دانشگاه آزاد اسلامی واحد اهر
فصلنامه‌ی علمی- پژوهشی فضای جغرافیایی

سال سیزدهم، شماره‌ی ۴۲
تابستان ۱۳۹۲، صفحات ۲۵۱ -۲۲۹

آزاده امیری[۱]
مهدی نیکو[۲]
محمد نیکو[۳]

روندیابی سیلاب در رودخانه مارون با استفاده از سریهای زمانی در شبکه عصبی مصنوعی مودولار

تاریخ دریافت مقاله: ۹۰/۰۳/۲۳ تاریخ پذیرش مقاله: ۹۰/۱۱/۱۶

چکیده

روندیابی سیلاب، یکی از پیچیده ترین مسائلی است که در علم هیدرولیک کانال های باز و مهندسی رودخانه مورد بررسی قرار گرفته است. روش های مختلفی در زمینهٔ روندیابی سیلاب وجود دارند که به دو گروه گسترده و متمرکز تقسیم بندی می شوند. امروزه تکنیک جدید استفاده از مدل شبکه های عصبی مصنوعی تکاملی که مبتنی بر هوش مصنوعی می باشد کاربرد گسترده ای در زمینه های مختلف علمی به ویژه مهندسی آب پیدا کرده است. در این تحقیق به روندیابی سیل در رودخانه مارون، بازه خیرآباد-پل فلور با استفاده از مدل های شبکه عصبی مصنوعی تکاملی JEN, FF, MNN وRBF پرداخته شد. از جمله مواردی که به عنوان یک روش جدید بیان شده است تعیین تعداد و تاخیر زمانی موثر داده های ورودی در مدل های شبکه عصبی مصنوعی با استفاده از روش همبستگی عرضی خطی بین سری های زمانی ورودی ها و خروجی ها می باشد. با استفاده از الگوریتم ژنتیک ساختار مدل های شبکه عصبی مصنوعی از نظر تعداد لایه ها، تعداد گره ها در لایه پنهان، نوع تابع انتقال و الگوریتم یادگیری شبکه بهینه گردید. نتایج نشان می دهد که روش همبستگی عرضی به خوبی تعداد و تاخیر زمانی موثر داده های

۱- دکتری جغرافیا، استادیار دانشگاه، عضو هیات علمی دانشگاه آزاد اسلامی واحد اهواز E-mail: Geography8484@yahoo.com
۲- کارشناسی ارشد مهندسی عمران-سازه،آموزشکده فنی و حرفه ای سماء دانشگاه آزاد اسلامی اهواز E-mail: m.nikoo@iauahvaz.ac.ir
۳-کارشناسی ارشد مهندسی عمران-آب ، آموزشکده فنی و حرفه ای سماءدانشگاه آزاد اسلامی اهواز E-mail: sazeh84@yahoo.com

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

ورودی را تعیین می نماید. علاوه بر این مقایسه خروجی مدل ها با مقادیر واقعی نشان می دهد که مدل MNN انتخاب شده نسبت به مدل های آماری و مدل های دیگر شبکه عصبی مصنوعی توانایی ، انعطاف پذیری و دقت بیشتری در پیش بینی و روندیابی سیلاب در رودخانه مارون را دارند.

کلیدواژه ها: روندیابی سیلاب، شبکه عصبی مصنوعی مودولار، سری زمانی، الگوریتم ژنتیک، مدل های آماری، رودخانه مارون.

مقدمه

یکی از مهم ترین ویژگی‌های مدیریت حوضه رودخانه، پیش بینی سیلاب های اتفاق افتاده می‌باشد. مقدار خسارت-های اقتصادی مرتبط با سیلاب‌ها، نقش مدیریت سیلاب را برجسته می‌نماید. یک سیستم هشدار سیلاب مؤثر که براساس پیش‌بینی رویدادهای سیلابی هشدار می‌دهد، می‌تواند به طور اساسی این ضررها را کاهش دهد. در مسایل سیلابی، شدت بارش و ویژگی‌های هیدرولوژیکی سطح حوضه، عوامل بسیار مناسبی می‌باشند، همچنین فاکتورهایی مثل بارش قبلی، نفوذپذیری خاک، شیب زمین و غیره، نقش مؤثری در سیلابی شدن یا نشدن یک مقدار بارش در یک زمان مشخص ایفا می‌کنند. تأثیرگذاری فاکتورها و عوامل مختلف و وجود رابطه غیرخطی بین آنها، پیش‌بینی دبی جریان را امری پیچیده می‌کند. بسیاری از تکنیک‌هایی که امروزه در مدل سازی سری‌های زمانی و پیش بینی جریان استفاده می شوند، رابطه خطی بین متغیرها را فرض می کنند. شبکه‌های عصبی مصنوعی در زمینه‌های فراوانی از جمله منابع آب، به طور موفقیت آمیزی به کار گرفته شده‌اند. تجربیات و مطالعات اخیر نشان داده اند که شبکه-های عصبی مصنوعی می توانند جایگزین مطمئنی برای مدل‌سازی فرایند بارش – رواناب ، پیش بینی جریان و دبی ورودی به مخزن باشند.

آرجی کو[4] (۲۰۰۱:۲۱) در تحقیقی با عنوان شبکه عصبی مصنوعی تکاملی برای پیش بینی سیستم های هیدرولوژیکی بیان می کند که استفاده از الگوریتم ژنتیک برای بهینه سازی داده های ورودی شبکه های عصبی مصنوعی می تواند نتایج دقیق تری را نسبت به حالتی که از این الگوریتم استفاده نمی شود بدهد (۲۸) زنگ یونگ[5] (۲۰۰۹:۲۳۷۳) در تحقیقی با عنوان کاربرد شبکه عصبی مصنوعی برای پیش بینی ضریب اصطحکاک جریان کانال های باز بیان می کندکه مدل شبکه عصبی مصنوعی می تواند در مهندسی به عنوان یک روش عملی موثر و مناسب استفاده شود و مشکلات هیدرویکی که بیشتر بر پایه آزمایشات آزمایشگاهی استوار است می تواند به وسیله مدل شبکه های عصبی تحلیل شود(۳۱). لی هوآ فنگ[6] (۲۰۰۷:۲۹۷٤) در تحقیقی با عنوان محاسبه هیدرولوژیکی با استفاده از شبکه عصبی مصنوعی بیان می کندکه تکنولوژی شبکه عصبی مصنوعی یک راه نسبتا موثر برای حل مشکلات محاسبات

4 -R.J.Kuo
5 - Zeng Yuhong
6 - Lihua Feng

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

هیدرولوژیکی را فراهم می کند (۲۱). مندوزا [۷] و همکاران (۲۰۰٤:۳۸) برای پیش‌بینی روزانه جریان در رودخانه زالاس در شمال غربی اسپانیا از مدل آماری کلاسیک Box–Jenkins و شبکه‌های عصبی مصنوعی (ANNs) استفاده و با هم مقایسه نمودند. مقایسه نتایج نشان داد که عملکرد ANNs بهتر از مدل آماری Box–Jenkins می‌باشد (۲۳). زوگلا[۸] و همکاران (۲۰۰۳:۱) برای پیش‌بینی جریان روزانه رودخانه از شبکه عصبی پرسپترون چند لایه با الگوریتم آموزشی انتشار برگشتی پیش‌رونده (FFBP) و الگوریتم ژنتیک (EANN) استفاده نمودند. نتایج شبیه‌سازی ها نشان داد که شبکه EANN در مقایسه با شبکه FFBP و مدل‌های آماری متداول پیش‌بینی‌ها را بهتر انجام می‌دهد (30) کولی بالی[۹] و همکاران (۲۰۰۰:۲٤٤) برای پیش‌بینی جریان یک تا هفت روز آینده در فصل بهار حوزه chute-du-diable با وسعت $۹۷۰۰\ km^2$ در شمال کانادا مدلهای سری زمانی ARMAX و مدل تفهیمی PREVIS که برای بهره‌برداری از مخازن استفاده می‌شود را به کار بردند. همچنین ایشان در مقاله ای دیگر برای پیش‌بینی جریان ورودی به سد واقع در حوزه Chute-du-Diable برای یک تا هفت روز آینده در فصل بهار، عملکرد مدل شبکه عصبی را با مدل سری زمانی ARMAX و مدل مفهومی PREVIS مقایسه نمودند نتایج نشان داد که مدل های شبکه عصبی مصنوعی توانایی بسیار بالایی در پیش بینی جریان رودخانه را دارند (۱۰).

اطمینان حسنلویی و همکاران (۱۳۸۹:۱) به پیش بینی روندیابی هیدروگراف سیلاب رودخانه گدارچای با استفاده از شبکه های عصبی پرسپترون چند لایه و شعاعی پرداختند. آنها نشان دادند که استفاده از شبکه های عصبی مصنوعی به دلیل ساختار غیرخطی می تواند جایگزین مناسبی برای مدلهای آماری و ریاضی باشند (۱). حسین قلخانی و همکاران (۱۳۸۸:۱) به استفاده از شبکه عصبی مصنوعی در روندیابی زمان واقعی سیلاب رودخانه پرداختند. آنها در این تحقیق به مقایسه مدل های شبکه عصبی مصنوعی با مدل های هیدرولیکی HEC-RAS پرداختند نتایج نشان داد که مدل های شبکه عصبی مصنوعی توانایی بسیار بالایی در پیش بینی سیلاب رودخانه دارند (۶). بنی حبیب و همکاران (۱۳۸۷:۱) در تحقیقی به تعیین زمان پیش هشدار سیلاب در حوضه گلابدره- دربند با استفاده از مدل شبکه عصبی مصنوعی پرداختند. آنها برای آموزش شبکه از سیلاب ۱۰۰۰۰ ساله که ماگزیمم داده ها را شامل می شود استفاده نمودند. همچنین برای تست شبکه از سیلاب های ۲۵ تا ۱۰۰۰ ساله استفاده نمودند که ابتدا سیلابهای یاد شده را با استفاده از نرم افزار HEC-HMS برآورد نمودند و سپس در آموزش و آزمون مدل شبکه عصبی مصنوعی به کار بردند. آنها نشان دادند که مدل های شبکه عصبی مصنوعی توانایی بالایی در تعیین زمان پیش بینی هشدار در شرایط مختلف کاربری سطح حوضه دارند. بنی حبیب و همکاران (۱۳۸۷:۱) به استفاده از شبکه عصبی مصنوعی برای پیش بینی سیلاب در حوضه آبریز آجی چای پرداختند. آنها در تحقیقشان از یک شبکه عصبی مصنوعی MLP-BP با ۳۰ نرون در لایه مخفی استفاده نمودند و نشان دادند این که این مدل می‌تواند سیلاب حوضه را به خوبی شبیه‌سازی نماید (۳). مجتبی شفیعی و همکاران (۱۳۸۵:۱) به تحلیل منطقه ای سیلاب توسط شبکه های

7 - Mendeza
8 - Zougla
9 - Coulibaly

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

عصبی مصنوعی در حوضه ماسال استان گیلان پرداختند. هدف از ارائه این مقاله کاربرد مدل منطقه ای سیلاب توسط شبکه های عصبی مصنوعی برای تخمین دبی های حداکثر لحظه ای سیلاب با دوره برگشت های مختلف در حوضه آبریز ماسال در استان گیلان و مقایسه آن با مدل رگرسیونی می باشد، که نشان دهنده برتری شبکه های عصبی مصنوعی است (۵).

در همه مقالات ذکر شده برای تعیین داده های ورودی در شبکه های عصبی مصنوعی از روش صحیح و خطا استفاده نموده اند که این روش دارای حجم محاسباتی و صرف زمان بالا و کاهش دقت در پیش بینی سیلاب می باشد، اما در مقاله حاضر از سری های زمانی به تعیین پارامترهای ورودی در شبکه های عصبی مصنوعی تکاملی[10](EANN) استفاده می شود. هدف اصلی این تحقیق بررسی توانایی شبکه‌های عصبی تکاملی در شبیه سازی الگوهای مناسب و پیش‌بینی جریان روزانه رودخانه مارون بازه خیرآباد تا پل فلور می‌باشد. بدین منظور با استفاده از روش همبستگی عرضی خطی ، تاخیر زمانی موثر دو پارامتر دبی و اشل را در ایستگاه هیدرومتری بالادست (خیرآباد) بر روی ایستگاه هیدرومتری پایین دست (پل فلور) تعیین کرده و از نتایج حاصل از آن به عنوان پارامترهای ورودی در شبکه‌های عصبی تکاملی استفاده می شود. شبکه عصبی مصنوعی مورد استفاده MNN[11] می باشد که به منظور بهینه سازی مدل از نظر تعداد لایه ، تعداد گره ها در لایه پنهان ، نوع تابع انتقال و الگوریتم یادگیری شبکه از روش الگوریتم ژنتیک استفاده می گردد. برای تعیین دقت مدل پایدار MNN آن را با مدل های دیگر شبکه عصبی مصنوعی FF[12] ، JEN[13] ، RBF[14] و مدل های آماری رگرسیونی مقایسه می گردد.

مواد و روش ها

معرفی رودخانه مارون و ایستگاه های مورد مطالعه

رودخانه مارون یکی از رودخانه های جنوب غرب ایران است و سرحد جغرافیایی فارس و خوزستان بوده و امروزه از میان خاک کهگیلویه و سپس بهبهان می گذرد. نام اصلی و قدیمی رودخانه مارون ، تاب است این رود از کوه های نیل و چشمه سارهای دامنه کوه های سادات از زاگرس سرچشمه گرفته و پس از طی مسافت ۱۲۰ کیلومتر به دریاچه سد مارون می رسد و از طریق تنگ تکاب وارد بهبهان می شود و توسط سد انحرافی شهدا و شبکه آبیاری بهبهان ، دشت بهبهان و سپس از طریق سد انحرافی جایزان ، دشت جایزان را مشروب و در محلی به نام قلعه شیخ ، پس از دریافت رود اعلا رامهرمز ، نام جراحی به خود گرفته و به هور شادگان می ریزد ، این رود در مواقع پرآبی از طریق خور موسی وارد خلیج فارس می شود. ایستگاه های مورد مطالعه در این تحقیق ایستگاه های خیرآباد و پل فلور می باشند. ایستگاه خیرآباد با مختصات جغرافیایی طول ۵۰ درجه ۲٤ دقیقه، عرض ۳۰ درجه ۳۱ دقیقه و

10 - Evolutionary Artificial Neural Network
11 - Modular Neural Network
12 - Feed Forward
13 - Jordan Elman Network
14 - Radial Basic Function

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

ارتفاع ایستگاه از سطح دریا ۳۸۰ متر می باشد. همچنین ایستگاه پل فلور با مختصات جغرافیایی طول ۵۰ درجه ۱۷ دقیقه، عرض ۳۰ درجه ۲۰ دقیقه و ارتفاع ایستگاه از سطح دریا ۲۰۰ متر می باشد، که در شکل (۱-۱) نمایش داده شده است.



شکل شماره ۱- نمایی از مسیر رودخانه مارون

سـری‌هـای زمـانـی

تحلیل سری‌های زمانی به طور نظری و عملی از سال ۱۹۷۰ به بعد برای پیش‌بینی و کنترل به سرعت توسعه پیدا کرده است. این تحلیل معمولاً به داده‌هایی مربوط می‌شود که مستقل نبوده و به طور متوالی به هم وابسته اند. همین وابستگی بین مشاهدات متوالی است که مورد توجه قرار می‌گیرد و بیشتر کاربرد آن در پیش‌بینی خواهد بود. توابع سری‌های زمانی برای یک مجموعه از داده که به طور متوالی به دست آمده اند به صورت زیر نمایش داده می شود.

$$y_t = \alpha_0 + \alpha_1 T^1 + \alpha_2 T^2 + ... + \alpha_n T^n \qquad (۱)$$

که در آن y_t متغیر وابسته حاصل از مشاهدات سری های زمانی، $\alpha_n,...,\alpha_2,\alpha_1,\alpha_0$ ضرایب توابع خودهمبستگی، T متغیرمستقل زمانی می باشد.ضرایب $\alpha_n,...,\alpha_2,\alpha_1,\alpha_0$ را از طریق تابع خود همبستگی ACF[15] با استفاده از نرم-افزارهای آماری مانند MINITAB می توان به دست آورد. برای آن که بتوان تأثیر یک سری زمانی را بر روی سری زمانی دیگر به دست آورد باید از تابع همبستگی عرضی CCF[16] استفاده نمود که در این حالت بازه زمانی موثر به صورت زیر به دست می‌آید.

$$-(10+\sqrt{n}) \le K \le +(10+\sqrt{n}) \qquad (۲)$$

15 - Auto Correlation Function
16 - Cross Correlation Function

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

که در آن K ، تاخیر زمانی[۱۷] مؤثر در سری زمانی پایین دست و n ، تعداد داده های مشاهده ای در سری‌های زمانی می‌باشد.

شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی یکی از پویاترین حوزه‌های تحقیقاتی در دوران معاصر می‌باشد که توجه افراد بسیاری از رشته‌های گوناگون علمی را به خود جلب کرده است. فعالیت‌های تحقیقاتی اخیر در زمینه شبکه‌های عصبی نشان داده است که این روش توانایی بسیار بالایی در حل مسائل پیچیده در کلیه رشته‌های مهندسی را دارد. متشابه با مغز واقعی انسان، شبکه‌های عصبی توانایی لازم را در یادگیری داشته و قادر به به کار بردن و استفاده از تجارب به دست آمده در مسائل نو و مشابه می باشند. شبکه‌های عصبی مصنوعی با وجود اینکه با سیستم عصبی طبیعی قابل مقایسه نیستند، ویژگی‌هایی دارند که آنها را در بعضی از کاربردها مانند تفکیک الگو و یا هرجا که نیاز به یادگیری با یک نگاشت خطی و یا غیرخطی باشد، ممتاز می نمایند. می‌توان از ویژگی‌ها و قابلیت‌های شبکه‌های عصبی مصنوعی به مواردی همچون قابلیت یادگیری و تطبیق پذیری با اطلاعات موجود، قابلیت تعمیم دهی، پردازش موازی ورودی-های شبکه و در نتیجه افزایش سرعت پردازش، تحمل پذیری بالای خطاها و.. اشاره کرد. شبکه‌های عصبی مصنوعی یک سیستم پردازشگر اطلاعات توده‌ای هستند که به صورت موازی قرار گرفته‌اند و عملکردی شبیه شبکه عصبی مغز انسان دارند. اصول زیر نشانگر اساس شبکه‌های عصبی مصنوعی می‌باشند:

۱.پردازش داده‌ها در واحدهای منفردی به نام گره صورت می‌گیرد.

۲. سیگنال‌های بین گره‌ها از طریق خطوط ارتباطی انتقال می‌یابند.

۳. وزن نسبت داده شده به هر خط ارتباطی نشانگر قدرت ارتباطی آن خط است.

٤. هر گره به طور معمول دارای توابع فعال‌سازی[۱۸] و تبدیلگر برای تعیین سیگنال‌های خروجی از داده‌های ورودی شبکه می‌باشد. ساختار شبکه‌های عصبی مصنوعی بوسیله الگوی ارتباط بین گره‌ها، متد تعیین وزن‌های ارتباطی و تابع فعالیت، معرفی می‌شود (فلچر و ریوز ١٩٦٤)، ساختار عادی یک شبکه عصبی مصنوعی، معمولاً از لایه ورودی، لایه‌های میانی (پنهان) و لایه خروجی تشکیل شده است (شکل۱). لایه ورودی یک لایه انتقال دهنده و وسیله‌ای برای تهیه کردن داده‌هاست. آخرین لایه یا لایه خروجی شامل مقادیر پیش بینی شده بوسیله شبکه می‌باشد و بنابراین خروجی مدل را معرفی می‌کند. لایه های میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌هاست. شمار لایه‌های مخفی و شمار گره‌ها در هر لایه مخفی به طور معمول بوسیله روش آزمون و خطا مشخص می شود. گره‌های لایه‌های مجاور در شبکه به طور کامل با هم در ارتباط هستند. ورودی های هر گره ممکن است از متغیرهای ورودی یا از خروجی گره‌های دیگر حاصل شود. هر گره دارای یک تابع تبدیل‌گر[۱۹] است.

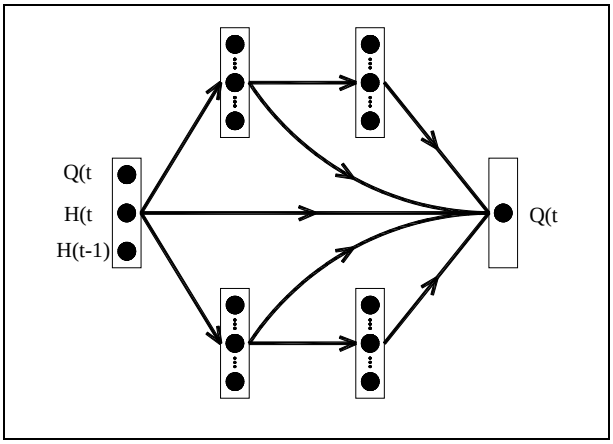
17 -Lag
18-Activation Function
19 -Transfer Function

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

ورودی‌ها به شکل یک بردار $X(x_1$ و x_2 . .. و $x_n)$ هستند و هر ورودی توسط یک وزن به گره پردازش‌گر مربوط می‌شود و در نهایت تسلسلی از وزن‌ها به شکل بردار وزن $W(w_1$ و w_2 . .. و $w_n)$ به گره مورد نظر مرتبط می‌گردد، w وزن ارتباطی از گره لایه پیشین به لایه مزبور را نشان می‌دهد. خروجی گره که y نامیده می‌شود، طبق رابطه (۳) محاسبه می‌شود (۷):

$$y = f(x.w - b) \qquad (۳)$$

x داده‌های ورودی، w بردار وزن، b مقدار آستانه یا بایاس[۲۰] می‌باشند. درون هر گره پردازش‌گر تابع تبدیل‌گر، تولید کننده خروجی‌های آن گره به شمار می‌رود. در شبکه های مودولار، لایه های میانی به دو قسمت جدا و به موازات هم قرار می گیرند تا وزن های مورد استفاده به جای اینکه بین تمامی گره ها تقسیم شوند به دو قسمت مجزا وارد گردند و در هرقسمت به طور جداگانه تقسیم گردند این امر موجب افزایش سرعت و کاهش زمان در تحلیل شبکه می باشد از خصوصیات منحصر به فردی که در هیچکدام از انواع شبکه های عصبی مصنوعی وجود ندارد، در شکل (۱-۲) یک نمونه از شبکه عصبی مصنوعی مودولار نشان داده شده است.



شکل شماره ۲- یک نمونه از شبکه عصبی مصنوعی مودولار با چهار لایه

در ساختار شبکه های عصبی مصنوعی از توابع تبدیل گر(تحریک) گوناگون Linear Axon, BiasAxon, Linear Sigmohid Axon Linear Tanh Axon, Sigmohid Axon, Tanh Axon می توان استفاده نمود. برای ارزیابی دقت مدل شبکه عصبی مصنوعی معمولاً دو معیار مختلف NMSE (متوسط خطای مربعات نرمال شده) و r استفاده می‌شود. MSE به صورت زیر محاسبه می‌شود :

$$MSE = \frac{\sum_{j=0}^{P}\sum_{i=0}^{N}(d_{ij} - y_{ij})^2}{N \times P} \qquad (٤)$$

20 -Bias

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

NMSE متوسط خطای مربعات نرمال شده می باشد که به وسیله فرمول زیر بیان می شود:

$$NMSE = \frac{P \times N \times MSE}{\sum_{j=0}^{P} \frac{N\sum_{i=0}^{N} d_{ij}^{\,2} - \left(\sum_{i=0}^{N} d_{ij}\right)^2}{N}} \qquad (۵)$$

که در آن، P تعداد خروجی عناصر پردازش شده، N تعداد نمونه ها در مجموعه داده ها، y_{ij} خروجی شبکه برای نمونه i در عنصرپردازش شده j ، d_{ij} خروجی مورد نظر برای نمونه i در عنصر پردازش شده j می باشد. MSE اختلاف مابین مقدار مشاهده شده و مقادیر محاسبه شده را نشان می‌دهد. کمترین مقدار MSE بالاترین صحت پیشگویی را بیان می کند.همچنین r نشانگر میزان بازده شبکه می‌باشد که به صورت زیر ارائه می‌گردد:

$$r = \frac{\frac{\sum_i \left(x_i - \bar{x}\right)\left(d_i - \bar{d}\right)}{N}}{\sqrt{\frac{\sum_i \left(d_i - \bar{d}\right)^2}{N}}\sqrt{\frac{\sum_i \left(x_i - \bar{x}\right)^2}{N}}} \qquad (٦)$$

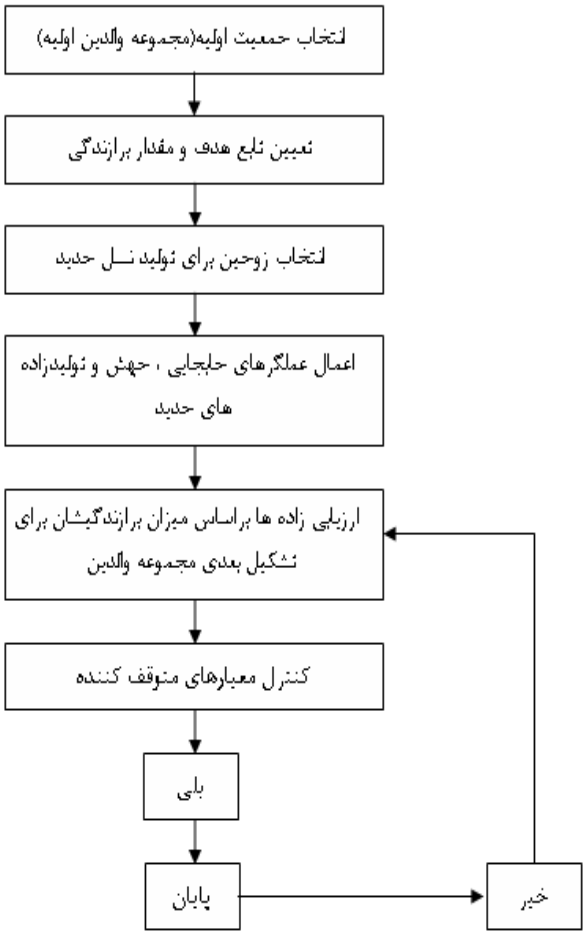
که x_i خروجی شبکه ، d_i خروجی مورد نظر ، $\bar{x}$ میانگین خروجی شبکه و $\bar{d}$ میانگین خروجی مورد نظر می باشد. بهترین جواب برای مدل هنگامی ایجاد خواهد شد که r و MSE به ترتیب به یک و صفر میل کنند .

روش بهینه سازی الگوریتم ژنتیک

الگوریتم ژنتیک الهام گرفته از طبیعت است و تکامل طبیعت با فرضیه داروین، اساس شکل گیری آن می باشد که در آن بهترین ها حق بقا را دارند. روش کار به این صورت است که ، در فرایند تکثیر ، کروموزوم هایی با شایستگی بالا شانس تکرار بیشتر در جمعیت منتخب را پیدا می کنند که این کار توسط فرایند انتخاب صورت می پذیرد. بدین منظور روش های متنوعی مطرح شده است و روش چرخ گردان معروف ترین آنهاست، همچنین از انتخاب نخبه گرا نیز استفاده شده که در هر نسل تعدادی از برازنده ترین افراد بدون تغییر به نسل بعد منتقل شده است. پس از تکمیل فرایند انتخاب ،نوبت به اعمال عمگر بر روی جهت منتخب به منظور تولید جمعیت فرزندان می رسد. در انجام فرایند پیوند،با انتخاب مقدار ثابت نرخ پیوند، به ترتیب برای هر کروموزوم یک عدد تصادفی تولید می شود. اگر عدد تصادفی تولید شده از نرخ پیوند کمتر باشد، این کروموزوم انتخاب می شود تا به کروموزوم های بعدی که شرایط فوق را دارد ، آمیزش نماید. در این روش از میان انواع مختلف پیوند، پیوند یکنواخت مورد استفاده قرار گرفته است، سپس نوبت به اعمال عملگر جهش می رسد، هدف از این کار ایجاد پراکندگی بیشتر در محدوده کاوش فضای طراحی است. در انجام فرایند جهش، با انتخاب نرخ ثابت جهش، برای کلیه بیتهای کروموزوم های

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

جمعیت عددتصادفی تولید می شود اگر عدد تصادفی تولید شده از نرخ جهش کوچک تر باشد، مقدار آن بیت عوض یعنی مقدار صفر به یک و برعکس تبدیل می شود. الگوریتم ژنتیک هنگامی که برخی ضوابط مانند تعداد معینی تولید نسل و یا میانگین انحراف معیار عملکرد اشخاص جمعیت تامین شود،به پایان می رسد. در شکل زیر فرایند کلی حل مساله را در الگوریتم ژنتیک به طور خلاصه نشان داده شده است (۲٤).



شکل شماره ۲- فرایند حل مسائل بهینه سازی با استفاده از الگوریتم ژنتیک

نتایج و بحث

جامعه آماری مورد استفاده

در این تحقیق داده‌ها از دو ایستگاه های هیدرومتری از تاریخ ۱۳٦۷ تا ۱۳۸٦ مورد استفاده قرار گرفته است، همچنین پارامترهای دبی و اشل به صورت روزانه اندازه گیری شده است، تعداد الگوهای مورد استفاده در این تحقیق به تفکیک سال در جدول زیر آماده است :

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

جدول ۱- تعدادالگوهای مورد استفاده در شبکه عصبی مصنوعی در سال های مختلف

رودخانه	ایستگاه	سال	تعدادالگو	سال	تعدادالگو	سال	تعدادالگو	سال	تعدادالگو
مارون	خیرآباد- پل فلور	۱۳٦۷	۱۳۳	۱۳۷۲	۲٤٦	۱۳۷۷	۲۷۳	۱۳۸۲	۳٤٥
		۱۳٦۸	۲۷٦	۱۳۷۳	۲۷٦	۱۳۷۸	۲۷۱	۱۳۸۳	۳۳۹
		۱۳٦۹	۲٦۹	۱۳۷٤	۲۷٤	۱۳۷۹	۲٦۹	۱۳۸٤	۳۳۰
		۱۳۷۰	۲۷٦	۱۳۷٥	۲٦۹	۱۳۸۰	۲۷٤	۱۳۸٥	۳۳٥
		۱۳۷۱	۲٦٤	۱۳۷٦	۲۷۲	۱۳۸۱	۳٦٤	۱۳۸٦	۳٤٦
جمع	٦۰٥۷ الگو								

داده های ورودی بهینه

برای آن که بتوان یک رابطه خطی بین دو سری زمانی دبی و اشل ایستگاه هیدرومتری خیرآباد و پل فلور تعیین نمود از ضریب پیرسن[21] استفاده می شود. هر چقدر این ضریب به عدد یک نزدیکتر باشد ، همبستگی خطی بین دوسری زمانی بیشتر است. با استفاده از نرم افزار SPSS ضریب پیرسن را برای دو پارامتر دبی و اشل در بازه خیرآباد – پل فلور تعیین شده که در جدول (۲) آمده است. با توجه به جدول(۲) چون ضریب پیرسن به عدد یک نزدیک و پارامتر Sig. (2-tailed) از ۰/۰۰۵ کمتر می باشد می‌توان نتیجه گرفت که در تمام ٦۰٥۷ روز داده یک همبستگی خطی بین سری‌های زمانی دبی و اشل در ایستگاه های هیدرومتری خیر آباد و پل فلور وجود دارد.

جدول ۲- همبستگی خطی بین سری‌های زمانی دبی و اشل در ایستگاه های هیدرومتری خیر آباد و پل فلور

		دبی ایستگاه خیر آباد	اشل ایستگاه خیر آباد
دبی ایستگاه پل فلور	Pearson Correlation	۰/۹۲٥	۰/۸٤٤
	Sig. (۲- tailed)	۰/۰۰۰	۰/۰۰۰
	تعداد الگوها	۶۰۷	٦۰۷

با استفاده از تابع همبستگی عرضی[22](CCF) تاخیر زمانی موثر بین سری‌های زمانی دبی و اشل در ایستگاه های خیرآباد و پل فلور را می توان به دست آورد. با توجه به این که کل الگوها به صورت روزانه برابر ٦۰٥۷ روز می-باشد بنابراین متغیر n در معادله (۲) برابر ٦۰٥۷ بوده و خواهیم داشت:

$$-87 \le K \le +87 \qquad (۷)$$

21- Pearson Correlation
22- Cross Correlation Function

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

بنابراین در کل دوره ۲۰ ساله در بازه ۸۷ روز ، تا روزی را در نظر می‌گیریم که ضریب همبستگی در آن بیشتر از ۰/۵ باشد. نتایج حاصل از همبستگی عرضی بین داده های دبی و اشل در جدول(۳) نشان داده شده است.

جدول۳- همبستگی عرضی بین داده های دبی و اشل در رودخانه مارون بین دو ایستگاه خیر آباد-پل فلور

تاثیر دبی در روزهای قبل ایستگاه خیرآباد نسبت به دبی پل فلور								تاثیر اشل در روزهای قبل ایستگاه خیرآباد نسبت به دبی پل فلور							
CCF	روز	CCF	روز	CCF	روز	CCF	روز	CCF	روز	CCF	روز	CCF	روز	CCF	روز
۰/۰۱۲	٦٦	۰/۰٤۱	٤٤	۰/۱۲۳	۲۲	۰/۹۳٦	۰	۰/۰۷۱	٦٦	۰/۱۱٦	٤٤	۰/۱۹٦	۲۲	۰/۹٤۳	۰
۰/۰۰۷	٦۷	۰/۰٤٤	٤٥	۰/۱۱۸	۲۳	۰/٤۸	۱	۰/۰٥۸	٦۷	۰/۱۱۸	٤٥	۰/۱۹٥	۲۳	۰/۷٥٤	۱
۰/۰۰۷	٦۸	۰/۰٤۸	٤٦	۰/۱٤۱	۲٤	۰/۳۱	۲	۰/۰٥۸	٦۸	۰/۱۱۷	٤٦	۰/۲۱	۲٤	۰/۳۳٤	۲
۰/۰۰٥	٦۹	۰/۰٤۳	٤۷	۰/۱۳۸	۲٥	۰/۲۷۷	۳	۰/۰٥۷	٦۹	۰/۱۱۹	٤۷	۰/۲۰٤	۲٥	۰/۲۷٦	۳
۰/۰۱٥	۷۰	۰/۰٤	٤۸	۰/۱۱٦	۲٦	۰/۳۰٥	٤	۰/۰٥۹	۷۰	۰/۱۱۹	٤۸	۰/۱۹۳	۲٦	۰/۲۷۷	٤
۰/۰۲٤	۷۱	۰/۰٥۷	٤۹	۰/۰۸۸	۲۷	۰/۲٥٦	٥	۰/۰٦۹	۷۱	۰/۱۲۱	٤۹	۰/۱۷	۲۷	۰/۲٥۸	٥
۰/۰۱۷	۷۲	۰/۰۷	٥۰	۰/۰۸۸	۲۸	۰/۲۰٥	٦	۰/۰٦٦	۷۲	۰/۱۲۷	٥۰	۰/۱۷۱	۲۸	۰/۲٤۳	٦
۰/۰۳٤	۷۳	۰/۰٥۸	٥۱	۰/۰۷	۲۹	۰/۱۹٦	۷	۰/۰٦٥	۷۳	۰/۱۱٥	٥۱	۰/۱٥۷	۲۹	۰/۲٤۷	۷
۰/۰۱	۷٤	۰/۰٥٥	٥۲	۰/۰٦٥	۳۰	۰/۱۸۷	۸	۰/۰٥٤	۷٤	۰/۱۱٦	٥۲	۰/۱٥۷	۳۰	۰/۲٥۲	۸
۰/۰۰٥	۷٥	۰/۰٥٤	٥۳	۰/۰۷۳	۳۱	۰/۲۳۲	۹	۰/۰٥۲	۷٥	۰/۱۰٦	٥۳	۰/۱٥٥	۳۱	۰/۲٥۳	۹
-۰	۷٦	۰/۰٤٦	٥٤	۰/۰۷۱	۳۲	۰/۱۷۳	۱۰	۰/۰٤٦	۷٦	۰/۱	٥٤	۰/۱٥	۳۲	۰/۲۱۹	۱۰
-۰/۰۱	۷۷	۰/۰۳۸	٥٥	۰/۰٦۳	۳۳	۰/۱۳۸	۱۱	۰/۰٤۳	۷۷	۰/۰۹۷	٥٥	۰/۱٤۷	۳۳	۰/۲۱۷	۱۱
-۰/۰۲	۷۸	۰/۰۲۷	٥٦	۰/۰٥	۳٤	۰/۱٤۸	۱۲	۰/۰۳٦	۷۸	۰/۰۹۲	٥٦	۰/۱۳٥	۳٤	۰/۲۰٦	۱۲
-۰/۰۲	۷۹	۰/۰۳	٥۷	۰/۰٥۳	۳٥	۰/۲۱۸	۱۳	۰/۰۳۳	۷۹	۰/۰۸۸	٥۷	۰/۱٤	۳٥	۰/۲٥	۱۳
-۰/۰۲	۸۰	۰/۰۲	٥۸	۰/۰٥٥	۳٦	۰/۲۱٤	۱٤	۰/۰۳۱	۸۰	۰/۰۷۸	٥۸	۰/۱۳٦	۳٦	۰/۲۲٥	۱٤
-۰/۰۲	۸۱	۰/۰۲۱	٥۹	۰/۰٥۳	۳۷	۰/۱٥۹	۱٥	۰/۰۳۳	۸۱	۰/۰۷٦	٥۹	۰/۱۳۲	۳۷	۰/۲۰۹	۱٥
-۰/۰۲	۸۲	۰/۰۱۸	٦۰	۰/۰۸	۳۸	۰/۱٤	۱٦	۰/۰۳۱	۸۲	۰/۰۷۳	٦۰	۰/۱۳۸	۳۸	۰/۱۹۱	۱٦
-۰/۰۲	۸۳	۰/۰۲	٦۱	۰/۰۸٦	۳۹	۰/۱٦۳	۱۷	۰/۰۳۲	۸۳	۰/۰۷۲	٦۱	۰/۱۳۹	۳۹	۰/۲۱	۱۷
-۰/۰۲	۸٤	۰/۰۲۲	٦۲	۰/۰٦٦	٤۰	۰/۱٥	۱۸	۰/۰۳۱	۸٤	۰/۰۷٦	٦۲	۰/۱۲٦	٤۰	۰/۲۰۱	۱۸
-۰/۰۲	۸٥	۰/۰٤۱	٦۳	۰/۰٥	٤۱	۰/۱٤۲	۱۹	۰/۰۳	۸٥	۰/۰۸۱	٦۳	۰/۱۲۸	٤۱	۰/۱۹٤	۱۹
-۰/۰۲	۸٦	۰/۰٦٥	٦٤	۰/۰٥٦	٤۲	۰/۱۱٥	۲۰	۰/۰۲۹	۸٦	۰/۰۹۲	٦٤	۰/۱۲٤	٤۲	۰/۱۸۹	۲۰
-۰/۰۱	۸۷	۰/۰۲۷	٦٥	۰/۰٤۸	٤۳	۰/۱٤٤	۲۱	۰/۰۳۲	۸۷	۰/۰۷۹	٦٥	۰/۱۱٤	٤۳	۰/۲	۲۱

با توجه به جدول(۳) تاخیر زمانی موثر بین ایستگاه خیرآباد و پل فلور برای مقادیر اشل برابر دو روز قبل و برای مقادیر دبی همان روز در نظر گرفته می شود. بنابراین تعداد پارامترهای ورودی در مدل های شبکه عصبی مصنوعی برابر سه پارامتر $H(t-1), H(t), Q(t)$ در ایستگاه خیرآباد و پارامتر خروجی برابر یک پارمتر $Q(t)$ در ایستگاه پل فلور می باشد.

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

در مدل های شبکه عصبی مصنوعی تعداد ورودی‌ها سه پارامتر $H(t-1), H(t), Q(t)$ و تعداد خروجی، یک پارامتر $Q(t)$ می باشند که در شکل(۱) نشان داده شده است. در این تحقیق از چهار مدل شبکه JEN,RBF، MNN و FF برای آموزش استفاده شده است. همچنین برای بهینه کردن ساختار و توپولوژی هر شبکه از الگوریتم ژنتیک استفاده گردید. از ٦٠٥٧ الگو داده ها ، ۷۰٪ الگوها (٤٢٣٩ الگو) برای آموزش[۲۳] و ۱۵٪ الگوها (۹۰۹ الگو) برای ارزیابی[۲٤] و ۱۵٪ انتخابی الگوها (۹۰۹ الگو) برای آزمون[۲۵] شبکه مورد استفاده قرار گرفت. توابع تحریک مختلف شامل Linear Tanh Axon, Sigmohid Axon, Tanh LinearAxon, Bias Axon, Linear Sigmohid Axon, Axon و الگوریتم‌های آموزش مختلف شامل Delta Bar Delta, Leven berg Marquat, Momentum ،Quickprop و Step جهت تعیین ساختار بهینه مدل های شبکه عصبی مصنوعی تکاملی در نظر گرفته شد. برای تعیین تعداد گره‌های لایه پنهان علاوه بر پیش فرض نرم افزار از فرمول تجربی زیر استفاده شد [16].

$$N_H \le 2N_I + 1 \qquad (۸)$$

که در آن N_H حداکثر تعداد گره‌های لایه‌های پنهان و N_I تعداد ورودی‌ها می‌باشد.با توجه به اینکه تعداد ورودی های موثر به دست آمده برابر با ۳ عدد می باشد ، حداکثر تعداد گره های لایه پنهان برابر با ۷ عدد می باشد $(N_H \le 7)$.برای تعیین ساختار بهینه هریک از مدل های شبکه عصبی مصنوعی تکاملی JEN، MNN ، FF و RBF از نظر تعداد لایه های پنهان، تعداد گره ها در لایه های پنهان ، الگوریتم یادگیری شبکه ، تابع انتقال و قابلیت الگوریتم بهینه سازی ژنتیک از نرم افزارNeuroSolutions ver5.0 استفاده می شود. جدول زیر ساختار بهینه هریک از مدل ها و مشخصات مختلف آنها که از الگوریتم ژنتیک به دست آمده را نشان می دهد.

جدول ٤- ساختار بهینه مدل های MNN ، FF ، JEN و RBF

ردیف	نام مدل	تعداد ورودیها	تعداد خروجی ها	تعداد لایه پنهان	تعدادگره های لایه پنهان	تابع انتقال	الگوریتم یادگیری شبکه
۱	MNN	۳	۱	۲	۲۵-۱۵	TanhAxon	Momentum
۲	FF			۱	۷	LinearSigmoidAxon	Delta Bar Delta
٤	JEN			۱	۵	SigmoidAxon	LevenbergMarquat
۳	RBF			۱	۱۰	LinearAxon	QuickProp

همچنین جداول (۵) تا (۷) نتایج حاصل از آموزش، اعتباریابی همزمان با آموزش و آزمون هر یک از مدلها با ساختار بهینه که در جدول (٤) آمده است را نشان می دهد.به منظور عملکرد مدل ها و تعیین بهترین مدل ، معیار

23 - Training
24 - Cross Validation
25 - Test

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

NMSE و r حاصل از آزمون مدل ها با یکدیگر مقایسه می شود. همانطور که در جداول (۵) تا (۷) ملاحظه می شود مدل MNN دارای بیشترین همبستگی (r) برای داده های دبی رودخانه در ایستگاه پل فلور در مرحله آزمون نسبت به سه مدل دیگر می باشد. علاوه بر این مقادیر دبی رودخانه در ایستگاه پل فلور نسبت به مقادیر متناظر اندازه گیری شده واقعی در مرحله آموزش،اعتباریابی و آزمون به ازای مدل های مختلف در شکل های (۳) تا (۵) نشان داده شده است.

جدول ۵- نتایج حاصل از مدل های بهینه MNN ، JEN, FF و RBF در مرحله آموزش

ردیف	مدل	دبی رودخانه در ایستگاه پل فلور			
		نتایج حاصل از نرم افزار Neuro solutions		نتایج حاصل از گرافها	
		r	NMSE	R^2	Equation
۱	MNN	0.957	0.084	0.916	y = 0.936x + 2.9614
۲	FF	0.879	0.489	0.772	y = 0.3856x + 38.703
۳	JEN	0.915	0.558	0.837	y = 0.2648x + 28.476
٤	RBF	0.718	0.492	0.515	y = 0.4516x + 17.609

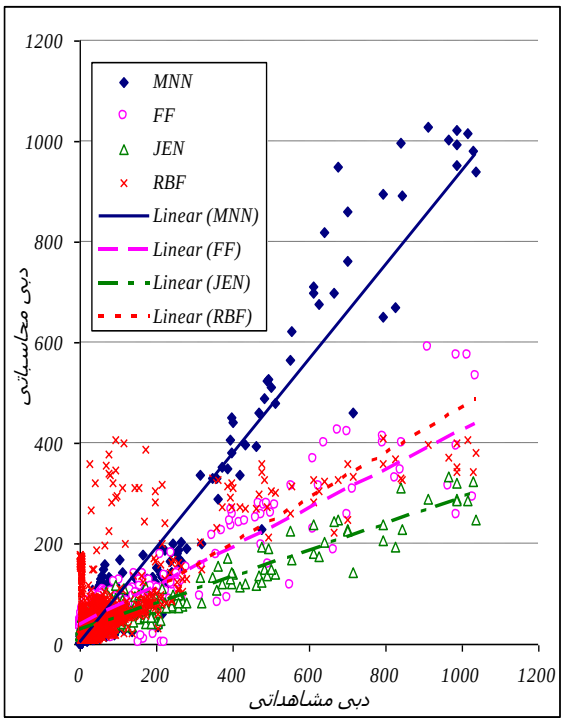
جدول ٦- نتایج حاصل از مدل های بهینه MNN ، JEN, FF و RBF در مرحله اعتباریابی

ردیف	مدل	دبی رودخانه در ایستگاه پل فلور			
		نتایج حاصل از نرم افزار Neuro solutions		نتایج حاصل از گرافها	
		r	NMSE	R^2	Equation
۱	MNN	0.950	0.163	0.903	y = 0.9103x + 2.6389
۲	FF	0.842	0.466	0.708	y = 0.4313x + 36.503
۳	JEN	0.887	0.562	0.787	y = 0.2657x + 28.314
٤	RBF	0.668	0.561	0.446	y = 0.5019x + 17.994

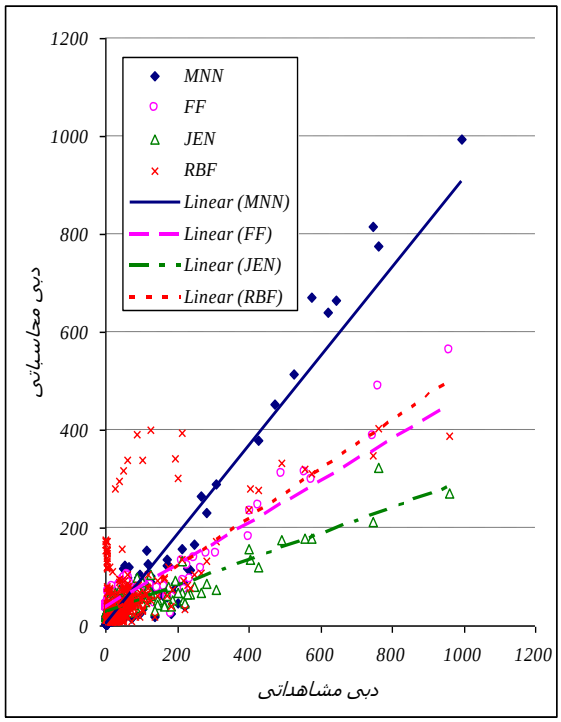
جدول ۷- نتایج حاصل از مدل های بهینه MNN ، JEN, FF و RBF در مرحله آزمون

ردیف	مدل	دبی رودخانه در ایستگاه پل فلور			
		نتایج حاصل از نرم افزار Neuro solutions		نتایج حاصل از گرافها	
		r	NMSE	R^2	Equation
۱	MNN	0.957	0.084	0.917	y = 0.91x + 2.7372
۲	FF	0.933	0.413	0.870	y = 0.4393x + 37.233
۳	JEN	0.914	0.581	0.836	y = 0.2477x + 28.539
٤	RBF	0.733	0.479	0.538	y = 0.445x + 17.025

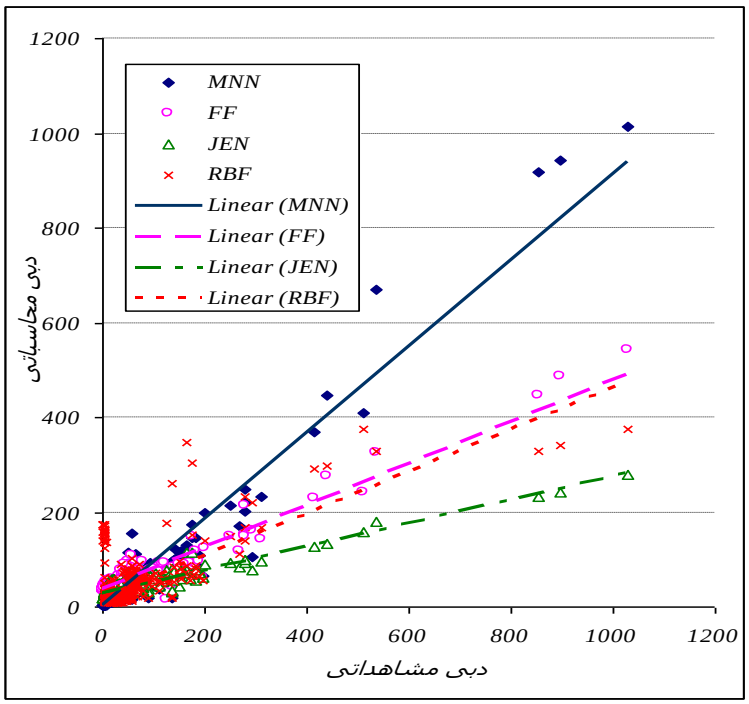
[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]



شکل شماره ۳-مقایسه دبی مشاهداتی و محاسباتی در ایستگاه پل فلور توسط مدل های EANN در مرحله آموزش



شکل شماره ٤- مقایسه دبی مشاهداتی و محاسباتی در ایستگاه پل فلور توسط مدل های EANN در مرحله اعتباریابی



شکل شماره ٥- مقایسه دبی مشاهداتی و محاسباتی در ایستگاه پل فلور توسط مدل های EANN در مرحله آزمون

همانطور که در شکل های (۳) تا (۵) و جداول (۵) تا (۷) مشاهده می شود در مدل MNN ضریب R^2 برای پارامتر دبی رودخانه در ایستگاه پل فلور در مراحل آموزش،اعتباریابی و آزمون به ترتیب برابر ۰.۹۱۶ ، ۰.۹۰۳ ، و ۰.۹۱۷

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

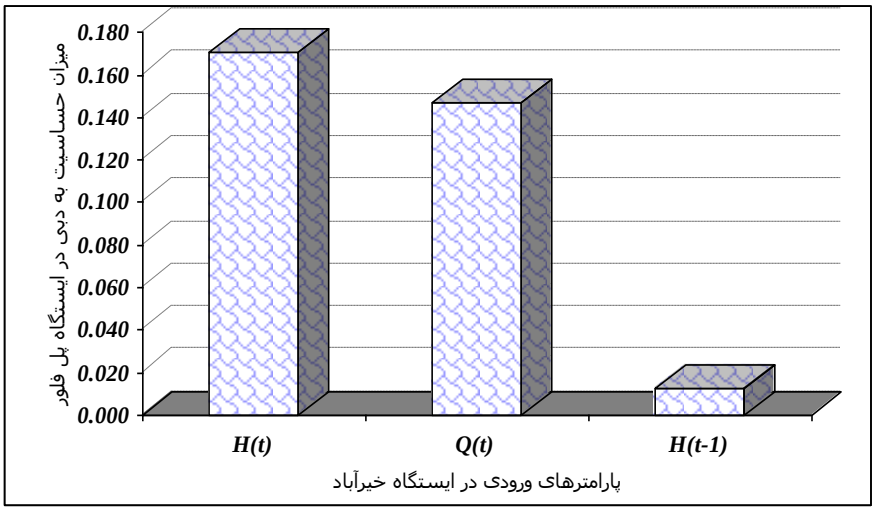
همچنین شیب خط راست برای این پارامتر برابر ۰/۹۳٦ ، ۰/۹۱۰۳ و ۰/۹۱ می باشد. بنابراین مدل MNN همبستگی بالاتری نسبت به سه مدل دیگر دارد. در نتیجه مدل MNN با ساختار آرایش (۱-۱۵-۲۵-۳) بهترین مدل شبکه عصبی مصنوعی تکاملی می باشد.

حساسیت خروجی های مدل بهینه MNN نسبت به پارامترهای ورودی

برای آنکه میزان تاثیر پارمترهای ورودی بر روی پارامتر خروجی مشخص شود، از روش تحلیل حساسیت استفاده می کنند. این روش برای مشخص کردن این موضوع می باشد که پارامتر خروجی در شبکه مورد نظر نسبت به کدامیک از پارامترهای ورودی دارای حساسیت بیشتر می باشد. تا مشخص شود کدام شاخص بر روی خروجی شبکه عصبی مصنوعی بیشترین تاثیر را دارد. نتایج حاصل از تحلیل حساسیت خروجی مدل MNN نسبت به پارامترهای ورودی در جدول (۸) آمده است که نمودار آن در شکل (٦) آمده است.

جدول ۸- آنالیز حساسیت خروجی مدل MNN نسبت به پارامترهای ورودی

نام پارامتر ورودی		دبی ایستگاه پل فلور
اشل ایستگاه خیرآباد	$H(t)$	0.171
دبی ایستگاه خیرآباد	$Q(t)$	0.147
اشل ایستگاه خیرآباد در روز قبل	$H(t-1)$	0.012



شکل ٦- تحلیل حساسیت پارامتر دبی در ایستگاه پل فلور در مدل MNN نسبت به پارامترهای ورودی

با توجه به شکل(٦) پارامترهای اشل و دبی در ایستگاه خیرآباد به ترتیب دارای بیشترین و کمترین تاثیر بر روی خروجی مدل MNN می باشند.

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

مقایسه مدل شبکه عصبی مصنوعی با مدل های آماری

مدل آماری مورد استفاده در این تحقیق مدل رگرسیون خطی چندگانه می باشد. در رگرسیون خطی چندگانه ، دو یا چند متغیر مستقل ، تاثیر عمده ای بر روی متغیر وابسته دارند که معادله آن به صورت زیر می باشد:

$$y = f(x_1, x_2, ...) \rightarrow y = a_0 + a_1 x_1 + a_2 x_2 + ... \quad (۹)$$

در معادله فوق y متغیر وابسته ، $x_1, x_2, ...$متغیر های مستقل، $a_1, a_2, a_3, ...$ ضرایب معادله از نوع رگرسیون می باشد.در این تحقیق برای متغیرهای ورودی و خروجی با استفاده از نرم افزار MINITABver14.0 مدل های مختلفی از رگرسیون خطی مورد بررسی قرار گرفت ، که مناسب ترین ضرایب برای مدل رگرسیون خطی در جدول زیر آمده است. در این جدول اعداد ستون Coef ضرایب مدل رگرسیونی را نشان می دهند و خطای استاندارد هر یک از تخمین ها در ستون SE Coef نشان داده شده است. برای به دست آوردن فاصله اطمینان ۹۵ درصد این اعداد را در ۱/۹۶ ضرب کرده و آن را از ضرایب اضافه و کم نماییم. همچنین اعداد ستون T همان تقسیم Coef بر SE Coef می باشند که برای محاسبه احتمال P از آن استفاده می کنند، P در آزمون فرض به ما کمک می کند که جواب را رد یا قبول کنیم در اصل احتمال رخداد خطای نوع اول می باشد که اگر کمتر از $\alpha = 0.005$ باشد بدان معنی است که رابطه بین این دو پارامتر مستقل و وابسته از لحاظ آماری بسیار قابل توجه است.

جدول ۹- ضرایب مدل رگرسیون خطی چندگانه

Predictor		Coef	SE Coef	T	P
مقدار ثابت	Constant	-43.429	1.478	-29.38	0.000
دبی در ایستگاه خیرآباد	x_1	0.699763	0.008400	83.31	0.000
اشل در ایستگاه خیرآباد	x_2	0.50153	0.01330	37.70	0.000
اشل روز قبل در ایستگاه خیرآباد	x_3	-0.145496	0.009099	-15.99	0.000

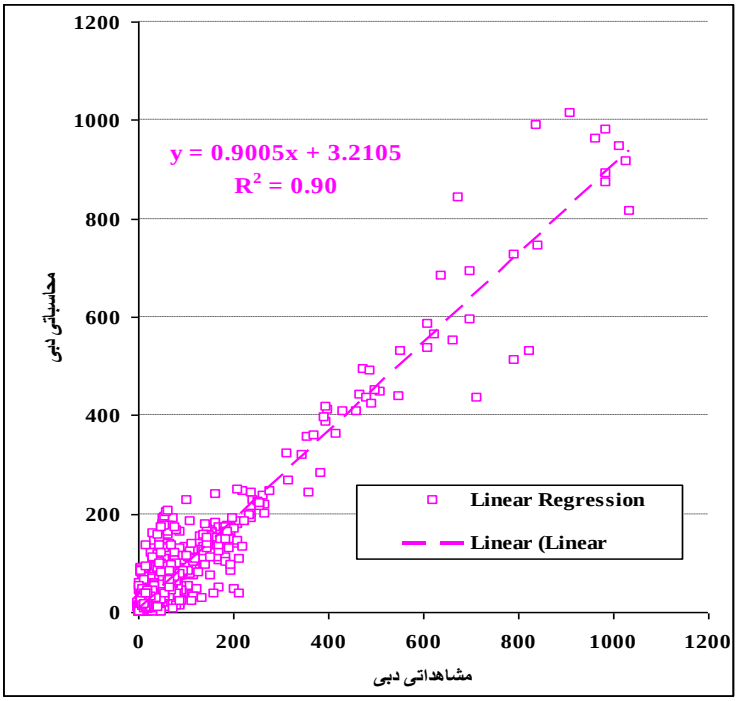
بهترین مدل رگرسیون خطی چندگانه که با داده های دبی در ایستگاه پل فلور هماهنگی بیشتری دارد در معادله زیر آمده است.

$$y = -43.4 + 0.700x_1 + 0.502x_2 - 0.145x_3 \quad (۱۰)$$

که در معادله فوق y دبی در ایستگاه پل فلور ، x_1 دبی در ایستگاه خیرآباد، x_2 اشل در ایستگاه خیرآباد ، x_3 اشل روز قبل در ایستگاه خیرآباد می باشد، با توجه به معادله فوق و استفاده از داده های آموزش می توان مقدار دبی در ایستگاه پل فلور را محاسبه نمود در مدل رگرسیون خطی چندگانه ضریب R^2 برای پارامتر خروجی برابر ۰/۹۰ می

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

باشد همچنین شیب خط راست برای این پارامتر برابر ۰/۹۰می باشد که برای این مدل مناسب می باشد مقدار R^2 و شیب خط راست برای معادله در شکل زیرنشان داده شده است.

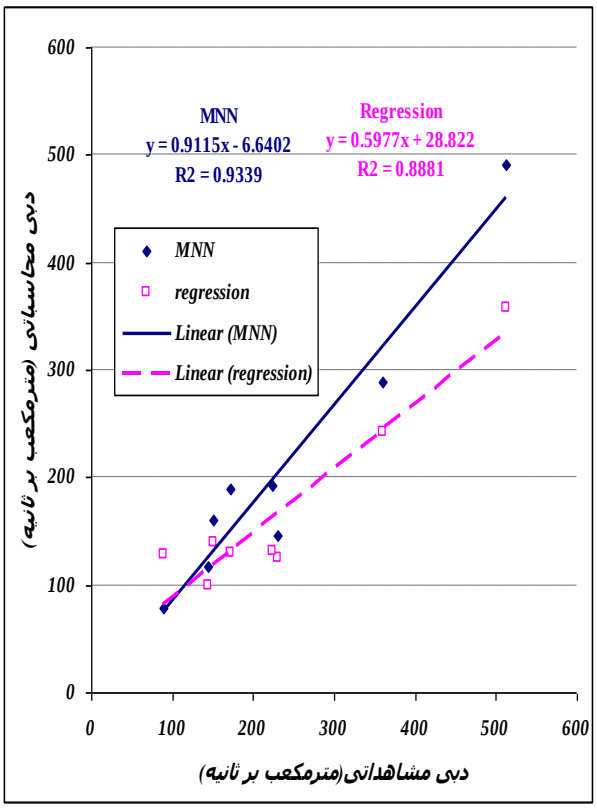


شکل شماره ۷- مقایسه مقادیردبی محاسباتی توسط مدل رگرسیون خطی چندگانه با مقادیر دبی مشاهداتی در ایستگاه پل فلور

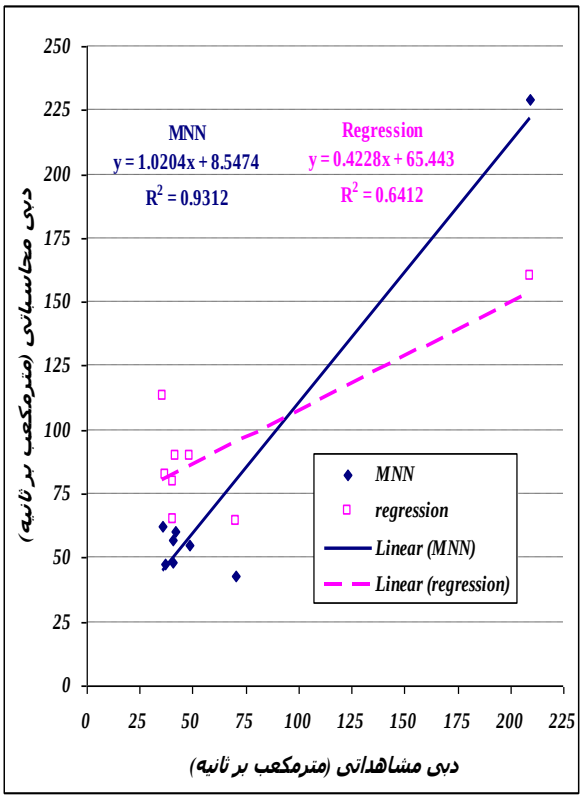
برای ارزیابی عملکرد مدل بهینه GA-MNN در روندیابی متمرکز هیدروگراف دبی در رودخانه، نتایج حاصل از آن با نتایج حاصل از مدل رگرسیون خطی چندگانه مقایسه می گردد. بدین منظور از سه هیدروگراف سیلاب در سال ۱۳۸۰ و ۱۳۸۱ در روندیابی توسط دو مدل استفاده شده است.

اشکال (۸) و(۱۰) مقایسه مقادیر دبی اندازه گیری شده و روندیابی شده توسط دو مدل را نشان می دهد. همچنین هیدروگراف دبی اندازه گیری شده در پایین دست بازه رودخانه در محل ایستگاه هیدرومتری پل فلور، هیدروگراف های روندیابی شده با مدل های MNN و مدل رگرسیون غیرخطی در شکلهای (۱۱) و (۱۳) نشان داده شده است. با توجه به معادلات خطوط برازش داده شده بر مقادیر دبی محاسباتی و مشاهداتی در هر مدل در شکلهای (۸) تا (۱۰) و ضریب تعیین مربوط به آنها می توان دریافت که مدل شبکه عصبی مصنوعی تکاملی MNN نسبت به مدل رگرسیون خطی چندگانه ، هیدروگراف سیل را در انتهای بازه رودخانه در ایستگاه هیدرومتری پل فلور با دقت بیشتری روندیابی کرده اند.همچنین مقایسه مقادیر ضریب تعیین مربوط به معادلات خطوط برازش شده بر مقادیر دبی محاسباتی و مشاهداتی در شکلهای (۱۱) و(۱۳) می توان دریافت که مدل MNN از دقت و انعطاف پذیری بیشتری نسبت به مدل رگرسیون خطی چندگانه در روندیابی هیدروگراف سیل را دارا می باشد.

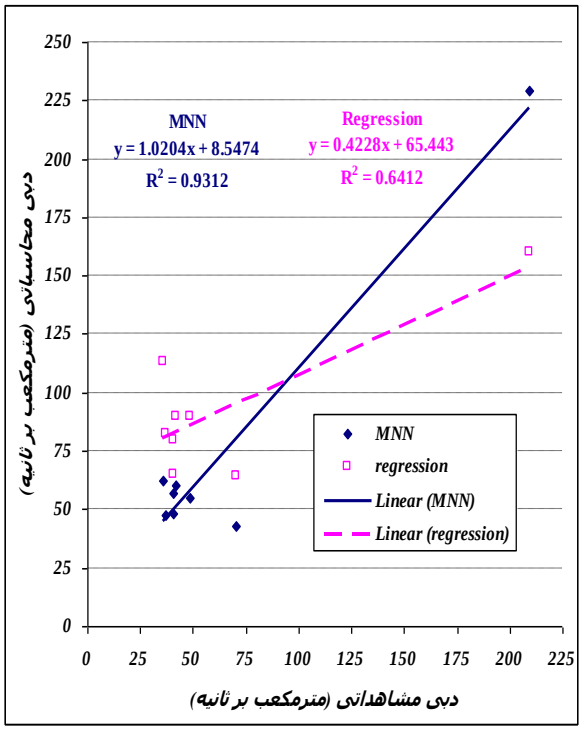
[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]



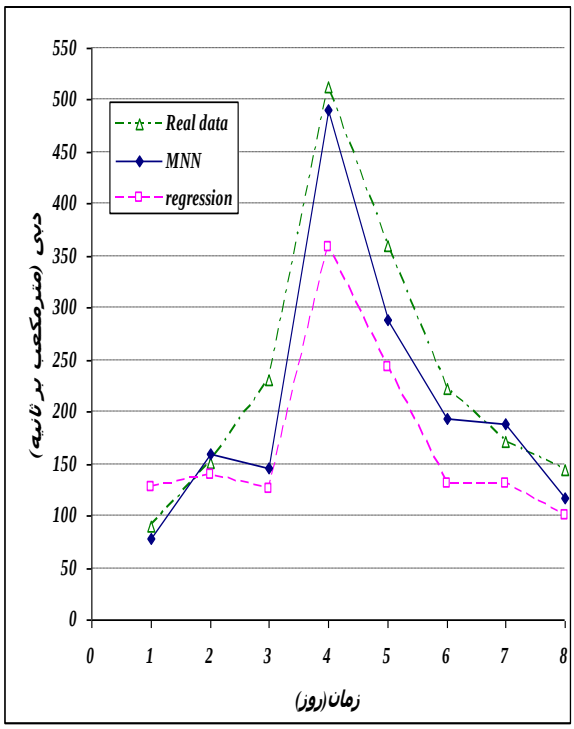
شکل شماره ۸- مقایسه مقادیر دبی مشاهداتی و محاسباتی حاصل از روندیابی هیدروگراف سیل با مدل های مختلف به ازای سیل دی ماه ۱۳۸۰



شکل شماره ۹- مقایسه مقادیر دبی مشاهداتی و محاسباتی حاصل از روندیابی هیدروگراف سیل با مدل های مختلف به ازای سیلاب بهمن ماه ۱۳۸۰

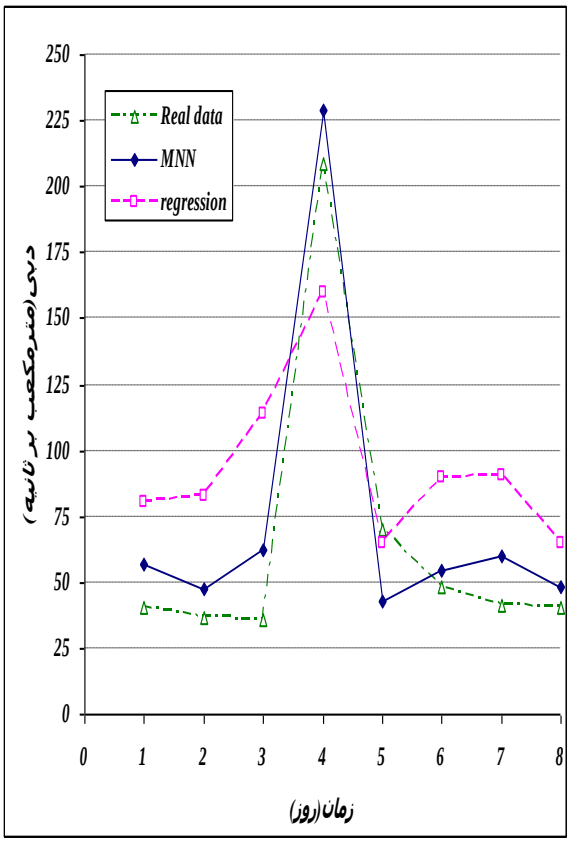


شکل شماره ۱۰- مقایسه مقادیر دبی مشاهداتی و محاسباتی حاصل از روندیابی هیدروگراف سیل با مدل های مختلف به ازای سیلاب فروردین ما

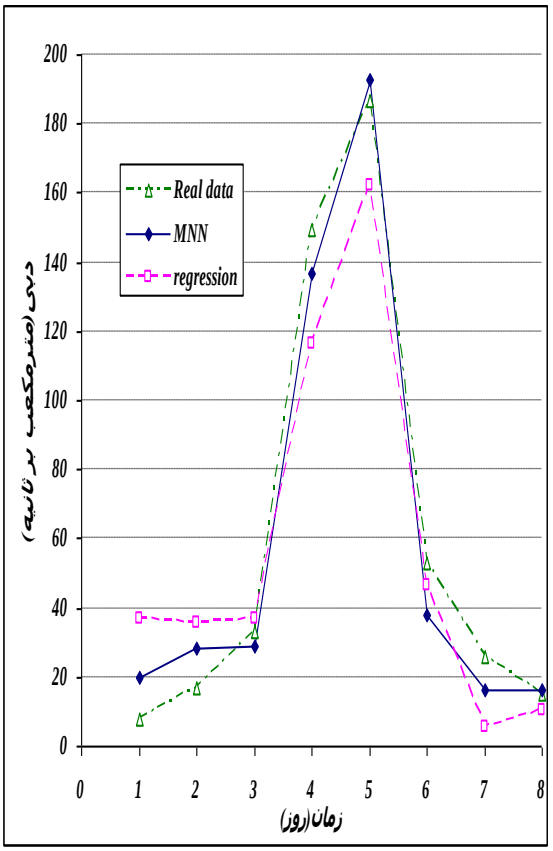


شکل شماره ۱۱- مقایسه هیدروگراف سیل خروجی و روندیابی شده با مدل های مختلف مربوط به سیلاب دی ماه ۱۳۸

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]



شکل شماره ۱۲- مقایسه هیدروگراف سیل خروجی و روندیابی شده با مدل های مختلف مربوط به سیلاب بهمن ماه ۱۳۸۰



شکل شماره ۱۳- مقایسه هیدروگراف سیل خروجی و روندیابی شده با مدل های مختلف مربوط به سیلاب فروردین ماه ۱۳۸۱

با توجه به شکل های (۸) تا (۱۳) می توان نتیجه گرفت که شبکه های عصبی-مصنوعی تکاملی از انعطاف پذیری و دقت بالاتری نسبت به مدل های رگرسیون خطی چندگانه برخوردار می باشند.

نتیجه گیری

همانطور که در این تحقیق نتیجه شد، با روش همبستگی عرضی سری های زمانی می توان تعداد و تاخیر زمانی موثر پارامترهای ورودی در مدل های شبکه عصبی را تعیین نمود. به طوری که با این روش پارامترهای اضافی و غیر موثر حذف و مجموعه داده های ورودی بهینه می گردد.در این تحقیق با روش همبستگی عرضی در سری های زمانی، دبی و اشل بین ایستگاه هیدرومتری بالادست و پایین دست مقادیر دبی ، اشل و اشل روز قبل ایستگاه خیرآباد بر مقادیر دبی ایستگاه پل فلور تاثیر قابل ملاحظه داشت.

با قابلیت بهینه سازی الگوریتم پرکاربرد ژنتیک می توان ساختار بهینه هریک از مدل های شبکه عصبی مصنوعی از نظر تعداد لایه های پنهان ، تعداد گره ها در لایه پنهان ، نوع تابع تحریک و الگوریتم یادگیری شبکه را مشخص نمود.به طوری که با این روش زمان لازم برای تعیین ساختار بهینه هر مدل ، به میزان قابل ملاحظه ای کاهش می یابد.

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

مقایسه نتایج حاصل از آموزش ، اعتباریابی همزمان با آموزش و آزمون مدل های شبکه های عصبی مصنوعی تکاملی با مقادیر اندازه گیری شده نشان می دهد که مدل های MNN ، JEN، FF و RBF به ترتیب توانایی و دقت بیشتری در روندیابی هیدروگراف دبی در رودخانه مارون را دارند. به طوری که مقدار ضریب همبستگی بین مقادیر دبی مشاهداتی و روندیابی شده با MNN ، JEN، FF و RBF در مرحله آزمون به ترتیب برابر ۰/۹۱۷، ۰/۸۷۰ ،۰/۸۳٦ و ۰/۵۳۸ به دست آمد.

مقایسه نتایج حاصل از مدل ها نشان می دهد که مدل شبکه عصبی مصنوعی مودولار از دقت و انعطاف پذیری بالاتری در روندیابی هیدروگراف سیل در رودخانه نسبت به مدل های آماری برخوردار می باشد.

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

منابع

۱- اطمینان حسنلویی، م؛ قادری، س.ج؛ عبقری، ه (۱۳۸۷)، «پیش بینی روندیابی هیدروگراف سیلاب رودخانه گدارچای با استفاده از شبکه های عصبی پرسپترون چند لایه و شعاعی»، مدیریت تولید، استحصال، توزیع، مصرف و بازچرخانی آب.

۲- آر. بیل، تی، جکسون (۱۳۸٦)، «***آشنایی با شبکه های عصبی***»، ترجمه محمود البرزی، تهران، انتشارات علمی دانشگاه صنعتی شریف.

۳-بنی حبیب، م.ا؛ عربی، آ (۱۳۸۷)، «مدل شبکه عصبی مصنوعی برای تعیین زمان پیش هشدار سیلاب در حوضه گلابدره- دربند»، مقالات سومین کنفرانس مدیریت منابع آب، صص ۲۹-۱۳.

٤- حسنلویی، م.ا؛ قادری، ق.ج؛ عبقری، ه (۱۳۸۹)، «پیش بینی روندیابی هیدروگراف سیلاب رودخانه گدارچای با استفاده از شبکه های عصبی پرسپترون چند لایه و شعاعی»، مقالات ششمین همایش ملی علوم و مهندسی آبخیزداری ایران، صص ٤۱-۳۵.

۵- شفیعی، م؛ شیرزاد، م ؛ نیک نیا، ن (۱۳۸۵)، «تحلیل منطقه ای سیلاب توسط شبکه های عصبی مصنوعی (ANN) مطالعه موردی حوضه ماسال استان گیلان»، مقالات دومین کنفرانس مدیریت منابع آب، صص ۱۳۱-۱۱۸.

٦- قلخانی.ح ؛ ثقفیان، ب (۱۳۸۸)، «کاربرد شبکه عصبی مصنوعی در روندیابی زمان واقعی سیلاب رودخانه»، مقالات هشتمین کنفرانس هیدرولیک ایران، صص ۱۵۰-۱۳۲.

۷- منهاج، م.ب (۱۳۷۷)، «***مبانی شبکه های عصبی***»، تهران، مرکز نشر پروفسور حسابی.

8- Amitabha, M., (2003)," Application of visual, statistical and artificial neural network methods in the differentiation of water from the exploited aquifers in Kuwait".***Hydrogeology Journal***, 11: 343–356.

9- Brion, G. M., Lingireddy, S., (2003), "Artificial neural network modeling: A summary of successful applications relative to microbial water quality". ***Water Science and Technology***, 47: 235–240.

10- Coulibaly, P., Anctil, F., Bobee, B., (2000),"Daily reservoir inflow forecasting using artificial neural networks with stopped training approach". ***Journal of Hydrology***, 230: 244–257.

11- Dawson, c.w.,(2005) , "Flood estimation at ungauged sites using artificial neural networks". ***Journal of Hydrology***, 230: 391-410.

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

12- Piri, D., J., (2009),"Comparison of LLR, MLP, Elman, NNARX and ANFIS modelswith a case study in solar radiation estimation". ***J. Atmos. Sol. Terr. Phys***. 71: 975–982.

13- Dorfliger, N., Jourde, H., Ladouche, B., Fleury, P., Lachassagne, P., Conroux, Y., Pistre,S., Vestier, A., (2008),"Active water management resources of Karstic water catchment: The example of Le Lez spring (Montpellier, South France", In World Water Congress. Montpellier. pp.801-823.

14- Dawson, C.W., Abrahart, R.J., See, L.M., (2007),"Hydrotest: a web-based toolbox of evaluation metrics for the standardised assessment of hydrological forecasts", ***Environmental Modelling & Software*** 22 (7): 1034–1052.

15- Diego, J., Pedregal , J., R. Trapero, R., (2010),"Mid-term hourly electricity forecasting based on a multi-rate approach", ***Energy conversion and management***. 51(1):105-111.

16- Gavin,J., Graeme, C., Holger, R., (2004)," Input determination for neural network models in water resources applications. Part 1-background and methodology".***Journal of Hydrology,***72:752-768.

17- Gavin, J., Graeme, C., Holger, R.,(2004)," Input determination for neural network models in water resources applications. Part 2. Case study: forecasting salinity in a river"***Journal of Hydrology***,72:1243-1258.

18- Ghorbani, M., Khatibi, R., Aytek, A., Makarynskyy, O., (2010),"Sea water level forecasting using genetic programming and artificial neural networks". ***J. Comput. Geosci***, 36 (5): 620–627.

19- Jain, A., Srinivasulu, S., (2004), "Development of effective and efficient rainfall–runoff models using integration of deterministic, real-coded genetic algorithms and artificial neural network techniques", ***Water Resources Research*** ,40:302-304.

20- Kenyon, W., Hill, G., Shannon, P., (2008),"Scoping the role of agriculture in sustainable flood management",. ***Land Use Policy***, 25: 351–360.

21- Li-Hua, F. , Jia, Lu.,(2010), "(The practical research on flood forecasting based on artificial neural networks", ***Expert Systems with Applications***, PP. 2974-2977.

22- Lihua, F., Weihu, H., , (2007),"On hydrologic calculation using artificial neural networks" . ***Applied Mathematics Letters*** , 21(5):453-458.

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]

23- Mendeza, M.C., Manteigaa, W.G., Bandea, M.F., Sancheza, J.M.P. Calderon, R.L., (2004), "Modelling of the monthly and daily behaviour of the runoff of the Xallas river using Box–Jenkins and neural networks methodS", ***Journal of Hydrology***, 296:38–58.

24- Sivapragasam, C., Maheswaran, R., Venkatesh V., (2007)," Genetic programming approach for flood routing in natural channels", ***Hydrol. Process***. doi:10.1002/ hyp.6628.

25- Tayfur, G., Moramarco, T., (2007),"Forecasting flood hydrographs at Tiber River basin",In: International River Basin Management Congress Book",General Directorate of State Hydraulic Works, Antalya, Turkey, pp. 485–497.

26- Ureyen, M. E., Gurkan, P., (2008), "Comparison of artificial neural network and linear regression models for prediction of ring spun yarn properties", I. Prediction of yarn tensile properties. ***Fibers and Polymers***, 9:87–91.

27- R.J.Kuo,C.H.chen,Y.C.Hwang "An intelligent stock trading decision support system through integration of genetic algorithm based fuzzy neural network and artificial neural network", ***Fuzzy Sets and Systems***, 118(1):21-45.

28- Vandaele,w., (1983),"***Applied time series and box-jenkins models***". Academic Press, Inc.

30- Zeng, Y., Huai, W., (2008) , "Application of artificial neural network to predict the friction factor of open channel flow" , ***Communications in Nonlinear Science and Numerical Simulation*** , 14(5):2373-2378.

[Downloaded from geographical-space.iau-ahar.ac.ir on 2026-10-31]