



Developing a New Class-based Probabilistic Hybrid Model for Monthly Precipitation Forecasting

F. Modaresi^{1*}

Abstract

High accuracy forecasting of monthly precipitation is one of the major challenges in hydrology and meteorology and is of great importance in water resources planning. In the current research a Class-Based Probabilistic Hybrid Model (CPHM) has been developed on the basis of a hybrid of classification methods and probabilistic kernel functions. Using this method, monthly precipitation (model output) can be forecasted more accurately for all months of a season according to seasonal precipitation (model input). The superiorities of this model over conventional monthly rainfall forecasting methods are on the one hand, its capability for monthly precipitation forecasting for a season such as autumn in Iran the previous months of which in summer have no precipitation, and on the other hand, the simultaneous prediction of precipitation for all months of a season which is valuable in terms of water resources management. In order to evaluate this model, it was applied to forecast autumnal monthly precipitation for Karkheh basin which includes Khuzestan fertile plain and its efficiency was compared to an optimized structural ANN model. Results revealed a high performance for the developed CPHM model while it was also superior to ANN model for its precipitation forecasts for all three months of autumn. The average accuracy of the model resulted from validation phase for three autumn months based on Nash-Sutcliffe (NSE), Root Mean Square Error (RMSE), and Pearson correlation coefficient (PCC) indices were 0.7, 12, and 0.86, respectively.

Keywords: Monthly Precipitation Forecasting, Hybrid Model, Kernel Function, Classification, Karkheh, CPHM.

Received: June 14, 2021

Accepted: September 6, 2021

توسعه یک مدل جدید ترکیبی احتمالاتی کلاس مینا برای پیش‌بینی بارش ماهانه

فرشته مدرسی^{۱*}

چکیده

پیش‌بینی بارش ماهانه با دقت زیاد یکی از چالش‌های مهم در علوم هیدرولوژی و هواشناسی می‌باشد و در برنامه‌ریزی منابع آب از اهمیت بالایی برخوردار است. در تحقیق حاضر، یک مدل ترکیبی احتمالاتی کلاس مینا (CPHM) بر پایه ترکیب روش‌های کلاس‌بندی و توابع کرنل احتمالاتی توسعه داده شده است که با استفاده از آن می‌توان بر اساس بارش‌های فصلی (ورودی مدل)، بارش ماهانه (خروجی مدل) را با دقت بالایی برای تمامی ماه‌های یک فصل پیش‌بینی نمود. برتری‌های این مدل نسبت به روش‌های مرسوم پیش‌بینی ماهانه بارش، از یک سو قابلیت آن برای پیش‌بینی بارش ماهانه برای فصلی نظیر پاییز در ایران می‌باشد که ماه‌های قبل از آن (در تابستان) بدون بارش است، و از سوی دیگر قابلیت آن برای پیش‌بینی هم‌زمان بارش برای تمامی ماه‌های یک فصل می‌باشد که از نظر مدیریت منابع آب بسیار ارزشمند است. از این‌رو، به منظور ارزیابی کارایی این مدل، مدل مذکور برای پیش‌بینی بارش ماهانه پاییز در حوضه آبریز کرخه که دربرگیرنده جلگه حاصلخیز خوزستان است، بکار گرفته شد و عملکرد آن با مدل شبکه عصبی مصنوعی (ANN) با ساختار بهینه شده نیز مورد مقایسه قرار گرفت. نتایج نشان‌دهنده عملکرد بالای مدل CPHM و برتری آن در مقایسه با مدل بهینه شده ANN برای پیش‌بینی بارش در هر سه ماه فصل پاییز می‌باشد؛ به طوری که متوسط دقت نتایج در مرحله صحت‌سنجی این مدل برای سه ماه پاییز بر اساس شاخص‌های نش-ساتکلیف (NSE)، جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی پیرسون (PCC) به ترتیب برابر با ۰/۷، ۱۲ و ۰/۸۶ می‌باشد.

کلمات کلیدی: پیش‌بینی بارش ماهانه، مدل ترکیبی، تابع کرنل، طبقه‌بندی، کرخه، CPHM.

تاریخ دریافت مقاله: ۱۴۰۰/۳/۲۴

تاریخ پذیرش مقاله: ۱۴۰۰/۶/۱۵

1- Assistant Professor, Department of Water and Science Engineering, Ferdowsi University of Mashhad, Mashhad, Iran (FUM).

Email: Fmodaresi@ferdowsi.um.ac.ir

*- Corresponding Author

Dor: [20.1001.1.17352347.1400.17.2.16.9](https://doi.org/10.1001.1.17352347.1400.17.2.16.9)

۱- استادیار گروه علوم و مهندسی آب دانشگاه فردوسی مشهد، مشهد، ایران.

*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان پائیز ۱۴۰۰ امکانپذیر است.

۱- مقدمه

یکی از چالش‌های مهم در مدیریت منابع آب، پیش‌بینی بارش با دقت زیاد می‌باشد. اهمیت این مسئله در تأمین نیاز آبی گیاهان در فصول کشت آبی و دیم بسیار نمایان است؛ به طوری که اگر پیش‌بینی دقیقی از میزان بارش در ماه‌های دوره رشد گیاهان در دسترس دیم‌کاران باشد، برنامه‌ریزی دقیق‌تری برای انتخاب نوع کشت با توجه به میزان آب قابل دسترس می‌تواند انجام دهند. همچنین، با در نظرگیری میزان بارش هر ماه، برنامه‌ریزی دقیق‌تری جهت تخصیص آب برای کشاورزی آبی قابل انجام است. علی‌رغم اهمیت این مسأله، به علت تصادفی بودن متغیر بارش، پیش‌بینی آن فرآیندی احتمالاتی بوده و به سادگی امکان‌پذیر نیست. با توجه به این امر، پژوهش‌های متعددی برای پیش‌بینی بارش بلندمدت بر اساس متغیرهای اقلیمی صورت گرفته است؛ از آن جمله می‌توان به موارد زیر اشاره نمود:

پیش‌بینی میزان بارش سالانه در هفت ناحیه اقلیمی در کالیفرنیا در سال آبی (اکتبر تا سپتامبر) با استفاده از شبکه عصبی مصنوعی و بر اساس متوسط سالانه شاخص‌های اقلیمی SOI، NINO 1+2 و NINO 3.4 در دوره زمانی (ژانویه تا دسامبر) با تأخیر زمانی یک ساله (Silverman and Dracup, 2000)، پیش‌بینی بارش پاییزه در دامنه جنوبی البرز و استان‌های شمال غرب ایران با استفاده از متوسط تابستانه شاخص SOI (Nazemosadat and Cordery, 2000)، پیش‌بینی بارش پاییزه و زمستانه در جنوب غرب ایران بر اساس نوسانات دمای سطح آب خلیج فارس در این فصول (Nazemosadat, 2008)، پیش‌بینی بارش شش ماهه در خراسان بر اساس فشار سطح آب در بخش جنوبی خلیج فارس، اختلاف فشار سطح آب بخش جنوبی خلیج فارس با دریای آدریاتیک در ایتالیا، دریای عرب، دریای عمان و جنوب دریای سرخ (Fallah-Ghahary et al., 2009)، پیش‌بینی بارش پاییزه در حوضه دریاچه ارومیه با استفاده از متوسط تابستانه شاخص‌های SOI و NINO3.4 و با بکارگیری شبکه عصبی مصنوعی (Fatehi marj and Mahdian, 2009)، پیش‌بینی بارش زمستانه و پاییزه ایستگاه‌هایی در منطقه غرب ایران با استفاده از نوسانات دمای سطح آب دریای مدیترانه در پاییز و تابستان (Rezaei Banafsheh et al., 2010)، پیش‌بینی بلندمدت بارش در حوضه کارون واقع در جنوب غرب ایران با استفاده از شاخص‌های SOI، NAO و دما و فشار سطح آب خلیج فارس (Afshin et al., 2011)، پیش‌بینی بارش پاییزه در نواحی غرب و شمال غرب ایران و نیز سواحل غربی دریای خزر با استفاده از متوسط تابستانه شاخص SOI (Roghani et al., 2012)، پیش‌بینی بارش سالانه در حوضه رودخانه کلرادو در غرب ایالات متحده آمریکا بر اساس شاخص‌های اقلیمی AMO، NAO، PDO و

ENSO (Kalra and Ahmad, 2012)، پیش‌بینی بارش تابستانه و پاییزه در استرالیا با استفاده از شاخص‌های اقلیمی PDO و SOI (Schepen et al., 2012)، پیش‌بینی بارش پاییزه در زیرحوضه سیمره بر اساس متوسط تابستانه دو شاخص SOI و NINO3.4 (Modaresi et al., 2015). مطالعات فوق همگی نشان می‌دهند که شاخص‌های اقلیمی پیش‌بینی‌کننده‌های مناسبی برای پیش‌بینی بارش‌های فصلی و سالانه می‌باشند و در آنها برای پیش‌بینی بارش پاییزه از متوسط تابستانه شاخص‌های اقلیمی استفاده شده است ولی این شاخص‌ها به طور مستقیم برای پیش‌بینی بارش ماهانه مناسب نبوده و همبستگی معنی‌داری با بارش ماهانه نداشته‌اند.

در سال‌های اخیر، پژوهش‌هایی برای پیش‌بینی بارش ماهانه نیز صورت گرفته است؛ از آن جمله می‌توان به تحقیقات صورت گرفته برای پیش‌بینی بارش ماهانه بر اساس مدل‌های استوکستیک اشاره نمود. در این تحقیقات، از میزان بارش در ماه‌های قبل به عنوان متغیر پیش‌بینی‌کننده برای پیش‌بینی بارش در یک ماه بعد استفاده شده است؛ نظیر پیش‌بینی بارش ماهانه در هندوستان با استفاده از مدل آریمای فصلی (SARIMA) (Nirmala and Sundaram, 2010)، پیش‌بینی بارش ماهانه در حوضه دریاچه ارومیه با استفاده از مدل ARIMA و مقایسه آن با شبکه عصبی (Farjazadeh et al., 2014) که نشان دادند نتایج هر دو مدل به هم بسیار شبیه هستند، پیش‌بینی بارش ماهانه در ۳۰ ایستگاه در بنگلادش با استفاده از مدل SARIMA (Mahmud et al., 2017)، پیش‌بینی بارش ماهانه در هندوستان با استفاده از مدل ARIMA (Swain et al., 2018)؛ (Dayal et al., 2019).

علاوه بر مدل‌های استوکستیک، در برخی از تحقیقات برای پیش‌بینی بارش ماهانه از مدل‌های یادگیری ماشینی نظیر شبکه عصبی مصنوعی و ماشین بردار پشتیبان و ترکیب آنها با مدل‌های دیگر و نیز از طیف وسیعی از متغیرهای اقلیمی نظیر دمای هوا، سرعت باد، بارش در ماه‌های قبل به عنوان متغیرهای پیش‌بینی‌کننده استفاده شده است؛ از آن جمله، (Abbot and Marohasy, 2014) برای پیش‌بینی بارش ماهانه در یک تا سه ماه بعد در سه ایستگاه هواشناسی در استرالیا، از شبکه عصبی استفاده کرده و ترکیب‌های مختلفی از متغیرهای اقلیمی شامل بارش ماهانه و دمای حداقل و حداکثر ماهانه و نیز شاخص‌های اقلیمی SOI، DMI، IPO، NINO را مورد بررسی قرار دادند. نتایج آنها نشان داد که ترکیب یکسانی از متغیرها برای هر سه ایستگاه منجر به بهترین جواب نمی‌شود؛ همچنین، در یک ایستگاه نیز، ترکیب یکسانی از متغیرها برای پیش‌بینی بارش در هر سه ماه قابل استفاده نمی‌باشد و برای رسیدن به بهترین پیش‌بینی باید از ترکیب‌های

نظیر ماه‌های فصل پاییز، این روش قابل کاربرد نیست. با این وجود، پیش‌بینی بارش فصلی بر اساس شاخص‌های دورپیوند اقلیمی با دقت بالایی صورت گرفته است.

از این‌رو، رویکرد تحقیق حاضر، پیش‌بینی بارش ماهانه بر اساس بارش فصلی می‌باشد. مزایای این نوع رویکرد پیش‌بینی بارش ماهانه، اولاً: قابلیت پیش‌بینی بارش ماهانه برای ماه‌هایی است که قبل از آنها بارشی رخ نداده است؛ نظیر ماه مهر. ثانیاً: قابلیت پیش‌بینی بارش ماهانه برای هر سه ماه یک فصل به‌طور هم‌زمان است که این امر برای مدیریت زراعی و مدیریت منابع آب از اهمیت بالایی برخوردار می‌باشد. برای تحقق رویکرد پیشنهاد شده در تحقیق حاضر، یک مدل ترکیبی احتمالاتی کلاس مبنا (CPHM)^۱ توسعه داده شده و کارایی آن برای پیش‌بینی بارش ماهانه پاییزه در زیرحوضه بالادست سد کرخه که تأمین‌کننده مهم آب جلگه خوزستان می‌باشد، ارزیابی شده است. همچنین، از آنجایی که مدل شبکه عصبی مصنوعی یک مدل تقریب زنده همه منظوره است که برای حل انواع مسائل پیچیده خطی و غیرخطی از قابلیت بالایی برخوردار می‌باشد و در اکثر تحقیقات پیشین، مدل شبکه عصبی مصنوعی نتایج قابل قبولی ارائه کرده است (Farajzadeh et al., 2014; Abbot and Marohasy, 2014; Mozafari et al., 2016; Bahrami et al., 2017; Rahiminasab and Amerian, 2019). در تحقیق حاضر عملکرد مدل CPHM با یک مدل شبکه عصبی مصنوعی با ساختار بهینه شده نیز مورد مقایسه قرار گرفته است.

۲- مواد و روش‌ها

۲-۱- معرفی منطقه مطالعاتی

در تحقیق حاضر حوضه کرخه به عنوان منطقه مطالعاتی انتخاب شد. حوضه کرخه دارای دو سد اصلی در دست بهره‌برداری با نام‌های کرخه و سیمره است که سد کرخه در پایین دست سد سیمره قرار دارد. از این‌رو، حوضه کرخه را می‌توان به دو زیرحوضه بالادست سد سیمره و بالادست سد کرخه تقسیم‌بندی نمود. موقعیت قرارگیری این دو سد در شکل ۱ نشان داده شده است.

از آنجایی که زیر حوضه کرخه تأمین‌کننده آب جلگه حاصلخیز خوزستان است و کشت پاییزه در دشت خوزستان از اهمیت بالایی برخوردار می‌باشد، در این پژوهش، پیش‌بینی بارش ماهانه پاییزه برای زیرحوضه بالادست سد کرخه با مساحت ۱۴۴۳۰ کیلومتر مربع به عنوان مورد مطالعاتی در نظر گرفته شده است. بدین منظور، از آمار بارش ماهانه پاییزه ۹ ایستگاه باران‌سنجی و سینوپتیک متعلق به

متفاوتی از متغیرهای پیش‌بینی‌کننده استفاده شود. Mozafari et al. (2016) با استفاده از مدل ترکیبی شبکه عصبی و موجک و بکارگیری چهار متغیر اقلیمی میانگین ماهانه دمای حداکثر و حداقل، رطوبت نسبی و سرعت باد، میزان بارش یک ماه بعد در ایستگاه کرمانشاه را پیش‌بینی کردند و نتایج آنها در مقایسه با شبکه عصبی مصنوعی از دقت بهتری برخوردار بود. (Ouyang et al., 2016). نیز برای پیش‌بینی بارش ماهانه در یک ماه بعد از مدل ترکیبی EEMD-SVR بهره بردند و نتایج آنها در مقایسه با مدل ARMA, SVR و شبکه عصبی مصنوعی از دقت مناسب‌تری برخوردار بود. Bahrami et al. (2017) با استفاده از متغیرهای میانگین بارش ماهانه، کمترین و بیشترین دما و نیز میزان رطوبت نسبی و با استفاده از شبکه عصبی مصنوعی بارش یک ماه بعد را برای ایستگاه سینوپتیک آباده واقع در استان فارس پیش‌بینی کردند. نتایج آنها نشان داد که شبکه عصبی سه لایه با دو متغیر ورودی کمترین دما و رطوبت بهترین نتایج را در شرایط کمبود داده ایجاد می‌کند. (Solgi and Zarei, 2018) با استفاده از سه متغیر متوسط ماهانه بارش، دما و رطوبت نسبی در دو ماه قبل، مقدار بارش ماهانه در ماه بعد را در ایستگاه وراینه شهرستان دماوند پیش‌بینی کردند و از مدل‌های برنامه‌ریزی بیان ژن و ماشین بردار پشتیبان بهره بردند و نتایج آنها نشان داد که مدل برنامه‌ریزی بیان ژن از کارایی بالاتری برخوردار است. Rahiminasab and Amerian (2019) با استفاده از ترکیب شبکه عصبی و فیلتر کالمن بارش متوسط ماهانه را برای اقلیم‌های مختلف ایران با استفاده از متغیرهای میانگین دمای ماهانه و سرعت باد ماهانه در هر اقلیم پیش‌بینی کردند و دقت نتایج آنها برای اقلیم‌های بسیار گرم بهتر از سایر اقلیم‌ها بدست آمد. همچنین، Danandeh Mehr et al. (2019) برای پیش‌بینی بارش ماهانه یک ماه بعد در ایستگاه‌های ارومیه و تبریز از مدل ترکیبی رگرسیون بردار پشتیبان و الگوریتم بهینه‌سازی کرم شبتاب بهره گرفتند و دقت نتایج آنها نسبت به مدل SVR به‌طور معنی‌داری افزایش یافت.

با توجه به مطالعات صورت گرفته فوق، مشاهده می‌شود که پیش‌بینی بارش ماهانه فرآیندی پیچیده است به نحوی که متغیرهای پیش‌بینی‌کننده آن از یک سو، از نقطه‌ای به نقطه دیگر متفاوت بوده و از سوی دیگر، نوع متغیرهای پیش‌بینی‌کننده از هر ماه به ماه دیگر متفاوت است (Abbot and Marohasy, 2014). همچنین، با بکارگیری طیف وسیعی از متغیرها در چندین ماه، اکثر محققان توانسته‌اند بارش را برای یک ماه بعد پیش‌بینی کنند. علاوه بر این، در مدل‌های استوکستیک از بارش یک یا چند ماه قبل برای پیش‌بینی بارش در ماه بعد استفاده شده است؛ ایراد این نوع پیش‌بینی بارش ماهانه در این است که برای ماه‌هایی که قبل از آنها بدون بارش است،

وزارت نیرو (۸ ایستگاه) و سازمان هواشناسی (۱ ایستگاه) واقع در زیرحوضه مطالعاتی در بازه زمانی ۳۲ ساله (۱۳۶۱-۱۳۹۳) استفاده گردید (موقعیت جغرافیایی ایستگاه‌ها در شکل ۱ نشان داده شده است) که ۲۲ سال آن (۱۳۶۱-۱۳۸۲) برای واسنجی و ۱۰ سال دیگر (۱۳۸۳-۱۳۸۳) برای صحت‌سنجی بکار برده شد. روند تغییرات سالانه بارش پاییزه در بازه زمانی مطالعاتی در شکل ۲ و شاخص‌های آماری (میانگین و انحراف معیار) توزیع ماهانه بارش پاییزه در این دوره زمانی در شکل ۳ نشان داده شده است.

وزارت نیرو (۸ ایستگاه) و سازمان هواشناسی (۱ ایستگاه) واقع در زیرحوضه مطالعاتی در بازه زمانی ۳۲ ساله (۱۳۶۱-۱۳۹۳) استفاده گردید (موقعیت جغرافیایی ایستگاه‌ها در شکل ۱ نشان داده شده است) که ۲۲ سال آن (۱۳۶۱-۱۳۸۲) برای واسنجی و ۱۰ سال دیگر (۱۳۸۳-۱۳۸۳) برای صحت‌سنجی بکار برده شد. روند تغییرات سالانه بارش پاییزه در بازه زمانی مطالعاتی در شکل ۲ و شاخص‌های آماری (میانگین و انحراف معیار) توزیع ماهانه بارش پاییزه در این دوره زمانی در شکل ۳ نشان داده شده است.

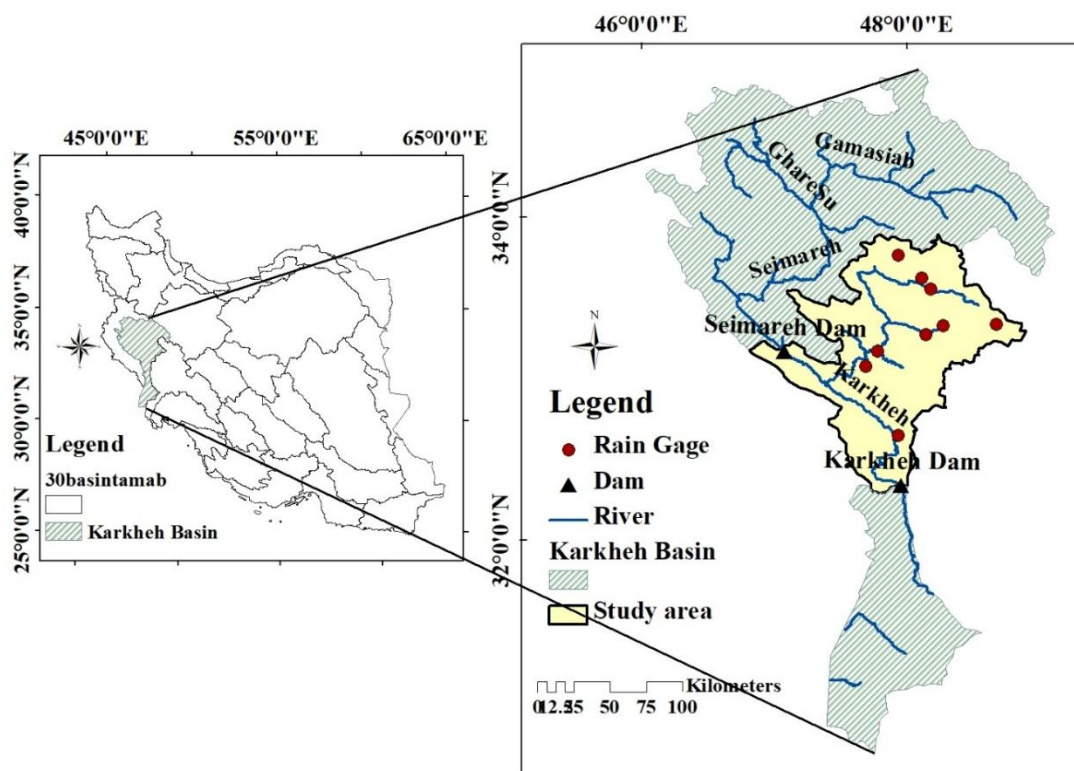


Fig. 1- The geographic location of the study area and the spatial distribution of the rain stations

شکل ۱- موقعیت جغرافیایی منطقه مطالعاتی و توزیع مکانی ایستگاه‌های بارش آن




Fig. 2- Annual variation of autumn precipitation in the study area for the period of 1982-2014

شکل ۲- روند تغییرات سالانه بارش پاییزه در منطقه مطالعاتی در بازه زمانی (۱۳۶۱-۱۳۹۳)




Fig. 3- Statistical criteria of the autumnal monthly precipitation in the study area for the period of 1982-2014

شکل ۳- شاخص‌های آماری توزیع ماهانه بارش پاییزه در منطقه مطالعاتی در بازه زمانی (۱۳۹۳-۱۳۶۱)

۲- تعیین احتمال متوسط رخداد بارش هر ماه در هر کلاس از بارش فصلی با استفاده از مقادیر بارش ماهانه مشاهداتی بر اساس تابع کرنل زیر:

$$Pr_{i,j} = \frac{\sum_{k=1}^{n_j} \frac{mp_{i,k}}{sp_k}}{n_j} \quad i=1,2,3, \quad j=1,2,3 \quad (2)$$

در رابطه ۲، $Pr_{i,j}$: احتمال متوسط رخداد بارش ماهانه ماه i ام در کلاس j ام بارش فصلی، $mp_{i,k}$: مقادیر بارش ماهانه در ماه i ام در سال‌های قرارگرفته در کلاس j ام بارش فصلی، n_j : تعداد سال‌های دربرگیرنده کلاس j ام بارش فصلی و sp_k : مقادیر بارش فصلی در سال‌های قرار گرفته در کلاس j ام می‌باشد.

با توجه به اینکه معادله (۲) یک تابع کرنل و نشان‌دهنده احتمالات بارش ماهانه برای یک فصل خاص می‌باشد، مجموع احتمالات بارش سه ماه در هر کلاس j برابر با ۱ است؛ به عبارت دیگر رابطه زیر برقرار می‌باشد:

$$Pr_{1,j} + Pr_{2,j} + Pr_{3,j} = 1 \quad (3)$$

۱- تعیین کلاس بارش‌های فصلی دوره پیش‌بینی براساس محدوده کلاس‌های ارائه شده در رابطه (۱)

۲- پیش‌بینی مقادیر بارش ماهانه در هر ماه از فصل مورد نظر، با استفاده از معادله زیر:

$$pmp_i = Pr_{i,j} \times psp_j, \quad i=1,2,3 \quad (4)$$

در معادله (۴)، pmp_i : بارش ماهانه پیش‌بینی شده در ماه i ام، $Pr_{i,j}$: احتمال بارش ماه مورد نظر در کلاس قرارگیری بارش فصلی (پیش‌بینی شده) و psp_j : بارش فصلی (پیش‌بینی شده) است که بر اساس طبقه‌بندی رابطه (۱)، در کلاس j ام قرار گرفته است.

۲-۲- مدل ترکیبی احتمالاتی کلاس مبنای (CPHM) برای پیش‌بینی بارش ماهانه بر اساس بارش فصلی

مدل CPHM که در تحقیق حاضر توسعه داده شده است، دارای یک الگوریتم چهار مرحله‌ای بر مبنای ترکیب روش‌های طبقه‌بندی و توابع کرنل احتمالاتی می‌باشد. این مدل برای پیش‌بینی بارش ماهانه بر اساس بارش فصلی ارائه شده است. همان‌طور که پیش‌تر بیان شد، اهمیت بکارگیری این مدل از دو جنبه می‌باشد:

الف: پیش‌بینی هم‌زمان بارش ماهانه برای هر سه ماه یک فصل بر اساس مقدار بارش فصلی بجای پیش‌بینی ماه به ماه بر اساس بارش ماه‌های پیشین که این امر در زمینه برنامه‌ریزی‌های منابع آب جهت تخصیص آب از اهمیت بالایی برخوردار است؛

ب: کارایی آن در پیش‌بینی بارش ماهانه برای ماه‌هایی که در ماه‌های قبل از آنها بارش رخ نداده است؛ نظیر ماه‌های ابتدایی فصل پاییز.

الگوریتم اجرای این مدل به صورت زیر می‌باشد:

۱- طبقه‌بندی بارش فصلی بر اساس مقادیر مشاهداتی بلندمدت به سه کلاس خشک، نرمال و تر. برای مجموعه SP از بارش فصلی با N داده در یک فصل خاص نظیر پاییز، محدوده کلاس‌ها از رابطه (۱) محاسبه می‌شود:

$$D = \frac{\text{Max}(SP) - \text{Min}(SP)}{3} \rightarrow$$

$$\begin{cases} \text{Dry Class: } [\text{Min}(SP), \text{Min}(SP)+D] \\ \text{Normal Class: } [\text{Min}(SP)+D, \text{Min}(SP)+2D] \\ \text{Wet Class: } [\text{Min}(SP)+2D, \text{Max}(SP)] \end{cases} \quad (1)$$

۳-۲- مدل شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی یک روش تخمین‌زننده همه منظوره است که برای نگاشت انواع توابع پیچیده خطی و غیرخطی قابل استفاده می‌باشد. شبکه عصبی مصنوعی از دسته روش‌های هوش مصنوعی است که از روش آموزش با ناظر برای یادگیری روابط میان متغیرها بهره می‌گیرد و رابطه پارامتری خاصی را ارائه نمی‌دهد.

یک شبکه عصبی مجموعه‌ای از نورون‌ها است که در لایه‌های مختلف با معماری خاصی در کنار یکدیگر قرار گرفته‌اند. معادله درون هر نورون به صورت زیر می‌باشد:

$$a=f(wx+b) \quad (5)$$

در معادله (۵)، x : ورودی به نورون، w : وزن مربوط به این ورودی، b : بایاس، f : تابع واکنش و a : خروجی از نورون است. تابع واکنش f تابعی است که بر اساس نوع الگوریتم یادگیری برای هر نورون تعریف می‌شود و می‌تواند از نوع خطی^۲، خطی اشباع کننده متقارن^۳، لوگ زیگموئید^۴ و تانژانت زیگموئید^۵ باشد.

یک شبکه عصبی شامل یک لایه ورودی و یک لایه خروجی و یک یا چند لایه میانی می‌باشد. تعداد نورون‌های لایه اول و آخر به ترتیب برابر با تعداد متغیرهای مستقل ورودی به مدل (در این پژوهش، بارش پاییزه) و تعداد متغیرهای خروجی (در این پژوهش، بارش هر ماه) می‌باشد. تعداد نورون‌های لایه‌های میانی انعطاف شبکه در میزان دقت پیش‌بینی را کنترل می‌کند و روش مستقیمی برای تخمین تعداد نورون‌های لایه میانی وجود ندارد. باید توجه داشت که اگرچه افزایش تعداد نورون‌های پنهان نتایج مثبت بسیاری به همراه دارد ولی باعث کاهش سرعت یادگیری شبکه و در برخی موارد، کاهش قدرت تعمیم‌دهی آن می‌شود.

قضیه تقریب‌ساز عمومی ثابت می‌کند که شبکه‌های عصبی با یک لایه مخفی، با توابع تبدیل زیگموئیدی در لایه میانی و توابع تبدیل خطی در لایه خروجی قادر به تقریب تمامی توابع مورد نظر با هر درجه تقریب خواهند بود مشروط بر اینکه به اندازه کافی نورون در لایه مخفی وجود داشته باشد (Menhaj, 2017). با توجه به این قضیه، در این پژوهش از یک شبکه عصبی سه لایه با ساختار اتصال کامل^۶ و پیش‌رو^۷ استفاده شده است. اتصال کامل بدین معناست که هر نورون در یک لایه به تمامی نورون‌های لایه بعد متصل شده و پیش‌رو به معنای حرکت یک طرفه از ورودی به سوی خروجی است.

علاوه بر معماری شبکه، الگوریتم آموزش آن نیز در میزان خطا و دقت شبکه در ارائه نتایج نقش دارد. از رایج‌ترین الگوریتم‌های آموزش شبکه‌های عصبی مصنوعی می‌توان الگوریتم انتشار خطای پس‌رو (BP)^۸ را نام برد که در اکثر مدل‌سازی‌ها بر مبنای شبکه عصبی بکار برده شده است (Coulibaly et al., 2000)؛ از این‌رو، در تحقیق حاضر این الگوریتم برای آموزش شبکه عصبی بکار رفته است. در الگوریتم پس‌رو، سیگنال خطا در خروجی نورون زام واقع در لایه خروجی در

$$e_j(K) = t_j(K) - Z_j(K) \quad (6)$$

تکرار K ام آموزش شبکه $(e_j(K))$ از معادله زیر به دست می‌آید: در معادله فوق، $Z_j(K)$: متغیر زام در خروجی متناظر با بردار ورودی $X(K)$ می‌باشد. K نشان‌دهنده تعداد تکرارها (epoch) برای یادگیری مجموعه‌ای از زوج‌ها است. در این الگوریتم با معرفی نمونه‌های مختلفی از ورودی و خروجی به شبکه، برای دستیابی به خروجی‌های مطلوب شبکه، تابع خطای زیر حداقل می‌شود:

$$E = 1/2 \sum_{p=1}^Q e_p^2 \quad (7)$$

در معادله (۷)، E : تابع خطای شبکه، e_p : مجموع سیگنال خطای تمامی نورون‌های خروجی به ازای زوج آموزشی p ام و Q نشان‌دهنده تعداد زوج‌های آموزشی می‌باشد.

یکی از عوامل اثرگذار بر دقت نتایج حاصل از مدل‌سازی با شبکه عصبی در الگوریتم BP، انتخاب وزن و بایاس اولیه اتصال نورون‌های لایه‌های مختلف به یکدیگر است. بنابراین، در مدل شبکه عصبی بکار رفته در تحقیق حاضر، تعداد بهینه نورون‌های لایه میانی (n) و مقادیر بهینه وزن‌ها (w) و بایاس (b) های اولیه اتصالات نورون‌ها از طریق کدنویسی در نرم‌افزار متلب و ایجاد حلقه‌های تو در تو برای سنجش تمامی مقادیر ممکن، محاسبه شده است.

۲-۲- شاخص‌های ارزیابی نتایج

برای ارزیابی و مقایسه کارایی مدل‌های بکار رفته در این تحقیق از سه شاخص ارزیابی نش- ساتکلیف (NSE)، جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی پیرسون (PCC) استفاده شد که به ترتیب در روابط ۸، ۹ و ۱۰ ارائه شده است (Moriasi et al., 2007):

$$NSE = 1 - \frac{\sum_{t=1}^N (P_t - \hat{P}_t)^2}{\sum_{t=1}^N (P_t - \bar{P})^2} \quad (8)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^N (P_t - \hat{P}_t)^2}{N}} \quad (9)$$

۳- نتایج و بحث

نحوه تغییرات سالانه بارش متوسط ماهانه در ماه‌های فصل پاییز در زیرحوضه مطالعاتی در طی بازه زمانی ۳۲ ساله مطالعاتی (۱۳۹۳-۱۳۶۱) در شکل ۴ نشان داده شده است.

با توجه به شکل ۴ مشاهده می‌شود که نحوه تغییرات بارش ماهانه در ماه‌های فصل پاییز طی سال‌های مورد مطالعه، منظم نیست؛ بدین معنا که نحوه افزایش و کاهش آنها در طول یکسال و نیز در سال‌های متوالی همسو نمی‌باشد. از این‌رو، پیش‌بینی بارش هر ماه بر اساس ماه‌های قبل و حتی ماه‌های متناظر در سال‌های قبل، بر اساس الگوریتم‌های پیش‌بینی یک ماه بعد با دقت بالا امکان‌پذیر نبوده و رویکرد پیشنهاد شده در این تحقیق که به صورت پیش‌بینی بارش ماهانه بر اساس بارش فصلی است، می‌تواند راهکار مناسبی برای افزایش دقت پیش‌بینی بارش ماهانه پاییزه در حوضه مطالعاتی باشد.




Fig. 4- Annual variations of monthly average precipitation for the study subbasin in Autumn

شکل ۴- تغییرات سالانه بارش متوسط ماهانه زیرحوضه مطالعاتی در پاییز

Table 1- Range of autumn Precipitation classes

جدول ۱- محدوده کلاس‌های بارش پاییزه	
Dry	<144.917
Normal	144.917--- 261.996
Wet	261.996<

بر اساس محدوده کلاس‌های نشان داده شده در جدول ۱، بارش پاییزه در دوره واسنجی طبقه‌بندی شده و تابع توزیع احتمالاتی رخداد بارش

$$PCC = \frac{\sum_{t=1}^N (P_t - \bar{P})(\hat{P}_t - \bar{\hat{P}})}{\sqrt{\sum_{t=1}^N (P_t - \bar{P})^2} \cdot \sqrt{\sum_{t=1}^N (\hat{P}_t - \bar{\hat{P}})^2}} \quad (10)$$

در روابط فوق، P_t و \hat{P}_t به ترتیب بارش ماهانه مشاهداتی و تخمین زده شده (پیش‌بینی شده) در زمان t ، \bar{P} و $\bar{\hat{P}}$ به ترتیب میانگین بارش ماهانه مشاهداتی و تخمین زده شده و N تعداد داده‌ها می‌باشد. دامنه تغییرات شاخص نش- ساتکلیف از منفی بی‌نهایت تا یک می‌باشد. هرچه مقدار این شاخص به یک نزدیک‌تر باشد، خطای مدل کمتر است. شاخص RMSE از صفر تا بی‌نهایت تغییر می‌کند. هر چه مقدار این شاخص به صفر نزدیک‌تر باشد، نشان‌دهنده خطای کمتر و کارایی بهتر مدل می‌باشد. مقدار شاخص PCC در دامنه -۱ تا ۱ تغییر می‌کند. مقدار ۱ و -۱ به ترتیب نشان‌دهنده همبستگی کامل مستقیم و معکوس مقادیر مشاهداتی و پیش‌بینی شده می‌باشد. همچنین، مقدار صفر این شاخص نشان می‌دهد که مقادیر مشاهداتی و پیش‌بینی شده هیچ‌گونه همبستگی خطی معنی‌داری ندارند. بنابراین، هر چه مقدار این شاخص به یک نزدیک‌تر باشد، کارایی مدل بهتر است و تغییرات مقادیر مشاهداتی و تخمین زده شده همسو می‌باشد.

۳-۱- نتایج پیش‌بینی بارش ماهانه بر اساس مدل CPHM

برای ارزیابی مدل CPHM، از داده‌های ۲۲ و ۱۰ سال به ترتیب برای آموزش (واسنجی) و صحت‌سنجی استفاده گردید. به منظور اجرای مدل CPHM، ابتدا بر اساس داده‌های بخش واسنجی، محدوده کلاس‌های خشک، نرمال و مرطوب برای بارش پاییزه به صورت زیر تعیین شد:

صحت‌سنجی در هر یک از سه کلاس خشک، نرمال و مرطوب نشان داده شده است. همان‌طور که در شکل ۶ مشاهده می‌شود، در هر یک از دوره‌های واسنجی و صحت‌سنجی، بارش پاییزه تنها در یک سال در محدوده تر قرار گرفته است و در سایر سال‌ها در محدوده نرمال و خشک قرار دارد که توالی قرارگیری بارش در این دو کلاس نیز از نظم خاصی پیروی نمی‌کند؛ به طوری که در برخی از سال‌ها، چندسال متوالی در یک کلاس قرار دارد نظیر سال‌های ۱۳۷۰ تا ۱۳۷۲ در محدوده نرمال و سال‌های ۱۳۸۳ تا ۱۳۸۴ که در محدوده خشک قرار دارند و در برخی دیگر از سال‌ها، توالی خشک و نرمال وجود دارد نظیر سال‌های ۱۳۶۶ تا ۱۳۷۰.

پس از تعیین کلاس‌های بارش پاییزه در دوره صحت‌سنجی، با استفاده از معادله ۴، مقادیر بارش ماهانه برای هر سال محاسبه شد. در جدول ۲ میزان خطای نتایج حاصل از مدل CPHM در دوره صحت‌سنجی برای پیش‌بینی بارش ماهانه پاییزه آورده شده است. همچنین، در شکل ۷، مقادیر بارش ماهانه پیش‌بینی شده در مقایسه با بارش ماهانه مشاهداتی برای هر یک از سه ماه مهر، آبان و آذر ترسیم شده است.

Table 2- Results of autumn monthly precipitation prediction in validation phase based on CPHM model

جدول ۲- نتایج پیش‌بینی بارش ماهانه پاییزه در دوره صحت‌سنجی بر اساس مدل CPHM

Month	Assessment Criteria		
	NSE	RMSE	PCC
October	0.723	4.990	0.906
November	0.700	17.062	0.845
December	0.689	14.028	0.834

ماهانه در هر یک از کلاس‌های رطوبتی بر اساس تابع کرنل ارائه شده در معادله ۲ محاسبه شد. توزیع احتمالاتی کلاس‌های خشک، نرمال و مرطوب در طول سه ماه فصل پاییز در شکل ۵ آورده شده است.

با توجه به شکل ۵ مشاهده می‌شود که توزیع احتمالاتی کلاس‌های خشک، نرمال و تر در سه ماه فصل پاییز با یکدیگر متفاوت است؛ به طوری که در کلاس‌های خشک و نرمال، احتمال رخداد بارش در ماه آذر بیشتر از آبان و در آبان بیشتر از مهر است. ولی در کلاس مرطوب، احتمال رخداد بارش در آبان ماه اندکی بیشتر از آذر ماه و در آذرماه بیشتر از مهرماه است. همچنین، مقایسه احتمالات سه کلاس در هر یک از ماه‌ها نشان می‌دهد که در ماه مهر، احتمال رخداد بارش به ترتیب از کلاس خشک به مرطوب در حال افزایش است. ولی در ماه آبان، احتمال رخداد بارش در کلاس نرمال کمتر از کلاس خشک است؛ با این وجود، احتمال رخداد بارش در کلاس مرطوب در این ماه بیشتر از دو کلاس دیگر است. اما در ماه آذر بر خلاف مهر، احتمال رخداد بارش‌ها از کلاس تر به خشک افزایش می‌یابد.

به بیان دیگر، با توجه به شکل ۵ می‌توان گفت در شرایطی که بارش پاییزه در کلاس‌های خشک و نرمال قرار می‌گیرد، بیش از ۵۵٪ کل بارش پاییزه در ماه آذر، بیش از ۳۵٪ بارش در ماه آبان و کمتر از ۱۰٪ بارش در ماه مهر رخ می‌دهد؛ ولی در زمان قرارگیری بارش پاییزه در کلاس تر، شرایط متفاوت است؛ به طوری که حدود ۴۳٪ از کل بارش پاییزه متعلق به هر یک از دو ماه آبان و آذر (در مجموع ۸۵٪) و حدود ۱۵٪ از آن متعلق به ماه مهر است.

در مرحله سوم، بارش پاییزه در دوره صحت‌سنجی کلاس‌بندی شد. در شکل ۶، محدوده قرارگیری بارش پاییزه در دوره‌های واسنجی و

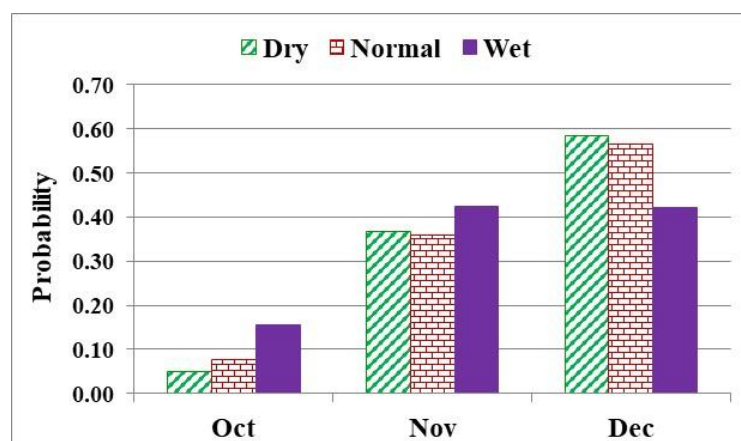


Fig. 5- Probability distribution functions of the moisture classes in months of autumn

شکل ۵- توابع توزیع احتمالاتی کلاس‌های رطوبتی بارش در ماه‌های فصل پاییز




Fig. 6- Classification of autumn rainfall in calibration and validation period

شکل ۶- کلاس بندی بارش پاییزه در دوره ۱۰ ساله صحت سنجی

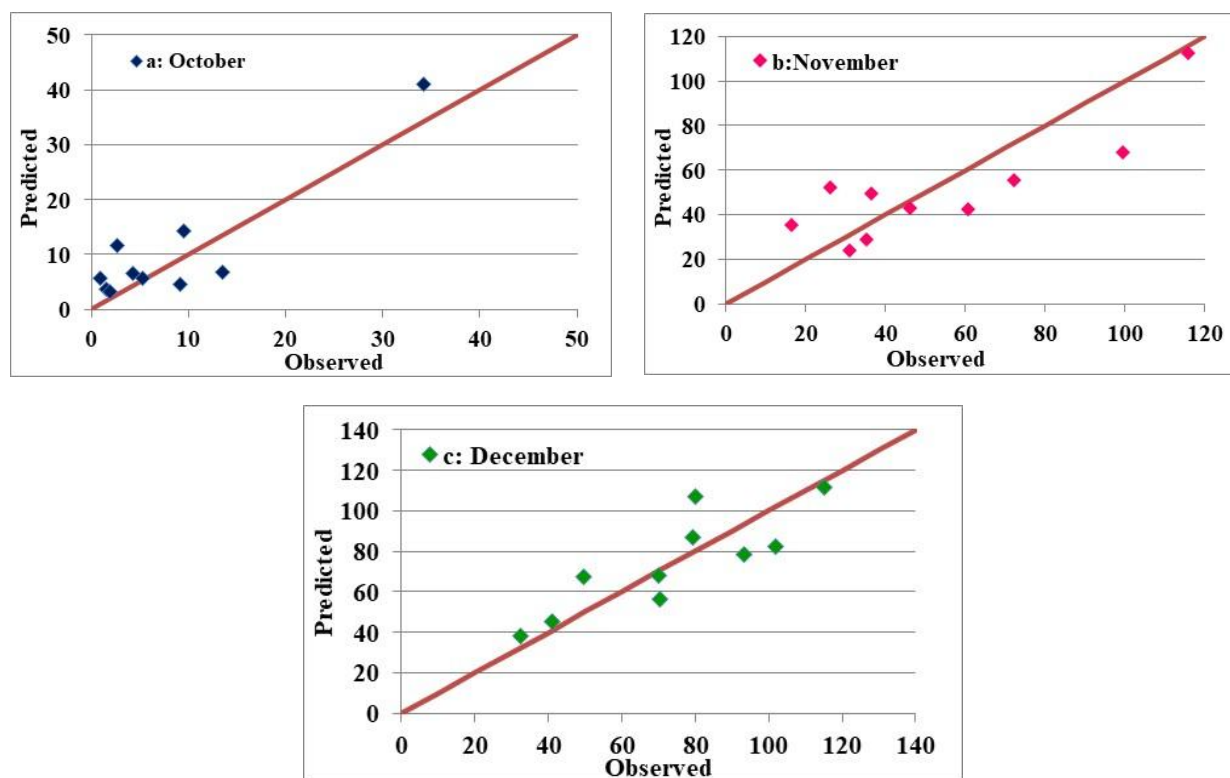


Fig. 7- Predicted monthly precipitation in validation phase based on CPHM model (a:Oct, b:Nov, c:Dec)

شکل ۷- بارش ماهانه پیش بینی شده در دوره صحت سنجی بر اساس مدل CPHM (الف: مهر، ب: آبان، ج: آذر)

مدل CPHM بر مبنای شاخص NSE در هر سه ماه در طبقه "خوب" قرار دارد. کارایی نتایج این مدل بر اساس شاخص RMSE در ماه مهر در طبقه "بسیار خوب" و در دو ماه آبان و آذر در طبقه "خوب" قرار دارد. همچنین، بر اساس شاخص PCC، کارایی مدل در ماه مهر در طبقه "خوب" و در دو ماه آبان و آذر در طبقه "مناسب" قرار دارد.

با توجه به جدول ۲ و شکل ۷ مشاهده می شود که نتایج حاصل از بکارگیری مدل CPHM برای پیش بینی بارش ماهانه پاییزه در هر سه ماه مهر، آبان و آذر از دقت بالایی برخوردار است؛ به طوری که بر اساس طبقه بندی های ارائه شده توسط Diaz-Ramirez et al. (2011) و Moriasi et al. (2007) که در جدول ۳ آورده شده است، کارایی

Table 3- Model efficiency classification based on efficiency criteria

جدول ۳- طبقه‌بندی کارایی مدل‌ها بر اساس شاخص‌های ارزیابی

Efficiency Criteria			Efficiency Class
PCC	RMSE	NSE	
$0.93 < PCC < 1.0$	$0 \leq RMSE \leq 0.5SD^*$	$0.75 < NSE \leq 1$	Very Good
$0.88 < PCC < 0.92$	$0.5SD < RMSE \leq 0.6SD$	$0.65 < NSE \leq 0.75$	Good
$0.81 < PCC < 0.87$	$0.6SD < RMSE \leq 0.7SD$	$0.5 < NSE \leq 0.65$	Appropriate
$PCC < 0.8$	$RMSE > 0.7SD$	$NSE \leq 0.5$	Inappropriate

*SD= Standard Deviation of data

سه ماه مهر، آبان و آذر در دوره صحت‌سنجی بر اساس بهترین مدل شبکه عصبی مصنوعی نشان داده شده است.

با توجه به جدول ۴ مشاهده می‌شود که ساختار بهینه مدل در سه ماه مورد بررسی با یکدیگر متفاوت است. نتایج این جدول نشان می‌دهد که مدل شبکه عصبی مصنوعی با ساختار بهینه به خوبی آموزش دیده است و نتایج آن در مراحل واسنجی و صحت‌سنجی از دقت مناسبی برخوردار است؛ به طوری که بر اساس طبقه‌بندی موجود در جدول ۳ می‌توان دریافت که دقت نتایج در هر دو مرحله واسنجی و صحت‌سنجی بر مبنای هر دو شاخص NSE و RMSE در هر سه ماه در طبقه "خوب" و بر اساس شاخص PCC در طبقه "مناسب" قرار دارد.

اگرچه نتایج شبکه عصبی مصنوعی بر اساس جدول ۴ از دقت مناسبی برخوردار است، ولی بررسی مقادیر خروجی این مدل بر مبنای شکل ۸ نشان می‌دهد که مدل شبکه عصبی ANN دارای مقدار خروجی منفی در مرحله صحت‌سنجی برای بارش مهرماه است که با توجه به مثبت بودن مقدار بارش، مقداری غیرقابل قبول برای متغیر بارش می‌باشد و به عنوان ضعف نتایج این مدل به شمار می‌آید.

۲-۳- نتایج پیش‌بینی بارش ماهانه بر اساس مدل شبکه عصبی مصنوعی (ANN)

برای پیش‌بینی بارش ماهانه پاییزه با استفاده از شبکه عصبی مصنوعی، مقادیر بارش پاییزه به عنوان متغیر ورودی و مقادیر بارش هر یک از سه ماه به عنوان متغیر خروجی به مدل معرفی شد و برای هر یک از سه ماه، مدل‌های جداگانه‌ای ایجاد گشت. هر یک از سه مدل با ۲۲ (۷۰٪) و ۱۰ (۳۰٪) داده‌ها (مشابه مدل CPHM) به ترتیب واسنجی و صحت‌سنجی شدند.

به منظور تعیین بهترین ساختار (بهترین تعداد نورون لایه میانی (n) و بهترین وزن و بایاس اولیه برای اتصال نورون‌ها (w, b)) برای مدل شبکه عصبی، ۹۰ مدل شبکه عصبی بر اساس تمامی ترکیب‌های مختلف از مقادیر وزن و بایاس و تعداد نورون برای هر ماه ایجاد و ارزیابی شد. نتایج ارزیابی مدل شبکه عصبی مصنوعی بر اساس سه شاخص NSE، RMSE و PCC در مراحل واسنجی و صحت‌سنجی همراه با مشخصات ساختار بهینه مدل برای پیش‌بینی بارش ماهانه در جدول ۴ آورده شده است. همچنین، در شکل ۸ مقادیر بارش ماهانه پیش‌بینی شده در مقایسه با بارش ماهانه مشاهداتی برای هر یک از

Table 4- Results of autumn monthly precipitation prediction in calibration and validation phases based on ANN modeling with best structure

جدول ۴- نتایج پیش‌بینی بارش ماهانه پاییزه در دوره‌های واسنجی و صحت‌سنجی بر اساس مدل‌سازی شبکه عصبی با بهترین ساختار

Phase	Month	Assessment Criteria			Best parameters	
		Nash	RMSE	PCC	w, b	n
Calibration	October	0.661	9.200	0.813	0.8	9
	November	0.669	21.768	0.820	0.5	9
	December	0.711	25.050	0.845	0.9	8
Validation	October	0.692	5.258	0.865	0.8	9
	November	0.667	17.976	0.868	0.5	9
	December	0.663	14.607	0.848	0.9	8

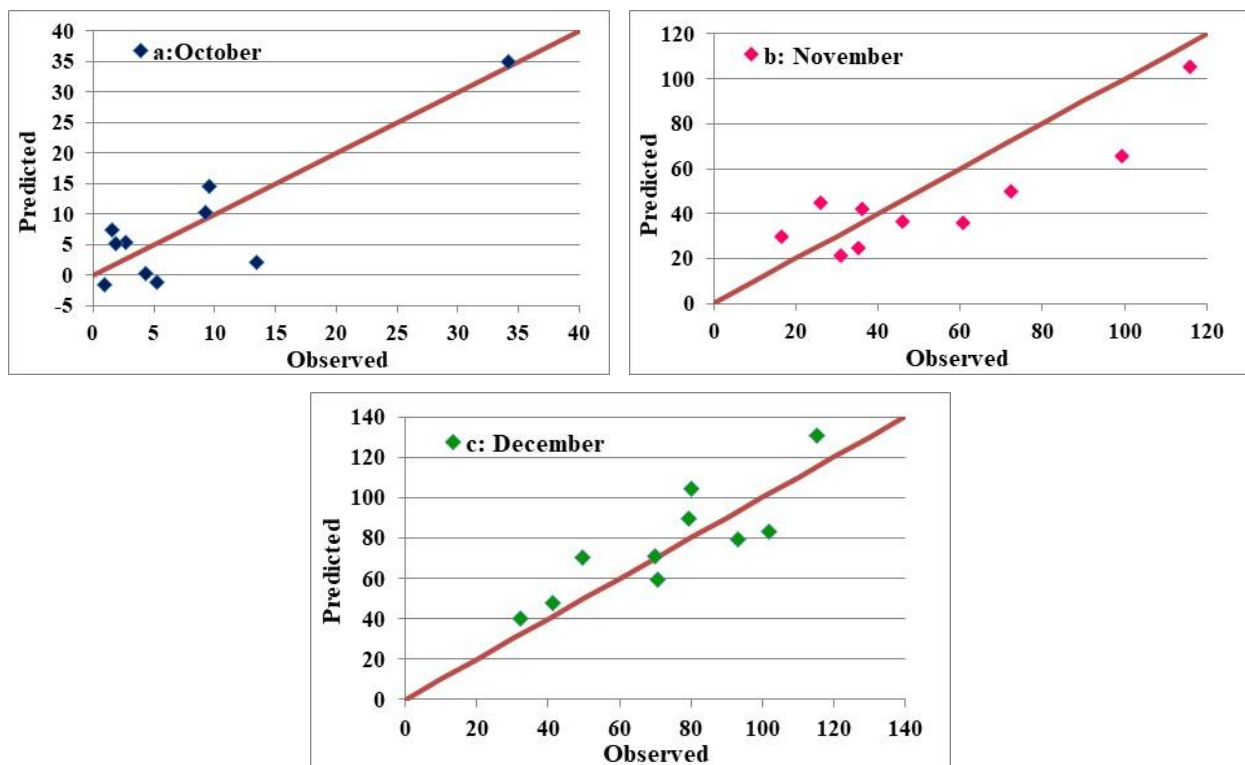


Fig. 8- Predicted monthly precipitation in validation Phase using ANN modeling (a:Oct, b:Nov, c:Dec)

شکل ۸- بارش ماهانه پیش‌بینی شده در دوره صحت‌سنجی بر اساس مدل‌سازی با شبکه عصبی مصنوعی با بهترین ساختار (الف: مهر، ب: آبان، ج: آذر)

مشخص در نتایج ماه مهر قابل مشاهده است؛ به طوری که مقدار بارش تخمین زده شده توسط مدل ANN در مرحله صحت‌سنجی در سال‌های ۱۳۸۳ و ۱۳۹۰ و در مرحله واسنجی در سال ۱۳۷۴ عددی منفی و غیرقابل قبول برای متغیر بارش می‌باشد. در حالی که مقادیر تخمین زده شده توسط مدل CPHM در هر سه ماه و در تمامی سال‌ها در دوره‌های واسنجی و صحت‌سنجی عددی مثبت و قابل قبول است.

با توجه به اینکه مدل ANN یک مدل جعبه سیاه است و بخش‌هایی از ساختار درون آن قابل کنترل توسط کاربران نیست و نتایج بدست آمده در این تحقیق نیز حاصل از یک ساختار بهینه برای شبکه عصبی مصنوعی می‌باشد، می‌توان گفت که بکارگیری مدل‌های شبکه عصبی ANN بدون ساختار بهینه منجر به نتایجی با دقت کمتر از نتیجه بدست آمده در این تحقیق می‌شود. از این رو، بکارگیری مدل ترکیبی احتمالاتی CPHM که دارای ساختاری کاملاً مشخص و واضح برای کاربران است، در مقایسه با شبکه عصبی مصنوعی، گزینه مناسب‌تری برای پیش‌بینی بارش ماهانه بر اساس بارش فصلی برای فصل پاییز است.

۳-۳- مقایسه نتایج پیش‌بینی بارش ماهانه پاییزه توسط مدل CPHM و مدل شبکه عصبی مصنوعی (ANN)

بر اساس نتایج حاصل از مدل CPHM و مدل شبکه عصبی مصنوعی ANN برای پیش‌بینی بارش ماهانه پاییزه در مرحله صحت‌سنجی (جدول‌های ۲ و ۴) می‌توان گفت که در هر سه ماه، دقت نتایج حاصل از مدل CPHM بر اساس هر سه شاخص ارزیابی RMSE، NSE و PCC بیشتر از مدل شبکه عصبی مصنوعی ANN می‌باشد. به منظور ارزیابی و مقایسه دقیق‌تر نتایج حاصل از دو مدل CPHM و ANN، در شکل ۹ مقادیر بارش ماهانه پیش‌بینی شده حاصل از دو روش در مقایسه با مقادیر بارش مشاهداتی در دوره‌های واسنجی (۱۳۶۱-۱۳۸۲) و صحت‌سنجی (۱۳۸۳-۱۳۹۲) برای ماه‌های مهر، آبان و آذر مورد ارزیابی قرار گرفته است.

با توجه به شکل ۹ مشاهده می‌شود که در هر سه ماه، روند تغییرات مقادیر بارش ماهانه پیش‌بینی شده توسط هر دو مدل CPHM و ANN در هر دو دوره واسنجی و صحت‌سنجی مشابه می‌باشد. با این وجود، بررسی‌های نقطه به نقطه نشان می‌دهد که در اکثر موارد دقت نتایج حاصل از مدل CPHM بیشتر از ANN است. این امر به طور

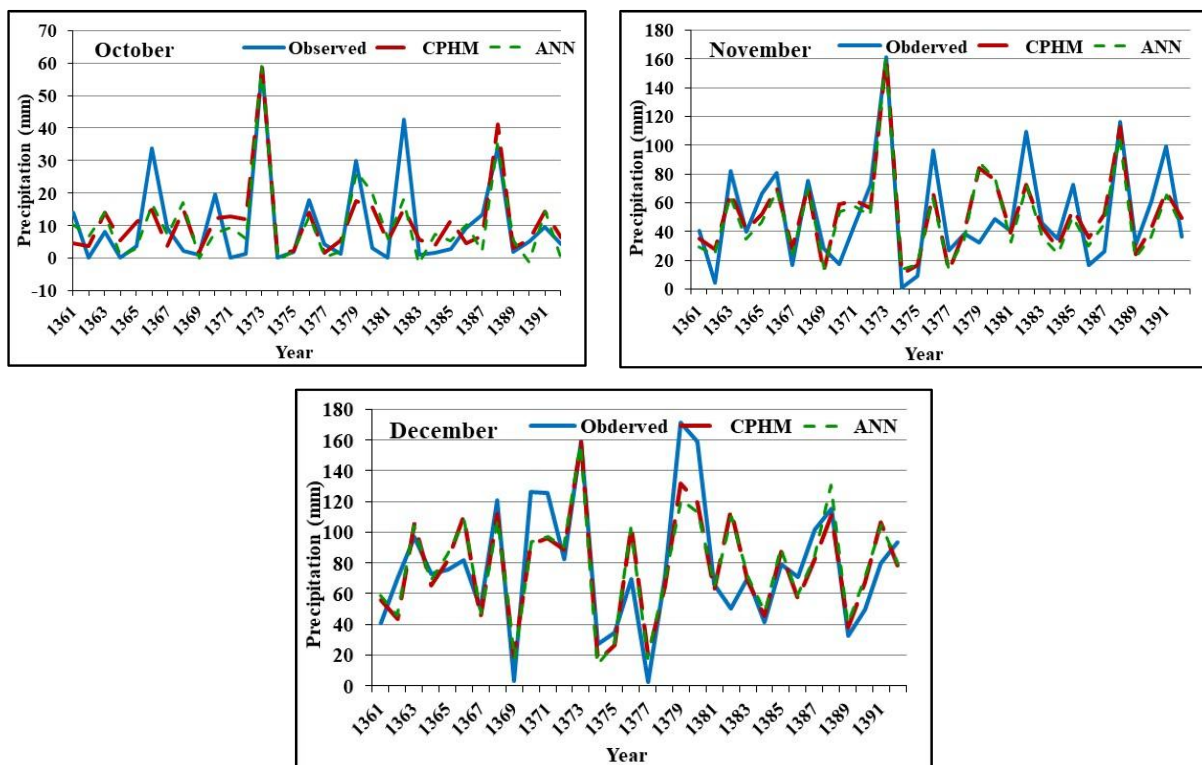


Fig. 9- Predicted monthly precipitation by CPHM and ANN models compared to observed data
 شکل ۹- بارش ماهانه پیش‌بینی شده توسط دو مدل CPHM و ANN در مقایسه با مقادیر مشاهداتی

بدین معنا که در این الگوریتم ابتدا مقادیر بارش فصلی در سه کلاس رطوبتی خشک، نرمال و مرطوب طبقه‌بندی می‌شوند و سپس مقادیر بارش ماهانه بر اساس کلاس رطوبتی که بارش فصلی در آن قرار می‌گیرد و یک تابع کرنل احتمالاتی که از داده‌های مشاهداتی بارش فصلی و ماهانه استخراج شده است، تخمین زده می‌شوند. مزایای دیگر مدل توسعه داده شده CPHM در مقایسه با روش‌های استوکستیک رایج پیش‌بینی بارش ماهانه، اولاً: امکان دهی پیش‌بینی هم‌زمان بارش هر سه ماه یک فصل بجای پیش‌بینی یک ماهه بارش و ثانیاً: امکان انجام پیش‌بینی بارش ماهانه برای ماه‌هایی نظیر مهرماه است که ماه‌های قبل از آنها بدون بارش می‌باشند و امکان پیش‌بینی مستقیم بارش ماهانه بر اساس بارش ماه‌های قبل برای آن وجود ندارد.

نتایج حاصل از پژوهش حاضر نشان داد که مدل ترکیبی احتمالاتی کلاس مبنای CPHM برای پیش‌بینی بارش ماهانه پاییزه از کارایی بالایی برخوردار است؛ به طوری که دقت نتایج آن برای هر سه ماه در مرحله صحت‌سنجی بر اساس دو شاخص NSE و RMSE در طبقه خوب و بسیار خوب قرار گرفت. دقت بالای نتایج این مدل برای ماه مهر نشانگر کارایی بالای مدل CPHM در مقایسه با روش‌های پیش‌بینی یک ماهه بارش بر اساس بارش ماه‌های قبل می‌باشد.

دقت بالای نتایج حاصل از مدل CPHM در ماه مهر که ماه‌های قبل از آن در منطقه مطالعاتی بدون بارش بوده و مدل‌های رایج پیش‌بینی بارش ماهانه بر اساس بارش ماه‌های قبل برای آن قابل کاربرد نیست، مزیت بسیار مهم این مدل می‌باشد. همچنین، نقطه قوت دیگر مدل ترکیبی احتمالاتی CPHM آن است که برخلاف اکثر مدل‌های داده‌مبنا که مبتنی بر درون‌یابی مقادیر هستند و در برون‌یابی عملکرد ضعیف دارند، این مدل با بهره‌بردن از ساختار ترکیبی احتمالاتی کلاس‌بندی شده توانایی برون‌یابی نیز دارد؛ فقط کافی است که بارش فصلی در کلاس مناسب طبقه‌بندی شود تا تابع کرنل احتمالاتی مناسب بر آن اعمال و مقادیر بارش ماهانه تخمین زده شود.

۴- نتیجه‌گیری

در پژوهش حاضر یک مدل ترکیبی احتمالاتی کلاس مبنای (CPHM) که مبتنی بر ترکیب روش‌های طبقه‌بندی و توابع کرنل احتمالاتی است، برای پیش‌بینی بارش ماهانه بر اساس بارش فصلی توسعه داده شد و کارایی آن برای پیش‌بینی بارش ماهانه پاییزه مورد ارزیابی قرار گرفته و عملکرد آن با مدل شبکه عصبی مصنوعی (ANN) با ساختار پهنه در حوضه آبریز کرخه مقایسه شد. مزیت موجود در ساختار مدل CPHM بهره‌گیری از یک الگوریتم احتمالاتی طبقه‌بندی شده است؛

محترمی که داوری این مقاله را عهده‌دار بودند، تشکر و قدردانی می‌نمایم.

پی‌نوشت‌ها

- 1- Class-based Probabilistic Hybrid Model
- 2- Linear
- 3- Symmetric Saturating Linear
- 4- Log Sigmoid
- 5- Tangent Sigmoid
- 6- Fully Connected
- 7- Feed Forward
- 8- Back Propagation

۶- مراجع

- Abbot J, Marohasy J (2014) Input selection and optimization for monthly rainfall forecasting in Queensland, Australia, using artificial neural networks. *Atmospheric Research* 138:166-178
- Afshin S, Fahmi H, Alizadeh A, Sedghi H, Kaveh F (2011) Long term rainfall forecasting by integrated artificial neural network-fuzzy logic-wavelet model in Karoon basin. *Scientific Research and Essays* 6(6):1200-1208
- Bahrami M, Amiri MJ, Rezaei Maharluei F, Ghaffari KA (2017) Data pre-processing effects on the artificial neural network performance to predict monthly rainfall (case study: Abadeh county). *Iranian Journal of Eco hydrology* 4(1):29-37 (In Persian)
- Coulibaly P, Anctil F, Bobe'e B (2000) Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology* 230(3-4):244-257
- Danandeh Mehr A, Nourani V, Karimi Khosrowshahi V, et al. (2019) A hybrid support vector regression-firefly model for monthly rainfall forecasting. *International Journal of Environmental Science and Technology* 16:335-346
- Dayal D, Swain S, Gautam AK, et al. (2019) Development of ARIMA model for monthly rainfall forecasting over an Indian river basin. In: *Proc. of World Environmental and Water Resources Congress*, 19-23 May, Pittsburgh, Pennsylvania
- Diaz-Ramirez JN, McAnally WH, Martin JL (2011) Analysis of hydrological processes applying the HSPF model in selected watersheds in Alabama, Mississippi, and Puerto Rico. *Applied Engineering in Agriculture* 27(6):937-954
- Fallah-Ghalhary GA, Mousavi Baygi M, Habibi Nokhandan M (2009) Annual rainfall forecasting by

ارزیابی نتایج حاصل از مدل CPHM در مقایسه با مدل شبکه عصبی مصنوعی (ANN) با ساختار بهینه نیز نشان داد که دقت نتایج مدل CPHM در هر سه ماه بیشتر از مدل شبکه عصبی مصنوعی ANN بهینه است. شبکه عصبی مصنوعی برای ماه مهر در هر دو مرحله واسنجی و صحت‌سنجی در چندین سال مقادیر بارش منفی را تخمین زد که با توجه به اینکه مقدار بارش فقط می‌تواند عددی مثبت باشد، نتایج غیرقابل قبول بودند و به عنوان نقص شبکه عصبی مصنوعی شناخته شدند؛ در حالی که نتایج حاصل از مدل CPHM در هر دو مرحله واسنجی و صحت‌سنجی در هر سه ماه اعدادی قابل قبول و مثبت بود. از دلایل عملکرد بهتر مدل CPHM در مقایسه با مدل ANN می‌توان به این نکته اشاره کرد که در مدل ANN برای برقراری رابطه میان مقادیر بارش فصلی (به عنوان ورودی مدل) و بارش هر ماه (به عنوان خروجی مدل) یک ساختار کلی شکل گرفته و هیچ نوع طبقه‌بندی بر روی داده‌ها صورت نمی‌گیرد. در حالی که الگوی روابط بارش فصلی و ماهانه در شرایط رطوبتی مختلف می‌تواند متفاوت باشد. همچنین، از آنجایی که بارش یک پدیده تصادفی است، با استفاده از قوانین احتمال، تحلیل بهتری می‌تواند بر آن صورت گیرد. از این‌رو، مدل CPHM که با در نظرگیری کلاس رطوبتی بارش فصلی و میزان احتمال رخداد بارش هر ماه در هر کلاس رطوبتی از بارش فصلی مقدار بارش ماهانه را تخمین می‌زند، عملکرد بهتری نسبت به مدل ANN داشته است.

همچنین، ارزیابی نقطه به نقطه نتایج دو مدل نیز نشانگر تشابه روند تغییرات نتایج حاصل از دو مدل در هر سه ماه بود که با توجه به ساختار پیچیده و بهینه شده مدل شبکه عصبی ANN، این تشابه نشانگر کارایی بالای مدل CPHM می‌باشد که دارای ساختاری کاملاً مشخص و قابل کنترل برای کاربران است و نتایج غیرقابل قبول نیز تولید نمی‌کند. همچنین، بر خلاف اکثر مدل‌های داده‌مبنا که مبتنی بر درون‌یابی مقادیر هستند و در برون‌یابی عملکرد ضعیفی دارند، مدل CPHM با بهره‌گیری از یک ساختار ترکیبی احتمالاتی کلاس‌بندی شده توانایی برون‌یابی را نیز در تخمین مقادیر بارش داراست. با توجه به ساختار فرمول‌بندی شده مدل CPHM، این مدل می‌تواند گزینه مناسبی برای پیش‌بینی بارش ماهانه باشد و در تحقیقات هواشناسی و هیدرولوژیکی مورد استفاده قرار گیرد.

۵- قدردانی

بدین وسیله از معاونت پژوهش و فناوری دانشگاه فردوسی مشهد برای تأمین اعتبارات لازم برای انجام طرح پژوهشی با کد ۵۴۶۹۹ که مقاله حاضر از دستاوردهای این طرح پژوهشی می‌باشد، و نیز از داوران

- Nirmala M, Sundaram SM (2010) A seasonal ARIMA model for forecasting monthly rainfall in Tamilandu. *Advances in building Sciences and Mechanics* 1(2):43-47
- Ouyang Q, Lu W, Xin X, et al. (2016) Monthly rainfall forecasting using EEMD-SVR based on phase-space reconstruction. *Water Resources Management* 30(7):2311-2325
- Rahiminasab M, Amerian Y (2019) Prediction of monthly rainfall in Iran using the combination of artificial neural networks and extended Kalman filter. *Journal of Geographical Data (SEPEHR)* 28(110):77-90 (In Persian)
- Rezaei Banafsheh M, Jahanbakhsh S, Khatibi M, Zeinali B (2010) Forecast of autumn and winter rainfall in the western half of Iran using Mediterranean SST in summer and autumn. *Natural Geography Journal* 74:47-62 (In Persian)
- Roghani R, Soltani S, Bashari H (2012) Investigation of the relationship between Southern Oscillation Index, Pacific and Indian sea surface temperature versus monthly and seasonal rainfall in Iran. *Journal of Water and Soil Science* 16(61):273-292
- Schepen A, Wang QJ, Robertson D (2012) Evidence for using lagged climate indices to forecast Australian seasonal rainfall. *Journal of Climate* 25(4):1230-1246
- Silverman D, Dracup JA (2000) Artificial neural networks and long-range precipitation prediction in California. *Journal of Applied Meteorology* 39(1):57-66
- Solgi A, Zarei H (2018) Application of gene expression programming and support vector regression models to modeling and prediction monthly precipitation. *Researches in Geographical Sciences* 18(50):91-103 (In Persian)
- Swain S, Nandi S, Patel P (2018) Development of an ARIMA model for monthly rainfall forecasting over Khordha District, Odisha, India. *Advances in Intelligent Systems and Computing* 708:158942575
- using mamdani fuzzy interface system. *Research Journal of Environmental Sciences* 3(4):400-413
- Farajzadeh J, Fakhari Fard A, Lotfi S (2014) Modeling of monthly rainfall and runoff of Urmia lake basin using "feed-forward neural network" and "time series analysis" model. *Water Resources and Industry* 7(8):38-48
- Fatehi Marj A, Mahdian MH (2009) Autumn rainfall forecasting using ENSO indices by Neural Network method in Urmia lake basin. *Watershed Management Researches* 84:42-52 (In Persian)
- Kalra A, Ahmad S (2012) Estimating annual precipitation for the Colorado river basin using oceanic-atmospheric oscillations. *Water Resources Research* 48:W06527
- Mahmud I, Bari SH, Rahman MT (2017) Monthly rainfall forecasting using autoregressive integrated moving average method. *Environmental Engineering Research* 22(2):162-168
- Menhaj MB (2017) *Fundamentals of neural networks: Computational intelligence (Vol. 1)*. Amirkabir University Press, 716 p (In Persian)
- Modaresi F, Araghinejad S, Ebrahimi K (2015) Assessment of model fusion strategy for increasing the accuracy of autumn rainfall forecasting. *Journal of Agricultural Meteorology* 2(2):62-69 (In Persian)
- Moriasi DN, Arnold JG, Van Liew MW, et al. (2007) Model evaluation guidelines for systemic quantification of accuracy in watershed simulations. *Transactions of ASABE* 50(3):885-900
- Mozafari GA, Shafie Sh, Hemati HR (2016) Predicting monthly precipitation of Kermanshah synoptic station using the hybrid model of neural network and wavelet. *Water and Soil Conservation* 22(6):135-152 (In Persian)
- Nazemosadat MJ, Cordery I (2000) On the relationships between Enso and autumn rainfall in Iran. *International Journal of Climatology* 20(1):47-61
- Nazemosadat MJ (2008) Improving neural network models for forecasting seasonal precipitation in southwestern Iran: The evaluation of oceanic-atmospheric indices. *Advances in Geosciences* 16:133-145