

مدل باز معلق رودخانه‌ها با استفاده از شبکه‌های عصبی مصنوعی*

طاهر رجائی^(۱)

سید احمد میر باقری^(۲)

چکیده پیش‌بینی و تخمین باز رسوب رودخانه‌ها در پژوهش‌های آینه از اهمیت بالایی برخوردار است. با توجه به پیچیدگی پدیده رسوب و عدم توانایی تعیین دقیق معادلات حاکم، به خاطر وجود پارامترهای مختلف و تأثیر تعییرات مکانی و زمانی شرایط هیدرولوژیکی حوضه آبریز و مشکلات ناشی از تعیین تأثیرات آن‌ها، محققان به استفاده از مدل‌های جعبه سیاه، نظیر شبکه‌های عصبی مصنوعی، روی آوردند. در این مقاله در مورد کارایی این شبکه‌ها در تخمین و پیش‌بینی باز معلق رودخانه‌ها، مطالعاتی انجام گرفته است. در شبکه‌های ایجاد شده، در انواع تسمیم بندي مجموعه داده‌ها، انواع ترکیبات و رودی شبکه، تعداد لايهای شبکه، تعداد نورون‌های لايهای ورودی و مخفی شبکه و ... تحقیقاتی انجام گرفته است. در مدل‌های طراحی شده با دادن سری زمانی دبی جریان و غلظت باز معلق در زمان‌های قبل، می‌توان غلظت باز معلق در زمان آینده را پیش‌بینی نمود. برای افزایش کارایی مدل‌ها، از تکیک توقف زود هنگام (Early Stopping) استفاده شده و در نهایت برای ارزیابی نتایج، مقایسه‌ای با روش مرسوم منحنی سنجه رسوب نیز انجام گرفته است. نتایج، نشان دهنده برتری مدل‌های شبکه عصبی بوده است.

واژه‌های کلیدی: باز معلق رودخانه، شبکه عصبی، پرسپترون چند لایه، پیش‌بینی رسوب، توقف زود هنگام، منحنی سنجه

Suspended Sediment Model in Rivers Using Artificial Neural Networks

T. Rajaei

S. A. Mirbagheri

Abstract Estimating the sediment being transported by river flow is one of the important aspects in water resources engineering. Erosion and sediment transport phenomena in watersheds and rivers are complex hydrodynamic problems. Due to large number of obscure parameters involved in these phenomena, the theoretical governing equations may not be of much advantage in gaining knowledge of the overall process. Researchers have developed practical techniques that do not require much theory, algorithm, or rule development, and thus, reduce the complexities of the problem. One such technique is known as Artificial Neural Networks (ANN). In this paper, Auto-Regressive ANN was utilized to estimate suspended sediment load in rivers. Various network topology, data partitioning and parameters were examined to find the best network with the best results. For increasing the efficiency of the models, Early Stopping technique has been used. Results of these networks were compared to the conventional sediment rating curves method and it was shown that ANN presented better results especially in peak flow discharges. Trained networks were able to model the sediment transport phenomena in rivers successfully, presumably because of the superior capability of ANN in nonlinear mapping, without any extra information from governing equation.

Key Words Artificial neural networks, Suspended sediment prediction, Sediment rating curve, Modelling.

* تاریخ دریافت نسخه نهایی اصلاح شده ۸۷/۰۷/۸ و تاریخ تصویب مقاله ۸۷/۱۰/۲.

۱- دانشجوی دکترای عمران، آب-محیط زیست، دانشکده عمران، دانشگاه صنعتی خواجه نصیرالدین طوسی

۲- دانشیار، دانشکده عمران، دانشگاه صنعتی خواجه نصیرالدین طوسی

...

شبکه عصبی در تخمین ضربی هدایت هیدرولیکی و ضربی آب گذری آبخوان دارد. در سال ۲۰۰۴، مرادخانی و همکارانش [۵]، دبی جریان عبوری از رودخانه را با استفاده از شبکه SORB که شبکه‌ای با ساختار ترکیبی (Radial Basis Function) و از دو شبکه پایه شعاعی (Self-Organizing Feature Map) بود، مورد بررسی قرار داده و به بحث در مورد نتایج بدست آمده پرداختند که نتایج تحقیق آنها، توانایی مدل ترکیبی شبکه عصبی را نشان می‌داد.

در تحقیق دیگری برین و یانگ [۶] در سال ۲۰۰۵، سیلان عبوری را پیش‌بینی نمودند. از جمله مطالعات انجام گرفته در زمینه انتقال رسوب، می‌توان به تحقیق انجام یافته توسط ناجی (Nagy) و همکارانش [۷] در سال ۲۰۰۱، برای پیش‌بینی دبی رسوبی رودخانه‌ها با استفاده از داده‌های اندازه‌گیری شده نظری: عمق، دبی و سرعت جریان، شبیب بستر، منحنی دانه‌بندي رسوب، عرض بستر، عدد فرود، سرعت سقوط ذرات و ... اشاره کرد. آنها برای این کار از شبکه پرسپترون چند لایه با الگوریتم پس انتشار خطا (Back Propagation) استفاده کردند. اگرچه این تحقیق دارای نتایج مثبتی است، ولی با توجه به تنوع داده‌های مورد نیاز برای شبکه و محدودیت داده‌های اندازه‌گیری شده در رودخانه‌ها، چندان کاربردی به نظر نمی‌رسد. در تحقیق دیگری جین (Jain) [۸] در سال ۲۰۰۱، با توجه به دبی جریان و دبی رسوب و اشل، در دو محل از رودخانه می‌سی سی پی به تخمین بار معلق پرداخت. نتایج این تحقیق، حاکی از عملکرد مناسب شبکه پرسپترون چند لایه بود. در سال ۱۳۸۱، متظر و همکارانش [۹] برای تخمین میزان رسوب رودخانه بازفت در محل ایستگاه آب سنجی مرغک از دو شبکه پرسپترون و شبکه پاد انتشار گراسبرگ (Counter Propagation) استفاده کردند. آنها با استفاده از شبکه‌های ایجاد شده به بررسی تأثیر دمای متوسط ماهانه در مقدار رسوب انتقالی پرداخته و در آخر نیز به مقایسه روش شبکه

مقدمه

تخمین و پیش‌بینی دبی رسوب، در طیف گسترده‌ای از مسائل، نظیر: مهندسی رودخانه‌ها، طراحی سدها، انتقال آلدگی، تأثیرات زیست محیطی، تأثیرات آبخیزداری و بسیاری از بحث‌های منابع آب، کاربرد دارد. روش‌های تخمین میزان رسوب را می‌توان در دو گروه، دسته‌بندی کرد. رویکرد روش‌های سری اول، ایجاد مدل‌های ریاضی با توجه به مفاهیم فیزیکی انتقال ذرات و حل معادلات هیدرودینامیک رسوب به همراه حل میدان جریان است. با توجه به این‌که در این روش‌ها به داده‌های متنوعی نیاز بوده و از طرفی نتایج حاصل از آن‌ها حتی در یک ایستگاه از یک رودخانه مشخص معمولاً یکسان و مشابه نبوده و انتخاب یکی از آن‌ها مشکل می‌باشد، محققان به جستجوی راه‌های عملی برای پیش‌بینی رسوب برآمده‌اند و تلاش آن‌ها باعث ایجاد روش دیگری به نام روش منحنی سنجه رسوب شده است.

در این روش، یک منحنی توانی به فرم $Q_s = aQ_w^b$ بر داده‌های آماری دبی جریان و دبی رسوبی برآذش داده می‌شود که در آن: Q_s دبی رسوب، Q_w دبی آب و a و b ، ضرایب ثابت می‌باشند. از جمله تحقیقات صورت گرفته با این روش، می‌توان به کار میرباقری و همکارانش [۱] اشاره کرد.

به طور کلی پدیده رسوب، یک مسئله نگاشت غیرخطی است و شبکه‌های عصبی به عنوان ابزاری توانمند، قادرند به نوعی روابط غیرخطی حاکم بر فرآیندهای رسوبی را تعیین نمایند. امروزه از این مدل‌ها در طیف وسیعی از تحقیقات استفاده می‌شود که از جمله آن‌ها می‌توان به کار چن و آدامز [۲] و سرینی واسولا و جین [۳] در سال ۲۰۰۶، در مدل کردن پدیده بارش- رواناب اشاره کرد. در تحقیق دیگری، گارسیا و شیجیدی [۴] در سال ۲۰۰۶ از مدل شبکه عصبی برای تخمین پارامترهای آب‌های زیر زمینی استفاده کردند. نتایج بدست آمده از این تحقیق، حکایت از توانایی مدل

افزایش می‌یابد که نشان دهنده ضعف شبکه‌های عصبی در این حالت می‌باشد. در تحقیق دیگری در سال ۲۰۰۵، سارانجی و باچاریا [13] به مقایسه مدل شبکه عصبی و روش‌های رگرسیون در پیش‌بینی رسوب و فرسایش پرداختند. در این تحقیق، مدل شبکه عصبی به منظور پیش‌بینی و تخمین بار معلق رودخانه‌ها به کار گرفته شده است. برای این کار از داده‌های ایستگاه‌های ساکرامنتو و فریپورت رودخانه ساکرامنتو آمریکا استفاده شده است. در ایجاد مدل‌های شبکه عصبی، حالات مختلفی در نظر گرفته شده و در هر حالت بحث‌هایی نیز بر روی عملکرد و ساختار مدل، انجام یافته است. در ادامه به منظور بهبود عملکرد مدل‌ها، از تکنیک توقف زود هنگام استفاده شده و مقایسه‌ای نیز با روش منحنی سنجه رسوب انجام گرفته است.

تبیین مسائله

برای مدل‌سازی و تحلیل سری‌های زمانی، روش‌هایی به کار گرفته می‌شود که این روش‌ها در طیف گسترده‌ای که در یک‌سوی آن مدل‌های مفهومی با اساس کاملاً فیزیکی و در سوی دیگر آن مدل‌های جعبه‌سیاه، نظری مدل تجربی غیرخطی شبکه عصبی مصنوعی است، قرار می‌گیرد. در اکثر مدل‌های به کار گرفته شده برای مدل‌سازی سری‌های زمانی، خروجی مدل در زمان افزون بر آن که به مقادیر ورودی‌های آن گام زمانی بستگی دارد، به مقادیر خروجی مدل در یک یا چند گام زمانی عقب‌تر نیز وابسته است. این مدل‌ها که به مدل‌های اتورگرنسیو معروفند، در مقایسه با مدل‌های غیر آن، این توانایی را دارند که با تعداد متغیرهای کم‌تری توصیف شوند. علت وجود چنین مزیتی این است که در این مدل‌ها قسمت و یا کل اطلاعاتی که در گذشته به مدل معرفی شده است، اثرشان را به صورت تجمعی بر روی خروجی مدل در گام زمانی پیشین نشان می‌دهند. بنابراین در این مدل‌ها ارائه آخرین

عصبی با روش مرسوم منحنی سنجه پرداختند. نتایج نشان دهنده، برتری روش شبکه عصبی مصنوعی بود. در سال ۲۰۰۲، سیگر اوغلو (Cigizoglu) [10] روش شبکه عصبی مصنوعی را به جای روش‌های متداول که پیچیده و زمان‌گیر هستند، در تخمین دبی رسوبی مورد استفاده قرار داد. وی برای پیش‌بینی دبی رسوبی عبوری از یک ایستگاه، از مقادیر دبی جریان و دبی رسوب در ایستگاه مجاور استفاده کرد. در ادامه کار، وی به مقایسه نتایج به دست آمده از روش شبکه عصبی مصنوعی با نتایج به دست آمده از روش کلاسیک رگرسیون پرداخته و مشاهده کرد که نتایج مدل شبکه عصبی مصنوعی به نتایج تجربی نزدیک‌تر هستند. در ادامه کار قبلی، سیگر اوغلو [11] در سال ۲۰۰۲، از اطلاعات دو رودخانه در شمال انگلستان استفاده کرد و به پیش‌بینی دبی رسوبی پرداخت. در ادامه کار، وی به مقایسه دو روش شبکه عصبی مصنوعی و روش منحنی سنجه پرداخته و نشان داد که مدل شبکه عصبی مصنوعی، حتی در غیاب داده‌های مشاهداتی کافی، می‌تواند تخمین درستی از میزان رسوبات رودخانه ارائه دهد. او نتیجه گرفت که مدل شبکه عصبی حتی قادر به مدل کردن شرایطی نظری پدیده هیسترزیس (Hysteresis) و روابط جریان نیز می‌باشد. در تحقیقی دیگر، طاهر شمسی و هم‌کارانش [12] در سال ۱۳۸۴، از شبکه عصبی پرسپترون و الگوریتم آموزش Levenberg-Marquardt برای پیش‌بینی رسوب استفاده کردند. در این تحقیق، داده‌های ورودی مدل شامل: عرض، عمق جریان، شب طولی کانال، دبی جریان و قطر متوسط ذرات رسوب بودند. برای رسیدن به نتایج بهتر، داده‌ها یکنواخت‌تر شده و داده‌های ورودی بر حسب نوع جریان با توجه به عدد فرود (جریان زیر بحرانی یا فوق بحرانی) جدا سازی شده و برای هر یک، مدل عصبی جداگانه‌ای طراحی شده است. با این دسته‌بندی، خطاهای ایجاد شده برای جریان زیر بحرانی به طرز قابل ملاحظه‌ای کاهش یافته؛ ولی برای جریان فوق بحرانی

...

از آن جا که در این تحقیق از شبکه‌های عصبی اتورگرسیو ناقص استفاده شده است، درباره این نوع شبکه‌ها توضیح داده می‌شود.

شبکه‌های عصبی اتورگرسیو. شبکه‌های عصبی اتورگرسیو، مدل‌هایی هستند که در آن‌ها خروجی مدل در گام زمانی t ، به مقادیر خروجی مدل در یک یا چند گام زمانی عقب‌تر نیز وابسته است. این مدل‌ها توانایی آن را دارند که با تعداد متغیرهای کم‌تری توصیف شوند. علت وجود چنین مزیتی این است که در این مدل‌ها قسمت و یا کل اطلاعاتی که درگذشته به مدل معرفی شده، اثرشان را به صورت تجمعی بر روی خروجی مدل در گام زمانی پیشین نشان می‌دهند. این مدل‌ها بر دو قسمت‌دادهای عصبی اتورگرسیو تمام عیار و مدل‌های عصبی اتورگرسیو ناقص.

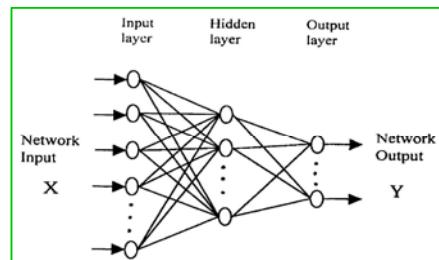
در مدل‌های عصبی اتورگرسیو تمام عیار، خروجی مدل در زمان t به عنوان ورودی مدل برای پیش‌بینی مقدار سری زمانی در زمان $t+1$ به کار گرفته می‌شود، ولی در مدل‌های اتورگرسیو ناقص، به جای فرستادن خروجی مدل در زمان t به عنوان ورودی برای پیش‌بینی گام زمانی $t+1$ ، مشاهده درست متاظر با خروجی یاد شده به عنوان ورودی برای پیش‌بینی گام زمانی $t+1$ ، فرستاده می‌شود. هدف از به کار گیری مدل اتورگرسیو ناقص در این تحقیق، لحاظ نمودن داده‌های واقعی (مشاهداتی) که برداشت‌هایی کاملاً واقعی از پدیده هستند، به جای داده‌های محاسبه شده توسط مدل که ناشی از عملکرد محاسباتی مدل هستند، می‌باشد. خاطر نشان می‌شود که صرف نظر از دقیقت پیش‌بینی مدل، واقعیت آن چیزی است که پس از پیش‌بینی مدل، مشاهده می‌شود. بنابراین استفاده از مقدار مشاهده‌ای (واقعی) در ورودی گام زمانی بعد، به جای استفاده از مقدار محاسبه‌ای مدل، به معنای نفی توانمندی مدل در

اطلاعات به دست آمده از پدیده مورد تحقیق به همراه خروجی مرحله قبل، برای پیش‌بینی داده سری زمانی آینده کفايت می‌کند.

با توجه به مطالب فوق، پیش‌بینی بار معلق عبوری از رودخانه که در مقوله تحلیل و مدل‌سازی سری‌های زمانی قرار می‌گیرد، به کارگیری مدل‌های اتورگرسیو را طلب می‌کند. بنابراین در این تحقیق، از شکل خاصی از شبکه عصبی که شبکه عصبی اتورگرسیو (Auto-Regressive Artificial Neural network) نامیده می‌شود، استفاده می‌شود.

شبکه‌های عصبی مصنوعی

یک شبکه عصبی مصنوعی بنا به تعریف، یک سیستم پردازش اطلاعات موازی است که عملکرد اجرایی مشخصی برگرفته از ساختار بیولوژیکی شبکه مغز انسان دارد [14]. این سیستم‌ها قادرند روابط پیچیده و غیرخطی بین ورودی و خروجی‌های یک سیستم فیزیکی را توسط شبکه‌ای از گره‌ها که همگی به‌هم متصل هستند، تعیین نمایند. در این سیستم‌ها، میزان فعالیت هر یک از این اتصالات توسط اطلاعات تاریخی تنظیم می‌شود (فرآیند یادگیری). در شکل زیر، ساختار استاندارد یک شبکه عصبی نشان داده شده است. این شبکه از سه لایه ورودی، مخفی و خروجی، تشکیل شده است. شبکه، ورودی‌های مسئله را دریافت کرده و پس از پردازش، خروجی مسئله نتیجه می‌دهد.



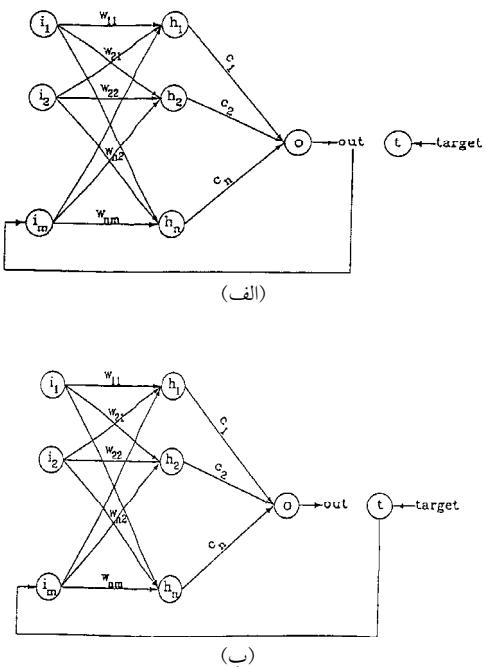
شکل ۱ ساختار یک شبکه عصبی مصنوعی استاندارد

۱۹۸۳-۱۹۸۸، برای مجموعه آموزشی و از ۱ اکتبر ۱۹۸۸ تا ۳۰ ژوئن ۱۹۸۹ برای مجموعه آزمایشی انتخاب شده است. برای ایستگاه ساکرامنتو نیز اطلاعات مربوطه از ۱ اکتبر سال ۱۹۷۶ تا ۳۰ سپتامبر سال ۱۹۷۸ به مدت دو سال برای مجموعه آموزشی و از ۱ اکتبر سال ۱۹۷۸ تا ۳۰ سپتامبر سال ۱۹۷۹، به مدت یک سال برای مجموعه آزمایشی انتخاب شده است. توجه شود که بازه زمانی آموزش و آزمایش شبکه، در هر ایستگاه یکی است. در یک ایستگاه (فریپورت)، کل سال در نظر گرفته شده و در ایستگاه دیگر (ساکرامنتو) ۹ ماه سال (به غیر از تابستان)، در نظر گرفته شده است. هدف بررسی دو حالت مختلف و در صورت لزوم استفاده از ماههای با روند مشابه بارندگی و استثنای کردن سه ماه تابستان بوده است.

در این مطالعه از داده‌های دبی جریان و غلظت بار معلق در گام‌های زمانی گذشته استفاده شده و غلظت بار معلق در گام زمانی آینده پیش‌بینی می‌شود. لازم به ذکر است که عمدۀ آورد رسوبی رودخانه‌ها به صورت بار معلق می‌باشد. آزمایشات نشان می‌دهد که در یک پروفیل قائم در جریان آب، ۷۰ الی ۹۰ درصد بار کل رسوب را بار معلق تشکیل می‌دهد [۱۵]. بنابراین در برآورد بار رسوبی، عمدتاً بار معلق را محاسبه کرده و درصدی از آن را بسته به شرایط منطقه، به عنوان بار کف به آن اضافه می‌نمایند.

در رودخانه‌های طبیعی، پارامتر دبی جریان بر مقدار دبی رسوبی تأثیر می‌گذارد. به طور کلی این دو پارامتر، مستقل از هم نمی‌باشند. بنابراین استفاده از مدلی که تأثیر این دو پارامتر بر یکدیگر را در نظر می‌گیرد، بسیار منظر ثمر خواهد بود. از طرفی در اکثر ایستگاه‌های آب‌سنگی موجود (به‌ویژه در ایران)، اطلاعات عمدتاً در حد عمق جریان، دبی جریان و دبی رسوبی هستند و اطلاعات دیگری نظیر منحنی دانه‌بندی مواد رسوبی، شبی بستر، سرعت سقوط ذرات، عدد فرود و ... در دسترس نمی‌باشد؛ لذا در انتخاب دو

پیش‌بینی یا اعلام عدم اطمینان به پاسخ مدل در مرحله قبل نیست. در شکل زیر، مدل‌های تمام عیار و ناقص شبکه‌های عصبی اتورگرسیو نشان داده شده است:



شکل ۲ (الف) مدل تمام عیار شبکه‌های عصبی اتورگرسیو،
(ب) مدل ناقص شبکه‌های عصبی اتورگرسیو

آنالیز داده‌ها. این مطالعه بر روی دو ایستگاه آب‌سنگی فریپورت (Station ID:11447650) و Freeport (Station ID:11447500) در رودخانه ساکرامنتو در ایالت کالیفرنیای آمریکا انجام گرفته است. داده‌های سری زمانی روزانه دبی جریان و غلظت بار معلق برای این ایستگاه‌ها از طریق سایت ایترننسی USGS اخذ شده و بعد از امتحان داده‌ها و توجه به این نکته که در بین داده‌ها از لحظه زمانی شکافی وجود نداشته باشد، دو پریود زمانی برای مجموعه آموزشی (Training Set) و مجموعه آزمایشی (Testing Set) انتخاب شده است. برای ایستگاه فریپورت، اطلاعات مربوطه از ۱ اکتبر تا ۳۰ ژوئن به مدت پنج سال، از سال

...

$$Q_t, Q_{t-1}, Q_{t-2} - ۳$$

$$Q_{t-1}, Q_{t-2}, Q_{t-3} - ۴$$

$$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3} - ۵$$

در همه حالات فوق، در لایه خروجی، یک نورون وجود دارد که C_t یعنی غلظت بار معلق در زمان t را نتیجه می‌دهد.

با توجه به محدودیت توابع آستانه نورون‌ها در مدل شبکه عصبی، ارائه نمونه‌های آموزشی و آزمایشی به صورت داده‌های خام اندازه گیری شده، باعث عدم دقت و کاهش سرعت شبکه می‌گردد. به همین دلیل در تحقیق حاضر، داده‌ها طبق رابطه زیر نرم‌الایزه شده و هنگام ارائه به شبکه، دارای مقادیری بین صفر تا ۱ هستند.

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

که در آن X داده به صورت خام، X_n داده نرم‌الایز شده، X_{\min} مینیمم داده‌ها و X_{\max} ماکریمم داده‌هاست.

بررسی ساختار مدل و تحلیل نتایج

تعیین ساختار یک مدل عصبی، از مهم‌ترین و مشکل‌ترین مراحل توسعه آن است. این کار به منظور پیکربندی مناسب شبکه‌ها و رسیدن به بهترین جواب ممکن انجام می‌گیرد. در این تحقیق، با تغییر تعداد نورون‌های لایه مخفی، تغییر ضریب ممتم، تغییر نرخ یادگیری و استفاده از توابع فعال‌ساز مختلف، بهترین شبکه برگزینده شده است. برای ساخت مدل‌ها از الگوریتم آموزشی Levenberg-Marquardt، برای لایه مخفی از تابع انتقال سیگموید، برای لایه خروجی از تابع انتقال سیگموید و در برخی حالات از تابع انتقال خطی، برای ضریب ممتم و نرخ یادگیری نیز از اعداد بازه $۰/۲$ الی $۰/۶$ استفاده شده است. در حالت (الف)، برای هر ترکیب (ترکیبات ۱ تا ۶)، تعداد نورون‌های مخفی که کم‌ترین مجموع مربعات خطا (SSE) را نتیجه دهد، انتخاب شده است. در جداول (۱) و (۲) نتایج

پارامتر دبی جریان و غلظت بار معلق در این تحقیق، این نکته مد نظر قرار گرفته است که تحقیق حاضر، جنبه کاربردی برای ایستگاه‌های آب سنجی موجود در داخل کشور را داشته باشد.

در مطالعه حاضر، دو نوع ترکیب برای ورودی شبکه در نظر گرفته شده است:

الف- ترکیباتی که در گام‌های زمانی گذشته از دبی جریان و غلظت بار معلق رودخانه به صورت توانم استفاده می‌کنند.

ب- ترکیباتی که در گام‌های زمانی گذشته فقط از دبی جریان رودخانه استفاده می‌کنند.

اهمیت ترکیب حالت (ب) زمانی بیشتر مشهود است که در گام‌های زمانی گذشته قادر اطلاعات غلظت بار معلق هستیم و می‌خواهیم در یک شکاف زمانی و یا پیش‌بینی بار معلق، اطلاعاتی از دبی بار معلق به دست آوریم. با توجه به توضیحات فوق، ترکیبات زیر برای حالت (الف) در نظر گرفته شد. C_t و Q_t به ترتیب دبی جریان و غلظت بار معلق در گام زمانی t می‌باشند.

$$C_{t-1}, Q_{t-1} - ۱$$

$$C_{t-1}, C_{t-2}, Q_{t-1}, Q_{t-2} - ۲$$

$$C_{t-1}, C_{t-2}, C_{t-3}, Q_{t-1}, Q_{t-2}, Q_{t-3} - ۳$$

$$C_{t-1}, Q_t, Q_{t-1} - ۴$$

$$C_{t-1}, C_{t-2}, Q_t, Q_{t-1}, Q_{t-2} - ۵$$

$$C_{t-1}, C_{t-2}, C_{t-3}, Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3} - ۶$$

در ترکیبات یک تا سه از دبی جریان در زمان t استفاده نشده، لذا از این سه ترکیب می‌توان برای پیش‌بینی غلظت بار معلق در زمان t استفاده کرد. در ترکیبات چهار تا شش، از دبی جریان در گام زمانی t نیز استفاده شده است؛ لذا از این ترکیبات برای تخمین غلظت بار معلق در زمان t استفاده می‌شود. برای حالت (ب) نیز ترکیبات زیر در نظر گرفته شد:

$$Q_t, Q_{t-1} - ۱$$

$$Q_{t-1}, Q_{t-2} - ۲$$

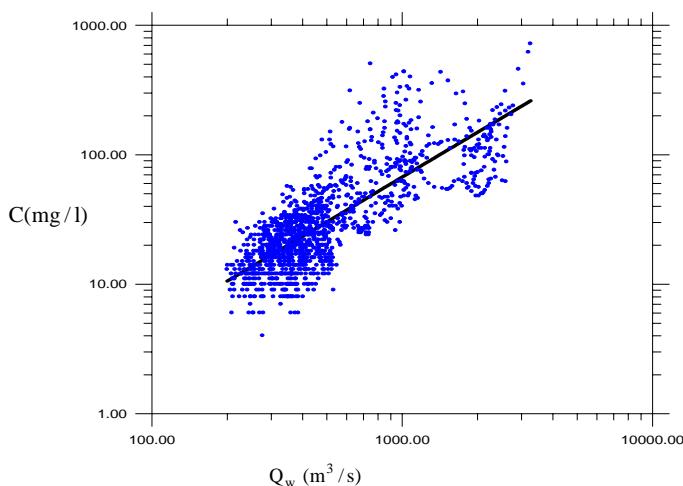
براین داده‌ها برازش داده شده و روابط زیر به ترتیب برای ایستگاه‌های فریپورت و ساکرامنتو به دست آمده است:

$$C = 0.02404 Q_w^{1.1489} \quad (2)$$

$$C = 0.19718 Q_w^{0.920144} \quad (3)$$

در شکل زیر، منحنی سنجه رسوب به دست آمده برای ایستگاه فریپورت نشان داده شده است:

ترکیبات مختلف ورودی مدل به صورت پارامترهای جذر میانگین مربعات خطأ (RMSE)، ضریب همبستگی (Correlation Coefficient) و کمترین مجموع مربعات خطأ آورده شده است. همچنان‌که در مقدمه آمده است، برای به دست آوردن منحنی سنجه رسوب، یک معادله توانی بر داده‌های دبی جریان و غلظت بار معلق برازش داده می‌شود. در تحقیق حاضر نیز یک معادله توانی



شکل ۳ منحنی سنجه رسوب به دست آمده برای ایستگاه فریپورت

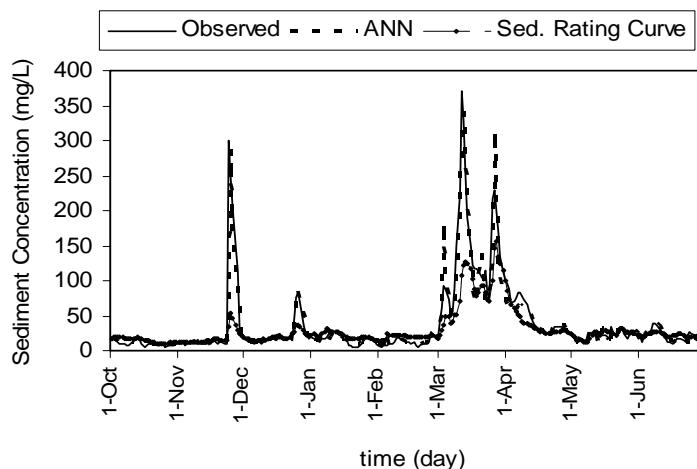
جدول ۱ نتایج حاصل از آموزش و آزمایش شبکه برای ایستگاه فریپورت برای ترکیبات حالت (الف)

مجموعه آزمایشی			مجموعه آموزشی			ردیف ردیف ردیف ردیف ردیف ردیف ردیف ردیف	ترکیبات مختلف ورودی مدل	نمایش نمایش نمایش نمایش نمایش نمایش نمایش نمایش			
غلاظت بار معلق			غلاظت بار معلق								
R	SSE $\times 10^6$	RMSE	R	SSE $\times 10^4$	RMSE						
۰/۸۶۹	۱/۹۹	۲۶/۹۹	۰/۹۱	۹/۹۷۳	۱۹/۰۸	۴	C_{t-1}, Q_{t-1}	۱			
۰/۸۶۷	۲/۰۵۴	۲۷/۳۹	۰/۹۷	۷/۸۰۲	۱۵/۷۲	۶	$C_{t-1}, C_{t-2}, Q_{t-1}, Q_{t-2}$	۲			
۰/۷۵۲	۲/۸۸۵	۳۳/۲۵	۰/۹۷	۷/۹۹۶	۱۵/۹۱۴	۸	$C_{t-1}, C_{t-2}, C_{t-3}, Q_{t-1}, Q_{t-2}, Q_{t-3}$	۳			
۰/۸۷۵	۱/۹۵۶	۲۶/۷۵	۰/۹۴۷	۷/۲۲۹	۱۵/۰۷۲	۵	C_{t-1}, Q_t, Q_{t-1}	۴			
۰/۹۱۶	۱/۳۱	۲۱/۸۳۱	۰/۹۸۵	۴/۱۹۶	۱۲/۳۲	۶	$C_{t-1}, C_{t-2}, Q_t, Q_{t-1}, Q_{t-2}$	۵			
۰/۷۱۲	۲/۴۵۴	۲۹/۹۴	۰/۹۶۱	۷/۲۱۳	۱۵/۴۵	۱۰	$C_{t-1}, C_{t-2}, C_{t-3}, Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	۶			
۰/۷۱۹	۵۳/۳۲	۱۳۹/۱۶۵	۰/۶۲۶	۱۹۳/۲۴	۵۰۴/۳۵	-	روش منحنی سنجه رسوب				

...

جدول ۲ نتایج حاصل از آموزش و آزمایش شبکه برای ایستگاه ساکرامنتو برای ترکیبات حالت (الف)

مجموعه آزمایشی			مجموعه آموزشی			ترکیبات مختلف ورودی مدل	نمودار		
غلظت بار معلق		غلظت بار معلق		R	SSE $\times 10^5$				
R	SSE $\times 10^5$	RMSE	R						
۰/۸۹۵	۲/۱۸۲	۲۴/۴۳	۰/۹۴۳	۱۱/۲۵	۵/۴۶۲	۳	C_{t-1}, Q_{t-1}		
۰/۹۲۲	۱/۶۳۱	۲۱/۰۹۲	۰/۹۹۰	۸/۴۰۶	۴/۵۸۶	۵	$C_{t-1}, C_{t-2}, Q_{t-1}, Q_{t-2}$		
۰/۸۵۵	۳/۳۱۶	۳۰/۰۹	۰/۹۹۲	۸/۹۳۷	۴/۶۳۵	۸	$C_{t-1}, C_{t-2}, C_{t-3}, Q_{t-1}, Q_{t-2}, Q_{t-3}$		
۰/۹۲۵	۱/۵۸۶	۲۰/۸۲	۰/۹۷۴	۹/۰۸	۴/۸۸۷	۵	C_{t-1}, Q_t, Q_{t-1}		
۰/۹۴۱	۱/۲۸۹	۱۸/۷۴۱	۰/۹۹۳	۷/۵۶۵	۴/۳۲۷	۷	$C_{t-1}, C_{t-2}, Q_t, Q_{t-1}, Q_{t-2}$		
۰/۸۹۳	۲/۳۹۱	۲۵/۰۳۴	۰/۹۸۹	۸/۶۲	۴/۵۴	۹	$C_{t-1}, C_{t-2}, C_{t-3}, Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$		
۰/۷۰۲	۴۹/۸۵۱	۷۷۸/۹۷	۰/۶۲۶	۱۹۶/۵۴	۲۷۶/۸۷	-	روش منحنی سنجه رسوب		



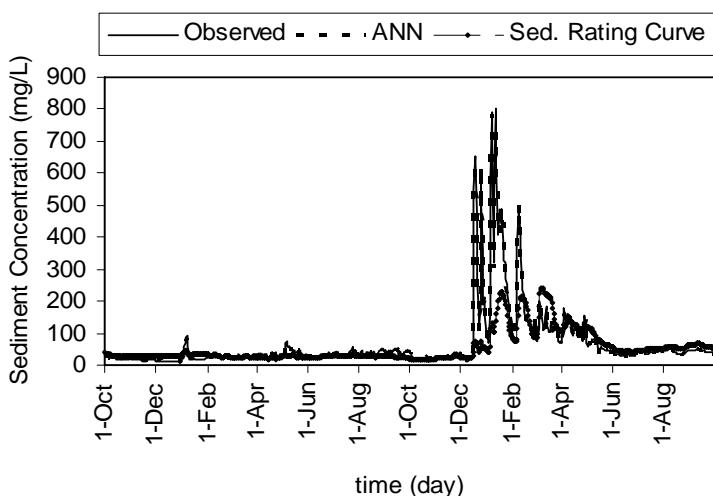
شکل ۴ غلظت رسوب مشاهداتی و محاسباتی از روش های شبکه عصبی و منحنی سنجه در ایستگاه فریپورت برای داده های آزمایشی

از بین ترکیبات مختلف ورودی، برای هر دو ایستگاه فریپورت و ساکرامنتو، ترکیب پنجم نسبت به حالات دیگر دارای نتایج بهتری است. در شکل (۴) غلظت بار معلق، اندازه گیری و محاسبه شده از روش های شبکه عصبی و منحنی سنجه

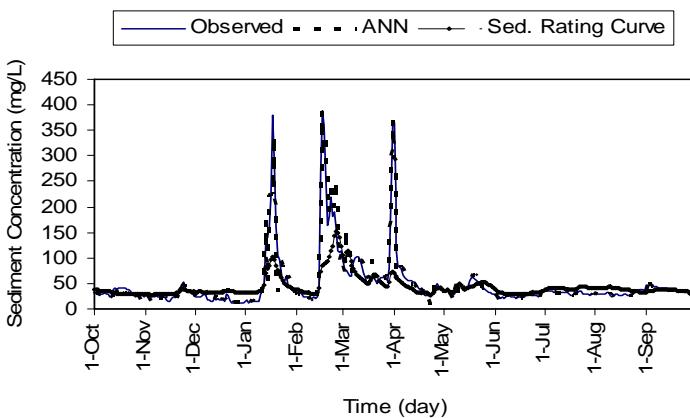
با توجه به جدول ها دیده می شود که مقادیر SSE و RMSE برای مدل ها خیلی کمتر از نتایج روشنایی سنجه است و ضریب همبستگی نیز برای اکثر مدل های عصبی بهتر از روشنایی سنجه بوده و نزدیک به یک است. با توجه به نتایج، دیده می شود که

بر پایه مقایسه هایی که به عمل آمده، مدل عصبی در کل فرآیند پیش بینی بار معلق، برتری محسوسی نسبت به روش منحنی سنجه داشته است. این مدل، فقط در شکل (۴) در دو پیک (قله)، پیش بینی خوبی نداشته، بلکه در واقع تخمین اضافی (Over Estimation) داشته است که به نظر می رسد این خطا ناشی از یادگیری اضافی در مرحله آموزش شبکه بوده است. برای رفع این مسئله و بهبود نتایج، از تکنیک توقف زودهنگام استفاده شد. در زیر، نتایج بدست آمده از این روش آمده است:

در ایستگاه فریپورت برای داده های آزمایشی نشان داده شده است. در شکل های (۵ و ۶) نیز این محاسبات و نتایج در ایستگاه ساکرامنتو، هم برای داده های آموزشی و هم برای داده های آزمایشی نشان داده شده است. همان طور که از شکل ها مشخص است، مدل شبکه عصبی خیلی بهتر از منحنی سنجه توانسته است رفتار غلط رسوی را یاد بگیرد و سپس پیش بینی نماید. توانایی مدل شبکه عصبی نسبت به منحنی سنجه بیشتر در پیش بینی و رفتارش در پیک ها (قله ها) مشهود است.



شکل ۵ غلط رسوی مشاهداتی و محاسباتی از روش های شبکه عصبی و منحنی سنجه در ایستگاه ساکرامنتو برای داده های آموزشی



شکل ۶ غلط رسوی مشاهداتی و محاسباتی از روش های شبکه عصبی و منحنی سنجه در ایستگاه ساکرامنتو برای داده های آزمایشی

...

و عملکرد آن را در مراحل مختلف آموزش مورد ارزیابی قرار می‌دهند.

در این تحقیق برای جلوگیری از بیش برازش و بهبود عملکرد مدل در پیش بینی بار معلق در کل بازه زمانی، از تکنیک توقف زودهنگام استفاده شده است. لذا با توجه به توضیحات ارائه شده، در ایستگاه فریپورت، اطلاعات مربوطه از ۱ اکتبر تا ۳۰ ژوئن به مدت سه دوره نه ماهه، از سال ۱۹۸۳ تا ۱۹۸۶ و نیز از ۱ اکتبر ۱۹۸۷ تا ۳۰ ژوئن ۱۹۸۸ برای مجموعه آموزشی، و از ۱ اکتبر ۱۹۸۶ تا ۳۰ ژوئن ۱۹۸۷ برای مجموعه اعتباری و از ۱ اکتبر ۱۹۸۸ تا ۳۰ ژوئن ۱۹۸۹ برای مجموعه آزمایشی انتخاب شد. برای ایستگاه ساکرامنتو نیز اطلاعات مربوطه از ۱ اکتبر سال ۱۹۷۵ تا ۳۰ سپتامبر سال ۱۹۷۷ به مدت دو سال برای مجموعه آموزشی و از ۱ اکتبر سال ۱۹۷۷ تا ۳۰ سپتامبر ۱۹۷۸ به مدت یک سال برای مجموعه اعتباری و از ۱ اکتبر سال ۱۹۷۸ تا ۳۰ سپتامبر ۱۹۷۹ به مدت یک سال برای مجموعه آزمایشی انتخاب شد. توجه شود که بازه‌های زمانی مجموعه‌های آموزشی، اعتباری و آزمایشی، در هر ایستگاه یکی است. در این حالت نیز بر روی پیکر بنده مناسب شبکه و رسیدن به بهترین حالت، کارهایی صورت گرفته و نتایج به صورت جداول زیر ارائه شده است:

بهبود نتایج

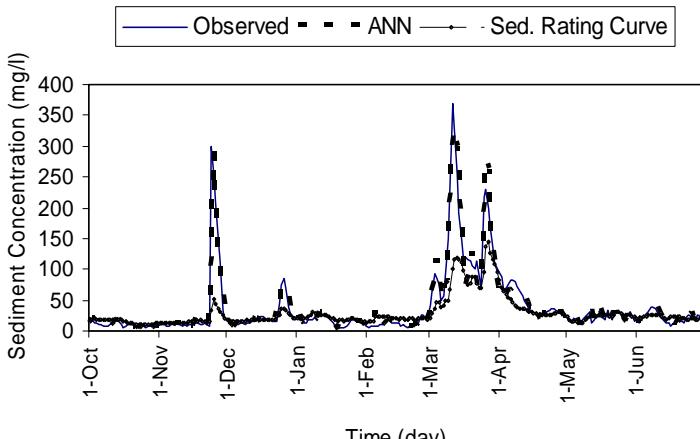
یکی از مسائلی که در هنگام آموزش مدل شبکه عصبی پیش می‌آید، مسئله بیش برازش یا یادگیری اضافی (Over Training) است. در این حالت حین آموزش شبکه، مقدار خطا در مجموعه آموزشی به مقدار بسیار کمی می‌رسد، ولی در هنگام معرفی داده‌های جدید برای آزمایش، خطای مدل زیاد می‌شود؛ یعنی شبکه در فاز آموزشی، روند داده‌ها را یاد نگرفته بلکه ازبر کرده، در نتیجه وزن‌ها بهینه نشده و از این رو نتایج، قابل تعیین به فاز آزمایشی نمی‌باشد. برای رفع این مشکل از تکنیکی به نام توقف زودهنگام استفاده می‌شود [16]. در این تکنیک که در بسیاری از حالات، بهتر از روش‌های مرتب سازی (regularization) است [17]، داده‌ها به سه مجموعه آموزشی، اعتباری (Calibrating Set) و آزمایشی تقسیم بندی می‌شوند. در ابتدای آموزش، از مقدار خطا در هر دو مجموعه آزمایشی و اعتباری کاسته می‌شود. در ادامه آموزش، در صورتی که شبکه شروع به بیش برازش کند، خطای مجموعه اعتبارهندۀ شروع به افزایش می‌کند. اگر این افزایش برای چندین مرحله سعی و خطا ادامه داشته باشد، برای جلوگیری از یادگیری اضافی، فرآیند آموزش متوقف شده و کار آموزش پایان می‌پذیرد. در این روش، مجموعه داده‌های اعتباری، توانایی تعیین دهی شبکه را اندازه گیری کرده

جدول ۳ نتایج حاصل از آموزش، اعتبار سنجی و آزمایش شبکه در ایستگاه فریپورت برای ترکیبات حالت (الف)

مجموعه آزمایشی				مجموعه اعتباری				مجموعه آموزشی					
غاظت بار معلق				غاظت بار معلق				غاظت بار معلق				۱	۲
Corr	SSE $\times 10^6$	RMSE	Corr	SSE $\times 10^6$	RMSE	Corr	SSE $\times 10^6$	RMSE	Corr	SSE $\times 10^6$	RMSE	۳	۴
۰/۸۸۵	۱/۷۴۷	۲۵/۲۷	۰/۸۹۷	۲/۲۷۳	۲۸/۷۷	۰/۸۸۱	۹/۹۱۷	۳۰/۰۹	۴			۱	
۰/۸۷۷	۱/۸۸۲	۲۷/۲۲	۰/۹۲۹	۱/۷۰	۲۴/۱۷	۰/۹۲۷	۷/۴۳	۲۴/۲۰	۷			۲	
۰/۸۷۷	۱/۸۷۱	۲۷/۰۵	۰/۹۵۳	۱/۰۸۷	۱۹/۸۸	۰/۹۳۵	۵/۵۹۷	۲۲/۵۷	۹			۳	
۰/۹۲۷	۱/۱۴۸	۲۰/۴۸	۰/۹۵۷	۰/۹۵۳	۱۸/۷۷	۰/۹۲۱	۷/۷۳۲	۲۴/۷۹	۵	*		۴	
۰/۹۲۳	۱/۱۹۹	۲۰/۹۱۷	۰/۹۷	۱/۰۹۲	۱۹/۹۵	۰/۹۲۹	۷/۲۴۲	۲۳/۸۴	۷			۵	
۰/۹۲۲	۱/۲۷۴	۲۱/۴۴	۰/۹۷	۱/۱۷۵	۲۰/۷۷	۰/۹۲۷	۷/۳۹۲	۲۴/۱۱	۱۱			۶	
۰/۸۲۱	۳/۹۷۷	۳۸/۱۷	۰/۸۷۱	۹/۲۷۳	۵۸/۲۸	۰/۷۵۸	۲۵/۷۲۳	۴۸/۳۹	-			۷	سنجه

جدول ۴ نتایج حاصل از آموزش، اعتبارسنجی و آزمایش شبکه در ایستگاه ساکرامنتو برای ترکیبات حالت (الف)

مجموعه آزمایشی			مجموعه اعتباری			مجموعه آموزشی			نمره برونزی پوشش گل (نف) کلار و روغنی	
غاظت بار معلق			غاظت بار معلق			غاظت بار معلق				
Corr	SSE $\times 10^5$	RMSE	Corr	SSE $\times 10^5$	RMSE	Corr	SSE $\times 10^5$	RMSE		
۰/۸۷۹	۲/۷۷۵	۲۷	۰/۷۹۷	۰/۲۲۵	۷/۷۹	۰/۹۴۱	۸/۴۷۴	۳۴/۰۱	۷	۱
۰/۹۴۱	۱/۳۳۲	۱۹/۰۵	۰/۹۴۷	۰/۰۷۴	۳/۹۳	۰/۹۴۹	۷/۸۷۲	۳۲/۷۷	۷	۲
۰/۹۱۵	۱/۸۷۳	۲۲/۵۳	۰/۸۳۱	۰/۱۸۲	۷/۸۵	۰/۹۷۹	۵/۲۴۳	۲۷/۷۳	۹	۳
۰/۹۳۹	۱/۲۷۸	۱۸/۷۸	۰/۸۴۲	۰/۱۷۹	۷/۹۳	۰/۹۷۳	۵/۳۹۹	۲۷/۱۷	۷	۴
۰/۹۷۱	۰/۸۵۹	۱۵/۲۸	۰/۸۹۲	۰/۱۲۱	۵/۵۸	۰/۹۷۹	۴/۷۲	۲۵/۰۸	۹	*۵
۰/۹۴۳	۱/۱۹۸	۱۸/۰۳	۰/۸۵۷	۰/۱۵	۷/۱۸	۰/۹۷۱	۴/۳۴	۲۴/۳	۱۲	۶
۰/۷۰۲	۷/۱۳	۴۰/۹۸	۰/۰۸۷	۰/۰۷۹۵	۱۳/۷۹	۰/۰۸۳	۵۲/۸۴	۸۵/۰۲	-	سنجه



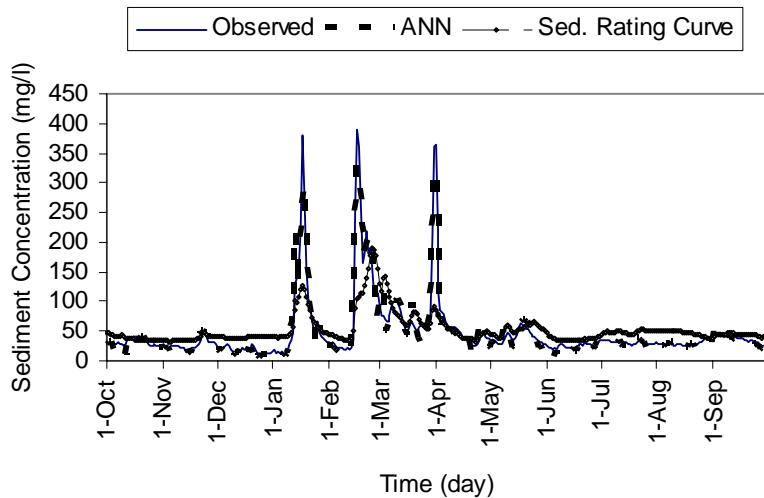
شکل ۷ ایستگاه فریپورت، داده‌های آزمایشی

با توجه به جدول‌ها، در ایستگاه فریپورت، مقادیر SSE و RMSE برای مجموعه آزمایشی همان‌طور که مشاهده می‌شود، استفاده از تکنیک توقف زودهنگام در بهبود نتایج، مؤثر بوده است. اگر این مقایسه را برای سایر ترکیبات وروودی نیز انجام دهیم، دیده می‌شود که در همهٔ حالات، استفاده از این تکنیک نتایج را بهبود بخشیده است.

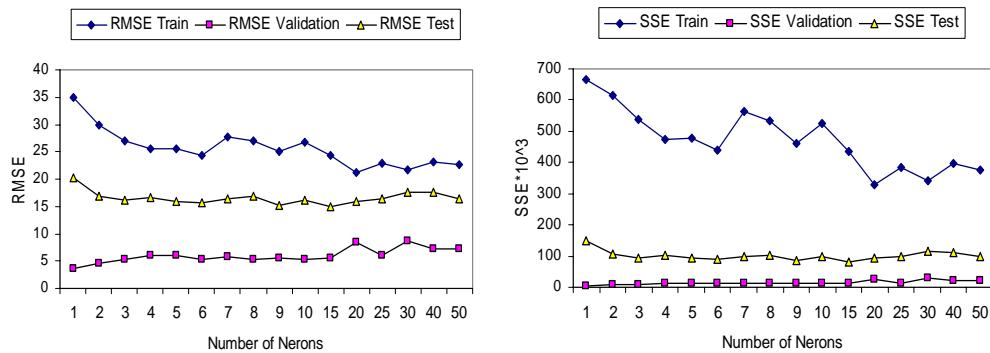
در شکل‌های زیر، عملکرد مدل‌ها و روش منحنی سنجه در حالت استفاده از تکنیک توقف زودهنگام برای ترکیبات حالت (الف) داده شده است. در شکل (۷)، غاظت بار معلق، اندازه‌گیری و محاسبه شده است.

با توجه به جدول‌ها، در ایستگاه ساکرامنتو، مقادیر SSE و RMSE برای مجموعه آزمایشی برای ترکیب چهارم، به ترتیب برابر با $۰/۹۱۶ \times 10^5$ و $۰/۹۲۷ \times 10^5$ بودند. در ایستگاه ساکرامنتو نیز این مقادیر برای مجموعه آزمایشی برای ترکیب پنجم، به ترتیب برابر با $۰/۹۱۶ \times 10^5$ و $۰/۹۷۱ \times 10^5$ بودند. در حالی که در قسمت قبل این تحقیق، طبق جدول (۱)، این مقادیر به ترتیب برابر با $۰/۹۱۶ \times 10^5$ و $۰/۹۲۷ \times 10^5$ بودند. در ایستگاه فریپورت نیز این مقادیر برای مجموعه آزمایشی برای ترکیب پنجم، به ترتیب برابر با $۰/۹۱۶ \times 10^5$ و $۰/۹۷۱ \times 10^5$ بودند. در حالی که در قسمت قبل طبق جدول (۲)، این مقادیر برابر با

...



شکل ۸ ایستگاه ساکرامنتو، داده‌های آزمایشی

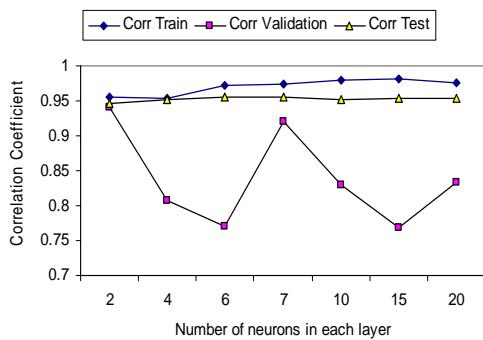


شکل ۱۰ RMSE در برابر تعداد نورون لایه مخفی (یک لایه)

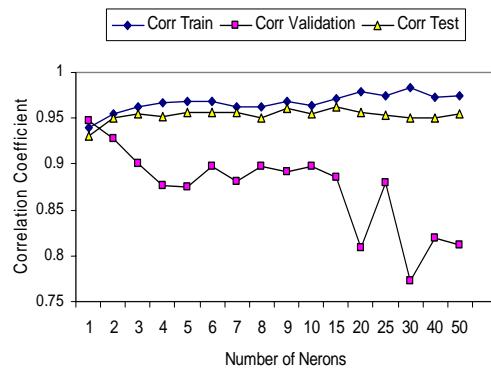
شکل ۹ SSE در برابر تعداد نورون لایه مخفی (یک لایه)

در شکل‌های (۹، ۱۰ و ۱۱)، تغییرات SSE و RMSE در برابر تعداد نورون‌های لایه مخفی در ایستگاه ساکرامنتو برای شبکه دارای یک لایه مخفی، آورده شده است. برای حصول اطمینان از کارایی ساختار مدل ایجاد شده (که دارای یک لایه مخفی بود)، مدلی با دو لایه مخفی نیز طراحی شده و نتایج مدل در شکل‌های (۱۲، ۱۳ و ۱۴) آورده شده و با نتایج مدل یک لایه مورد مقایسه قرار گرفته است.

از روش‌های شبکه عصبی و منحنی سنجه در ایستگاه فرپورت برای داده‌های آزمایشی و در شکل (۸) نیز این نتایج در ایستگاه ساکرامنتو آورده شده است. با توجه به شکل‌های فوق، مشاهده می‌شود که با استفاده از تکنیک توقف زودهنگام، عملکرد شبکه عصبی بهبود یافته و رفتارش در پیش‌بینی کل بازه زمانی، بهویژه در پیک‌ها بسیار بهتر از حالت قبل شده و نیز نسبت به روش منحنی سنجه بسیار دقیق‌تر است.



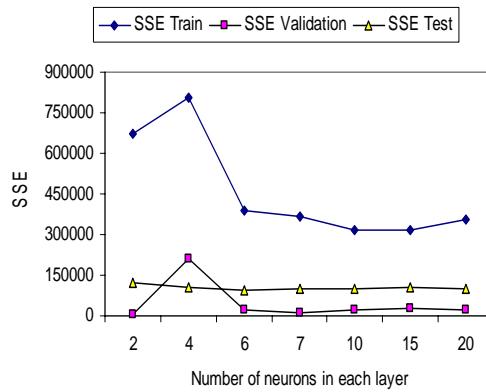
شکل ۱۴ Corr در برابر تعداد نورون لایه مخفی (دو لایه)



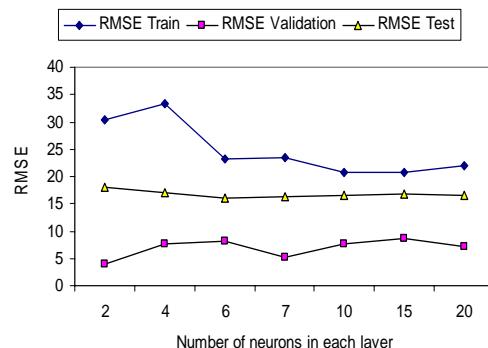
شکل ۱۱ Corr در برابر تعداد نورون لایه مخفی (شبکه یک لایه)

با توجه به شکل های (۹، ۱۰ و ۱۱) مشاهده می شود که بهترین جواب تست برای شبکه ای با نورون در لایه مخفی به دست می آید. در ابتدا که تعداد نورون لایه مخفی کم است، خطای مدل برای آزمایش زیاد می باشد، ولی با افزایش تعداد نورون از خطای مدل کاسته می گردد. با مقایسه SSE نتایج مجموعه تست در شکل های (۹ و ۱۲) و RMSE نتایج مجموعه آزمایشی در شکل های (۱۰ و ۱۳) و همچنین Corr نتایج مجموعه آزمایشی در شکل های (۱۱ و ۱۴)، دیده می شود که مدل ایجاد شده با دو لایه مخفی، برتری خاصی نسبت به مدل ایجاد شده با یک لایه مخفی نداشته و تقریباً دارای همان جواب های شبکه دارای یک لایه مخفی است. از طرفی شبکه دو لایه، دارای اتصالات زیادی بوده و در نتیجه زمان زیادی صرف تحلیل مسئله می شود. نتایج این مقایسه، توانایی و کارایی به کارگیری شبکه هایی با یک لایه مخفی در تقریب توابع را نشان می دهد.

در این قسمت نتایج حاصله از ترکیبات حالت (ب) نیز آورده می شود. همان طوری که گفته شد، اهمیت این ترکیب، زمانی بیشتر روشن می شود که در یک ایستگاه هیدرومتری در یک بازه زمانی بنا به برخی دلایل، مقادیر بار معلق، اندازه گیری نشده است. در این



شکل ۱۲ SSE در برابر تعداد نورون لایه مخفی (دو لایه)



شکل ۱۳ RMSE در برابر تعداد نورون لایه مخفی (دو لایه)

...

حالت (ب)، در ایستگاه فریپورت ترکیب پنجم (ترکیبی که از داده‌های دبی جریان رودخانه در گام‌های زمانی $t-1$ ، $t-2$ و $t-3$ استفاده می‌کند) و در ایستگاه ساکرامنتو، ترکیب سوم (ترکیبی که از داده‌های دبی جریان رودخانه در گام‌های زمانی $t-1$ و $t-2$ استفاده می‌کند) نسبت به حالات دیگر دارای نتایج بهتری می‌باشد.

از شکل‌های فوق، توانایی و برتری مدل شبکه عصبی نسبت به روش منحنی سنجه رسوب، برای ترکیبات حالت (ب) نیز دیده می‌شود.

حالت می‌توان با استفاده از آمار گذشته، موجود بار معلق و دبی جریان، مدلی ایجاد کرده و در بازه‌ای که فاقد آمار هستیم، از این مدل استفاده کرد. در زیر، نتایج این حالت به صورت جداول و شکل‌ها برای ترکیبات مختلف حالت (ب) آورده شده است. چنان‌که دیده می‌شود، در این حالت نیز مدل شبکه عصبی، نسبت به روش منحنی سنجه، عملکرد خوبی داشته است.

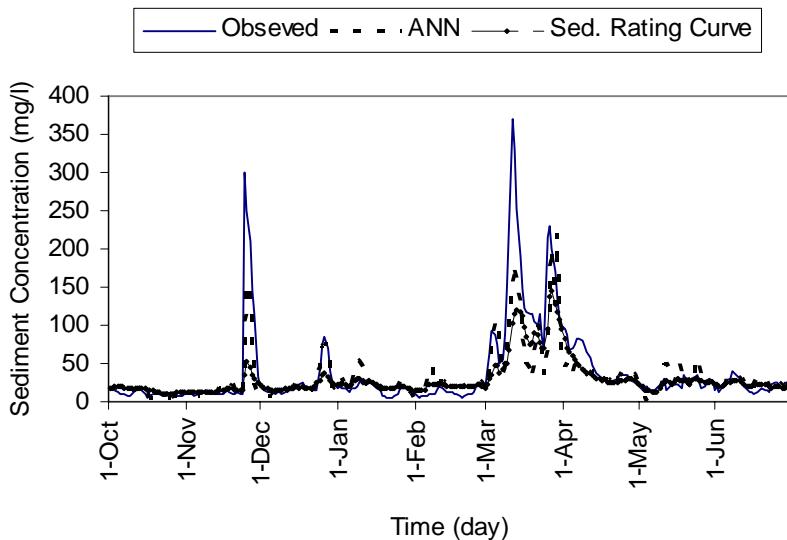
با توجه به نتایج جداول (حالتی که داده‌ها به سه مجموعه: آموزشی، اعتباری و آزمایشی، تقسیم شده اند). دیده می‌شود که از بین ترکیبات مختلف ورودی

جدول ۵ نتایج حاصل از آموزش، اعتبارسنجی و آزمایش شبکه در ایستگاه فریپورت برای ترکیبات حالت (ب)

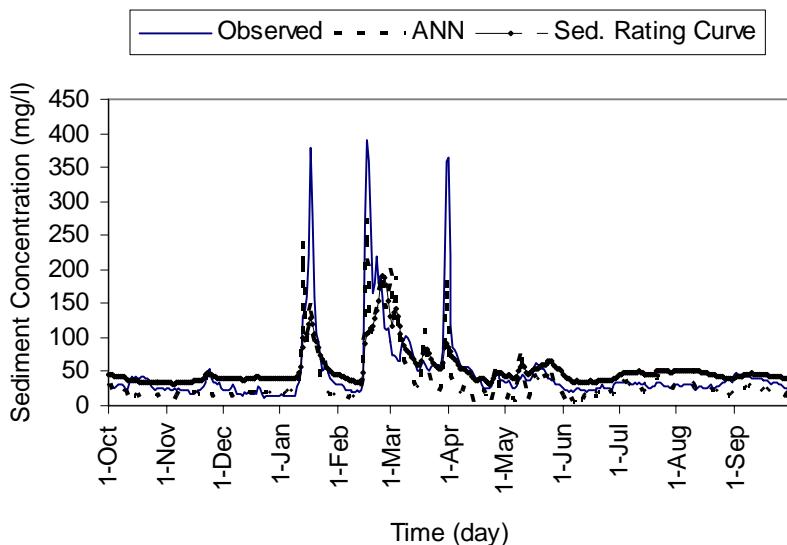
مجموعه تست			مجموعه اعتباری			مجموعه آموزشی			نحوه آزمایش شبکه	
غلظت بار معلق			غلظت بار معلق			غلظت بار معلق				
Corr	$\times 10^{-7}$ SSE	RMSE	Corr	$\times 10^{-7}$ SSE	RMSE	Corr	$\times 10^{-7}$ SSE	RMSE		
۰/۸۰۱	۰/۳۲	۳۴/۲۱	۰/۷۹۵	۰/۴۴	۴۰/۲۱	۰/۸۰۱	۱/۵۹	۳۸/۰۹	۵	۱
۰/۷۳۹	۰/۳۸۲	۳۷/۳۹	۰/۷۸۲	۰/۴۵۴	۴۰/۷۷	۰/۷۷۴	۱/۸۲۷	۴۰/۸۴	۵	۲
۰/۸۳۷	۰/۲۹۵	۳۲/۸۳	۰/۸۱۲	۰/۴۵۱	۴۰/۷۱	۰/۷۵۷	۱/۹۳۹	۴۲/۰۸	۷	۳
۰/۷۹۹	۰/۳۱۷	۳۳/۹۹	۰/۸۲۵	۰/۳۸۹	۳۷/۷۲	۰/۸۱۴	۱/۴۹	۳۷/۹۴	۱۰	۴
۰/۸۴	۰/۲۸۱	۳۲/۰۴	۰/۷۸۴	۰/۴۵۷	۴۰/۰۸۷	۰/۸۲۳	۱/۳۸۳	۳۵/۵۱	۱۰	* ۵
۰/۸۲۱	۰/۳۹۸	۳۸/۱۷	۰/۸۷۱	۰/۹۲۷	۵۸/۲۸	۰/۷۵۸	۲/۵۷۲	۴۸/۳۹	-	سنجه

جدول ۶ نتایج حاصل از آموزش، اعتبارسنجی و آزمایش شبکه در ایستگاه ساکرامنتو برای ترکیبات حالت (ب)

مجموعه تست			مجموعه اعتباری			مجموعه آموزشی			نحوه آزمایش شبکه	
غلظت بار معلق			غلظت بار معلق			غلظت بار معلق				
Corr	$SSE \times 10^{-7}$	RMSE	Corr	$SSE \times 10^{-7}$	RMSE	Corr	$SSE \times 10^{-7}$	RMSE		
۰/۷۴۷	۰/۵۷۲	۳۹/۲۳	۰/۵۵	۰/۱۰۸	۱۷/۱۳	۰/۷۳۷	۳/۷۵۷	۷۰/۷۲	۵	۱
۰/۸	۰/۵۱۱	۳۷/۳۹	۰/۵۷۳	۰/۱۱۵	۱۷/۷۱	۰/۷۷۳	۴/۲۲	۷۷/۰۱	۵	۲
۰/۷۷۱	۰/۵۰۸	۳۷/۲۷	۰/۷۱۲	۰/۱۰۳	۱۷/۷۱	۰/۷۱۲	۳/۷۳	۷۱/۴۴	۷	* ۳
۰/۷۵۸	۰/۵۲۸	۳۷/۹۹	۰/۵۴۷	۰/۰۷۸	۱۴/۵۷۲	۰/۷۵۴	۷/۴۱	۹۳/۷۱	۷	۴
۰/۷۵۹	۰/۵۱۳	۳۷/۴۷	۰/۷۰۱	۰/۱۳	۱۸/۸۱۲	۰/۷۰۱	۳/۸۷	۷۲/۷۷	۹	۵
۰/۷۰۲	۰/۷۱۳	۴۰/۹۸	۰/۰۸۷	۰/۰۷۹	۱۳/۷۹	۰/۵۸۳	۵/۲۸۴	۸۵/۰۲	-	سنجه



شکل ۱۵ ایستگاه فریبورت، داده‌های آزمایشی



شکل ۱۶ ایستگاه ساکرامنتو، داده‌های آزمایشی

موجود در دو ایستگاه آب سنجی بر روی رودخانه ساکرامنتو بهره گرفته شد. مدل به کار گرفته شده از داده‌های دبی جریان و غلظت بار معلق در زمان‌های گذشته استفاده کرده و غلظت بار معلق در زمان آینده را

نتیجه گیری

در این تحقیق، توانایی و کارایی شبکه‌های عصبی مصنوعی در پیش‌بینی و تخمین بار معلق رودخانه‌ها مورد بررسی قرار گرفت. برای این کار از اطلاعات

...

و $t-2$ و غلظت بار معلق در گام زمانی $t-1$ و $t-2$ استفاده می‌کند، دارای نتایج بهتری نسبت به سایر مدل‌ها می‌باشد. از بین ترکیبات حالت (ب) نیز در ایستگاه فریپورت مدل ترکیب پنجم که از داده‌های دبی جریان در گام‌های زمانی $t-1$ ، $t-2$ و $t-3$ استفاده می‌کند و در ایستگاه ساکرامنتو مدل ترکیب سوم که از داده‌های دبی جریان در گام‌های زمانی $t-1$ و $t-2$ استفاده می‌کند، نسبت به حالات دیگر دارای نتایج بهتری است.

از دیگر نتایج این تحقیق می‌توان به توانایی شبکه‌های دارای یک لایه مخفی در نگاشت مسائل غیرخطی اشاره نمود. طبق بررسی‌های انجام یافته در این تحقیق، عملکرد شبکه دولایه با شبکه یک لایه تفاوتی نداشت، در حالی که استفاده از شبکه‌ای با دولایه مخفی، هزینه محاسبات را بالا می‌برد.

پیش‌بینی می‌کند. با توجه به توانایی‌های شبکه‌های عصبی مصنوعی در ارتباط غیرخطی ورودی و خروجی سیستم‌ها، مدل ایجاد شده در این تحقیق توانسته است عملکرد موفقی در برآذش سطح بر فضای چند بعدی مسأله داشته باشد. دیده شد که استفاده از تکنیک توقف زودهنگام، دقت پیش‌بینی مدل را (به‌ویژه در پیک‌ها) افزایش می‌دهد. از مقایسه نتایج مدل با روش منحنی سنجه نیز مشخص شد که مدل شبکه عصبی در کل فرآیند پیش‌بینی، برتری بارزی نسبت به این روش دارد. از بحث روی معماری و ساختار مدل، مشخص شد که از ترکیبات حالت (الف) در ایستگاه فریپورت، مدلی که از دبی جریان در گام زمانی $t-1$ و غلظت بار معلق در گام زمانی $t-1$ استفاده می‌کند و در ایستگاه ساکرامنتو، مدلی که از دبی جریان در گام زمانی $t-1$ و

مراجع

- 1- Mirbagheri, S. A., Tanji, K. K., and Krone, R. B., "Sediment characterization and transport in Colusa Basin Drain", *J. Env. Engineering*, 114(6), ASCE, pp. 1257-1273, (1988).
- 2- Chen, J., and Adams, B. J., "Integration of artificial neural networks with conceptual models in rainfall-runoff modeling", *Journal of Hydrology*, 318, pp. 232–249, (2006).
- 3- Srinivasulu, S., and Jain, A., "A comparative analysis of training methods for artificial neural network rainfall-runoff models", *Applied Soft Computing*, 6, pp. 295-306, (2006).
- 4- Garcia, L. A., and Shigidi, A., "Using neural networks for parameter estimation in ground water", *Journal of Hydrology*, 318, pp. 215-231, (2006).
- 5- Moradkhani, H., Hsu, K., Gupta, H.V., and Sorooshian, S., "Improved stream flow forecasting using self-organizing radial basis function artificial neural networks", *Journal of Hydrology*, 295, pp. 246-262, (2004).
- 6- Bruen, M., and Yang, J., "Functional networks in real-time .Flood forecasting-a novel application", *Advances in Water Recourses*, 28, pp. 899-909, (2005).
- 7- Nagy, H. M., Watanabe, K., and Hirano, M., "Prediction of load concentration in rivers using artificial neural network model", *J. Hydraulic Eng.*, 128(6), ASCE, pp. 588-595, (2001).

- 8- Jain, S. K., "Development of integrated sediment rating curves using ANNs", *J. Hydraulic Eng.*, 127(1), ASCE, pp. 30-37, (2001).
- ۹- منتظر، غلامعلی، ذاکر مشقق، محمد و قدسیان، مسعود، "تخمین خبره میزان رسوب رودخانه بازفت به کمک شبکه عصبی مصنوعی"، ششمین سمینار بین المللی مهندسی رودخانه، بهمن ماه ۱۳۸۱، دانشگاه شهید چمران اهواز، (۱۳۸۱).
- 10- Cigizoglu, H. K., "Suspended Sediment Estimation and Forecasting using artificial Neural Networks", *Turkish J. Eng. Env. Sci.*, 26, pp. 15-25, (2002).
- 11-Cigizoglu, H. K., "Suspended Sediment Estimation for Rivers using Artificial Neural Networks and Sediment Rating Curves", *Turkish J. Eng. Env. Sci.*, 26, pp. 27-36, (2002).
- ۱۲- طاهر شمسی، احمد، منهاج، محمد باقر و احمدیان، رضا، "برآورد بار رسوب با استفاده از شبکه عصبی و مقایسه نتایج برای جریانهای فوق بحرانی و زیر بحرانی"، پنجمین کنفرانس هیدرولیک ایران، آبان ۱۳۸۴، دانشگاه شهید باهنر کرمان، (۱۳۸۴).
- 13- Sarangi, A., and Bhattacharya, A. K., "Comparison of Artificial Neural Network and regression models for sediment loss prediction from Banha watershed in India", *Agricultural Water Management*, 78, pp. 195-208, (2005).
- 14- Haykin, S., "Neural Networks: a comprehensive foundation", MacMillan, New York, (1994).
- ۱۵- محمود شفاعی بجستان، "هیدرولیک رسوب"، انتشارات دانشگاه شهید چمران اهواز، (۱۳۷۸).
- 16- Smith, M., "Neural networks for statistical modeling", Van Nostrand - Reinhold, New York, (1993).
- 17- Finnoff, W., "Improving model selection by nonconvergent method", *Neural Networks*, 6, pp. 771-783, (1993).