



آزاده امیری^۱
مهردی نیکو^۲
محمد نیکو^۳

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

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

چکیده

روندیابی سیلاب، یکی از پیچیده‌ترین مسائلی است که در علم هیدرولیک کanal های باز و مهندسی رودخانه مورد بررسی قرار گرفته است. روش‌های مختلفی در زمینه روندیابی سیلاب وجود دارند که به دو گروه گستردۀ و متتمرکز تقسیم بنایی می‌شوند. امروزه تکنیک جدید استفاده از مدل شبکه‌های عصبی مصنوعی تکاملی که مبتنی بر هوش مصنوعی می‌باشد کاربرد گسترده‌ای در زمینه‌های 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 مدل‌های شبکه عصبی مصنوعی تکاملی JEN, FF, MNN و RBF پرداخته شد. از جمله مواردی که به عنوان یک روش جدید بیان شده است تعیین تعداد و تاخیر زمانی موثر داده‌های ورودی در مدل‌های شبکه عصبی مصنوعی با استفاده از روش همبستگی عرضی خطی بین سری‌های زمانی ورودی‌ها و خروجی‌ها می‌باشد. با استفاده از الگوریتم ژنتیک ساختار مدل‌های شبکه عصبی مصنوعی از نظر تعداد لایه‌ها، تعداد گره‌ها در لایه پنهان، نوع تابع انتقال و الگوریتم یادگیری شبکه بهینه گردید. نتایج نشان می‌دهد که روش همبستگی عرضی به خوبی تعداد و تاخیر زمانی موثر داده‌های

۱- دکتری جغرافیا، استادیار دانشگاه، عضو هیات علمی دانشگاه آزاد اسلامی واحد اهواز

۲- کارشناسی ارشد مهندسی عمران-سازه، آموزشکده فنی و حرفه‌ای سماء دانشگاه آزاد اسلامی اهواز

۳- کارشناسی ارشد مهندسی عمران-آب، آموزشکده فنی و حرفه‌ای سماء دانشگاه آزاد اسلامی اهواز

ورودی را تعیین می‌نماید. علاوه بر این مقایسه خروجی مدل‌ها با مقادیر واقعی نشان می‌دهد که مدل MNN انتخاب شده نسبت به مدل‌های آماری و مدل‌های دیگر شبکه عصبی مصنوعی توانایی، انعطاف پذیری و دقت بیشتری در پیش‌بینی و روندیابی سیلاب در رودخانه مارون را دارد.

کلیدواژه‌های: روندیابی سیلاب، شبکه عصبی مصنوعی مودولار، سری زمانی، الگوریتم ژنتیک، مدل‌های آماری، رودخانه مارون.

مقدمه

یکی از مهم‌ترین ویژگی‌های مدیریت حوضه رودخانه، پیش‌بینی سیلاب‌های اتفاق افتاده می‌باشد. مقدار خسارت‌های 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، شبکه 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 جریان را امری پیچیده می‌کند. بسیاری از تکنیک‌هایی که امروزه در مدل سازی سری‌های زمانی و پیش‌بینی جریان استفاده می‌شوند، رابطه خطی بین متغیرها را فرض می‌کنند. 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 شبکه‌های عصبی مصنوعی می‌توانند جایگزین مطمئنی برای مدل‌سازی فرآیند بارش - رواناب، پیش‌بینی جریان و دبی ورودی به مخزن باشند.

آرجی کو^۴ (۲۰۰۱:۲۱) در تحقیقی با عنوان شبکه عصبی مصنوعی تکاملی برای پیش‌بینی سیستم‌های هیدرولوژیکی بیان می‌کند که استفاده از الگوریتم ژنتیک برای بهینه سازی داده‌های ورودی شبکه‌های عصبی مصنوعی می‌تواند نتایج دقیق‌تری را نسبت به حالتی که از این الگوریتم استفاده نمی‌شود بدهد (۲۸) زنگ یونگ^۵ (۲۰۰۹:۲۳۷۳) در تحقیقی با عنوان کاربرد شبکه عصبی مصنوعی برای پیش‌بینی ضریب اصطحکاک جریان کانال‌های باز بیان می‌کند که مدل شبکه عصبی مصنوعی می‌تواند در مهندسی به عنوان یک روش عملی موثر و مناسب استفاده شود و مشکلات هیدرولوژیکی که بیشتر بر پایه آزمایشگاهی استوار است می‌تواند به وسیله مدل شبکه‌های عصبی تحلیل شود (۳۱). لی هوا فنگ^۶ (۲۰۰۷:۲۹۷۴) در تحقیقی با عنوان محاسبه هیدرولوژیکی با استفاده از شبکه عصبی مصنوعی بیان می‌کند که تکنولوژی شبکه عصبی مصنوعی یک راه نسبتاً موثر برای حل مشکلات محاسبات

4 -R.J.Kuo

5 - Zeng Yuhong

6 - Lihua Feng

هیدرولوژیکی را فراهم می کند (۲۱). مندوza^۷ و همکاران (۲۰۰۴:۳۸) 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 شبیه‌سازی‌ها نشان داد که شبکه EANN در مقایسه با شبکه FFBP و مدل‌های آماری متداول پیش‌بینی‌ها را بهتر انجام می‌دهد (۳۰) کولی بالی^۹ و همکاران (۲۰۰۰:۲۴۴) برای پیش‌بینی جریان یک تا هفت روز آینده در فصل بهار حوزه-chute-du-diable با وسعت^۲ ۹۷۰۰ km² در شمال کانادا مدل‌های سری زمانی ARMAX و مدل تفهیمی PREVIS که برای بهره‌برداری از مخازن استفاده می‌شود را به کار برند. همچنین ایشان در مقاله‌ای دیگر برای پیش‌بینی جریان ورودی به سد واقع در حوزه Chute-du-Diable PREVIS مقایسه نمودند نتایج نشان داد که مدل‌های شبکه عصبی مصنوعی توانایی بسیار بالایی در پیش‌بینی جریان رودخانه را دارند (۱۰).

اطمینان حسنلویی و همکاران (۱۳۸۹:۱) به پیش‌بینی روندیابی هیدرولوگراف سیلاب رودخانه گدارچای با استفاده از شبکه‌های عصبی پرسپترون چند لایه و شعاعی پرداختند. آنها نشان دادند که استفاده از شبکه‌های عصبی مصنوعی به دلیل ساختار غیرخطی می‌تواند جایگزین مناسبی برای مدل‌های آماری و ریاضی باشد (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 مدل‌های شبکه عصبی مصنوعی با مدل‌های هیدرولیکی HEC-RAS پرداختند نتایج نشان داد که مدل‌های شبکه عصبی مصنوعی توانایی بسیار بالایی در پیش‌بینی سیلاب رودخانه دارند (۶). بنی حبیب و همکاران (۱۳۸۷:۱) در تحقیقی به تعیین زمان پیش‌هشدار سیلاب در حوضه گلابدره- دربند با استفاده از مدل شبکه عصبی مصنوعی پرداختند. آنها برای آموزش شبکه از سیلاب ۱۰۰۰۰ ساله که ماگزیمم داده‌ها را شامل می‌شود استفاده نمودند. همچنین برای تست شبکه از سیلاب‌های 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 بردن. آنها نشان دادند که مدل‌های شبکه عصبی مصنوعی توانایی بالایی در تعیین زمان پیش‌بینی هشدار در شرایط مختلف کاربری سطح حوضه دارند. بنی حبیب و همکاران (۱۳۸۷:۱) به استفاده از شبکه عصبی مصنوعی برای پیش‌بینی 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 منطقه‌ای سیلاب توسط شبکه‌های

7 - Mendeza

8 - Zougla

9 - Coulibaly

عصبی مصنوعی در حوضه ماسال استان گیلان پرداختند. هدف از ارائه این مقاله کاربرد مدل منطقه‌ای سیلاب توسط شبکه‌های عصبی مصنوعی برای تخمین دبی‌های حداکثر لحظه‌ای سیلاب با دوره برگشت‌های مختلف در حوضه آبریز ماسال در استان گیلان و مقایسه آن با مدل رگرسیونی می‌باشد، که نشان دهنده برتری شبکه‌های عصبی مصنوعی است^(۵).

در همه مقالات ذکر شده برای تعیین داده‌های ورودی در شبکه‌های عصبی مصنوعی از روش صحیح و خطاب استفاده نموده اند که این روش دارای حجم محاسباتی و صرف زمان بالا و کاهش دقیق در پیش‌بینی سیلاب می‌باشد، اما در مقاله حاضر از سری‌های زمانی به تعیین پارامترهای ورودی در شبکه‌های عصبی مصنوعی تکاملی^(۶) (EANN) استفاده می‌شود. هدف اصلی این تحقیق بررسی توانایی شبکه‌های عصبی تکاملی در شبیه‌سازی 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 می‌شود. شبکه عصبی مصنوعی مورد استفاده^(۷) MNN می‌باشد که به منظور بهینه‌سازی مدل از نظر تعداد لایه، تعداد گره‌ها در لایه پنهان، نوع تابع انتقال و الگوریتم یادگیری شبکه از روش الگوریتم ثنتیک استفاده می‌گردد. برای تعیین دقیق مدل پایدار MNN آن را با مدل‌های دیگر شبکه عصبی مصنوعی^(۸) FF،^(۹) RBF^(۱۰)، JEN^(۱۱) و مدل‌های آماری رگرسیونی مقایسه می‌گردد.

مواد و روش‌ها

معرفی رودخانه مارون و ایستگاه‌های مورد مطالعه

رودخانه مارون یکی از رودخانه‌های جنوب غرب ایران است و سرحد جغرافیایی فارس و خوزستان بوده و امروزه از میان خاک کهگیلویه و سپس بهبهان می‌گذرد. نام اصلی و قدیمی رودخانه مارون، تاب است این رود از کوه‌های نیل و چشمۀ سارهای دامنه کوه‌های سادات از زاگرس سرچشمه گرفته و پس از طی مسافت ۱۲۰ کیلومتر به دریاچه سد مارون می‌رسد و از طریق تنگ تکاب وارد بهبهان می‌شود 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 می‌ریزد، این رود در موقع پرآبی از طریق خور موسی وارد خلیج فارس می‌شود. ایستگاه‌های مورد مطالعه در این تحقیق ایستگاه‌های خیرآباد و پل فلور می‌باشند. ایستگاه خیرآباد با مختصات جغرافیایی طول ۵۰ درجه ۲۴ 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

ارتفاع ایستگاه از سطح دریا ۳۸۰ متر می باشد. همچنین ایستگاه پل فلور با مختصات جغرافیایی طول ۵۰ درجه ۱۷ دقیقه، عرض ۳۰ درجه 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

سری های زمانی

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

$$y_t = \alpha_0 + \alpha_1 T^1 + \alpha_2 T^2 + \dots + \alpha_n T^n \quad (1)$$

که در آن y_t متغیر وابسته حاصل از مشاهدات سری های زمانی، $\alpha_0, \alpha_1, \alpha_2, \dots, \alpha_n$ ضرایب توابع خودهمبستگی، T متغیر مستقل زمانی می باشد. ضرایب $\alpha_0, \alpha_1, \alpha_2, \dots, \alpha_n$ را از طریق تابع خود همبستگی^{۱۵} ACF 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^{۱۶} استفاده نمود که در این حالت بازه زمانی موثر به صورت زیر به دست می آید.

$$-(10 + \sqrt{n}) \leq K \leq +(10 + \sqrt{n}) \quad (2)$$

15 - Auto Correlation Function

16 - Cross Correlation Function

که در آن K ، تاخیر زمانی^{۱۷} مؤثر در سری زمانی پایین دست و n ، تعداد داده‌های مشاهده‌ای 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 کار بردن و استفاده از تجارت به دست آمده در مسائل نو و مشابه می‌باشند. 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 می‌نمایند. می‌توان از ویژگی‌ها و قابلیت‌های شبکه‌های عصبی مصنوعی به مواردی همچون قابلیت یادگیری و تطبیق پذیری با اطلاعات موجود، قابلیت تعمیم دهنده، پردازش موازی ورودی-های شبکه و در نتیجه افزایش سرعت پردازش، تحمل پذیری بالای خطاهای 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.
۴. 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، متدهای تعیین وزن‌های ارتباطی و تابع فعالیت، معرفی می‌شود (فلچر و ریوز ۱۹۶۴)، ساختار عادی یک شبکه عصبی مصنوعی، معمولاً از لایه ورودی، لایه‌های میانی (پنهان) و لایه خروجی تشکیل شده است (شکل ۱). لایه ورودی یک لایه انتقال دهنده و وسیله‌ای برای تهیه کردن داده‌هاست. آخرین لایه یا لایه خروجی شامل مقادیر پیش‌بینی شده بوسیله شبکه می‌باشد و بنابراین خروجی مدل را معرفی می‌کند. لایه‌های 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 می‌شود. گره‌های لایه‌های مجاور در شبکه به طور کامل با هم در ارتباط هستند. ورودی‌های هر گره ممکن است از متغیرهای ورودی یا از خروجی گره‌های دیگر حاصل شود. هر گره دارای یک تابع تبدیل‌گر^{۱۹} است.

17 -Lag

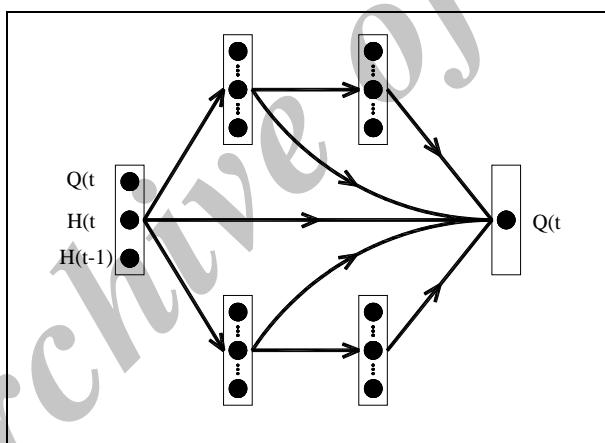
18-Activation Function

19 -Transfer Function

ورودی‌ها به شکل یک بردار (x_1, \dots, x_n) هستند و هر ورودی توسط یک وزن به گره پردازش گر مربوط می‌شود و در نهایت تسلسی از وزن‌ها به شکل بردار وزن (w_1, \dots, 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) :

$$y = f(x \cdot w - b) \quad (3)$$

x داده‌های ورودی، w بردار وزن، b مقدار آستانه یا بایاس^{۳۰} می‌باشند. درون هر گره پردازش گر تابع تبدیل گر، تولید کننده خروجی‌های آن گره به شمار می‌رود. در شبکه‌های مودولار، لایه‌های میانی به دو قسمت جدا و به موازات هم قرار می‌گیرند تا وزن‌های مورد استفاده به جای اینکه بین تمامی گره‌ها تقسیم شوند به دو قسمت مجزا وارد گردند و در هر قسمت به طور جداگانه تقسیم گردند این امر موجب افزایش سرعت و کاهش زمان در تحلیل شبکه می‌باشد از خصوصیات منحصر به فردی که در هیچ‌کدام از انواع شبکه‌های عصبی مصنوعی وجود ندارد، در شکل (۲-۱) 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 شبکه‌های عصبی مصنوعی از توابع تبدیل گر (تحریک) گوناگون Linear Axon, BiasAxon, Linear Sigmoid Axon Linear Tanh Axon, Sigmoid Axon, Tanh Axon مدل شبکه عصبی مصنوعی معمولاً دو معیار مختلف NMSE (متوسط خطای مربعات نرمال شده) و r استفاده می‌شود. MSE به صورت زیر محاسبه می‌شود :

$$MSE = \frac{\sum_{j=0}^P \sum_{i=0}^N (d_{ij} - y_{ij})^2}{N \times P} \quad (4)$$

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

$$NMSE = \frac{P \times N \times MSE}{\sum_{j=0}^P \frac{N \sum_{i=0}^N d_{ij}^2 - \left(\sum_{i=0}^N d_{ij} \right)^2}{N}} \quad (5)$$

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

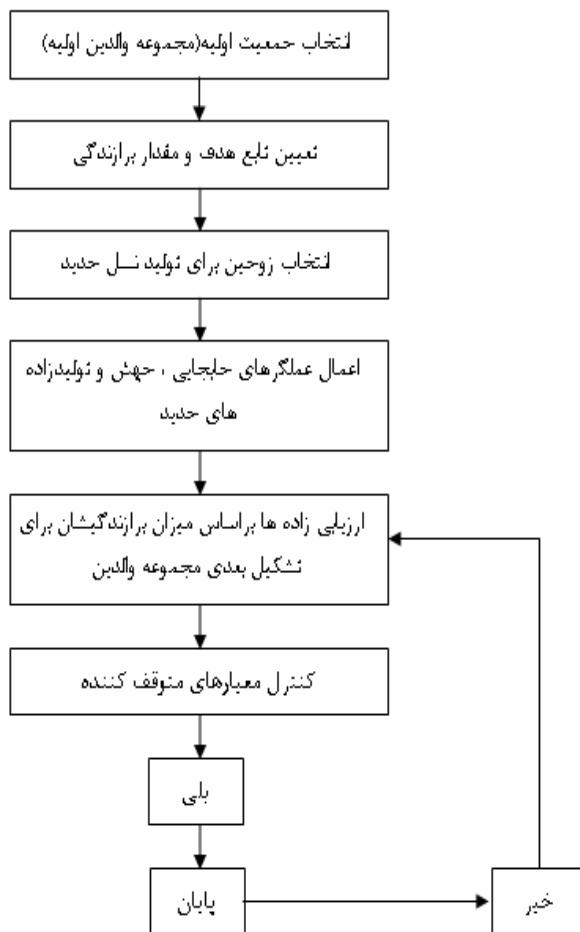
$$r = \frac{\frac{\sum_i (x_i - \bar{x})(d_i - \bar{d})}{N}}{\sqrt{\frac{\sum_i (d_i - \bar{d})^2}{N}} \sqrt{\frac{\sum_i (x_i - \bar{x})^2}{N}}} \quad (6)$$

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 برآنده ترین افراد بدون تغییر به نسل بعد منتقل شده است. پس از تکمیل فرایند انتخاب، نوبت به اعمال عملگر 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 بیتها کروموزوم های

جمعیت عدد تصادفی 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 (۲۴).



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 ایستگاه‌های هیدرومتری از تاریخ ۱۳۶۷ تا ۱۳۸۶ 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 :

جدول ۱- تعداد الگوهای مورد استفاده در شبکه عصبی مصنوعی در سال‌های مختلف

رودخانه	ایستگاه	سال	تعداد الگو								
مارون	خیرآباد- پل فلور	۱۳۸۲	۲۷۳	۱۳۷۷	۲۴۶	۱۳۷۲	۱۳۳	۱۳۶۷	۱۳۳	۱۳۶۷	۱۳۳
		۱۳۸۳	۲۷۱	۱۳۷۸	۲۷۶	۱۳۷۳	۲۷۶	۱۳۶۸	۲۷۶	۱۳۶۸	۲۷۶
		۱۳۸۴	۲۶۹	۱۳۷۹	۲۷۴	۱۳۷۴	۲۶۹	۱۳۶۹	۲۶۹	۱۳۶۹	۲۶۹
		۱۳۸۵	۲۷۴	۱۳۸۰	۲۶۹	۱۳۷۵	۲۷۶	۱۳۷۰	۲۷۶	۱۳۷۰	۲۷۶
		۱۳۸۶	۳۶۴	۱۳۸۱	۲۷۲	۱۳۷۶	۲۶۴	۱۳۷۱	۲۶۴	۱۳۷۱	۲۶۴
جمع											۶۰۵۷ الگو

داده‌های 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^{۲۱} استفاده می‌شود. هر چقدر این ضریب به عدد یک نزدیکتر باشد، همبستگی خطی بین دو سری 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 (2-tailed) Sig. از ۰/۰۰۵ کمتر می‌باشد می‌توان نتیجه گرفت که در تمام ۶۰۵۷ روز داده یک همبستگی خطی بین سری‌های زمانی دبی و اشل در ایستگاه‌های هیدرومتری خیرآباد و پل فلور وجود دارد.

جدول ۲- همبستگی خطی بین سری‌های زمانی دبی و اشل در ایستگاه‌های هیدرومتری خیرآباد و پل فلور

	دبی ایستگاه خیرآباد	اشل ایستگاه خیرآباد
دبی ایستگاه پل فلور	Pearson Correlation	۰/۹۲۵
	Sig. (2-tailed)	۰/۰۰۰
	تعداد الگوها	۶۰۷

با استفاده از تابع همبستگی عرضی^{۲۲} (CCF) تاخیر زمانی موثر بین سری‌های زمانی دبی و اشل در ایستگاه‌های خیرآباد و پل فلور را می‌توان به دست آورد. با توجه به این که کل الگوها به صورت روزانه برابر ۶۰۵۷ روز می‌باشد بنابراین متغیر n در معادله (۲) برابر ۶۰۵۷ بوده و خواهیم داشت:

$$-87 \leq K \leq +87 \quad (7)$$

21- Pearson Correlation

22- Cross Correlation Function

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 داده‌های دبی و اشل در جدول (۳) نشان داده شده است.

جدول ۳- همبستگی عرضی بین داده‌های دبی و اشل در رودخانه مارون بین دو ایستگاه خیرآباد-پل فلور

تاثیر اشل در روزهای قبل ایستگاه خیرآباد نسبت به دبی پل فلور								تاثیر دبی در روزهای قبل ایستگاه خیرآباد نسبت به دبی پل فلور							
روز	CCF	روز	CCF	روز	CCF	روز	CCF	روز	CCF	روز	CCF	روز	CCF	روز	CCF
۰	۰/۹۴۳	۲۲	۰/۱۹۶	۴۴	۰/۱۱۶	۶۶	۰/۰۷۱	۰	۰/۹۳۶	۲۲	۰/۱۲۳	۴۴	۰/۰۴۱	۶۶	۰/۰۱۲
۱	۰/۷۵۴	۲۳	۰/۱۹۵	۴۵	۰/۱۱۸	۶۷	۰/۰۵۸	۱	۰/۴۸	۲۳	۰/۱۱۸	۴۵	۰/۰۴۴	۶۷	۰/۰۰۷
۲	۰/۳۳۴	۲۴	۰/۲۱	۴۶	۰/۱۱۷	۶۸	۰/۰۵۸	۲	۰/۳۱	۲۴	۰/۱۴۱	۴۶	۰/۰۴۸	۶۸	۰/۰۰۷
۳	۰/۲۷۶	۲۵	۰/۲۰۴	۴۷	۰/۱۱۹	۶۹	۰/۰۵۷	۳	۰/۲۷۷	۲۵	۰/۱۳۸	۴۷	۰/۰۴۳	۶۹	۰/۰۰۵
۴	۰/۲۷۷	۲۶	۰/۱۹۳	۴۸	۰/۱۱۹	۷۰	۰/۰۵۹	۴	۰/۳۰۵	۲۶	۰/۱۱۶	۴۸	۰/۰۴	۷۰	۰/۰۱۵
۵	۰/۲۵۸	۲۷	۰/۱۷	۴۹	۰/۱۲۱	۷۱	۰/۰۶۹	۵	۰/۲۵۶	۲۷	۰/۰۸۸	۴۹	۰/۰۵۷	۷۱	۰/۰۲۴
۶	۰/۲۴۳	۲۸	۰/۱۷۱	۵۰	۰/۱۲۷	۷۲	۰/۰۶۶	۶	۰/۲۰۵	۲۸	۰/۰۸۸	۵۰	۰/۰۷	۷۲	۰/۰۱۷
۷	۰/۲۴۷	۲۹	۰/۱۵۷	۵۱	۰/۱۱۵	۷۳	۰/۰۶۵	۷	۰/۱۹۶	۲۹	۰/۰۷	۵۱	۰/۰۵۸	۷۳	۰/۰۳۴
۸	۰/۲۵۲	۳۰	۰/۱۵۷	۵۲	۰/۱۱۶	۷۴	۰/۰۵۴	۸	۰/۱۸۷	۳۰	۰/۰۶۵	۵۲	۰/۰۵۵	۷۴	۰/۰۱
۹	۰/۲۵۳	۳۱	۰/۱۵۵	۵۳	۰/۱۰۶	۷۵	۰/۰۵۲	۹	۰/۲۳۲	۳۱	۰/۰۷۳	۵۳	۰/۰۵۴	۷۵	۰/۰۰۵
۱۰	۰/۲۱۹	۳۲	۰/۱۵	۵۴	۰/۱	۷۶	۰/۰۴۶	۱۰	۰/۱۷۳	۳۲	۰/۰۷۱	۵۴	۰/۰۴۶	۷۶	–
۱۱	۰/۲۱۷	۳۳	۰/۱۴۷	۵۵	۰/۰۹۷	۷۷	۰/۰۴۳	۱۱	۰/۱۳۸	۳۳	۰/۰۶۳	۵۵	۰/۰۳۸	۷۷	–۰/۰۱
۱۲	۰/۲۰۶	۳۴	۰/۱۳۵	۵۶	۰/۰۹۲	۷۸	۰/۰۳۶	۱۲	۰/۱۴۸	۳۴	۰/۰۵	۵۶	۰/۰۲۷	۷۸	–۰/۰۲
۱۳	۰/۲۵	۳۵	۰/۱۴	۵۷	۰/۰۸۸	۷۹	۰/۰۳۳	۱۳	۰/۲۱۸	۳۵	۰/۰۵۳	۵۷	۰/۰۳	۷۹	–۰/۰۲
۱۴	۰/۲۲۵	۳۶	۰/۱۳۶	۵۸	۰/۰۷۸	۸۰	۰/۰۳۱	۱۴	۰/۲۱۴	۳۶	۰/۰۵۵	۵۸	۰/۰۲	۸۰	–۰/۰۲
۱۵	۰/۲۰۹	۳۷	۰/۱۳۲	۵۹	۰/۰۷۶	۸۱	۰/۰۳۳	۱۵	۰/۱۵۹	۳۷	۰/۰۵۳	۵۹	۰/۰۲۱	۸۱	–۰/۰۲
۱۶	۰/۱۹۱	۳۸	۰/۱۳۸	۶۰	۰/۰۷۳	۸۲	۰/۰۳۱	۱۶	۰/۱۴	۳۸	۰/۰۸	۶۰	۰/۰۱۸	۸۲	–۰/۰۲
۱۷	۰/۲۱	۳۹	۰/۱۳۹	۶۱	۰/۰۷۲	۸۳	۰/۰۳۲	۱۷	۰/۱۶۳	۳۹	۰/۰۸۶	۶۱	۰/۰۲	۸۳	–۰/۰۲
۱۸	۰/۲۰۱	۴۰	۰/۱۲۶	۶۲	۰/۰۷۶	۸۴	۰/۰۳۱	۱۸	۰/۱۵	۴۰	۰/۰۶	۶۲	۰/۰۲۲	۸۴	–۰/۰۲
۱۹	۰/۱۹۴	۴۱	۰/۱۲۸	۶۳	۰/۰۸۱	۸۵	۰/۰۳	۱۹	۰/۱۴۲	۴۱	۰/۰۵	۶۳	۰/۰۴۱	۸۵	–۰/۰۲
۲۰	۰/۱۸۹	۴۲	۰/۱۲۴	۶۴	۰/۰۹۲	۸۶	۰/۰۲۹	۲۰	۰/۱۱۵	۴۲	۰/۰۵۶	۶۴	۰/۰۶۵	۸۶	–۰/۰۲
۲۱	۰/۲	۴۳	۰/۱۱۴	۶۵	۰/۰۷۹	۸۷	۰/۰۳۲	۲۱	۰/۱۴۴	۴۳	۰/۰۴۸	۶۵	۰/۰۲۷	۸۷	–۰/۰۱

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 می‌شود. بنابراین تعداد پارامترهای ورودی در مدل‌های شبکه عصبی مصنوعی برابر سه پارامتر ($H(t-1), H(t), Q(t)$) در ایستگاه پل فلور می‌باشد.

در مدل‌های شبکه عصبی مصنوعی تعداد ورودی‌ها سه پارامتر ($H(t-1), H(t), Q(t)$) و تعداد خروجی، یک پارامتر ($Q(t)$) می‌باشند 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 ۶۰۵۷ الگو داده‌ها، ۷۰٪ الگوها (۴۲۳۹ الگو) برای آموزش^{۲۳} و ۱۵٪ الگوها (۹۰۹ الگو) برای ارزیابی^{۲۴} 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, Delta Bar Delta, Leven berg Marquat, Momentum و Quickprop. تعیین تعداد گره‌های لایه پنهان علاوه بر پیش فرض نرم افزار از فرمول تجربی زیر استفاده شد [۱۶].

$$N_H \leq 2N_I + 1 \quad (8)$$

که در آن N_H حداقل تعداد گره‌های لایه‌های پنهان و N_I تعداد ورودی‌ها می‌باشد. با توجه به اینکه تعداد ورودی‌های موثر به دست آمده برابر با ۳ عدد می‌باشد، حداقل تعداد گره‌های لایه پنهان برابر با ۷ عدد می‌باشد ($N_H \leq 7$). برای تعیین ساختار بهینه هریک از مدل‌های شبکه عصبی مصنوعی تکاملی MNN, FF, JEN و RBF از نظر تعداد لایه‌های پنهان، تعداد گره‌ها در لایه‌های پنهان، الگوریتم یادگیری شبکه، تابع انتقال و قابلیت الگوریتم بهینه سازی ژنتیک از نرم افزار NeuroSolutions ver5.0 استفاده می‌شود. جدول زیر ساختار بهینه هریک از مدل‌ها و مشخصات مختلف آنها که از الگوریتم ژنتیک به دست آمده را نشان می‌دهد.

جدول ۴- ساختار بهینه مدل‌های RBF, JEN, FF و MNN

ردیف	نام مدل	تعداد ورودی‌ها	تعداد خروجی‌ها	تعداد لایه پنهان	تعداد گره‌های لایه پنهان	تابع انتقال	الگوریتم یادگیری شبکه
۱	MNN	۳	۱	۲	۲۵-۱۵	TanhAxon	Momentum
۲	FF			۱	۷	LinearSigmoidAxon	Delta Bar Delta
۴	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 (۴) آمده است را نشان می‌دهد. به منظور عملکرد مدل‌ها و تعیین بهترین مدل، معیار

23 - Training

24 - Cross Validation

25 - Test

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, FF, JEN و RBF در مرحله آموزش

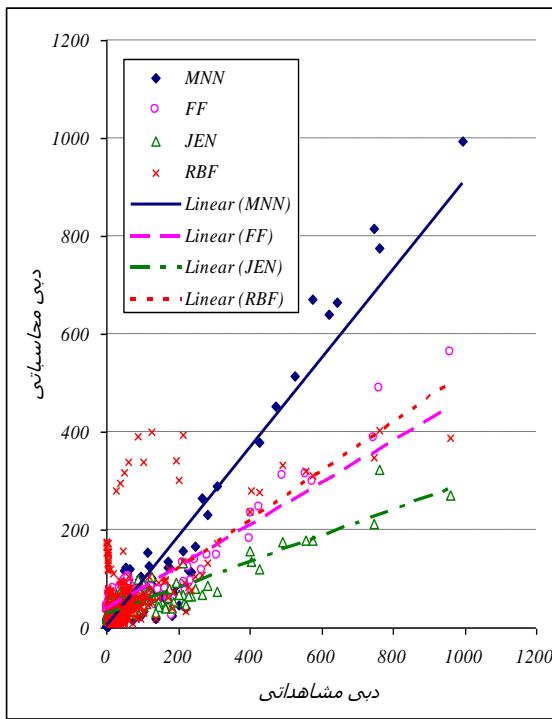
ردیف	مدل	دبی رودخانه در ایستگاه پل فلور			
		نتایج حاصل از نرم افزار Neuro solutions		نتایج حاصل از گرافها	
		r	NMSE	R^2	Equation
۱	MNN	0.957	0.084	0.916	$y = 0.936x + 2.9614$
۲	FF	0.879	0.489	0.772	$y = 0.3856x + 38.703$
۳	JEN	0.915	0.558	0.837	$y = 0.2648x + 28.476$
۴	RBF	0.718	0.492	0.515	$y = 0.4516x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

جدول ۶- نتایج حاصل از مدل های بهینه MNN, FF, JEN و RBF در مرحله اعتباریابی

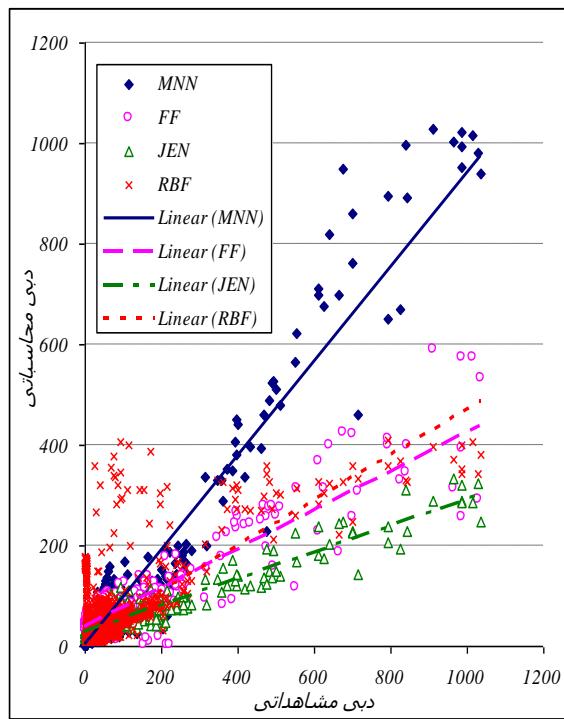
ردیف	مدل	دبی رودخانه در ایستگاه پل فلور			
		نتایج حاصل از نرم افزار Neuro solutions		نتایج حاصل از گرافها	
		r	NMSE	R^2	Equation
۱	MNN	0.950	0.163	0.903	$y = 0.9103x + 2.6389$
۲	FF	0.842	0.466	0.708	$y = 0.4313x + 36.503$
۳	JEN	0.887	0.562	0.787	$y = 0.2657x + 28.314$
۴	RBF	0.668	0.561	0.446	$y = 0.5019x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

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

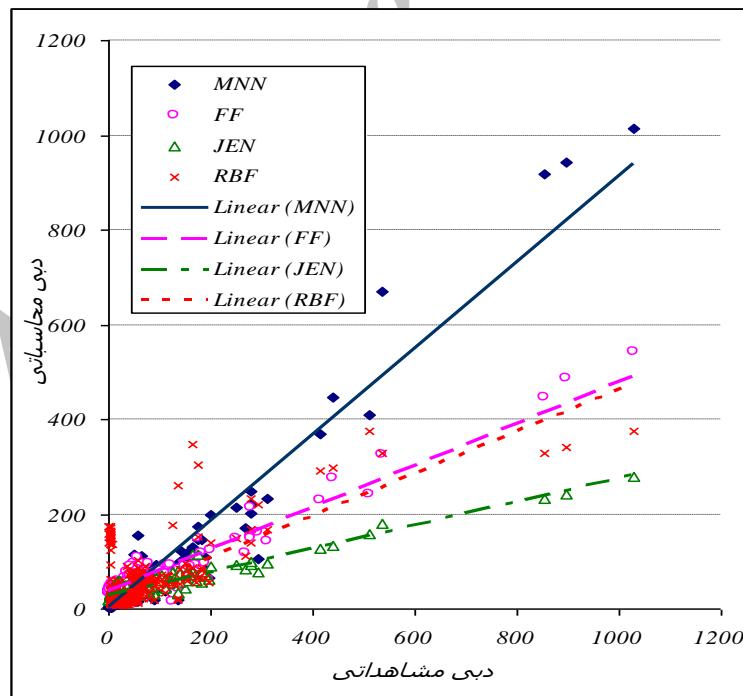
ردیف	مدل	دبی رودخانه در ایستگاه پل فلور			
		نتایج حاصل از نرم افزار Neuro solutions		نتایج حاصل از گرافها	
		r	NMSE	R^2	Equation
۱	MNN	0.957	0.084	0.917	$y = 0.91x + 2.7372$
۲	FF	0.933	0.413	0.870	$y = 0.4393x + 37.233$
۳	JEN	0.914	0.581	0.836	$y = 0.2477x + 28.539$
۴	RBF	0.733	0.479	0.538	$y = 0.445x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



شکل شماره ۴- مقایسه دبی مشاهداتی و محاسباتی در ایستگاه پل
فلور توسط مدل های EANN در مرحله اعتباریابی



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



شکل شماره ۵- 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 0.917 ، 0.903 ، و 0.916

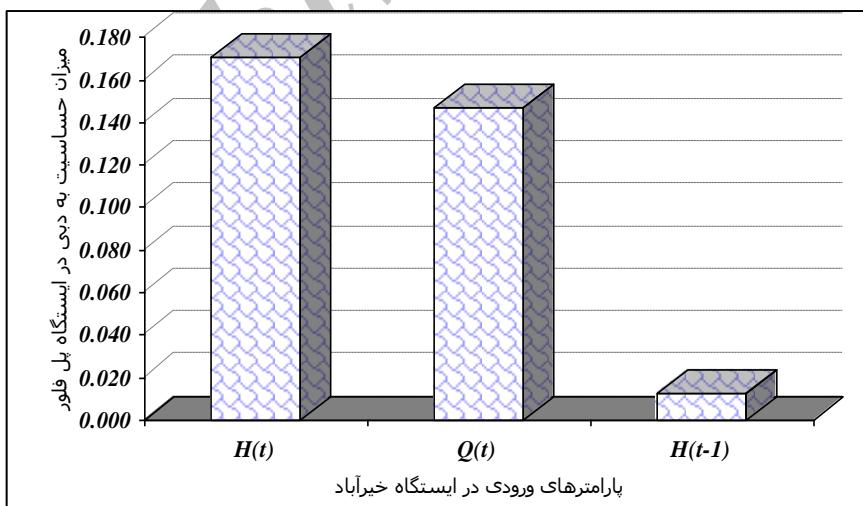
همچنین شیب خط راست برای این پارامتر برابر $0/936$ ، $0/9103$ و $0/91$ می باشد. بنابراین مدل MNN همبستگی بالاتری نسبت به سه مدل دیگر دارد. در نتیجه مدل MNN با ساختار آرایش (۱۵-۲۵-۳) بهترین مدل شبکه عصبی مصنوعی تکاملی می باشد.

حساسیت خروجی های مدل بهینه MNN نسبت به پارامترهای ورودی

برای آنکه میزان تاثیر پارامترهای 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 (۶) آمده است.

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

نام پارامتر ورودی	دبي ايستگاه پل فلور
اشنل ايستگاه خيرآباد	$H(t)$ 0.171
دبي ايستگاه خيرآباد	$Q(t)$ 0.147
اشنل ايستگاه خيرآباد در روز قبل	$H(t-1)$ 0.012



شکل ۶- تحلیل حساسیت پارامتر دبی در ایستگاه پل فلور در مدل MNN نسبت به پارامترهای ورودی

با توجه به شکل (۶) پارامترهای اشنل و دبی در ایستگاه خیرآباد به ترتیب دارای بیشترین و کمترین تاثیر بر روی خروجی مدل MNN می باشند.

مقایسه مدل شبکه عصبی مصنوعی با مدل‌های آماری

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

$$y = f(x_1, x_2, \dots) \rightarrow y = a_0 + a_1 x_1 + a_2 x_2 + \dots \quad (9)$$

در معادله فوق y متغیر وابسته، $x_1, x_2, \dots, x_n, a_1, a_2, \dots, a_n$ متغیرهای مستقل، ضرایب معادله از نوع رگرسیون می‌باشد. در این تحقیق برای متغیرهای ورودی و خروجی با استفاده از نرم افزار MINITABver14.0 مدل‌های 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 می‌دهند و خطای استاندارد هر یک از تخمین‌ها 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 می‌باشند که برای محاسبه احتمال P از آن استفاده می‌کنند، P در آزمون فرض به ما کمک می‌کند که جواب را رد یا قبول کنیم در اصل احتمال رخداد خطای نوع اول می‌باشد 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

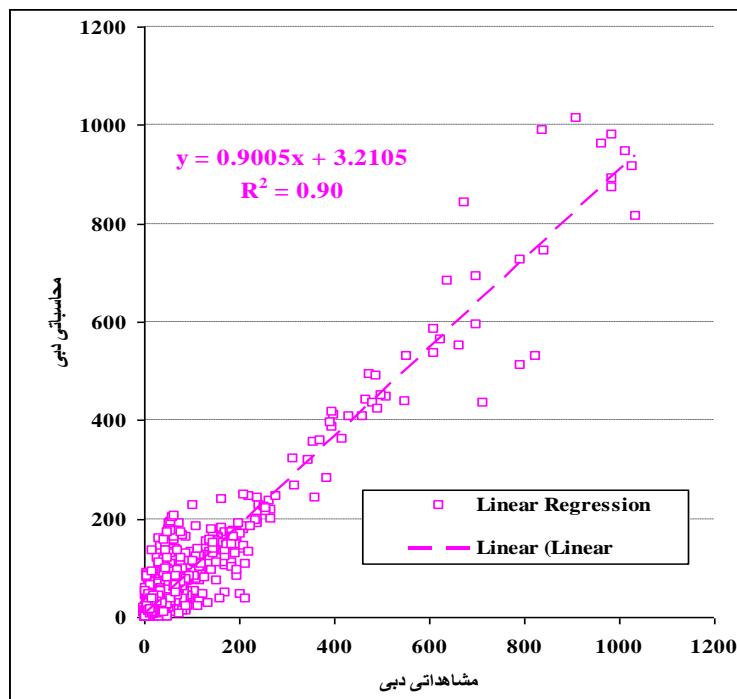
Predictor		Coef	SE Coef	T	P
مقدار ثابت	Constant	-43.429	1.478	-29.38	0.000
دبی در ایستگاه خیرآباد	x_1	0.699763	0.008400	83.31	0.000
اشل در ایستگاه خیرآباد	x_2	0.50153	0.01330	37.70	0.000
اشل روز قبل در ایستگاه خیرآباد	x_3	-0.145496	0.009099	-15.99	0.000

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

$$y = -43.4 + 0.700x_1 + 0.502x_2 - 0.145x_3 \quad (10)$$

که در معادله فوق y دبی در ایستگاه پل فلور، x_1 دبی در ایستگاه خیرآباد، x_2 اشنل در ایستگاه خیرآباد، x_3 اشنل روز قبل در ایستگاه خیرآباد می‌باشد، با توجه به معادله فوق و استفاده از داده‌های آموزش می‌توان مقدار دبی در ایستگاه پل فلور را محاسبه نمود در مدل رگرسیون خطی چندگانه ضریب R^2 برای پارامتر خروجی برابر ۰/۹۰ می‌باشد.

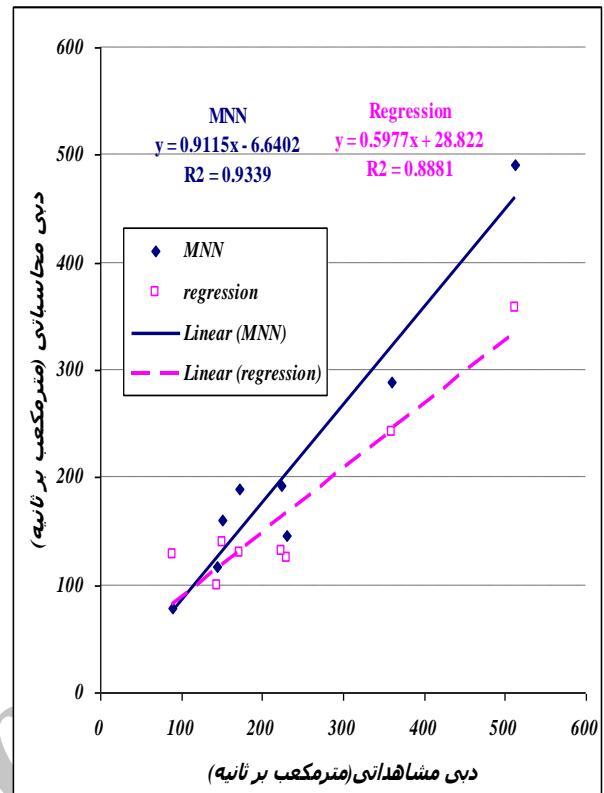
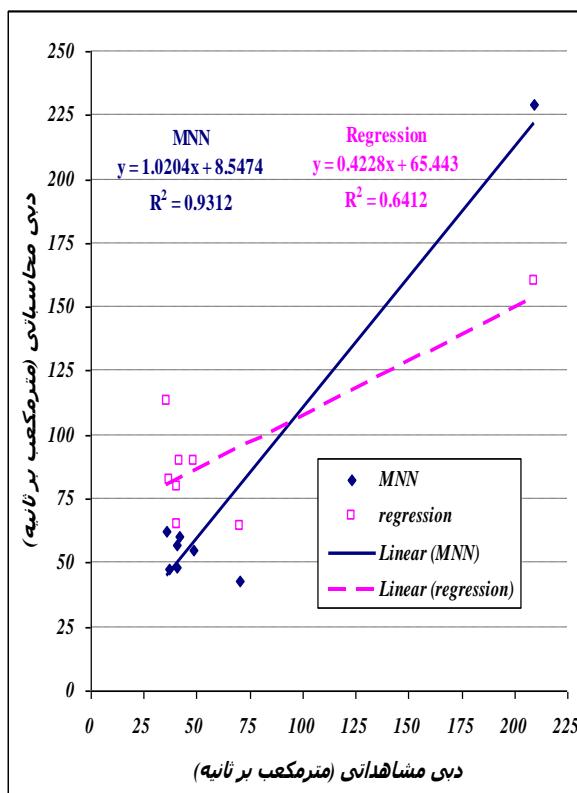
باشد همچنین شیب خط راست برای این پارامتر برابر $90/0\%$ می باشد که برای این مدل مناسب می باشد مقدار R^2 و شیب خط راست برای معادله در شکل زیرنشان داده شده است.



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

برای ارزیابی عملکرد مدل بهینه GA-MNN در روندیابی متراکر 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.

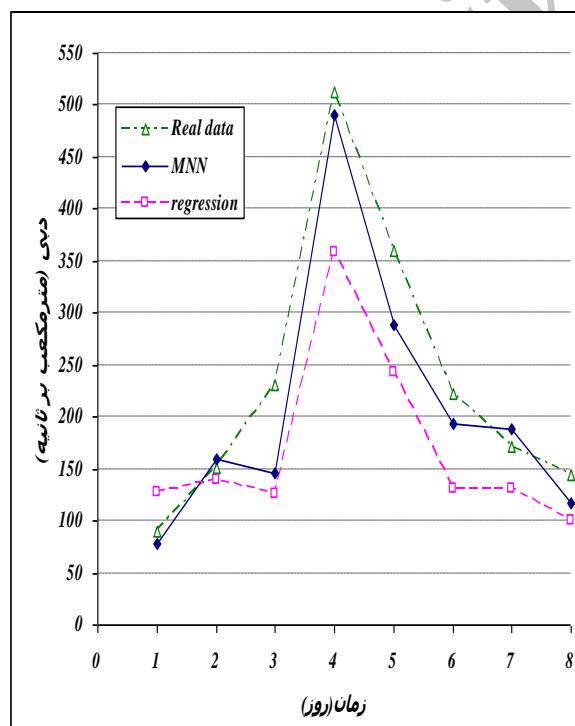
اشکال (۸) و (۱۰) مقایسه مقادیر دبی اندازه گیری شده و روندیابی شده توسط دو مدل را نشان می دهد. همچنین هیدروگراف دبی اندازه گیری شده در پایین دست بازه رودخانه در محل ایستگاه هیدرومتری پل فلور، هیدروگراف های روندیابی شده با مدل های MNN و مدل رگرسیون غیرخطی در شکل های (۱۱) و (۱۳) نشان داده شده است. با توجه به معادلات خطوط برازش داده شده بر مقادیر دبی محاسباتی و مشاهداتی در هر مدل در شکل های (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 شکل های (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.



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 سیل دی ماه ۱۳۸۰



شکل شماره ۱۰- مقایسه مقادیر دبی مشاهداتی و محاسباتی حاصل از

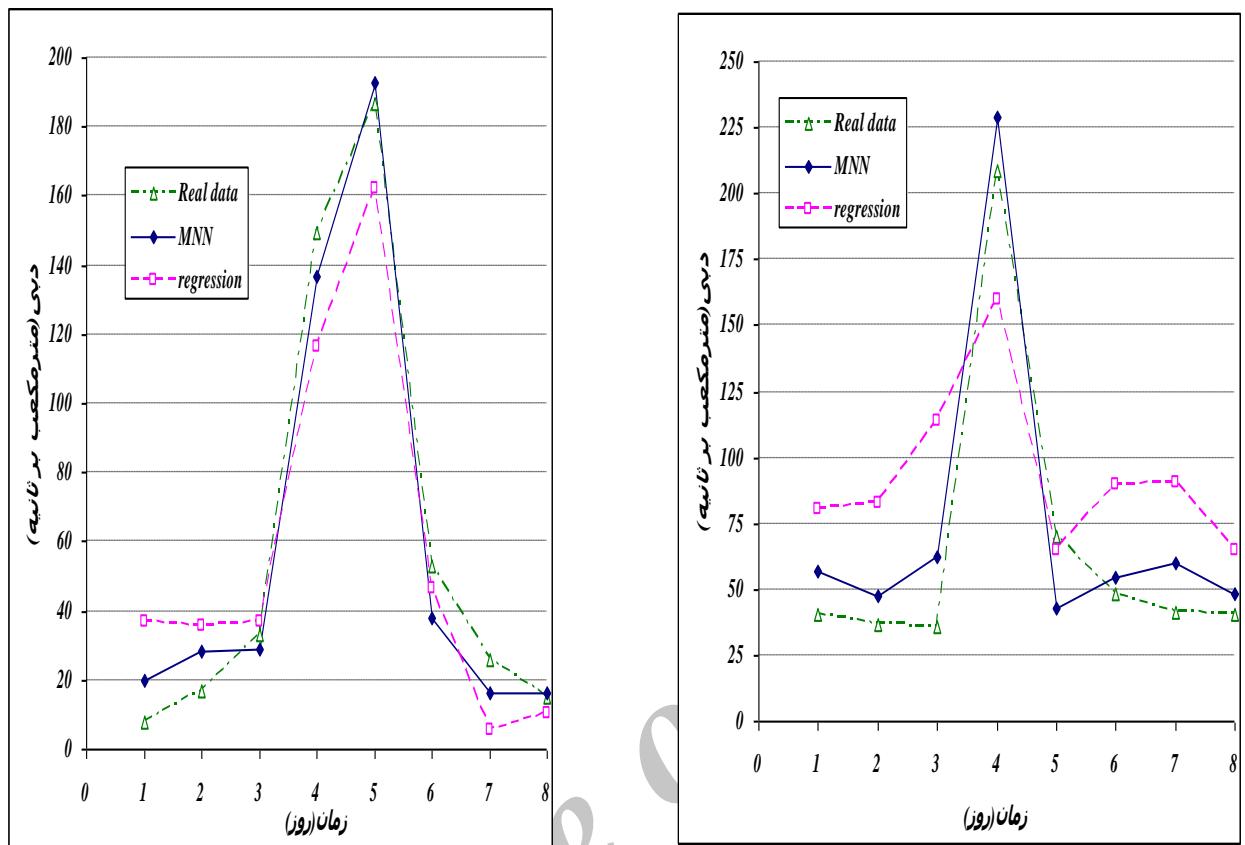
روندیابی هیدروگراف سیل با مدل های مختلف به ازای سیل فروردین ما

شکل شماره ۱۱- مقایسه مقادیر سیل خروجی و روندیابی شده با مدل

های مختلف مربوط به سیل دی ماه ۱۳۸۰

شکل شماره ۱۰- مقایسه مقادیر دبی مشاهداتی و محاسباتی حاصل از

روندیابی هیدروگراف سیل با مدل های مختلف به ازای سیل فروردین ما



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

با توجه به شکل های (۸) تا (۱۳) می توان نتیجه گرفت که شبکه های عصبی- مصنوعی تکاملی از انعطاف پذیری و دقیق 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 بالادرست 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.

مقایسه نتایج حاصل از آموزش ، اعتباریابی همزمان با آموزش و آزمون مدل‌های شبکه‌های عصبی مصنوعی تکاملی با مقادیر اندازه گیری شده نشان می دهد که مدل‌های 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 RBF، JEN، FF و MNN در مرحله آزمون به ترتیب برابر $0/917$ ، $0/870$ ، $0/836$ و $0/538$ به دست آمد.

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

منابع

- ۱- اطمینان حسنلویی، م؛ قادری، س.ج؛ عقری، 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 (۱۳۸۶)، «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- دربنده»، مقالات سومین کنفرانس مدیریت منابع آب، صص ۲۹-۱۳.
- ۴- حسنلویی، م.ا؛ قادری، ق.ج؛ عقری، 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 ۴۱-۳۵.
- 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.
- ۶- قلخانی ح؛ ثقیفیان، 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.

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

- 23- Mendeza, M.C., Manteigaa, W.G., Bandea, M.F., Sanchez, 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.