

فصلنامه تحقیقات جغرافیایی، سال ۲۷، شماره اول، بهار ۱۳۹۱، شماره پیاپی ۱۰۴

E. Fatahi
M. Delavar
K. Noohi

ابراهیم فتاحی، عضو هیات علمی پژوهشکده هواشناسی

مجید دلاور، دانشجوی دکتری سازه‌های آبی

کیوان نوحی، عضو هیات علمی پژوهشکده هواشناسی

E-mail: efattahi23@gmail.com

شماره مقاله: ۸۴۶

شماره صفحه پیاپی ۱۷۸۴۷-۱۷۸۱۹

پیش‌بینی جریان رودخانه‌های کارون شمالی با استفاده از شبکه عصبی مصنوعی

چکیده:

پیش‌بینی جریان رودخانه‌ها نقش بسزایی در برنامه ریزی، مدیریت و بهره‌برداری از منابع آب دارد. هدف اصلی این تحقیق بررسی امکان پیش‌آگاهی و پیش‌بینی دبی رودخانه‌های کارون شمالی (رودخانه ارمند و بازفت) با استفاده از روش‌های نوین شبیه‌سازی می‌باشد. در این مطالعه نوسانات جریان رودخانه‌های ارمند و بازفت در ارتباط با سیگنال‌های بزرگ مقیاس اقلیمی بررسی شده است. بدین منظور از داده‌های ماهانه شاخص نوسان جنوبی (SOI)، نوسان اطلس شمالی (NAO) و پدیده ENSO در مناطق $NINO_{1+2}$ ، $NINO_{3,4}$ ، $NINO_3$ ، $NINO_4$ استفاده گردید. تمامی داده‌های مربوط به سیگنال‌های اقلیمی از مرکز داده‌های آنالیز شده NCEP دریافت شد. داده‌های مربوط به دبی روزانه ایستگاه‌های هیدرومتری ارمند و مرغک نیز از مرکز داده‌های وزارت نیرو تهیه گردید. در این مطالعه به منظور طراحی بهینه معماری شبکه عصبی مصنوعی جهت پیش‌بینی دبی رودخانه‌ها براساس سیگنال‌های اقلیمی از الگوریتم ژنتیک بهره‌گرفته شد. نتایج تحقیق نشان داد که سیگنال‌های ENSO در ناحیه $NINO_{1+2}$ و $NINO_3$ به عنوان موثرترین سیگنال بر تغییرات جریان رودخانه‌های ارمند و بازفت هستند و برای پیش

آگاهی از وضعیت دبی رودخانه‌های کارون شمالی می‌توان از سیگنال‌های فوق استفاده کرد.

واژه‌های کلیدی: الگوریتم ژنتیک، پیش بینی، سیگنال‌های اقلیمی، شبکه عصبی مصنوعی، کارون شمالی

۱- مقدمه

افزایش برای تقاضای آب در مناطق مختلف بویژه در نواحی خشک و نیمه خشک، نیاز به مدیریت بهینه منابع آب را بیش از پیش نشان می‌دهد. پیش بینی دقیق و به موقع منابع آب در دسترس را می‌توان نکته کلیدی در برنامه ریزی، مدیریت و بهره برداری بهینه از منابع آب قلمداد کرد. بر این پایه دستیابی به روش‌های مطمئن پیش بینی جریان رودخانه‌ها به منظور برنامه ریزی در بهره برداری به موقع از منابع آب از اهمیت روزافزونی برخوردار است. در مناطقی که جریان رودخانه با تاسیسات ویژه ای کنترل می‌شود، مدل‌های پیش بینی جریان رودخانه‌ها به عنوان ابزار مناسبی در برنامه ریزی و مدیریت منابع آب مورد بهره گیری قرار می‌گیرند. پیش بینی رواناب و آگاهی پیش از موعد از میزان آب در دسترس می‌تواند در تقسیم بهینه منابع آب برای آبیاری، تولید جریان برق، کنترل سیلاب، برنامه ریزی کاربرد آب در بخش‌های صنعت، کشاورزی و شرب، حفاظت زیستگاه‌های منطقه‌های طبیعی، کنترل آلودگی آب و نیز گسترش بهره گیری تفرجگاهی از منابع و اراضی مفید بوده و منافع اقتصادی در بر داشته باشد. علاوه بر این، بهبود مدل‌ها و افزایش دقت پیش بینی را با توجه به اثرگذاری یادشده می‌توان به عنوان درآمد اقتصادی که در این راستا فراهم می‌شود در نظر گرفت. بنابراین مطالعه و بررسی روش‌های نوین و تعیین الگوریتم‌های مناسب جهت پیش بینی و مدلسازی مقادیر دبی رودخانه‌ها ضروری به نظر می‌رسد.

در این رابطه آلن و همکاران (۱۹۹۶) کریپلانی و کولکارانی (۱۹۹۷) بر این نکته تأکید می‌کنند که ENSO از مهم‌ترین پدیده‌های شناخته شده‌ای است که ناشی از واکنش‌های متقابل اقیانوس- جو و خشکی بوده و تغییرات اقلیمی در مقیاس سالانه در سطح کره زمین را موجب می‌گردد. وقوع دو پدیده متوالی ENSO تابع قانون زمانی مشخص نبوده و دوره برگشت‌های آن در فواصل زمانی ۲ تا ۱۰ سال مشاهده شده است. در همین رابطه روی و ردموند (۱۹۹۱) ارتباط بارش، دما و رواناب غرب آمریکا را با سیگنال‌های بزرگ مقیاس بررسی نموده‌اند. وانگ (۱۹۹۱) برای کالیبره کردن مدل بارش-رواناب از الگوریتم ژنتیک استفاده کرد. ایست وهال (۱۹۹۴) مطالعاتی در مورد استفاده از الگوریتم‌های ژنتیک در بهینه سازی مخزن انجام داده و به نتایج مطلوبی رسیدند. اسمیت و همکاران (۱۹۹۵) مایر و داندی (۱۹۹۶) از از شبکه‌های عصبی مصنوعی در مدل سازی کمی و کیفی منابع آب استفاده کرده اند. داندی و همکاران (۱۹۹۶) در طراحی بهینه شبکه آب رسانی، ریتزل و همکاران (۱۹۹۶) نیز در مسایل آلودگی آبهای زیرزمینی از روش الگوریتم ژنتیک استفاده کردند. جین و همکاران (۱۹۹۹) شبکه عصبی مصنوعی و مدل سری زمانی ARIMA را جهت پیش‌بینی جریان ورودی به مخزن حوضه اوريسا هند بکار بردند. هدف آنها پیش‌بینی یک ماه آینده جریان ورودی به سد با استفاده از اطلاعات ورودی سه ماه قبل بود. واردلاووشریف (۱۹۹۹) از الگوریتم ژنتیک به منظوری بهینه سازی بهره برداری از سیستم‌های تک مخزنی به خوبی استفاده کرده اند. سالاس و همکاران (۲۰۰۰) شبکه عصبی مصنوعی را برای پیش‌بینی جریان رودخانه لس پینوس کلرادو آمریکا برای ماههای می، جون، جولای و آگوست بکار بردند. داده‌های استفاده شده در تحقیق آنها شامل ۴۰ سال (۸۷-۱۹۴۸) جریان رودخانه و مقدار آب معادل برف بود.

کارآموز و زهرایی (۲۰۰۴) با استفاده از سیگنال‌های بزرگ مقیاس اقلیمی و بیلان برفی، جریان‌های فصلی مربوط به رودخانهٔ سالت مربوط به ایالت آریزونا را پیش‌بینی

کردند، نتایج تحقیق آنها نشان داد که ارتباط تنگاتنگی بین سیگنال‌های بزرگ مقیاس اقلیمی و سطح پوشش برف و جریان رودخانه در این حوضه وجود دارد. در ایران نیز تحقیقاتی در این راستا انجام شده است که به چند مورد از آنها اشاره می‌شود:

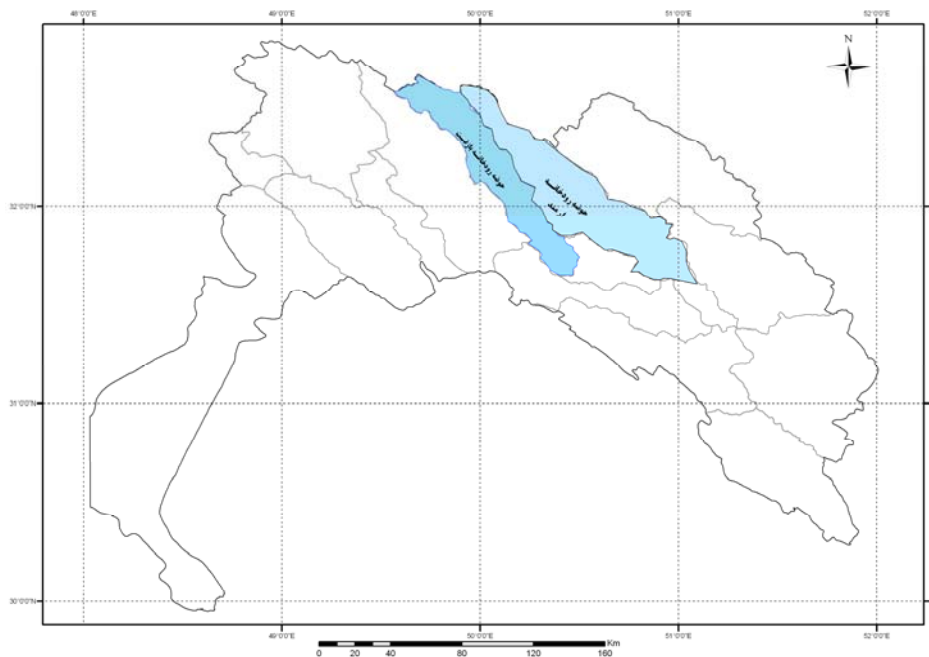
استوار (۱۳۷۹) ارتباط پدیده ال‌نینو با بارش‌های ماهیانه ایران را مورد ارزیابی قرار داده است، که نتایج حاصل نشان می‌دهد که اثرگذاری پدیده ال‌نینو بر بارش‌های ایران هم زمان با تغییر الگوی فشار در اقیانوس آرام نبوده، بلکه با تأخیر زمانی همراه است. سلطانی (۱۳۸۱) طیف متنوعی از شبکه‌های عصبی شامل BPN, RNN, RBF و STA- BPN را به منظور پیش‌بینی‌های کوتاه مدت و بلندمدت جریان ورودی به سد علویان مورد بررسی و ارزیابی قرار داد. پیش‌بینی‌های انجام شده شامل میانگین سه روز، یک هفته، ده روز، دو هفته، یک ماه، دو ماه، سه ماه و شش ماه آینده بود که به منظور مدیریت و تدوین سیاست‌های بهینه بهره‌برداری از مخزن سد انجام شد. و در نهایت شبکه BPN عملکرد بهتری نسبت به سایر شبکه‌ها نشان داد. کوره پزان (۱۳۸۲) در تحقیقی به بررسی تاثیر سیگنال‌های هواشناسی بزرگ مقیاسی چون ENSO, SST و NAO بر پیش‌بینی تغییرات بارش مناطق جنوبی ایران پرداخت. تحلیل‌های اولیه وی نشان داد که جنوب ایران در فازهای گرم ENSO و NAO و فاز سرد SST با پربارشی و در فازهای سرد ENSO و NAO و فاز گرم SST با کم‌بارشی مواجه هستند. فتاحی و همکاران (۱۳۸۸) تغییرات سطح پوشش برف حوضه‌های جنوب غربی ایران را در ارتباط با سیگنال‌های بزرگ مقیاس اقلیمی مورد بررسی دادند، نتایج تحقیق آنها نشان داد که سیگنال‌های NAO, SOI و تغییرات ناهنجاری SST در ناحیه NINO₄ و NINO₁₊₂ به عنوان موثرترین سیگنال بر تغییرات پوشش برفی حوضه‌های مورد مطالعه می‌باشند و برای پیش آگاهی از وضعیت سطوح تحت پوشش برف سیگنال‌های فوق کاربرد دارند.

هدف اصلی این تحقیق، بررسی امکان پیش‌بینی دبی در حوضه‌های منتخب کارون شمالی با استفاده از کاربرد روش‌های نوین مطرح در امر شبیه‌سازی و پیش‌بینی می‌باشد. از آنجائیکه سیستم دوگانه اتمسفر-اقیانوس^۱ (ENSO) و اثرش بر وضعیت جوی و پدیده‌های مربوط به اتمسفر در جوامع علمی مورد توجه زیادی قرار گرفته است، در این بررسی نیز سعی شده است با لحاظ کردن سیگنال‌های بزرگ مقیاس اقلیمی و با به کارگیری شبکه‌های عصبی مصنوعی به صورت تلفیقی با الگوریتم ژنتیک امکان پیش‌بینی‌های لازم طی دوره‌های همزمان، سه ماهه و شش ماهه مورد ارزیابی قرار گیرد.

۲- محدوده مورد مطالعه

در این مطالعه دو زیر حوضه بازفت و ارمند که جزو شاخه‌های اصلی آبریز کارون شمالی هستند به عنوان محدوده تحقیق در نظر گرفته شد. این زیر حوضه‌ها از ارتفاعات زاگرس در جنوب غرب ایران سرچشمه گرفته و به رودخانه کارون و در نهایت به خلیج فارس منتهی می‌شوند. از آنجایی که زیر حوضه‌های بازفت و ارمند جزو زیر حوضه‌های اصلی با آبدهی بالا هستند، بنابراین به منظور بررسی و امکان‌سنجی پیش‌بینی و پیش‌آگاهی فصلی جریان حوضه‌های فوق به عنوان نماینده کارون شمالی مورد بررسی قرار گرفتند. شکل ۱ موقعیت حوضه کارون و زیر حوضه‌های ارمند و بازفت را نشان می‌دهد.

^۱ - El nino-Southern oscillation



شکل ۱- موقعیت حوضه‌های کارون شمالی (حوزه ارمند و مرغک)

۳- داده‌ها و روش کار

۳-۱- داده‌ها

در این تحقیق از داده‌های سیگنال‌های بزرگ مقیاس اقلیمی نظیر شاخص نوسان جنوبی SOI شاخص NAO و پدیده ENSO در مناطق $NINO_3$ ، $NINO_4$ ، $NINO_{3,4}$ و $NINO_{1+2}$ و میانگین دبی روزانه رودخانه‌های ارمند و بازفت استفاده شده است (با توجه به تفاوت اندازه گیریهای داده‌های دبی که بر حسب شمسی و داده‌های سیگنال‌ها که بر اساس میلادی می‌باشند در این مطالعه داده‌های میانگین دبی روزانه از تقویم شمسی به میلادی تبدیل شدند و بدین ترتیب تفاوت ۱۱-۱۰ روزه بین داده‌های شمسی و میلادی نیز بر طرف گردید و داده‌ها از نظر زمانی یکسان شدند). شاخص‌های متعددی برای تعیین زمان وقوع پدیده‌های النینو و لانینو تعریف شده اند، در این مطالعه از داده‌های

ماهانه شاخص نوسان جنوبی، نوسان اطلس شمالی (NAO) و تغییرات ناهنجاریهای مربوط به SST در مناطق $NINO_4$ ، $NINO_3$ ، $NINO_{3.4}$ ، $NINO_{1+2}$ ، مورد استفاده قرار گرفته است. شاخص نوسان جنوبی (SOI) براساس فشار و سایر شاخص‌ها بر اساس دمای سطح آب دریا (SST) می‌باشد (خسروی و غیور، ۱۳۸۰) شاخص‌هایی که مبتنی بر دمای سطح آب دریا هستند، بر اساس میانگین SST در نواحی مختلف تعریف شده‌اند جدول ۱ محدوده طول و عرض جغرافیایی شاخص‌ها SST را بیان می‌کند. در این مطالعه کلیه داده‌های مربوط به سیگنال‌ها اقلیمی از مرکز NCEP/NCAR وابسته به مرکز NOAA دریافت گردید.

جدول (۱) - محدوده طول و عرض جغرافیایی تعریف شده برای شاخص‌های SST

طول جغرافیایی	عرض جغرافیایی	شاخص
۹۰ °W ۸۰ °W	۰-۱۰ S	Nino ₁₊₂
۱۵۰ °W ۹۰ °W	۵ °N- ۵ °S	Nino ₃
۱۷۰ ° W ۱۲۰ ° W	۵ °N- ۵ °S	Nino _{3.4}
۱۵۰ °E ۹۰ °W	۵ °N- ۵ °S	Nino ₄

پدیده نوسانات اطلس شمالی نیز بر پایه اختلاف فشار نرمال شده سطح دریا (P) بین منطقه حاره (آزور A) و کم فشار جنب قطبی (ایسلند I) بنا نهاده شده است، که به شرح زیر تعریف می‌شود.

$$NAO=P(A)-P(I)$$

این شاخص به دو صورت زمستانه (دسامبر- مارس) و سالانه بیان می‌شود.

۳-۱- روش کار

۳-۲-۱- شبکه‌های عصبی مصنوعی

شبکه عصبی مدل‌های محاسباتی هستند که قادرند رابطه میان ورودی‌ها و خروجی‌های یک سیستم فیزیکی را توسط شبکه‌ای از گره‌ها که همگی با هم متصل هستند، تعیین نمایند. میزان فعالیت هر یک از این اتصالات توسط اطلاعات تاریخی تنظیم می‌شود (فرآیند یادگیری) و در نهایت مدل قادر خواهد بود قوانین مرتبط میان ورودی‌ها و خروجی‌ها را کشف نماید.

این سیستم‌های مبتنی بر هوش محاسباتی، سعی در مدل‌سازی ساختار نروسیناپتیکی مغز بشر دارند. شبکه‌های عصبی مصنوعی با وجود اینکه با سیستم عصبی طبیعی قابل مقایسه نیستند، ولی ویژگی‌هایی دارند که آنها را در بعضی از کاربردها مانند تفکیک الگوها، رباتیک، کنترل و بطور کلی در هر جا که نیاز به یادگیری یک نگاشت خطی و یا غیر خطی باشد، ممتاز می‌نماید. این ویژگی‌ها شامل قابلیت یادگیری، پردازش توزیعی و قابلیت تعمیم دهی هستند.

ساختار شبکه‌های عصبی مصنوعی که معماری به آن اطلاق می‌گردد به شکلی است که نرون‌ها (واحدهای محاسباتی) در دسته‌هایی که لایه نام دارند، مرتب می‌شوند. معماری معمول شبکه عصبی متشکل از سه لایه است، لایه ورودی (داده‌ها را در شبکه توزیع می‌کند)، لایه پنهان (داده‌ها را پردازش می‌کند) و لایه خروجی (نتایج را به ازای ورودی‌های مشخص استخراج می‌کند). یک شبکه می‌تواند از یک یا چند لایه پنهان تشکیل شود. در غالب مطالعات انجام شده، انتخاب معماری در طراحی شبکه‌های عصبی مصنوعی با روش سعی و خطا می‌باشد که طی آن با استفاده از ارقام مختلف لایه‌های پنهان و نرون‌های مربوط، می‌توان شبکه بهینه را تعیین نمود. هرچه تعداد لایه‌ها و نرون‌ها افزایش یابد، باعث عملکرد بهتر شبکه برای دوره آموزش می‌شود، اما عملکرد برای دوره آزمون شبکه معمولاً کاهش می‌یابد. این مسأله را برآزش بیش از حد اطلاق می‌کنند.

بطوری که شبکه با داشتن تعداد زیاد لایه پنهان و نرون‌های مربوط، بیش از اندازه براساس داده‌های دوره آموزش واسنجی می‌گردد و قدرت انعطاف را برای الگوهای دیگر داده‌ای از دست می‌دهد.

نحوه محاسبات در شبکه‌های عصبی بدین شکل است که ورودی‌های به نرون (x_1 تا x_i) در اوزان (w_1 تا w_i) ضرب شده و مجموع نتایج حاصل از هر ورودی پس از اعمال در یک تابع، خروجی نرون را تشکیل می‌دهد مدل ریاضی آن بصورت رابطه زیر است:

$$net_j = \sum_{i=1}^n w_{ij} x_j \quad (1)$$

در بعضی موارد مقدار ثابتی در هر نرون به عبارت رابطه فوق بنام وزن اریب^۲ نیز افزوده می‌شود که رابطه (۱) بصورت زیر در می‌آید:

$$net_j = \sum_{i=1}^n w_{ij} x_j + b_j \quad (2)$$

شبکه‌های عصبی مصنوعی دارای مدل‌های مختلفی هستند که مبتنی بر جهت ورود اطلاعات و پردازش آنها به انواع زیر تقسیم شوند.

- شبکه‌های عصبی پیشرو^۳
- شبکه‌های بازگشتی^۴
- شبکه‌های توابع پایه شعاعی^۵
- شبکه‌های پرسپترون چند لایه^۶

بررسی‌های انجام شده نشان می‌دهند حدود ۹۰٪ ANNs که در فرآیندهای هیدرولوژیکی استفاده شده‌اند، شبکه عصبی پیشرو با الگوریتم آموزش انتشار برگشتی می‌باشند (کولیباوی و همکاران، ۲۰۰۰).

2-Biase weight
3-Feed-forward neural networks
4-Recurrent networks
Radial basis function networks-5
6-Multilayer perceptron networks

۳-۲-۲- الگوریتم ژنتیک

الگوریتم ژنتیک، یک الگوریتم جستجو بر مبنای ساختار طبیعی و ژنتیک موجودات زنده و یکی از روشهای مرسوم بهینه سازی است. اصول اساسی آن برای اولین بار توسط هولند و همکارانش (۱۹۷۵) در دانشگاه میشیگان مطرح شد و در سالهای بعد گسترش یافت. الگوریتم ژنتیک یک روش محاسباتی است که بر اساس ساختارهای ژنتیکی بنا شده است. این الگوریتم سعی می کند فرآیند تکامل تدریجی طبیعت را شبیه سازی کند. این تکنیک در عین اینکه تصادفی است، اما ساختار یافته و هوشمندانه است و به عنوان یک روش جستجو و بهینه سازی کاربرد وسیع دارد. اساس در این الگوریتم بر این قرار گرفته است که با بررسی برآیندگی شرایط قبلی، سعی در بهینه سازی شرایط بعدی دارد. الگوریتم ژنتیک در مقایسه با سایر روشهای جستجو مزایای قابل توجهی دارد. از جمله اینکه این الگوریتم به جای کار کردن بر روی یک جواب و بهینه سازی آن در تکرارهای بعدی، بر روی دسته ای از جوابها به طور همزمان کار می کند و به تدریج به سمت نقطه بهینه همگرا می شود. بنابراین احتمال اینکه در دام می نیممهای موضعی بیافتد بسیار کم است. این الگوریتم تنها به اطلاعات ورودی- خروجی سیستم نیاز دارد و بنابراین هیچ گونه قیدی از جمله خطی بودن، پیوسته بودن و یا مشتق پذیر بودن بر تابع تحمیل نمی کند. از این رو قابل کاربرد به دسته وسیعی از مسائل است.

در این الگوریتم که منطق حاکم بر آن بسیار ساده است، ابتدا باید توسط روشی جوابهای امکان پذیر را به ساختاری که الگوریتم ژنتیک با آن کار خواهد کرد، تبدیل نمود. سپس یک مجموعه اولیه از جوابها برای مسأله ایجاد می شود که به آن جمعیت گویند. در مرحله بعد چند جواب برتر انتخاب شده و از ترکیب آنها با استفاده از فرآیندهای ژنتیکی ترویج (Crossover) و جهش (Mutation) مجموعه جدید از جوابها ایجاد می شود. فرآیند انتخاب معمولاً فرآیندی تصادفی است که شانس بیشتری را به انتخاب جوابهای بهتر می دهد.

تنها اطلاعاتی که برای اجرای یک الگوریتم ژنتیکی مورد استفاده قرار می‌گیرد، مقدار تابع هدف است. با استفاده از فرآیندهای ژنتیکی یک نسل به نسل دیگر تبدیل می‌شود که به احتمال قوی‌تر از نسل فعلی دارای تابع هدف بهتری می‌باشد. فرآیند Crossover دو کروموزم انتخاب شده را (که اغلب کروموزمهای والد نامیده می‌شوند) برای تولید یک یا دو کروموزم جدید (که معمولاً کروموزمهای فرزند نامیده می‌شوند) ترکیب می‌کند. فرآیند Mutation یک اغتشاش کوچک در کروموزمهای موجود ایجاد می‌کند تا حالات مختلف جامعه حفظ شود. احتمال عملگر Crossover که معمولاً نرخ Crossover نامیده می‌شود، در اغلب موارد عدد بزرگی است، در حالیکه احتمال یا نرخ عملگر Mutation معمولاً کوچک است. البته تعیین مقادیر مناسب احتمال عملگرها را می‌توان پس از چند سعی و خطا بگونه‌ای محاسبه نمود که سرعت همگرایی و بهبود در نسل‌ها به حداکثر خود افزایش یابد. بدین شکل نسل‌های بعدی پدید می‌آیند و این فرآیند تا آنجا تکرار می‌شود که بهبود معنی‌داری در مجموعه مشاهده نشود. البته در برخی از روشها به منظور جلوگیری از تکرارهای بیش از حد مسأله که ممکن است هیچگاه به جواب با دقت ذکر شده نرسد، تعداد تکرارها را محدود و مقدار آن را مشخصاً در الگوریتم تعیین می‌کنند.

۳-۲-۳- پیش‌بینی دبی با استفاده از روش تلفیقی شبکه عصبی و الگوریتم ژنتیک

در این مطالعه به منظور طراحی بهینه معماری شبکه عصبی مصنوعی جهت پیش‌بینی دبی با استفاده از سیگنال‌های اقلیمی از الگوریتم ژنتیک بهره گرفته شد. بدین منظور تعداد و ترکیب پارامترهای ورودی و همچنین تعداد نرونهای شبکه در لایه‌های پنهان به عنوان متغیرهای تصمیم مساله بهینه‌سازی در نظر گرفته شد. بدین ترتیب یک شبکه عصبی پیشرو با دولایه پنهان مبنای طراحی بهینه قرار گرفت، و نوع و تعداد ورودی‌ها و تعداد نرونها در هر لایه با استفاده از الگوریتم ژنتیک تعیین گردید.


در الگوریتم ژنتیک پیشنهادی از یک جمعیت در هر نسل با تعداد ۱۰۰ فرد (کروموزوم) استفاده شده است که هر فرد (کروموزوم) دارای یک سری پارامترهایی می‌باشد که این پارامترها در طی نسل‌های مختلف این جامعه بهبود پیدا می‌کنند و جامعه بسمت تکامل حرکت می‌کند. پارامترهای ثابت افراد که ژن نامیده می‌شوند نشان‌دهنده خصوصیات و مشخصه‌های افراد یک جامعه هستند.

ژن‌ها بصورت تعداد نرونها در لایه‌های ورودی و لایه‌های دوم و سوم در نظر گرفته می‌شود. بدین صورت برای هر شبکه تعداد سه ژن در هر کروموزوم در نسل‌های مختلف بهبود می‌یابد. حداکثر نرونها در لایه‌های پنهان برای جلوگیری از پیچیدگی و همچنین فرابرازشی شدن شبکه عصبی ۸ عدد در نظر گرفته شد.

همچنین در این مدل بهینه‌سازی بمنظور میزان برازش واقعی هر کروموزوم از یک تابع هدف واقعی بر مبنای میزان ریشه میانگین مجذور خطا (RMSE) مطابق با رابطه زیر در نظر گرفته شد:

$$RMSE = \sqrt{\frac{\sum_{K=1}^K (X_K - Y_K)^2}{K}} \quad (۳)$$

که در آن X_K مقادیر مشاهداتی، Y_K مقادیر برآورد شده و K تعداد داده‌ها می‌باشد. عملگرهای ژنتیکی مورد استفاده عبارتند از عملگر تزویج (Crossover)، عملگر جهش (Mutation)، عملگر انتخاب (Selection) است. با توجه به در نظر گرفتن کدگذاری مقدار واقعی در هر کروموزوم می‌بایست در انتخاب عملگرهای ژنتیکی دقت خاصی نمود تا میزان همگرایی نسل‌ها بسمت بهبود هر چه بیشتر شود. الگوریتم بهینه سازی برای تعیین بهترین معماری شبکه عصبی با توجه به پارامترهای ذکر شده مطابق شکل شماره ۲ است:



شکل ۲: الگوریتم بهینه سازی معماری شبکه عصبی توسط الگوریتم ژنتیک

به منظور بررسی امکان پیش بینی موثر دبی با استفاده از سیگنال‌های اقلیمی، در این مطالعه از روش تعیین معماری لایه‌های میانی شبکه، نوع و تعداد ورودی‌ها به شبکه نیز با استفاده از الگوریتم ژنتیک تعیین می‌گردد.

۴- نتایج و بحث

۴-۱- بررسی اولیه داده‌ها

به منظور بررسی اولیه داده‌ها و تعیین همبستگی بین آنها برای تهیه مناسبترین مدل پیش‌بینی دبی، گام‌های زمانی ۰، ۳ و ۶ ماهه مد نظر قرار گرفت. بدین ترتیب در مرحله اول، ماتریس همبستگی بین دبی ماهانه ایستگاههای هیدرومتری، ارمنند و مرغک در حوضه‌های مورد مطالعه و سیگنال‌های اقلیمی مطابق با جداول ۲ تا ۴ برای گام‌های زمانی همزمان، سه ماهه و شش ماهه استخراج گردید:

جدول ۲: ماتریس همبستگی دبی ایستگاهها و سیگنال‌های بزرگ مقیاس اقلیمی در حالت بدون

تاخیر (همزمان)

سیگنال	ارمنند	بازفت (مرغک)
NINO _{1.2}	۰/۵۷۳	۰/۵۹۴
NINO ₃	۰/۵۸۶	۰/۵۶۵
NINO ₄	۰/۲۱۹	۰/۱۸۲
NINO _{3.4}	۰/۴۴۹	۰/۴۱۳
NAO	۰/۱۷۹	۰/۱۹۰
SOI	-۰/۲۷۱	-۰/۳۰۲

همانطور که ملاحظه می‌گردد بالاترین میزان همبستگی برای دبی ایستگاههای هیدرومتری در حالت بدون تاخیر، مربوط به سیگنال NINO_{1.2} و NINO₃ است. در حالت تاخیر سه ماهه میزان همبستگی دبی با سیگنال‌های اقلیمی به طور قابل ملاحظه‌ای کاهش می‌یابد، در این مورد بیشترین همبستگی بین دبی و سیگنال NINO₄ در ایستگاه‌های مرغک دیده می‌شود و در مورد ایستگاه ارمنند سیگنال NINO_{1.2} همچنان

پیش‌بینی جریان رودخانه‌های کارون شمالی با استفاده از شبکه عصبی مصنوعی / ۶۵

تاثیر گذارترین سیگنال می‌باشد. در حالت تاخیر شش ماهه همبستگی بین دبی و سیگنال‌های $NINO_{1.2}$ و $NINO_4$ موثرترین سیگنال‌ها در میزان دبی ماهانه است.

جدول ۳: ماتریس همبستگی دبی ایستگاهها و سیگنال‌های بزرگ مقیاس اقلیمی در حالت تاخیر

سه ماهه

سیگنال	ارمند	بازفت(مرغک)
$NINO_{1.2}$	۰/۲۲۰	۰/۱۱۱
$NINO_3$	۰/۰۰۶	-۰/۰۷۳
$NINO_4$	۰/۱۰۶	۰/۱۲۳
$NINO_{3.4}$	۰/۰۱۴	-۰/۰۲۶
NAO	۰/۱۶۱	۰/۱۰۱
SOI	-۰/۱۹۱	-۰/۱۸۹

جدول ۴: ماتریس همبستگی دبی ایستگاهها و سیگنال‌های بزرگ مقیاس اقلیمی در حالت تاخیر

شش ماهه

سیگنال	ارمند	بازفت(مرغک)
$NINO_{1.2}$	-۰/۵۰۹	-۰/۵۳۰
$NINO_3$	-۰/۳۰۲	-۰/۳۰۳
$NINO_4$	۰/۳۰۶	۰/۲۹۹
$NINO_{3.4}$	-۰/۰۰۹	-۰/۰۰۹
NAO	-۰/۱۰۴	-۰/۱۰۰
SOI	-۰/۱۰۳	-۰/۱۱۶

بنابراین ترتیب و میزان اثرگذاری سیگنال‌های بزرگ مقیاس اقلیمی در حالات همزمان و تاخیرهای سه ماهه و شش ماهه براساس مقدار ضریب همبستگی به صورت جداول ۵ تا ۷ قابل مشاهده هستند.

جدول ۵: میزان اثرگذاری سیگنال‌های بزرگ مقیاس اقلیمی بر دبی ماهانه به صورت همزمان

ایستگاه	NINO _{1,2}	NINO ₃	NINO ₄	NINO _{3,4}	NAO	SOI
ارمند	1*	□	□	□	□	□
مرغک	1	□	□	□	□	□

* رنگ سیگنال به ترتیب میزان اثرگذاری در دبی ماهانه حوضه‌های مورد مطالعه

جدول ۶: میزان اثرگذاری سیگنال‌های بزرگ مقیاس اقلیمی بر دبی ماهانه با تاخیر سه ماهه

ایستگاه	NINO _{1,2}	NINO ₃	NINO ₄	NINO _{3,4}	NAO	SOI
ارمند	1	□	□	□	□	□
مرغک	□	□	1	□	□	□

جدول ۷: میزان اثرگذاری سیگنال‌های بزرگ مقیاس اقلیمی بر دبی ماهانه با تاخیر شش ماهه

ایستگاه	NINO _{1,2}	NINO ₃	NINO ₄	NINO _{3,4}	NAO	SOI
ارمند	1	□	□	□	□	□
مرغک	1	□	□	□	□	□

همانطور که ملاحظه می‌گردد، تقریباً در تمامی ایستگاه‌ها شاخص ENSO در منطقه جزو پر اهمیت ترین سیگنال برای برآورد دبی ماهانه در حالات همزمان و تاخیر شش ماهه است، ولی مقدار سیگنال‌های اقلیمی دیگر اهمیت کمتری در مقدار دبی حوضه‌های مورد مطالعه دارند. همچنین در این مورد سیگنال NAO کم اهمیت‌ترین

پیش‌بینی جریان رودخانه‌های کارون شمالی با استفاده از شبکه عصبی مصنوعی / ۶۷

سیگنال برای برآورد در میزان دبی ماهانه است. در حالت تاخیر سه ماهه تفاوت‌هایی در میزان اثرگذاری سیگنال‌ها دیده می‌شود، در این مورد روند خاصی برای میزان تاثیرگذاری شاخص ENSO در منطقه دیده نمی‌شود، ولی شاخص SOI تاثیرگذاری قابل توجهی دارد.

۴-۲- تعیین مدل پیش‌بینی دبی ماهانه

در تحقیق حاضر علاوه بر تعیین معماری لایه‌های میانی شبکه، نوع و تعداد ورودی‌ها نیز با استفاده از الگوریتم ژنتیک تعیین شده است. جدول ۸ بهترین معماری تعیین شده توسط الگوریتم ژنتیک برای شبکه عصبی مصنوعی به منظور پیش‌بینی دبی برای حوضه‌های مورد مطالعه را نشان می‌دهد. اعداد نشان داده شده در جدول ۸ به ترتیب از چپ به راست نمایانگر تعداد نرونها در لایه ورودی، دو لایه میانی و لایه خروجی است.

جدول ۸: بهینه ترین معماری مدل‌های شبکه عصبی به منظور پیش‌بینی دبی

مدل	ارمند	مرغک
پیش‌بینی همزمان	۶-۲-۲-۱	۶-۲-۳-۱
پیش‌بینی با تاخیر سه ماهه	۶-۵-۳-۱	۶-۵-۴-۱
پیش‌بینی با تاخیر شش ماهه	۶-۳-۳-۱	۶-۴-۲-۱

جدول ۹ نیز نوع پارامترهای ورودی هر مدل شبکه عصبی را در حالت عملکرد بهینه نشان می‌دهد.

جدول ۹: نوع پارامترهای ورودی مدل‌های شبکه عصبی مصنوعی

مدل	ارمند	مرغک
پیش‌بینی همزمان	NINO _{1,2} , NAO	NINO _{1,2} , NAO
پیش‌بینی با تاخیر سه ماهه	NINO _{1,2} , NINO ₃ , NINO _{3,4}	NINO _{1,2} , NINO ₃ , NINO _{3,4}
پیش‌بینی با تاخیر شش ماهه	NINO _{1,2} , NINO ₃ , NINO _{3,4}	NINO _{1,2} , SOI

۴-۲-۱- پیش‌بینی دبی در حالت همزمان


جدول ۱۰ عملکرد شبکه‌های عصبی مصنوعی طراحی شده را در پیش‌بینی دبی ماهانه در حالت همزمان را نشان می‌دهد:

جدول ۱۰: عملکرد شبکه‌های عصبی مصنوعی طراحی شده در پیش‌بینی دبی ماهانه در حالت


همزمان

Performance	ارمند	مرغک
MSE	۳۲۵۵/۰۱	۲۳۳۳/۰۸
NMSE	۰/۵۸۹	۰/۵۹۳
MAE	۴۴/۴۳۳	۳۴/۵۲
Min Abs Error	۲/۵۴	۰/۰۲۳
Max Abs Error	۱۷۸/۶۵	۱۵۵/۸۴
r	۰/۶۳	۰/۶۳۳

شکل‌های ۲ و ۳ نحوه تغییرات و عملکرد بهترین مدل‌ها در پیش‌بینی دبی در ایستگاههای مورد مطالعه را در مرحله صحت‌یابی نشان می‌دهند.



شکل ۲: مقایسه دبی ماهانه مشاهداتی و پیش‌بینی شده در ایستگاه ارمند در حالت همزمان



شکل ۳: مقایسه دبی ماهانه مشاهداتی و پیش‌بینی شده در ایستگاه مرگک در حالت همزمان


۵-۲-۴-۲- پیش‌بینی دبی در حالت تاخیر سه ماهه

جدول ۱۱ و شکل‌های ۴ و ۵ عملکرد شبکه‌های عصبی مصنوعی طراحی شده را در


پیش‌بینی دبی ماهانه با تاخیر سه ماهه در مرحله صحت‌سنجی را نشان می‌دهد.

جدول ۱۱: عملکرد شبکه‌های مصنوعی طراحی شده در پیش بینی دبی ماهانه با تاخیر سه ماهه

Performance	ارمند	مرغک
MSE	۳۲۴۷/۴۸	۲۳۴۵/۵۶
NMSE	۰/۵۸۳	۰/۷۸۷
MAE	۴۰/۱۷۵	۳۶/۷۲
Min Abs Error	۱/۰۳۹	۱/۳۲
Max Abs Error	۲۰۶/۳۸	۱۳۴/۱۵
r	۰/۵۰۲	۰/۵۰۶



شکل ۴: مقایسه دبی ماهانه مشاهداتی و پیش بینی شده در ایستگاه ارمند



شکل ۵: مقایسه دبی ماهانه مشاهداتی و پیش‌بینی شده رودخانه بازفت (ایستگاه مرغک)


۴-۲-۳- پیش‌بینی دبی در حالت تاخیر شش ماهه

جدول ۵ عملکرد شبکه‌های عصبی مصنوعی طراحی شده را در پیش‌بینی دبی ماهانه با تاخیر شش ماهه در حالت کاربرد روش اول را نشان می‌دهد:


جدول ۵: عملکرد شبکه‌های مصنوعی طراحی شده در پیش‌بینی دبی ماهانه با تاخیر شش ماهه

Performance	ارمند	مرغک
MSE	۳۳۰۷/۳۳	۲۹۴۰/۶۰۷
NMSE	۱/۰۴۵	۱/۰۴۵
MAE	۵۰/۳۵۲	۴۳/۴۵
Min Abs Error	۰/۷۹۵	۱/۰۷۵
Max Abs Error	۲۰۹/۳۸	۱۰۸/۳۹
r	۰/۷۹۸	۰/۸۵۶


شکل‌های ۶ و ۷ نیز نحوه تغییرات و عملکرد بهترین مدل‌ها در حالت کاربرد روش دوم، در پیش‌بینی دبی در ایستگاه‌های مورد مطالعه را در مرحله صحت‌یابی نشان می‌دهند.



شکل ۶: مقایسه دبی ماهانه مشاهداتی و پیش بینی شده در ایستگاه ارومند



شکل ۷: مقایسه دبی ماهانه مشاهداتی و پیش بینی شده در ایستگاه مرغک



شکل ۸: تغییرات سطح پوشش برف حوضه‌های مرغک و ارمند طی دوره آماری ۲۰۰۰-۰۳

شکل ۸ تغییرات سطح پوشش برف حوضه‌های مرغک و ارمند را بر اساس داده‌های سنجنده مادیس طی دوره آماری ۲۰۰۰-۰۳ نشان می‌دهد. با توجه به نتایج ملاحظه می‌شود که بخش عظیمی از بارش‌ها در حوضه‌های مورد مطالعه به صورت برف است و آب

حاصل از ذوب برف نقش مهمی در ایجاد رواناب سطحی، تغذیه آبهای زیر زمینی و ایجاد سیل را باعث می‌شود. همچنین مقایسه تغییرات سطح پوشش برف حوضه‌های مرغک و ارمند طی دوره آماری ۲۰۰۳-۲۰۰۰ بیانگر بالاتر بودن ضریب برفگیری حوضه ارمند نسبت به حوضه مرغک می‌باشد. و به همین دلیل ماتریس همبستگی (نتایج جداول ۲، ۳، ۴) بین دبی ایستگاهها و سیگنال‌های بزرگ مقیاس اقلیمی در حوضه ارمند و مرغک که از نظر موقعیت مجاور هم واقع شده اند، مشابه نبوده و با تاخیر همراه است.

۶- جمع بندی و نتیجه گیری

هدف اصلی در این مطالعه بررسی امکان پیش بینی دبی در حوضه آبریز کارون شمالی با استفاده از شبکه‌های عصبی مصنوعی و بر اساس کاربرد مستقیم مقدار سیگنال‌های هواشناسی موثر است، بدین منظور قابلیت شبکه‌های عصبی مصنوعی در پیش بینی دبی با سه رویکرد پیش بینی همزمان، پیش بینی سه ماهه، و پیش بینی شش ماهه مدنظر قرار گرفت.

در این تحقیق، طراحی بهینه معماری شبکه عصبی مصنوعی جهت پیش بینی دبی با استفاده از الگوریتم ژنتیک انجام گرفت. بدین منظور تعداد و ترکیب پارامترهای ورودی و همچنین تعداد نرون‌های شبکه در لایه‌های پنهان به عنوان متغیرهای تصمیم مساله بهینه سازی در نظر گرفته شد. بدین ترتیب یک شبکه عصبی پیشرو با دولایه پنهان منبای طراحی بهینه قرار گرفت، و نوع و تعداد ورودی‌ها و تعداد نرون‌ها در هر لایه با استفاده از الگوریتم ژنتیک تعیین گردید.

جدول ۱۹: موثرترین سیگنال‌های اقلیمی در پیش‌بینی دبی در حوضه کارون شمالی

مدل	ارمند	مرغک
پیش‌بینی همزمان	NINO _{1,2} , NAO	NINO _{1,2} , NAO
پیش‌بینی با تاخیر سه ماهه	NINO _{1,2} , NINO ₃ , NINO _{3,4}	NINO _{1,2} , NINO ₃ , NINO _{3,4}
پیش‌بینی با تاخیر شش ماهه	NINO _{1,2} , NINO ₃ , NINO _{3,4}	NINO _{1,2} , SOI

نتایج مطالعه حاکی از آن است که پیش‌بینی دبی در حالت تاخیر شش ماهه سیگنال‌های اقلیمی نتایج مطلوبتری را داراست در این مورد طراحی بهینه شبکه‌های عصبی مصنوعی توسط روش دوم بسیار موثر است و در تمامی حالات پیش‌بینی‌های بهتری را ارائه می‌دهند.

همچنین در تمامی ایستگاهها شاخص ENSO در منطقه NINO1.2، پر اهمیت ترین سیگنال بر دبی ماهانه در حالات همزمان و تاخیر سه ماهه و شش ماهه است، ولی مقدار سیگنال‌های اقلیمی دیگر اهمیت کمتری در مقدار دبی منطقه مورد مطالعه دارند. بدین ترتیب نتایج حاصل از آنالیز حساسیت و بهینه سازی شبکه‌های عصبی مصنوعی، استفاده از سیگنال‌های ارائه شده در جدول ۱۹ را در پیش‌بینی موثر دبی در حالات مختلف و در منطقه مورد مطالعه پیشنهاد می‌کند.

منابع

- ۱- استوار میبیدی، الف (۱۳۷۹). ال‌نینو و رابطه آن با بارش‌های ایران. پایان‌نامه کارشناسی ارشد جغرافیای طبیعی (هیدرو اقلیم)، دانشگاه تربیت مدرس.
- ۲- سلطانی، س (۱۳۸۱). ارزیابی شبکه‌های عصبی مصنوعی در پیش‌بینی کوتاه مدت جریان رودخانه‌ها. پایان‌نامه کارشناسی ارشد، دانشگاه تربیت مدرس.
- ۳- غیور، ح و م، خسروی (۱۳۸۰) "تاثیر پدیده انسو بر ناهنجاری‌های بارش تابستانی و پاییزی منطقه جنوب شرق ایران" فصلنامه تحقیقات جغرافیایی، شماره ۶۲

۴- فتاحی، ا، نوحی، ک و دلاور، م (۱۳۸۸) " بررسی سطح پوشش برف حوضه‌های جنوب غربی ایران در ارتباط با

سیگنال‌های اقلیمی " فصلنامه تحقیقات جغرافیایی، شماره ۹۳

۵- کوره‌پزان دزفولی، الف (۱۳۸۲). تاثیر سیگنال‌های هواشناسی در پیش بینی تغییرات بارش. پایان‌نامه کارشناسی

ارشد، دانشگاه امیر کبیر.

- 6- Allan, R. J., Bread, G. S., Close, A., Herczeg, A. L., Jones, P. D., and Simpson, H. J. (1996). Mean sea level pressure indices of the El Nino/Southern Oscillation: Relevance to stream discharge in Southeastern Australia. CSIRO Australia, Division of Water Resources, Report No.96/1, ISSN 1033 5579.
- 7- Coulibaly, P., Anctil, F. and Bobee, B. (2000) "Daily reservoir inflow forecasting using artificial neural networks with stopped training approach" Journal of Hydrology, 230, 244-257
- 8- Dandy, G. C., Simpson, A. R. and Murphy, L. J.(1996), An improved genetic algorithm for pipe network Optimization, Water Resour. Res., 32(2): 449-458.
- 9- Esat, V., and Hall, M.J.(1994), Water resources system optimization using genetic algorithms Hydroinformatics '94, Proc., 1st Int. Conf. on Hydroinformatics, Balkema, Rotterdam, The Netherlands, 225-231.
- 10-Goldberg, D.E., and Richardson, J., Genetic algorithms with sharing for multimodal function optimization, In Genetic Algorithms and their Applications, J. J. Grefenstette, Ed.
- 11-Haykin, S., (1994). Neural Networks – A Comprehensive Foundation. Macmillan College Publishing Company, New York.
- 12-Holland, J.H.(1975), Adaption in natural and artificial systems, The University of Michigan Press, Ann Harbor, MI.
- 13-Jain, S. K., Das, A. and Sirvastava, D.K.(1999). Application of ANN for reservoir inflow prediction and operation. Journal of Water Resource Planning and Management, 125:263-271.
- 14-Karamouz, M. and B, Zahraie (2004) "Seasonal streamflow forecasting using snow budget and ENSO climate signal's Application to salt Basin in Arizona" ASCE Journal of Hydrology
- 15-Kim, T. W. and Valdes, J. B. (2003). Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks, ASCE. Journal of Hydrologic Engineering, 8: 319-328.
- 16-Kripalani, R. H., and Kulkarani, A. (1997). Rainfall variability over Southern-East Asia, connections with India monsoon and ENSO extremes: new perspective. International Journal of Climatology, 20(1): 47-61.
- 17-Maier, H. R., and Dondy, G. C. (1996). "Use of artificial neural networks for prediction of water quality parameters" water resources Research, 32 (4) 1013-1022.
- 18-Mariotti, A., Zeng, N. and Lau, K. M. (2002). Euro-Mediterranean rainfall and ENSO-a seasonally varying relationship. South African Journal of Science, 82: 196-198.

- 19-Mason, S. J., and Gilian, M. M. (2001). Comparison of some statistical methods of probabilistic forecasting of ENSO. *Journal of Climate*, 15(1): 8-29.
- 20-McCulloch, W. S., and Pitts, W. (1943). A logic calculus of the ideas immanent in neurous activity. *Bull Math. Biophys.*, No. 5: 115-133.
- 21-Nicholson, S. E., and Kim, J. (1997). The relationship of the El Nino/Southern Oscillation to African rainfall. *International Journal of Climatology*, 17: 117-135.
- 22-Ritzel, B., Ebeart, J. W. and Ranjithan, S.,(1994) Use genetic algorithms to solve a multiple objective, ground water pollution problem, *Water Resour ,Res.*, 30(5): 1589-1603
- 23-Salas.J.D.,Boes.C.D. and Smith.R. A (2000)." Estimation of ARIMA models with seasonal parameters". *Water Resour . Res.*18. 1006-1010.
- 24-Smith, J., and Eli, R. N. (1995) "Neural –network models of rain fall – runoff Process" *Journal water Resources, AACE*, 121 (6), 499-508.
- 25-Wang, Q. J.(1991), The genetic algorithm and its application to calibrating conceptual rainfall-runoff ,models, *Water Resour. Res.*, 27(9): 2467-2471.
- 26-Wardlaw, R., and Sharif, M.(1999), Evaluation of genetic algorithms for optimal reservoir system ,operation, *J. Water Res. Plng. and Mgmt.*, ASCE,125(1): 25-33.

