

Introducing a Nonlinear Model Based on Hybrid Machine Learning for Modeling and Prediction of Precipitation and Comparison with SDSM Method (Cases Studies: Shahrekord, Barez, and Yasuj)

MAHDI VALIKHAN ANARAKI¹, SAYED-FARHAD MOUSAVI¹, SAEED FARZIN^{1*}, HOJAT KARAMI¹

1. Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan University, Semnan, Iran.

(Received: July. 17, 2019- Revised: Aug. 25, 2019- Accepted: Sep. 16, 2019)

ABSTRACT

In the present study, a nonlinear hybrid model, based on multivariate adaptive regression splines (MARS), artificial neural networks (ANN) and K-nearest neighbor (KNN) has been presented for downscaling the precipitation of Shahrekord, Barez, and Yasuj under climate change conditions. This model, similar to SDSM, is composed of two steps; classification and regression. The MARS model is employed for classification of precipitation occurrence and the ANN and KNN are employed for determination of the amount of precipitation. The results of MARS showed that the mentioned model is more accurate than the SDSM model. Comparing the results of downscaled precipitation showed that the ANN model is more accurate than the SDSM and KNN in prediction of average annual and monthly precipitation. So that the R value for ANN was 54% more than the one in SDSM model, in Shahrekord. Also, according to the highest accuracy, standard deviation and skewness coefficient, the ANN, KNN and SDSM model ranked first, second, and third, respectively, for prediction of monthly average precipitation in three investigated stations. Eventually, the precipitation changes in the near future (2020-2040) and far future (2070-2100) periods were investigated under the A2 and B2 scenarios of the HADCM3 model. Results revealed that the lowest precipitation reduction is corresponded to ANN (in Shahrekord) and A2 scenario in the near future period and the highest precipitation reduction is corresponded to SDSM (in Yasuj) and A2 scenario in the far future period. Finally, it can be concluded that the proposed model is more accurate than the SDSM model and can be used as an alternative to the SDSM model.

Keywords: Climate change, Downscaling, Machine learning, Precipitation

معرفی یک مدل غیرخطی بر اساس هیبرید ماشین‌های یادگیری به منظور مدل‌سازی و پیش‌بینی بارش و مقایسه با روش SDSM (مطالعات موردی: شهرکرد، بارز و یاسوج)

مهدی ولیخان انارکی^۱، سید فرهاد موسوی^۱، سعید فرزین^{۱*}، حجت کرمی^۱

۱. گروه مهندسی آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه سمنان، سمنان، ایران

(تاریخ دریافت: ۱۳۹۸/۴/۲۶ - تاریخ بازنگری: ۱۳۹۸/۶/۳ - تاریخ تصویب: ۱۳۹۸/۶/۲۵)

چکیده

در پژوهش حاضر، مدلی هیبریدی بر مبنای روش‌های غیرخطی شامل رگرسیون تطبیقی چندگانه اسپلاین (MARS)، شبکه‌عصبی مصنوعی (ANN) و K نزدیکترین همسایه (KNN) به منظور ریزمقیاس‌نمایی و پیش‌بینی بارش ایستگاه‌های شهرکرد، بارز و یاسوج تحت شرایط تغییر اقلیم معرفی شده است. مدل هیبریدی ارائه شده، مانند مدل ریزمقیاس‌نمایی SDSM، از دو گام طبقه‌بندی و رگرسیون تشکیل شده است. مدل MARS برای طبقه‌بندی وقوع بارش و الگوریتم‌های ANN و KNN برای تعیین مقدار بارش به کار برده شده‌اند. نتایج مدل MARS برای تعیین وقوع بارش نشان می‌دهد که مدل مذکور نسبت به مدل SDSM از دقت بیش‌تری برخوردار است. با مقایسه نتایج ریزمقیاس‌نمایی مشاهده می‌شود که الگوریتم ANN نسبت به مدل SDSM و الگوریتم KNN دارای دقت بیش‌تری در تعیین میانگین سالانه و ماهانه بارش است. به طوری که در ایستگاه شهرکرد مقدار معیار R برای الگوریتم ANN نسبت به مدل SDSM به اندازه ۵۴ درصد دقیق‌تر است. همچنین، الگوریتم‌های ANN، KNN و SDSM از نظر بیش‌ترین دقت در سه ایستگاه بررسی شده، با در نظر گرفتن میانگین، انحراف معیار و ضریب چولگی ماهانه به ترتیب در رتبه‌های اول، دوم و سوم قرار داده می‌شوند. در نهایت، مقدار تغییرات بارش در دوره آینده نزدیک (۲۰۲۰-۲۰۴۰) و آینده دور (۲۰۷۰-۲۱۰۰) تحت سناریوهای A2 و B2 مدل HADCM3 بررسی شد. نتایج نشان داد که کم‌ترین کاهش بارش (۲ درصد) مربوط به الگوریتم ANN (در ایستگاه شهرکرد) و سناریوی A2 در دوره آینده نزدیک و بیش‌ترین آن (۵۴ درصد) مربوط به مدل SDSM (در ایستگاه یاسوج) و سناریوی A2 در دوره آینده دور می‌باشد. در نهایت می‌توان نتیجه گرفت که هیبرید ماشین‌های یادگیری نسبت به مدل SDSM، از دقت بیشتری برخوردار است و می‌توان از مدل معرفی شده به عنوان جایگزین مدل SDSM استفاده کرد.

واژه‌های کلیدی: تغییر اقلیم، ریزمقیاس‌نمایی، ماشین‌های یادگیری، بارش.

مقدمه

در دهه‌های اخیر، بررسی اثر تغییر اقلیم بر متغیرهای هیدرولوژیک به یکی از مهم‌ترین بحث‌های مدیریت منابع آب تبدیل شده است. یکی از روش‌های متداول برای بررسی اثر تغییر اقلیم بر متغیرهای هیدرولوژیک مانند بارش، استفاده از مدل‌های گردش عمومی جو (GCMs) است. اما، این مدل‌ها بزرگ مقیاس (تا صدها هزار کیلومتر مربع) می‌باشند و باید با استفاده از تکنیک‌های ریزمقیاس‌نمایی کوچک‌مقیاس شوند. ریزمقیاس‌نمایی به فرآیندی اطلاق می‌شود که طی آن متغیرهای بزرگ‌مقیاس مدل‌های گردش عمومی جو از مقیاس‌های جهانی به مقیاس‌های محلی تبدیل می‌شوند (Khashei *et al.*, 2018). به منظور ریزمقیاس‌نمایی، چهار روش، شامل روش‌های آماری، الگوهای آب و هوایی، احتمالاتی و روش دینامیک

ارائه شده است که در این میان روش‌های آماری به دلیل تعداد کم‌تر پارامترها و هزینه محاسباتی کم‌تر، از کاربرد بیش‌تری در مطالعات منابع آب برخوردارند (Salajegheh *et al.*, 2018).

در دهه‌های گذشته، مطالعات چندی برای ریزمقیاس‌نمایی مدل‌های گردش عمومی جو با استفاده از روش‌های آماری صورت گرفته است. (2002) Wilby *et al.* نرم‌افزار SDSM را که از یک روش رگرسیون خطی چندمتغیره استفاده می‌کند، برای ریزمقیاس‌نمایی مدل‌های گردش عمومی جو ارائه دادند. در پژوهش (2005) Harpham and Wilby ثابت شد که نرم‌افزار SDSM در مقایسه با روش شبکه‌های عصبی شعاعی و شبکه‌های عصبی پرسپترون چندلایه، بارش روزانه را با دقت بیش‌تری ریزمقیاس می‌کند.

ابزارهای بررسی اثر تغییر اقلیم به شمار می‌روند که در این میان مدل HadCM3 و سناریوهای مربوط به آن از کاربرد فراوانی برخوردار بوده است. این مدل در مطالعات بسیاری همچون Beheshti, LARS-WG (2019) Sayedi *et al.* با استفاده از مدل Mesbahzadeh *et al.*, 2019 و *et al.* 2019 با استفاده از مدل SDSM و Moghadam *et al.* 2019 با استفاده از ترکیب روش‌های K نزدیک‌ترین همسایه و مونت کارلو، جهت ریزمقیاس‌نمایی بارش و دما به کار برده شده است.

با توجه به مطالعات داخلی و خارجی، تا کنون مطالعات چندی در زمینه استفاده از ماشین‌های یادگیری در زمینه ریز-مقیاس‌نمایی و پیش‌بینی بارش تحت شرایط تغییر اقلیم انجام شده است. اما در اکثر این مطالعات، توجهی به تعیین وقوع بارش نشده است. مدل SDSM نیز با وجود ریزمقیاس‌نمایی بارش در دو گام تعیین وقوع و مقدار بارش، تنها توانایی در نظر گرفتن روابط خطی را دارد. لذا در پژوهش حاضر با استفاده از هیبرید ماشین‌های یادگیری غیرخطی بر اساس رویکرد مدل SDSM به بررسی جامع ریزمقیاس‌نمایی و پیش‌بینی بارش تحت شرایط تغییر اقلیم پرداخته می‌شود. در روش هیبریدی ارائه شده، الگوریتم MARS به دلیل توانایی بالا در حل مسائل غیرخطی، با استفاده از تقسیم فضای ورودی و تشکیل روابط رگرسیونی برای هر بخش، جهت تعیین وقوع بارش استفاده می‌شود. همچنین از آن‌جا که هر الگوریتم در مناطق و شرایط مختلف جواب‌های متفاوتی می‌دهد، از دو الگوریتم KNN و ANN برای تعیین مقدار بارش به کار برده می‌شوند. الگوریتم KNN با در نظر گرفتن شباهت بین ورودی‌ها و الگوریتم ANN با پردازش اطلاعات در چندین لایه توانایی زیادی در حل مسائل غیر خطی دارند. پس از ریزمقیاس‌نمایی بارش، مقدار بارش با استفاده از خروجی‌های مدل HadCM3 تحت دو سناریوی A2 و B2 برای افق نزدیک (۲۰۴۰-۲۰۲۰) و افق دور (۲۱۰۰-۲۰۷۰) پیش‌بینی می‌شود.

مواد و روش‌ها

مطالعات موردی

در پژوهش حاضر، به منظور ریزمقیاس‌نمایی بارش، اطلاعات بارش ایستگاه شهرکرد، بارز و یاسوج به عنوان داده‌های مشاهداتی از سازمان هواشناسی دریافت و سپس مورد بررسی قرار گرفتند. ایستگاه‌های شهرکرد، بارز و یاسوج به ترتیب در ارتفاع ۲۰۴۸، ۹۸۰ و ۱۸۱۶/۳ متری از سطح دریا قرار گرفته‌اند. دلیل انتخاب

در سال‌های اخیر نیز ماشین‌های یادگیری مانند شبکه‌های عصبی مصنوعی^۱ (ANN) و K نزدیک‌ترین همسایه^۲ (KNN) دارای کاربردی موفق در ریزمقیاس‌نمایی مدل‌های گردش عمومی جو بوده‌اند. Devak *et al.* (2015) برای ریزمقیاس‌نمایی بارش، عملکرد سه روش KNN، ماشین‌بردار پشتیبان و روش هیبریدی ماشین‌بردار پشتیبان^۳ (SVM) و KNN را ارزیابی کردند که برتری روش هیبریدی مذکور در تعیین میانگین سالانه و انحراف معیار بارش نشان داده شد. در پژوهش (Nourani *et al.* 2018) از الگوریتم‌های ماشین‌بردار پشتیبان حداقل مربعات، ANN و رگرسیون خطی چندمتغیره برای ریزمقیاس‌نمایی بارش استفاده شده که روش ANN دارای دقت بیشتری بود. Haji Hosseini *et al.* (2018) الگوریتم‌های ANN، KNN و عصبی-فازی^۴ (ANFIS) را برای ریزمقیاس‌نمایی پارامترهای بارش به کار بردند. نتایج، حاکی از عملکرد مطلوب هر سه روش بود اما، الگوریتم KNN نسبت به دو الگوریتم دیگر برتر بود. در پژوهش Chaudhary *et al.*, 2019 از ترکیب الگوریتم ANN و روش کاهش ابعاد^۵ (PCA) جهت ریزمقیاس‌نمایی بارش رودخانه‌ای در هندوستان استفاده شد. نتایج نشان‌گر دقت خوب روش ریزمقیاس‌نمایی مذکور بارش بود. (Nourani *et al.* 2019) از الگوریتم ANN برای ریزمقیاس‌نمایی بارش و دمای میانگین ایستگاه سینوپتیک تبریز و از الگوریتم درخت تصمیم برای انتخاب پیش‌بینی‌کننده‌ها استفاده کردند که عملکرد قابل قبول روش مذکور گزارش شد. همچنین نتایج ریزمقیاس‌نمایی نشان داد که مقدار بارش و دمای میانگین، تحت سناریو B1 مدل CGCM3 افزایش می‌یابد.

Ghamghami *et al.* (2010) با استفاده از روش‌های LARS-WG و KNN به ریزمقیاس‌نمایی داده‌های هواشناسی پرداختند که اختلاف عملکرد هر دو روش ناچیز بود. Ashofteh and Bozorg-Haddad, (2013) خروجی‌های مدل HadCM3 را برای بررسی اثر تغییر اقلیم بر منابع آب به کار بردند. Salajegheh *et al.* (2018) از دو روش LARS-WG و SDSM برای ریز-مقیاس‌نمایی دما و بارش کرمانشاه و روانسر استفاده کردند. نتایج نشان‌دهنده برتری مدل SDSM در ریزمقیاس‌نمایی دما و برتری مدل LARS-WG در ریزمقیاس‌نمایی بارش بود. Khashei *et al.* 2018 نیز با استفاده از روش‌های ANN و SVM به ریزمقیاس-نمایی بارش روزانه پرداختند که نتایج حاکی از برتری SVM بود. همانطور که گفته شد مدل‌های گردش عمومی از مهم‌ترین

4. Adaptive neuro fuzzy inference system
5. principal component regression

1. Artificial neural network
2. K nearest neighbor
3. Support vector machine

این ایستگاه‌ها، قرار گرفتن آن‌ها در بالادست حوضه کارون ۳ و سد کارون ۳ می‌باشد (شکل ۱). داده‌های بزرگ‌مقیاس مدل HadCM3 و پایگاه داده‌های NCEP از سایت تغییر اقلیم کانادا (<http://www.cccsn.ec.gc.ca>) دریافت گردیده و به عنوان پیش‌بینی کننده استفاده شده‌اند. از داده‌های پایگاه داده‌ها به منظور ایجاد مدل ریزمقیاس‌نمایی و از داده‌های مدل HadCM3 تحت سناریوهای A2 و B2 برای بررسی تغییر اقلیم در دوره آینده استفاده شده است. هر یک از سناریوهای تغییر اقلیم بر مبنای فرضیات مختلفی مانند رشد جمعیت، فناوری و اقتصاد ایجاد شده‌اند. سناریو A2 با فرض جهانی متفاوت با تأکید بر رسوم خانوادگی و ارزش‌های خانواده در نظر گرفته می‌شود. در این سناریو رشد اقتصاد متغیر و پیشرفت فناوری آهسته است. اما در سناریو B2 تمرکز بر راه‌حل‌های منطقه‌ای برای حل مشکلات اقتصادی، سیاسی و محیط زیست و تساوی حقوق بین جوامع می‌باشد. نرخ رشد جمعیت در این سناریو کمتر از سناریو A2 است توسعه اقتصاد در جهان متوسط است. در پژوهش حاضر، دوره پایه با بیش‌ترین تعداد داده از سال ۱۹۷۲ تا ۲۰۰۱ در نظر گرفته شده است که ۷۰ درصد آن دوره برای آموزش و ۳۰ درصد آن برای آزمون اختصاص یافت. این طول دوره آماری بر اساس پیشنهاد هیأت بین‌الدول IPCC در گزارشات (IPCC-TGCI, 2007) در نظر گرفته شده است. در نظر گرفته شده است. در اکثر مطالعات، دوره‌های ۲۰ یا ۳۰ ساله برای بررسی اثر تغییر اقلیم در نظر گرفته می‌شود. لذا دوره آینده نزدیک ۲۰۲۰ تا ۲۰۴۰ جهت برنامه‌ریزی‌های کوتاه‌مدت و دوره آینده دور ۲۰۷۰ تا ۲۱۰۰ نیز جهت برنامه‌ریزی‌های بلندمدت تحت شرایط تغییر اقلیم انتخاب شده‌اند.

مدل هیبریدی برای ریزمقیاس‌نمایی و پیش‌بینی بارش روش پیشنهادی برای ریزمقیاس‌نمایی بارش در پژوهش حاضر از شش گام اساسی تشکیل شده است. لازم به ذکر است که در روش پیشنهادی نخست وقوع بارش و سپس مقدار بارش تعیین می‌شود:

۱- پیش‌بینی‌کننده‌های بزرگ‌مقیاس با بیش‌ترین ضریب همبستگی با داده‌های مشاهداتی بارش انتخاب می‌شوند. هم-چنین، داده‌ها به دو گروه آموزش (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم‌بندی می‌شوند (Ahmed *et al.*, 2019; Al-Mukhtar and Qasim, 2019).

۲- برای ریزمقیاس‌نمایی بارش، روزهای هر ماه با استفاده از الگوریتم MARS به دو گروه تر و خشک طبقه‌بندی می‌شوند. به این منظور، برای روزهای بارانی عدد ۱ و برای روزهای خشک عدد صفر در نظر گرفته می‌شود. سپس بر اساس ورودی‌ها و مقادیر صفر و یک، مدل آموزش داده و سپس آزمون می‌شود. صورتی که خروجی مدل بزرگ‌تر از یک مقدار مشخص (در اینجا ۰/۴ میلی‌متر) بود، آن روز بارانی است (Hessami *et al.*, 2008).

۳- با استفاده از پارامترهای تعیین شده در گام دوم، مقدار بارش برای روزهای بارانی توسط الگوریتم‌های ANN و KNN تخمین زده می‌شود.

۴- بر اساس معیارهای ارزیابی (روابط ۹-۱۳) عملکرد مدل ارزیابی می‌شود.

۵- بارش برای دوره آینده (۲۰۲۰-۲۰۴۰ و ۲۰۷۰-۲۱۰۰) تحت سناریوهای تغییر اقلیم (سناریو A2 و B2) پیش‌بینی می‌شود.

۶- میانگین اختلاف بارش مدل شده و مشاهداتی (b) در دوره آموزش به مقدار بارش پیش‌بینی شده در روزهای بارانی اضافه می‌گردد.

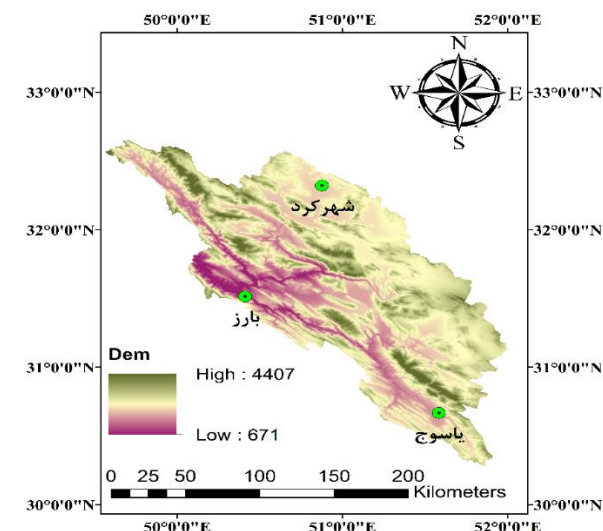
۷- به مقدار بارش روزهای بارانی هر روز یک عدد تصادفی با میانگین صفر و انحراف معیار برابر با SD اضافه می‌شود.

روابط (۱) و (۲) به ترتیب طریقه محاسبه b و SD را نشان می‌دهند:

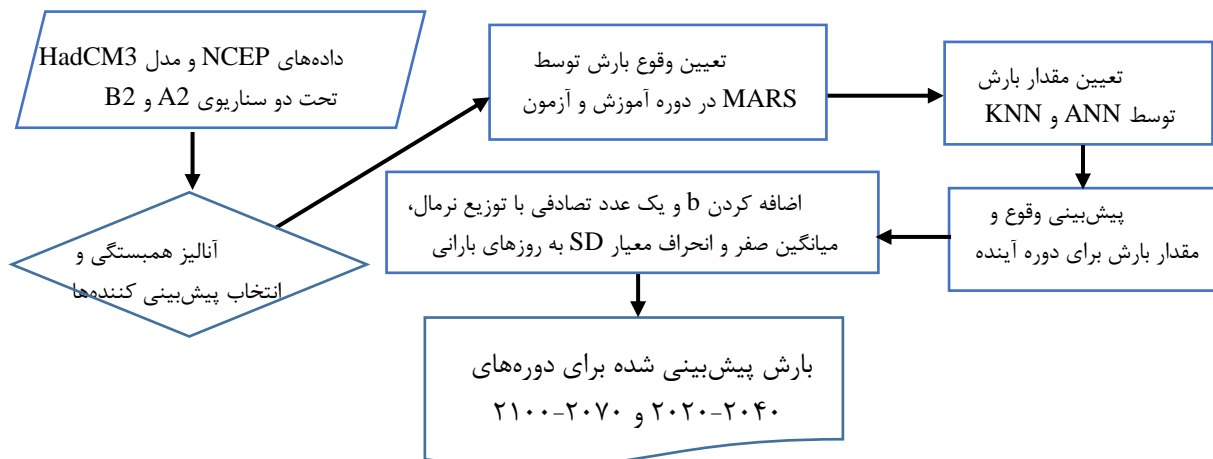
$$b = mean_{obs} - mean_{mod} \quad (1) \text{ رابطه } (1)$$

$$SD = \sqrt{Var_{obs} - Var_{mod}} \quad (2) \text{ رابطه } (2)$$

گام‌های ۵ و ۶ بیان شده مطابق با پژوهش Hessami *et al.* (2008) به منظور اصلاح خطای مدل‌سازی در نظر گرفته شده‌اند. شکل (۲)، مراحل ریزمقیاس‌نمایی و پیش‌بینی بارش با استفاده از مدل‌های پیشنهادی را نشان می‌دهد.



شکل ۱. موقعیت ایستگاه سینوپتیک شهرکرد در حوضه کارون ۳



شکل ۲. روش ریزمقیاس‌نمایی بارش با استفاده از هیبرید ماشین‌های یادگیری

می‌زند.

این الگوریتم به جستجو و انتخاب K تا از شبیه‌ترین بردار-های ویژگی با داده‌های مشاهداتی می‌پردازد. این شباهت بر مبنای فاصله اقلیدوسی و با استفاده از رابطه (۳) محاسبه می‌شود (Araghinejad, 2014).

$$D_n = \sqrt{\sum_{i=1}^d w_i (X_{ir} - X_{it})^2} \quad (\text{رابطه ۳})$$

که X_r مقدار پیش‌بینی‌کننده‌ها برای داده‌های مشاهداتی، X_t مقدار پیش‌بینی‌کننده‌ها برای داده‌های پیش‌بینی شونده، d تعداد پیش‌بینی‌کننده‌ها، D_n فاصله اقلیدوسی بین بردارهای X_r و X_t و نیز مقدار وزن مربوط به هر یک از پیش‌بینی‌کننده‌ها با مجموع ۱ می‌باشد.

پس از محاسبه فاصله اقلیدوسی، فرمول تابع کرنل R برای تخمین خروجی‌های مدل، به شکل رابطه (۴) استفاده می‌شود (Araghinejad, 2014).

$$R(D_n) = \frac{1/D_n}{\sum_{j=1}^K D_{nj}} \quad (\text{رابطه ۴})$$

که K تعداد داده‌های مشاهداتی با کم‌ترین فاصله با داده‌های پیش‌بینی شونده است.

در ادامه، برای پیش‌بینی خروجی‌ها از رابطه (۵) استفاده می‌شود (Modaresi et al., 2018):

$$Y_r = \sum_{i=1}^n R(D_{rj}) * Y_j \quad (\text{رابطه ۵})$$

مدل MARS

روش رگرسیون تطبیقی چندگانه اسپلاین (MARS^۱) یک روش

شبکه عصبی مصنوعی

الگوریتم شبکه عصبی مصنوعی یک سیستم پردازش اطلاعات است که با تقلید از انتقال اطلاعات نرون‌های سیستم‌های بیولوژیک عمل می‌کند (Lee et al., 2008). این الگوریتم از یک لایه ورودی، یک یا چندین لایه پنهان و یک لایه خروجی تشکیل شده است. در این الگوریتم، هر لایه نیز از تعدادی نرون تشکیل شده است. در الگوریتم شبکه‌های عصبی مصنوعی هر لینک ارتباطی بین نرون‌ها دارای یک وزن است. هر نرون نیز با جمع مقدار حاصل ضرب ورودی‌ها در وزن لینک مربوط و عبور آن از یک تابع انتقالی، یک خروجی می‌دهد. این خروجی به عنوان ورودی نرون‌های لایه بعدی استفاده می‌شود. با تنظیم لینک‌های ارتباطی در این فرآیند، نزدیکترین خروجی به خروجی مشاهداتی تعیین می‌شود (Singh et al., 2010). در پژوهش حاضر، از پرسپترون چندلایه به عنوان ساختار شبکه‌های عصبی مصنوعی استفاده شده است (Ahmadi et al., 2014). روش لونیبرگ-مارکوارت نیز به عنوان روش آموزش مورد استفاده قرار گرفته است (Hadi and Tombul, 2018). شکل (۲)، فلوچارت ساختار شبکه‌های عصبی مصنوعی را نشان می‌دهد. همچنین، یک شبکه سه لایه با ۵ نرون در لایه پنهان، ۱۴ نرون در لایه ورودی (پیش-بینی‌کننده‌ها) و یک نرون در لایه خروجی (بارش ریزمقیاس شده) برای ریزمقیاس‌نمایی بارش به کار برده شده است. تعداد نرون‌های لایه مخفی با استفاده از روش سعی و خطا تعیین شده است.

الگوریتم K نزدیکترین همسایه (KNN)

الگوریتم جستجوی نزدیکترین همسایه (KNN) یک روش رگرسیون ناپارامتری است. این روش بدون هیچ فرضی در مورد رابطه‌ی بین ورودی‌ها و خروجی‌ها، مقدار خروجی‌ها را تخمین

توسط رابطه (۶) محاسبه می‌شود:

$$Y = \sum_{i=1}^n \beta_i BF_i(x) \quad (\text{رابطه ۶})$$


که β_i ، BF_i و n به ترتیب توابع پایه i ام، وزن مربوط به تابع پایه i ام و تعداد توابع پایه می‌باشند. همچنین، مقدار توابع پایه از روابط زیر محاسبه می‌شود:

$$BF_i = \max(0, x - c_i) \quad (\text{رابطه ۷})$$


$$BF_i = \max(0, c_i - x) \quad (\text{رابطه ۸})$$

در این روابط، c_i بیانگر گره تابع پایه i ام یا knot است. شکل (۳) ساختار الگوریتم KNN و مدل MARS را نیز نشان می‌دهد.

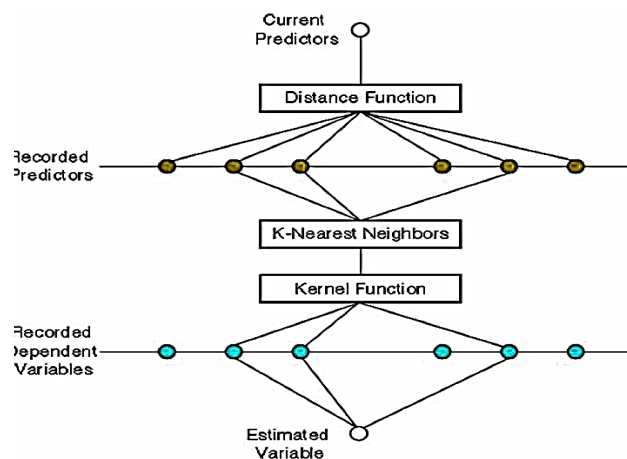
رگرسیون غیر پارامتریک است که اولین بار توسط Friedman (1991) معرفی شد. این الگوریتم، دارای توانایی بیان روابط غیرخطی و پیچیده بین ورودی‌ها و خروجی‌ها می‌باشد. الگوریتم MARS با استفاده از استراتژی تقسیم و حل، ورودی‌ها در دوره آموزش را تقسیم‌بندی می‌کند و برای هر قسمت یک رابطه رگرسیونی پله‌ای تشکیل می‌دهد (Rezaie-Balf *et al.*, 2017). همچنین، الگوریتم در دو گام پیشرو و پسرو، رابطه‌ی بین ورودی‌ها و خروجی‌ها را تخمین می‌زند. در فاز پیشرو، یک مدل با تعداد زیادی رابطه تشکیل شده و در فاز پسرو، روابط اضافی حذف می‌شوند. فاز پسرو باعث افزایش دقت مدل و جلوگیری از بیش‌برازش می‌شود. در الگوریتم MARS، مقدار متغیر Y بر اساس ورودی x



(الف)



(ج)



(ب)

شکل ۳. ساختار الگوریتم‌های بررسی شده: الف) شبکه‌های عصبی مصنوعی (ANN)، ب) K نزدیکترین همسایه (KNN) و ج) مدل MARS

ضریب همبستگی (R) برای ارزیابی نتایج حاصل از ریزمقیاس - نمایی بارش توسط روش‌های بررسی شده، به کار گرفته شده‌اند (Chen *et al.*, 2010; Ashofteh and Bozorg-Haddad, 2013)

معیارهای ارزیابی دقت مدل‌سازی

در پژوهش حاضر، معیارهای درصد خطا (PBIAS)، میانگین خطای مطلق (MAE)، مجذور میانگین مربعات خطا (RMSE) و

$$ACC = \frac{D | D+W | W}{D+W} \quad (\text{رابطه ۱۳})$$

که D ، W ، $D | D$ و $W | W$ به ترتیب معرف تعداد روزهای خشک، تعداد روزهای تر، تعداد روزهای خشک که درست مدل شده‌اند و تعداد روزهای تر که درست مدل شده‌اند می‌باشند.

نتایج و بحث

در جدول (۱)، لیست پیش‌بینی‌کننده‌های بزرگ‌مقیاس با بیشترین همبستگی با بارش مشاهداتی ایستگاه شهرکرد (به عنوان نمونه) آورده شده است. در این جدول، مقدار قدر مطلق ضریب همبستگی، از ۰/۲۶۷ برای سرعت نصف‌النهاری سطحی (با طول جغرافیایی ۵۲/۵ درجه شرقی و عرض جغرافیایی ۳۰ درجه شمالی) تا ۰/۴۱۳ برای رطوبت نسبی در تراز ۸۵۰ (با طول جغرافیایی ۵۲/۵ درجه شرقی و عرض جغرافیایی ۳۰ درجه شمالی) هکتوپاسکال تغییر می‌کند.

$$PBIAS = \frac{\sum_{i=1}^n (\hat{y}_i - y_i) * 100}{\sum_{i=1}^n \hat{y}_i} \quad (\text{رابطه ۹})$$

$$MAE = \sum_{i=1}^n \left| \frac{(\hat{y}_i - y_i)}{N} \right| \quad (\text{رابطه ۱۰})$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{N}} \quad (\text{رابطه ۱۱})$$

$$R = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}}_i)(y_i - \bar{y}_i)}{\sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}}_i)^2 \sum_{i=1}^n (y_i - \bar{y}_i)^2}} \quad (\text{رابطه ۱۲})$$

هم‌چنین، به منظور ارزیابی دقت در طبقه‌بندی وقوع بارش (ACC) از رابطه زیر استفاده شده است (Chen et al., 2010):

جدول ۱. لیست متغیرهای بزرگ‌مقیاس انتخاب شده بر اساس آنالیز همبستگی در ایستگاه شهرکرد


نام متغیر	تأخیر زمانی	طول جغرافیایی	عرض جغرافیایی	ضریب همبستگی
رطوبت نسبی در تراز ۸۵۰ هکتوپاسکال	۰	۵۲/۵	۳۰	۰/۴۱۳
رطوبت نسبی در سطح زمین	۰	۵۲/۵	۳۰	۰/۴۱۳
واگرایی در تراز ۸۵۰ هکتوپاسکال	۱	۴۸/۷۵	۳۰	-۰/۳۷۶
سرعت مداری در تراز ۸۵۰ هکتوپاسکال	۱	۴۸/۷۵	۳۰	۰/۳۷۱
رطوبت ویژه در سطح زمین	۰	۵۲/۵	۳۰	۰/۳۷۱
سرعت مداری در تراز ۵۰۰ هکتوپاسکال	۰	۵۲/۵	۳۲/۵	۰/۳۶۵
واگرایی در تراز ۵۰۰ هکتوپاسکال	۰	۵۲/۵	۳۰	-۰/۳۵۷
چرخندگی در تراز ۵۰۰ هکتوپاسکال	۰	۴۵	۳۲/۵	۰/۳۳۸
رطوبت نسبی در تراز ۵۰۰ هکتوپاسکال	۱	۴۸/۷۵	۳۰	۰/۳۳۰
قدرت جریان هوا در تراز ۵۰۰ هکتوپاسکال	۰	۴۸/۷۵	۳۰	۰/۳۲۸
ارتفاع ژئوپتانسیل در تراز ۵۰۰ هکتوپاسکال	۰	۴۵	۳۲/۵	-۰/۳۰۹
سرعت نصف‌النهاری در تراز ۵۰۰ هکتوپاسکال	۰	۴۵	۳۰	۰/۳۰۰
سرعت نصف‌النهاری در تراز ۸۵۰ هکتوپاسکال	۰	۵۲/۵	۳۰	۰/۲۹۱
جهت حرکت باد در تراز ۸۵۰ هکتوپاسکال	۰	۵۲/۵	۳۰	-۰/۲۶۷

افزایش ۳ و ۱۴ درصدی متوسط دقت طبقه‌بندی را به دنبال داشته است. در مورد ایستگاه بارز نیز، در دوره آموزش دقت الگوریتم MARS و مدل SDSM تقریباً برابر است. اما در دوره آزمون الگوریتم MARS تا ۰/۳۶ درصد دقیق‌تر است. این برتری به دلیل استفاده از استراتژی تقسیم و حل در الگوریتم MARS و استفاده از روابط غیرخطی در این الگوریتم می‌باشد. اختلاف دقت الگوریتم MARS و SDSM در سه ماه فصل زمستان و سه ماه فصل پاییز نسبت به دیگر ماه‌ها بیشتر است. این موضوع نشان

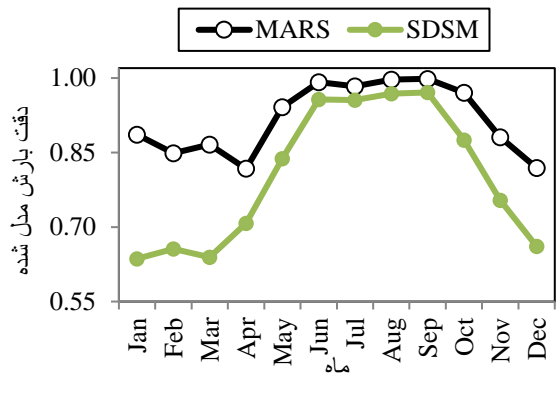
شکل (۴) نتایج میانگین ماهانه دقت طبقه‌بندی روزهای تر و خشک را در سه ایستگاه بررسی شده نشان می‌دهد. در این شکل، دقت مدل MARS برای ایستگاه‌های شهرکرد و یاسوج در هر دو دوره آموزش و آزمون بیش‌تر از مدل SDSM می‌باشد. در دوره آموزش، استفاده از مدل MARS در ایستگاه‌های شهرکرد و یاسوج سبب افزایش ۱۱ و ۱۸ درصدی میانگین ماهانه دقت طبقه‌بندی شده است. هم‌چنین، در دوره آزمون، استفاده از مدل MARS در ایستگاه‌های شهرکرد و یاسوج نسبت به مدل SDSM

در سه ایستگاه بررسی شده می‌تواند به دلیل عواملی چون موقعیت جغرافیایی متفاوت و در نتیجه آب و هوایی متفاوت در هر ایستگاه باشد.


می‌دهد که الگوریتم MARS در تعیین وقوع بارش مربوط به فصل‌های مرطوب توانایی بیشتری نسبت به فصل‌های خشک دارد. در حالی که در فصل تابستان، دقت الگوریتم SDSM تقریباً با الگوریتم MARS برابر است. همچنین تفاوت نتایج طبقه‌بندی




(ب)




(الف)




(د)



(ج)



(و)



(ه)

شکل ۴. مقایسه دقت مدل‌های SDSM و MARS در طبقه‌بندی روزهای تر و خشک در (الف) شهرکرد-دوره آموزش، (ب) شهرکرد-دوره آزمون، (ج) بارز-دوره آموزش، (د) بارز-دوره آزمون، (و) یاسوج-دوره آموزش و (ه) یاسوج-دوره آزمون

مقایسه قرار گرفته است. با توجه به جدول (۲)، در دوره آموزش، بیش‌ترین و کم‌ترین مقدار PBIAS به ترتیب مربوط به مدل SDSM در ایستگاه یاسوج و الگوریتم KNN در ایستگاه شهرکرد

در جدول (۲)، خطای PBIAS مربوط به میانگین سالانه پارامترهای آماری حاصل از ریزمقیاس‌نمایی توسط الگوریتم ANN، KNN و مدل SDSM نسبت به داده‌های مشاهداتی مورد

یاسوج مربوط به الگوریتم SDSM و به ترتیب برابر با ۳/۸۶، ۷/۶۳ و ۶/۹۵- درصد می‌باشد. همچنین، الگوریتم ANN در دو ایستگاه شهرکرد و بارز (با مقادیر ۱۲/۲۵ و ۲۳/۴۱- درصد برای درصد خطا) دارای دقیق‌ترین نتایج در ریزمقیاس‌نمایی ضریب چولگی بارش است. اما در ایستگاه یاسوج مقدار ضریب چولگی توسط مدل SDSM با دقت بیشتری نسبت به دو الگوریتم دیگر ریزمقیاس شده است. با در نظر گرفتن هر سه معیار و سه ایستگاه بررسی شده می‌توان نتیجه گرفت که الگوریتم ANN از دقت بیشتری نسبت به مدل SDSM و الگوریتم KNN برخوردار است. با این حال، برتری SDSM در برخی از ایستگاه‌ها می‌تواند به دلیل میانگین‌گیری و خطی بودن سری زمانی در مقیاس سالانه باشد. همچنین، با توجه جدول (۲)، دقیق‌ترین نتایج مربوط به ایستگاه یاسوج است. این موضوع نیز به علت تفاوت مشخصات آماری سری زمانی بارش در ایستگاه‌های مختلف است.

با مقدار ۰/۰۰ و ۲۴/۷۳ درصد می‌شود. در مورد انحراف معیار در میان روش‌های بررسی شده مدل SDSM و الگوریتم KNN در ایستگاه بارز با مقدار درصد خطای ۱/۴۴ و ۴۹/۷۱- درصد به ترتیب دارای بیش‌ترین دقت و کم‌ترین دقت می‌باشند. در حالی که کم‌ترین و بیش‌ترین مقدار خطای ضریب چولگی به ترتیب توسط الگوریتم SDSM در ایستگاه یاسوج برابر با ۰/۰۰ درصد و الگوریتم SDSM در ایستگاه شهرکرد برابر با ۴۷/۱۷ درصد محاسبه شده است.

در دوره آزمون، بهترین نتایج ریزمقیاس‌نمایی میانگین بارش برای ایستگاه شهرکرد مربوط به مدل SDSM (با مقدار درصد خطا ۸/۰۵ درصد) می‌شود. در حالی که در ایستگاه‌های بارز و یاسوج بهترین نتایج ریزمقیاس‌نمایی میانگین بارش مربوط به ANN (با مقادیر ۸/۲۴- و ۵/۳۱- درصد) است. در مورد انحراف معیار، کمترین مقادیر درصد خطا در ایستگاه‌های شهرکرد، بارز و

جدول ۲. پارامترهای آماری بارش ریزمقیاس شده و مشاهداتی

ایستگاه	مدل	آموزش			آزمون		
		Mean (mm/day)	PBIAS	SD (mm/day)	PBIAS	SD (mm/day)	Mean (mm/day)
شهرکرد	مشاهداتی	۰/۹۳	-	۳/۹۰	-	۶/۵۳	۰/۸۷
	SDSM	۱/۱۱	-۱۶/۲۲	۳/۶۷	۳/۸۶	۳/۴۹	۱/۰۰
	ANN	۰/۷۷	۱۷/۲۰	۲/۶۱	۲۸/۰۸	۲/۵۱	۰/۷۴
	KNN	۰/۷۰	۲۴/۷۳	۲/۰۴	۴۵/۵۶	۱/۹۰	۰/۶۵
بارز	مشاهداتی	۱/۶۹	-	۶/۹۶	-	۶/۰۸	۱/۶۹
	SDSM	۱/۹۳	۱۴/۲۰	۷/۰۶	۱/۴۴	۴/۱۵	۱/۹۳
	ANN	۱/۶۲	-۴/۱۴	۶/۲۲	-۱۰/۶۳	۴۰/۰۸	۱/۶۲
	KNN	۱/۴۶	-۱۳/۶۱	۳/۵۰	-۴۹/۷۱	۳/۴۶	۱/۴۶
بارز	مشاهداتی	۱/۷۰	-	۷/۲۱	-	۵/۹۸	۱/۷۰
	SDSM	۱/۹۶	۱۵/۲۹	۷/۷۶	۷/۶۳	۷/۴۶	۱/۹۶
	ANN	۱/۵۶	-۸/۲۴	۳/۹۶	-۴۵/۰۸	۴/۵۸	۱/۵۶
	KNN	۱/۴۷	-۱۳/۵۳	۳/۴۱	-۵۲/۷۰	۳/۴۷	۱/۴۷
یاسوج	مشاهداتی	۲/۳۷	-	۸/۷۲	-	۵/۴۰	۲/۳۷
	SDSM	۲/۳۷	۰/۰۰	۸/۳۷	-۴/۰۱	۵/۴۰	۲/۳۷
	ANN	۲/۴۱	۱/۶۹	۶/۰۳	-۳۰/۸۵	۳/۹۰	۲/۴۱
	KNN	۱/۹۶	-۱۷/۳۰	۴/۶۶	-۴۶/۵۶	۳/۳۳	۱/۹۶
یاسوج	مشاهداتی	۲/۴۵	-	۹/۵۰	-	۵/۷۹	۲/۴۵
	SDSM	۲/۳۰	-۶/۱۲	۸/۸۴	-۶/۹۵	۶/۱۳	۲/۳۰
	ANN	۲/۳۲	-۵/۳۱	۵/۹۷	-۳۷/۱۶	۴/۰۱	۲/۳۲
	KNN	۱/۹۳	-۲/۱۲۲	۴/۶۱	-۵۱/۴۷	۳/۲۱	۱/۹۳

مورد معیار MAE بهترین نتایج برای میانگین و ضریب چولگی مربوط به ANN در ایستگاه شهرکرد (با مقادیر ۰/۱۷ و ۱/۹۵ میلی‌متر بر روز) می‌شود. بهترین نتایج MAE برای انحراف معیار مربوط به ANN در ایستگاه بارز (۰/۰۱ میلی‌متر بر روز) می‌شود. بهترین مقادیر RMSE نیز مربوط به SDSM در شهرکرد، ANN در بارز و ANN در شهرکرد و به ترتیب برابر با ۰/۲۹، ۱/۴۷ و ۲/۶۴ میلی‌متر بر روز محاسبه شده است.

در جدول (۳)، معیارهای ارزیابی خطا برای مقادیر میانگین ماهانه ریزمقیاس شده توسط الگوریتم‌های ANN، KNN و مدل SDSM مورد مقایسه قرار گرفته‌اند. در دوره آموزش، دقیق‌ترین مقادیر ضریب R برای میانگین ماهانه و انحراف معیار ماهانه بارش برابر با ۰/۹۹ (توسط KNN در ایستگاه شهرکرد و ANN در یاسوج) و ۱/۰۰ (توسط ANN در ایستگاه بارز) محاسبه شده است. در حالی که در مورد ضریب چولگی بیش‌ترین مقدار R برابر با ۰/۹۷ توسط ANN در ایستگاه شهرکرد به دست آمده است. در

جدول ۳. معیارهای ارزیابی برای بارش ریزمقیاس شده

ایستگاه	پارامتر	دوره	R			MAE (mm/day)			RMSE (mm/day)		
			KNN	ANN	SDSM	KNN	ANN	SDSM	KNN	ANN	SDSM
شهرکرد	میانگین	آموزش	۰/۹۷	۰/۹۶	۰/۹۹	۰/۲۶	۰/۱۷	۰/۲۳	۰/۲۹	۰/۲۹	۰/۲۸
		آزمون	۰/۹۷	۰/۹۸	۰/۹۷	۰/۲	۰/۱۵	۰/۲۲	۰/۳۱	۰/۲۲	۰/۲۳
	انحراف معیار	آموزش	۰/۸۶	۰/۹۳	۰/۹۸	۱/۷۲	۱/۰۴	۱/۶۵	۱/۹۵	۱/۴۷	۱/۸۷
		آزمون	۰/۹۶	۰/۹۷	۰/۹۵	۰/۸۹	۰/۹۹	۱/۴۴	۱/۸۵	۱/۱۵	۱/۰۱
	ضریب چولگی	آموزش	۰/۹۲	۰/۹۷	۰/۹۶	۵/۴۰	۱/۹۵	۲/۸۰	۳/۳۲	۲/۶۴	۷/۲۵
		آزمون	۰/۵۹	۰/۹۱	۰/۷۶	۴/۵۱	۳/۶۹	۲/۷۸	۳/۹۰	۵/۷۱	۵/۳۶
بارز	میانگین	آموزش	۰/۹۷	۰/۹۵	۰/۹۸	۰/۳۵	۰/۴۰	۰/۲۶	۰/۴۱	۰/۵۷	۰/۵۲
		آزمون	۰/۸۸	۰/۹۵	۰/۹۸	۰/۵۶	۰/۳۵	۰/۲۵	۰/۴۳	۰/۵۹	۰/۹۰
	انحراف معیار	آموزش	۰/۹۵	۱/۰۰	۰/۹۹	۱/۴۰	۰/۰۱	۳/۱۳	۴/۰۳	۰/۰۲	۱/۵۸
		آزمون	۰/۸۲	۰/۸۶	۰/۹۷	۲/۰۲	۲/۶۶	۲/۹۲	۴/۰۷	۳/۹۲	۲/۹۱
	ضریب چولگی	آموزش	۰/۶۸	۰/۸۵	۰/۷۳	۴/۶۹	۳/۷۳	۵/۷۱	۷/۸۱	۵/۲۵	۶/۵۷
		آزمون	-۰/۷۷	-۰/۰۶	-۰/۳۱	۵/۹۰	۳/۸۶	۳/۷۶	۵/۷۲	۵/۱۲	۹/۲۰
یاسوج	میانگین	آموزش	۰/۹۶	۰/۹۹	۰/۹۹	۰/۵۲	۰/۲۸	۰/۴۱	۰/۵۵	۰/۴۲	۰/۷۱
		آزمون	۰/۹۸	۰/۹۸	۰/۹۷	۰/۴۶	۰/۳۴	۰/۵۳	۰/۸۷	۰/۴۹	۰/۶۷
	انحراف معیار	آموزش	۰/۹۷	۰/۹۷	۰/۹۸	۱/۳۸	۲/۵۱	۳/۵۳	۴/۳۷	۳/۲۰	۱/۶۵
		آزمون	۰/۹۶	۰/۹۶	۰/۹۸	۱/۴۴	۲/۸۹	۳/۸۷	۵/۱۸	۴/۰۶	۱/۹۳
	ضریب چولگی	آموزش	۰/۷۵	۰/۷۱	۰/۷۸	۲/۹۱	۳/۶۶	۴/۰۹	۶/۰۱	۵/۸۸	۴/۷۴
		آزمون	۰/۴۱	۰/۰۷	۰/۱۹	۳/۱۴	۳/۸۱	۴/۱۷	۵/۶۵	۵/۵۲	۴/۹۰

۰/۵۶ و ۰/۹۰ میلی‌متر بر روز به ترتیب دارای بیشترین و کمترین دقت در تعیین میانگین ماهانه بارش می‌باشند. برای انحراف معیار ماهانه کمترین مقادیر MAE و RMSE مربوط به الگوریتم SDSM در ایستگاه شهرکرد با مقادیر ۰/۸۹ و ۱/۰۱ و بیشترین مقادیر مربوط به مدل KNN در ایستگاه یاسوج با مقادیر ۳/۸۷ و ۵/۱۸ میلی‌متر بر روز است. همچنین اختلاف مقادیر مذکور برای SDSM و ANN بسیار کم بود. بهترین مقادیر MAE و RMSE برای ضریب چولگی ماهانه در ایستگاه‌های شهرکرد، بارز و یاسوج به ترتیب برابر با ۲/۸۷ و ۳/۹۰ (توسط KNN)، ۳/۷۶ (توسط ANN) و ۵/۱۲ (توسط ANN) و ۳/۴۱ و ۴/۹۰ میلی‌متر بر روز (توسط مدل SDSM) محاسبه شده شده‌اند.


در نهایت، با توجه به نتایج جدول (۳)، می‌توان دریافت که به صورت کلی، الگوریتم ANN در دو ایستگاه شهرکرد و بارز

در دوره آزمون، الگوریتم ANN مقدار ضریب R را در ایستگاه شهرکرد برای میانگین، انحراف معیار و ضریب چولگی به ترتیب برابر با ۰/۹۸، ۰/۹۷ و ۰/۹۱ محاسبه کرده است. این مقادیر نسبت به مدل SDSM به ترتیب در حدود ۱، ۳ و ۵۴ درصد دقیق‌تر محاسبه شده‌اند. در ایستگاه بارز بهترین نتایج ضریب R برای میانگین و انحراف معیار مربوط به الگوریتم KNN با ۱۱ و ۱۸ درصد برتری می‌باشد. بهترین مقدار معیار مذکور در ایستگاه بارز برای ضریب چولگی مربوط به الگوریتم ANN می‌شود. در ایستگاه یاسوج نیز دقیق‌ترین مقدار ضریب R برای تعیین میانگین، انحراف معیار و ضریب چولگی با اختلاف اندک، به ترتیب مربوط به ANN، KNN و SDSM می‌شود. در مورد معیار MAE و RMSE الگوریتم ANN در ایستگاه شهرکرد با مقدار ۰/۱۵ و ۰/۲۲ میلی‌متر بر روز و الگوریتم SDSM در ایستگاه بارز با مقدار

است. با توجه به این شکل، الگوریتم ANN در ریزمقیاس‌نمایی میانگین و ضریب چولگی ماهانه بارش ایستگاه شهرکرد در هر دو دوره آموزش و آزمون از عملکرد بهتری نسبت به الگوریتم KNN و مدل SDSM برخوردار است. همچنین، بارش ماهانه در ایستگاه بارز توسط الگوریتم ANN با دقت بیشتری نسبت به الگوریتم KNN و مدل SDSM مدل شده است. در حالی که در ایستگاه یاسوج دقت مدل SDSM بیشتر از دو الگوریتم ANN و KNN است. نتایج شکل (۱) تأیید کننده مقادیر به‌دست آمده در جدول (۳) است.

نسبت به دو روش دیگر از دقت بیشتری در ریزمقیاس‌نمایی بارش ماهانه برخوردار است. در حالی که در ایستگاه یاسوج بهترین نتایج مربوط به مدل SDSM است. همچنین، با توجه به نتایج، مدل پیشنهادی در عرض‌های شمالی‌تر حوضه نسبت به عرض‌های جنوبی‌تر حوضه بهتر عمل می‌کند. این تفاوت در نتایج به علت تفاوت در معیارهای پراکندگی و پیچیدگی سری زمانی بارش در ایستگاه‌های مختلف است.

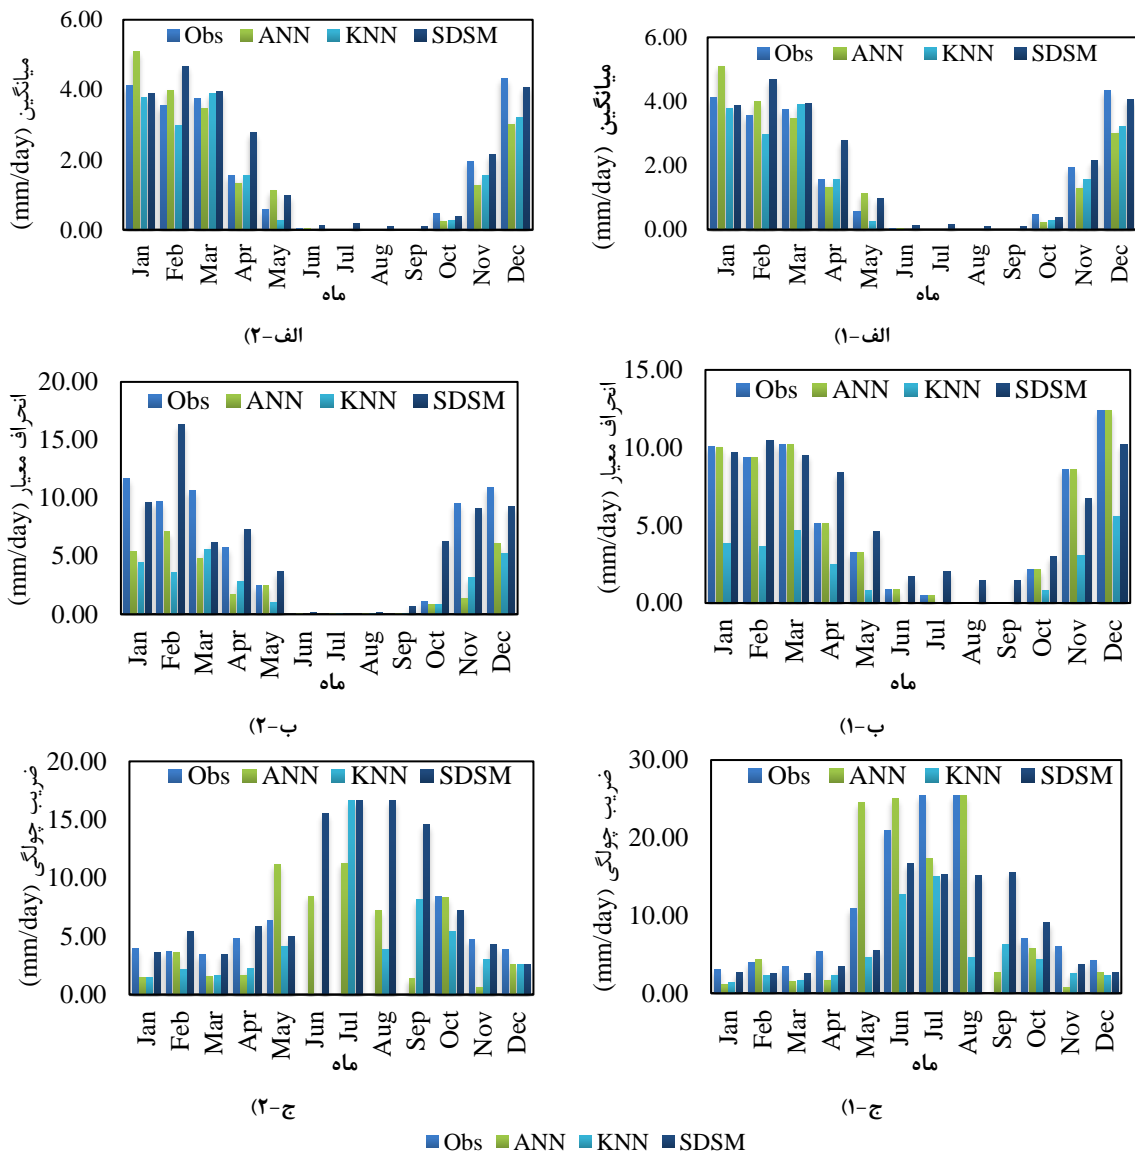
نتایج ریزمقیاس‌نمایی بارش با استفاده از الگوریتم‌های ANN و KNN و مدل SDSM برای ماه‌های مختلف سال و ایستگاه‌های بررسی شده در شکل‌های (۵) تا (۷) نشان داده شده



شکل ۵. مقایسه داده‌های بارش مشاهداتی و ریزمقیاس شده در ایستگاه شهرکرد: الف) میانگین، ب) انحراف معیار و ج) ضریب چولگی، سمت راست آموزش، سمت چپ آزمون

معیار و ضریب چولگی توسط SDSM بیشتر از مقدار مشاهداتی محاسبه شده است.

بنابراین، با در نظر گرفتن هر سه ایستگاه در مقیاس سالانه و ماهانه، الگوریتم ANN از دقت بیشتری نسبت به الگوریتم KNN و مدل SDSM برخوردار است. همچنین مقدار انحراف




شکل ۶. مقایسه داده‌های بارش مشاهداتی و ریزمقیاس شده در ایستگاه بارز: (الف) میانگین، (ب) انحراف معیار و (ج) ضریب چولگی، سمت راست آموزش، سمت چپ آزمون

است. تفاوت نتایج در سه ایستگاه بررسی شده نیز به علت اختلاف در موقعیت جغرافیایی، ارتفاع از سطح دریا و آب و هوا و در نتیجه سری زمانی با پراکندگی و پیچیدگی متفاوت در هر ایستگاه می‌باشد. برتری ANN نسبت به SDSM تأیید کننده نتایج پژوهش‌های *Dorji et al. (2017)* و *Campozano et al. (2016)* می‌باشد. برتری ANN نسبت به KNN، نتایج پژوهش‌های *Wu et al. (2010)* و *Mekanik et al. (2013)* را تأیید می‌کند. به منظور پیش‌بینی بارش آینده ایستگاه شهرکرد از خروجی‌های مدل HadCM3 تحت سناریوهای A2 و B2 استفاده شده است. در جدول (۴) نتایج پیش‌بینی درصد تغییر مقدار بارش توسط روش‌های SDSM، ANN و KNN در دو دوره آینده نزدیک


این موضوع به دلیل وجود روابط غیرخطی در ساختار الگوریتم ANN است. الگوریتم ANN با پردازش اطلاعات در چندین لایه و الگوریتم KNN با در نظر گرفتن شباهت بین داده‌ها با استفاده از محاسبه فاصله اقلیدوسی و تابع کرنل، روابط غیرخطی را به خوبی در نظر می‌گیرند. در حالی که روش SDSM تنها از یک رگرسیون خطی برای تعیین مقدار بارش استفاده می‌کند. دلیل دیگر این برتری، دقت بیشتر الگوریتم MARS نسبت به مدل SDSM در طبقه‌بندی روزهای تر و خشک است. لازم به ذکر است که مدل MARS یک مدل غیرخطی است و به همین علت از نتایج دقیق‌تری نسبت به مدل خطی SDSM (از روابط خطی برای طبقه‌بندی بارش استفاده می‌کند) برخوردار

همچنین دلیل دیگر این تفاوت، وجود روابط غیرخطی در مدل پیشنهادی و در نتیجه حساسیت بیشتر نسبت به تغییرات متغیرهای بزرگ مقیاس مربوط به سناریوهای تغییر اقلیم است. علاوه بر این، مدل SDSM مقدار بارش را در ایستگاه یاسوج با افزایش پیش‌بینی کرده است. در حالی که نتایج مدل پیشنهادی حاکی از کاهش بارش در ایستگاه یاسوج است. این موضوع به علت وجود فرضیات متفاوت در مدل پیشنهادی و مدل SDSM است. نتایج پژوهش حاضر، کاهش بارش در ایستگاه کرمانشاه توسط مطالعه (Salajegheh et al., 2018) را تأیید می‌کند. در پژوهش مذکور، مقدار بارش تحت سناریوی A2 مدل HadCM3 در دهه ۲۰۲۰ در حدود ۱۵ درصد و در دهه ۲۰۵۰ در حدود ۲۱ درصد کاهش داشت.


(۲۰۲۰-۲۰۴۰) و آینده دور (۲۰۷۰-۲۱۰۰) نسبت به دوره پایه ارائه شده است. با توجه به نتایج، بیشترین (۵۴ درصد) و کمترین مقدار کاهش (۲ درصد) بارش به ترتیب مربوط به الگوریتم SDSM در ایستگاه یاسوج و دوره ۲۰۷۰-۲۱۰۰ تحت سناریوی A2 و الگوریتم KNN در دوره ۲۰۷۰-۲۱۰۰ تحت سناریو A2 می‌باشد. با توجه به نتایج، هر یک از سناریوها و روش‌های ریزمقیاس‌نمایی دارای نتایج متفاوتی هستند. این موضوع به دلیل فرضیات متفاوت در هر یک از سناریوها و روش‌ها است. به عنوان مثال، مطابق با گزارش IPCC مقدار تولید گازهای گلخانه‌ای در سناریو A2 و در دوره ۲۰۷۰-۲۱۰۰ بیشتر از سناریو B2 است. همچنین مقدار افزایش دما در سناریو A2 در حدود ۰/۶ تا ۱/۶ درجه سلسیوس بیشتر از سناریو B2 است (Morita, 2001).




الف-۲




الف-۱




ب-۲



ب-۱



ج-۲



ج-۱

■ Obs ■ ANN ■ KNN ■ SDSM

شکل ۷. مقایسه داده‌های بارش مشاهداتی و ریزمقیاس شده در ایستگاه یاسوج: الف) میانگین، ب) انحراف معیار و ج) ضریب چولگی، سمت

جدول ۴. درصد تغییرات بارش در دوره‌های ۲۰۲۰-۲۰۴۰ و ۲۰۷۰-۲۱۰۰

ایستگاه	مدل ریزمقیاس- نمایی	در دوره پایه (mm/day)	سناریوی A2		سناریوی B2	
			۲۰۲۰-۲۰۴۰	۲۰۷۰-۲۱۰۰	۲۰۲۰-۲۰۴۰	۲۰۷۰-۲۱۰۰
شهرکرد	SDSM		-۱۶	-۱۷	-۱۸	-۱۹
	ANN	۰/۹۱	-۲	-۲۳	-۱۶	-۶
	KNN		-۲۰	-۳۲	-۸	-۲۸
بارز	SDSM		۵۶	۶۷	۶۶	۶۶
	ANN	۱/۶۹	-۲۴	-۲۰	-۱۸	-۶۶
	KNN		-۱۲	-۱۱	-۱۲	-۷
یاسوج	SDSM		-۵۳	-۵۴	-۵۲	-۵۳
	ANN	۲/۳۹	-۷	-۱۹	-۱۵۹	-۱۵۷
	KNN		-۳۱	-۳۲	-۲۹	-۳۳

نتیجه‌گیری

در پژوهش حاضر، با استفاده از ترکیب مدل MARS، شبکه‌های عصبی مصنوعی (ANN) و K نزدیکترین همسایه (KNN)، روشی هیبریدی برای ریزمقیاس نمایی بارش شهرکرد، بارز و یاسوج پیشنهاد شد. این مدل مشابه با مدل SDSM از دو قسمت تعیین وقوع بارش و مقدار بارش تشکیل شده است. روش پیشنهادی برای تعیین وقوع بارش از مدل MARS و برای تعیین مقدار بارش از روش‌های ANN و KNN بهره برد. به این منظور، پس از انتخاب پیش‌بینی کننده‌ها، MARS وقوع بارش را تعیین کرد. این مدل در دوره‌های آموزش و آزمون، روزهای تر و خشک را با دقت بیشتری نسبت به مدل SDSM طبقه‌بندی کرد. در ادامه، با

استفاده از الگوریتم‌های ANN و KNN و مدل SDSM، مقدار بارش ریزمقیاس شد. بررسی نتایج نشان داد که الگوریتم ANN در مقیاس سالانه بر اساس معیار PBIAS و در مقیاس ماهانه بر اساس معیارهای R، MAE و RMSE نسبت به دو مدل دیگر دارای برتری می‌باشد. نتایج پیش‌بینی بارش بر اساس خروجی-های مدل HadCM3 تحت سناریوهای A2 و B2 نشان داد که کمترین مقدار کاهش بارش مربوط به الگوریتم ANN در دوره ۲۰۲۰-۲۰۴۰ تحت سناریوی A2 بود. بیشترین مقدار کاهش بارش نیز مربوط به مدل SDSM در دوره ۲۰۷۰-۲۱۰۰ تحت سناریوی A2 بود. به منظور تحقیقات آتی، می‌توان مدل‌های جدید مانند CanESM2 و سناریوهای RCP را به کار برد و نتایج حاصل را با نتایج پژوهش حاضر مقایسه کرد.

REFERENCES

- Ahmadi, A., Moridi, A., Lafdani, E. K. and Kianpishneh, G. (2014). Assessment of climate change impacts on rainfall using large scale climate variables and downscaling models—A case study. *Journal of Earth System Science*, 123(7), 1603-1618.
- Ahmed, K., Shahid, S., Nawaz, N. and Khan, N. (2019). Modeling climate change impacts on precipitation in arid regions of Pakistan: a non-local model output statistics downscaling approach. *Theoretical and Applied Climatology*, 137(1-2), 1347-1364.
- Al-Mukhtar, M. and Qasim, M. (2019). Future predictions of precipitation and temperature in Iraq using the statistical downscaling model. *Arabian Journal of Geosciences*, <https://doi.org/10.1007/s12517-018-4187-x>.
- Araghinejad, S. (2014). Data-driven modeling: Using MATLAB in Water Resources and Environmental Engineering. Springer, *Water Science and Technology Library*, 67.
- Ashofteh, S. A. and Bozorg-Haddad, O. (2013). Use of multi-conditional functions in the field of reservoir management and under climate change. *Iranian Journal of Soil and Water Research*, 45(4), 397-404. (In Farsi).
- Beheshti, M., Heidari, A. and Saghafian. (2019). Susceptibility of Hydropower Generation to Climate Change: Karun III Dam Case Study. *Water*, 11(5), 1025.
- Camposano, L., Tenelanda, D., Sanchez, E., Samaniego, E. and Feyen, J. (2016). Comparison of statistical downscaling methods for monthly total precipitation: Case study for the Paute River Basin in Southern Ecuador. *Advances in Meteorology*, 2016, ID: 6526341.
- Chaudhary, S., Agarwal, A. and Nakamura, T. (2019). Rainfall Projection in Yamuna River Basin, India, Using Statistical Downscaling. In: Rathinasamy M., Chandramouli S., Phanindra K., Mahesh U. (eds) *Water Resources and Environmental Engineering II*. Springer, Singapore.
- Chen, S. T., Yu, P. S. and Tang, Y. H. (2010). Statistical downscaling of daily precipitation using support vector machines and multivariate analysis. *Journal of Hydrology*, 385(1-4), 13-22.
- Devak, M., Dhanya, C. T. and Gosain, A. K. (2015). Dynamic coupling of support vector machine and K-nearest neighbour for downscaling daily

- rainfall. *Journal of Hydrology*, 525, 286-301.
- Dorji, S., Herath, S. and Mishra, B. (2017). Future climate of colombo downscaled with SDSM-neural network. *Climate*, 5(1), 24.
- Friedman, J. H. (1991). Multivariate adaptive regression splines. *The Annals of Statistics*, 19(1), 1-67.
- Ghamghami, M., Ghahreman, N. and Araghinejad, S. (2010). An evaluation of the performance of an advanced approach of the K-nearest neighbor in simulating the daily meteorological data. *Iranian Journal of Soil and Water Research*, 42(1), 45-54. (In Farsi).
- Hadi, S. J. and Tombul, M. (2018). Streamflow forecasting using four wavelet transformation combinations approaches with data-driven models: A comparative study. *Water Resources Management*, 32(14), 4661-4679.
- Haji Hosseini, R., Golian, S. and Yazdi, J. (2018). Evaluation of data-driven models to downscale rainfall parameters from global climate models outputs: The case study of Lalyan watershed. *Journal of Water and Climate Change*, <https://doi.org/10.2166/wcc.2018.191>
- Harpham, C. and Wilby, R. L. (2005). Multi-site downscaling of heavy daily precipitation occurrence and amounts. *Journal of Hydrology*, 312(1-4), 235-255.
- Hessami, M., Gachon, P., Ouarda, T. B. M. J. and St-Hilaire, A. (2008). Automated regression-based statistical downscaling tool. *Environmental Modelling & Software*, 23(6), 813-834.
- IPCC-TGCI. (1999). Guidelines on the Use of Scenario Data for Climate Impact and Adaptation Assessment, Version 1. *Intergovernmental Panel on Climate Change*, 69 p.
- IPCC-TGCI. (2007). General Guidelines on the Use of Scenario Data for Climate Impact and Adaptation Assessment. Version 1, 312, *Intergovernmental Panel on Climate Change*, 66 p.
- Khashei, A., Shahidi, A., Pourrezabilondi, M., Amirabadzadeh, A. and Jafarzadeh, A. (2018). Performance assessment of ANN and SVR for downscaling of daily rainfall in dry regions. *Iranian Journal of Soil and Water Research*, 49(4), 781-793. (In Farsi).
- Lee, K. T., Hung, W. C. and Meng, C. C. (2008). Deterministic insight into ANN model performance for storm runoff simulation. *Water Resources Management*, 22(1), 67-82.
- Mekanik, F., Imteaz, M. A., Gato-Trinidad, S. and Elmahdi, A. (2013). Multiple regression and artificial neural network for long-term rainfall forecasting using large scale climate modes. *Journal of Hydrology*, 503, 11-21.
- Mesbahzadeh, T., Miglietta, M. M., Miakbari, M., Soleimani Sardoo, F. and Abdolhoseini, M. (2019). Joint Modeling of Precipitation and Temperature Using Copula Theory for Current and Future Prediction under Climate Change Scenarios in Arid Lands (Case Study, Kerman Province, Iran). *Advances in Meteorology*, <https://doi.org/10.1155/2019/6848049>.
- Modaresi, F. Araghinejad, S. and Ebrahimi, K. (2018). A comparative assessment of artificial neural network, generalized regression neural network, least-square support vector regression, and K-nearest neighbor regression for monthly streamflow forecasting in linear and nonlinear conditions. *Water Resources Management*, 32(1), 243-258.
- Moghadam, S. H., Ashofteh, P. S. and Loáiciga. H. A. (2019). Application of Climate Projections and Monte Carlo Approach for Assessment of Future River Flow: Khorramabad River Basin, Iran. *Journal of Hydrologic Engineering*, [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001801](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001801).
- Morita, T., (2001). 2.5. 1.1 IPCC Emissions Scenarios and the SRES Process. IPCC TAR WG3.
- Nourani, V., Baghanam, A. H. and Gokcekus, H. (2018). Data-driven ensemble model to statistically downscale rainfall using nonlinear predictor screening approach. *Journal of Hydrology*, 565, 538-551.
- Nourani, V., Razzaghzadeh, Z., Baghanam, A.H. and Molajou, A. (2019). *Theoretical and Applied Climatology*, 137(3-4): 1729-1746.
- Rezaie-Balf, M., Zahmatkesh, Z and. Kim, S. (2017). Soft computing techniques for rainfall-runoff simulation: Local non-parametric paradigm vs. model classification methods. *Water Resources Management*, 31(12), 3843-3865.
- Salajegheh, A., Rafiei Sardoi, E., Moghaddamnia, A., Malekian, A., Araghinejad, S., Khalighi Sigarodi, S. and Pourjam, A. S. (2018). Performance assessment of LARS-WG and SDSM downscaling models in simulation of precipitation and temperature. *Iranian Journal of Soil and Water Research*, 48(2), 253-262. (In Farsi).
- Sayedi, A., Taleb beydokhti, N., Najarchi, M. and Najafizadeh, M. M. (2019). Investigation into the Effects of Climatic Change on Temperature, Rainfall, and Runoff of the Doroudzan Catchment, Iran, Using the Ensemble Approach of CMIP3 Climate Models. *Advances in Meteorology*, <https://doi.org/10.1155/2019/6357912>.
- Singh, K. K., Pal, M. and Singh, V. P. (2010). Estimation of mean annual flood in Indian catchments using back propagation neural network and M5 model tree. *Water Resources Management*, 24(10), 2007-2019.
- Wilby, R. L., Dawson, C. W. and Barrow, E. M. (2002). SDSM- A decision support tool for the assessment of regional climate change impacts. *Environmental Modelling & Software*, 17(2), 145-157.
- Wu, C. L., Chau, K. W. and Fan, C. (2010). Prediction of rainfall time series using modular artificial neural networks coupled with data-preprocessing techniques. *Journal of Hydrology*, 389(1-2), 146-167.