

بررسی عملکرد روش‌های ANN و SVM در ریزمقیاس‌نمایی بارش روزانه مناطق خشک

عباس خاشعی سیوکی^۱، علی شهیدی^۲، محسن پوررضا بیلندی^۳، مهدی امیرآبادی زاده^۴، احمد جعفرزاده^۵

۱. دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند

۲. دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند

۳. استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند

۴. استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند

۵. دانشجوی دکتری مهندسی منابع آب، دانشکده کشاورزی، دانشگاه بیرجند

(تاریخ دریافت: ۱۳۹۶/۴/۲۱ - تاریخ بازنگری: ۱۳۹۶/۹/۲۵ - تاریخ تصویب: ۱۳۹۶/۱۰/۲۳)

چکیده

مطالعات بررسی پیامدهای تغییر اقلیم بر منابع آب نیازمند تبدیل رفتار متغیرهای اقلیمی شبیه‌سازی شده توسط خروجی مدل‌های گردش عمومی، از یک مقیاس بزرگ به یک مقیاس محلی و مناسب است. فرآیند ریزمقیاس‌نمایی به طور قابل توجهی نتایج مربوط به شبیه‌سازی مدل‌های گردش عمومی را بهبود می‌بخشد. با وجود اینکه مطالعات کمی در خصوص عملکرد روش‌های ریزمقیاس‌نمایی در مناطق خشک وجود دارد، این پژوهش در نظر دارد تا کارایی روش‌های آماری را به منظور ریزمقیاس‌نمایی بارش روزانه بررسی نماید. در این مطالعه به منظور بررسی عملکرد روش ANN و SVM در ریزمقیاس‌نمایی بارش روزانه مشاهداتی (۱۹۹۰-۱۹۶۰)، مقادیر ۲۶ متغیر پیش‌بینی‌کننده از خروجی مدل گردش عمومی CanESM2 در گزارش پنجم، برای مدت مشابه استفاده شد. نخست فرآیند انتخاب بهترین متغیرهای پیش‌بینی‌کننده توسط آزمون رگرسیون گام به گام پیش‌رو انجام شد. به منظور بررسی توانمندی روش‌های ریزمقیاس‌نمایی از شاخص‌های ارزیابی R^2 ، RMSE و NSE بهره گرفته شد. همچنین به منظور تحلیل بهتر از آزمون‌های مقایسه‌ای متعددی نظیر بررسی عدم قطعیت، آماره‌های توصیفی، دوره‌های تر و خشک و بارندگی ماهانه استفاده شد. نتایج شاخص‌های ارزیابی نشان داد که در حالت کلی عملکرد دو روش در تخمین بارش نسبتاً مناسب می‌باشد. مقدار شاخص‌های ارزیابی R^2 ، RMSE و NSE در بهترین حالت به ترتیب معادل ۰/۴۸، ۱/۵ میلی‌متر در روز و ۰/۴۷ و متعلق به روش SVM با تابع کرنل Polynomial می‌باشد. مقایسه تغییرات بارندگی روزانه نشان داد عدم قطعیت تخمین زده شده در روش SVM به عدم قطعیت مقادیر مشاهداتی نزدیک‌تر می‌باشد. عملکرد روش‌ها در تخمین آماره‌های توصیفی نشان داد که روش SVM با تابع کرنل Polynomial از برتری قابل توجهی نسبت به سایر روش‌ها برخوردار می‌باشد. مقایسه میانگین بارش‌های ماه به ماه در دوره آزمون نشان داد که در ماه‌های با بارش بالا، عملکرد SVM بهتر از ANN می‌باشد. همچنین هر دو روش بارش در فصل تابستان را بیش از مقدار مشاهداتی برآورد نموده‌اند. نتایج تشخیص روزهای خشک نشان داد که عملکرد روش‌ها به یکدیگر نزدیک می‌باشد. در این مقوله ANN حدود ۹۶٪ روزهای خشک را به درستی تشخیص داد. اما در تشخیص روزهای تر عملکرد SVM در مقایسه با ANN بسیار بالاتر بود. بررسی توانمندی روش‌ها در تخمین طول دوره‌های خشک نشان داد که عملکرد دو روش در تخمین دوره‌های بحرانی خشک بهتر از دوره‌های خشک با طول کم می‌باشد. همچنین نتایج مربوط به تخمین طول دوره‌های تر نشان داد که دقت روش‌ها مناسب نمی‌باشد.

واژه‌های کلیدی: تغییر اقلیم، دوره‌های خشک و تر، رگرسیون گام به گام، CanESM2

مقدمه

شبیه‌سازی رفتار مؤلفه‌های اقلیمی در حال حاضر استفاده از خروجی مدل‌های گردش عمومی (GCM^۱) می‌باشد. به منظور بررسی اثرات تغییر اقلیم بر منابع آب در یک منطقه خاص لازم است تا خروجی این مدل‌ها در مقیاس محلی و یا منطقه‌ای تبدیل گردد (Wilby et al, 2002). به فرآیند تبدیل پیش‌بینی،

تغییر اقلیم و بررسی اثرات آن بر منابع آب از موضوعات مهمی به شمار می‌رود که پژوهشگران زیادی هدف تحقیق خود را در این زمینه تعریف نموده‌اند. مهم‌ترین و مطمئن‌ترین ابزار برای

سنجی نشان داد که هرچند دو روش در تخمین بارندگی دارای بیش تخمینی می‌باشند، لکن SVM عملکرد بهتری دارد. Lu & Qin (2014) در مطالعه‌ای با ترکیب توانمندی ANN و KNN^۴ اقدام به تولید یک روش ریزمقیاس نمایی جدید جهت شبیه‌سازی بارندگی ماهانه نمودند. در این مطالعه ابتدا با استفاده از KNN سری روزهای تر و خشک مشخص گردید و در ادامه برای روزهای بارانی با استفاده از ANN بارندگی ماهانه شبیه‌سازی شد. در نهایت به منظور تحلیل عملکرد روش پیشنهاد شده، نتایج شبیه‌سازی بارندگی با روش ریزمقیاس نمایی^۵ ASD مورد مقایسه قرار گرفت. نتایج مطالعه آن‌ها نشان داد که روش پیشنهاد شده به طور قابل توجهی توانمندی بالایی نسبت به ASD دارد. این برتری به خصوص در شاخص‌های آماری میانگین و حداکثر ماهانه بسیار قابل توجه است. مطالعه‌ی Vu et al. (2016) با هدف ریزمقیاس نمایی خروجی مدل ECHAM5 با استفاده از روش ANN برای شبیه‌سازی و پیش‌بینی بارش فصلی در ایستگاه باران‌سنجی بانکوک کشور تایلند انجام پذیرفت. مطالعه آن‌ها نشان داد که بین مقادیر مشاهداتی و شبیه‌سازی شده همبستگی بالایی وجود دارد و شبکه عصبی از دقت خوبی برخوردار است. همچنین Mendes and Marengo (2010) نیز در مطالعه خود به عملکرد بالای شبکه عصبی در ریزمقیاس نمایی ماهانه بارش اشاره نمودند.

مطالعه‌ی Yang et al. (2106) نشان داد که ANN توانمندی قابل توجهی در ریزمقیاس نمایی بارندگی ماهانه دارد. آن‌ها در مطالعه خود از شاخص‌های آماری میانگین، واریانس و توزیع بارندگی جهت مقایسه توانمندی شبکه عصبی استفاده نمودند. همچنین مطالعه Schoof and Pryor, (2001) نشان داد که روش شبکه عصبی، دقت مناسبی در خصوص ریزمقیاس-نمایی بارندگی روزانه ندارد.

مطالعات مقایسه‌ای فوق ضمن تأکید بر غلبه بعضی روش‌ها، نشان می‌دهند که توانمندی روش‌های ریزمقیاس نمایی در تخمین بارندگی ماهانه، فصلی و سالانه یکسان نمی‌باشد. لازم به ذکر است که عمدتاً دقت روش‌ها در ریزمقیاس نمایی بارش با مقیاس‌های بیشتر از روزانه بهتر می‌باشد. چراکه تخمین بارش روزانه در وهله نخست مستلزم تشخیص روز تر می‌باشد و مدل‌هایی قوی‌تر خواهند بود که سری روزهای تر مشاهداتی را به درستی تشخیص دهند. همچنین باید توجه داشت که در اقلیم‌های خشک نظیر دشت بیرجند (با بارش سالانه کمتر از ۲۰۰

شبیه‌سازی و طرح‌های مدل‌های گردش عمومی از مقیاس‌های جهانی به محلی و یا منطقه‌ای، ریزمقیاس نمایی اطلاق می‌شود. ریزمقیاس نمایی عمدتاً به دو روش آماری و دینامیک انجام می‌شود. روش دینامیک بر پایه شبیه‌سازی مدل‌های منطقه‌ای (RCM^۱) می‌باشد. از آنجا که این مدل‌ها برای یک منطقه خاص مشخص شده‌اند، عموماً دقت این مدل‌ها در مقایسه با مدل‌های GCM بالاتر می‌باشد. همین دقت بالا باعث شده است تا ریزمقیاس نمایی دینامیکی در کنار هزینه و زمان بیشتر، نیاز به فناوری و صنعت بالا داشته باشد (Camici et al, 2015; Salathe et al. 2007). محدودیت‌های ذکر شده در بالا باعث شده است که بیشتر پژوهش‌های ریزمقیاس نمایی در کشورهای در حال توسعه معطوف به روش‌های آماری شوند. روش‌های آماری عمدتاً در پی ایجاد یک رابطه ریاضی تجربی بین خروجی مدل‌های GCM و متغیرهای اقلیمی می‌باشند (Wood et al. 2004). روش‌های آماری عمدتاً به سه دسته مولد اقلیمی، تابع انتقال و الگوهای هواشناسی تقسیم می‌شوند. از این میان توابع انتقال بیشترین کاربرد را در ریزمقیاس نمایی آماری دارا می‌باشند. توابع انتقال با استفاده از رگرسیون‌های خطی و غیرخطی، در پی مدل‌سازی بین متغیرهای بزرگ مقیاس جو (پیش‌بینی کننده) و متغیرهای مقیاس محلی (پیش‌بینی شونده) می‌باشند (Wilby et al. 2002; Devak et al. 2015). در این بین روش‌هایی نظیر SVM^۲ و ANN^۳ زیرمجموعه روش‌های رگرسیون غیرخطی خواهند بود. تا کنون مطالعات گسترده‌ای در خصوص توانمندی رگرسیون‌های غیرخطی در ریزمقیاس نمایی بارندگی صورت پذیرفته است. مطالعات زیادی عملکرد رگرسیون‌های خطی و غیرخطی را جهت ریزمقیاس نمایی بارش بررسی نمودند که در ادامه به اختصار به بعضی از آن‌ها اشاره می‌شود.

در مطالعه‌ای Kalra and Ahmad, (2012) مبادرت به ریزمقیاس نمایی آماری خروجی مدل‌های نوسانات اقیانوسی برای حوضه آبریز بالادست رودخانه کلرادو نمودند. آن‌ها در این مطالعه از روش SVM برای تخمین بارندگی سالانه استفاده کردند. نتایج پژوهش آن‌ها گویای دقت بالاتر SVM نسبت به ANN را دارد. Sachindra et al, (2013) در مطالعه‌ای مبادرت به مقایسه توانمندی SVM و رگرسیون چندگانه خطی جهت شبیه‌سازی بارندگی ماهانه نمودند. نتایج دوره واسنجی نشانگر عملکرد خوب برای هر دو روش می‌باشد. نتایج در دوره صحت

4. K-Nearest Neighbor
5. Automated statistical downscaling

1. Regional climate model
2. Support vector machine
3. Artificial neural network

حالت کلی SDSM توانمندی بالاتری در اکثر ایستگاه‌ها داشت. بر اساس بررسی‌های انجام شده چنین به نظر می‌رسد که مطالعات کمی در خصوص مقایسه توانمندی روش‌های رگرسیون غیرخطی نظیر SVM و ANN در ریزمقیاس‌نمایی روزانه بارندگی مناطق خشک انجام شده است. مطالعه پیش‌رو در نظر دارد تا عملکرد این روش‌ها را با استفاده از آزمون‌های مقایسه‌ای در تشخیص سری‌های تر و خشک و تخمین آن‌ها از مقادیر بارش روزانه به چالش بکشد. همچنین باید توجه داشت که اکثر مطالعات انجام شده با تمرکز بر خروجی مدل‌های گردش عمومی در گزارش چهارم IPCC انجام شده‌اند. در این خصوص مطالعه پیش‌رو مبادرت به استفاده از آخرین خروجی این مدل‌ها در گزارش پنجم این نهاد نموده است.

مواد و روش‌ها

معرفی منطقه مورد مطالعه و توصیف داده‌ها

شهرستان بیرجند مرکز استان خراسان جنوبی در شمال رشته کوه‌های باقران و در محدوده‌ی ۵۹ درجه و ۱۳ ثانیه طول جغرافیایی و با ۳۲ درجه و ۵۳ ثانیه عرض جغرافیایی قرار گرفته است. وسعت این شهر ۴۲/۷ کیلومتر مربع، دارای ۲ بخش و ۱۰ دهستان می‌باشد. میانگین کمینه و بیشینه دمای سالیانه بیرجند به ترتیب ۸ و ۲۴ درجه سانتی‌گراد است. بارش سالانه ۱۵۲ میلی‌متر و ارتفاع از سطح دریا ۱۴۹۱ متر می‌باشد. اقلیم خشک در این محدوده مطالعاتی با میانگین تبخیر پتانسیل ۱۷۴۵/۳۸ میلی‌متر و عدم دسترسی به منابع سطحی قوی و پایدار، تکیه بر منابع آب زیرزمینی را تشدید کرده است. بر اساس آمار دراز مدت ایستگاه هواشناسی سینوپتیک بیرجند (۱۹۹۲-۲۰۱۲)، میانگین بارندگی ماهانه ۱۲/۴۸ میلی‌متر و میانگین بارندگی سالانه این دشت ۱۵۲ میلی‌متر است (Jafarzadeh, et al, 2017).

عموماً در مطالعات تغییر اقلیم به مؤلفه‌های اقلیمی در مقیاس محلی پیش‌بینی شونده اطلاق می‌شود. همچنین از واژه‌ی پیش‌بینی کننده برای متغیرهای توصیف‌کننده وضعیت رطوبت، چرخش و دمای اتمسفر در سطوح مختلف ارتفاعی یاد می‌شود. از آنجایی که مطالعه پیش‌رو به دنبال بررسی عملکرد روش‌های ANN و SVM در ریزمقیاس‌نمایی بارندگی روزانه می‌باشد، آمار مشاهداتی بارندگی روزانه ایستگاه سینوپتیک بیرجند (پیش‌بینی شونده) حداقل سال‌های ۱۹۶۰ تا ۲۰۱۳ از سازمان هواشناسی استان گردآوری شد. همچنین به منظور شبیه‌سازی بارندگی از خروجی مدل CanESM2 (Canadian Earth System Model) که محصول مرکز اقلیم‌شناسی

میلی‌متر) اکثر روزهای سال بدون بارندگی می‌باشد، از این رو تخمین مقدار بارش در روزهای تر مشکل به نظر می‌رسد. به بیان دیگر تشخیص سری روزهای تر و در کنار آن تخمین درست مقدار بارش روزانه در اقلیم‌های خشک دو چالش مهمی می‌باشند که عموماً روش‌های ریزمقیاس‌نمایی با آن‌ها روبه‌رو می‌باشند. این موضوع باعث شده است که با وجود مطالعات محدودی که در مقوله ریزمقیاس‌نمایی بارش روزانه وجود دارد، بررسی عملکرد روش‌های ریزمقیاس‌نمایی در مناطق خشک و به صورت روزانه با اقبال کمتری مواجه شود. به عنوان مثال Harpham and Wilby, (2005) در پژوهشی اقدام به بررسی توانمندی روش‌های ANN و SDSM در ریزمقیاس‌نمایی بارش‌های سنگین روزانه نمودند. آن‌ها در مطالعه خود از آمار مشاهداتی ۱۳ ایستگاه باران‌سنجی در شمال غربی و ۲۷ ایستگاه در جنوب غربی کشور انگلستان استفاده نمودند. شبکه‌های عصبی مصنوعی در این مطالعه شامل MLP^۱ و RBF^۲ می‌شود. نتایج مطالعه آن‌ها نشان داد که هرچند ANN قادر است تا ۸۰ درصد بارش‌های سنگین مشاهداتی را به درستی تشخیص دهد، لکن SDSM از عملکرد بهتری در خصوص تخمین مقادیر بارش‌ها برخوردار است. مطالعه‌ی Chen et al, (2012) مبادرت به ارزیابی دو روش SVM^۳ و SDSM^۳ در ریزمقیاس‌نمایی روزانه بارش در حوضه آبریز هانجیانگ کشور چین نمودند. حوضه‌ی هانجیانگ با بارش سالانه ۹۰۰ میلی‌متری و متوسط درجه حرارت ۱۶-۱۲ سانتی‌گراد در شمال غربی کشور چین قرار دارد. آن‌ها در این مطالعه نیز خروجی دو مدل گردش عمومی HadCM3 و CGCM3 را با یکدیگر مقایسه نمودند. نتایج شبیه‌سازی بارندگی نشان می‌دهد که عملکرد SVM در شبیه‌سازی بارش بهتر از SDSM می‌باشد. در مطالعه‌ی Samadi et al, (2013) بارندگی روزانه شبیه‌سازی شده توسط دو روش ریزمقیاس‌نمایی ANN و SDSM را با آمار مشاهداتی مناطق غرب ایران مورد مقایسه قرار دادند. نتایج حاکی از این بود که SDSM توانایی بالاتری نسبت به ANN دارد. Duan and Mei, (2014) در پژوهشی اقدام به مقایسه سه روش ریزمقیاس‌نمایی آماری SVM، SDSM و LARS-WG در شبیه‌سازی بارندگی روزانه در اقلیم‌های متفاوت کشور چین نمودند. آن‌ها در این مطالعه از داده‌های مشاهداتی ۳۰ ایستگاه در پهنه کشور چین استفاده نمودند. نتایج مطالعه آن‌ها نشان داد که هر کدام از این روش‌ها دقت و کارایی خاصی متناسب با نوع اقلیم دارد. لکن در

1. Multi-Layer Perceptron
2. Radial Basis Function
3. Statistical DownScaling Model

معنی‌داری داشته باشند. در حالت کلی بهتر است مجموعه پیش-بینی کننده‌ها شامل متغیرهایی باشند که توصیف کاملی از رطوبت، گردش و ارتباط بین لایه‌های مختلف جو بالای زمین را دارا باشند (Wilby *et al.* 2000). علاوه بر این دما نیز در برخی مطالعات به عنوان ورودی مشخص گردیده است (Liu *et al.* 2014; Duan *et al.* 2013).

در این پژوهش تعداد ۲۶ متغیر بزرگ مقیاس که توانمندی برقراری ارتباط معنادار با بارندگی روزانه را دارا می‌باشند، به عنوان پیش‌بینی کننده انتخاب شدند. این ۲۶ متغیر که در جدول (۱) ارائه شده‌اند، به صورت روزانه و در لایه‌های مختلف سطح و بالای زمین توسط مرکز NCEP ارائه شده‌اند (<http://climate-scenarios.canada.ca/?page=pred-help>). در این مطالعه به منظور انتخاب بهترین پیش‌بینی کننده‌ها از آزمون رگرسیون گام به گام پیش‌رو (forward stepwise regression) که به طور گسترده در مطالعات آب و هواشناسی استفاده می‌شود، بهره گرفته شد. به عنوان مثال مطالعات (Yang *et al.*, 2016)، (Hessami *et al.*, 2007) و (Harpham, and Wilby, 2005) از این روش برای کاهش دامنه متغیرهای ورودی استفاده کردند. در ادامه توضیحات مربوط به این آزمون ارائه شده است.

Canadian Climate Data and Scenarios (www.ccds-dscc.ec.gc.ca) می‌باشد، استفاده شد. این مدل کل سطح زمین را به منظور شبیه‌سازی مقادیر اقلیمی به ۱۲۸ گره افقی و ۶۴ گره عمودی تقسیم نموده است. از این رو فاصله افقی و عمودی هر گره حدوداً ۲/۸۱۲۵ درجه می‌باشد. در حال حاضر این پایگاه در کنار مقادیر روزانه، مدل CanESM2 را برای پیش‌بینی-کننده‌ها و شبیه‌سازی‌های ماهانه کلیه مدل‌های گردش عمومی را به دو صورت نقطه‌ای و پیکسلی برای بارندگی، متوسط درجه حرارت، سرعت باد و غیره در اختیار کاربران قرار می‌دهد. بدین ترتیب پیش‌بینی کننده‌های بزرگ مقیاس برای حداقل سال-های ۱۹۶۰ الی ۱۹۹۰ میلادی از این پایگاه استخراج گردید. به منظور دقت روش‌های ریزمقیاس نمایی سال‌های ۱۹۶۰ الی ۱۹۸۱، ۱۹۸۲ الی ۱۹۸۶ و ۱۹۸۷ الی ۱۹۹۰ میلادی به ترتیب به عنوان دوره آموزش، صحت‌سنجی و آزمون انتخاب گردیدند (Hamidi *et al.*, 2015).

انتخاب پیش‌بینی کننده‌ها

انتخاب پیش‌بینی کننده‌ها گام نخست در استفاده از هر مدل ریزمقیاس‌نمایی می‌باشد. عموماً لازم است تا بین پیش‌بینی کننده‌ها و متغیر مورد نظر (پیش‌بینی شونده) همبستگی قوی وجود داشته باشد. همچنین از حیث مشخصات فیزیکی همسانی

جدول ۱. جزئیات متغیرهای پیش‌بینی کننده

سطح/ارتفاع میلی‌بار (هکتو پاسکال)	چرخش	رطوبت	دما
	X1- فشار میانگین سطح دریا	X22- رطوبت نسبی	X26- دمای میانگین
	X7- دیوژانس	X25- رطوبت ویژه نزدیک سطح	
	X6- جهت باد		
سطح زمین-۱۰۰۰	X5- چرخش هوا		
	X3- سرعت نصف‌النهاری-عرض		
	X4- سرعت ناحیه‌ای-طول		
	X2- سرعت جریان هوای زمین گرد		
	X13- دیوژانس	X23- رطوبت ویژه	
	X12- جهت باد		
	X11- چرخش هوا		
۵۰۰	X9- سرعت نصف‌النهاری-عرض		
	X10- سرعت ناحیه‌ای-طول		
	X8- سرعت جریان هوای زمین گرد		
	X20- ارتفاع ژئوپتانسیل		
	X19- دیوژانس	X24- رطوبت ویژه	
	X18- جهت باد		
	X17- چرخش هوا		
۸۵۰	X15- سرعت نصف‌النهاری-عرض		
	X16- سرعت ناحیه‌ای-طول		
	X14- سرعت جریان هوای زمین گرد		
	X21- ارتفاع ژئوپتانسیل		

*انتخاب شده از مطالعه (Yang *et al.*, 2106)

آزمون رگرسیون گام به گام پیشرو

آزمون رگرسیون گام به گام می‌تواند به دو صورت اضافه کردن متغیرهای وابسته (پیشرو) و یا حذف آن‌ها (پس‌رو) از معادله رگرسیون انجام شود. برای شروع ابتدا یک مدل بر متغیر مستقل برازش داده می‌شود. در ادامه برای انتخاب متغیرهای ورودی به مدل لازم است تا یک فرآیند تکراری انجام شود. تمامی متغیرها لازم است تا یک مدل بر متغیر وابسته برازش دهند و مقدار آماره ρ -value برای ضریب رگرسیونی تخمین زده توسط آن‌ها تعیین گردد. در اولین گام متغیری وارد مدل خواهد شد که مقدار ρ -value آن از حد ورودی کمتر بوده و ضمناً کمترین مقدار ρ -value را در بین متغیرهای مستقل دارا باشد. در گام‌های بعدی نیز نحوه ورود متغیرها نیز به همین شکل خواهد بود. لکن در هر گام چنانچه مقدار ρ -value متغیری از حد خروجی بیشتر باشد از مدل خارج خواهد شد (Draper et al, 1996). همچنین در هر گام مقدار ضریب اختصاص داده شده به هر متغیر و مقدار خطای برآورد مشخص می‌شود.

روش‌های ریزمقیاس‌نمایی

مدل‌های گردش عمومی مورد استفاده برای شبکه‌سازی اقلیم به طور معمول از قدرت تفکیک مکانی بالایی برخوردارند. با این حال، به‌منظور ارزیابی درست منطقه‌ای و محلی اثرات تغییر اقلیم، محققان نیاز به سطح بسیار بالاتری از جزئیات - در حد ۱۰ کیلومتر- را دارند. از این رو از فرآیندی به نام ریزمقیاس‌نمایی استفاده می‌شود. ریزمقیاس‌نمایی فرآیند انتقال اطلاعات اقلیمی از یک مدل اقلیمی درشت مقیاس به ریز مقیاس است (Richardson, 1984). در این مطالعه از دو روش ریزمقیاس‌نمایی آماری SVM و ANN استفاده شد که در ادامه توضیحات آن ارائه خواهد شد.

روش SVM

چارچوب رگرسیون حداقل مربعات ماشین بردار پشتیبان به صورت زیر توضیح داده می‌شود:

با فرض $\{x_i, y_i\}_{i=1}^N$ که در آن $x_i \in R^p$ به عنوان بردار ورودی و $y_i \in R$ به عنوان بردار خروجی معرفی می‌شوند، تابع رگرسیون غیرخطی در مسائل تخمین به صورت زیر تعیین می‌گردد:

$$y(x) = w^T \cdot \varphi(x) + b \quad (\text{رابطه ۱})$$

w و b به ترتیب مقادیر وزن‌ها و بایاس تابع رگرسیون هستند. $\varphi(x)$ ترسیم غیرخطی ورودی‌ها می‌باشد. ضرایب باید به گونه‌ای انتخاب گردند تا مقدار خطا حداقل گردد. از این رو تابع

هدف به صورت معادله (۲) تعیین می‌گردد:

$$\psi(w, e) = \frac{1}{2} w^T \cdot w + \frac{1}{2} C \sum_1^n e_i^2$$

subject to: (رابطه ۲)

$$y_i - \hat{y}_i = e_i \rightarrow i = 1, 2, \dots, n$$

که در آن e میزان خطا را نشان می‌دهد. به منظور حل این معادله از روش لاگرانژ استفاده می‌شود (معادله ۳):

$$L(w, b, e, \alpha) = \frac{1}{2} w^T \cdot w + \frac{1}{2} C \sum_1^n e_i^2 - \sum_1^n \alpha_i (\hat{y}_i + e_i - y_i)$$

در این معادله، α_i ضریب لاگرانژ است. بر اساس شرایط کان-تاکر (KKT):

$$\begin{aligned} \frac{\partial L}{\partial w} = 0 &\rightarrow w = \sum_i^n \alpha_i \cdot \varphi_i(x_i) \\ \frac{\partial L}{\partial b} = 0 &\rightarrow w = \sum_i^n \alpha_i = 0 \\ \frac{\partial L}{\partial e_i} = 0 &\rightarrow \alpha_i = \gamma \cdot e_i \end{aligned} \quad (\text{رابطه ۴})$$

$$\frac{\partial L}{\partial \alpha_i} = 0 \rightarrow y_k = w^T \cdot \varphi_i(x_i) + b + e_i$$

$$i = 1, 2, \dots, n$$

با اعمال شرایط KKT، مدل رگرسیونی بردار پشتیبان به صورت زیر مشخص می‌شود:

$$y(x) = \sum \alpha_i K(x_i, x_j) + b \quad (\text{رابطه ۵})$$

$K(x_i, x_j)$ تابع کرنل نامیده می‌شود که با تبعیت از شرایط Mercer به عنوان تابعی با ایجاد ضرب داخلی در فضای ویژگی معرفی می‌شود (Rezaei et al, 2015). (رابطه ۶)

$$K(x_i, x_j) = \varphi(x_i)^T \cdot \varphi(x_j) \rightarrow i, j = 1, 2, \dots, n$$

در این تحقیق از سه تابع کرنل خطی^۱، چندجمله‌ای^۲ و توابع شعاعی^۳ استفاده شده است.

شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی، برای اولین بار در سال ۱۹۴۳ توسط مک کولاک و پیتس معرفی شد (McCulloch and Pitts, 1943)، اما این روش برای مدت‌های طولانی بدون استفاده بود که بعدها با توسعه رایانه‌ها و همچنین ظهور

1. Linear
2. Polynomial
3. Radial Basis Function (RBF)

$$R^2 = \frac{\sum_i^n (O_i - \bar{O}) \times \sum_i^n (S_i - \bar{S})}{\sum_i^n (O_i - \bar{O})^2 \times \sum_i^n (S_i - \bar{S})^2} \quad (\text{رابطه ۹})$$

در روابط فوق O_i و S_i به ترتیب مقادیر بارندگی ماهانه مشاهداتی و شبیه‌سازی شده توسط مدل‌های گردش عمومی، b مقدار شیب معادله رگرسیونی بین مقادیر مشاهداتی و شبیه‌سازی و \bar{O} و \bar{S} نیز به ترتیب میانگین این مقادیر در طول دوره ۱۹۸۲ الی ۱۹۹۰ می‌باشند. لازم به ذکر است که کلیه مراحل در محیط برنامه‌نویسی MATLAB R2016a انجام شده است.

نتایج و بحث

در این مطالعه تعداد ۲۶ متغیر ورودی به دو روش ریزمقیاس‌نمایی، در ابتدا مورد ارزیابی قرار گرفت تا متغیرهای با همبستگی بالا وارد دو روش شوند. طبق نتایج آزمون رگرسیون گام‌به‌گام پیشرو، تعداد ۱۷ متغیر که دارای همبستگی بالایی با مقادیر بارش روزانه دارند به عنوان ورودی مدل انتخاب شد. در نهایت مقدار عرض از مبدأ این معادله حدود ۰/۲۷ بدست آمد. همچنین جدول (۲) ضرایب و مقدار ρ -value مربوط به متغیرهای انتخابی را نشان می‌دهد. همانطور که مشخص است عموماً متغیرهایی به عنوان ورودی تعیین گشته‌اند که ρ -value کمتر از ۰/۰۵ را دارا می‌باشند.

جدول ۲. جزئیات مربوط به معادله رگرسیون انتخاب متغیرهای ورودی

متغیر	وزن-ضریب	ρ -value	متغیر	وزن-ضریب	ρ -value
X1	-۰/۹۲	.	X13	۰/۰۷	۰/۰۰۱۸۳
X2	۰/۲۲۴	۰/۰۰۰۰۳	X14	-۰/۳۰۳	.
X6	-۰/۰۰۱	۰/۰۰۴۸۶	X16	-۰/۱۵۹	۰/۰۰۰۰۱
X7	۰/۱۰۷	۰/۰۳۷۷۷	X17	۰/۱۲۴	۰/۰۰۰۰۲
X8	۰/۲۸۹	.	X21	۰/۴۲۵	.
X9	-۰/۳۸۲	.	X22	۰/۹۴۱	.
X10	۰/۳۱۹	.	X23	۰/۱۷۷	.
X11	۰/۱۴۲	.	X26	-۰/۸۰۲	.
X12	۰/۰۰۱	۰/۰۰۰۰۶	مقدار عرض از مبدأ		۰/۲۷

در ادامه نتایج مربوط به دقت روش‌های ریزمقیاس‌نمایی در شبیه‌سازی بارش روزانه ارائه می‌شود. شکل (۱) جزئیات مربوط به عملکرد روش‌های ریزمقیاس‌نمایی به کار گرفته شده در خصوص شبیه‌سازی بارندگی روزانه را نشان می‌دهد. مقایسه مقادیر نشان می‌دهد که روش SVM با تابع Polynomial دقت بهتری را نسبت به سایر روش‌ها داشته است. به طوری که دقت این روش در تمامی شاخص‌ها بهتر می‌باشد. روش SVM با تابع RBF و ANN به ترتیب در رتبه‌های بعدی

الگوریتم آموزش پس انتشار خطا برای شبکه‌های پیش‌خور توسط Rumelhart et al (1986) استفاده از آن‌ها وارد مرحله تازه‌ای گردید. شبکه عصبی مصنوعی ایده‌ای است برای پردازش اطلاعات که از سیستم عصبی زیستی الهام گرفته شده است و مانند مغز انسان به پردازش اطلاعات می‌پردازد. این سیستم از عناصر زیادی به نام نرون تشکیل شده است که برای حل یک مسئله با هم هماهنگ عمل می‌کنند. یک نرون کوچکترین واحد پردازش‌گر اطلاعات است که اساس عملکرد شبکه عصبی را تشکیل می‌دهد. هر شبکه از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه میانی تشکیل شده است. هر لایه توسط وزن‌ها به نرون‌های لایه بعد متصل می‌شوند. هر نرون مقادیر ورودی را در وزن خود ضرب کرده و با بایاس جمع می‌کند و حاصل به تابع محرکه انتقال داده می‌شود تا به این وسیله به نرون‌های لایه بعد انتقال داده شود. این عمل در نرون‌های همه لایه‌های شبکه انجام شده تا در نهایت خروجی شبکه به دست آید.

شبکه پرسپترون چندلایه

در شبکه عصبی پرسپترون چندلایه با الگوریتم پس انتشار خطا، مدل شبکه عصبی در لایه پنهان از تابع محرکه تانژانت سیگموئید (tansig) و در لایه خروجی از تابع محرکه خطی (purelin) استفاده می‌نماید و تابع یادگیری وزن‌ها تابع لونیبرگ-مارکواریت (trainlm) می‌باشد. در این شبکه‌ها اطلاعات ورودی توسط نرون‌های ورودی دریافت شده، سپس به نرون‌های لایه پنهان فرستاده می‌شود و پردازش مورد نظر روی آن‌ها انجام می‌گیرد و نتیجه به نرون‌های لایه خروجی فرستاده شده تا به عنوان خروجی شبکه نمایش داده شوند.

ارزیابی عملکرد روش‌های ریزمقیاس


پس از ریزمقیاس‌نمایی با مقایسه داده‌های مشاهداتی ایستگاه سینوپتیک و شبیه‌سازی شده در دوره پایه، دقت هر مدل با شاخص‌های ارزیابی مختلف مورد بررسی قرار گرفت. روابط (۷) الی (۹) معادله این شاخص‌ها را نمایش می‌دهد.

$$RMSE = \sqrt{\frac{\sum_i^n (S_i - O_i)^2}{n}} \quad (\text{رابطه ۷})$$

$$NSE = 1 - \frac{\sum_i^n (O_i - S_i)^2}{\sum_i^n (O_i - \bar{O})^2} \quad (\text{رابطه ۸})$$

به بررسی توانمندی ماشین بردار پشتیبان و شبکه عصبی در ریزمقیاس نمایی بارش ماهانه پرداخته است، به برتری قابل توجه SVM نسبت به ANN اشاره می‌کند. همچنین مطالعاتی نظیر Yoon *et al.*, (2011) و Çimen and Kisi (2009) نیز که به بررسی توانمندی این دو روش در سایر مطالعات هیدرولوژی پرداخته بودند، نیز به عملکرد بهتر SVM نسبت به ANN اذعان داشته‌اند.

قرار دارند. مطالعات زیادی وجود دارد که بر برتری SVM بر ANN دلالت دارد. در خصوص مقادیر شاخص‌های ارزیابی می‌توان به مطالعاتی نظیر Chadwick *et al.*, (2015) و Devak *et al.*, (2011) که بر روی ریزمقیاس نمایی بارش روزانه انجام شده‌اند، اشاره نمود. همچنین در خصوص برتری روش SVM نسبت به روش ANN یافته‌های مشابهی در مطالعات انجام شده دیده می‌شود. به عنوان مثال مطالعه Hamidi *et al.*, (2015) که



شکل ۱. نمودار میله‌ای مقادیر شاخص‌های ارزیابی

جهت مقایسه توزیع‌های احتمالاتی مقادیر بارش مشاهداتی و ریزمقیاس شده از آزمون کروسکال-والیس^۱ استفاده شد. در این آزمون فرض صفر بر یکسان بودن توزیع‌های احتمالاتی در دو سری داده دلالت می‌کند. از این رو مقادیر p -value کمتر از ۰/۰۵ فرض صفر را رد می‌کند. نتایج این آزمون در ستون دوم جدول (۳) ارائه شده است. بر اساس این آزمون توزیع‌های مقادیر بارش در هیچ‌کدام از دو روش ریزمقیاس نمایی با توزیع احتمالاتی بارش مشاهداتی یکسان نمی‌باشد. به منظور ارزیابی آماری دقیق و شفاف‌تر روش‌های ریزمقیاس نمایی، بین مقادیر بارندگی مشاهداتی و شبیه‌سازی، تحلیل فراوانی و آزمون مقایسه میانگین انجام شد. بدین منظور از دستورات ANOVA1 و Multiple Comparison Test در محیط MATLAB بهره گرفته شد. در تحلیل فراوانی فرض

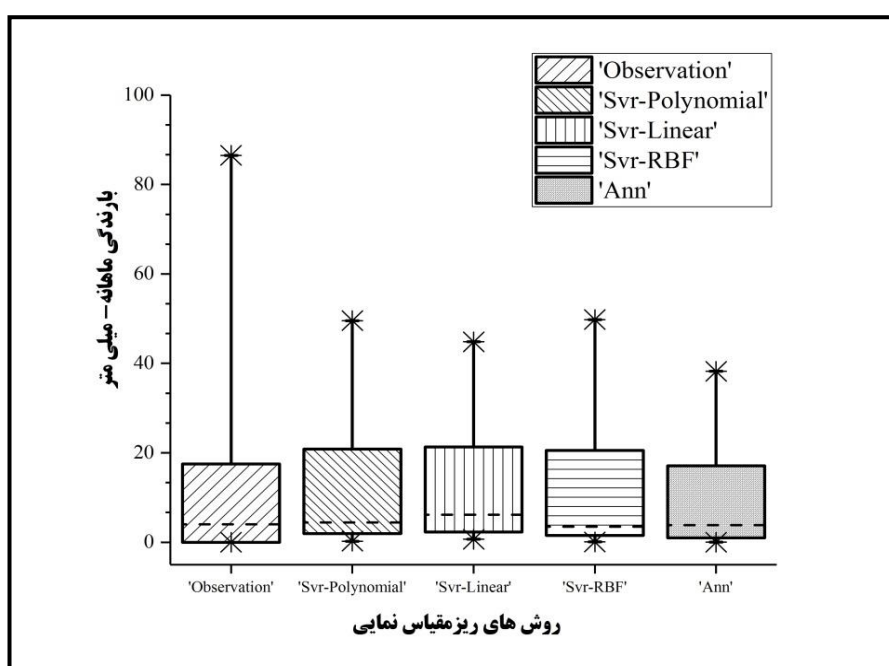
عدم قطعیت مقادیر بارش روزانه مشاهداتی و ریزمقیاس شده در شکل (۲) برای دوره آزمون ارائه شده است. آماره‌های حداقل و حداکثر با علامت ستاره و مقادیر صدک ۲/۵ و ۹۷/۵ درصد به ترتیب در ابتدا و انتهای مستطیل مشخص شده‌اند. نتایج نمودار جعبه‌ای مقادیر بارش ماهانه نشان می‌دهد که علی‌رغم اینکه هر دو روش برآورد کمتری از مقدار واریانس (پراکنش) مقادیر مشاهداتی داشته‌اند، لکن دقت روش SVM در مقایسه با ANN بهتر می‌باشد. با توجه به فاصله صدک‌ها می‌توان نتیجه گرفت که عدم قطعیت موجود در روش SVM به عدم قطعیت مقادیر مشاهداتی نزدیک‌تر می‌باشد. از این حیث نتایج مطالعه با پژوهش Campozano *et al.*, (2015) مطابقت دارد. همچنین مقدار بارندگی حداکثر روزانه تخمین زده شده توسط روش SVM با تابع کرنل Polynomial در مقایسه با ANN به مقدار مشاهداتی نزدیک‌تر می‌باشد.

1. Kruskal-Wallis test

های موجود را با یکدیگر مورد مقایسه قرار می‌دهد و برای هر مقایسه بر اساس آزمون توکی-کرامر مقدار ρ -value ارائه می‌نماید. فرض صفر در این آزمون بر یکسان بودن میانگین ۲ سری داده در سطح ۵ درصد تأکید دارد. ستون سوم در جدول (۳) مقادیر ρ -value را برای هرکدام از دو جفت سری داده‌ها، نمایش می‌دهد.

صفر مبنی بر یکسان بودن مقادیر مختلف با یکدیگر می‌باشد. پس از اجرای برنامه در محیط MATLAB مقدار ρ -value معادل ۰/۲۰۱ بدست آمد. بدین ترتیب فرض صفر مبنی بر یکسان بودن داده‌ها پذیرفته شد. در ادامه و جهت بررسی بهتر عملکرد روش‌های ریزمقیاس نمایی از مقایسه میانگین و آماره توکی-کرامر^۱ استفاده شده است. این آزمون تمامی جفت سری-

1. Tukey-Kramer test statistic



شکل ۲. نمودار جعبه‌ای بارش ماهانه مشاهداتی و شبیه‌سازی شده

مشاهداتی و ریزمقیاس شده نشان می‌دهد. بررسی مقادیر هر کدام از آماره توصیفی برای روش‌های ریزمقیاس نمایی و بارندگی مشاهداتی نشان می‌دهد که روش SVM با تابع کرنل Polynomial نسبت به سایر روش‌ها دارای عملکرد بهتری می‌باشد. در هر کدام از آماره‌های توصیفی، روشی که بهترین عملکرد را داشته است به صورت خاکستری مشخص شده است.

در شکل (۴) نمودار^۲ q-qqplot برای بارش روزانه داده‌های مشاهداتی و ریزمقیاس شده ارائه شده است. این نمودار نشان می‌دهد که روش‌های ریزمقیاس نمایی برای بارش‌های بیش از ۵ میلی‌متر بر روز همواره با کم تخمینی همراه می‌باشند. در خصوص بارش‌های کمتر از ۵ میلی‌متر در روز روند خاصی تشخیص داده نمی‌شود. همچنین به علت بالاتر بودن مقادیر R^2 در روش SVM با تابع کرنل Polynomial، تخمین‌های این روش (نسبت به دو روش دیگر) به خط مرجع نزدیک‌تر می‌باشد.

جدول ۳. مقدار ρ -value آزمون‌های مقایسه میانگین و توزیع احتمال

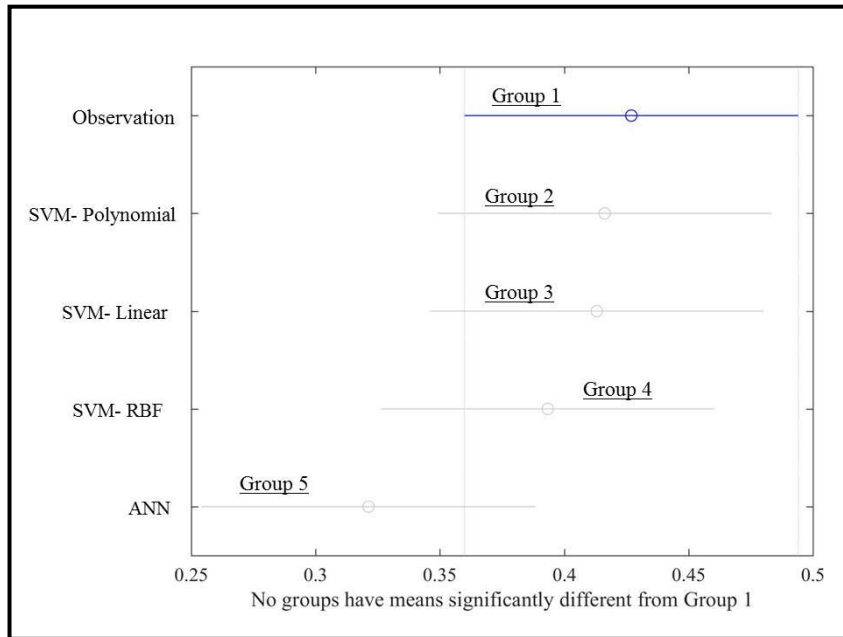
سری ریزمقیاس نمایی	توزیع احتمال	مقایسه میانگین
SVM- Polynomial	صفر	۰/۹۹
SVM- Linear	صفر	۰/۹۹
SVM- RBF	صفر	۰/۹۶
ANN	صفر	۰/۱۹

مطابق با اعداد مندرج در جدول (۳) مشخص می‌گردد که بارندگی در هیچ کدام از روش‌های ریزمقیاس نمایی تفاوت معنی‌داری با بارندگی مشاهداتی ندارد. هرچند که مقدار ρ -value در روش SVM در مقایسه با روش ANN بیشتر می‌باشد. همچنین شکل (۳) نتایج این آزمون را در قالب تصویر نمایش می‌دهد. همان‌طور که در این شکل مشخص شده است، تفاوت معنی‌داری بین مقادیر مشاهداتی و ریزمقیاس شده وجود ندارد.

جدول (۴) مشخصات آماری میانگین، انحراف معیار،

ضریب تغییرات، کشیدگی و چولگی را در سری داده‌های

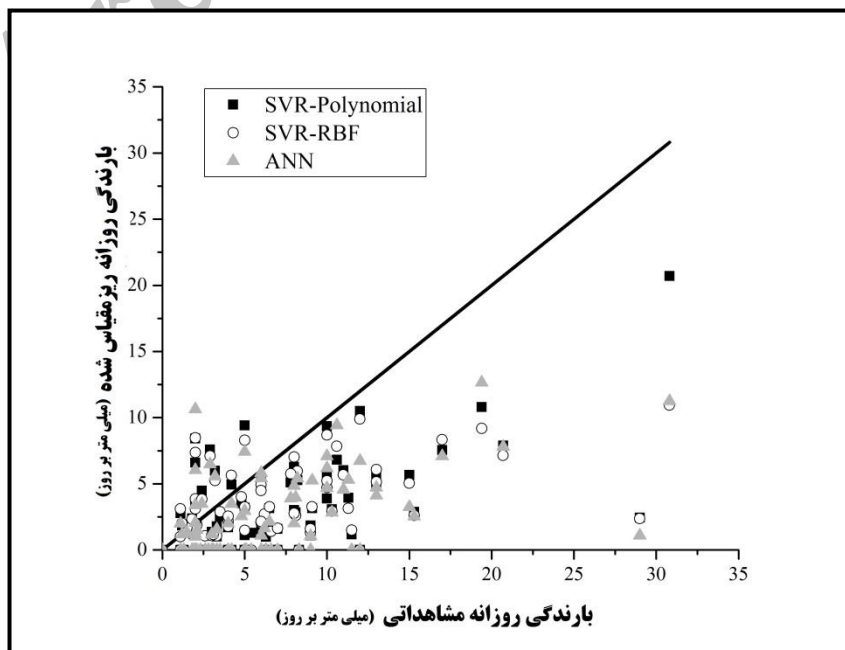
2. Quantile-Quantile plot



شکل ۳. نتیجه مقایسه میانگین مقادیر مشاهداتی و ریزمقیاس شده

جدول ۴. مقادیر آماره های توصیفی در سری داده های مشاهداتی و ریزمقیاس شده

ANN	SVM-RBF	SVM-Linear	SVM-Polynomial	Observation	
۰/۳۲۱	۰/۳۹۳	۰/۴۱۳	۰/۴۱۶	۰/۴۲۷	میانگین (میلی متر)
۱/۰۳۴	۱/۱۰۳	۰/۹۰۸	۱/۱۹۸	۲/۰۷۲	میانه (میلی متر)
۰/۰۱	۰/۰۰۷	۰/۰۳۹	۰/۰۱۹	۰	انحراف از معیار (میلی متر)
۳/۲۱۸	۲/۸۰۴	۲/۱۹۹	۲/۸۷۷	۴/۸۵۳	ضریب تغییرات
۶/۴۷۴	۵/۰۶۹	۴/۶۵۹	۷/۸۱۶	۸/۲۲۵	چولگی (میلی متر)
۵۱/۱۹۲	۳۰/۹۰۶	۲۸/۸۲۳	۹۱/۰۱۴	۸۴/۱۵۱	کشیدگی (میلی متر)



شکل ۴. نمودار q-qplot برای بارش روزانه در طی دوره آزمون

روزهای تر و خشک موجود در سری داده‌های مشاهداتی به ترتیب معادل ۱۰۶ و ۱۳۷۵ روز می‌باشد. در ابتدا و به عنوان یک نتیجه کلی می‌توان بیان نمود که کلیه روش‌ها در برآورد تعداد روزهای تر با کم‌تخمینی همراه می‌باشند. طبق این جدول مشخص می‌شود که روش SVM (در هر سه تابع کرنل) در تشخیص تعداد روزهای تر بهتر از ANN عمل کرده است. به طوری که روش SVM توانسته است بیش از ۶۵ درصد تعداد روزهای تر را به درستی تشخیص دهد. به بیان دیگر این روش توانسته است که از ۱۰۶ روز تر مشاهداتی، ۶۹ روز را به درستی تشخیص دهد. این مقدار برای روش ANN حدود ۵۰ درصد می‌باشد (۵۲ تشخیص درست از وقوع بارش). البته دقت روش SVM در هر سه تابع کرنل برای تشخیص بارش یکسان می‌باشد. به طور مشابه نتایج مطالعه *Chen et al, (2010)* نشان داد که روش SVM از برتری قابل‌توجهی نسبت به سایر روش‌ها برخوردار است. همچنین این جدول نشان می‌دهد که روش ANN توانسته است ۹۶/۳ درصد بدون بارش را به درستی تشخیص دهد. به طوری که این روش ۱۳۰۵ روز از ۱۳۷۵ روز خشک را به درستی تشخیص داده است. البته نتایج مندرج در جدول نشان می‌دهد که عموماً دقت روش‌ها در تشخیص روزهای خشک بسیار بالا می‌باشد.

کاربرد روش‌های ریزمقیاس‌نمایی در مسائل مربوط به منابع آب نظیر تحلیل خشکسالی و برنامه‌ریزی آبیاری و کشاورزی، به مهارت آن‌ها در شبیه‌سازی دوره‌های خشک و تر مربوط می‌شود. از این رو جهت تحلیل بهتر عملکرد روش‌های ریزمقیاس‌نمایی مقایسه دوره‌های تر و خشک مشاهداتی و شبیه‌سازی انجام شد. لازم به ذکر است که حد آستانه روز تر و خشک معادل ۱ میلی‌متر در روز در نظر گرفته شده است (Raje and Mujumdar, 2011; Harpham, and Wilby, 2005). به منظور تحلیل بهتر و کامل‌تر، از جدول احتمال رخداد (Contingency Table) استفاده شد. در واقع این جدول رخدادهای مقایسه روزهای تر و خشک را به صورت متقابل نشان می‌دهد (Chanda and Maity, 2018; Pearson, 1904). به بیان دیگر خروجی این جدول مشخص می‌کند که هر کدام از روش‌های ریزمقیاس‌نمایی تا چه اندازه‌ای از تعداد روزهای تر مشاهداتی را به ترتیب تر (تشخیص درست وقوع بارش) و خشک برآورد کرده‌اند.

جدول (۵) در این مطالعه تعداد روزهای تر و خشک مشاهداتی و شبیه‌سازی را برای هر یک از روش‌های ریزمقیاس‌نمایی نشان می‌دهد. سلول‌های خاکستری نشان‌دهنده تشخیص درست روش‌ها در سری روزهای خشک و تر می‌باشد. تعداد

جدول ۵. مقایسه احتمالاتی شاخص‌های رخداد

مشاهداتی	سری شبیه‌سازی		مجموع مقادیر شبیه‌سازی
	وقوع بارش - روز تر	عدم وقوع بارش - روز خشک	
۱۴۹	۶۹	۸۰	SVM- Polynomial
۱۳۱۲	۳۷	۱۲۷۵	SVM- Linear
۱۷۰	۶۹	۱۰۱	SVM- RBF
۱۲۹۱	۳۷	۱۲۵۴	ANN
۱۵۰	۶۹	۸۱	
۱۳۱۴	۳۷	۱۲۷۴	
۱۰۲	۵۲	۵۰	
۱۳۵۹	۵۴	۱۳۰۵	
-	۱۰۶	۱۳۷۵	مجموع مقادیر مشاهداتی

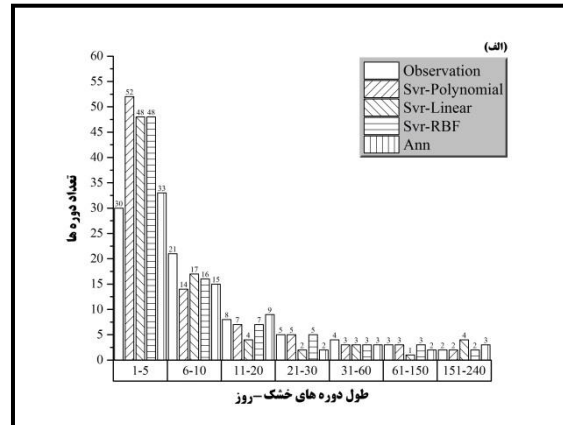

با طول کم می‌باشد. همچنین لازم به ذکر است که با افزایش طول دوره‌های خشک، به طور کلی دقت روش‌ها به یکدیگر نزدیک‌تر و بهتر می‌شود. این موضوع با یافته‌های پژوهش *Harpham, and Wilby, (2005)* یکسان می‌باشد. نتایج مطالعه آن‌ها نشان داد که عملکرد روش‌ها در تشخیص دوره‌های خشک و تر طولانی مدت بهتر می‌باشد. در خصوص طول دوره‌های مرطوب عملکرد روش‌ها در برآورد طول دوره‌های مرطوب بالا نمی‌باشد (شکل ۵-ب). به طوری که برای دوره‌های مرطوب با

در ادامه در شکل (۵) عملکرد روش‌های ریزمقیاس‌نمایی در شبیه‌سازی طول دوره‌های خشک و تر نمایش داده شده است. با استناد به شکل (۵-الف) عملکرد روش‌های ریزمقیاس‌نمایی در تخمین دوره‌های خشک با افزایش طول دوره بهبود پیدا می‌کند. به طوری که در دوره‌های با طول بیش از ۱۰ روز، اختلاف بین تعداد دوره‌های خشک مشاهداتی و شبیه‌سازی شده به مراتب کمتر می‌باشد. به عبارت دیگر عملکرد روش‌ها در تخمین طول دوره‌های خشک بحرانی‌تر از دوره‌های خشک


مشخص می‌شود که کلیه روش‌ها در این ماه‌ها با بیش تخمینی همراه بوده‌اند. به طوریکه در ماه‌های June تا Oct مقدار میانگین بارندگی شبیه‌سازی شده بیشتر از مشاهداتی است. در تمامی ماه‌های با میانگین بارش بالا (Jan, Feb, Mar, Dec)، روش SVM برآورد نزدیکتری به مقادیر داشته است.

طول بیش از ۱ روز همه روش‌ها با بیش تخمینی همراه می‌باشند. همچنین تمامی روش‌های ریزمقیاس نمایی دوره‌های مرطوب با طول یک روز را کمتر از مقادیر موجود در داده‌های مشاهداتی برآورد نموده‌اند.

میانگین بارندگی ماهانه در دوره آزمون در شکل (۶) ارائه شده است. با توجه به مقادیر بارندگی در ماه‌های کم بارش،



شکل ۵. طول دوره‌های خشک (الف) مرطوب (ب) به همراه تعداد دوره‌های موجود حدفاصل سال‌های ۱۹۸۲ الی ۱۹۹۰



شکل ۶. مقایسه میانگین بارندگی ماهانه مشاهداتی و شبیه‌سازی شده

احتمالی تغییر اقلیم را محدود می‌کند. در مطالعه پیش‌رو عملکرد روش‌های ANN و SVM در ریزمقیاس نمایی بارش روزانه با آزمون‌های مقایسه‌ای بررسی شد. نتایج این آزمون‌ها نشان داد که دو روش در برآورد بارش روزانه دارای دقت نسبتاً مناسبی می‌باشند. مقادیر شاخص‌های ارزیابی حاکی از برتری

نتیجه‌گیری

ارزیابی عملکرد روش‌های ریزمقیاس نمایی در برآورد بارش به دلیل عدم قطعیت موجود در خروجی مدل‌های گردش عمومی، در مناطق خشک بسیار با اهمیت‌تر است. عدم قطعیت موجود در خروجی مدل‌های گردش عمومی، تخمین دقیق پیامدهای

SVM در تشخیص درست روزهای تر عملکرد بهتری نسبت به روش ANN دارد. همچنین روش‌ها در تشخیص روزهای خشک عملکرد بسیار خوبی ارائه نمودند. در نهایت توانمندی دو روش در خصوص طول دوره‌های خشک و تر نشان داد که دو روش در تخمین دوره‌های مرطوب عملکرد بالایی را دارا نمی‌باشد. لکن در برآورد دوره‌های خشک بحرانی، دو روش از دقت بهتری برخوردار می‌باشند.

نسبی روش SVM نسبت به سایر روش‌ها است. مقایسه تغییرات بارش نشان داد که واریانس برآورد شده توسط دو روش در مقایسه با مقادیر مشاهداتی کمتر می‌باشد. با این وجود عدم قطعیت بارش تخمین زده شده توسط روش SVM به عدم قطعیت مقادیر مشاهداتی نزدیک‌تر می‌باشد. بررسی ماه به ماه بارش نیز نشان داد که عملکرد SVM در برآورد بارش در ماه‌های با بارش بالا بهتر از ANN می‌باشد. بررسی توانمندی دو روش در تشخیص سری روزهای تر و خشک نشان داد که روش

REFERENCES

- Camici, S., Palazzi, E., Pieri, A., Brocca, L., Moramarco, T. and Provenzale, A. (2015). Comparison between dynamical and stochastic downscaling methods in central Italy. In EGU General Assembly Conference Abstracts, 10270.. 10270.
- Campozano, L., Tenelanda, D., Sanchez, E., Samaniego, E., & Feyen, J. (2015). Comparison of statistical downscaling methods for monthly total precipitation: case study for the paute river basin in Southern Ecuador. *Advances in Meteorology*, 2016.
- Chadwick, R., Coppola, E., & Giorgi, F. (2011). An artificial neural network technique for downscaling GCM outputs to RCM spatial scale. *Nonlinear Processes in Geophysics*, 18(6).
- Chanda, K., & Maity, R. (2018). Global Climate Pattern Behind Hydrological Extremes in Central India. In *Climate Change Impacts* (pp. 71-89). Springer, Singapore.
- Chen, H., Xu, C. Y., & Guo, S. (2012). Comparison and evaluation of multiple GCMs, statistical downscaling and hydrological models in the study of climate change impacts on runoff. *Journal of hydrology*, 434, 36-45.
- Çimen M. and Kisi, O. (2009). Comparison of two different data-driven techniques in modeling lake level fluctuations in Turkey. *J Hydrol* 378:253–262.
- Devak, M., Dhanya, C. T., & Gosain, A. K. (2015). Dynamic coupling of support vector machine and K-nearest neighbour for downscaling daily rainfall. *Journal of Hydrology*, 525, 286-301.
- Draper, N. R., Smith, H., & Pownell, E. (1966). *Applied regression analysis* (Vol. 3, pp. 217-220). New York: Wiley.
- Duan, K., & Mei, Y. (2014). A comparison study of three statistical downscaling methods and their model-averaging ensemble for precipitation downscaling in China. *Theoretical and applied climatology*, 116(3-4), 707-719.
- Hamidi, O., Poorolajal, J., Sadeghifar, M., Abbasi, H., Maryanaji, Z., Faridi, H. R., & Tapak, L. (2015). A comparative study of support vector machines and artificial neural networks for predicting precipitation in Iran. *Theoretical and applied climatology*, 119(3-4), 723-731.
- Harpham, C., & Wilby, R. L. (2005). Multi-site downscaling of heavy daily precipitation occurrence and amounts. *Journal of Hydrology*, 312(1), 235-255.
- Jafarzadeh, A., Khashei-Siuki, A., & Shahidi, A. (2017). Designing a multiobjective decision-making model to determine optimal crop pattern influenced by climate change phenomenon (case study: Birjand plain). *Iranian Journal of Soil And Water Reaserch*. 47(4). 849-859 (In Farsi).
- Kalra, A., & Ahmad, S. (2012). Estimating ANNUal precipitation for the Colorado River Basin using oceanic-atmospheric oscillations. *Water Resources Research*, 48(6).
- Liu, W., Fu, G., Liu, C., & Charles, S. P. (2013). A comparison of three multi-site statistical downscaling models for daily rainfall in the North China Plain. *Theoretical and applied climatology*, 111(3-4), 585-600.
- Lu, Y., & Qin, X. S. (2014). A coupled K-nearest neighbour and Bayesian neural network model for daily rainfall downscaling. *International Journal of Climatology*, 34(11), 3221-3236.
- Mendes, D., & Marengo, J. A. (2010). Temporal downscaling: a comparison between artificial neural network and autocorrelation techniques over the Amazon Basin in present and future climate change scenarios. *Theoretical and Applied Climatology*, 100(3-4), 413-421.
- Pearson, K. (1904). *On the theory of contingency and its relation to association and normal correlation; On the general theory of skew correlation and non-linear regression*. Cambridge University Press.
- Rezaei, E., Khashei-Siuki, A., & Shahidi, A. (2015). Design of Groundwater Level Monitoring Network, Using the Model of Least Squares Support Vector Machine (LS-SVM). *Iranian Journal of Soil And Water Reaserch*. 45(4). 389-396 (In Farsi).
- Richardson, C. 1981 Stochastic simulation of daily precipitation, temperature, and solar radiation. *Water resources research*, 17.
- Sachindra, D. A., Huang, F., Barton, A., & Perera, B. J. C. (2013). Least square support vector and multi-linear regression for statistically downscaling

- general circulation model outputs to catchment streamflows. *International Journal of Climatology*, 33(5), 1087-1106.
- Salathe, E. P., Mote, P. W., & Wiley, M. W. (2007). Review of scenario selection and downscaling methods for the assessment of climate change impacts on hydrology in the United States Pacific Northwest. *International Journal of Climatology*, 27(12), 1611-1621.
- Samadi, S., Wilson, C. A., & Moradkhani, H. (2013). Uncertainty analysis of statistical downscaling models using Hadley Centre Coupled Model. *Theoretical and applied climatology*, 114(3-4), 673-690.
- Schoof, J. T., & Pryor, S. C. (2001). Downscaling temperature and precipitation: A comparison of regression-based methods and artificial neural networks. *International Journal of climatology*, 21(7), 773-790.
- Vu, M. T., Aribarg, T., Supratid, S., Raghavan, S. V., & Liong, S. Y. (2016). Statistical downscaling rainfall using artificial neural network: significantly wetter Bangkok?. *Theoretical and applied climatology*, 126(3-4), 453-467.
- Wilby, R. L., & Wigley, T. M. L. (2000). Precipitation predictors for downscaling: observed and general circulation model relationships. *International Journal of Climatology*, 20(6), 641-661.
- Wilby, R. L., Dawson, C. W., & Barrow, E. M. (2002). SDSM—a decision support tool for the assessment of regional climate change impacts. *Environmental Modelling & Software*, 17(2), 145-157.
- Wood, A. W., Leung, L. R., Sridhar, V., and Lettenmaier, D. P. (2004). Hydrologic implications of dynamical and statistical approaches to downscaling climate model outputs.”
- Yang, C., Wang, N., Wang, S., & Zhou, L. (2016). Performance comparison of three predictor selection methods for statistical downscaling of daily precipitation. *Theoretical and Applied Climatology*, 1-12.
- Yoon H, Jun S-C, Hyun Y, Bae G-O, Lee K-K (2011) A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *J Hydrol* 396:128–138.

Archive of SID