

تخمین دبی بار معلق رسوب با استفاده از بهترین ساختار شبکه عصبی مصنوعی در حوزه آبخیز طالقان

سمانه رضوی زاده^{۱*}، عطااله کاویان^۱ و مهدی وفاخواه^۲

(تاریخ دریافت: ۱۳۹۱/۰۲/۲۳؛ تاریخ پذیرش: ۱۳۹۱/۰۷/۲۶)

چکیده

پیش‌بینی میزان بار رسوب منتقل شده توسط رودخانه‌ها، یکی از جنبه‌های مهم مدیریت رودخانه‌ها، مخازن سدها و به‌طور کلی پروژه‌های آبی به‌شمار می‌رود. در تحقیق حاضر به‌منظور پیش‌بینی بار معلق رسوب رودخانه طالقان با استفاده از شبکه عصبی مصنوعی و شناسایی شبکه بهینه با بالاترین دقت، از ۵۰۰ داده روزانه متغیرهای دبی روز موردنظر، دبی یک روز قبل، اشل و وضعیت هیدروگراف (به‌ترتیب با میانگین $13/83 \text{ (m}^3/\text{s)}$ ، $15/42 \text{ (m}^3/\text{s)}$ و $89/83 \text{ (cm)}$ و $-0/036$) به‌عنوان ورودی مدل و ۵۰۰ داده روزانه بار معلق رسوب متناظر، به‌عنوان خروجی مدل استفاده شد. داده‌های مورد استفاده مربوط به بازه زمانی ۱۳۸۴-۱۳۶۳، می‌باشد. با ایجاد ترکیب‌های متفاوتی از متغیرهای ورودی و هم‌چنین با تغییر تعداد نرون‌های لایه پنهان و تابع آستانه، ۸۰ شبکه عصبی متفاوت ایجاد شد، که با مقایسه دو پارامتر R^2 و RMSE در مدل‌های مختلف، دقت آنها بررسی شد. نتایج نشان داد که شبکه عصبی با ساختار ۱-۹-۳ و با ترکیب پارامترهای ورودی شامل دبی روز موردنظر، دبی یک روز قبل و اشل، با R^2 و RMSE آزمون، به‌ترتیب ۰/۹۷ و ۰/۰۶۸ دارای بالاترین دقت می‌باشد. براساس نتایج حاصل از شبکه ۱-۹-۳، میانگین داده‌های رسوب مشاهداتی و پیش‌بینی شده توسط مدل بهینه (مربوط به بخش آزمون)، به‌ترتیب $1122/802$ و $1184/924$ (تن در روز) می‌باشد.

واژه‌های کلیدی: رسوب، دبی، وضعیت هیدروگراف، ANN، رودخانه طالقان

۱. گروه آبخیزداری، دانشکده منابع طبیعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری

۲. گروه آبخیزداری، دانشکده منابع طبیعی، دانشگاه تربیت مدرس تهران

*: مسئول مکاتبات، پست الکترونیکی: srazavizade@gmail.com

مقدمه

(Output layer) تشکیل می‌شود و تعداد نرون‌های موجود در لایه ورودی و خروجی با توجه به مسئله موردنظر مشخص می‌شود. البته تعداد لایه‌ها و تعداد نرون‌های موجود در لایه پنهان با نظر طراح و به‌وسیله سعی و خطا مشخص می‌شود (۱۰ و ۱۴). مدل‌های شبکه عصبی مصنوعی در مطالعات هیدرولیکی و هیدرولوژیک مثل انتقال رسوب، مدل‌سازی بارش-رواناب و پیش‌بینی جریان به‌کار برده می‌شوند (۱۷).

دهقانی و همکاران (۱)، به مقایسه تخمین بار معلق رسوب به دو روش منحنی‌سنجه رسوب و شبکه عصبی مصنوعی در رودخانه دوغ استان گلستان پرداختند. آنها از دبی جریان موردنظر، دبی جریان روز قبل و وضعیت هیدروگراف (به لحاظ شاخه صعودی یا نزولی)، به‌عنوان ورودی و دبی بار معلق رسوب به‌عنوان پارامتر خروجی استفاده کردند. نتایج نشان داد که شبکه عصبی مصنوعی با دقت بیشتری نسبت به منحنی‌سنجه رسوب بار معلق رسوب را برآورد می‌کند. هم‌چنین بیان کردند که قرار دادن وضعیت هیدروگراف در پارامترهای ورودی نیز سبب افزایش دقت برآورد شده است.

آگاروال و همکاران (۴)، دبی جریان و بار رسوبی روزانه، هفتگی، ده روزه و ماهانه را با استفاده از شبکه‌های عصبی مصنوعی در یکی از حوضه‌های هندوستان شبیه‌سازی کردند. آنها از شبکه عصبی با الگوریتم پس‌انتشار خطا (Back propagation) استفاده کرده و نتایج را با مقادیر مشاهداتی مقایسه کردند. نتایج نشان داد که شبکه عصبی مصنوعی از دقت بالایی در مدل‌سازی رواناب-رسوب برخوردار است.


مصطفی و همکاران (۱۱)، به مقایسه دقت دو مدل شبکه عصبی مصنوعی RBF و MLFF در برآورد بار معلق رسوب پرداختند. نتایج نشان داد که هر دو مدل از قابلیت مناسبی برخوردار می‌باشند، اما مدل RBF نتایج نسبتاً بهتری را در شبیه‌سازی دبی رسوب معلق ارائه می‌دهد.

راگوانشی و همکاران (۱۲)، با استفاده از شبکه عصبی مصنوعی به پیش‌بینی رواناب و بار رسوبی در یکی از حوزه‌های آبخیز هند پرداختند. نتایج نشان داد

تعیین میزان دقیق بار رسوبی منتقل شده توسط رودخانه‌ها، برای دامنه وسیعی از پروژه‌های آبی حائز اهمیت است. فرسایش و رسوب‌گذاری منجر به اعمال آثار منفی بر شاخص‌های کیفی آب، از دست رفتن خاک، کاهش ظرفیت مخازن سدها و وارد شدن خسارت به تأسیسات رودخانه‌ای می‌شود. در اغلب رودخانه‌ها بخش اعظم رسوبات به‌صورت بار معلق انتقال می‌یابد. برآورد دقیق میزان رسوب در مسائلی از جمله طراحی مخازن، برآورد آلودگی دریاچه، تعیین خسارات ناشی از رسوب‌گذاری به محیط زیست و تعیین تأثیرات مدیریت آبخیز، مورد نیاز است (۳). با توجه به عدم وجود اطلاعات کافی و صحیح از فرسایش، انتقال رسوب و رسوب‌گذاری در رودخانه‌ها و مخازن سدهای ایران و هم‌چنین جوان بودن تحقیقات در این رشته و فقدان اندازه‌گیری‌های دراز مدت رسوب، دسترسی به داده‌های قابل اعتماد رسوب مشکل بوده و لزوم استفاده از روش‌های برآورد و تخمین رسوب را مطرح می‌سازد (۱).

از جمله روش‌های متداول در تخمین دبی رسوب معلق در ایستگاه‌های هیدرومتری، ایجاد ارتباط بین داده‌های دبی رسوب با داده‌های دبی جریان متناظر با آنها می‌باشد که از برآزش منحنی میان مقادیر دبی جریان و رسوب معلق متناظر با آن به‌دست می‌آید. از آنجایی که استفاده از روش‌های منحنی‌های سنجه رسوب همواره با خطای زیادی همراه است لزوم استفاده از روشی هوشمند مانند شبکه عصبی مصنوعی در برآورد مقدار بار معلق رسوب احساس می‌شود (۱).

یکی از روش‌های نوظهور در حل مسائل مهندسی در دو دهه اخیر، استفاده از شبکه‌های عصبی مصنوعی است. در این شبکه‌ها، سعی بر آن است که ساختاری مشابه ساختار بیولوژیک مغز انسان و شبکه اعصاب بدن ساخته شود تا همانند مغز قدرت یادگیری، تعمیم‌دهی و تصمیم‌گیری داشته باشد (۵ و ۹). هر شبکه عصبی مصنوعی از سه نوع لایه به نام‌های لایه ورودی (Input layer)، لایه پنهان (Hidden layer) و لایه خروجی



شکل ۱. نقشه حوزه آبخیز طالقان

ورودی مورد نیاز، در جهت برآورد با دقت بالای دبی رسوب روزانه مورد استفاده قرار گیرد.

مواد و روش‌ها

منطقه مورد مطالعه

حوزه آبخیز طالقان در استان تهران و در ۱۲۰ کیلومتری شمال غربی شهر تهران، در $36^{\circ} 11' 15''$ و $51^{\circ} 11' 22''$ و $50^{\circ} 45' 00''$ و $51^{\circ} 11' 22''$ طول شرقی واقع شده است و یکی از زیر حوضه‌های حوزه آبخیز سفیدرود می باشد. رودخانه طالقان یکی از سرشاخه‌های سفید رود به شمار می رود که در رشته کوه البرز واقع شده است. طالقان رود در پایاب به الموت رود پیوسته و شاهرود را تشکیل می دهد. این رودخانه پس از طی ۷۰ کیلومتر مسافت، به مخزن سد سفید رود می پیوندد. در این مطالعه، از داده‌های مربوط به بازه زمانی ۱۳۸۴-۱۳۶۳ ایستگاه آب‌سنجی گلینک (در نزدیکی ورودی به سد سفیدرود) استفاده شد. طول رودخانه طالقان تا محل ایستگاه گلینک حدود ۳۹ کیلومتر است. موقعیت جغرافیایی رودخانه طالقان و ایستگاه هیدرومتری گلینک در شکل ۱ نشان داده شده است (۲).

روش تحقیق

داده‌های مورد استفاده

در تحقیق حاضر از داده‌های روزانه دبی روز موردنظر، دبی یک روز قبل، اشل و وضعیت هیدروگراف جریان به لحاظ شاخه

که شبکه‌های عصبی مصنوعی از دقت بالاتری نسبت به مدل‌های رگرسیون خطی برخوردار می باشند.

وفاخواه (۱۶)، به مقایسه چهار روش شبکه عصبی مصنوعی، نروفازی، کریجینگ و کوکریجینگ، به منظور تخمین بار معلق رسوب پرداخت. نتایج نشان داد که روش‌های فوق به ترتیب نروفازی، شبکه عصبی، کوکریجینگ و کریجینگ دارای بیشترین و کمترین دقت تخمین بار معلق رسوب می باشند.

بررسی منابع موجود نشان می دهد که در اغلب تحقیقات انجام شده، از شبکه‌های عصبی مصنوعی به عنوان روشی به منظور برآورد رسوب رودخانه استفاده شده و دقت نتایج به دست آمده از آن با روش منحنی سنج رسوب مقایسه شده است. اما در تحقیق حاضر علاوه بر برآورد بار معلق رسوب روزانه در ایستگاه گلینک واقع در رودخانه طالقان با استفاده از شبکه عصبی مصنوعی و بررسی دقت نتایج به دست آمده از آن، شناسایی مدلی از شبکه عصبی مصنوعی مورد توجه بود که با بالاترین دقت به برآورد بار معلق رسوب پردازد. بدین منظور با کاربرد همزمان دو نرم افزار MATLAB و SPSS علاوه بر بررسی میزان اهمیت هر یک از متغیرهای ورودی در ایجاد شبکه، به شناسایی ترکیب بهینه متغیرهای ورودی جهت پیش‌بینی رسوب پرداخته شده است. مدل نهایی انتخاب شده، تحت عنوان مدل بهینه، دارای این قابلیت می باشد که در منطقه مورد مطالعه در روزهای فاقد آمار که داده دبی رسوب اندازه‌گیری نشده است، با ورود داده‌های

جدول ۱. مشخصات آماری داده‌های مورد بررسی اخذ شده از ایستگاه گلینک طالقان

پارامتر آماری	دبی آب در همان روز (مترمکعب بر ثانیه)	دبی آب در یک روز قبل (مترمکعب بر ثانیه)	اشل (سانتی‌متر)	وضعیت هیدروگراف	دبی رسوب در همان روز (تن در روز)
حداکثر	۸۴/۸	۱۱۴/۷۴	۱۹۰	+۱	۳۹۱۶۷/۶۸
حداقل	۱/۹۶	۱/۹۶	۰/۵	-۱	۰/۱۷۶
میانگین	۱۳/۸۳	۱۵/۴۲	۸۹/۸۳	-۰/۰۳۶	۱۵۰۵/۶۷

برای مثال $[۱, -۱]$ ، $[۰/۹, ۰/۱]$ و $[۰, ۱]$. داده‌های ورودی و خروجی در تحقیق حاضر در محدوده $[۰, ۱]$ استاندارد شدند.

$$X_n = \frac{X_i - X_{\max}}{X_{\max} - X_{\min}} \quad [1]$$

در این رابطه X_n معرف داده‌های استاندارد شده، X_i معرف داده‌های مشاهداتی و X_{\max} و X_{\min} به ترتیب معرف داده‌های حداکثر و حداقل می‌باشند (۱۷).

بررسی میزان اهمیت هر یک از داده‌های ورودی به مدل در شبیه‌سازی دبی رسوب

در تحقیق حاضر با هدف تعیین بهترین ساختار مدل و همچنین بهترین ترکیب داده‌های ورودی، به منظور تخمین بار رسوبی با بهترین شبکه عصبی و با بالاترین دقت، طی چندین مرحله به حذف نوبتی هر یک از متغیرهای ورودی پرداخته شد. در هر نوبت با تغییر تعداد نرون‌های لایه پنهان و تابع محرک، به شناسایی شبکه بهینه اقدام شد. در این راستا تعداد چهار شبکه عصبی با ساختار بهینه شناسایی و معرفی شد که هر یک دارای ترکیب متغیرهای ورودی متفاوت می‌باشند.

لذا شبکه اول، شبکه بهینه با چهار ورودی (دبی روز موردنظر، دبی یک روز قبل، اشل و وضعیت هیدروگراف) می‌باشد. در مرحله بعد به منظور ارزیابی نقش وضعیت هیدروگراف، به عنوان ورودی به شبکه در دقت تخمین داده‌های دبی رسوب، این متغیر از میان ورودی‌های شبکه عصبی مصنوعی حذف شد و با سه ورودی (دبی روز موردنظر، دبی یک روز قبل و اشل) مانند مرحله قبل بهترین ساختار شبکه

صعودی و نزولی، به عنوان ورودی‌های مدل و دبی رسوب به عنوان خروجی استفاده شد. داده‌های مذکور شامل ۵۰۰ داده متناظر روزانه دبی، دبی رسوب و اشل می‌باشند که از سازمان تماب تهیه شد. جدول ۱ مشخصات آماری داده‌های موردنظر را نشان می‌دهد.

انتخاب پارامتری به نام وضعیت هیدروگراف بدین جهت است که بتوان اثرات شاخه صعودی و نزولی هیدروگراف را به طوری شبیه‌سازی نمود که سبب شود تا اثر ناپایداری جریان رودخانه نیز در تخمین مقدار دبی رسوب درنظر گرفته شود. برای نمایش وضعیت هیدروگراف سالیانه، پس از رسم هیدروگراف برای هر سال، بر مبنای میزان تغییر ۱۰ درصد نسبت به روز قبل، در حالت افزایشی کد +۱، در حالت کاهش کد -۱ و نیز برای حالت بدون تغییر کد صفر درنظر گرفته می‌شود (۱).

همچنین در مورد داده‌های ورودی به مدل مانند دبی جریان که خروجی مدل (دبی رسوب) با آنها رابطه نزدیکی دارد، تنها استفاده از تأخیر زمانی کوتاه مدت تأثیر مثبتی در افزایش دقت مدل داشته و تأخیرهای بلند مدت، علیرغم افزایش پیچیدگی مدل، دقت برآورد را کاهش می‌دهد (۱۸). بدین منظور دبی جریان با یک روز تأخیر نیز به عنوان ورودی در نظر گرفته شد. داده‌های ورودی و خروجی مدل، از پارامترهای متفاوت با واحدهای متفاوت تشکیل شده‌اند که منجر می‌شود که دارای محدوده عددی بسیار متفاوتی باشند. لذا برای اطمینان از عملکرد یکسان تمام پارامترها در مدل، داده‌ها معمولاً طی فرایند استانداردسازی در محدوده‌های یکسانی قرار می‌گیرند،

سازی شده و دارای یک لایه ورودی، یک لایه پنهان و یک لایه خروجی می‌باشد. لایه ورودی دارای ۴ نرون شامل دبی جریان همان روز، دبی روز قبل، اشل و وضعیت هیدروگراف و لایه خروجی دارای یک نرون، دبی رسوب معلق، می‌باشد. ۶۰ درصد داده‌ها (۳۰۰ داده) به آموزش شبکه، ۱۰ درصد داده‌ها (۱۰۰ داده) به آزمون شبکه و ۱۰ درصد داده‌ها (۱۰۰ داده) به اعتبارسنجی شبکه اختصاص داده شد.

تعداد نرون‌ها در لایه پنهان به روش آزمون و خطا تعیین شد. بدین منظور شبکه‌هایی با تعداد نرون‌های متفاوت در لایه پنهان، ایجاد شدند که تعداد نرون‌ها تا رسیدن به بهترین مدل با حداقل خطا به تدریج افزایش یافت. هم‌چنین تابع‌های محرک مورد استفاده در ایجاد شبکه در لایه پنهان شامل دو تابع تانژانت هایپربولیک و سیگموئید و در لایه خروجی شامل تابع Pure-line بود. توابع ذکر شده در شبکه‌های مختلف به‌همراه تعداد نرون‌های متفاوت در لایه پنهان، آزموده شد. این فرایند نهایتاً منجر شد که بهترین ساختار شبکه به‌همراه تابع محرک مناسب، از میان ۸۰ شبکه عصبی ایجاد شده با ترکیب متفاوت متغیرهای ورودی، تعداد نرون متفاوت در لایه پنهان و توابع محرک متفاوت، شناسایی شود. شکل ۲، ساختار شماتیک یک شبکه عصبی مصنوعی را نشان می‌دهد.

به‌منظور ارزیابی دقت شبکه از دو پارامتر ضریب تعیین (R^2) و جذر میانگین مربعات خطا (RMSE) استفاده شد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i^o - x_i^p)^2} \quad [2]$$

$$R^2 = \left[\frac{\sum_{i=1}^n (x_i^o - \bar{x}^o)(x_i^p - \bar{x}^p)}{\sqrt{\sum_{i=1}^n (x_i^o - \bar{x}^o)^2} \sqrt{\sum_{i=1}^n (x_i^p - \bar{x}^p)^2}} \right] \quad [3]$$

نتایج و بحث

نتایج به‌دست آمده از نرم‌افزار SPSS در تعیین اهمیت هریک از متغیرهای ورودی برای ایجاد شبکه عصبی مصنوعی موردنظر، در شکل ۳ نشان داده شده است. در این شکل محور افقی

به‌همراه تابع محرک مناسب شناسایی شد (شبکه دوم). شبکه سوم، شبکه بهینه با سه ورودی (دبی روز موردنظر، دبی یک روز قبل، وضعیت هیدروگراف) می‌باشد. سپس شبکه چهارم با دو ورودی (دبی جریان در روز موردنظر، دبی جریان در یک روز قبل) به‌عنوان شبکه بهینه با ورودی‌های ذکر شده، معرفی شد. هم‌چنین با استفاده از بخش شبکه عصبی مصنوعی موجود در نرم‌افزار SPSS میزان اهمیت هر یک از متغیرهای ورودی، در ایجاد شبکه تعیین شد.


در پایان به‌منظور شناسایی مدل نهایی با بهترین ترکیب متغیرهای ورودی جهت شبیه‌سازی دبی بار معلق رسوب، دقت شبکه‌های عصبی مصنوعی ذکر شده (شبکه‌های اول، دوم، سوم و چهارم) باهم مقایسه شد.

شبکه عصبی مصنوعی


هر شبکه عصبی مصنوعی از تعدادی واحدهای پردازش اطلاعات به نام نرون تشکیل شده است که در لایه‌های شبکه معرفی می‌شوند. نرون‌های لایه ورودی، داده‌های ورودی را دریافت کرده و به لایه بعدی (لایه پنهان) انتقال می‌دهد. فرایند پردازش داده‌ها تا لایه خروجی ادامه می‌یابد. این نوع شبکه که در آن پردازش داده‌ها در یک جهت (به‌سمت جلو) انجام می‌شود، تحت عنوان شبکه‌های پیشخور (Feed-forward network) شناخته می‌شوند (۱۷).

به‌طورکلی شبکه‌های عصبی مصنوعی براساس جهت انتقال و پردازش داده‌ها به دو دسته شبکه‌های پیشخور و شبکه‌های برگشتی یا پسخور، تقسیم می‌شوند. شبکه‌های پرسپترون چند لایه (MLP) جزء شبکه‌های پیشخور می‌باشند. مطالعات متعدد نشان داده است که شبکه‌های MLP با یک لایه پنهان، دارای توانایی و دقت بالایی در برآورد توابع غیرخطی بوده و به‌صورت گسترده‌ای مورد استفاده قرار می‌گیرند (۸ و ۱۳).

شبکه عصبی مورد استفاده در تحقیق حاضر، شبکه پرسپترون چند لایه و روش آموزش آن پس انتشار خطا می‌باشد. این شبکه با استفاده از نرم‌افزار MATLAB 7.12 شبیه



شکل ۲. ساختار یک مدل شبکه عصبی مصنوعی



شکل ۳. اهمیت داده‌های ورودی به شبکه عصبی مصنوعی در برآورد رسوب

هیدروگراف از داده‌های ورودی مدل (و با در نظر گرفتن سه متغیر ورودی شامل دبی روز مورد نظر، دبی یک روز قبل و اشل) می‌باشد. در این شبکه R^2 و RMSE مربوط به آزمون به ترتیب ۰/۹۷ و ۰/۰۶۸ می‌باشد.

شبکه سوم با ساختار ۱-۵-۳، با ۵ نرون در لایه پنهان و با تابع محرک سیگموئید، بهترین شبکه با حذف متغیر اشل از داده‌های ورودی مدل (و با در نظر گرفتن سه متغیر ورودی شامل دبی روز مورد نظر، دبی یک روز قبل و وضعیت هیدروگراف) می‌باشد. در این شبکه R^2 و RMSE مربوط به آزمون آزمون به ترتیب ۰/۹۶ و ۰/۱۵۲ می‌باشد. شبکه چهارم با ساختار ۱-۷-۲، با ۷ نرون در لایه پنهان و با تابع محرک سیگموئید، بهترین شبکه با حذف دو متغیر اشل و وضعیت هیدروگراف از داده‌های ورودی به مدل (و با در نظر گرفتن دو متغیر ورودی شامل دبی روز مورد نظر، دبی یک روز قبل) می‌باشد. در این شبکه R^2 و RMSE مربوط به آزمون به ترتیب ۰/۹ و ۰/۰۴۶ می‌باشد.

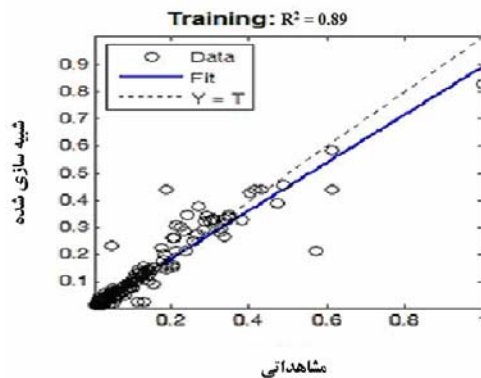
نتایج به دست آمده نشان دهنده توانایی و دقت شبکه عصبی مصنوعی در شبیه‌سازی رسوب معلق بوده که با خطای کم و

پایین نشان دهنده میزان اهمیت هر یک از متغیرها است. این میزان اهمیت در محور افقی بالا به صورت نرمال شده نمایش داده شده است. این شکل در واقع نوعی آنالیز حساسیت متغیرها ورودی در ایجاد شبکه عصبی مورد نظر محسوب می‌شود (۱۵)، که نشان دهنده میزان حساسیت و اهمیت هر یک از متغیرهای ورودی در ایجاد شبکه می‌باشد. بر اساس نتایج به دست آمده متغیر دبی روز قبل (Q_b)، دبی همان روز (Q_a)، وضعیت هیدروگراف (hydrograph) و اشل (H)، به ترتیب دارای بیشترین حساسیت در ایجاد شبکه عصبی مصنوعی می‌باشند. نتایج به دست آمده از چهار شبکه عصبی منتخب مربوط به چهار ترکیب متفاوت از متغیرهای ورودی، به صورت خلاصه در جدول ۲ قابل مشاهده است. نتایج نشان می‌دهد که شبکه اول با ساختار ۱-۴-۴، با ۴ نرون در لایه پنهان و با تابع محرک سیگموئید، بهترین شبکه با در نظر گرفتن هر چهار متغیر ورودی به مدل می‌باشد. در این شبکه R^2 و RMSE مربوط به آزمون به ترتیب ۰/۹۷ و ۰/۰۸۴ می‌باشد.

شبکه دوم با ساختار ۱-۹-۳، با ۹ نرون در لایه پنهان و با تابع محرک سیگموئید، بهترین شبکه با حذف متغیر وضعیت

جدول ۲. نتایج شبکه‌های عصبی مصنوعی بهینه با ترکیب متغیرهای ورودی متفاوت

آزمون	اعتبارسنجی		آموزش		تابع		نوع شبکه
	RMSE	R ²	RMSE	R ²	محرك	ساختار شبکه	
						لایه پنهان	
۰/۰۸۴	۰/۹۷	۰/۰۵۷	۰/۷	۰/۰۴۴	۰/۹۲	سیگموئید	۴-۴-۱
۰/۰۶۸	۰/۹۷	۰/۰۶۸	۰/۸۳	۰/۰۴۱	۰/۸۹	سیگموئید	۳-۹-۱
۰/۱۵۲	۰/۹۶	۰/۰۳۸	۰/۹۲	۰/۰۴	۰/۸۹	سیگموئید	۳-۵-۱
۰/۰۴۶	۰/۹	۰/۰۳۸	۰/۶۸	۰/۰۵۱	۰/۸۷	سیگموئید	۲-۷-۱



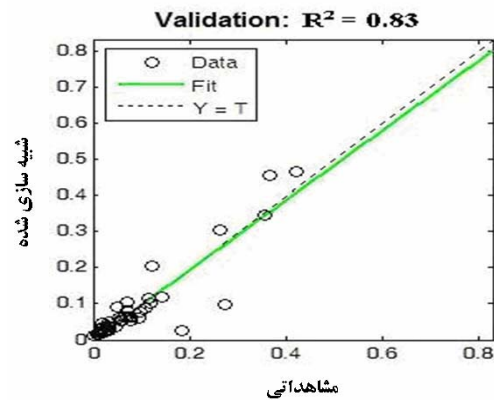
شکل ۴. همبستگی میان داده‌های مشاهداتی و شبه‌سازی شده دبی بار معلق در مرحله آموزش (مربوط به شبکه بهینه نهایی (۳-۹-۱))

سیگموئید، دارای بیشترین دقت در برآورد بار معلق رسوب می‌باشد. همچنین میانگین داده‌های رسوب مشاهداتی و پیش‌بینی شده توسط مدل بهینه (مربوط به بخش آزمون)، به ترتیب ۱۱۲۲/۸۰۲ و ۱۱۸۴/۹۲۴ (تن در روز) می‌باشد. شکل‌های ۴ تا ۶ همبستگی میان داده‌های مشاهداتی و شبه‌سازی شده دبی بار معلق رسوب، مربوط به شبکه عصبی بهینه نهایی را نشان می‌دهد.

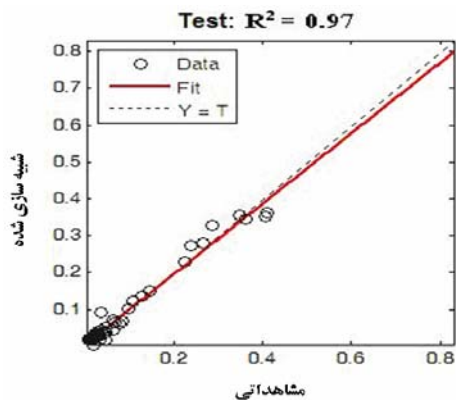
نتایج ارائه شده نشان می‌دهد که ورود داده‌های مربوط به وضعیت هیدروگراف، به‌عنوان ورودی به شبکه عصبی مصنوعی، نقشی در افزایش دقت مدل نداشته است. لذا می‌توان این پارامتر را از جمع ورودی‌های مدل حذف کرد. دهقانی و همکاران (۱)، نتایج متفاوتی را گزارش کردند. آنها بیان کردند که در نظر گرفتن روند افزایش یا کاهش در شاخه‌های هیدروگراف، سبب افزایش دقت تخمین رسوب معلق شده

همبستگی بالا تخمین بار معلق رسوب را انجام می‌دهد. سیگموزگلو (۶ و ۷) نیز در تحقیقات خود، به نتایج مشابهی دست یافت. او از شبکه عصبی مصنوعی به منظور تخمین بار رسوب معلق استفاده کرده و بیان کرد که شبکه عصبی مصنوعی از قابلیت بالایی جهت مدل‌سازی فرایند رواناب رسوب برخوردار می‌باشد. همچنین ژو و همکاران (۱۸)، با استفاده از شبکه عصبی مصنوعی مدل‌سازی رواناب- رسوب را در حوضه‌ای در چین انجام دادند. آنها در نتایج خود بیان کردند که شبکه عصبی مصنوعی نسبت به سایر روش‌ها، در برآورد بار رسوبی دارای دقت بالاتری است.

نتایج به دست آمده همچنین نشان می‌دهد که از میان ۸۰ شبکه عصبی مصنوعی ایجاد شده، شبکه عصبی بهینه نهایی با ساختار ۳-۹-۱ و با سه متغیر ورودی (شامل دبی روز مورد نظر، دبی یک روز قبل و اشل)، ۹ نرون در لایه پنهان و تابع فعال‌سازی



شکل ۵. همبستگی میان داده‌های مشاهداتی و شبیه‌سازی شده دبی بار معلق در مرحله اعتبارسنجی (مربوط به شبکه بهینه نهایی (۱-۹-۳))



شکل ۶. همبستگی میان داده‌های مشاهداتی و شبیه‌سازی شده دبی بار معلق در مرحله آزمون (مربوط به شبکه بهینه نهایی (۱-۹-۳))

نتیجه‌گیری

در تحقیق حاضر از شبکه عصبی مصنوعی (ANN) پرسپترون چند لایه جهت شبیه‌سازی دبی بار معلق رسوب رودخانه طالقان، در ایستگاه گلینک استفاده شد. متغیرهای ورودی به مدل شامل چهار متغیر دبی روز موردنظر، دبی یک روز قبل، اشل و وضعیت هیدروگراف بودند که در هر مرحله با حذف نوبتی هر یک از متغیرها، تأثیر ترکیب متغیرهای ورودی بر دقت شبیه‌سازی بار رسوبی توسط ANN بررسی شد. هم‌چنین در هر مرحله با تغییر تابع محرک و تعداد نرون لایه پنهان، به شناسایی شبکه بهینه اقدام شد. نتایج به‌دست آمده نشان می‌دهد

است. این تفاوت در نتایج، می‌تواند به دلیل تفاوت در مناطق مطالعاتی و ترکیب متغیرهای ورودی باشد.

ژو و همکاران (۱۸)، بیان کردند که تأخیر زمانی در داده‌های ورودی منجر به افزایش دقت تخمین بار رسوبی، توسط شبکه عصبی مصنوعی می‌شود. آنها هم‌چنین بیان کردند، در مورد داده‌های ورودی (مانند دبی جریان)، که خروجی مدل (مانند دبی رسوب)، رابطه نزدیکی با آنها دارند، تنها استفاده از تأخیر زمانی کوتاه مدت تأثیر مثبتی در افزایش دقت مدل داشته و تأخیرهای بلند مدت، علی‌رغم افزایش پیچیدگی مدل، دقت برآورد را کاهش می‌دهد.

مطالعه دست یافت و استفاده از پارامتر وضعیت هیدروگراف به عنوان ورودی مدل، علی‌رغم افزایش پیچیدگی مدل و افزایش زمان و انرژی لازم جهت ایجاد ساختار مدل، نقشی در افزایش دقت مدل نخواهد داشت.

که در میان کلیه شبکه‌های شبیه‌سازی شده، شبکه عصبی با ساختار ۱-۹-۳ (سه پارامتر ورودی و ۹ نرون در لایه پنهان و تابع فعال‌سازی سیگموئید) دارای بیشترین دقت در برآورد بار معلق رسوب می‌باشد. لذا می‌توان نتیجه‌گیری کرد که با سه ورودی دبی روز مورد نظر، دبی یک روز قبل و اشل می‌توان به‌بهترین ساختار از مدل شبکه عصبی مصنوعی در منطقه مورد

منابع مورد استفاده

- دهقانی، ا. ا. م. ا. زنگانه، ا. مساعدی و ن. کوهستانی. ۱۳۸۸. مقایسه تخمین بار معلق به دو روش منحنی سنج رسوب و شبکه عصبی مصنوعی (مطالعه موردی رودخانه دوغ استان گلستان). مجله علوم کشاورزی و منابع طبیعی ۱۶(۱): ۲۷۶-۲۶۶.
- رضوی زاده، س. ۱۳۸۹. سناریوهای مختلف تغییر کاربری اراضی و اثرات آن بر خصوصیات سیلاب با استفاده از مدل HEC-HMS (مطالعه موردی حوزه آبخیز طالقان)، پایان‌نامه کارشناسی ارشد آبخیزداری، دانشکده منابع طبیعی، دانشگاه تهران.
- طهمورث، م. ح. احمدی، ن. تقوی و ح. محمد عسکری. ۱۳۸۸. مقایسه دقت مدل‌های شبکه عصبی مصنوعی ژئومرفولوژی (GANN_s) و رگرسیون (RM) در برآورد رسوب طالقان رود. مجله پژوهش‌های آبخیزداری، ۲۲(۳) (پیاپی ۸۴): ۲۷-۱۹.
- Agarwal, A. H., S. K. Mishra and J. K. Singh. 2006. Simulation of runoff and sediment yield using artificial neural networks. *Biosys. Eng.* 97(4): 597-613.
- Ahmat Nor, N. I. B. 2005. Rainfall-runoff Modelling using Artificial Neural Networks Method PhD. Thesis, College of Civil Eng., Malaysia Technology University, Johor, Malaysia.
- Cigizoglu, H. K. 2002a. Suspended sediment estimation and forecasting using artificial neural networks. *Turk. J. Eng. and Environ. Sci.* 26 (1): 16-26.
- Cigizoglu, H. K., 2002b. Suspended sediment estimation for rivers using artificial neural networks and sediment rating curves. *Turk. J. Eng. and Environ. Sci.* 26(1), 27-36.
- Hornik, K., M. Stinchcombe and H. White. 1989. Multilayer feedforward networks are universal approximators. *Neural Netw.* 2(5):359-66.
- Lee, S., J. H. Ryu, M. J. Lee and J. S. Won. 2006. The application of artificial neural networks to landslide susceptibility mapping at Janghung, Korea. *Mathematical Geol.* 38(2): 199-220.
- Maria, C. V. R., F. C. V. Haroldo and J. F. Nelson. 2005. Artificial neural network technique for rainfall forecasting applied to the São Paulo region, *J. Hydrol.* 301(1-4): 146-162.
- Mustafa, M. R., M. H. Isa and R. B. Rezaur. 2011. A Comparison of Artificial Neural Networks for Prediction of Suspended Sediment Discharge in River, A Case Study in Malaysia. *World Academy of Sci., Eng. and Technol. (WASET).* 81: 372-376.
- Raghuwanshi, N. S., R. Singh and L. S. Reddy. 2006. Runoff and sediment yield modeling using artificial neural networks: Upper Siwane River, India. *J. Hydraul. Eng. ASCE.* 11(1): 71-79.
- Schalkoff, R. J. 1997. *Artificial Neural Networks.* McGraw-Hill Pub., New York.
- Solaimani, K. 2009. Rainfall-runoff prediction based on artificial neural network. *Am. – Eur. J. Agric. and Environ. Sci.* 5(6): 856-865.
- SPSS Inc. 2010. *SPSS Neural Network 17.0 (User's Guide).* Available at <http://www.spss.com/>.
- Vafakhah, M. 2012. Comparison of cokriging and adaptive neuro-fuzzy inference system models for suspended sediment load forecasting. *Arab. J. Geosci.* DOI 10.1007/s12517-012-0550-5.
- Yang, C. T., R. Marsooli and M. T. Aalami. 2009. Evaluation of total load sediment transport formulas using ANN. *Intl. J. Sediment Res.* 24(3): 274-286.
- Zhu, Y. M., X. X. Lu and Y. Zhou. 2007. Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the Upper Yangtze Catchment, China. *J. Geomorph.* 84: 111-125.