

تخمین دبی متوسط ماهانه با استفاده از شبکه‌های عصبی مصنوعی مطالعه موردی: آبخیز قشلاق سندج

* یوسف محمدی^۱، پرویز فتحی^۲، علی نجفی نژاد^۳ و نادر نورا^۳

^۱ دانش‌آموخته کارشناسی ارشد گروه آبخیزداری دانشگاه علوم کشاورزی و منابع طبیعی گرگان، ^۲ استادیار گروه مهندسی آب دانشگاه کردستان،

^۳ استادیار گروه آبخیزداری دانشگاه علوم کشاورزی و منابع طبیعی گرگان

تاریخ دریافت: ۸۶/۲/۲۵؛ تاریخ پذیرش: ۸۷/۶/۲

چکیده

پیش‌بینی دقیق مقدار دبی متوسط ماهانه ورودی به منابع آبی نظیر سدها، نقشی اساسی در برنامه‌ریزی، مدیریت و بهره‌برداری بهینه و پایدار آنها ایفا می‌کند. با مشخص شدن مقدار دبی ورودی به سد، می‌توان حجم سالانه آب ورودی به آن را محاسبه کرد و برای تخصیص بهینه آب به بخش‌های مختلف مصرف نظیر آب آشامیدنی، کشاورزی، تولید انرژی برق-آبی و... به خوبی برنامه‌ریزی کرد. پارامترهای مختلفی بر میزان دبی ورودی به سد تأثیرگذار هستند. این پارامترها کاملاً شناخته شده نبوده، ارتباط آنها با دبی ورودی پیچیده و غیرخطی است. بنابراین ارائه رابطه تحلیلی و ریاضی از این ارتباط، مشکل و غیرعملی است. شبکه‌های عصبی مصنوعی به علت خصوصیات منحصربه‌فرد خود دارای قابلیت بالایی در شبیه‌سازی روابط غیرخطی و پیچیده می‌باشند. در این تحقیق سعی شده است با تبیین ویژگی‌های شبکه عصبی مصنوعی، شبکه از نوع پرسپترون^۱ چند لایه با قانون یادگیری پس انتشار خطا برای بازبانی ارتباط غیرخطی مابین متغیرهای مستقل و وابسته طراحی گردد تا به کمک آن تخمین هوشمند دبی متوسط ماهانه ورودی به سد قشلاق میسر گردد. با مقایسه نتایج حاصل از مدل شبکه عصبی و روش تجربی خوسلا، عملکرد مدل پیشنهادی ارزیابی و سنجیده شد. نتایج حاصل از تحقیق نشان داد که انطباق قابل قبولی مابین مقادیر پیش‌بینی شده با شبکه عصبی مصنوعی و داده‌های مشاهداتی وجود دارد. نتایج همچنین نشان داد که مدل شبکه عصبی پیشنهادی و روش خوسلا به ترتیب با حداقل خطای میانگین مربعات خطا ($RMSE$) ۱/۴۹ و ۱۱/۸۸، مقدار دبی متوسط ماهانه را پیش‌بینی می‌نماید.

واژه‌های کلیدی: حوضه آبخیز قشلاق، دبی متوسط ماهانه، شبکه عصبی مصنوعی، پرسپترون چند لایه

مقدمه

از نظر میزان فرسایش و رسوب‌گذاری پیش از هر فرآیند دیگر نظر هیدرولوژیست‌ها را به خود جلب نموده است. این دو فرآیند در محدوده مکان و زمان، بیشترین تغییرات را داشته و شبیه‌سازی آنها به لحاظ

فرآیند بارندگی - رواناب به لحاظ اهمیت آن در مدیریت آبخیزداری حوضه‌ها، بهره‌برداری از مخازن سدها، سیستم‌های هشدار سیل، اولویت‌بندی حوضه‌ها

* - مسئول مکاتبه: y_abidar21@yahoo.com

سرشت غیرخطی و ابعاد زیاد همواره با مشکلات ع دیده‌ای همراه بوده است. استفاده از شبیه‌سازها، مدل‌های فیزیکی، مدل‌های ریاضی، توزیع‌های آماری و برنامه‌های کامپیوتری از مواردی است که برای پیش‌بینی پدیده‌ها استفاده می‌گردد (رضایی، ۲۰۰۴). امروزه، به‌کارگیری و ترکیب روش‌های هوشمند همچون شبکه‌های عصبی مصنوعی^۱، سیستم‌های منطق فازی^۲ و الگوریتم‌های ژنتیکی^۳ برای کنترل سیستم‌ها بسیار مورد توجه قرار گرفته است. مزیت عمده این روش‌ها، امکان بهره‌گیری از قابلیت یادگیری است (آنکتیل و همکاران، ۲۰۰۳).

شبکه عصبی مصنوعی از جمله مدل‌های شبیه‌سازی است که می‌تواند با دقت مناسبی واقعیات موجود را به تصویر بکشد و پیش‌بینی آن به واقعیت نزدیک‌تر باشد. اساس کار شبکه عصبی مصنوعی مثل مغز انسان است که با تجزیه و تحلیل شرایط و محدودیت‌ها و پارامترهای دخیل در یک فرآیند، تصمیم بهینه را اتخاذ می‌کند و این فرآیند را به‌حدی تکرار می‌کند که ضرایب هر یک از پارامترها بهینه شده، با واقعیت موضوع تطابق بسیار نزدیکی پیدا کند (رضایی، ۲۰۰۴). بنابراین امروزه از این شبکه‌ها به‌صورت گسترده‌ای برای فرآیندهای مختلف مرتبط با علوم مهندسی آب از قبیل روابط بارش- رواناب، پیش‌بینی هیدروگراف یا آب‌نمود سیل و... استفاده می‌شود (حسینی، ۱۹۹۹؛ سلطانی، ۲۰۰۲؛ میثاقی و محمدی، ۲۰۰۲؛ رادمان و همکاران، ۲۰۰۳؛ نظرنژاد و قربانی، ۲۰۰۵؛ مساعدی و هاشمی‌نجفی، ۲۰۰۵؛ دهقانی و همکاران، ۲۰۰۶؛ اسمیت و الی، ۱۹۹۵؛ سو و همکاران، ۱۹۹۵؛ تاکر و جانسون، ۱۹۹۹؛ تاکر و مارکوس، ۲۰۰۰؛ آنامال و همکاران، ۲۰۰۰؛ بریکونداوی و همکاران، ۲۰۰۲؛ کاستلانومندز و همکاران، ۲۰۰۴؛ دیمیتیری و همکاران، ۲۰۰۴؛ نیلسون و همکاران، ۲۰۰۵؛ دووس و رینت جز، ۲۰۰۵؛ باتاچاریا و سولوماتین، ۲۰۰۶؛ جانین و اسرینیواسولو، ۲۰۰۶ و دولاکشی و همکاران، ۲۰۰۶).

وجود روابط غیرخطی مابین عوامل مؤثر بر پدیده‌های مختلف هیدرولوژیکی آنچه که بر اهمیت موضوع می‌افزاید. مدل شبکه عصبی مصنوعی توانایی لازم را برای تطابق خود با این روابط غیرخطی دارد (کونرادز و روهمی، ۱۹۹۹). مهم‌ترین موضوع در مورد این مدل‌ها انتخاب ورودی‌های مناسب با مدل برای رسیدن به آن ویژگی مطلوب به‌منظور اخذ خروجی‌های مورد نظر است (آتیا و اتال، ۱۹۹۹). این تحقیق به مدلی نیاز دارد که بتواند ویژگی‌های مهم سیستم‌های عصبی را به‌منظور بروز رفتار مشابه کسب کند. اگر بخواهیم این مدل فهمیدن و به‌کارگیری ساده باشد، باید بسیاری از جزئیات عمداً نادیده گرفته شود. در پی تحقیقات گذشته، در پژوهش حاضر نیز سعی بر آن است گامی هر چند کوچک برای کاربرد بیشتر این روش برای پیش‌بینی دقیق‌تر مقادیر رواناب خروجی از حوضه آبریز برداشته شود. طبق تحقیقات صورت گرفته در مدل‌سازی بارش- رواناب، تنها از مقدار بارش برای پیش‌بینی دبی استفاده شده و تاکید شده است که این تنها پارامتر تأثیرگذار است (لورای و سچی، ۱۹۹۵). در این تحقیق برای بررسی بیشتر موضوع، علاوه بر بارش ماهانه، تأثیر دمای ماهانه و زمان وقوع بارش هم در نظر گرفته شده است و مدل به‌دست آمده خاص حوضه مورد مطالعه است، در نتیجه تأثیر پارامترهای دیگر مثل خصوصیات حوضه را می‌توان ثابت فرض نمود. منظور از زمان وقوع بارش، شماره ماه مورد نظر در طول سال است. مثلاً برای ماه‌های مهر و شهریور زمان وقوع بارش به‌ترتیب برابر ۱ و ۱۲ می‌باشد. هدف از این تحقیق طراحی و بسط مدل شبکه عصبی برای پیش‌بینی دبی خروجی حوضه، ارزیابی دقت مدل، مقایسه نتایج حاصل از مدل پیشنهادی با مدل تجربی خوسلا و بررسی تأثیر پارامترهای ورودی بر دقت پیش‌بینی مدل می‌باشد.

- 1- Artificial Neural Network (ANN)
- 2- Fuzzy Logic System
- 3- Genetic Algorithm

مواد و روش‌ها

موقعیت جغرافیایی حوضه مورد مطالعه: محل پروژه قشلاق در استان کردستان واقع در شمال غربی ایران و در فاصله ۱۲ کیلومتری شمال شهر سنندج می‌باشد. محدوده مورد مطالعه، بخشی از حوضه آبریز سیروان با مساحتی در حدود ۱۰۵ هزار هکتار می‌باشد، که ۳/۸ درصد سطح استان را در بر می‌گیرد. حوضه مورد مطالعه از شمال با حوضه رودخانه سفیدرود و از سمت شرق با حوضه رودخانه گاو رود هم مرز می‌باشد. در سمت جنوب، رودخانه خروجی این حوضه پس از پیوستن به رودخانه گاو رود رودخانه سیروان را تشکیل می‌دهد و به سمت مرز ایران و عراق جریان یافته، یا در کشور عراق به

رودخانه دجله متصل می‌شود. از سمت غرب نیز این حوضه با حوضه رودخانه سیروان هم مرز است (شکل ۱). این حوضه بین مختصات جغرافیایی "۴۰° ۴۶' ۴۶" تا "۴۳° ۲۰' ۲۰" طول شرقی و "۴۴° ۲۴' ۳۵" تا "۳۵° ۲۳' ۴۳" عرض شمالی واقع شده است. ارتفاع حوضه از رقوم ۱۵۰۰ متر تا ۲۹۰۰ متر متغیر است. رواناب‌های سطحی این حوضه از طریق دو رودخانه اصلی چهل گزی و خلیفه ترخان، وارد دریاچه سد قشلاق می‌شود. تراکم هیدروگرافی آن ۱/۷۲ کیلومتر/کیلومتر مربع می‌باشد. طول بلندترین زهکش منطقه، یعنی، رودخانه قشلاق و رودخانه سیروان، ۱۳۱ کیلومتر و شیب آن نیز در مجموع، حدود ۰/۷ درصد می‌باشد.



شکل ۱- موقعیت حوضه آبخیز قشلاق در ایران و استان کردستان.


شبکه‌های عصبی مصنوعی^۱

شبکه‌های عصبی مصنوعی، ابزار قدرتمندی هستند که با تقلید ساده از سیستم عصبی بیولوژیک انسان ساخته شده است (فلوپ و همکاران، ۱۹۹۸). شبکه‌های عصبی به دو نوع شبکه عصبی مصنوعی و طبیعی تقسیم می‌شوند. تحقیقات در زمینه شبکه‌های عصبی زمانی شروع شد که مغز به‌عنوان یک سیستم دینامیکی با ساختار موازی و پردازشگری کاملاً مغایر با پردازشگرهای متداول شناخته شد. نتایج تحقیقات نشان می‌دهد، با وجود کاربرد روزافزون روش شبکه عصبی در شبیه‌سازی پدیده‌های مختلف هیدرولوژی، استفاده از این روش در مدل‌سازی

پدیده بارش- رواناب در مراحل اولیه توسعه و تکامل است و امروزه به‌عنوان مبحثی مهم مدنظر محققان و پژوهشگران مرتبط با علوم مهندسی آب قرار گرفته است. (آنکتیل و همکاران، ۲۰۰۴؛ جاین و اسرینیواسولو، ۲۰۰۴ و راجورکار و همکاران، ۲۰۰۴)، که به‌دلیل توانایی این ابزار در شبیه‌سازی فرآیندهای بسیار پیچیده و نامعلومی که در علوم مرتبط با آب به وفور یافت می‌شوند، برای محققان و پژوهشگران در زمینه علوم مهندسی آب موضوع مهمی است، به‌طوری‌که زمینه و امکان کاربرد گسترده آنها مهیا شده و در این باره پژوهش‌های بسیاری انجام شده است. ساختار کلی شبکه MLP^۲ در شکل (۲) آمده است (منهاج، ۲۰۰۵).

1- Artificial Neural Network

2- Multi Lager Perceptron



شکل ۲- ساختار کلی شبکه عصبی پرسپترون چند لایه.

قامیش برای بازسازی داده‌های مفقود شده ایستگاه خلیفه ترخان استفاده گردید.

استانداردسازی: اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای اجتناب 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 ادامه این تحقیق از معادله‌های شماره ۱ و ۲ برای نرمال‌سازی داده‌های ورودی به مدل استفاده و نتایج آنها با هم مقایسه گردید:

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

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

که در آن: X_{norm} : مقدار نرمال شده ورودی، \bar{X} : میانگین داده‌ها، X_{max} و X_{min} : به ترتیب مقدار حداکثر و حداقل داده‌ها می‌باشد. مقادیر خطای مطلق آموزشی و صحت‌سنجی مدل پیشنهادی حاصل از دو فرمول یاد شده در جدول ۱ قید گردیده است:

جدول ۱- مقایسه خطاهای آموزش و صحت‌سنجی حاصل از دو فرمول نرمال‌سازی مختلف.

تکرار	خطای آموزش	خطای صحت‌سنجی	فرمول نرمال‌سازی
۱۰۰۰۰	۰/۰۹۶۰	۰/۰۳۹۹	(۱)
۱۴۰۰	۰/۰۴۳۲	۰/۰۷۳۶	(۲)

می‌کند، بنابراین در این تحقیق از این معادله برای نرمال‌سازی داده‌ها استفاده شد.

انتخاب و پیش‌پردازش داده‌ها

انتخاب ایستگاه‌ها: در این تحقیق دو ایستگاه هیدرومتری تونل-چهل‌گری و خلیفه ترخان، ایستگاه تبخیرسنجی سراب قامیش و ایستگاه باران‌سنجی خلیفه ترخان به دلیل طولانی بودن، مستند بودن و مطمئن بودن از کیفیت آمار آنها ایستگاه‌های مرجع، در نظر گرفته شدند. طول دوره آماری مشترک ایستگاه‌ها با توجه به نمودارهای میله‌ای برابر ۱۵ سال (از ۶۷-۶۸ تا ۸۱-۸۲) می‌باشد.

آزمون همگنی: برای داده‌های بارندگی، دما و دبی آزمون همگنی به روش منحنی جرم مضاعف انجام شد، نتایج آزمون نشان داد که چون از نقاط حاصله خطی مستقیم برآش شد داده‌ها از همگنی قابل قبولی برخوردارند.

بازسازی آماری: در این مرحله، به منظور بازسازی نواقص آماری از روش همبستگی بین ایستگاه‌ها استفاده شده است. چون ایستگاه باران‌سنجی خلیفه ترخان در سال (۸۰-۸۱) فاقد آمار بود بنابراین در این سال، از روش همبستگی مابین ایستگاه‌ها برای بازسازی داده ناقص استفاده شد. نتایج نشان می‌دهد که داده‌های ایستگاه خلیفه ترخان و سراب قامیش دارای بالاترین همبستگی و ارتباط می‌باشد. بنابراین در این تحقیق از داده‌های ایستگاه سراب

جدول ۱ نشان می‌دهد که استفاده از معادله ۱ برای نرمال‌سازی داده‌ها، خطای صحت‌سنجی کمتری ایجاد

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

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

مرحله طراحی شبکه

تقسیم‌بندی داده‌ها: مدل‌های شبکه عصبی برای طراحی، نیازمند سه دسته داده آموزشی^۱، صحت‌سنجی^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 (یک‌بار ۸۰ درصد و یک‌بار ۵۰ درصد) از کل داده‌ها برای آموزش شبکه در نظر گرفته شد. بنابراین از مجموع کل ۱۸۰ ماهه (۱۵ سال) داده آماری، یک‌بار ۱۴۴ و بار دوم ۹۰ داده ماهانه برای آموزش شبکه استفاده شد. نتایج، نشان‌دهنده آموزش بهتر شبکه با ۱۴۴ داده ماهانه آماری بود.

ب) داده‌های صحت‌سنجی: یعنی اینکه بخشی از داده‌های موجود، برای کنترل و نظارت بر یادگیری صحیح شبکه استفاده می‌شود. در این تحقیق، درصدهای مختلفی (یک‌بار ۱۰ درصد (۱۸ داده ماهانه آماری) و یک‌بار ۴۰ درصد (۷۲ داده ماهانه آماری)) از کل داده‌ها نیز برای صحت‌سنجی شبکه در نظر گرفته شد.

ج) داده‌های آزمون: در این تحقیق از ۱۰ درصد کل داده‌ها (۱۸ ماه یا ۱/۵ سال) برای ارزیابی عملکرد شبکه پیشنهادی استفاده گردید. نتایج برای دو دسته‌بندی بهینه به صورت جدول ۲ نمایش داده شده است. در نهایت مشاهده شد که اختصاص ۸۰، ۱۰ و ۱۰ درصد کل داده‌ها، به ترتیب برای آموزش، صحت‌سنجی و آزمون مدل، کمترین خطای صحت‌سنجی را به وجود می‌آورد:

روش طراحی: در این مرحله، برای طراحی شبکه عصبی از روش اعتباردهی مقطعی^۴ بهره گرفته شد. در این تحقیق

انتخاب تعداد مناسب نرون‌ها در لایه میانی و تعداد تکرار مطلوب براساس مقایسه شاخص‌های $RMSE$ و R^2 در آزمون ترکیب‌های متفاوت صورت گرفت. در روش *Cross Validation* طراحی شبکه بر مبنای حداکثرسازی کارایی و عملکرد آن صورت می‌گیرد. آموزش، زمانی متوقف می‌شود که خطای صحت‌سنجی به حداقل میزان ممکن کاهش یابد. در این روش، به منظور کاهش بیشتر خطای صحت‌سنجی، داده‌هایی که نسبت به سایر داده‌ها پرت باشند با داده‌های آموزشی جابجا می‌شود. در این روش انتخاب اجزای فنی شبکه، بر مبنای کمترین خطا و بیشترین ضریب همبستگی در مرحله آزمون صورت می‌گیرد.

اولین قدم در معماری یک شبکه، انتخاب قانون یادگیری مناسب می‌باشد که در این پژوهش از قوانین یادگیری *Quick Prop*، *Delta Rule*، *Ext DBD*، *Max Prop*، *Delta Bar De* و *Norm Cum D* استفاده شد و در نهایت مشخص شد که مدل شبکه عصبی با قانون یادگیری *Quick Prop* مقادیر دبی متوسط ماهیانه را با دقت بالاتری پیش‌بینی می‌نماید. بنابراین در این تحقیق، طراحی و معماری شبکه‌های مورد نیاز بر مبنای این قانون صورت می‌گیرد.

در بخش معماری شبکه (انتخاب تعداد لایه مخفی، تعداد نرون و...) ابتدا با در نظر گرفتن یک لایه مخفی، شبکه با تعداد نرون‌های مختلف طراحی شد. نتایج حاصله نشان‌دهنده میزان بالای خطا و عدم آموزش مناسب شبکه بود. در ادامه، با فرض دو لایه مخفی طراحی شد. شبکه عصبی مصنوعی (با تعداد نرون‌های مختلف در لایه اول و دوم) گردید. مشخصات فنی و طراحی شده شبکه منتخب در جدول ۳ نمایش داده شده است.

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


4- Cross Validation

جدول ۳- مشخصات فنی شبکه دو لایه.

تکرار اولیه	تعداد نرون	Transfer	Epoch	ضریب مومنتوم	ضریب یادگیری	آموزش نهایی (تکرار)	مشخصات
۹۰۰	۶-۱	Tan H	۱۶	۰/۲	۰/۲۵	۱۷۰۰۰	مشخصات
۰/۱۹۵۰	۰/۱۹۵۰	۰/۱۹۵۰	۰/۱۹۵۰	۰/۱۹۸۲	۰/۱۹۸۲	۰/۰۷۳۳	خطای آموزشی
۰/۰۴۱۴	۰/۰۴۱۴	۰/۰۴۱۴	۰/۰۴۱۴	۰/۰۴۱۰	۰/۰۴۱۰	۰/۰۲۸۷	خطای صحت‌سنجی

جدول ۴- مقادیر خطا و ضریب همبستگی مدل در تکرار محاسباتی ۱۷۰۰۰.

تکرار نهایی	خطای آموزشی	خطای صحت‌سنجی	ضریب همبستگی
۱۷۰۰۰	۰/۰۷۳۳	۰/۰۲۸۷	۰/۹۵۷۴



شکل ۳- آموزش نهایی شبکه دو لایه.

و اختلاف بین مقادیر اندازه‌گیری و برآورد شده، بهره گرفت. آماره‌های زیادی برای ارزیابی عملکرد مدل‌ها وجود دارد (هومایی و همکاران، ۲۰۰۲). در این پژوهش از جذر میانگین مربعات خطا^۲ (RMSE)، خطای حداکثر^۳ (ME)، راندمان یا کارایی مدل^۴ (EF)، ضریب تعیین^۵ (CD)، میانگین درصد خطای^۶ (MAPE) و ضریب مجموع باقی‌مانده^۷ (CRM) برای ارزیابی عملکرد مدل استفاده شد. بیان ریاضی این آماره‌ها به صورت زیر می‌باشد:

آموزش نهایی شبکه: در این بخش، شبکه طراحی شده برای مقادیر مختلف از تکرارهای محاسباتی تحت آموزش قرار گرفته و مقادیر خطای آموزشی و صحت‌سنجی مدل محاسبه و به صورت شکل ۳ ترسیم گردید.

شکل ۳ نشان می‌دهد که تکراری برابر ۱۷۰۰۰ کمترین خطای صحت‌سنجی را به دست می‌دهد و لذا آموزش شبکه در این مرحله به اتمام می‌رسد. در جدول ۴ مقادیر خطا و ضریب همبستگی مدل در تکرار نهایی ۱۷۰۰۰ قید گردیده است.

آزمون مدل: در این قسمت با استفاده از داده‌های ناشناخته (داده‌های آزمون) برای ارزیابی دقت پیش‌بینی مدل استفاده گردید. برای مقایسه کمی عملکرد مدل‌های پیشنهادی، می‌توان از تجزیه و تحلیل خطاهای باقی‌مانده^۱

- 2- Root Mean Square Error
- 3- Maximum Error
- 4- Modeling Efficiency
- 5- Coefficient of Determination
- 6- Mean Absolute Percentage of Error
- 7- Coefficient of Residual Mass

- 1- Residual Error

اندازه‌گیری، \bar{Q} : مقدار میانگین دبی اندازه‌گیری شده، است.

روش تجربی خوسلا^۱: با توجه به اینکه رواناب را می‌توان به صورت بارش منهای تبخیر تعرق در نظر گرفت و با نظر به اینکه مقادیر تبخیر تعرق تا حد زیادی به دما وابسته است، اغلب، دما در ارتباطات بارش- رواناب پارامتر مهمی در نظر گرفته می‌شود (باجلان و همکاران، ۲۰۰۵). براساس این فرض که دمای میانگین می‌تواند تمام فاکتورهای مؤثر در تلفات را در خود داشته باشد، خوسلا معادله زیر را برای رواناب ماهانه پیشنهاد نمود:

$$R_m = P_m - L_m \quad \& \quad R_m \geq 0 \quad (9)$$

که در آن: P_m : بارندگی در ماه m ام برحسب میلی‌متر، R_m : رواناب در ماه m ام برحسب میلی‌متر، L_m : تلفات در ماه m ام برحسب میلی‌متر، که به صورت زیر محاسبه می‌شود: اگر $T_m > 4.5$ باشد در این صورت از معادله $L_m = 5T_m$ برای محاسبه L_m استفاده می‌گردد. در غیر این صورت ($T_m < 4.5$) با توجه به جدول (۵) مقدار L_m استخراج می‌گردد.

$T_m (C)$	۱۸-	۱۲-	۷-	۱-	۵/۴
$L_m (mm)$	۱۰	۱۲/۵	۱۵	۱۸	۲۱

(۳) جذر میانگین مربعات خطا (RMSE):

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

(۴) راندمان یا کارایی مدل (EF):

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

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

$$CD = \frac{\sum_{i=1}^n (Q_i^c - \bar{Q})^2}{\sum_{i=1}^n (Q_i^m - \bar{Q})^2} \quad (6) \quad \text{ضریب تعیین (CD)}$$

(۷) میانگین درصد خطا (MAPE):

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

(۸) ضریب مجموع باقی مانده (CRM):

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

که در آن: Q_i^m و Q_i^c : به ترتیب مقدار پیش‌بینی و اندازه‌گیری شده دبی متوسط ماهیانه، n : تعداد ماه‌های

جدول ۵- میزان تلفات (L_m) در روش خوسلا.

آنالیز حساسیت^۱: فرآیند آنالیز حساسیت اطلاعات

ارزشمندی درباره میزان حساسیت مدل به متغیرهای ورودی به آن را در اختیار طراح و معمار مدل قرار می‌دهد. با شناسایی میزان تأثیر متغیرهای ورودی بر دقت پیش‌بینی مدل، می‌توان متغیرهای کم‌اثر را از شبکه حذف و مدل ساده‌تری را بسط و توسعه داد. در این تحقیق برای انجام آنالیز حساسیت مدل از ضریب بدون بعد حساسیت^۱ (هیل، ۱۹۹۸) به شکل زیر استفاده

گردید:

$$SS_{ij} = \left(\frac{\delta \hat{y}_i}{\delta \beta_j} \right) \beta_j \quad (10)$$

که در آن B_j بیانگر J امین متغیر ورودی به مدل و y_i خروجی مدل (دبی متوسط ماهانه) است.

$$\delta \beta_j = 0.1 \cdot \beta_j \quad (11)$$

معادله ۱۰ بیانگر میزان حساسیت مدل نسبت به پارامتر

CSS متغیرهای مختلف، از مقدار نسبی CSS به نام ضریب حساسیت نسبی (γ) به شکل زیر استفاده گردید.

$$\gamma_i = \frac{CSS_i}{\max(CSS)} \quad (13)$$

که در آن $\max(CSS)$ حداکثر مقدار CSS برای همه متغیرهای ورودی به مدل مورد نظر می‌باشد. حداکثر مقدار γ برابر واحد بوده و مربوط به پارامتری است که دارای حداکثر CSS می‌باشد.


نتایج و بحث

مقایسه نتایج مدل پیشنهادی با روش تجربی خوسلا مقایسه کیفی: به این منظور با استفاده از مدل پیشنهادی، مقادیر دبی متوسط ماهیانه پیش‌بینی و با مقادیر مشاهداتی و مقادیر حاصل از روش تجربی خوسلا مقایسه گردید. نتایج به صورت شکل‌های ۴ و ۵ نمایش داده شده است.


B_j در داده مشاهده‌ای J رام می‌باشد. δB_j نیز ورودی تغییر یافته است که از رابطه ۱۱ محاسبه می‌شود (در این تحقیق ورودی‌ها ۱۰ درصد تغییر یافتند). این مراحل برای تک‌تک ورودی‌ها انجام می‌شود، به عبارتی هر بار یکی از ورودی‌ها را ۱۰ درصد تغییر داده، دو ورودی دیگر ثابت در نظر گرفته می‌شود. برای محاسبه حساسیت مدل برای تمامی مشاهدات از ضریب حساسیت مرکب^۱ (CSS) استفاده گردید. (هیل، ۱۹۹۲ و آندرمین و همکاران، ۱۹۹۶) مقدار این ضریب برای پارامتر J رام را به شکل زیر تعریف کردند:

$$CSS_i = \left(\frac{1}{N} \sum_{j=1}^N SS_{ij}^2 \right)^{\frac{1}{2}} \quad (12)$$

که رابطه ۱۲ در واقع میانگین ضریب حساسیت هر کدام از ورودی‌ها می‌باشد. برای مقایسه ساده‌تر مقادیر



شکل ۴- مقایسه مقادیر دبی محاسبه شده توسط شبکه عصبی با روش تجربی خوسلا برای داده‌های صحت‌سنجی.



شکل ۵- مقایسه مقادیر دبی محاسبه شده توسط شبکه عصبی با روش تجربی خوسلا برای داده‌های آزمون.

مشاهده شکل های ۴ و ۵ نشان می دهد که چون انطباق قابل قبولی بین داده های مشاهداتی و شبکه عصبی وجود دارد، مدل پیشنهادی، مقدار دبی متوسط ماهیانه را با دقت بالاتری نسبت به روش تجربی خوسلا پیش بینی می نماید. **مقایسه کمی:** پس از طراحی شبکه های عصبی مصنوعی با روشی که پیش تر بیان شد، به منظور ارزیابی و مقایسه


عملکرد این شبکه ها با یکدیگر، کلیه شبکه ها با دسته سومی از داده ها، تحت عنوان داده های تست که حاوی داده های ناشناخته برای شبکه ها بود ارزیابی شدند، سپس مقادیر خروجی از هر شبکه با مقادیر متناظر آن که با رابطه خوسلا به دست آمده بود، مقایسه شد، جزئیات این مقایسه در جدول های ۶ و ۷ آمده است.

جدول ۶- مقایسه شیب و ضریب همبستگی دو مدل پیشنهادی و خوسلا.

شیب	ضریب همبستگی	
۰/۹۶	۰/۹۱	مدل شبکه عصبی
۱/۱۸	-۰/۳۴	خوسلا

جدول ۷- مقایسه کمی شاخص های آماری مدل طراحی شده با روش تجربی خوسلا.

CRM	CD	EF	MAPE	ME	RMSE	شاخص ها
						روش ها
۰	۱	۱	۰	۰	۰	بهترین حالت
-۰/۱۱	۱/۱	۰/۸۵	۵/۵۳	۲/۹۵	۱/۴۹	روش شبکه عصبی
-۱/۸۱	۰/۱۶	-۴/۸۱	۳۳/۹۳	۲۸/۲۴	۱۱/۸۸	روش خوسلا



شکل ۶- مقادیر ضریب نسبی حساسیت مدل به متغیرهای ورودی آن.

روش شبکه عصبی، می تواند دبی ماهانه را با تخمین بهتری پیش بینی نماید.

آنالیز حساسیت: در این مرحله فرآیند آنالیز حساسیت مدل نسبت به متغیرهای ورودی آن انجام و مقادیر ضریب حساسیت نسبی متغیرها محاسبه شد. نتایج به صورت شکل ۶ نمایش داده شده است:

شکل ۶ نشان دهنده این مطلب است که بارندگی و دما به ترتیب بیشترین و کمترین تأثیر را بر دقت پیش بینی مدل

جدول های ۶ و ۷ نشان می دهد، به دلیل بالا بودن ضریب همبستگی و نزدیک بودن مقادیر شاخص های آماری به کار گرفته شده نسبت به حالت های بهینه، روش شبکه عصبی از جواب قابل قبولی در حوضه مطالعه برخوردار می باشد. همچنین در تمام موارد شاخص های آماری مرتبط با مدل شبکه عصبی ارجحیت محسوسی نسبت به روش تجربی خوسلا دارد و نشان می دهد که

آموزش، صحت‌سنجی و آزمون، تقسیم‌بندی شد و از آنها برای معماری و آموزش نهایی شبکه استفاده گردید. معماری و طراحی اجزای فنی شبکه بر پایه روش *Cross Validation* صورت گرفت. همچنین از قوانین یادگیری مختلف برای انتخاب اجزای مناسب شبکه استفاده شد. در ادامه، با شناسایی اجزای فنی مناسب مدل، آموزش نهایی مدل صورت گرفت. برای ارزیابی دقت پیش‌بینی و عملکرد مدل پیشنهادی، با استفاده از داده‌های آزمون، مدل اجرا و مقادیر دبی متوسط ماهیانه پیش‌بینی و با مقادیر مشاهداتی مقایسه گردید. برای ارزیابی بیشتر، نتایج مدل پیشنهادی با نتایج مدل تجربی خوسلا مقایسه شد. در نهایت با انجام فرآیند آنالیز حساسیت میزان تأثیر متغیرهای ورودی بر عملکرد مدل پیشنهادی مطالعه و بررسی شد. نتیجه نهایی از این تحقیق مویید این مطلب است که مدل شبکه عصبی با کارایی بالاتری نسبت به روش‌های معمول می‌تواند فرآیند بارش- رواناب در حوضه قشلاق را مدل‌سازی نماید. این نتیجه با نتایج حاصل از تحقیقات صورت گرفته توسط محققین دیگر در مناطق مختلف دنیا مطابقت دارد.

شبکه عصبی دارا است. مطابق تحقیقات هیل (۱۹۹۸)، اگر مقدار ضریب نسبی حساسیت یک متغیر کمتر از ۰/۱ باشد، آن متغیر، تأثیر معنی‌داری بر دقت پیش‌بینی مدل ندارد، بنابراین می‌توان آن را از مجموعه متغیرهای ورودی حذف نمود. چون در این تحقیق، مقدار ضریب یاد شده برای تمامی متغیرها بزرگ‌تر از آستانه ۰/۱ می‌باشد بنابراین هیچ‌یک از متغیرهای ورودی، قابل حذف نیست. **جمع‌بندی:** در این تحقیق از روش شبکه عصبی مصنوعی برای مدل‌سازی فرآیند بارش- رواناب و پیش‌بینی دبی متوسط ماهانه ورودی به سد قشلاق استفاده گردید. مطابق مطالعات صورت گرفته در این پژوهش، مدل تجربی خوسلا یکی از مدل‌های ریاضی موجود برای پیش‌بینی رواناب متوسط ماهیانه است. چون در این مدل از متغیرهای دما، بارندگی و به‌طور غیرمستقیم، زمان بارش برای پیش‌بینی رواناب ماهانه استفاده گردیده است و این که مقایسه بایستی در شرایط یکسان صورت گیرد، بنابراین در این تحقیق، بارندگی، دما و زمان بارش به‌عنوان ورودی به مدل مورد نظر انتخاب گردید، به‌عبارتی ورودی‌های دو مدل شبکه عصبی و خوسلا یکسان می‌باشند. ابتدا داده‌های آماری موجود به سه دسته؛

منابع

1. Anamal, J., Zhang, B., and 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.
2. Anctil, F., Perrin, C.H., 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.
3. Anctil, 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.
4. Anderman, E.R., Hill, M.C., and Poeter, E.P. 1996. Two-dimensional advective transport in ground-water flow parameter estimation. Ground Water. 34:1001-1009.
5. Atiya, A., and Et al. 1999. A comparison between Neural network forecasting Techniques-Case study: River flow forecasting, IEEE Transactions on Neural Network, 10(2):145-154.
6. Bajelan, A., Mahmudian Shshtari, M., and Aula pur, M. 2005. Prediction of the monthly run off using Artificial Neural Network and comparison with results of experimental methods at Kassillian watershed, The fifth hydraulic conference of Iran, the engineering faculty of Bahonar of Kerman university.
7. Bhattacharaya, B., and Solomatine, D.P. 2006. Machine learning in sedimentation modeling. Journal of Neural Networks, 19(2): 208-214.
8. Birikundavyi, S., Labib, R., Trung, H.T., and Rousselle, J., 2002. Performance of neural networks in daily streamflow Forecasting. J.Hydrol.Eng., ASCE 7(5): 392-398.
9. Castellano-Mendez, M., Gonzalez-Mantegia, W., and Lozano-Calderon, R. 2004. Modelling of the monthly and daily behaviour of the runoff of the Xallas river using Box-Jenkins and neural networks methods. J. Hydrol. 296: 38-58.
10. Conrads, P.A., and Roehl, E.A. 1999. Comparing physics-based and neural network models for simulating salinity, temperature, and dissolved oxygen in a complex, tidally affected river basin proceeding of the south Carolina environmental conference.

11. Dehghani, A., Salamatian, S., and Ghodsian, M. 2006. Intelligence estimation of river flow discharge using Artificial Neural Network, the first regional conference of optimal operation from water resources of Karun and Zaiandeh Rood basins. Shahre kord university. 938-943 p.
12. DeVos, N.J., and Rientjes, T.H.M. 2005. Constraints of artificial neural networks for rainfall-runoff modeling: trade-offs in hydrological state representation and model evaluation. *Hydrol. Earth Syst. Sci. Discuss.*, 52(3): 397- 413pp.
13. Dimitri, P., Solomatin., and Yunpeng, X. 2004. M5 model trees and neural networks: Application to flood forecasting in the upper reach of the Huai River in China. *J. Hydrol. Eng.*, 1-10.
14. Dulkashi, S. Karunasinghe, K and Shie-Yui Liong. 2006. Chaotic time series prediction with global model: Artificial neural network, *J. Hydrol.*, 323: 92-105.
15. Flup, I.A., Jozsa, J., and Kramer, T. 1998. A Neural network application in estimating wind induced shallow lake motion. *Hydroinformatic*, 98(2):753-757.
16. Hill, M.C. 1992. A computer program (MODFLOWP) for estimating parameters of a transient, three-dimensional, ground-water flow model using nonlinear regression. U.S. Geological Survey Open-File Rep. 91-484, 358. U.S. Geol. Survey, Reston, VA.
17. Hill, M.C. 1998. Methods and guidelines for effective model calibration. U.S. Geological survey Water-Resources Investigations Rep. 98-4005. Available at: <http://water.usgs.gov/software/ucode.html> (modified 4 jan 2002; verified 144 feb. 2003). U.S. Geol. survey, Reston, VA.
18. Hosseini, H. 1999. The Artificial Neural Network model for determination of flood water hydrograph, The M.Sc thesis of civil engineering of Elmo Sanat Iran university. 103 p.
19. Homaei, M., Dirksen, C., and Feddes, R.A. 2002. Simulation of root water uptake I. non-uniform transient salinity using different macroscopic reduction function. *Agricultural Water Management* 57:89-109.
20. Hsu, K.L., Gupta, H.V., and Sorooshian, S. 1995. Artificial neural network modeling of rainfall-runoff process, *Water Resour. Res.*, 31(10): 2517-2530.
21. 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 Resour. Res.*, 40,4.
22. Jain, A., and Srinivasulu, S. 2006. Integrated approach to model decomposed flow hydrograph using artificial neural network and conceptual techniques. *J. Hydrol.* 317(3-4): 291-306.
23. Lorrai, M. and Sechi, H.M. 1995. Neural nets for modeling rainfall-runoff transformations. *Water Resources Management*, 9:4. 299-313.
24. Menhaj, M. 2005. Basis of Artificial Neural Network (Calculative Intelligence), the first volume, publication center of Poly Technic university. 715 p.
25. Misaghi, F., and Mohammadi, K. 2002. Precipitation-run off simulation and channel routing using Artificial Neural Network. Article collection of river engineering eighth international conference. Ahvaz Chamran university. 455-462 p.
26. Mosaedi, A., and Hashemi Najafi, F. 2005. Effectiveness comparison of Artificial Neural Network on sediment rating curve, Article collection of river engineering eighth international conference. Ahvaz Chamran university. 801-805P.
27. Nazar Nejad, H., and Ghorbani, M. 2005. Artificial Neural Network application in prediction river maximum discharge. Article collection of watershed management and soil & water resource management second conference. Kerman university. 2223-2230 p.
28. Nilsson, P., Uvo, C.B., and Berndtsson, R. 2005. Monthly runoff simulation: Comparing and combining conceptual and neural network models. *J. Hydrol.* xx. 1-20pp.
29. Radman, R., Alimohammadi, S., and Jabari, E. 2003. Comparison of classic models and Artificial Neural Network in prediction of river flow, the first annual conference of Irans water resources management.
30. Rajurkar, M.P., Kothyari, U.C., and Chaube, U.C. 2004. Modelling of the daily rainfall-runoff relationship with artificial neural network, *J. Hydrol.* 285(1/4): 96-113.
31. Rezaii, E., 2004. Regional modeling of watershed sub-basins peak discharge of Sefid Rood dam using Artificial Neural Network, thesis submitted for P.H.d degree on watershed management engineering, the faculty of Natural Resources in Tehran university.
32. Smith, J., and Eli, R.N. 1995. Neural network models of rainfall-runoff process. *Journal of Water Resources Planning and Management*, 121(6): 499-508.
33. Soltani, S., 2002. Comparison of coceptual models with Artificial Neural Network on simulation of precipitation- run off. Thesis of M.Sc. the agriculture faculty of Tarbiat Modares university. 98 p.
34. Tokar, A.S., and Johnson, A. 1999. Rainfall-runoff modeling using artificial neural networks. *J. Hydrol. Eng.*, 4(3):232-239.
35. Tokar, A.S., and Markus, M. 2000. Precipitation-Runoff modeling using artificiaall neural networks and conceptual models, *J. Hydrol. Eng.* 5(2):156-160.

Estimation of the average monthly discharge using Artificial Neural Network Case study: the Qeshlaq's watershed of Sanandaj

***Y. Mohammadi¹, P. Fathi², A. Najafi Nejad³ and N. Nura³**

¹Former M.Sc. student Dept. of Watershed Management Gorgan University of Agricultural Sciences and Natural Resources, ²Assistant Prof. Dpt. Of water Engineering University of Kurdistan, ³Assistant Prof. Dept. of Watershed Management, Gorgan University of Agricultural Sciences and Natural Resources

Abstract

Precise prediction of monthly average discharge values input to water resources such as dams has a basic role in their planning, management, sustainable and optimal operation. Given the input discharge value to dam, the annual input water volume can be calculated, and well-management for water optimum allocating to various consumption sectors, including edible, agricultural, hydro-electrical production can be scheduled. There are various parameters affecting the input discharge value. They are not fully known, and their relationship with input discharge is non-linear and complex. Thus, giving analytical and mathematical relationship of this concern is difficult and impossible. Artificial Neural Networks, due to their unique properties, have high abilities in non-linear and complex relation simulation. In this study it is attempted to design multi-layer Perceptron with Back Propagation learning rule for recovering the non-linear relationship between dependant and independent variables, so that, using it, prediction of monthly average input discharge to Qeshlaq dam could be done. For further validation of the proposed model, obtained results from neural network model were compared with the ones obtaining from Khosla's empirical method. The results from the study showed that there is an acceptable overlapping between predicted values from Artificial Neural Networks and observed data, as well as the proposed neural network model and Khosla's empirical method predicts the monthly average discharge with root mean square error as 1.49 and 11.88 respectively.

Key words: Qeshlaq's watershed, Monthly Average Discharge, Artificial Neural Networks, Multi-Layer Perceptron.

*- Corresponding Author; Email: y_abidar21@yahoo.com