

مدلسازی هوشمند سری زمانی آورد ماهانه ورودی به سد وحدت سنندج

پرویز فتحی^{۱*} - یوسف محمدی^۲ - مهدی همایی^۳

تاریخ دریافت: ۸۷/۷/۱۳

تاریخ پذیرش: ۸۷/۹/۱۸

چکیده

پیش‌بینی جریان ورودی به منابع آبی یکی از مهمترین مسائل در برنامه‌ریزی و مدیریت بهینه آنها در جهت تولید انرژی برق آبی و تخصیص آب به منابع مصرف، محسوب می‌شود. پارامترهای مختلفی بر میزان دبی ورودی به سد تاثیرگذار می‌باشند. در مناطق خشک و نیمه خشک نظیر ایران، متغیرهای اقلیمی نظیر درجه حرارت و بارندگی بیشترین تاثیر را بر میزان رواناب ورودی به منابع آبی دارند. یک مدل بارش - رواناب ماهانه مناسب، ابزاری توانمند جهت بررسی اثر تغییرات اقلیمی بر قابلیت دسترسی آب برای تولید انرژی برق آبی به شمار می‌آید. تحقیقات نشان داده است که رابطه مابین مقدار رواناب و متغیرهای تاثیر گذار بر آن ارتباطی غیرخطی و پیچیده دارند. شبکه‌های عصبی مصنوعی به علت خصوصیات منحصر بفرد خود، قابلیت بالایی را در شبیه سازی روابط غیرخطی دارا می‌باشند. شبکه‌های عصبی مصنوعی تحولی عظیم در تحلیل رفتار سیستم‌های دینامیک در علوم مختلف مهندسی آب ایجاد کرده است. در این تحقیق سعی شده است با تبیین ویژگی‌های شبکه عصبی مصنوعی، شبکه استاتیکی برای بازبانی ارتباط غیرخطی مابین متغیرهای مستقل و وابسته طراحی گردد تا به کمک آن، تخمین هوشمند دبی متوسط ماهیانه ورودی به سد وحدت میسر گردد. در ادامه، با طراحی و بسط مدل شبکه عصبی دینامیکی بر مبنای کارکرد سری زمانی، مقدار آورد ماهانه ورودی به سد، مورد پیش‌بینی قرار گرفت. سپس از شبکه عصبی برای مدل سازی سری زمانی غیر خطی آورد ماهانه رودخانه استفاده شد. همچنین با مقایسه نتایج حاصل از مدل شبکه عصبی استاتیکی و دینامیکی، عملکرد مدل‌های طراحی شده مورد ارزیابی و سنجش قرار گرفت. نتایج حاصل از تحقیق نشان داد که انطباق خوبی مابین مقادیر پیش‌بینی شده با شبکه‌های عصبی ترکیبی و داده‌های مشاهداتی وجود دارد. همچنین نتایج نشان داد که مدل شبکه عصبی دینامیکی سری زمانی با دقت بالاتری نسبت به مدل استاتیکی، مقدار آورد ماهانه را پیش‌بینی می‌نماید.

واژه‌های کلیدی: دبی متوسط ماهیانه، شبکه عصبی مصنوعی، سری زمانی

مقدمه

تغییرات زمانی و مکانی بوده و لذا مدلسازی آن بدلیل سرشت غیرخطی و پیچیدگی آن با مشکلات عدیده‌ای همراه میباشد. در این موارد نوع مدل و ساختار آن تاثیر زیادی بر دقت پیش‌بینی رواناب ورودی به منابع آبی دارد (۱۱). اگرچه تحقیقات تفصیلی از این فرآیند ممکن است بیشتر جنبه پژوهشی داشته باشد تا جنبه کاربردی، با این حال بسیاری از فعالیت‌ها و طراحی‌های مهندسی نیازمند تخمینی مناسب از کمیت و کیفیت رواناب ناشی از یک بارش معین می‌باشند. بعلاوه در بسیاری از کاربردهای دیگر، سناریوهای مختلفی از بارش‌های بعدی به منظور شناسایی رفتار یک ناحیه، شبیه‌سازی می‌شود. در منابع و مقالات، روش‌های ریاضی متعددی یافت می‌شود تا با شناسایی کمیت و کیفیت بارندگی برای یک ناحیه فرضی تخمین دقیقی از رواناب ایجاد شود (۲۱). با این وجود مدلسازی فرآیند بارش - رواناب هنوز یک مسئله چالش برانگیز است. برای غلبه بر مشکلات موجود در این زمینه، می‌توان از روش‌های نوین پردازش، برای پیش‌بینی مقدار دبی متوسط ماهیانه ورودی به سدها استفاده نمود.

تخمین مقدار رواناب ورودی به سدهای ذخیره‌ای اولین و مهمترین قدم در برنامه ریزی و تخصیص بهینه آب به منابع مصرف و همچنین تولید انرژی برق آبی به شمار می‌آید. مدلسازی پدیده بارش - رواناب اولین و مهمترین گام در مدیریت آبخیزداری حوزه‌ها، بهره برداری از مخازن سدها، سیستم‌های هشدار سیل، اولویت بندی حوزه‌ها از نظر میزان فرسایش و رسوبگذاری بوده و پیش از هر گام دیگر نظر هیدرولوژیست‌ها را به خود جلب نموده است (۴). فرآیند بارش - رواناب به عنوان یکی از پیچیده‌ترین پدیده‌های غیر خطی در زمینه مهندسی آب محسوب می‌شود (۱۴). این فرآیند دارای بیشترین

۱- استادیار گروه مهندسی آب دانشگاه کردستان

* - نویسنده مسئول (Email: P.fath@uok.ac.ir)

۲- کارشناس ارشد آبخیزداری، دانشگاه تربیت مدرس

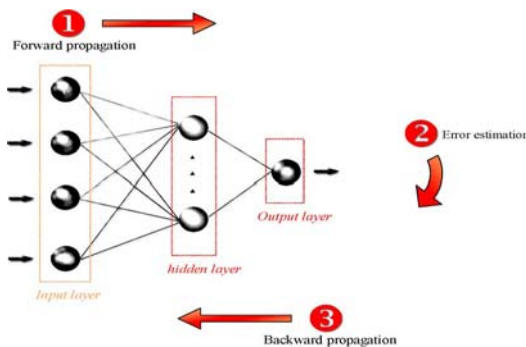
۳- دانشیار گروه خاکشناسی دانشگاه تربیت مدرس

از این قابلیت‌ها در ایجاد نگاهت بین میزان دبی ماه‌های قبل به همراه متغیرهای اقلیمی حوزه با مقدار دبی متوسط ماهیانه آب ورودی به سد وحدت سنندج می‌باشد. تحقیقات صورت گرفته نشان می‌دهد، با وجود کاربرد روزافزون روش شبکه عصبی مصنوعی در شبیه‌سازی رفتار پدیده‌های مختلف هیدرولوژی، استفاده از این روش در مدل‌سازی پدیده بارش - رواناب در مراحل اولیه توسعه و تکامل خود بوده و امروزه به عنوان مبحثی چالش برانگیز مد نظر محققین و پژوهشگران مرتبط با علوم آب قرار گرفته است (۷، ۱۵ و ۲۳).

هدف از این تحقیق بسط، واسنجی و آزمون مدل‌های استاتیکی و دینامیکی بر مبنای سری‌های زمانی در جهت پیش‌بینی آورد ماهانه ورودی به سد وحدت می‌باشد. در این تحقیق بر مبنای دبی متوسط ماه‌های قبل، مقدار دبی در ماه آتی مورد پیش‌بینی قرار می‌گیرد.

شبکه‌های عصبی مصنوعی (ANN)

یکی از روش‌های جدید در حل مسائل مختلف، روش شبکه عصبی مصنوعی است در این روش سعی می‌شود بر اساس روابط ذاتی مابین داده‌ها، نگاشتی غیرخطی مابین متغیرهای مستقل و وابسته برقرار گردد. ایده اصلی شبکه عصبی بر مبنای شبیه‌سازی عملکرد مغز انسان بوده و در مقیاس خیلی کوچک، می‌تواند مانند شبکه‌های زیستی قدرت یادگیری داشته باشد و همچنین این یادگیری را تعمیم دهد. مهمترین بخش یک شبکه زیستی، نرون می‌باشد. نرون‌ها سلول‌های تشکیل دهنده دستگاه عصبی انسان هستند. هر شبکه عصبی از تعداد زیادی گره و پیوندهای جهت دار که گره‌ها را به هم ارتباط می‌دهد، تشکیل شده است. این گره‌ها در چند لایه به نام لایه ورودی، مخفی و خروجی آرایش داده شده‌اند (شکل ۱).



(شکل ۱) - ساختار کلی شبکه عصبی مصنوعی

به گره‌هایی که در لایه ورودی و خروجی قرار گرفته‌اند، به ترتیب نرون‌های حسی و پاسخ دهنده نیز اطلاق می‌شود، اطلاعات از طریق گره‌های ورودی به شبکه وارد و سپس از طریق اتصالات به لایه‌های نهانی منتقل شده و در نهایت خروجی شبکه از طریق گره‌های لایه خروجی به دست می‌آید. هر عنصر پردازشگر (نرون) از

روش‌های ریاضی هوشمند ابزاری قدرتمند در جهت مدل‌سازی پدیده‌های پیچیده و غیرخطی به شمار می‌آید. مزیت عمده این روش‌ها قابلیت یادگیری با استفاده از داده‌های اندازه‌گیری شده می‌باشد. یکی از روش‌های نوظهور در حل مسایل مهندسی، روش شبکه عصبی مصنوعی است. این روش ابزاری موثر در شبیه‌سازی رفتار سیستم‌های غیرخطی می‌باشد (۱۸) که عملکرد آن شبیه به عملکرد مغز انسان است. اخیراً از این روش بطور گسترده‌ای در مدل‌سازی، کنترل و مدیریت سیستم‌های مختلف، جداسازی الگوها، پیش‌بینی‌های مالی و اقتصادی استفاده شده است. از جمله کاربردهای این روش می‌توان به مدل‌سازی بارش - رواناب (۱۲ و ۲۰)، مدیریت منابع آب (۱۵)، برآورد خصوصیات هیدرولیکی سفره‌های آب زیرزمینی (۲۵) اشاره نمود. شبکه‌های عصبی مصنوعی ساختار ریاضی قابل انعطافی دارند که قادرند روابط پیچیده غیر خطی میان داده‌های ورودی و خروجی را شناسایی کنند (۱۴ و ۲۴). کاربردهای فزاینده‌ای از شبکه‌های عصبی مصنوعی در جنبه‌های مختلف هیدرولوژی یافت شده است (۱۸) و تحقیقات انجام شده، پتانسیل شبکه‌های عصبی را برای مدل‌سازی روابط بارش - رواناب نشان داده است (۱۰ و ۲۰ و ۲۴ و ۲۶).

Zhang & Govindaraju (۲۷) با استفاده از روش شبکه عصبی مقدار رواناب ماهانه را در سه حوزه با وسعت متوسط در کانزاس آمریکا پیش‌بینی نمودند. نتایج تحقیق نشان داد که شبکه پیشنهادی در پیش‌بینی جریان‌ات حداقل و متوسط نتایج قابل قبولی ارائه می‌دهد اما در پیش‌بینی جریان‌ات حداکثر کارایی بالایی از خود نشان نمی‌دهد. Lorrai & Sechi (۱۹) و Anmala و همکاران (۵) نیز با استفاده از شبکه عصبی مصنوعی فرایند بارش - رواناب ماهانه چند حوزه مختلف را مدل‌سازی نمودند. نتایج حاصله نشان داد که روش شبکه عصبی می‌تواند با دقت بالایی مقدار رواناب ماهانه را پیش‌بینی نماید.

بررسی کارایی مدل شبکه عصبی توسط هسو و همکاران (۱۴) با استفاده از سری‌های زمانی روزانه نشان داد که شبکه عصبی در مقایسه با مدل مفهومی و مدل خطی ARMAX، می‌تواند روابط بارش رواناب را در حوزه رودخانه می‌سی‌سی‌پی آمریکا با دقت بالاتری شبیه‌سازی نماید. امکان تلفیق مدل‌ها به منظور ارتقاء عملکرد شبیه‌سازی رواناب به وسیله Anctil و همکاران (۷) مورد مطالعه قرار گرفت.

بررسی منابع و مقالات موجود در زمینه پژوهش حاضر نشان می‌دهد که هیچ گونه تحقیقی در خصوص استفاده از شبکه عصبی مصنوعی در پیش‌بینی دبی متوسط ماهانه ورودی به سد وحدت سنندج انجام نشده است. بر مبنای قابلیت‌ها و توانایی‌هایی که شبکه عصبی در شبیه‌سازی رفتار سیستم‌های غیرخطی و ایجاد نگاهت مابین متغیرهای ورودی و خروجی دارد، هدف از این تحقیق استفاده

ه) برازش الگو: برازش الگو در اصل محاسبه و تعیین پارامترهای مدل‌های انتخاب شده در مرحله اول و بررسی معنی دار بودن یا نبودن پارامترهای هر مدل است. به عبارت دیگر معنی‌دار نبودن پارامترهای هر مدل در این مرحله به معنی حذف آن مدل از بین مدل‌های انتخاب شده است. تخمین پارامتر یکی از مهمترین گام‌ها در مدلسازی است.

مدل‌های سری زمانی در حقیقت مدل‌های تصادفی هستند که در مورد سری زمانی که شامل N مشاهده از یک جامعه نامتناهی است که بوسیله یک فرایند تصادفی بوجود آمده است. انواع مدل‌های سری‌های زمانی عبارتند از: مدل اتورگرسیو، مدل میانگین متحرک، مدل ترکیبی. برخی از فرایندها وجود دارند که نه تنها واجد شرایط خود همبستگی هستند، بلکه دارای ویژگیهای میانگین متحرک نیز می‌باشند. در چنین مواردی از مدل‌های ترکیبی مدل‌های اتورگرسیو- میانگین متحرک و مدل‌های اتورگرسیو- میانگین متحرک تجمعی استفاده می‌شود.

اولین گام در مدلسازی تعیین یا شناسایی مدل بر اساس ویژگی‌های سری مشاهداتی است. تحلیل تغییرات پارامترهای آماری سری نظیر میانگین، انحراف معیار و چولگی در گام نخست می‌تواند برخی ویژگی‌های مدل را آشکار کند.

تبیین مساله

اولین قدم در پیش‌بینی دقیق دبی متوسط ماهیانه ورودی به سدهای ذخیره‌ای، شناسایی متغیرهای تاثیرگذار بر مساله می‌باشد. از متغیرهای تاثیرگذار بر دبی متوسط ماهیانه می‌توان به مقدار بارش ماهیانه، درجه حرارت ماهیانه و دبی ماه‌های قبل اشاره نمود. لورای و سچی^۱، ضمن تشریح روش شبیه‌سازی بارش- رواناب با شبکه عصبی، کارآمدی این مدل را تأیید نموده و عنوان کردند که شبکه عصبی مصنوعی حتی در مواردی که تنها اطلاعات مربوط به بارندگی و دما در دست باشد، پاسخ مناسبی از این پدیده را به دست می‌دهد.

در این تحقیق از سه متغیر فوق‌الذکر به عنوان ورودی مدل شبکه عصبی استفاده می‌گردد. با توجه به اینکه متغیرهای تاثیرگذار بر مساله شامل، درجه حرارت محیط (T)، مقدار بارش ماهیانه (P) و دبی ماه‌های قبل (Q) می‌باشد، بنابراین الگوهای ورودی سه عضوی بوده و لذا نیاز به شبکه‌های مختلفی با یک، دو و سه نرون در لایه ورودی می‌باشد. با توجه به اینکه تنها متغیر وابسته مساله، مقدار دبی متوسط ماهیانه ورودی به سد می‌باشد، در نظر گرفتن یک نرون در لایه خروجی مدل، برای حل مساله کفایت می‌کند. با مشخص شدن ساختار لایه ورودی و خروجی، مرحله بعدی تعیین تعداد لایه‌های

دو بخش تشکیل شده است. در بخش نخست، مجموعه وزنی مقادیر ورودی محاسبه می‌شود. در بخش دوم خروجی بخش نخست در یک تابع ریاضی قرار گرفته و خروجی نرون محاسبه می‌شود. این تابع ریاضی اصطلاحاً تابع آستانه یا تابع انتقالی نام دارد و عملکرد آن شبیه یک فیلتر غیر خطی است و موجب می‌شود تا خروجی نرون در یک محدوده عددی خاصی قرار گیرد. مهمترین مزیت شبکه عصبی نسبت به سایر روشهای دیگر قدرت یادگیری شبکه از محیط پیرامون آنست. در فرایند یادگیری مقادیر وزنه‌های شبکه به گونه‌ای انتخاب می‌گردد که عملکرد (خروجی) شبکه متناسب با انتظار ما باشد. الگوریتم یادگیری شبکه باید به گونه‌ای باشد که در طی آن مقادیر وزنه‌ها، گام به گام تا به حداقل رسیدن مقدار خطای پیش بینی شبکه تعدیل شود. برای یادگیری شبکه می‌توان الگوریتم‌های آموزشی مختلف، الگوریتم پس انتشار خطا و... استفاده نمود. با وجود پیشرفت‌های چشمگیر ساختارهای مبتنی بر هوش محاسباتی در علوم مختلف، کاربرد این ابزار در علوم آب‌اندک و در ابتدای راه است. اما به دلیل توانایی این ابزار در شبیه‌سازی فرآیندهای بسیار پیچیده و نامعلوم که در علوم مرتبط با آب به وفور یافت می‌شوند، زمینه و امکان کاربرد گسترده آنها مهیا شده و تعداد بسیاری از پژوهش‌ها در این مورد می‌باشد.

سری‌های زمانی

سری زمانی مجموعه‌ای از مشاهدات است که بر حسب زمان (یا هر کمیت دیگر) مرتب شده باشد و معمولاً آن را به صورت زیر نشان می‌دهند: $X_{t1}, X_{t2}, \dots, X_{tm}$. در تحلیل یک سری زمانی چندین هدف ممکن است وجود داشته باشد این اهداف را می‌توان به شرح زیر رده بندی کرد:

الف) توصیف: وقتی یک سری زمانی داده می‌شود معمولاً اولین مرحله در تحلیل اینست که نمودار داده‌ها را رسم کرده و اندازه‌های توصیفی ساده را به دست می‌دهد.

ب) تشریح: وقتی مشاهدات روی دو متغیر یا بیشتر صورت گیرد ممکن است بتوان از تغییرات یک سری زمانی برای بیان تغییرات سری دیگر استفاده نمود. در اینگونه موارد ممکن است الگوهای رگرسیون چندمتغیره مفید باشند.

ج) پیش بینی: یک سری زمانی مفروض است، قرار است مقادیر آینده سری را پیش بینی کنیم. این کار در پیش بینی و تحلیل سری‌های زمانی در هیدرولوژی از اهمیت زیادی برخوردار است.

د) کنترل: وقتی از تحلیل یک سری زمانی بحث می‌شود "کیفیت" یک فرایند تولید را اندازه می‌گیرد، هدف از تحلیل می‌تواند کنترل فرایند باشد. در کنترل آماری، مشاهدات روی نمودارهای کنترل رسم شده و کنترل کننده با توجه به نتیجه مطالعات و نقشه‌ها اقدام می‌کند.

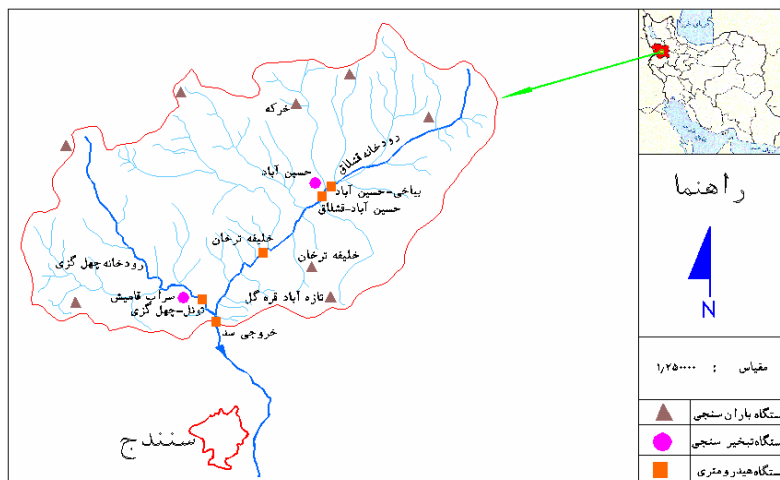
مخفی و نرونهاى هر لایه و بطور کلی معماری شبکه است.

مواد و روش‌ها

موقعیت جغرافیایی حوزه مورد مطالعه: محدوده مورد

مطالعه بخشی از حوزه آبریز سیروان با مساحتی در حدود ۱۰۵ هزار هکتار در قسمت مرکزی استان کردستان واقع می‌باشد، که ۳/۸ درصد سطح استان را در بر می‌گیرد. حوزه مورد مطالعه از شمال با حوزه رودخانه سفیدرود و از سمت شرق با حوزه رودخانه گاو رود هم مرز می‌باشد. در سمت جنوب، رودخانه خروجی این حوزه پس از پیوستن با

رودخانه گاو رود تشکیل رودخانه سیروان را داده و به سمت مرز ایران و عراق جریان یافته و در کشور عراق به رودخانه دجله متصل می‌شود. از سمت غرب نیز این حوزه با حوزه رودخانه سیروان هم مرز می‌باشد. این حوزه بین مختصات جغرافیایی "۴۶° ۴۰' تا "۴۶° ۲۰' ۰۰" طول شرقی و "۳۵° ۲۴' ۴۴" تا "۳۵° ۴۳' ۲۳" عرض شمالی واقع شده است. موقعیت مکانی سد وحدت و ایستگاههای هیدرومتری، باران سنجی و تبخیرسنجی در شکل ۲ نمایش داده شده است.



(شکل ۲) - موقعیت حوزه آبخیز قشلاق در ایران و استان کردستان

ترخان و سراب قامیش دارای بالاترین همبستگی و ارتباط می‌باشد. لذا در این تحقیق از داده‌های ایستگاه سراب قامیش برای بازسازی داده‌های مفقود شده ایستگاه خلیفه ترخان استفاده گردید.

نرمال سازی داده‌ها: اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای احراز از چنین شرایطی و همچنین به منظور یکسان نمودن ارزش داده‌ها، قبل از آموزش شبکه عصبی، داده‌های ورودی به آن بایستی استاندارد (نرمال) شوند. در این تحقیق از فرمول‌های شماره ۱ و ۲ برای نرمال سازی داده‌های ورودی به مدل استفاده و نتایج آن‌ها با هم مقایسه گردید:

$$= 0.5 + 0.5 \left(\frac{X - X_{mean}}{X_{max} - X_{min}} \right) \quad (1)$$

$$= 0.5 + 0.5 \left(\frac{X - X_{min}}{X_{max} - X_{min}} \right) \quad (2)$$

در این تحقیق دو ایستگاه هیدرومتری تونل - چهل گزی و خلیفه ترخان، ایستگاه تبخیر سنجی سراب قامیش و ایستگاه باران سنجی خلیفه ترخان به دلیل طولانی بودن، مستند بودن و مطمئن بودن از کیفیت آمار آنها به عنوان ایستگاه‌های مرجع، مورد استفاده قرار گرفتند که طول دوره آماری مشترک ایستگاه‌ها برابر ۱۵ سال (از سال ۶۸-۶۷ الی ۸۲-۸۱) می‌باشد.

پیش پردازش داده‌ها:

آزمون همگنی: برای داده‌های بارندگی، دما و دبی آزمون همگنی به روش منحنی جرم مضاعف انجام شد که نتایج آزمون نشان داد که داده‌ها از همگنی قابل قبولی برخوردار می‌باشند.

بازسازی داده‌ها: در این مرحله، به منظور بازسازی نواقص آماری از روش همبستگی بین ایستگاه‌ها استفاده شده است. چون ایستگاه باران سنجی خلیفه ترخان در سال (۸۱-۸۰) فاقد آمار بود لذا در این سال از روش همبستگی مابین ایستگاه‌ها جهت بازسازی داده ناقص استفاده گردید. نتایج نشان می‌دهد که داده‌های ایستگاه خلیفه

مقادیر خطای آموزشی و صحت سنجی مدل پیشنهادی حاصل از دو فرمول فوق الذکر در جدول ۱ قید گردیده است.

که در آن: X_{norm} : مقدار نرمال شده داده‌ها، X_{mean} : میانگین داده‌ها، X_{max} و X_{min} : به ترتیب مقدار حداکثر و حداقل داده‌ها می‌باشد.

(جدول ۱) - مقایسه خطاهای آموزش و صحت سنجی حاصل از دو فرمول نرمال سازی مختلف

تکرار	خطای آموزش	خطای صحت سنجی	فرمول نرمال سازی
۱۰۰۰۰	۰/۰۹۶۰	۰/۰۳۹۹	(۱)
۱۴۰۰	۰/۰۴۳۲	۰/۰۷۳۶	(۲)

آموزشی جایجا می‌شود. در این روش انتخاب اجزاء فنی شبکه بر مبنای کمترین خطا و بیشترین ضریب همبستگی در مرحله صحت سنجی صورت می‌گیرد. اولین قدم در معماری یک شبکه انتخاب قانون یادگیری مناسب می‌باشد. در این تحقیق از قوانین یادگیری و توابع آستانه متفاوتی استفاده گردید که در نهایت مشخص شد که مدل شبکه عصبی با قانون یادگیری *Quick Prop* و تابع آستانه تانژانت هیپربولیک ($\tan H$) مقادیر دبی متوسط ماهیانه را با دقت بالاتری پیش بینی می‌نماید. لذا در این تحقیق طراحی و معماری شبکه‌های مورد نیاز بر مبنای این قانون و تابع صورت می‌گیرد. در بخش معماری شبکه (انتخاب تعداد لایه مخفی، تعداد نرون و...) شبکه دو لایه (نرون‌های مختلف در لایه اول و دوم) تک تک آموزش و طراحی می‌شود. یعنی به ازای هر تعداد نرون در لایه اول و در لایه دوم، یک شبکه جداگانه طراحی می‌شود که همزمان با خطای $RMSE$ نیز محاسبه شده و همزمان با روند کاهش خطای $RMSE$ میزان R^2 نیز محاسبه می‌شود. در این تحقیق ۴ مدل استاتیکی، دینامیکی یک فاکتوره، دینامیکی دو فاکتوره و دینامیکی-استاتیکی به شرح زیر طراحی گردید که در تمامی این مدل‌ها، شبکه پیش فرض دارای مشخصات زیر می‌باشد:

الف) شبکه دینامیکی دو متغیره: با توجه به توانایی‌های شبکه مذکور، هدف از این تحقیق، طراحی و بسط مدل شبکه عصبی مناسب، جهت پیش بینی سری زمانی غیرخطی دبی رودخانه می‌باشد. در این تحقیق از مدل شبکه‌های عصبی اتورگرسیو ناقص استفاده شده است. در مدل‌های عصبی اتورگرسیو، خروجی مدل در گام زمانی t به مقادیر خروجی مدل در یک یا چند گام زمانی عقبتر وابسته است. در مدل‌های عصبی اتورگرسیو تمام عیار، خروجی مدل در زمان t به عنوان ورودی مدل جهت پیش بینی مقدار سری زمانی در زمان $t+1$ بکار گرفته می‌شود. ولی در مدل‌های اتورگرسیو ناقص، بجای فرستادن خروجی مدل در زمان t به عنوان ورودی برای پیش بینی گام زمانی $t+1$ ، مشاهده درست متناظر با خروجی مذکور به عنوان ورودی برای پیش بینی گام زمانی $t+1$ فرستاده می‌شود. هدف از به کارگیری مدل اتورگرسیو ناقص در این تحقیق، لحاظ نمودن داده‌های واقعی (مشاهداتی) که برداشته‌ای کاملاً واقعی از پدیده

جدول ۱ نشان می‌دهد که استفاده از معادله ۱ جهت نرمال سازی داده‌ها، خطای صحت سنجی کمتری ایجاد می‌کند. لذا در این تحقیق از این معادله برای نرمال سازی داده‌ها استفاده گردید.

معماری شبکه:

تقسیم بندی داده‌ها: مدل‌های شبکه عصبی جهت طراحی

نیازمند سه دسته داده آموزشی^۱، صحت سنجی^۲ و آزمون^۳ می‌باشند. **الف) داده‌های آموزشی:** از این داده‌ها به منظور پیدا کردن رابطه بین ورودی‌ها و خروجی‌های مشاهده‌ای توسط مدل استفاده می‌شود. در این تحقیق درصد‌های مختلفی از کل داده‌ها برای آموزش شبکه در نظر گرفته شد.

ب) داده‌های صحت سنجی: یعنی اینک بخش‌های از داده‌های موجود، برای کنترل و نظارت بر یادگیری صحیح شبکه استفاده می‌شود. در این تحقیق، درصد‌های مختلفی از کل داده‌ها نیز برای صحت سنجی شبکه در نظر گرفته شد.

ج) داده‌های آزمون: در این تحقیق از ۱۰ درصد کل داده‌ها برای ارزیابی عملکرد شبکه پیشنهادی استفاده گردید. برای تقسیم بندی داده‌ها از درصد‌های متفاوتی استفاده شد. نتایج برای دو دسته بندی بهینه بصورت جدول ۲ نمایش داده شده است. در نهایت مشاهده گردید که اختصاص ۸۰، ۱۰ و ۱۰ درصد کل داده‌ها، به ترتیب برای آموزش، صحت سنجی و آزمون مدل، کمترین خطای صحت سنجی را بوجود می‌آورد.

روش طراحی: در این مرحله برای طراحی شبکه عصبی از روش *Cross Validation* استفاده گردید. در این روش، طراحی شبکه بر مبنای حداکثر سازی کارایی و عملکرد آن صورت می‌گیرد. آموزش زمانی متوقف می‌شود که خطای صحت سنجی به حداقل میزان ممکن کاهش یابد. در این روش به منظور کاهش بیشتر خطای صحت سنجی، داده‌هایی که نسبت به سایر داده‌ها پرت باشند با داده‌های

- 1- Training Data
- 2- Validation Data
- 3- Test Data

هستند، بجای داده‌های محاسبه شده توسط مدل (ناشی از عملکرد محاسباتی مدل) می‌باشند.

(جدول ۲) - مقادیر خطای شبکه برای درصدهای مختلف از داده‌های ورودی به آن


آموزش و صحت	خطای تست	خطای صحت سنجی	خطای آموزشی
(%۸۰ و %۱۰)	۰/۰۴۸۸	۰/۰۳۹۹	۰/۰۹۶۰
(%۵۰ و %۴۰)	۰/۱۰۷۱	۰/۰۸۱۸	۰/۰۶۷۲

(جدول ۳) - مشخصات فنی شبکه پیش فرض در تمامی مدل‌ها

Transfer	Epoch	ضریب مومتوم	ضریب یادگیری	تکرار اولیه مشخصات پیش فرض
Tan H	۱۶	۰/۴	۰/۵	۲۰۰۰

شکاف زمانی و یا پیش بینی دبی، اطلاعاتی از دبی متوسط ماهیانه بدست آوریم. در این شبکه با استفاده از دبی دو ماه قبل، دبی ماه آینده پیش‌بینی می‌گردد. به عنوان مثال با استفاده از دبی ماه‌های فروردین و اردیبهشت به عنوان ورودی شبکه، دبی ماه خرداد پیش‌بینی می‌شود. در این مرحله شبکه طراحی شده برای مقادیر مختلفی از تکرارهای محاسباتی تحت آموزش قرار گرفته و مقادیر خطای صحت‌سنجی و ضریب همبستگی مدل محاسبه و بصورت شکل ۳ ترسیم گردید. مشخصات فنی و طراحی شده شبکه اخیر در جدول ۴ نمایش داده شده است.

برای جلوگیری از یادگیری اضافی در حین آموزش مدل، از تکنیک Cross Validation به عنوان یک معیار توقف استفاده شده است و سه پرورد زمانی که از لحاظ پارامترهای آماری سازگار هستند، به عنوان مجموعه‌های آموزشی، اعتباری و آزمایشی در نظر گرفته شده‌اند. اگر Q_1 دبی جریان در گام زمانی t باشد، در مطالعه حاضر ترکیب زیر برای ورودی شبکه در نظر گرفته شده است: Q_{t-1}, Q_{t-2} . همانطوریکه مشاهده می‌شود این ترکیب در گام‌های زمانی گذشته فقط از دبی جریان رودخانه استفاده می‌کنند. اهمیت این ترکیبات زمانی بیشتر مشهود است که ما در گام‌های زمانی گذشته فاقد اطلاعات بارندگی یا دما و زمان بارش هستیم و می‌خواهیم در یک



(شکل ۳) - آموزش نهایی شبکه دینامیکی دو فاکتوره

در این مرحله به اتمام می‌رسد. در جدول ۴ مقادیر خطا و ضریب همبستگی مدل در تکرار نهایی ۲۲۰۰۰ قید گردیده است.

مشاهده شکل شماره ۳ نشان می‌دهد که تکراری برابر ۲۲۰۰۰ کمترین خطای صحت سنجی را به دست می‌دهد و لذا آموزش شبکه

(جدول ۴) - مقادیر خطا و ضریب همبستگی مدل در تکرار محاسباتی ۲۲۰۰۰ شبکه دینامیکی دو فاکتوره

ضریب همبستگی	خطای صحت‌سنجی	خطای آموزشی	آموزش نهایی (تکرار)	تعداد نرون
۰/۷۱۷۳	۰/۰۲۱۶	۰/۱۹۷۴	۲۲۰۰۰	۲-۴-۴-۱

شبکه، دبی همان ماه بهمن پیش‌بینی می‌شد. خصوصیات فنی شبکه طراحی شده در جدول شماره ۸ آمده است.

(د) شبکه ترکیبی: در این شبکه با استفاده از مقدار بارندگی هر ماه و دبی دو ماه قبل به عنوان ورودی شبکه، دبی ماه آینده پیش‌بینی می‌گردد. به عنوان مثال با استفاده از دبی ماه‌های تیر و مرداد به اضافه مقدار بارندگی شهریور ماه، دبی شهریور ماه پیش‌بینی می‌شود. مشخصات فنی شبکه طراحی شده در جدول ۸ قید گردیده است.

(ب) شبکه دینامیکی یک متغیره: در این شبکه با استفاده از دبی یک ماه قبل، دبی ماه آینده پیش‌بینی شد. به عنوان مثال با استفاده از دبی تیر ماه به عنوان ورودی شبکه، دبی ماه مرداد پیش‌بینی شد یا با استفاده از دبی ماه اسفند به عنوان ورودی شبکه، دبی ماه فروردین سال آینده پیش‌بینی می‌شد. در این شبکه R^2 های بدست آمده تقریباً همگی منفی بودند. مشخصات فنی و طراحی شده شبکه اخیر نیز در جدول ۸ نمایش داده شده است.

(ج) شبکه استاتیکی: در این شبکه با استفاده از میزان بارندگی و دمای هر ماه، مقدار دبی متوسط همان ماه پیش‌بینی می‌شود. به عنوان مثال با استفاده از بارندگی و دمای ماه بهمن به عنوان ورودی

(جدول ۵) - مشخصات فنی شبکه‌های پیشنهادی

نوع شبکه	تعداد نرون	آموزش نهایی (تعداد تکرار)	خطای آموزشی	خطای صحت-سنجی	ضریب همبستگی
شبکه دینامیکی ۲ متغیره	۲-۴-۱	۲۲۰۰۰	۰/۱۹۷۴	۰/۰۲۱۶	۰/۷۱۷۳
شبکه دینامیکی ۱ متغیره	۱-۴-۱	۱۷۰۰۰	۰/۴۲۲۰	۰/۰۲۹۵	۰/۵۳۷۷
شبکه استاتیکی	۲-۳-۱-۱	۱۱۰۰۰	۰/۲۴۹۸	۰/۰۲۸۳	۰/۷۰۶۸
شبکه ترکیبی	۳-۲-۴-۱	۴۹۰۰۰	۰/۱۸۶۰	۰/۰۱۸۹	۰/۸۵۳۱

EF و CRM می‌توانند منفی باشند. مقدار ME بدترین حالت عملکرد مدل را نشان می‌دهد در حالیکه مقدار RMSE نشان می‌دهد که پیش‌بینی‌ها تا چه حد، اندازه‌گیری‌ها را بیشتر یا کمتر تخمین زده‌اند. مقدار CD نسبت میان پراکنش مقادیر اندازه‌گیری شده و پیش‌بینی شده را به دست می‌دهد. مقدار EF مقادیر پیش‌بینی شده را با مقادیر میانگین اندازه‌گیری شده مقایسه می‌کند. یک مقدار EF منفی نشان می‌دهد که مقادیر میانگین اندازه‌گیری شده تخمین بهتری نسبت به مقادیر پیش‌بینی شده به دست می‌دهد. CRM اندازه‌گیری گرایش مدل به سمت تخمین اندازه‌گیری بیش از حد یا کمتر از حد است. در CRM منفی نشانگر گرایش به سمت تخمین بیش از حد است. در شرایطی که مقادیر پیش‌بینی و اندازه‌گیری شده با هم برابر باشند (بهترین حالت) مقدار آماره‌ها به ترتیب، $MAPE = 0, CD = 1, EF = 1, ME = 0, RMSE = 0$ و $CRM = 0$ خواهد بود.

نتایج و بحث

مقایسه مدل‌های پیشنهادی

الف) مقایسه کیفی

برای این منظور با استفاده از داده‌های آزمون، مدل‌های هوشمند ترکیبی، استاتیکی، دینامیکی دو فاکتوره و دینامیکی یک فاکتوره اجرا و مقادیر دبی متوسط ماهیانه، پیش‌بینی و با مقادیر مشاهداتی مقایسه گردید. نتایج به صورت شکل‌های ۵، ۶ و ۷ نمایش داده شده است.

آزمون مدل‌های پیشنهادی

در این قسمت از داده‌های ناشناخته (داده‌های آزمون) برای ارزیابی دقت پیش‌بینی مدل‌های پیشنهادی استفاده گردید. برای مقایسه کمی عملکرد مدل‌های پیشنهادی می‌توان از تجزیه و تحلیل خطاهای باقیمانده^۱ و اختلاف بین مقادیر اندازه‌گیری و برآورد شده، بهره گرفت. آماره‌های زیادی برای ارزیابی عملکرد مدل‌ها وجود دارد (همایی^۲). در این پژوهش از جذر میانگین مربعات خطا^۳ (RMSE)، خطای حداکثر^۴ (ME)، راندمان یا کارایی مدل^۵ (EF)، ضریب تغییرات^۶ (CD)، میانگین درصد خطای^۷ (MAPE) و ضریب مجموع باقیمانده^۸ (CRM) برای ارزیابی عملکرد مدل استفاده شد. بیان ریاضی این آماره‌ها بصورت زیر می‌باشد:

که در آن: Q_i^c و Q_i^m : به ترتیب مقدار پیش‌بینی و اندازه‌گیری

شده دبی متوسط ماهیانه، n تعداد ماه‌های اندازه‌گیری، \bar{Q} : مقدار میانگین دبی اندازه‌گیری شده، است.

- 1- Residual error
- 2- Homae
- 3- Root mean square error
- 4- Maximum error
- 5- Modeling efficiency
- 6- Coefficient of variation
- 7- Mean absolute percentage of error
- 8- Coefficient of residual mass

راندمان یا کارایی مدل (EF):

$$EF = \frac{\sum_{i=1}^n (Q_i^m - \bar{Q})^2 - \sum_{i=1}^n (Q_i^c - Q_i^m)^2}{\sum_{i=1}^n (Q_i^m - \bar{Q})^2} \quad (۴)$$

ضریب تعیین (CD):

$$CD = \frac{\sum_{i=1}^n (Q_i^c - \bar{Q})^2}{\sum_{i=1}^n (Q_i^m - \bar{Q})^2} \quad (۶)$$

ضریب مجموع باقیمانده (CRM):

$$CRM = \frac{\sum_{i=1}^n Q_i^c - \sum_{i=1}^n Q_i^m}{\sum_{i=1}^n Q_i^c} \quad (۸)$$

جذر میانگین مربعات خطا (RMSE):


$$RMSE = \left[\frac{\sum_{i=1}^n (Q_i^c - Q_i^m)^2}{n} \right]^{1/2} \quad (۳)$$

خطای حداکثر (ME):


$$ME = \max |Q_i^c - Q_i^m|_{i=1}^n \quad (۵)$$

میانگین درصد خطا (MAPE):


$$MAPE = \frac{\sum_{i=1}^n \left| \frac{Q_i^c - Q_i^m}{Q_i^m} \right|}{n} \quad (۷)$$



(شکل ۵) - مقادیر دبی مشاهداتی با دبی مدل‌های هوشمند مختلف برای داده‌های آموزشی



(شکل ۶) - مقادیر دبی مشاهداتی با دبی مدل‌های هوشمند مختلف برای داده‌های صحت‌سنجی



(شکل ۷) - مقادیر دبی مشاهداتی با دبی مدل‌های هوشمند مختلف برای داده‌های آزمون

برای این منظور از شاخص‌های آماری برای مقایسه نتایج حاصل از اجرای مدل‌های پیشنهادی استفاده گردید. جزئیات این مقایسه در جدول ۸ آمده است.

مشاهده شکل‌های ۵، ۶ و ۷ نشان می‌دهد که مدل شبکه عصبی دینامیکی - استاتیکی، مقدار دبی متوسط ماهیانه را با دقت بالاتری نسبت به سایر مدل‌ها پیش‌بینی می‌نماید. (ب) مقایسه کمی

(جدول ۶) - مقایسه کمی شاخص‌های آماری مدل‌های طراحی شده

شاخصها	CRM	CD	EF	MAPE	ME	RMSE
بهترین حالت	*	۱	۱	*	*	*
مدل دینامیکی دو پارامتره	۰/۱۸۱۹	۱/۵۷۲۸	۰/۳۷۴۴	۳/۳۸۸۰	۸/۶۶۰۲	۳/۶۱۲۶
مدل دینامیکی یک پارامتره	۰/۴۷۷۷	۱/۹۹۳۵	-۰/۳۶۴۷	۱۱۶/۵۶۹۲	۱۳/۱۴۶۹	۵/۳۳۵۹
مدل استاتیکی	-۱/۸۵۹۱	۰/۶۴۴۵	-۰/۱۱۶۱	۶۷/۷۴۰۲	۱۰/۳۰۶۴	۴/۸۲۵۴
مدل دینامیکی - استاتیکی	۰/۰۱۹۰	۰/۸۱۶۶	۰/۷۵۲۵	۴۴/۰۷۶۳	۷/۹۲۶۸	۲/۲۶۷۸

جدول ۹ نشان می‌دهد که در بیشتر موارد شاخص‌های آماری مرتبط با مدل ترکیبی ارجحیت کاملی نسبت به مدل‌های دیگر دارد و نشان می‌دهد که روش ترکیبی می‌تواند دبی ماهانه را با دقت بهتری پیش‌بینی نماید. برای ارزیابی بیشتر مدل‌های پیشنهادی، مقادیر دبی متوسط ماهیانه پیش‌بینی شده توسط مدل‌های مذکور در مقابل داده‌های مشاهداتی ترسیم و بهترین خط عبوری از میان داده‌ها برآزش داده

شد. مقادیر شیب و ضریب همبستگی بهترین خط عبوری در جدول شماره ۱۰ نشان داده شده است. هر چه مقدار شیب و همبستگی ضریب همبستگی به عدد ۱ نزدیکتر باشد، نتایج حاصل از مدل از دقت بالاتری برخوردار می‌باشد. مشاهده جدول ۸ نشان می‌دهد که مدل ترکیبی نسبت به سایر مدل‌ها مقدار دبی متوسط ماهیانه را با دقت بالاتری پیش‌بینی می‌نماید.

(جدول ۷) - مقایسه شیب و ضریب تبیین چهار مدل دینامیکی دو پارامتره، یک پارامتره، استاتیکی و دینامیکی - استاتیکی

شیب	ضریب تبیین	
۱/۰۶۰۴	۰/۷۷۴۰	مدل دینامیکی دو متغیره
۱/۱۹۸۳	۰/۳۹۴۷	مدل دینامیکی یک متغیره
۰/۳۹۴۱	۰/۴۰۱۱	مدل استاتیکی
۰/۸۶۶۸	۰/۸۵۵۲	مدل دینامیکی - استاتیکی

نتیجه گیری

ارزیابی دقت پیش بینی و عملکرد مدل‌های پیشنهادی، با استفاده از داده‌های آزمون، مدل اجرا و مقادیر دبی متوسط ماهیانه پیش بینی و با مقادیر مشاهداتی مقایسه گردید نتایج حاصل از تحقیق نشان داد که مدل شبکه عصبی مصنوعی بر مبنای سری زمانی مقدار آورد میانگین ماهانه جریان ورودی به سد وحدت سنندج را با دقت بالایی پیش‌بینی می‌نماید. نتایج همچنین نشان داد که مدل شبکه عصبی دینامیکی - استاتیکی با کارایی بالاتری نسبت به سایر مدل‌های هوشمند دیگر می‌تواند فرایند بارش - رواناب در حوزه قشلاق را مدلسازی نماید.

در این تحقیق مدل‌های شبکه عصبی دینامیکی، استاتیکی و ترکیبی برای مدلسازی هوشمند فرایند بارش - رواناب و پیش بینی آورد متوسط ماهانه ورودی به سد وحدت سنندج بسط و توسعه داده شد. بدین منظور ابتدا داده‌های آماری موجود به سه دسته آموزش، صحت سنجی و آزمون تقسیم بندی و از آنها جهت معماری و آموزش نهایی شبکه‌های مذکور استفاده گردید. معماری و طراحی اجزای فنی شبکه‌ها بر پایه روش اعتبار دهی مقطعی^۱ و قانون یادگیری *Quick Prop* برای انتخاب اجزا مناسب شبکه استفاده به عمل آمد. در ادامه با شناسایی اجزای فنی مناسب، آموزش نهایی مدل صورت گرفت. جهت

منابع

- ۱- اسلامیان، س. و گوهری، ع. ۱۳۸۶. پیش‌بینی جریان کم با استفاده از تحلیل سری زمانی. ششمین کنفرانس هیدرولیک ایران، دانشگاه شهرکرد. ص ۴۷۳-۴۸۷.
- ۲- رادمان، ر.، علیمحمدی، س. و جباری، ا. ۱۳۸۲. مقایسه مدل‌های کلاسیک و شبکه‌های عصبی مصنوعی در پیش‌بینی جریان رودخانه. اولین کنفرانس سالانه مدیریت منابع آب ایران. ص ۳۱۰-۳۱۷.
- ۳- رجایی، ط.، میرباقری، س. ا.، بوداچیور، س. و کرمانی، م. استفاده از شبکه عصبی جهت مدل نمودن سری زمانی غیرخطی بار معلق رودخانه‌ها. ششمین کنفرانس هیدرولیک ایران، دانشگاه شهرکرد: ص ۳۶۵-۳۷۳.
- ۴- محمدی، ی. ۱۳۸۶، تخمین هوشمند دبی متوسط ماهیانه با استفاده از شبکه عصبی مصنوعی در حوزه آبریز قشلاق سنندج، پایان نامه کارشناسی ارشد رشته آبخیزداری دانشگاه گرگان، ۱۲۶ صفحه.
- 5- Anamal, J., Zhang, B. Govindaraju. R.S. 2000. Comparison o Ann's and empirical approaches predicting watershed runoff, j. of Water Resources Planning and Management, 126(3):56-66.
- 6- Antil, F., Michel, C., Perrin, C., and Andrassian, V. 2004. A soil moisture index as an auxiliary ANN input for streamflow forecasting, J.Hydrol., 286(1): 155-167.
- 7- Antil, F., C.H.Perrin and Andreassian. V. 2003. Impact of the length of observed records on the performance of ANN and of conceptual parsimonious rainfall-runoff forecasting models. Environmental Modeling & Software, 19: 357-368.
- 8- ASCE Task Committee on application of artificial neural networks in hydrology. 2000. artificial neural networks in hydrology, II-ydrologic applications, J.Hydrol.Eng., 5(2): 124-137.
- 9- Atiya, A. and etal.1999. A comparison between Neural network forecasting Techniques-Case study: River flow forecasting, IEEE Transactions on Neural Network, 10(2):145-154.
- 10- Coulibali, P. Antil, F. and Bobee. 2000. Daily Reservoir Inflow Forecasting Using Artificial Neural Network With Stopped Training Approach. Journal of Hydrology, 230: 244-257.
- 11- EIA, 2004. Energy Information Administration. http://www.eia.doe.gov/emeu/world/country/cntry_NO.html. Accessed September 2004.
- 12- French MN, Krajewski WF, Cuykendall RR, 1992. Rainfall forecasting in space and time using a neural network . Journal of Hydrology, 137: 1-31.
- 13- Homae, M., Dirksen, C., and Feddes, R.A. 2002. Simulation of root water uptake I.non-unifprm transient salinity using different macroscopic reduction function. Agricultural Water Management 57: 89-109.
- 14- Hsu, K.L., Gupta, H.V., and Sorooshian, S. 1995. Artificial neural network modeling of rainfall-runoff process, Water Resource Research, 31(10): 2517-2530.
- 15- Jain, A., and Srinivasulu, S. 2004. Development of effective and efficient rainfall-runoff models using integration deterministic, real-coded genetic algorithms and artificial neural network techniques, Water Resource Research, 40: 4-10

- 16- Jain, S.K., Das, A., and Srivastava, D.K, 1999. Application of ANN for Reservoir Inflow Prediction and operation". *Journal of Water Resource Planning and Management*, ASCE, 125(5): 263-271.
- 17- Jang, J., Sun, S. R. and Mizutani, C. T. E. 1997: *Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence*, prentice Hall, upper Saddle River, NJ.
- 18- Kumar, M., Raghuwanshi, N.S., Singh, R., Wallender, W.W. and Pruitt, W.O., 2002. Estimating evapotranspiration using artificial neural network. *Journal of Irrigation and Drainage Engineering*, 28(4): 224-233.
- 19- Lorrai, M. and Sechi, H.M. 1995. Neural nets for modeling rainfall-runoff transformations. *Water Resources Management*, 9(4): 299-313.
- 20- Minns, A.W. and M.J. Hall. 1996. Artificial neural network as rainfall-runoff models. *Hydrological Sciences Journal*, 41(3): 399-417.
- 21- Nazemi, A., poorkhadem, H., Mohammad, R., Akbarzadeh, T., and Hosseini, M. 2003. Evolutionary neural network modeling for describing rainfall–runoff process. *Hydrology Days*. 224–235pp.
- 22- Nilsson, P., Uvo, C.B., and Berndtsson, R. 2005. Monthly runoff simulation: Comparing and combining conceptual and neural network models. *Journal of Hydrology*.321(1/4):344-363.
- 23- Rajurkar, M.P., Kothyari, U.C., and Chaube, U.C. 2004. Modelling of the daily rainfall-runoff relationship with artificial neural network, *Journal of Hydrology*. 285(1/4): 96-113.
- 24- Salas, J.D., Markus, M., and Tokar, A.S. 2000. Streamflow forecasting based on artificial neural networks. In: Govindaraju, R.S., Ramachandra Roa, A. (Eds), *artificial neural network in Hydrology*. Kluwer Academic Publishers, pp. 23-51.
- 25- Srinivasa raju, K., Nagesh kumar, D., and Duckstein, L. 2006. Artificial neural networks and multicriterion analysis for sustainable irrigation planning. *Computers and operations research* 33: 138–1153.
- 26- Tokar, A.S. and Johnson. A. 1999. Rainfall-runoff modeling using artificial neural networks. *Journal of Hydrology Engineering*, 4(3): 232-239.
- 27- Zhang, B., and Govindaruja, R.S., 2000. Prediction of watershed runoff using Bayesian concepts and modular neural networks. *Water Resources Research*, 36 (3): 753-762.



Intelligent Modeling of Monthly flow Time Series into Vahdat dam in sanandaj city

P. Fathi^{1*} - Y. Mohamadi² - M. Homaei³

Abstract

Prediction of input flow into water resources is regarded as one of the most important issues in optimum planning and management in producing electro-water energy and optimum allocation of water into different consumption sources. Different parameters affect on input discharge into dams. Climate variables including temperature and rainfall have the most effect on input runoff rate to water resource in dry and semi-dry regions like Iran. A suitable monthly runoff-rainfall model is a strong tool to consider the climate changes effect on accessibility of water to produce electro-water energy. The investigations have shown that the relation between runoff rate and effective variables is non-linear and complicated. Artificial Neural Networks due to their unique properties have a tremendous capability in non-linear relations simulation. Artificial Neural Networks establish a great change in analyzing dynamic systems behavior in different water-science engineering. In this paper it has been attempted to design static network to recover the non-linear relations between dependant and independent variables, so that the intelligent discharge estimation of average monthly input to Vahdat dam can be done by its help. In addition, by designing and extension of dynamic neural network model based on times series performance, the amount of the monthly input discharge to the dam was predicted. Considering the capability of Artificial Neural Networks, these networks were used for modeling the rivers monthly discharge non-linear time series. Analysis of time series having two major goals; random mechanism understanding or modeling and future series value prediction was done base on previous ones. Also, the performance of the designed models was evaluated by comparing results of the static and dynamic neural network. The results of the investigation showed that there is a good conformity between the predicted values given by combined neural network and observed data. Furthermore, the results showed that the time series dynamic neural network model predict the monthly discharge more accurate than static model.

Keywords: monthly average discharge, Artificial Neural Networks, time series

1- Assistant Professor, Dept. of Water Engineering, University of Kurdistan, Sanandaj 416, Iran. (Corresponding author Email: P.fath@uok.ac.ir)

2- Master of Science in watershed management

3- Associate Professor, Dept. of Soil Science, University of Tarbiat Modares