



مه‌دی فیض اله پور<sup>۱</sup>

## تخمین بار معلق رسوبی رودخانه سنگورچای با استفاده از مدل شبکه عصبی مصنوعی

تاریخ پذیرش: ۱۳۹۴/۰۱/۲۶

تاریخ دریافت: ۱۳۹۲/۱۱/۱۶

### چکیده

حوضه رودخانه سنگورچای به‌عنوان یکی از شاخه‌های رودخانه قزل‌اوزن دارای حجم بالایی از رسوبات است. با توجه به این نکته در این تحقیق برای تخمین بار معلق رسوبی روزانه از مدل پیش‌خور با الگوریتم پس انتشار خطا (FFBP) و تابع پایه شعاعی (RBF) استفاده شد. در واقع طبیعت غیرخطی بار معلق رسوبی استفاده از مدل‌های فوق را به‌عنوان مدل‌های غیرخطی در شبیه‌سازی این پارامتر اجتناب‌ناپذیر کرده است. لیکن پارامترهای ورودی برای هر مدل متفاوت بوده و در یک مرحله تنها از داده دبی استفاده شده و در مرحله بعد علاوه بر داده دبی از داده بارندگی نیز در هر مدل استفاده گردید. سپس برای تعیین کارایی مدل‌ها از فاکتور مجذور میانگین مربعات خطا (RMSE) و خطای تعیین ( $R^2$ ) استفاده شده و مشاهده می‌شود که مدل RBF در صورت استفاده از دو پارامتر دبی و بارندگی به‌عنوان پارامترهای ورودی، با برخورداری از خطای تعیین  $0/9251$  و مجذور میانگین مربعات خطای معادل ۲۶۵ میلی‌گرم در لیتر به نتایج بهتری دست یافته است. در نهایت برای تعیین قابلیت پارامتر RMSE در صحت سنجی هر یک از مدل‌ها، از سیستم اطلاعاتی آکائیک (AIC) استفاده شده و مشاهده شد که مدل RBF با برخورداری از مقادیر آکائیک معادل ۱۰۴۲ از قابلیت بهتری برخوردار است.

**کلید واژه‌ها:** بار معلق رسوبی، مدل پیش‌خور با الگوریتم پس انتشار، تابع پایه شعاعی، سیستم آکائیک، حوضه سنگورچای.

## مقدمه

پیش‌بینی بار معلق رسوبی از اهمیت بالایی در مهندسی هیدرولیک و محیط‌زیست برخوردار است. در مخازنی که برای نگهداری حجم وسیعی از آب طراحی شده‌اند بایستی مقادیر ورودی بار رسوبی نیز در نظر گرفته شود. تخمین کم‌تر از حد واقعی باعث پر شدن سریع مخازن شده و تخمین بیش از حد معمول نیز منجر به طراحی مخازن با حجم بالا می‌گردد؛ بنابراین تعیین بار رسوبی بایستی با دقت بالایی صورت گیرد. در کنار آن در مباحث مربوط به محیط‌زیست، پیش‌بینی بار رسوبی از اهمیت بالایی برخوردار بوده و نیازمند در نظر گرفتن انتقال آلاینده‌ها توسط رسوبات می‌باشد. این امر با در نظر گرفتن توزیع زمانی انتقال رسوبات، در کنترل سطح آلودگی در رودخانه‌ها و مخازن نقش مهمی را ایفا خواهد کرد. روش‌های معمول هیدرومکانیک به علت پیچیدگی حرکت ذرات در جریان‌های اغتشاشی و روند تصادفی آن موفق به ارائه مدل کاملی در تخمین بار معلق رسوبی نگردیده‌اند. برخی از تکنیک‌های موجود برای تحلیل سری‌های زمانی متغیرها را خطی فرض می‌کنند. در جهان واقعی، متغیرهای زمانی از روابط منظم برخوردار نبوده و این امر تحلیل و پیش‌بینی دقیق را با مشکل مواجه می‌سازد؛ بنابراین بهره‌گیری از مدل‌های غیرخطی از قبیل شبکه‌های عصبی (ANN) ضروری به نظر می‌رسد. شبکه‌های عصبی مصنوعی برای تحلیل داده‌های زمانی به نتایج مطلوبی دست می‌یابند.

کاربردهای متفاوتی از شبکه‌های عصبی مصنوعی در منابع آب وجود دارد. روابط بارش رواناب به‌طور موفقیت‌آمیزی توسط شبکه عصبی مصنوعی مدل‌سازی شده‌اند (مانس و هال<sup>۲</sup>، ۱۹۹۶: ۴۰۲، فرناندو و جایاواردینا<sup>۳</sup>، ۱۹۹۸: ۲۰۵). توکار و جانسون<sup>۴</sup> (۱۹۹۹: ۲۳۶) و سیقیزاغلو<sup>۵</sup> (۲۰۰۳: ۳۵۲)، شبکه عصبی مصنوعی را برای پیش‌بینی دبی رودخانه‌ها به‌کار گرفتند. سایر کاربردهای مدل ANN شامل تحلیل خشکسالی (شین و سالاس<sup>۶</sup>، ۲۰۰۰: ۱۴۸)، طبقه‌بندی حوضه‌های رودخانه‌ای (تانداوسوارا و ساجیکومار<sup>۷</sup>، ۲۰۰۰: ۲۹۳) و ارزیابی آسیب‌پذیری زمین‌های کشاورزی در اثر حفر چاه‌های عمیق (رای و کلیندورث<sup>۸</sup>، ۲۰۰۰: ۱۶۹) می‌باشد.

در سایر تحقیقات، مدل میانگین متحرک اتورگرسیو در تست و تعلیم مجموعه داده با مدل ANN ادغام گردید (سیقیزاغلو<sup>۹</sup>، ۲۰۰۳: ۳۵۴). در تحقیقی دیگر سیقیزاغلو<sup>۱۰</sup> (۲۰۰۴: ۱۶۸) به پیش‌بینی و تخمین مجموع بار معلق روزانه پرداخته است. به این منظور، داده‌های روزانه یا ماهانه بار معلق رسوبی و دبی توسط مدل پیش‌خور پس انتشار (FFBP) مورد پردازش قرار گرفتند.

2- Minns et al

3- Fernando et al

4- Tokar et al

5- Cigizoglu

6- Shin et al

7- Thandaveswara et al

8- Ray et al

9- Cigizoglu

10- Cigizoglu

کیسی<sup>۱۱</sup> (۲۰۰۴: ۱۰۲۸)، با استفاده از مدل ANN و با بهره‌گیری از داده‌های دبی و رسوب به تخمین بار معلق رسوبی پرداخت. سقیزاغلو و کیسی<sup>۱۲</sup> (۲۰۰۵: ۱۳) به بررسی صحت مدل ANN در تخمین و پیش‌بینی داده‌های رسوبی روزانه پرداخته‌اند. کیسی (۲۰۰۵: ۶۹۲) برای مدل‌سازی بار معلق رسوبی روزانه از شبکه عصبی مصنوعی بهره گرفته و به این نتیجه دست یافته که مدل ANN نسبت به مدل منحنی سنج رسوبی از کارایی بهتری برخوردار است. باتاچاریا<sup>۱۳</sup> و همکاران (۲۰۰۵: ۲۹۹) با استفاده از تحقیقات چندین محقق از یک نوع الگوریتم برای اصلاح مدل ANN استفاده کرده و صحت سنجی مدل نشان می‌دهد که این مدل نسبت به مدل‌های انتقال رسوب به نتایج بهتری دست یافته است. سقیزاغلو و کیسی<sup>۱۴</sup> (۲۰۰۶: ۲۲۶) برای بهبود کارایی مدل ANN از روش‌های مختلفی استفاده کرده‌اند. تایفور و گولدال<sup>۱۵</sup> (۲۰۰۶: ۷۱) از روش پرسپترون چندلایه برای پیش‌بینی بار معلق رسوبی بهره گرفته است. راگوانشی<sup>۱۶</sup> و همکاران (۲۰۰۶: ۷۵) عنوان کرده‌اند که در پیش‌بینی دبی و بار معلق رسوبی حوضه رودخانه ناگوان در هند، مدل ANN به نتایج مطلوبی دست یافته است.


اکثر کاربردهای مدل ANN در مهندسی منابع آب اختصاص به استفاده از مدل پیش‌خور پس انتشار (FFBP) داشته و در فرآیند تعلیم داده‌ها از این الگوریتم بهره گرفته شده است. کارایی الگوریتم FFBP در پیش‌بینی روند دبی، مقدم بر مدل‌های تصادفی و آماری می‌باشد (بریکاندای و همکاران<sup>۱۷</sup>، ۲۰۰۲: ۳۹۵، سقیزاغلو<sup>۱۸</sup>، ۲۰۰۳: ۳۵۲). با توجه به محدودیت‌های این مدل، مقایسه‌ای بین الگوریتم‌های مختلف شبکه عصبی مصنوعی صورت گرفته است (سقیزاغلو<sup>۱۹</sup> و همکاران، ۲۰۰۵: ۱۳). الگوریتم FFBP دارای برخی نقایص از قبیل مشکل کمینه‌های محلی می‌باشد. مایر و دندی<sup>۲۰</sup> (۲۰۰۰: ۱۱۱)، در تحقیقی با بررسی نتایج تحقیقات مختلف و تعلیم شماری از شبکه‌ها با وزن‌های ورودی متفاوت، بر این مشکل غلبه کرده و با اضافه کردن داده‌های تصادفی باعث گریز شبکه از کمینه‌های محلی گردیدند. در این بین برای تسریع این فرآیند از الگوریتم‌های نیوتونی و لونبرگ مارکواردت یا مدل الگوریتم گرادیان نزولی بهره گرفته شد. در ایران نیز تحقیقاتی در این زمینه صورت گرفته است. دهقانی و همکاران (۱۳۸۸: ۴۲) با استفاده از منحنی سنج رسوبی و شبکه عصبی مصنوعی به تخمین بار معلق رسوبی رودخانه دوغ در استان گلستان پرداختند. تحقیق فوق نشان داد که شبکه عصبی مصنوعی نسبت به منحنی سنج رسوبی به نتایج بهتری دست یافته است. دهقانی و همکاران (۱۳۸۹: ۱۶۳) با استفاده از شبکه عصبی مصنوعی به تخمین بار معلق رسوبی رودخانه

- 11- Kisi
- 12- Cigizoglu & Kisi
- 13- Bhattacharya
- 14- Cigizoglu & Kisi
- 15- Tayfur & Guldal
- 16- Raghuwanshi
- 17- Brikundavyi et al
- 18- Cigizoglu
- 19- Cigizoglu et al
- 20- Maier & Dandy

بهشت‌آباد پرداختند. نتایج نشان داد که مدل شبکه عصبی مصنوعی از قابلیت بالایی در تخمین بار معلق رسوبی برخوردار است. رضایی بنفشه و همکاران (۱۳۹۲: ۸۴) با استفاده از سیستم استنتاجی فازی عصبی و مدل‌های MLR و SRC به تخمین بار معلق رسوبی رودخانه قرانقو پرداخته و به این نتیجه رسیدند که سیستم استنتاجی نسبت به سایر مدل‌های استفاده شده به نتایج بهتری دست یافته است. در این تحقیق برای پیش‌بینی دقیق بار معلق رسوبی از مدل شبکه عصبی مصنوعی با عناوین پرسپترون چند لایه با الگوریتم پیش‌خور پس انتشار (FFBP) و تابع پایه شعاعی (RBF) استفاده شد. این فرآیند در دو مرحله صورت می‌گیرد. در هر مرحله با یکسری پارامترها اقدام به شبیه‌سازی گردید. در مرحله اول برای تخمین بار معلق رسوبی تنها از داده‌های دبی به‌عنوان ورودی استفاده شد. در دومین مرحله از شبیه‌سازی از دو پارامتر بارندگی و دبی در کنار بار معلق رسوبی استفاده شد.

#### گستره مورد مطالعه

حوضه رودخانه سنگور چای با مجموع مساحت ۸۵۳ کیلومتر مربع یکی از زیرحوضه‌های آبریز سفیدرود می‌باشد که در مختصات ۴۸ درجه و ۴ دقیقه و ۲۰ ثانیه تا ۴۸ درجه ۳۳ دقیقه و ۲۴ ثانیه طول شرقی و ۳۷ درجه و ۳۴ دقیقه و ۳۲ ثانیه تا ۳۷ درجه و ۵۶ دقیقه و ۱۷ ثانیه عرض شمالی واقع شده است. این حوضه از شمال به حوضه آبریز قره‌سو، از غرب به حوضه آبریز رودخانه قرنقو و از شرق به رشته‌کوه‌های تالش و از جنوب به حوضه آبریز رودخانه قزل‌اوزن محدود می‌شود (شکل ۱).



شکل ۱: موقعیت جغرافیایی حوضه رودخانه سنگورچای در استان اردبیل

میانگین بارندگی در این حوضه ۴۲۷ میلی‌متر بوده و ۸۳ تا ۹۲ درصد از مجموع بارندگی در ماه‌های فروردین و اردیبهشت رخ می‌دهد. بارندگی در فصل مرطوب دارای بیش‌ترین شدت و فراوانی است. علاوه بر آن این منطقه به‌شدت از عوامل انسانی از قبیل رشد جمعیت، توسعه سریع اقتصادی، جنگل‌زدایی، تشدید فعالیت کشاورزی، احداث سدها، استخراج معادن و جاده‌سازی تاثیر پذیرفته است.

در این تحقیق، داده‌های دبی روزانه و بار معلق رسوبی حوضه رودخانه سنگورچای برای تخمین بار معلق رسوبی مورد استفاده قرار گرفته است. داده‌های فوق دوره زمانی ۱۳۸۹ تا ۱۳۹۱ را در بر گرفته و از سازمان تماب گردآوری شده است. سپس پارامترهای آماری میانگین  $(\bar{X})$ ، انحراف معیار  $(S_x)$ ، ضریب چولگی  $(C_{sx})$  و حداقل و حداکثر داده‌ها برای حوضه سنگورچای محاسبه گردید. مقادیر آماری فوق در (جدول ۱) نشان داده شده است.

جدول ۱- پارامترهای آماری روزانه دبی و رسوب در ایستگاه سنگور چای (۹۱-۱۳۸۹)

| نوع داده‌ها      | نوع داده                | میانگین | انحراف معیار | ضریب چولگی | حداکثر داده | حداقل داده |
|------------------|-------------------------|---------|--------------|------------|-------------|------------|
| داده‌های تعلیمی  | دبی (متر مکعب در ثانیه) | ۴۹      | ۱۲۶          | ۴/۸۲       | ۹۲۴         | ۰/۷        |
|                  | رسوب (میلی‌گرم در لیتر) | ۳۲۸     | ۷۵۹          | ۵/۳۶       | ۷۴۵۲        | ۶          |
|                  | بارندگی (میلی‌متر)      | ۴۳/۷    | ۴۶/۰۸        | ۱/۷        | ۲۹/۲        | ۰/۱        |
| داده‌های آزمایشی | دبی (متر مکعب در ثانیه) | ۳۸      | ۶۷           | ۲/۵۵       | ۴۶۱         | ۰/۴        |
|                  | رسوب (میلی‌گرم در لیتر) | ۴۱۵     | ۹۵۱          | ۴/۰۲       | ۷۳۰۰        | ۸          |
|                  | بارندگی (میلی‌متر)      | ۵۵/۷    | ۳۳/۱۴        | ۰/۶        | ۲۱/۷        | ۰/۳        |

## مواد و روش‌ها

در اولین مرحله از تحقیق در نرم‌افزار MATLAB دو کد برای مدل‌های RBF و FFBBP در ساختار الگوریتم لونبرگ مارکوارت نوشته شد. این الگوریتم به علت سرعت بالای آن در همگرایی داده‌ها مورد توجه قرار گرفته است. به‌کارگیری مدل‌های شبکه عصبی مصنوعی در دو مرحله صورت می‌گیرد. اولین مرحله شامل تعلیم شبکه عصبی مصنوعی بوده و داده‌های دبی، بارندگی و رسوب با اختصاص وزن‌هایی در درون شبکه، ورودی‌های مدل را شامل می‌شوند. پس از تکمیل و اتمام مرحله تعلیم، نیمی از داده‌ها به‌منظور آزمون مدل انتخاب می‌گردد. در این میان، تعیین ساختار مناسب به علت نقش آن در قابلیت تصمیم‌گیری و پیچیدگی محاسباتی از اهمیت بالایی برخوردار است. تعداد گره‌های لایه ورودی در اولین لایه با استفاده از پارامترهای آماری و احتمالاتی تعیین می‌گردد. سپس کارایی مدل‌های FFBBP و RBF در تخمین بار معلق رسوبی رودخانه سنگورچای مورد ارزیابی و مقایسه قرار

می‌گیرند. دوره زمانی انتخاب شده برای تعلیم و تست داده‌ها به ترتیب اول دی ماه سال ۱۳۸۹ تا اواخر خرداد ماه سال ۱۳۹۰ و اول دی ماه ۱۳۹۰ تا اول خرداد ماه ۱۳۹۱ را در بر می‌گیرد. علت این امر تاثیر منفی داده‌های دوره خشک در صحت پیش‌بینی بار معلق رسوبی است که باعث شده تا در این تحقیق داده‌های ۱۸۵ روز واقع در بازه زمانی فوق در پیش‌بینی مد نظر قرار گیرد. برای ارزیابی کارایی هر مدل نیز مقادیر مشاهداتی و پیش‌بینی شده با استفاده از پارامتر  $RMSE$  و  $R^2$  مورد بررسی قرار گرفت. البته در این تحقیق اقدام به دو سری شبیه‌سازی گردید. در اولین شبیه‌سازی، تنها از داده دبی برای شبیه‌سازی بار معلق رسوبی استفاده شده ولی در دومین مرحله از شبیه‌سازی از داده‌های بارندگی نیز در کنار داده دبی استفاده شده است. بررسی‌ها در انواع ساختارها نشان داد که بهره‌گیری از دو پارامتر دبی و بارندگی به بهترین نتیجه در تخمین بار معلق رسوبی دست می‌یابد. در زیر هر یک از مدل‌های مورد استفاده در این تحقیق تشریح می‌گردد:

ساختار مدل‌های شبکه عصبی مصنوعی (ANN)

الگوریتم پیش‌خور پس انتشار (FFBP)

شبکه‌های عصبی از لایه‌هایی شامل اجزا ساده پردازشگری به نام نرون تشکیل شده‌اند که به‌صورت موازی باهم عمل می‌کنند. لایه اول، لایه ورودی است که می‌تواند پارامترهای آماری یا مولفه‌های حاصل از تبدیلات ریاضی روی توابع باشند. لایه دوم، لایه‌های پنهان هستند که اساس ساختار یک شبکه را تشکیل می‌دهند. کار اصلی این لایه، استخراج اطلاعات دسته‌بندی شده از داده‌های موجود می‌باشد. لایه آخر یا لایه خروجی بر اساس انتظارات کاربر تعیین می‌شود. این لایه می‌تواند توسط یک یا چند عنصر پردازشگر که خروجی آن نشان دهنده دسته‌بندی نهایی است شناخته شود. هر لایه دارای وزنی است که بیانگر میزان تاثیر دو نرون بر یکدیگر است. تخمین پارامترها (وزن‌ها) توسط قوانین یادگیری که همان برآورد پارامترها است صورت می‌پذیرد. در این حالت پس از یادگیری شبکه و یافتن ارتباط تابعی بین ورودی‌ها و خروجی‌ها، شبکه می‌تواند به‌عنوان یک مدل برای پیش‌بینی یک پاسخ مطابق با یک الگوی ورودی جدید استفاده شود (وارنر<sup>۲۱</sup>، ۲۰۰۳: ۹). در عملکرد شبکه دو گام یادگیری (آموزش) و به یاد آوردن (آزمایش) وجود دارد و مبتنی بر این واقعیت داده‌ها به تصادف به دو مجموعه آموزشی و آزمایشی تقسیم می‌شوند. در گام آموزش انتظار می‌رود که شبکه قادر باشد که الگوی موجود در داده‌ها را بازشناسی کرده و در ادامه در داده‌های جدید (داده‌های آزمایشی) استفاده نماید. در گام آزمایش، شبکه بر اساس برآوردهای حاصل از مرحله آموزشی، داده‌های آزمایشی را پیش‌بینی می‌کند (اسمیت<sup>۲۲</sup>، ۱۹۹۳: ۱۲۴). یکی از الگوریتم‌های یادگیری، الگوریتم پس انتشار است. مبنای نظری این الگوریتم، همان مبنای نظری روش‌های معمول مبتنی بر مشتقات جزئی گوس-نیوتون و نیوتون-رافسون است (سوباسا<sup>۲۳</sup>، ۲۰۰۵: ۹۲). این الگوریتم به‌وسیله وجود یک یا چندین لایه پنهان

21- Werner

22- Smith

23- Subasia

شناخته می‌شود. هر لایه پنهان، به محاسبه گره‌های سیستم می‌پردازد. در صورتی که نورون‌های پنهان در بین ورودی و شبکه خروجی‌ها واقع گردد، بهترین عملکرد را خواهد داشت. با افزایش یک یا چندین لایه پنهان، بیش‌ترین تعداد شاخه‌های آماری استخراج می‌گردد. این مدل با بهره‌گیری از تکنیک لون برگ-مارکوات، بیش‌ترین دقت را نسبت به تکنیک گرادیان نزولی کسب نموده است. الگوریتم لون برگ مارکوات برگرفته از روش نیوتون می‌باشد. اگر تابع  $V(X)$ ، کم‌ترین اثرگذاری را به پارامتر برداری  $(X)$  داشته باشد، در آن صورت، مدل نیوتونی به شکل زیر خواهد بود:

$$\Delta x = -[\nabla^2 v(x)]^{-1} \nabla v(x), \quad \text{رابطه (۱)}$$

در این فرمول  $\nabla V(X)$  گرادیان می‌باشد. اگر فرض شود که  $V(x)$ ، مجموع مربعات تابع زیر باشد:

$$v(x) = \sum_{i=1}^n e_i^2(x) \quad \text{رابطه (۲)}$$

در این صورت معادله به شکل زیر بیان می‌گردد:

$$\nabla v(x) = J^T(x) e(x) \quad \text{رابطه (۳)}$$

$$\nabla^2 v(x) = J^T(x) J(x) + s(x) \quad \text{رابطه (۴)}$$

در معادله فوق  $J(x)$ ، ماتریکس یاکوبین بوده و  $S(x)$  نیز از طریق معادله زیر محاسبه می‌گردد:

$$s(x) = \sum_{i=1}^n e_i \nabla^2 e_i(x) \quad \text{رابطه (۵)}$$

در صورتی که در روش گوسن نیوتون،  $s(x)=0$  فرض گردد، شکل ارتقا یافته معادله به صورت زیر خواهد بود:

$$\Delta x = [J^T(x) J(x)]^{-1} J^T(x) e(x) \quad \text{رابطه (۶)}$$

در نهایت شکل اصلاح شده مدل گوس نیوتون، به صورت معادله لون برگ مارکوات ارائه می‌شود:

$$\Delta x = [J^T(x) J(x) + \mu I]^{-1} J^T(x) e(x) \quad \text{رابطه (۷)}$$

در صورتی که  $V(X)$ ، یک تابع نزولی بوده و  $M$  به وسیله فاکتور  $B$  تقسیم شده باشد، در این صورت می‌توان مقدار  $M$  را از مجموع چندین فاکتور  $B$  به دست آورد. افزایش میزان  $M$  باعث ایجاد شیب نزولی در الگوریتم خواهد شد.

مرحله کلیدی الگوریتم فوق، محاسبه ماتریس یاکوبین می‌باشد. مدل FFBP می‌تواند متشکل از چندین لایه پنهان باشد که به صورت توابع غیرخطی در محاسبات اعمال می‌گردند.

تابع پایه شعاعی (RBF))

مدل RBF، با استفاده از توابع غیرخطی به طبقه‌بندی داده‌های ورودی قبل از الصاق به شبکه می‌پردازد. این توابع سطحی فضای ورودی را تحت پوشش قرار می‌دهند.

لایه پنهان محتوی شمار یکسانی از گره‌ها در مرکز شبکه می‌باشند. داده‌های غیر صفری فقط در زمانی که داده‌های ورودی در بین سطح کوچکی از فضای داده‌های ورودی واقع شده باشد، مورد استفاده قرار می‌گیرند. با وجود این کاستی، روش فوق به عنوان یکی از روش‌های پیش‌بینی حجم رسوبات استفاده شده است.

انتقال ورودی‌ها در مدل تجربی، مهم‌ترین قسمت مطالعات می‌باشد. انتقال ورودی در مدل RBF به صورت غیرخطی بوده و در غالب یک تابع پایه‌ای تثبیت شده شعاعی صورت می‌گیرد. بعد از یک رابطه غیرخطی، ورودی‌های چندبعدی بدون در نظر گرفتن فضای خروجی در تابع پایه‌ای شعاعی، نقش پیش‌بینی کننده‌ای را ایفا می‌کنند. با این وجود لایه خروجی به صورت یک رگرسیون خطی بوده و فقط قابلیت تنظیم پارامترهایی را دارا می‌باشد که از وزن معینی برخوردار باشند این پارامترها به عنوان روش کم‌ترین مربعات شناخته می‌شوند. معادله برآورد روش RBF به صورت معادله زیر می‌باشد:

$$y(x) = \phi((x - c)^{T\zeta - 1}(x - c)) \quad \text{رابطه (۸)}$$

در این فرمول  $\phi$  تابع فعال، C مرکز شبکه و  $\xi$  واحد اندازه‌گیری تابع می‌باشد. غالباً واحد متریک، یک عبارت اقلیدسی بوده و برابر معادله فوق می‌باشد:

$$\xi = r^2 i \quad \text{رابطه (۹)}$$

$$y(x) = \phi\left(\frac{(x-c)^T(x-c)}{r^2}\right) \quad \text{رابطه (۱۰)}$$

در این معادله، طول اقلیدسی به وسیله  $I_j$  نمایش داده می‌شود که از طریق تفریق بین بردار  $y = (y_1, y_2, \dots, y_m)$  و مرکز شعاع  $y_i = (w_1, w_2, \dots, w_{mj})$  به دست می‌آید و فرمول کلی آن به صورت زیر می‌باشد:

$$r_j = \|y - Y^j\| = [\sum_{i=1}^m (y_i - w_{ij})^2]^{1/2} \quad \text{رابطه (۱۱)}$$

تابع انتقالی مناسبی که برای تخمین  $I_j$  به کار برده می‌شود، از طریق رابطه زیر به دست می‌آید:

$$\phi(r_j) = \phi(\|y - Y^k\|) \quad \text{رابطه (۱۲)}$$

نهایتاً لایه خروجی، یک ترکیب خطی وزن دار می باشد که از طریق معادله زیر محاسبه می گردد:

$$\bar{y}(x) = \sum_{j=1}^n c_j^k \phi(r_j) = \sum_{i=1}^n c_i^k = \phi(\|y - Y^k\|) \quad \text{رابطه (۱۳)}$$

### یافته ها و بحث

در این تحقیق، قبل از ورود داده ها به مدل های شبکه عصبی مصنوعی بایستی پیش پردازشی انجام گیرد به این منظور داده ها کران دار می شوند (مستر<sup>۲۴</sup>، ۱۹۹۳: ۱۳۷، گاه، ۱۹۹۵: ۱۴۷). لذا داده ها از طریق معادله زیر در محدوده ۰/۰۱ تا ۰/۹۹ قرار می گیرند.

$$x_s = \frac{0.99(x_i - x_{min})}{(x_{max} - x_{min})} + 0.01 \quad \text{رابطه (۱۴)}$$

در این معادله،  $x_s$ ، داده های ورودی مقیاس گذاری شده بوده و  $x_i$ ،  $x_{min}$  و  $x_{max}$  به ترتیب داده های غیرمقیاس گذاری شده، داده های حداقل و داده های حداکثر می باشند. سپس برای شبیه سازی بار معلق رسوبی در مدل شبکه عصبی مصنوعی کدهایی در نرم افزار MATLAB برای مدل پیش خور پس انتشار و تابع پایه شعاعی نوشته شد. ساختار شبکه عصبی مصنوعی شامل ۳ لایه ورودی، پنهان و خروجی است. لایه ورودی با استفاده از ترکیب متفاوت داده های هیدرواقليم تهیه شده است. کاربرد مدل های ANN در تحلیل سری های زمانی در ۲ مرحله صورت می گیرد. در اولین مرحله، شبکه های عصبی تعلیم داده می شوند. در این بخش با اختصاص وزن به داده های ورودی که شامل داده های دبی و بارندگی روزانه هستند سعی شده تا داده های خروجی که همان داده های پیش بینی شده بار معلق رسوبی هستند شبیه سازی شوند. پس از اینکه تعلیم داده ها در شبکه عصبی مصنوعی انجام گرفت داده ها آزمایش یا تست می شوند. به این منظور داده های اول دی ماه سال ۱۳۸۹ تا اواخر خرداد ماه سال ۱۳۹۰ برای تعلیم و داده های اول دی ماه ۱۳۹۰ تا اول خرداد ماه ۱۳۹۱ برای تست در نظر گرفته شد.

تعیین ساختار مناسب برای شبکه عصبی مصنوعی به علت پیچیدگی محاسباتی از اهمیت بالایی برخوردار است. برای مدل FFBBP، تعداد لایه های پنهان و تعداد گره ها در لایه ورودی و پنهان بعد از آزمودن انواع ساختارهای شبکه تعیین می گردد. خطای مجذور میانگین مربعات (RMSE) نیز به منظور صحت سنجی داده ها برای داده ها محاسبه گردید. مقادیر RMSE از طریق معادله زیر برآورد می گردد:

رابطه (۱۵)

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N [S_{t \text{ measured}} - S_{t \text{ predicted}}]^2}$$

فرآیند تعلیم به محض اینکه میزان خطای صحت‌سنجی افزایش یابد متوقف می‌شود. تعداد تکرار با استفاده از این فرآیند تعیین می‌گردد. برای مدل FFBP، ۱۵۰ مرتبه فرآیند تکرار آموزش و تعلیم انجام گرفته و فواصل توزیع نرمال برای وزن داده‌ها در بین ۳- تا ۳+ قرار گرفت. برای تابع انتقالی نیز، تابع تانژانت زیگموئید استفاده گردید. مقادیر مومنتم و یادگیری نیز پارامترهایی هستند که در طول مرحله تعلیم تغییر می‌کنند. در این تحقیق مقدار یادگیری متغیرها نیز در بین فرآیند شبیه‌سازی استفاده شده و در بین صفر تا ۱ در نوسان است. کارایی الگوریتم به میزان مناسبی از فرآیند یادگیری حساس است. اگر میزان یادگیری بیش از اندازه باشد ممکن است الگوریتم دچار نوسان شده و ناپایدار گردد. اگر میزان یادگیری کم باشد فرآیند همگرایی در الگوریتم نیز بسیار طولانی خواهد بود. تعیین میزان یادگیری قبل از فرآیند تعلیم امکان‌پذیر نیست. در حقیقت میزان یادگیری بهینه در طول فرآیند تعلیم تعیین شده و در این صورت است که الگوریتم به سطح کارآمدتری حرکت می‌کند. میزان یادگیری به پیچیدگی سطح خطای محلی حساس می‌باشد. لذا در ابتدا در اولین شبکه مقادیر خروجی و خطا محاسبه می‌گردد. در هر دوره، وزن‌های جدید و مقادیر بایاس با استفاده از مقادیر یادگیری متفاوت محاسبه شده و خروجی و خطا برآورد می‌گردد. اگر خطای جدید بیش از خطای قبلی باشد وزن‌های جدید به همراه عبارات بایاس کنار گذاشته می‌شود. علاوه بر این، میزان یادگیری کاهش می‌یابد؛ به عبارت دیگر، وزن‌های جدید مورد بازبینی قرار می‌گیرد. اگر خطای جدید کم‌تر از خطاهای قدیمی باشد میزان یادگیری افزایش می‌یابد؛ بنابراین فرآیند یادگیری بایستی در حدی باشد که باعث افزایش خطا نگردد. تعداد واحدها در لایه پنهان نیز به‌طور جداگانه بر مبنای لایه ورودی تعیین می‌گردد. به‌منظور به گیر انداختن مشکل کمینه‌های محلی در شبیه‌سازی FFBP، فرآیند تکرار در هر ساختار مدل فوق صورت می‌گیرد. کم‌ترین میزان خطای RMSE در مجموعه تست شده به‌عنوان مبنای شبیه‌سازی در نظر گرفته شد. بررسی بین سری‌های متفاوت داده‌های هیدرواقليمی، تاکید بر تعداد گره‌ها در لایه ورودی دارد.

برای مدل RBF، ساختار یکسانی در لایه ورودی با مدل FFBP استفاده گردید. تعداد تکرار برای دوره تست شده از ۷ تا ۸۰ بار انجام گرفته و مشاهده شد که در ۲۰ بار تکرار بهترین نتیجه برای مدل RBF به‌دست می‌آید. بهترین ساختار ورودی برای این مدل‌ها در (جدول ۲ و ۳) نشان داده شده است. داده‌های ورودی و خروجی بین ۰/۱ تا ۰/۹ رتبه‌بندی گردید. برای ارزیابی کارایی مدل‌ها، خطای مجذور میانگین مربعات (RMSE) و خطای تعیین ( $R^2$ ) به کار گرفته شد. با این وجود در انتخاب بهترین ساختار برای مدل‌های شبکه عصبی مصنوعی، پارامتر RMSE مقدم می‌باشد؛ اما در کل، پارامتر  $R^2$  با پارامتر RMSE در تطابق کامل قرار دارد. در این تحقیق فرآیند شبیه‌سازی در دو مرحله انجام می‌گیرد. در اولین مرحله، در تخمین بار معلق رسوبی تنها از داده‌های دبی به‌عنوان ورودی استفاده می‌شود. در دومین مرحله، علاوه بر داده‌های دبی روزانه از داده‌های بارندگی نیز به‌عنوان ورودی استفاده شد. سپس مقادیر هر دو تخمین با یکدیگر مقایسه گردید.

تخمین بار معلق رسوبی با استفاده از داده‌های دبی برای حوضه سنگورچای

در این بخش از تحقیق تنها از داده‌های دبی به‌عنوان لایه ورودی استفاده شد. روابط بین دبی و بار معلق رسوبی غیرخطی بوده و از روابط پیچیده‌ای برخوردار است. منحنی سنج رسوبی در بین دبی و بار معلق رسوبی به‌وضوح نشان داده که روابط بین این دو پارامتر بسیار پیچیده است (سیقیزاغلو و همکاران<sup>۲۵</sup>، ۲۰۰۴: ۱۶۹).


در ابتدا انواع لایه‌های ورودی با شمار متفاوتی از داده‌های دبی و بار رسوبی ترکیب شده و مشاهده شد که ساختار برخوردار از ترکیب  $Q_{rt}$ ,  $Q_{rt-1}$ ,  $S_{rt-1}$  به بهترین نتیجه دست یافته است. ساختار متفاوتی از شبکه‌ها برای هر یک از مدل‌های FFBP و RBF به همراه دو مرحله شبیه‌سازی یا تخمین در (جداول ۲ و ۳) نمایش داده شد. بر اساس نتایج به‌دست‌آمده مشاهده می‌شود که سومین ترکیب ورودی در مدل RBF با برخورداری از خطای تعیین  $0/9084$  و مجذور خطای میانگین مربعات برابر  $306$  میلی‌گرم در لیتر در تخمین بار رسوبی به بهترین میزان تخمین دست یافته است. البته این در صورتی است که تنها از پارامتر دبی استفاده شود. نمودار پراکنش و مقادیر تخمین زده بار رسوبی هر یک از مدل‌ها در صورت استفاده از پارامتر دبی در (شکل ۲) نمایش داده شده است.

جدول ۲- بررسی ساختارها و کارایی مدل FFBP با بهره‌گیری از داده دبی در دوره تست شده

| مدل FFBP |                              |                         | ساختار ورودی مدل                     |
|----------|------------------------------|-------------------------|--------------------------------------|
| $R^2$    | RMSE بر حسب میلی‌گرم در لیتر | تعداد گره در لایه پنهان |                                      |
| $0/8539$ | ۳۶۲                          | ۲                       | $Q_{rt}$                             |
| $0/8928$ | ۳۳۸                          | ۳                       | $Q_{rt}$ and $S_{rt-1}$              |
| $0/9041$ | ۳۲۷                          | ۴                       | $Q_{rt}$ , $Q_{rt-1}$ and $S_{rt-1}$ |

جدول ۳- بررسی ساختارها و کارایی مدل RBF با بهره‌گیری از داده دبی در دوره تست شده

| مدل RBF  |                              | ساختار ورودی مدل                     |
|----------|------------------------------|--------------------------------------|
| $R^2$    | RMSE بر حسب میلی‌گرم در لیتر |                                      |
| $0/8936$ | ۳۲۴                          | $Q_{rt}$                             |
| $0/9024$ | ۳۱۵                          | $Q_{rt}$ and $S_{rt-1}$              |
| $0/9084$ | ۳۰۶                          | $Q_{rt}$ , $Q_{rt-1}$ and $S_{rt-1}$ |



شکل ۲: مقایسه مقادیر مشاهداتی و پیش‌بینی شده برای هر یک از مدل‌های برخوردار از ورودی دبی

- تخمین بار معلق رسوبی با استفاده از داده‌های دبی و بارندگی برای حوضه سنگورچای

در دومین بخش از تحقیق، هر دو داده دبی و بارندگی به‌عنوان داده‌های ورودی در نظر گرفته شد. انواع ساختارهای لایه ورودی نیز برای تخمین بار معلق رسوبی در مدل‌های شبکه عصبی مصنوعی آزمایش گردید. برای مدل FFBP بهترین نتیجه برای ساختار برخوردار از ۳ گره در لایه پنهان و ۴ گره در لایه ورودی به‌دست آمد. در این حالت مقدار  $RMSE$  و  $R^2$  به‌ترتیب ۲۸۴ و ۰/۹۱۶۹ برآورد گردید. مقادیر فوق در (جدول ۴) نشان داده شده است. کارایی مدل RBF با مقادیر  $RMSE$  (۲۶۵ میلی‌گرم در لیتر) و  $R^2$  (۰/۹۲۵۱)، بهتر از مدل FFBP بوده است. نتایج نشان می‌دهد که بهره‌گیری از دو داده دبی و بارندگی به‌عنوان لایه ورودی در مقایسه با بهره‌گیری از داده‌های دبی به نتایج بهتری دست می‌یابد. با این حال به نظر می‌رسد که مدل RBF و FFBP در مقادیر دبی کم به تخمین‌های منفی دست می‌یابند. نمودار پراکنش و مقادیر تخمین زده بار رسوبی هر یک از مدل‌ها در صورت استفاده از پارامتر دبی و بارندگی در (شکل ۳) نمایش داده شده است.

جدول ۴- بررسی ساختارها و کارایی مدل FFBP با بهره‌گیری از داده دبی و بارندگی در دوره تست شده

| مدل FFBP |                              |                         | ساختار ورودی مدل                      |
|----------|------------------------------|-------------------------|---------------------------------------|
| $R^2$    | RMSE بر حسب میلی‌گرم در لیتر | تعداد گره در لایه پنهان |                                       |
| ۰/۹۰۲۶   | ۳۱۵                          | ۳                       | $R_t, R_{t-1}, R_{t-2}, Q_t$          |
| ۰/۸۹۱۴   | ۳۴۶                          | ۵                       | $R_t, R_{t-1}, R_{t-2}, Q_t, Q_{t-1}$ |
| ۰/۹۱۶۹   | ۲۸۴                          | ۳                       | $R_t, R_{t-1}, Q_t, Q_{t-1}$          |

جدول ۵- بررسی ساختارها و کارایی مدل RBF با بهره‌گیری از داده دبی و بارندگی در دوره تست شده

| مدل RBF |                              | ساختار ورودی مدل                      |
|---------|------------------------------|---------------------------------------|
| $R^2$   | RMSE بر حسب میلی‌گرم در لیتر |                                       |
| ۰/۹۱۲۴  | ۲۸۳                          | $R_t, R_{t-1}, R_{t-2}, Q_t$          |
| ۰/۹۰۱۳  | ۲۹۷                          | $R_t, R_{t-1}, R_{t-2}, Q_t, Q_{t-1}$ |
| ۰/۹۲۵۱  | ۲۶۵                          | $R_t, R_{t-1}, Q_t, Q_{t-1}$          |


در نهایت برای ارزیابی قابلیت مدل‌های RBF و FFBP از سیستم اطلاعاتی آکائیک استفاده شد. معادله آکائیک به‌صورت زیر می‌باشد:

$$AIC = N \times \ln(RMSE) + 2k \quad \text{رابطه (۱۶)}$$

در اینجا  $N$  تعداد نمونه‌ها در مجموعه آزموده شده و  $K$  تعداد پارامترهای مدل یا وزن داده‌ها می‌باشد. معادله ۱۶ نشان می‌دهد که با افزایش مقدار  $K$  مقدار  $AIC$  افزایش می‌یابد لیکن اگر مقادیر  $RMSE$  کم‌تر از سایر مدل‌ها باشد مقادیر  $AIC$  کم‌تر خواهد بود. مقادیر  $AIC$  برای دوره تست شده در (جدول ۶) نشان داده شده است. (جدول ۶) نشان می‌دهد که RBF در حوضه رودخانه سنگورچای دارای کم‌ترین مقادیر  $AIC$  به مقدار ۱۰۴۲ می‌باشد.

جدول ۶- مقادیر آکائیک برای هر یک از مدل‌های مورد استفاده

| مدل‌ها | RMSE(mg/l) | k | AIC  |
|--------|------------|---|------|
| FFBP   | ۲۸۴        | ۸ | ۱۰۵۹ |
| RBF    | ۲۶۵        | ۶ | ۱۰۴۲ |



شکل ۳: مقایسه مقادیر مشاهداتی و پیش‌بینی شده برای هر یک از مدل‌های برخوردار از ورودی دبی و بارندگی

در کل نتایج نشان می‌دهد که مدل RBF در صورت استفاده از ورودی دبی و بارندگی، با مقادیر  $R^2$  و RMSE به ترتیب ۲۶۵ میلی گرم در لیتر و ۰/۹۲۵۱ به بهترین نتیجه در تخمین بار معلق رسوبی دست می‌یابد. این در حالی است که مدل FFBP در صورت استفاده از ورودی دبی و عدم ورود داده‌های بارندگی با مقادیر ۰/۹۰۴۱ برای پارامتر  $R^2$  و ۳۲۷ میلی گرم در لیتر برای پارامتر RMSE در بهترین ساختار ورودی نسبت به سایر مدل‌ها به نتایج ضعیفی دست یافته است؛ بنابراین چنین می‌توان استدلال نمود که در صورتی که از دو پارامتر دبی و بارندگی در کنار هم استفاده شود بهترین نتیجه در تخمین بار معلق رسوبی به دست می‌آید.

### نتیجه‌گیری

در این تحقیق روابط بین متغیرهای دبی، بارندگی و بار معلق رسوبی روزانه در قالب ۲ مدل پیش‌خور پس انتشار (FFBP) و تابع پایه شعاعی (RBF) مورد بررسی قرار گرفت. به نظر می‌رسد که استفاده از داده دبی به تنهایی در ورودی مدل نمی‌تواند نتایج رضایت بخشی را در شبیه‌سازی بار معلق رسوبی به دست آورد. بهره‌گیری از داده‌های

بارندگی در کنار دبی می‌تواند باعث بهبود نتایج شود. بهره‌گیری از داده بارندگی نیز به‌تنهایی به نتایج مطلوبی دست نمی‌یابد. علت این امر چشم‌پوشی از خصوصیات حوضه از قبیل فرآیند حمل بار رسوبی و فرسایش می‌باشد. بهترین مقدار RMSE زمانی حاصل می‌شود که هر دو پارامتر دبی و بارندگی به‌عنوان ورودی مدل در نظر گرفته شوند. مقادیر RMSE اطلاعات ارزشمندی را درباره بهترین ساختار ورودی در مدل‌های ANN ارائه می‌دهد. بررسی مقادیر RMSE کاربر را در انتخاب تعداد مناسب گره‌ها در لایه ورودی راهنمایی کرده و با جلوگیری از تکرار فرآیند تعلیم مانع از اتلاف زمان می‌گردد. در این تحقیق، مدل RBF در صورتی که از دو پارامتر دبی و بارندگی استفاده نماید با برخورداری از مقادیر  $0/9251$  و  $265$  میلی‌گرم در لیتر برای پارامترهای  $R2$  و RMSE در مقایسه با مدل دیگر به بهترین نتیجه دست یافته است. این در حالی است که مدل FFBP در صورتی که از پارامتر دبی استفاده نماید با برخورداری از مقادیر  $0/9041$  و  $327$  میلی‌گرم در لیتر برای پارامترهای  $R2$  و RMSE در مقایسه با مدل دیگر به ضعیف‌ترین نتیجه دست یافته است. در کل، مدل‌های RBF و FFBP به نتایج مشابهی در شبیه‌سازی دست می‌یابند. با این حال مدل RBF از مزایایی برخوردار است. مدل FFBP به علت طراحی تصادفی وزن‌های اولیه قبل از هر شبیه‌سازی، کارایی‌های متفاوتی را برای ساختارهای شبکه ارائه نموده است؛ بنابراین برای به‌دست آوردن بهترین کارایی در این مدل به شبیه‌سازی زیادی نیاز است. برخلاف آن، مدل RBF تخمین بار معلق رسوبی را منحصر با یک شبیه‌سازی انجام می‌دهد. مدل‌های ANN به علت روابط غیرخطی و تعلیم فرآیند تعلیم به تمام مجموعه داده‌های ورودی نسبت به سایر مدل‌ها در فرآیند شبیه‌سازی بار معلق رسوبی به نتایج مطلوبی دست یافته و موفقیت آن‌ها نسبت به سایر روش‌ها امری بدیهی است.

## منابع

- دهقانی، ا؛ زنگانه، م؛ مساعدی، ا؛ کوهستانی، ن (۱۳۸۸)، «مقایسه تخمین بار معلق به دو روش منحنی‌سنجه رسوب و شبکه عصبی مصنوعی»، *علوم کشاورزی و منابع طبیعی*، شماره ۱۶، صص ۵۱-۳۶.
- دهقانی، ا؛ محمدی، م؛ هزارجریبی، ا (۱۳۸۹)، «تخمین رسوب معلق رودخانه بهشت‌آباد با استفاده از شبکه عصبی مصنوعی»، *پژوهش‌های حفاظت آب‌وخاک*، شماره ۱۷، صص ۱۶۸-۱۵۹.
- رضایی بنفشه، م؛ فیض اله پور، م؛ صدرافشاری، س (۱۳۹۲)، «استفاده از سیستم استنتاجی فازی عصبی در تخمین بار رسوبی و مقایسه آن با مدل‌های MLR و SRC در حوضه رودخانه قرانقو»، *پژوهش‌های جغرافیای طبیعی*، شماره ۴۵ (۲)، صص ۹۰-۷۷.

- Bhattacharya, B., price, R., Solomatine, D., (2005), "Data- driven modeling in the context of sediment transport", *Phys Chem. Earth*, 30: 297-302.
- Brikundavyi, S., Labib, R., Trung, HT., Rousselle, J., (2002), "Performance of neural networks in daily streamflow forecasting", *J. Hydrol Eng*, 7 (5): 392-398.
- Cigizoglu, H. K., (2003), "Estimation, forecasting and extrapolation of acceleration data by artificial neural networks", *Hydrol Sci. J*, 43 (3): 349-361.
- Cigizoglu, H. K., Kisi, O., (2005), "Flow prediction by three back propagation techniques using K-fold partitioning of neural network training data", *Nordic Hydrol*, 36 (1): 1-16.
- Cigizoglu, H. K., Kisi, O., (2006), "Methods to improve the neural network performance in suspended sediment estimation", *Journal of Hydrology*, 317 (3): 221-238.
- Fernando, D. A. K., Jayawardena, A. W., (1998), "Runoff forecasting using RBF networks with OLS algorithm", *Hydrol Eng*, 3 (3): 203-209.
- Goh, A. T. C., (1995), "Back-propagation neural networks for modeling complex systems", *Artificial Intelligence in Engineering*, 9: 143-151.
- Kisi, O., (2004), "Multi-layer Perceptrons with Leven berg-marquardt optimization algorithm for suspended sediment concentration prediction and estimation", *Hydrological Sciences Journal*, 49 (6): 1025-1040.
- Kisi, O., (2005), "Suspended Sediment estimation using neuro-fuzzy and neural network approaches", *Hydrological Sciences Journal*, 50(4): 683-696.
- Maier, H. R., Dandy, G. C., (2000), "Neural network for the prediction and forecasting of water resources variables: a review of modeling issues and applications", *Environ Model Software*, 15 (2): 101-124.
- Masters, T., (1993), *"Practical neural network recipes C++ san diego"*, Academic Press, San Diego, California, USA.
- Minns, A.W., Hall, M. J., (1996), "Artificial neural networks as rainfall runoff models". *Hydrol Sci J*, 41 (3): 399-417.
- Raghuwanshi, N., Singh, R., Reddy L., (2006), "Runoff and sediment yield modeling using artificial neural networks: upper Siwane River, India", *J. HydrolEng*, 11 (1): 71-9.
- Ray, C., Klindworth, K. K., (2000), "Neural networks for agricultural vulnerability assessment of rural private wells", *J. Hydrol Eng*, 5 (2): 162-171.

- Shin, H. S., Salas, J. D., (2000), "Regional drought analysis based on neural networks". *J Hydrol Eng*, 5 (2): 145–55.
- Smith, M., (1993), "neural networks for statistical modeling, New York", *John Wiley & Sons*.
- Subasia, A., Erçelebib, E., (2005), "Classification of EEG signals using neural network and logistic regression", *Computer Methods and Programs in Biomedicine*, 78 (2): 87-99.
- Tayfur, G., Guldal, V., (2006), "Artificial neural networks for estimating daily total suspended sediment in natural streams", *Nordic Hydrology*, 37: 69-79.
- Thandaveswara, B. S., Sajikumar, N., (2000), "Clasification of river basins using artificial neural network", *J. Hydrol .Eng*, 5 (3): 290–298.
- Tokar, A. S., Johnson, P. A., (1999), "Rainfall–runoff modelling using artificial neural networks", *J. Hydrol. Eng*, 4 (3): 232–239.
- Werner, D., Francisco, J. A., (2003), "Artificial intelligence in the life sciences", *Artif Intell Rev*, 20: 7-11.