safari, M. J. S. (2020). Drought modeling using classic time series and hybrid wavelet-gene expression programming models. *Journal of Hydrology*, 587(8), 1-17.
 30. Mehrabian, A. R., & Lucas, C. (2006). A novel numerical optimization algorithm inspired from weed colonization. *Ecological Informatics*, 1(4), 355-366.
 31. Mirakbari, M., Mortezaie, F. G., & Mohseni, S. M. (2018). Investigation of the effect of meteorological drought on surface and ground water resources by Indices SPI, SPEI, SDI and GRI. *Iranian Journal of Watershed Management Science and Engineering*, 12(42), 70-80. (In Persian)
 32. Mucherino, A., Papajorgji, P. J., & Pardalos, P. M. (2009). K-nearest neighbor classification. In *Data mining in agriculture*. New York, USA, 83-106.
 33. Nabipour, N., Dehghani, M., Mosavi, A., & 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.
 34. Park, S., Im, J., Jang, E., & Rhee, J. (2016). Drought assessment and monitoring through blending of multi-sensor indices using machine learning approaches for different climate regions. *Agricultural and Forest Meteorology*, 216, 157-169.
 35. Rao, R. V., Savsani, V. J., & Vakharia, D. P. (2012). Teaching-learning-based optimization an optimization method for continuous non-linear large scale problems. *Information Sciences*, 183(1), 1-15.
 36. Rao, R. V., Savsani, V. J., & Vakharia, D. P. (2011). Teaching-learning-based optimization. A novel method for constrained mechanical design optimization problems. *Computer-Aided Design*, 43(3), 303-315.
 37. Shafiei, M., Ghahraman, B., Ansari, H., & Sharifi, M. (2011). Stochastic simulation of drought severity based on palmer index. *Water and Irrigation Management*, 1(1), 1-13. (In Persian)
 38. Shamshirband, S., Hashemi, S., Salimi, H., Samadianfard, S., Asadi, E., Shadkani, S., & Chau, K.W. (2020). Predicting standardized streamflow index for hydrological drought using machine learning models. *Engineering Applications of Computational Fluid Mechanics*, 14(1), 339-350.
 39. Satapathy, S. C., Naik, A., & Parvathi, K. (2012, December). Teaching learning based optimization for neural networks learning enhancement. In: *International Conference on Swarm, Evolutionary, and Memetic Computing*. Berlin, Heidelberg, Germany, 761-769.
 40. Sheffield, J., & Wood, E. F. (2011). *Drought. past problems and future scenarios*. Routledge.
 41. Toğan, V. (2012). Design of planar steel frames using teaching-learning based optimization. *Engineering Structures*, 34, 225-232.
 42. Vicente-Serrano, S. M., Beguería, S., & López-Moreno, J. I. (2010). A multiscalar drought index sensitive to global warming. the standardized precipitation evapotranspiration index. *Journal of Climate*, 23(7), 1696-1718.