

ارزیابی شبیه‌های مختلف شبکه‌ی عصبی مصنوعی و روشهای زمین آمار در تکمیل داده‌های مفقود بارش روزانه

نادره طایفه نسکیلی^{*}، بنفشه زهرائی^۲، بهرام ثقفیان^۳

چکیده

افزایش دقت برآورد داده‌های مفقود بارش روزانه، بویژه در حوضه‌های بزرگ آبخیز با شبکه باران سنجی غیر متراکم، یکی از چالشهای آشناسها می‌باشد. در این مطالعه، شش شبیه شبکه عصبی مصنوعی به نامهای MLP، TLFN، RBF، RNN، CFNN و TDRNN با روشهای مختلف اعتبار سنجی برای تکمیل داده‌های مفقود بارش روزانه در مقایسه با روشهای زمین آمار کریجینگ و کوکریجینگ با شبیه‌های مختلف مورد بررسی قرار گرفته اند. برای ارزیابی دقت شبیه‌های مختلف در تکمیل داده‌های مفقود، از داده‌های بارش ۱۵ ایستگاه بارانسنجی موجود در حوضه‌ی رود کرخه استفاده شده است. نتایج نشان می‌دهند که شبیه‌های MLP، TLFN، CFNN و کوکریجینگ می‌توانند دقیقترین برآورد را از مقادیر گم شده ارائه دهند، هرچند به نظر می‌رسد که شبیه MLP در برآورد داده‌های مفقود بارش موثرتر از بقیه است. همچنین، بر اساس نتایج به دست آمده، شبیه RNN و TDRNN در مورد داده‌های بارش تناسب کمتری داشته، و ضعیفترین نتیجه مربوط به شبیه RBF است. روش کریجینگ از روشهای برتر عملکرد ضعیفتری داشته، اما از شبیه‌های RNN و TDRNN و RBF بهتر است.

واژه‌های کلیدی: شبکه‌ی عصبی مصنوعی، زمین آمار، بازسازی داده‌های مفقود، بارش روزانه.

^۱ - دانشجوی دکترای گروه عمران، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، تهران، ایران

^۲ - دانشیار دانشکده مهندسی عمران، پردیس دانشکده های فنی، دانشگاه تهران

^۳ - استاد گروه عمران، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران، ایران

*- نویسنده مسوول مقاله: n_tayefeh@yahoo.com

مقدمه

بارش روزانه به همان اندازه که در شبیه سازی تاثیر تغییر اقلیم در مورد سامانه‌های منابع آب و کشاورزی اهمیت دارد، مهمترین داده ورودی در شبیه سازی و پیش بینی جریان رود، جریان ورودی مخزن و متغیرهای کیفی آب نیز به شمار می‌رود. از طرفی، مهمترین مشخصات آب نگار رواناب، مانند زمان و شکل به شدت تحت تاثیر متغیرهای مکانی و لحظه ای بارش می‌باشند. هر چند در عمل، داده‌های بارش در اغلب مواقع به دلیل خرابی ابزارهای اندازه گیری و یا مسائل دیگر دارای مشکل داده گم شده بوده، این مساله یکی از مهمترین مشکلات همیشگی در حوضه‌های آبخیز می باشد. تخمین داده‌های مفقود بارش یکی از موضوعهای مشکل در آشناسی از جهت متغیرهای مکانی-زمانی باران/برف بوده و فرایندهای فیزیکی پیچیده ای را شامل می شود.

همبستگی‌های ترتیبی^۱ بین داده‌های جریان روزانه و ماهانه زمینه‌ای خوب را برای به کارگیری روشهای ساده آماری فراهم می نمایند؛ برعکس، رفتار نا ایستای^۲ الگوهای بارش اجازه نمی دهد تا از وایازی خطی ساده، یا روشهای درون یابی بتوان استفاده کرد (کروتین و همکاران، ۱۹۹۷)؛ در نتیجه، روشهای آماری گوناگونی برای تکمیل داده‌های مفقود جریان رود ارائه شده اند (خلیلی و همکاران، ۲۰۰۱؛ طایفه نسکیلی، ۱۳۸۹). لاک و همکاران (۲۰۰۰) یک ترکیب مطلوب زمانی- مکانی^۳ از داده‌های ورودی برای یک شبیه پیش بینی باران را در شبکه‌ی عصبی مصنوعی با استفاده از داده‌های بارش ۱۵ دقیقه ای ارائه نمودند. آب و همکاران (۲۰۰۰) نیز شبیه سازی قانون بنیان^۴ را با شبکه‌ی عصبی مصنوعی برای وقایع بارش گم شده مقایسه کردند. در ۲۵ سال گذشته، شبکه‌های عصبی مصنوعی، قابلیت امید بخشی را در کاربردهای گوناگون آشناسی از خود نشان داده اند (کائولیبالی و همکاران، ۱۹۹۹؛ و مایر و دندی، ۲۰۰۰).

بیشتر کاربردهای آشناسی اخیر شبکه‌های عصبی مصنوعی به وسیله‌ی سیگیزاوقلو (۲۰۰۵)، سیگیزاوقلو و

کیسی (۲۰۰۶)، کائولیبالی و بالدوین (۲۰۰۵)، دیبایک و کائولیبالی (۲۰۰۶) ارائه شده اند. اخیراً عبقری و همکاران (۲۰۰۹) از هوش مصنوعی در شبیه سازی بارش- رواناب حوضه‌ی نازلوچای در آذربایجان غربی استفاده کرده‌اند. نتایج نشان دادند که خوشه بندی الگوهای بارش- رواناب و شبیه سازی هر گروه با شبکه‌ی RBF به صورت جداگانه، دقت بیشتری را نسبت به استفاده از الگوهای پیش پردازش نشده در پیش بینی و شبیه سازی جریان رود دارد. عبقری و همکاران (۲۰۱۲) به پیش بینی تبخیر از تشتک به صورت روزانه پرداختند که در آن از دو موج ضربه ای مادر به نامهای Mexican Hat و polyWOG1 به عنوان تابع فعال سازی به جای استفاده از سیگموئید معمولی در ایستگاه سینوپتیک لار و شبکه‌ی MLP استفاده کردند. نتایج نشان دهنده‌ی برتری شبیه Mexican Hat در شبیه سازی تبخیر روزانه نسبت به شبکه‌ی MLP با تابع سیگموئید می باشد.

از کاربردهای روشهای زمین آمار، تخمین بارش منطقه ای است. در این ارتباط، ایگوزکویزا (۱۹۹۸)، به منظور تخمین میانگین بارش حوضه‌ی رود گودال هورس در اسپانیا، از روشهای سنتی تیسن و کریجینگ معمولی و کریجینگ و کوکریجینگ همراه با روند (داده‌های بارش و ارتفاع) استفاده کرد. نتایج نشان دادند که کریجینگ همراه با روند نتیجه مناسبتری دارد. دروگو و همکاران (۲۰۰۲)، به منظور تهیه‌ی نقشه‌ی مکانی بارش کوهستانی در فرانسه، با کاربرد شبیه پلوویا^۵، روشهای وایازی خطی چند متغیره بین فراسنجهای بارش و ریخت شناسی، روشهای چند متغیری زمین آماری نظیر کریجینگ همراه با روند و کوکریجینگ را مقایسه کردند. دیاداتو و سسرالی (۲۰۰۵) با کاربرد روشهای زمین آماری چند متغیره به تهیه‌ی نقشه‌های مکانی بارش در کوههای سانویو واقع در ایتالیا پرداختند. آنها علاوه بر رابطه‌ی ساده وایازی خطی بین ارتفاع و بارش، روش عکس مجذور فاصله (IDW) و کریجینگ معمولی را به کار بردند. نتایج نشان داد که روش IDW خطایی بیش از روش وایازی و کریجینگ داشت. چنگ و همکاران (۲۰۰۸)، به منظور

¹ serial correlation

² nonstationary

³ spatio-temporal

⁴ fuzzy rule-based

⁵ Pluvia

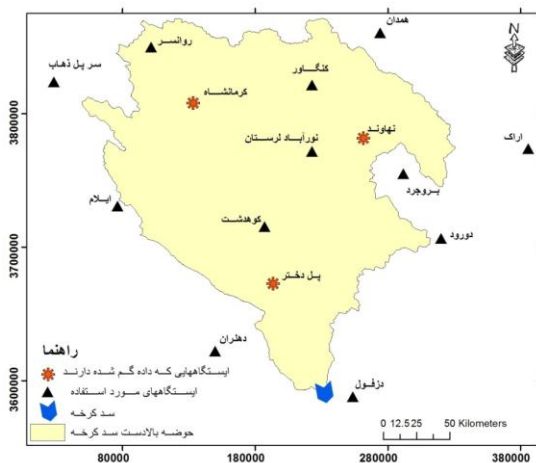
⁶ Inverse distance weighted

بررسی قرار گرفته اند. البته، در تحقیقات گذشته بیشتر بارش ماهانه و سالانه مورد بررسی قرار گرفته بوده، و در مورد بارش روزانه بررسی جامعی در خصوص روش‌های زمین آمار و بویژه در مقایسه با شبیه‌های هوش مصنوعی انجام نشده است. هدف اصلی این تحقیق تعیین بهترین شبیه در تکمیل داده‌های مفقود روزانه بارش می باشد.

مواد و روشها

منطقه‌ی مورد مطالعه

محدوده‌ی مورد مطالعه، حوضه‌ی بالادست سد کرخه در جنوب غربی ایران می‌باشد. شبکه‌ی ایستگاههای بارانسنجی موجود در داخل این حوضه و اطراف آن برای مطالعه مورد استفاده قرار گرفته که در شکل (۱) موقعیت آنها نشان داده شده است. در این تحقیق از داده‌های بارش روزانه‌ی ۱۵ ایستگاه باران سنجی در یک دوره‌ی ۱۰ ساله (۱۳۸۰-۱۳۹۰) استفاده شد پس از حذف داده‌های نامطمئن از گروه داده‌ها، بازسازی برای ۳ ایستگاه نهایند، کرمانشاه و پل دختر در دوره‌ی آماری مشترک با حذف عمدی داده‌ها انجام یافته و با داده‌های مشاهداتی مقایسه شده است.



شکل ۱- نقشه محدوده‌ی مورد مطالعه و موقعیت ایستگاهها.

تخمین میانگین منطقه ای بارش و تخمین نقطه ای در مناطق بدون ایستگاه، به ارزیابی شبکه باران سنجی با کاربرد روشهای زمین آمار پرداختند. در ارتباط با تهیه‌ی نقشه‌های مکانی بارش و خشکسالی، قهرودی تالی (۱۳۸۱) با ارزیابی درون یابی با کاربرد کریجینگ و IDW در استان کرمان پرداخت. ثقفیان و رحیمی بندر آبادی (۱۳۸۴) قابلیت چند روش درون یابی از جمله میانگین متحرک وزنی و کریجینگ را برای برآورد توزیع مکانی بارندگی ماهانه و سالانه‌ی جنوب غربی ایران بررسی کردند. مقایسه‌ی روشها با کاربرد روش اعتبار سنجی تقاطعی نشان داد که روش کریجینگ تغییرات مکانی بارندگی را بهتر نشان می‌دهد. شقاقی و همکاران (۱۳۸۵) به ارزیابی تغییرات منطقه ای بارش ماهانه و سالانه‌ی حوضه‌ی کارون با به کارگیری روشهای زمین آمار از جمله کریجینگ، کوکریجینگ و IDW با توانهای ۱ تا ۴ پرداختند، نتایج نشان دادند که روش کریجینگ تخمین بهتری دارد. میثاقی و محمدی (۱۳۸۵) پهنه بندی اطلاعات بارندگی حوضه مارون را با استفاده از روشهای آمار سنتی و زمین آمار انجام داده و نتایج را با برآورد حاصل از شبکه‌های عصبی مصنوعی مقایسه کردند. نتایج بیانگر برتری روشهای زمین آمار و تخمینگرهای کریجینگ و کوکریجینگ بودند. رحیمی بندر آبادی و ثقفیان (۱۳۸۶) به برآورد توزیع مکانی بارش با کاربرد نظریه مجموعه‌های فازی پرداختند. نتایج نشان دادند که روش فازی کریجینگ بهتر از سایر روشها عمل می‌کند. عساکره (۱۳۸۷) به کاربرد روش کریجینگ در تهیه‌ی نقشه‌های همباران ایران پرداخت؛ نتایج حاکی از برتری کریجینگ خطی به عنوان روش بهینه بودند. با توجه به نتایج پژوهشهای انجام یافته که حاکی از برتری روش کریجینگ و کوکریجینگ نسبت به سایر روشهای زمین آمار می باشد، در این مطالعه نیز این دو روش زمین آمار در بازسازی داده‌های مفقود بارش روزانه به همراه شش نوع از شبکه‌های عصبی مصنوعی با عناوین MLP^1 ، $TLFN^2$ ، RBF^3 ، RNN^4 ، $TDRNN^5$ و $CFNN^6$ مورد

¹ Multilayer perceptron networks (MLP)

² Time-lagged feed forward network (TLFN)

³ Recurrent neural network (RNN)

⁴ Radial basis function (RBF) network

⁵ Time Delay RNN

⁶ Counterpropagation fuzzy-neural network (CFNN)

ب) شبیه TLFN

یک روش معرفی "حافظه" در MLP جایگزین کردن نرونهای لایه‌ی ورودی با یک ساختار حافظه به نام tap delay line است. به چنین شبیه MLP شبکه‌ی عصبی پیشخور تاخیر زمانی^۷ (TLFN) می‌گویند که به علت ساختار حافظه‌ی پایایی به کار رفته مغایر با ساختار حافظه‌ی انطباقی در شبکه‌های عصبی بازگشتی، یک شبکه عصبی پویای کاذب^۸ می‌باشد.

ویژگی جالب TLFN این است که tap delay line ورودی هیچ فراسنج آزادی ندارد؛ بنابراین شبکه هنوز می‌تواند با الگوریتم انتشار به عقب سنتی آموزش داده شود. توپولوژی TLFN بطور موفقیت آمیزی در پیش بینی گروههای زمانی آشناسی (کائولیبالی و همکاران، a & b ۲۰۰۱)، بازشناخت الگوی لحظه ای (پرینسیپ و همکاران، ۲۰۰۰) و شبیه سازی هیبرید موازی (آنستیل و همکاران، ۲۰۰۳) مورد استفاده قرار گرفته است. TLFN برای نمایش خروجی شبکه‌های پویای به کاررفته شده در ریزمقیاس سازی بارش روزانه نیز استفاده شده است (کائولیبالی و همکاران، ۲۰۰۵). یک مزیت TLFN این است که نسبت به شبکه‌های بازگشتی و تاخیر زمانی قاعده دار پیچیدگی کمتری داشته و قابلیت پردازش الگوهای لحظه ای مشابه را دارد (کلاوس و همکاران، ۱۹۹۷).

ج) شبیه RNN^۹

شبیه RNN استفاده شده در این مطالعه بر اساس RNN نوع المانی است (المان، ۱۹۹۰). شبکه شامل ۴ لایه می‌باشد: یک لایه‌ی ورودی، یک لایه‌ی پنهان، یک لایه‌ی متنی^{۱۰}، و یک لایه‌ی خروجی. RNN یک حافظه‌ی پویای ذاتی دارد که به وسیله‌ی واحدهای متنی در اتصالات برگشتی آن ساخته می‌شود. در نهایت، خروجی شبکه تنها به وزن اتصالات و علائم ورودی فعلی بستگی نداشته، بلکه به مراحل قبلی شبکه نیز وابسته است. شبیه RNN سبک المانی یک شبیه state-space است. از آن جا که

شبیه‌های شبکه‌ی عصبی مصنوعی مورد استفاده در بازسازی داده‌های مفقود بارش

الف) شبیه MLP

در شبکه‌ی MLP، اطلاعات (یا علائم ورودی) به صورت passed forward بوده و شبکه‌ی MLP به صورت یک شبکه‌ی چند لایه پیشخور^۱ می‌باشد. خروجی شبکه MLP با یک نرون خروجی خطی^۲؛ یک لایه‌ی پنهان با گرههای پنهان سیگموئید^۳ و یک متغیر ورودی $x(t)$ به صورت زیر می‌باشد.

$$y_k = F\left(\sum_{j=1}^n w_j G(s_j) + b_k\right) \quad (1)$$

که $F(\cdot)$ یک تابع فعال سازخطی از نرون خروجی k و b_k اربب یا آستانه^۴ آن می‌باشد، w_j وزنه‌های اتصالات بین واحدهای پنهان و خروجی بوده، $G(\cdot)$ هیپربولیک تانژانت سیگموئید^۳ استفاده شده به عنوان تابع فعال سازی برای گرههای پنهان است.

یک مزیت بزرگ شبکه‌ی MLP این است که نسبت به شبکه‌های عصبی لحظه ای مانند شبکه‌های تاخیری^۴ و پی در پی^۵ پیچیدگی کمتری داشته، و همان قابلیت نگاشت ورودی-خروجی غیر خطی را دارد. علاوه بر آن MLP می‌تواند حتی با استفاده از الگوریتم انتشار به عقب معیار^۶ آموزش داده شود (روملهارت و همکاران، ۱۹۸۶). به نظر می‌رسد که قابلیت نگاشت ورودی-خروجی ایستای شبیه MLP برای شبیه سازی گروههای بارش روزانه، که معمولاً همبستگی ترتیبی ندارند، مناسب باشد. علاوه بر آن، مطالعات قبلی توانایی شبیه MLP را در شبیه سازی باران نشان داده است (توس و همکاران، ۲۰۰۰)؛ به همین دلیل، در تحقیق حاضر، شبیه MLP برای تکمیل داده‌های مفقود باران در مقایسه با سایر شبیه‌های شبکه‌ی عصبی مصنوعی مورد بررسی قرار گرفته است.

¹ multilayer feed forward network

² bias or threshold

³ hyperbolic tangent sigmoid

⁴ time delay

⁵ recurrent

⁶ standard Backpropagation algorithm

⁷ time-lagged feed forward neural network

⁸ pseudo-dynamic

⁹ Recurrent neural network

¹⁰ context

یادگیری شبکه پیش خور انتشار به عقب می‌تواند به صورت یک تقریب تصادفی به نظر آید. جهت یک نگاشت ورودی- خروجی غیر خطی خاص، شبکه RBF باید به- وسیله‌ی یک مجموعه مثالهای ورودی- خروجی معلوم آموزش داده شود.

(و) شبیه^۶ CFNN

شبکه‌ی فازی- عصبی انتشار معکوس (CFNN) به- وسیله‌ی نای و لینکنز در سال ۱۹۹۴ ارائه شده است. این شبکه ترکیب شبکه‌ی عصبی انتشار معکوس (CNN) ارائه شده به وسیله‌ی هج- نیلسون (۱۹۸۷) و محاسبات فازی می‌باشد. CNNها بطور گسترده‌ای در مسائل کاربردی مورد استفاده قرار گرفته‌اند (سیرکا و آدلی، ۲۰۰۴). CFNN در آشناسی به عنوان یک روش تخمین بارندگی با استفاده از سنجش از راه دور (هسو و همکاران، ۱۹۹۱)، پیش بینی جریان با زمان واقعی (چانگ و چن، ۲۰۰۱) و بازسازی جریان رود (چانگ و همکاران، ۲۰۰۱) به کار گرفته شده است. در این مطالعات تنها گونه‌ی پیش خور CNN مورد استفاده قرار گرفته است.

برای بهبود عملکرد^۷ CNN یک نوع محاسبات فازی فازی ارائه شده است که در آن تنظیم فازی با یک تابع عضویت گاوسی^۸، به هر بنیاد ورودی در هر یک از قاعده‌ها یا خوشه‌ها، یک درجه‌ی عضویت اختصاص می‌دهد (چانگ و چن، ۲۰۰۱). خروجی تنظیم فازی، یک متوسط وزن دار از خروجی هر قاعده است. بازسازی داده‌های مفقود با یک CFNN به دلیل این بر اساس یک دسته بندی نزدیکترین همسایگی بوده و قادر است در محاسبات مکانی و ابعاد زمانی داده‌های هواشناسی روزانه موثر واقع شود، بسیار جذاب می‌باشد. علاوه بر این، تنظیم فازی خطاها را به هنگام انتخاب یک قاعده کاهش می‌دهد (نای، ۱۹۸۹).

خطا در یک نقطه‌ی ثابت تعریف نشده، اما بطور نسبی یک تابع از رفتار لحظه‌ای شبکه است، شکل اساسی هنگام استفاده از RNN، پیچیدگی آموزش به دلیل محاسبه‌ی شیب خطا با توجه به وزنهایی است که کم مایه هم نیستند. به شکل خاص، در این مطالعه یک واریانس^۱ BPTT پیشنهادی به وسیله‌ی ویلیامز و پنگ (۱۹۹۰) مورد استفاده قرار گرفته است. این الگوریتم از یک حالت پیوسته آموزش استفاده می‌کند. تنظیم وزنها در هر گام زمانی انجام گرفته و تنها خلاصه‌ی مربوط به الگوهای ورودی و مراحل شبکه برای یک تعداد ثابت از گامهای زمانی به نام عمق ناقص^۲ ذخیره می‌شود. در عمل، این روش به عنوان بهترین روش روی خط^۳ برای مشکلات کاربردی مورد توجه بوده (پیرلموتر، ۱۹۹۵) و برای آموزش RNN بطور گسترده‌ای در کاربردهای گوناگون مورد استفاده قرار گرفته است (فلدکمپ و پوسکوربوس، ۱۹۹۸ و کائولیبالی و همکاران، ۲۰۰۱a).

(د) شبیه^۴ RBF

این نوع شبکه RBF از توابع بنیادی گاوسی^۵ (شعاعی) برای واحدهای پنهان استفاده می‌کند که با داشتن مزیت عمومی بودن از پیچیدگی محاسبات می‌کاهد (اسپیجت، ۱۹۹۱)، اما این ویژگی در رد ورودیهای بی ربط یا شلوغ خوب نیست. علاوه بر آن، ثابت شده است که شبکه‌های RBF با یک لایه‌ی پنهان واحدهای گاوسی، تقریب زنده‌های عمومی به شمار می- روند (پارک و سندبرگ، ۱۹۹۱).

اساساً، یک شبکه‌ی RBF سه لایه‌ی مشابه شبکه‌ی MLP معیار دارد. لایه‌ی ورودی، که به سادگی ورودیها را به یک لایه‌ی پنهان عبور می‌دهد که یک انتقال غیر خطی از فضای ورودی به فضای پنهان می‌باشد. پاسخ شبکه به وسیله‌ی یک لایه‌ی خروجی خطی ارائه می‌شود. گرچه شبکه RBF شبیه شبکه‌های پیش خور سه لایه‌ی معمولی به نظر می‌آید، اما عملکرد آن اساساً متفاوت است. از آن جا که یادگیری شبکه‌ی RBF مشابه یافتن سطحی بهینه در فضایی چند بعدی است، طرح‌واره

¹ backpropagation through time

² truncation depth

³ -online

⁴ Radial basis function (RBF) network

⁵ Gaussian

⁶ Counter propagation fuzzy-neural network (CFNN)

⁷ Fuzzy arithmetic

⁸ Gaussian membership function

گره‌های پنهان و مرتبه‌ی حافظه^۱ بر اساس آزمون و خطا
خطا تعیین شده است. شرح معماری شبیه‌های ANN
انتخابی به همراه تعداد فرانسجهای هر یک در جدول (۳)
ارائه شده اند.

طراحی شبکه برای تکمیل داده‌های مفقود بارش

توپولوژی شبکه‌ی عصبی مصنوعی به نوع مساله بستگی داشته و به اندازه نوع شبیه شبکه عصبی مورد استفاده در تعیین معماری شبکه‌ی مناسب (تعداد گره‌های ورودی، پنهان و خروجی) در جهت به دست آوردن توانایی تعمیم رضایت بخش شبکه مهم است. همه شبیه‌های شبکه عصبی مصنوعی در محیط Matlab نوشته شده است.

برای هر شبیه ANN، متغیرهای ورودی داده‌های بارش ایستگاه‌های مجاور ایستگاه مورد نظر جهت بازسازی داده، با توجه به دوری و نزدیکی ایستگاه‌ها می باشند. انتخاب ایستگاه‌های مجاور بر اساس مقبولیت داده‌ها و ماتریس همبستگی بین ایستگاه مجاور و ایستگاه مورد نظر می باشد که در جدول (۱) ارائه شده است. در جدول (۲) ایستگاه‌های مورد استفاده جهت بازسازی، دوره‌های آموزش (۷۰٪ داده‌ها) و اعتبار سنجی (۳۰٪ داده‌ها)، فرانسجهای آماری (میانگین و انحراف معیار) و درصد داده مفقود ۳ ایستگاه مورد استفاده در بازسازی آماری نشان داده شده اند، که پس از حذف این دوره‌ی آماری دارای داده مفقود، از گروه آماری دارای داده کامل برای شبیه سازی استفاده شده است به این ترتیب که ۳۰٪ داده‌ها در دوره‌ی اعتبار سنجی از ۳ ایستگاه مورد استفاده عمداً حذف شده و پس از بازسازی با کاربرد شبیه‌ها، با داده‌های مشاهداتی مقایسه شده اند. در روشهای آماری قدیمی مانند شبیه‌های خود کاهنده^۱، به علت مشکل چند خطی بودن^۲، معمولاً تنها دو ایستگاه مجاور انتخاب می شوند، اما مزیت ویژه‌ی روشهایی که بر اساس شبکه عصبی مصنوعی می باشند، این است که چند خطی بودن در آنها مشکلی را ایجاد نمی کند؛ بنابراین، می توان از چندین ایستگاه مجاور برای شبیه سازی استفاده کرد (کائولیبالی و اوورا، ۲۰۰۷). در این مطالعه ۴ ایستگاه مجاور براساس کیفیت داده‌های موجود، نزدیکی ایستگاه، طول دوره آماری و ماتریس همبستگی برای شبیه‌سازی انتخاب شده‌اند. برای هر شبیه تعداد بهینه‌ی فرانسجهای (تعداد

³ time delay/memory order

¹ auto-regressive

² multicollinearity

جدول ۱- همبستگی بین ایستگاههای مورد مطالعه.

ایستگاه	اراک	ایلام	نورآباد لرستان	دزفول	نهایوند	کرمانشاه	پل دختر	همدان	کنگاور	بروجرد	روانسر	کوهدشت	سر پل ذهاب	دورود	دهلران
اراک	۱**														
ایلام	۰/۲۵	۱**													
نورآباد لرستان	۰/۷۹**	۰/۲۴	۱**												
دزفول	۰/۴۵*	۰/۸۲**	۰/۵۲-	۱**											
نهایوند	۰/۸۴**	۰/۱۸	۰/۴۵**	۰/۶۴*	۱**										
کرمانشاه	۰/۳۸	-۰/۰۸	۰/۷۲**	-۰/۳۱	۰/۶۵**	۱**									
پل دختر	۰/۶۵**	۰/۸۶**	۰/۳۹	۰/۸۱**	۰/۵۲*	۰/۶۳**	۱**								
همدان	۰/۳۵	-۰/۰۱	۰/۵۴*	۰/۱۳	۰/۸۶**	۰/۴۷	۰/۷۸**	۱**							
کنگاور	۰/۳۵	۰/۷۳**	۰/۸۶**	۰/۴۳	۰/۶۱**	۰/۹۴**	۰/۷۴**	-۰/۵۴	۱**						
بروجرد	۰/۸۴**	۰/۴۱	۰/۴۸*	۰/۵۸*	۰/۸۵**	۰/۴۵	۰/۳۵	۰/۰۹	۰/۴۷	۱**					
روانسر	۰/۶۵*	۰/۱۲	۰/۷**	۰/۵۴*	۰/۳۸**	۰/۱۸**	۰/۵۳*	۰/۴۵	۰/۹۵**	۰/۰۱	۱**				
کوهدشت	۰/۴۵	۰/۷۵**	۰/۵۷**	۰/۸۵**	۰/۲۸	۰/۷۹**	۰/۹۷**	-۰/۰۳	۰/۳۲	۰/۷۳**	-۰/۵۷	۱**			
سر پل ذهاب	۰/۵۴*	۰/۷۳**	۰/۸۴**	-۰/۱۶	۰/۶۴*	۰/۱۸۷**	۰/۴۸*	۰/۶۸**	۰/۸۱**	۰/۵۵*	۰/۹۳**	۰/۳۵-	۱**		
دورود	۰/۶۳**	-۰/۸۱	-۰/۴۵	-۰/۳۲	۰/۸۷**	۰/۰۶	۰/۴۱	۰/۲۳	۰/۸۳**	۰/۸۲**	۰/۲۱	-۰/۷۷	۰/۶۴**	۱**	
دهلران	۰/۱۴	۰/۰۹**	۰/۸۸*	۰/۷۵**	۰/۷۹**	۰/۰۷	۰/۰۹**	۰/۵**	-۰/۸۷	۰/۷۴**	۰/۳۷	۰/۸۵**	۰/۷۵**	۰/۶۴**	۱**

** سطح معنی داری ۰/۰۱ * سطح معنی داری ۰/۰۵

جدول ۲- ایستگاههای مورد استفاده در تکمیل داده های روزانه‌ی بارش گروه داده های مرحله آموزش و اعتباریابی.

گروه اعتباریابی	گروه آموزش			ایستگاههای مورد استفاده برای بازسازی و بازسازی شده		
	درصد داده گم شده	انحراف معیار	میانگین	درصد داده گم شده	انحراف معیار	میانگین
۳/۷	۵/۴۲	۱/۴۸	۱۰/۶	۵/۸۳	۱/۵۷	نهایوند
	۴/۸۶	۱/۶۵		۵/۲۳	۱/۳۲	بروجرد
	۵/۰۷	۱/۴۲		۵/۴۵	۱/۶۹	اراک
	۵/۲۵	۱/۱۲		۵/۶۵	۱/۳۷	همدان
	۴/۹۸	۱/۴۷		۵/۳۶	۱/۸۶	دورود
۴/۲	۵/۴۴	۱/۲۳	۸/۴	۵/۸۵	۱/۱۶	کرمانشاه
	۵/۵۳	۱/۴۱		۵/۹۵	۱/۵	نورآباد لرستان
	۵/۰۷	۱/۱۴		۵/۴۵	۱/۲۷	روانسر
	۴/۸۸	۱/۲۶		۵/۲۵	۱/۶۹	کنگاور
	۴/۸۷	۱/۳۴		۵/۲۴	۱/۴۴	سر پل ذهاب
۵/۶	۴/۹	۱/۸۶	۱۷/۶	۵/۲۷	۱/۹۵	پل دختر
	۵/۲۳	۱/۵۴		۵/۶۲	۱/۸۸	دزفول
	۴/۹۸	۱/۲۳		۵/۳۵	۱/۸۵	ایلام
	۵/۲۵	۱/۳۵		۵/۶۵	۱/۶۷	کوهدشت
	۵/۰۷	۱/۶۱		۵/۴۵	۱/۷۳	دهلران

جدول ۳- ساختار شبیه‌های ANN انتخابی.

شبهه	مرتبه‌ی ساختار حافظه (p)	معماری شبکه (o-h-n)	تعداد فراسنجه‌ها
MLP	Static (p=۱)	$(1-18-4)^n$	۱۰۳
		$(1-14-4)^k$	۸۱
		$(1-18-4)^p$	۱۰۳
TLFN	Pseudo-dynamic (p=۶)	$(1-28-26)^n$	۷۲۹
		$(1-32-26)^k$	۸۳۳
		$(1-14-26)^p$	۴۱۷
RNN	Adaptive (p=۱)	$(1-18-4)^n$	۴۹۳
		$(1-18-4)^k$	۴۹۳
		$(1-18-4)^p$	۴۹۳
TDRNN	Adaptive (p=۵)	$(1-18-18)^n$	۷۸۶
		$(1-18-18)^k$	۷۸۶
		$(1-18-18)^p$	۷۸۶
RBF	Static (p=۱)	$(1-18-4)^n$	۱۰۳
		$(1-18-4)^k$	۱۰۳
		$(1-18-4)^p$	۱۰۳
CFNN	Static (p=۱)	$(1-1087-4)^n$	۵۱۰۳
		$(1-634-4)^k$	۳۶۷۰
		$(1-1986-4)^p$	۱۰۹۶۵

N- نه‌اوند k- کرمانشاه p- پل دختر

$$2\gamma^*(h) = \frac{1}{N(h)} \sum_{i=1}^{N(h)} [z(x_i + h) - z(x_i)]^2 \quad (2)$$

که در آن $N(h)$ تعداد جفت نمونه‌های به کار رفته در محاسبه به ازای فاصله h است. واریوگرام تجربی به بررسی و شناخت ویژگیهای ساختاری متغیر ناحیه ای پرداخته، چگونگی تغییرات آنها را بیان کرده و نقش تلخیص کننده‌ی داده‌ها را ایفا می کند. پیش از کاربرد واریوگرام در تخمین، لازم است مناسبترین شبیه نظری را بر آن برازش داد. از جمله شبیه‌های کاربردی در زمین آمار می توان به شبیه‌های کروی، گاوسی و نمایی اشاره کرد.

الف) روش کریجینگ

روش زمین آمار مورد استفاده در این پژوهش، کریجینگ (چاقوی ضامن دار)^۱ می باشد. در این شبیه می

روشهای زمین آمار مورد استفاده در بازسازی داده-های مفقود بارش

به دلیل محدودیت داده‌های نقطه‌ای و ضرورت تدوین نقشه از کل یک پهنه، به منظور تهیه‌ی نقشه‌های هم ارزش (هم باران، هم دما و ...) درون‌یابی انجام می‌گیرد (عساکره، ۱۳۸۷). در تعیین ارزش یک نقطه تمامی نقاط مجاور و معلوم به گونه ای یکسان و همسان موثر نیستند، لذا هر یک از نقاط یاد شده به تناسب تاثیرشان بر ارزش نقطه مجهول، حامل وزنی خواهند بود. روشهای تعیین وزنها مرتب با هر یک از نقاط سبب تکوین روشهای گوناگونی در درون یابی شده است (ثقفیان و همکاران، ۱۳۹۰). روش کریجینگ برای داده‌هایی که پراکنش نامنظم دارند، به کار می رود و روشی محلی، احتمالی، دقیق، خطی، نارایب و با واریانس کمینه در یک نقطه می- باشد (عساکره، ۱۳۸۷). برای تعیین رابطه‌ی مکانی پدیده‌ها از واریوگرام استفاده می شود که از رابطه زیر قابل محاسبه است:

¹ Jake knife

گوناگون، تخمین زد. این ویژگی باعث دقت بیشتر تخمین و صرفه جویی در هزینه با نمونه برداری کمتر می‌شود.

اگر داده‌های تجربی به صورت $\{z_j, j=1, 2, \dots, m\}$ $Z_j(X_i)$ $\{i=1, 2, \dots, n\}$ باشند، به گونه‌ای که m متغیر ناحیه‌ای ایستاد n نقطه‌ی نمونه برداری شده باشد، مقدار تخمین به روش کوکریجینگ در نقطه‌ی (X_0) برای m متغیر ناحیه‌ای از ترکیب خطی $m \times n$ داده به صورت زیر به دست می‌آید:

$$z^*(x_0) = \sum_{i=1}^N \Lambda_i z^*(xi) \quad (5)$$

که در آن مقادیر Λ_i مجهول بوده و باید تخمین زده شوند. معادله‌های کوکریجینگ، باکمینه کردن واریانس تخمین در شرایط حفظ شرط نا اریبی عمل می‌کنند (حسنی پاک، ۱۳۷۲).

نتایج و بحث

همه شش شبیه شبکه عصبی مصنوعی که برای بازسازی داده‌های روزانه بارش به کار گرفته شدند، در همان گروه داده‌ها آموزش دیده و برای ارزیابی جامع عملکرد شبکه‌های مختلف در بازسازی داده‌های بارش، هر شبیه ANN در سه ایستگاه منتخب (نهایوند، کرمانشاه و پل دختر) به کار رفتند. روشهای زمین آمار کوکریجینگ و کوکریجینگ نیز برای بازسازی داده‌های روزانه مورد استفاده قرار گرفتند. در روش کوکریجینگ از داده‌های دمای روزانه و ارتفاع منطقه نیز استفاده شد. محاسبه خطای روشهای زمین آمار به حالت اعتبار سنجی تقاطعی تحقق یافت، سپس نتایج اعتبار یابی تمامی شبیه‌ها برای هر سه ایستگاه تجزیه و تحلیل شده و مورد مقایسه قرار گرفت.

در این مطالعه، RNN المانی مطرح شده در بالا با ورودیهای با تاخیر زمانی مورد استفاده قرار گرفته و شبکه‌ی نهایی به صورت شبکه‌ی عصبی برگشتی تاخیر زمانی $(TDRNN)^7$ می‌باشد. به این ترتیب TDRNN هر دو حافظه‌ی ایستا و انطباقی را دارد که آن را برای آموزش ورودی پی در پی پیچیده مناسب می‌سازد. هر چند شبیه نیاز به زمان آموزش طولانی بدون تضمین همگرایی دارد.

⁷ time delay recurrent neural network

توان خصوصیات واریوگرام^۱ را به دست آورد. به این منظور، هر بار یکی از نقاط با داده‌ی معلوم حذف گردیده، سپس مقدار آن داده به روش کوکریجینگ تخمین زده می‌شود. خطای تخمینهای کوکریجینگ باید میانگین صفر داشته و با خطای تخمین نظری برابر باشد. این تخمینگر خطی به شکل زیر است:

$$z(x_0) = \sum_{i=1}^N \lambda_i z^*(x_i) \quad (3)$$

که N : تعداد داده‌ها، $Z(X_0)$: مشخصه‌ی تخمین زده شده در نقطه‌ی X_0 ، $Z^*(X_0)$: مقدار اندازه گیری شده‌ی عددی مشخصه‌ی مورد بررسی در نقطه‌ی X_i و λ_i : وزن آماری است که به نمونه‌ی $Z(X_i)$ واقع در همسایگی نقطه‌ی X_0 اختصاص می‌یابد. در حقیقت هدف از کوکریجینگ یافتن وزنه‌ی آماری نمونه‌ها به گونه‌ای است که واریانس تخمین کمینه شود. به این ترتیب کوکریجینگ را می‌توان روشی دانست که طی آن به مجموعه‌ی نمونه‌ها به گونه‌ای وزن آماری داده می‌شود که ترکیب خطی آنها نه تنها نا اریب شود، بلکه در بین سایر تخمینگرهای خطی، کمترین واریانس را داشته باشد. برای اینکه تخمین $Z(X_0)$ نا اریب باشد، باید مجموع ضرائب، برابر یک در نظر گرفته شود.

$$\sum_{i=1}^n \lambda_i = 1 \quad (4)$$

کوکریجینگ بر حسب ویژگیهای ساختار مکانی به انواع کوکریجینگ ساده^۲، کوکریجینگ معمولی^۳، کوکریجینگ عام^۴، لوگ کوکریجینگ^۵ و کوکریجینگ^۶ تقسیم می‌شود.

(ب) روش کوکریجینگ

همان گونه که در آمار سنتی روشهای چند متغیره برای تخمین وجود دارد، در زمین آمار نیز می‌توان به روش کوکریجینگ بر اساس همبستگی بین متغیرهای

¹ variogram characteristics

² Simple kriging

³ Ordinary kriging

⁴ Universal kriging

⁵ Log kriging

⁶ Cokriging

مرحله‌ی آموزش شبکه‌ی CFNN بسیار شبیه ارائه‌ی چانگ و چن (۲۰۰۱) می‌باشد. برای یک Δ داده شده، ثبات تعداد قاعده‌ها (تعداد نرونهای لایه کوهنون) زمانی به دست می‌آید که تعداد قاعده‌ها بعد از پنج بار تکرار ثابت باشد. داده‌های ورودی CFNN قبل از ورود به شبیه پیش پردازش می‌شوند. پیش پردازش شامل معیار سازی یا بهنجار سازی داده‌ها از -۱ تا +۱ می‌باشد که بطور بهنجار با میانگین صفر و واریانس ۱ توزیع شده‌اند. در مواردی که در تمامی ایستگاه‌های ورودی شبیه CFNN هیچ بارشی مشاهده نشده بود، برای بازسازی داده‌های بارش، محاسبات فازی به کار نرفته است. فراسنجهای آماری مرحله‌ی اعتبار یابی شبیه برای داده‌های بارش روزانه با کاربرد شش شبیه ANN در جدول (۴) ارائه شده‌اند.

در نهایت برای ارزیابی عملکرد روشهای مختلف در بازسازی داده‌های روزانه بارش، برخی معیارهای اساسی از جمله متوسط خطای مطلق (MAE^3)، ضریب همبستگی بین داده‌های مشاهداتی و بازسازی شده (R^2) و شاخص ناش ساتکلیف^۴ ($N.S$) مورد استفاده قرار گرفته‌اند:

$$MAE = \frac{\sum |O_i - P_i|}{N} \quad (۶)$$

(۷)

$$N.S = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2}$$

که در آن O_i : داده‌های مشاهداتی، P_i : داده‌های پیش بینی شده به وسیله‌ی شبیه، N : تعداد روزها و \bar{O} : میانگین داده‌های مشاهداتی می‌باشد.

این معیارها نشان می‌دهند که تا چه اندازه شبیه، داده‌های مشاهداتی را شبیه سازی کرده و بطور گسترده در ارزیابی شبیه‌های پیش بینی بارش مورد استفاده قرار می‌گیرند (توس و همکاران، ۲۰۰۰). ضریب همبستگی بطور واضح اختلاف بین شبیه سازیهای و مشاهدات را در واحدهای متغیر نشان می‌دهد. علاوه بر آن، برای بررسی مجدد عملکرد شبیه، میانگین و انحراف معیار داده‌های مشاهداتی و بازسازی شده نیز تعیین شده‌اند؛ نمودار


جهت کاهش زمان آموزش شبکه، BBTT ناقص با یک آموزش توقف زود هنگام به کار می‌رود (پرچلت، ۱۹۹۸؛ کائولیبالی و همکاران، ۲۰۰۰) که در آن، زمانی که اعتبار سازی^۱ خطا شروع به افزایش می‌کند، آموزش متوقف می‌شود.

در این تحقیق برای آموزش شبکه‌ی RBF، روش شیب نزولی نظارت بنیان^۲ (پوگیو و گریوسی، ۱۹۹۰) به کار رفته است. در این فرایند آموزش، تابع خطای E با به هنگام شدن اقتباسی همه فراسنجهای آزاد شبکه $(w_j \bar{O}_j; w_{ikj})$ کمینه شده است. در حقیقت، آموزش عبارت تطبیق مراکز نرونهای شعاعی بنیادی (واحدهای پنهان) است. شبکه‌ی RBF آموزش یافته به وسیله‌ی الگوریتم شیب نزولی نظارت بنیان، اساساً در تعمیم عملکرد شبکه‌های معیاری که به صورت انتشار به عقب آموزش یافته‌اند بسیار مستعد گزارش شده است (وتسچرک و دیتراچ، ۱۹۹۲)، اگرچه، در یکی از مطالعات انجام یافته نشان داده شده است که RBF قابلیت TLFN در پیش بینی عمق آب زیرزمینی را ندارد (کائولیبالی و همکاران، ۲۰۱۵)، با این حال، تا کنون، هیچ مطالعه‌ای توانایی شبکه‌ی RBF را برای تکمیل داده‌های آماری بارش بطور مفصل بررسی نکرده است.

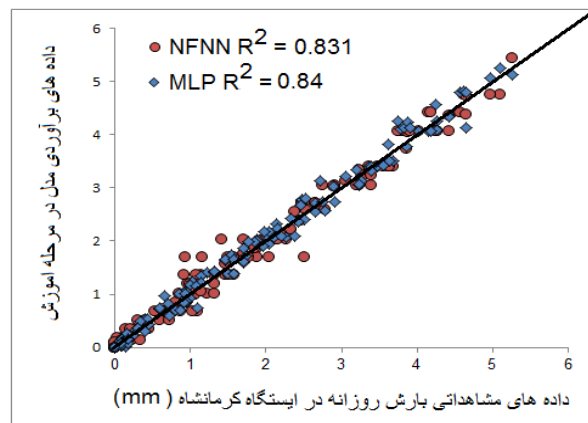

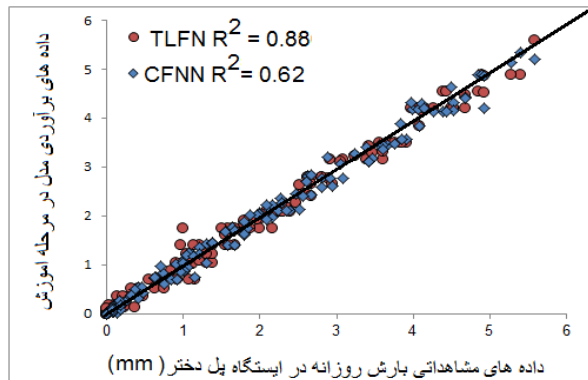
در شبیه CFNN اگر یک بردار ورودی به مرکز یک نرون کوهنون که نماینده‌ی مرکز یک خوشه است نزدیکتر از مرکز سایر خوشه‌ها باشد رقابت را نرون کوهنون می‌برد. فاصله‌ی اقلیدسی معیار نزدیکی می‌باشد. بنابراین، هر دفعه که یک بردار ورودی به شبکه معرفی می‌شود، یک تصمیم گرفته خواهد شد، خواه برای به زمان کردن وزنه‌های نرون کوهنون برنده شد، یا برای ایجاد یک خوشه جدید. اگر حداقل فاصله اقلیدسی بین بردار ورودی و نرونهای کوهنون بزرگتر از یک فاصله حداقل Δ انتخاب شده پیش از آموزش شبکه‌ی عصبی باشد. Δ^2 به عنوان واریانس خوشه‌ها مطرح شده است. وزنه‌های نرون برنده به دنبال قاعده‌ی آموزش رقابتی به هنگام سازی می‌شوند (روملهارت و زیپسر، ۱۹۸۵).

³ Mean Absolute Error⁴ Nash-Sutcliffe¹ validation² supervised gradient-descent-based method

اعتبار سنجی در شکل (۲) نشان داده شده است.



داده‌های مشاهده‌ای و برآوردی شبیه‌ها در مرحله آموزش و



شکل ۲- نمودار داده‌های برآوردی و مشاهده‌ای در مرحله‌ی آموزش و اعتبار سنجی شبیه‌های مختلف.

و در نهایت داده‌های شبیه زمین آمار با شبیه‌های شبکه عصبی مصنوعی مورد مقایسه و ارزیابی قرار گرفتند که در جدول (۶) ارائه شده‌اند. نیم تغییر نمای شبیه برتر زمین آمار (شبیه کوکریجینگ با شبیه گاوسی) در شکل (۳) و نمودار داده‌های مشاهده‌ای و برآوردی آن در شکل (۴) ارائه و نمونه‌ی نقشه‌ی حاصل در شکل شماره (۵) ارائه شده است.

در نهایت، نمودار داده‌های مشاهده‌ای و بازسازی شده ماهانه‌ی بارش برای ارزیابی مجدد دقت شبیه در تخمین بارش تجمعی ماهانه تهیه شده است که برای پیش‌بینی بلندمدت (فصلی) جریان رودخانه/ورودی مخزن لازم می‌باشد.

برای ارزیابی روشهای زمین آمار و یافتن بهترین شبیه از روش اعتبار سنجی^۱ موجود در نرم افزار ARC GIS استفاده شد (راهنمای نرم افزار GIS). برای ساختن شبیه-های زمین آمار با کمترین خطا روش ارزیابی مقابل^۲ مورد استفاده قرار گرفت. نتایج حاصل از روشهای زمین آمار در جدول (۵) ارائه شده‌اند که نشان می‌دهند روش کوکریجینگ با شبیه گاوسی بهترین نتیجه را بین روشهای زمین آمار دارد. در شبیه کوکریجینگ نیز مانند گاوسی عملکرد بهتری را دارد. برای بخش اعتبار سنجی، داده‌های مفقود از طریق روش اعتبار سنجی برآورد شدند،

¹ validation

² Cross validation

جدول ۴- فراسنجهای آماری مرحله اعتبار یابی شبیه برای داده های بارش روزانه با کاربرد شش شبیه ANN.


ایستگاه	شبیه ANN	MAE	N.S	R ²
نهاد	MLP	۱/۱۹	۰/۸۴	۰/۹۲۳
	TLFN	۱/۴	۰/۸۱	۰/۸۲۴
	RNN	۱/۴۷	۰/۵۶۵	۰/۶۴۹
	TDRNN	۱/۸۴	۰/۵۷۴	۰/۷۸۹
	RBF	۱/۸۷	-۰/۲۱	۰/۶۳۷
	CFNN	۱/۳۶	۰/۸۸	۰/۸۳۹
کرمانشاه	MLP	۱/۲	۰/۸۵۶	۰/۸۲۳
	TLFN	۱/۴	-۰/۸۲۱	۰/۸۱۳
	RNN	۱/۴۶	-۰/۳۴۲	۰/۷۹
	TDRNN	۱/۶۵	-۰/۳۶۵	۰/۷۴
	RBF	۱/۵۸	-۰/۴۷۶	۰/۷۳۵
	CFNN	۱/۲۸	۰/۶۵۸	۰/۸۱۴
پل دختر	MLP	۱/۱۲	۰/۸۶۵	۰/۸۴۹
	TLFN	۱/۱۴	۰/۸۲	۰/۸۶
	RNN	۱/۸۱	۰/۴۲۵	۰/۶۷۷
	TDRNN	۱/۹۶	۰/۵۸۷	۰/۵۸۴
	RBF	۲/۳۱	۰/۴۸۴	۰/۶۳۱
	CFNN	۱/۹	۰/۵۸	۰/۶۱۲

جدول ۵- شبیه های برازش داده شده بر بارش روزانه و نتایج ارزیابی آنها

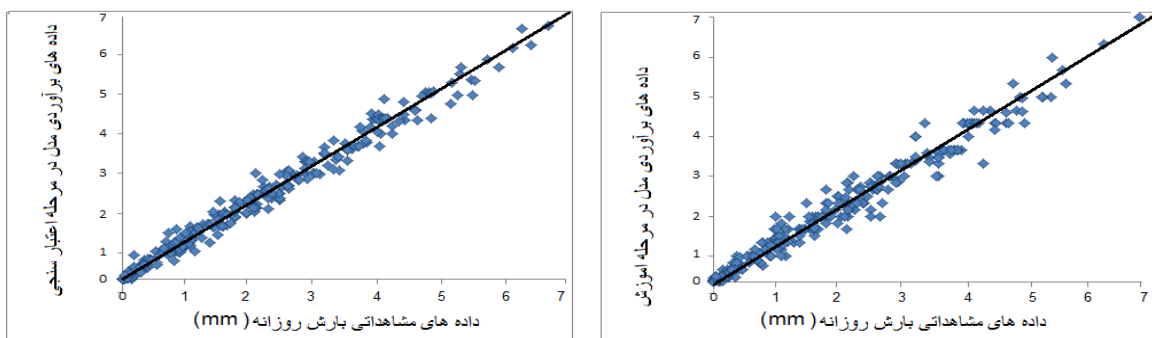
روش درون یابی	شبیه	دامنه‌ی اصلی ^۱	قطعه ^۲	Lag size	MAE	R ²	N.S
کریجینگ	کروی	۴/۶	۷۶/۸	۰/۳۸	۱/۵۱	۰/۶۷۴	۰/۵۴
	گاوسی	۳/۴	۵۰	۰/۳۸	۱/۳	۰/۸۴۱	۰/۷۲۳
	نمایی	۳/۸	۶۸	۰/۳۶	۱/۸	۰/۷۲۲	۰/۶۶۴
کو کریجینگ	کروی	۳/۲	۵۵	۰/۴۱	۱/۳۱	۰/۸۲۱	۰/۶۴۲
	نمایی	۳	۴۰	۰/۴۸	۱/۱۷	۰/۷۶۲	۰/۷۴۶

جدول ۶- فراسنجهای آماری اعتبار یابی شبیه های برتر.

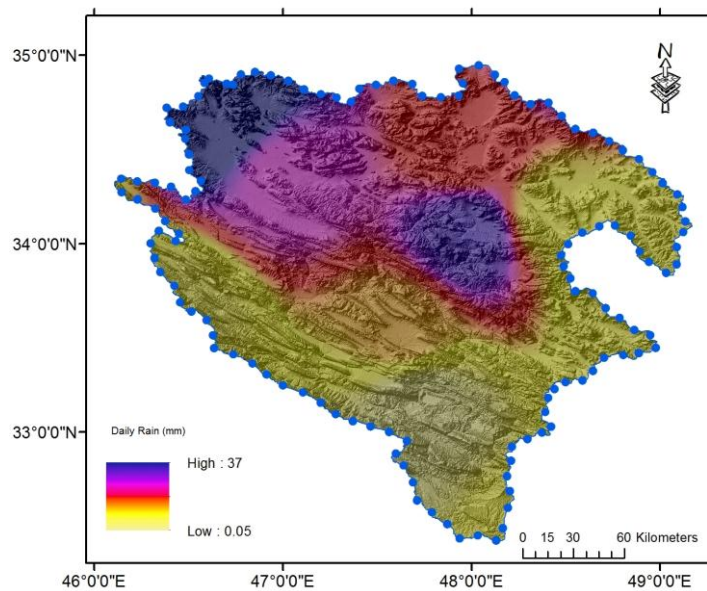
ایستگاه	داده های مشاهداتی		داده های بازسازی شده	
	میانگین	انحراف معیار	شبیه ANN	میانگین
نهاد	۱/۸	۵/۴۲	TLFN	۱/۶۷
			CFNN	۱/۴۳
			کو کریجینگ	۱/۴۵
کرمانشاه	۱/۲۳	۵/۴۴	MLP	۱/۹۹
			CFNN	۱/۳۸
			کو کریجینگ	۱/۳
پل دختر	۲/۱	۴/۹	TLFN	۱/۸۷
			CFNN	۲/۱۸
			کو کریجینگ	۲



شکل ۳- نیم تغییر نمای شبیه گاوسی شبیه کوکریجینگ.



شکل ۴- نمودار داده های مشاهده‌ای و برآوردی شبیه کوکریجینگ در مرحله‌ی آموزش و اعتبار سنجی.




شکل ۵- نمونه‌ی نقشه بارش تولیدی با کاربرد شبیه کوکریجینگ با شبیه گاوسی.

مشاهداتی را بهتر حفظ می‌کند. اما در شاخص‌های ناش ساتکلیف، MAE و R^2 سه شبیه کوکریجینگ، TLFN و MLP، دقت بیشتری در تکمیل داده‌های مفقود دارند. بنابراین زمانی که دقت برآورد اولویت دارد، باید سه شبیه کوکریجینگ، TLFN و MLP ترجیح داده شوند، زمانی که تغییر پذیری گروه‌های زمانی اولویت دارد، باید شبیه CFNN انتخاب شود.


برای مستند سازی بیشتر و مقایسه بهتر شبیه‌هایی که نتایج بهتری داشتند (MLP، TLFN و CFNN، کوکریجینگ و کریجینگ)، نمودارهای بارش ماهانه داده‌های مشاهداتی و بازسازی شده با کاربرد شبیه‌ها در شکل‌های (۶ تا ۹) ارائه شده‌اند. این نمودارها کمک می‌کنند تا دقت شبیه‌ها در برآورد تراکمی بارش ماهانه که در پیش‌بینی‌های بلند مدت (فصلی) جریان رود یا مخزن لازم است بهتر و بیشتر سنجیده شود. در این حالت، برای بارش ماهانه‌ی کمتر از ۳۰ میلی‌متر، شبیه CFNN برآورد دقیق‌تری را نسبت به شبیه TLFN دارد، در حالی که برای بارش ماهانه‌ی بیش از ۸۰ میلی‌متر، همانند شبیه TLFN عمل می‌کند. برای بارش بین ۳۰ تا ۸۰ میلی‌متر، شبیه CFNN اندکی بهتر از TLFN عمل می‌کند.

در مجموع، به نظر می‌رسد که شبیه MLP معیار، کوکریجینگ و TLFN دقیق‌ترین بازسازی را برای داده‌های مفقود بارش روزانه دارند. و بین آنها نتایج MLP دقیق‌تر از بقیه است. برعکس شبکه‌های عصبی پویا (RNN و TDRNN)، همانند شبکه‌ی RBF عملکرد ضعیف‌تری دارند. روش کریجینگ نسبت به روش MLP، کوکریجینگ و TLFN ضعیف‌تر بوده اما از شبکه‌های عصبی پویا (RNN و TDRNN) و RBF نتایج بهتری دارد. شبکه‌ی CFNN در دو ایستگاه نهاوند و کرمانشاه عملکرد بسیار خوبی داشت، اما در ایستگاه پل دختر نتایج ضعیف بود. هر چند، تحلیل بیشتر داده‌های بارش بازسازی شده، دید بهتری نسبت به عملکرد شبیه CFNN فراهم می‌نماید. طبق نتایج ارائه شده در جدول (۶) شبیه CFNN شاخص‌های آماری (میانگین و انحراف معیار) داده‌های مشاهداتی هر سه ایستگاه را به خوبی باز تولید کرده است، که نشان می‌دهد الگوی داده‌های مشاهداتی را به خوبی حفظ نموده است. شبیه‌های MLP و TLFN نیز شاخص‌های آماری داده‌های مشاهداتی را کاملاً خوب باز تولید کرده‌اند، اما نسبت به شبیه CFNN دقت کمتری دارند.

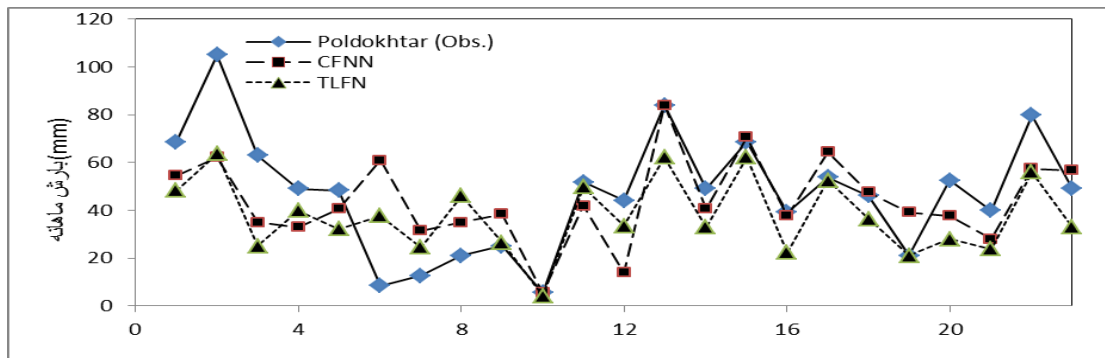
در مجموع، شبیه CFNN در مقایسه با دو شبیه MLP، TLFN و کوکریجینگ، شاخص‌های آماری داده‌های



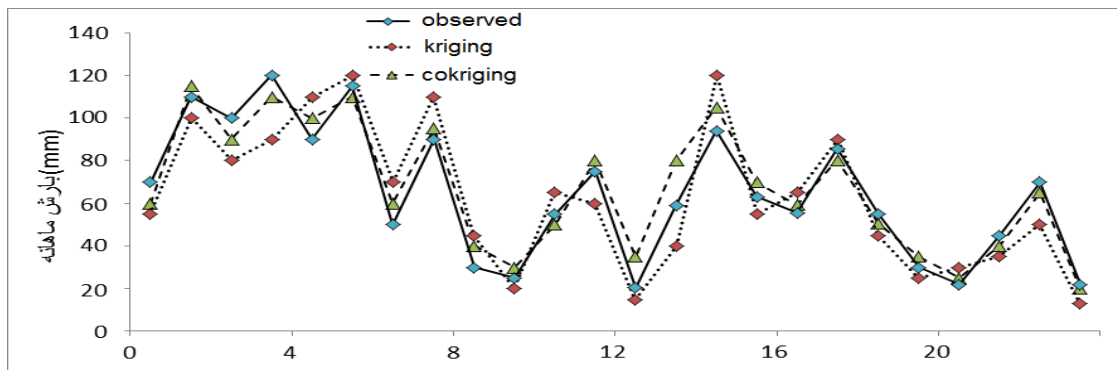
شکل ۶- مقایسه‌ی نتایج شبیه‌های TLFN و CFNN با داده‌های مشاهداتی ماهانه در ایستگاه نهاوند.



شکل ۷- مقایسه‌ی نتایج شبیه‌های MLP و CFNN با داده‌های ماهانه‌ی ایستگاه کرمانشاه.



شکل ۸- مقایسه‌ی نتایج شبیه‌های TLFN و CFNN با داده‌های ماهانه‌ی ایستگاه پل دختر.



شکل ۹- مقایسه‌ی نتایج شبیه‌های کوکریجینگ و کریجینگ با داده‌های ماهانه‌ی ایستگاه.

نتیجه گیری

این مطالعه نشان می‌دهد که نتایج دو شبیه MLP، کوکریجینگ و TLFN در تکمیل داده‌های بارش روزانه بهتر از بقیه شبیه‌ها می‌باشند. نتایج نشان می‌دهند که شبیه CFNN می‌تواند جایگزین شبیه MLP در بازسازی داده‌های بارش روزانه باشد. نتایج شبیه کریجینگ از شبیه‌های برتر (MLP، TLFN، کوکریجینگ و CFNN) ضعیفتر بوده، اما از شبیه‌های شبکه‌های پویا بهتر عمل می‌کند که می‌تواند در مواردی که دقت بسیار بالای داده‌های بازسازی شده مد نظر نباشد مورد استفاده قرار گیرد. شبیه RBF در بازسازی داده‌های بارش گم شده نسبت به بقیه شبیه‌ها کمتر مناسب به نظر می‌رسد. در مجموع، شبیه‌های انتخابی این مطالعه به عنوان بهترین شبیه یک چار چوب کاری جدید در بازسازی داده‌های بارش ارائه می‌دهد. این شبیه‌ها می‌توانند در سایر زمینه‌ها که در آنها هدف تکمیل نواقص داده‌های هواشناسی باشد توسعه یابند. سازگاری (انتخاب فراسنجهای داخلی مناسب) و آموزش شبیه‌ها بر اساس نوع و تعداد داده‌های در دسترس، تنها لازمه‌ی این کار است. یک مزیت ویژه‌ی شبیه‌های برتر هوش مصنوعی (MLP، TLFN و CFNN) مطالعه‌ی سادگی آموزش آنها در مقایسه با شبکه‌های پویا (RNN و TDRNN) می‌باشد که می‌توانند به آسانی آموزش یافته و در تکمیل داده‌های مفقود هواشناسی در زمینه‌های مختلف مورد استفاده قرار گیرند. البته، روشهای زمین آمار به دلیل عدم توانایی در بازسازی به حالت گروه داده‌ها، روندی بسیار طولانی را در بازسازی داده‌های روزانه دارند، (برای هر روز داده، باید یکبار شبیه به کار افتد)، اما توانایی بالای آنها در بازسازی دقیق داده‌ها استفاده از آنها را قابل قبول می‌نماید.

منابع

۳. ثقفیان، ب. ه.، رزمخواه، ب.، قرمز چشمه. ۱۳۹۰. بررسی تغییرات منطقه ای بارش سالانه با کاربرد روشهای زمین آمار (مطالعه موردی استان فارس). مجله مهندسی منابع آب. سال چهارم.
۴. رحیمی بندر آبادی، س. ب.، ثقفیان. ۱۳۸۶. برآورد توزیع مکانی بارندگی با کمک نظری مجموعه‌های فازی. تحقیقات منابع آب ایران. ۳(۲): ۲۶-۳۸
۵. شقاقی، م. م.، نظری فر. ر.، مومنی. ز.، زواره ای مقدم. ۱۳۸۵. بررسی تغییرات منطقه ای بارش ماهانه و سالانه حوضه کارون با استفاده از روشهای زمین آمار. اولین همایش منطقه ای بهره برداری بهینه از منابع آب حوضه‌های کارون و زاینده رود. شهرکرد.
۶. عساکره، ح. ۱۳۸۷. کاربرد روش کریجینگ در درون یابی بارش. مطالعه موردی درون یابی بارش در ایران. جغرافیا و توسعه. ۱۲: ۲۵-۴۲
۷. طایفه نسکیلی، ن. ۱۳۸۹. بررسی روشهای مختلف تحلیل داده های مفقود جریان رودخانه (مطالعه موردی حوضه بالادست سد کرخه). پایان‌نامه کارشناسی ارشد. دانشگاه آزاد اسلامی، واحد مهاباد.
۸. قهرودی تالی، م. ۱۳۸۱. ارزیابی درون یابی به روش کریجینگ. پژوهشهای جغرافیایی. ۴۳: ۹۵-۱۰۸
۹. میثاقی، ف. ک.، محمدی. ۱۳۸۵. پهنه بندی اطلاعات بارندگی با استفاده از روشهای آمار سنتی و زمین آمار و مقایسه با شبکه‌های عصبی مصنوعی. مجله علمی کشاورزی. ۲۹(۴): ۱-۱۴.
10. Abebe, A.J., D.P, Solomatine and R.G.W. Venneker. 2000. Application of adaptive fuzzy rule-based models for reconstruction of missing precipitation events. Hydrol. Sci. J 45:425-436.
11. Abghari, H., M, Mahdavi. A, Fakherifard, and A. Salajegheh, 2009. Cluster Analysis of Rainfall-Runoff training patterns to flow modeling using hybrid RBF networks. Asian J Appl. Sci. 2: 150-159.
12. Abghari H, H. Ahmadi, S. Besharat, V. Verdinejad. 2012. Prediction of daily pan evaporation using wavelet neural networks. J Water Resour.

۱. حسنی پاک، ع. ۱۳۷۷. زمین آمار (ژئواستاتستیک). انتشارات دانشگاه تهران، چاپ اول.
۲. ثقفیان، ب. س.، رحیمی بندر آبادی. ۱۳۸۴. مقایسه روشهای درون یابی و برون یابی برآورد توزیع مکانی مقدار بارندگی سالانه. تحقیقات منابع آب ایران. ۲(۲): ۷۴-۸۴

22. Coulibaly, P., F. Anctil, and B. Bobe'e. 2000. Daily reservoir in flow forecasting using artificial neural networks with stopped training approach. *J. Hydrol.* 230: 244–257.
23. Coulibaly, P., F. Anctil, R. Aravena, and B. Bobee. 2001a. Artificial neural network modeling of water table depth. *Water Resour. Re.* 37:885–896.
24. Coulibaly, P., F. Anctil, and B. Bobee, 2001b. Multivariate reservoir inflow forecasting using temporal neural networks. *J. Hydrol. Eng. ASCE* 6: 367–376.
25. Coulibaly, P., Y.B. Dibikey, and F. Anctil, 2005. Downscaling precipitation and temperature with temporal neural networks. *J. Hydrometeor.* 6:483–496.
26. Coulibaly, P., and N.D. Evora, 2007. Comparison of neural network methods for infilling missing daily weather records. *J. Hydrol.* 341:27–41
27. Creutin, J.D., E. Andrieu, and D. Faure, 1997. Use of weather radar for the hydrology of a mountainous area. Part II: radar measurement validation. *J. Hydrol.* 193:26–44.
28. Dibikey, Y.B, and P. Coulibaly, 2006. Temporal neural networks for downscaling climate variability and extremes. *Neural Net.* 19:135–144.
29. Diodato, N., and M. Ceccarelli, 2005. Interpolation processes using multivariate geostatistics for mapping of climatological precipitation mean in the Sannio Mountains (southern Italy). *Earth Surface Proc. Landforms.* 30: 259-268.
30. Drogue, G., J. Humbert, J. Deraisme, N. Mahr, and N. Freslon, 2002. A statistical topographic model using an omnidirectional parameterization of the relief for mapping orographic rainfall. *Inter. J. Climate.* 22: 599-613.
31. Elman, J.L., 1990. Finding structure in time. *Cogn, Sci.* 14:179–211.
32. Manage. 3639- 3652. DOI: 10.1007/s11269-012-0096-z.
13. Anctil F, Perrin C, Andre'assian V. 2003. ANN output updating of lumped conceptual rainfall/runoff forecasting models. *J Am. Water Resour. Assoc.* 39:1269–1279.
14. Chang, F.J., and Y.C. Chen. 2001. A counter propagation fuzzy-neural network modeling approach to real time stream flow prediction. *J. Hydrol* 245: 153–164.
15. Chang, F.J., H.F. Hu, Y.C. Chen. 2001. Counter propagation fuzzy-neural network for stream flow reconstruction. *Hydrol. Proc.* 15. 219–232.
16. Cheng, K, Sh. Lin, J.J. Liou. 2008. Rain-gauge network evaluation and augmentation using geostatistics. *Hydrol. Proc.* 22: 2554-2564.
17. Cigizoglu, H.K. 2005. Application of the generalized regression neural networks to intermittent flow forecasting and estimation. *J. Hydrol. Eng ASCE* 10: 336–341.
18. Cigizoglu, H. K., and O. Kisi. 2006. Methods to improve the neural network performance in suspended sediment estimation. *J. Hydrol* 317: 221–238.
19. Clouse D.S., C.L. Giles., B.G. Horne, and G.W. Cottrell. 1997. Time delay neural networks: Representation and induction of finite state machines. *IEEE Trans. Neural Net.* 8:1065–1070.
20. Coulibaly, P. and C.K. Baldwin. 2005. Non stationary hydrological time series forecasting using nonlinear dynamic methods. *J. Hydrol.* 307: 164–174.
21. Coulibaly, P., F. Anctil, and B. Bobe'e. 1999. Hydrological forecasting using artificial neural network: the state of the art (in French). *Canadian J Civ. Eng.* 26:293–304.

- basis function networks. *Neural Comput.* 3:246–257.
42. Pearlmutter, B.A. 1995. Gradient calculations for dynamic recurrent neural networks: a survey. *IEEE Trans Neural Net.* 6:1212–1228.
 43. Poggio, T., and F. Girosi, 1990. Networks for approximation and learning. *Proc the IEEE* 78:1481–1497.
 44. Principe, J.C., N.R. Euliano, and W.C. Lefebvre, 2000. *Neural and adaptive systems: fundamentals through simulations.* John Wiley, New York.
 45. Prechelt, L. 1998. Automatic early stopping using cross-validation: Quantifying criteria. *Neural Net.* 6:1212–1228.
 46. Rumelhart, D.E., Zipser, D. 1985. Feature discovery by competitive learning. *Cogn. Sci.* 9:75–112.
 47. Rumelhart, D.E., G.E. Hinton, and R.J. Williams, 1986. Learning internal representation by error propagation. p. 318–362. In: Rumelhart D.E, and McClelland J.L. (Eds.), *Parallel distributed Processing: explorations in the microstructure of cognition.* vol. 1. MIT Press, Cambridge. MA.
 48. Sirca, G.F., and H. Adeli, 2004. Counter propagation neural network model for steel girder bridge structures. *J. Bridge Engi.* 9:55–65.
 49. Specht, D.F. 1991. A general regression neural network. *IEEE Trans. Neural Net.* 2:569–576.
 50. Toth, E., A. Brath, and A. Montanari, 2000. Comparison of short-term rainfall prediction models for real-time flood forecasting. *J. Hydrol.* 239:132–147.
 51. Wettschereck, D., T. Dietterich, 1992. Improving the performance of radial basis function networks by learning center locations. p. 1133–1140 In: Moody J.E, Hanson S.J, Lippmann R.P. (Eds.). *Advances in neural*
 32. Feldkamp L.A, and G.V., Puskorius, 1998. A signal processing framework based on dynamic neural networks with application to problems in adaptation. filtering and classification. *Proc. IEEE* 86: 2259–2277.
 33. Hecht-Nielsen, R. 1987. Counter propagation networks. *Appl Opt.* 26: 4979–4984.
 34. Hsu, K., H.V. Gupta, X. Gao, and S. Sorooshian, 1999. Estimation of physical variables from multichannel remotely sensed imagery using a neural network: application to rainfall estimation. *Water Resour. Res.* 35: 1605–1618.
 35. Igúzquiza, E. P. 1998. Comparison of geostatistical methods for estimating the areal average climatological rainfall mean using data on precipitation and topography. *Int. J. Climate.* 8: 1031–1047.
 36. Khalil, M., U.S. Panu, and W.C. Lennox, 2001. Groups and neural networks based stream flow data infilling procedures. *J. Hydrol.* 241: 153–176.
 37. Luck, K.C., J.E. Ball, and A. Sharma. 2000. A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting. *J. Hydrol.* 227:56–65.
 38. Maier, H.R, and G.C. Dandy, 2000. Neural network for the prediction and forecasting of water resources variables: A review of modeling issues and applications. *Environ. Model. Softw.* 15:101–124.
 39. Nie, J. 1989. A class of new fuzzy control algorithms. In: *Proc IEEE Int. Confe Control and Appl.* p. 896–897.
 40. Nie, J., and D.A. Linkens, 1994. Fast self-learning multivariable fuzzy controllers constructed from a CPN network. *Int. J. Control* 60: 369–393.
 41. Park, J., and I.W. Sandberg. 1991. Universal approximation using radial

- information processing systems, Vol. 4. Morgan Kaufmann, San Mateo. CA.
52. Williams, R.J, and J. Peng, 1990. An efficient gradient-based algorithm for on-line training of recurrent network trajectories. *Neural Comput.* 2: 490–501.

