

## مدل بار معلق رودخانه‌ها با استفاده از شبکه‌های عصبی مصنوعی\*

سید احمد میر باقری<sup>(۲)</sup>طاہر رجائی<sup>(۱)</sup>

**چکیده** پیش بینی و تخمین بار رسوب رودخانه‌ها، در مدیریت رودخانه‌ها و مخازن سدها در پروژه‌های آبی 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 تغییرات 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 آورده اند. در این مقاله در مورد کارایی این شبکه‌ها در تخمین و پیش بینی بار معلق رودخانه‌ها، مطالعاتی انجام گرفته است. در شبکه‌های ایجاد شده، در انواع تقسیم بندی مجموعه داده‌ها، انواع ترکیبات ورودی شبکه، تعداد لایه‌های شبکه، تعداد نورون‌های لایه‌های ورودی و مخفی شبکه و ... تحقیقاتی انجام گرفته است. در مدل‌های طراحی شده با دادن سری زمانی دبی جریان و غلظت بار معلق در زمان‌های قبل، می‌توان غلظت بار معلق در زمان آینده را پیش بینی نمود. برای افزایش کارایی مدل‌ها، از تکنیک توقف زود هنگام (Early Stopping) استفاده شده و در نهایت برای ارزیابی نتایج، مقایسه‌ای با روش مرسوم منحنی سنج رسوب نیز انجام گرفته است. نتایج، نشان دهنده برتری مدل‌های شبکه عصبی بوده است.

**واژه‌های کلیدی:** بار معلق رودخانه، شبکه عصبی، پرسپترون چند لایه، پیش بینی رسوب، توقف زود هنگام، منحنی سنج

## Suspended Sediment Model in Rivers Using Artificial Neural Networks

T. Rajae

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 ۸۶/۸/۷ 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

## مقدمه

شبکه عصبی در تخمین ضریب هدایت هیدرولیکی و ضریب آب‌گذری آب‌خوان دارد. در سال ۲۰۰۴، مرادخانی و هم‌کارانش [5]، دبی جریان عبوری از رودخانه را با استفاده از شبکه SORB که شبکه‌ای با ساختار ترکیبی از دو شبکه پایه شعاعی (Radial Basis Function) و SOFM (Self-Organizing Feature Map) بود، مورد بررسی قرار داده و به بحث در مورد نتایج به دست آمده پرداختند که نتایج تحقیق آن‌ها، توانایی مدل ترکیبی شبکه عصبی را نشان می‌داد.

در تحقیق دیگری برین و یانگ [6] در سال ۲۰۰۵، سیلاب عبوری را پیش بینی نمودند. از جمله مطالعات انجام گرفته در زمینه انتقال رسوب، می‌توان به تحقیق انجام یافته توسط ناجی (Nagy) و هم‌کارانش [7] در سال ۲۰۰۱، برای پیش‌بینی دبی رسوبی رودخانه‌ها با استفاده از داده‌های اندازه گیری شده نظیر: عمق، دبی و سرعت جریان، شیب بستر، منحنی دانه‌بندی 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) [8] 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، منتظر 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

تخمین و پیش‌بینی دبی رسوب، در طیف گسترده‌ای از مسائل، نظیر: مهندسی رودخانه‌ها، طراحی سدها، انتقال آلودگی، 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 سنج رسوب شده است.

در این روش، یک منحنی توانی به فرم  $Q_s = aQ_w^b$  بر داده‌های آماری دبی جریان و دبی رسوبی برازش 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 [1] اشاره کرد.

به طور کلی پدیده رسوب، یک مسأله نگاشت غیرخطی است و شبکه‌های عصبی به‌عنوان 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 [2] و سرینی واسولا و جین [3] در سال ۲۰۰۶، در مدل کردن پدیده بارش- رواناب اشاره کرد. در تحقیق دیگری، گارسیا و شیجیدی [4] در سال ۲۰۰۶، از مدل شبکه عصبی برای تخمین پارامترهای آب‌های زیر زمینی استفاده کردند. نتایج به دست 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، سارانچی و باچاریا [13] به مقایسه مدل شبکه عصبی و روش‌های رگرسیون در پیش بینی رسوب و فرسایش پرداختند. در این تحقیق، مدل شبکه عصبی به منظور پیش بینی 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 مسأله

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 جعبه سیاه، نظیر مدل تجربی غیرخطی شبکه عصبی مصنوعی است، قرار می‌گیرد. در اکثر مدل‌های به کار گرفته شده برای مدل‌سازی سری‌های زمانی، خروجی مدل در زمان  $t$ ، افزون بر آن‌که 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 اتورگرسیو 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، سیگز 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 پیش بینی 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، سیگز اوغلو [11] در سال ۲۰۰۲، از اطلاعات دو رودخانه در شمال انگلستان استفاده کرد و به پیش بینی 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 نظیر پدیده هیستریزس (Hysteresis) و روابط جریان نیز می‌باشد. در تحقیقی دیگر، طاهر شمسی و هم‌کارانش [۱۲] در سال ۱۳۸۴، از شبکه عصبی پرسپترون و الگوریتم آموزش Levenberg-Marquardt برای پیش بینی رسوب استفاده کردند. در این تحقیق، داده‌های ورودی مدل شامل: عرض، عمق جریان، شیب 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 آنجا 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 در گذشته به مدل معرفی شده، اثرشان را به صورت تجمعی بر روی خروجی مدل در گام زمانی پیشین نشان می‌دهند. این مدل‌ها بر دو قسمت: مدل‌های عصبی اتورگرسیو تمام عیار و مدل‌های عصبی اتورگرسیو ناقص.


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

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

با توجه به مطالب فوق، پیش‌بینی بار معلق عبوری از رودخانه که در مقوله تحلیل و مدل‌سازی سری‌های زمانی قرار می‌گیرد، به‌کارگیری مدل‌های اتورگرسیو را طلب می‌کند. بنابراین در این تحقیق، از شکل خاصی از 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] (Haykion, 1994). 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 مسأله را دریافت کرده و پس از پردازش، خروجی مسأله را 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 استثنا 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 پیش بینی می‌شود. لازم به ذکر است که عمده 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 مثمر ثمر خواهد بود. از طرفی در اکثر ایستگاه‌های آب‌سنجی موجود (به‌ویژه در ایران)، اطلاعات عمدتاً در حد عمق جریان، دبی جریان و دبی رسوبی هستند و اطلاعات دیگری نظیر منحنی دانه‌بندی مواد رسوبی، شیب بستر، سرعت سقوط ذرات، عدد فرود و ... در دسترس نمی‌باشد؛ لذا در انتخاب دو

پیش بینی 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:



(الف)



(ب)

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

**آنالیز داده‌ها.** این مطالعه بر روی دو ایستگاه آب‌سنجی فریپورت (Station ID:11447650) و ساکرامنتو (Station ID:11447500) در رودخانه ساکرامنتو در ایالت کالیفرنیا آمریکا انجام گرفته است. داده‌های سری زمانی روزانه دبی جریان و غلظت بار معلق برای این ایستگاه‌ها از طریق سایت اینترنتی USGS اخذ شده و بعد از امتحان داده‌ها و توجه به این نکته که در بین داده‌ها از لحاظ زمانی شکافی وجود نداشته باشد، دو پرئود 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

$$Q_t, Q_{t-1}, Q_{t-2} \quad 3-$$

$$Q_{t-1}, Q_{t-2}, Q_{t-3} \quad 4-$$

$$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3} \quad 5-$$

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

با توجه به محدودیت توابع آستانه نورون ها در مدل شبکه عصبی، ارائه نمونه های آموزشی و آزمایشی به صورت داده های خام اندازه گیری شده، باعث عدم دقت و کاهش سرعت شبکه می گردد. به همین دلیل در تحقیق حاضر، داده ها طبق رابطه زیر نرمالیزه 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 نرمالیزه شده،  $X_{\min}$  مینیمم داده ها و  $X_{\max}$  ماکزیمم داده ها است.

### بررسی ساختار مدل و تحلیل نتایج

تعیین ساختار یک مدل عصبی، از مهم ترین و مشکل ترین مراحل توسعه آن است. این کار به منظور پیکربندی مناسب شبکه ها و رسیدن به بهترین جواب ممکن انجام می گیرد. در این تحقیق، با تغییر تعداد نورون های لایه مخفی، تغییر ضریب ممتنم، تغییر نرخ یادگیری و استفاده از توابع فعال ساز مختلف، بهترین شبکه برگزیده شده است. برای ساخت مدل ها از الگوریتم آموزشی Levenberg-Marquardt، برای لایه مخفی از تابع انتقال سیگموئید، برای لایه خروجی از تابع انتقال سیگموئید و در برخی حالات از تابع انتقال خطی، برای ضریب ممتنم و نرخ یادگیری نیز از اعداد بازه  $0/2$  الی  $0/6$  استفاده شده است. در حالت (الف)، برای هر ترکیب (ترکیبات ۱ تا ۶)، تعداد نورون لایه مخفی که کم ترین 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 ایستگاه های 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 گام های زمانی گذشته از دبی جریان و غلظت بار معلق رودخانه به صورت توأم استفاده می کنند.

ب- ترکیباتی که در گام های زمانی گذشته فقط از دبی جریان رودخانه استفاده می کنند.

اهمیت ترکیب حالت (ب) زمانی بیشتر مشهود است که در گام های زمانی گذشته فاقد اطلاعات غلظت بار معلق هستیم و می خواهیم در یک شکاف زمانی و یا پیش بینی بار معلق، اطلاعاتی از دبی بار معلق به دست آوریم. با توجه به توضیحات فوق، ترکیبات زیر برای حالت (الف) در نظر گرفته شد.  $Q_t$  و  $C_t$  به ترتیب دبی جریان و غلظت بار معلق در گام زمانی  $t$  می باشند.

$$C_{t-1}, Q_{t-1} \quad 1-$$

$$C_{t-1}, C_{t-2}, Q_{t-1}, Q_{t-2} \quad 2-$$

$$C_{t-1}, C_{t-2}, C_{t-3}, Q_{t-1}, Q_{t-2}, Q_{t-3} \quad 3-$$

$$C_{t-1}, Q_t, Q_{t-1} \quad 4-$$

$$C_{t-1}, C_{t-2}, Q_t, Q_{t-1}, Q_{t-2} \quad 5-$$

$$C_{t-1}, C_{t-2}, C_{t-3}, Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3} \quad 6-$$

در ترکیبات یک تا سه از دبی جریان در زمان  $t$  استفاده نشده، لذا از این سه ترکیب می توان برای پیش بینی 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 می شود. برای حالت (ب) نیز ترکیبات زیر در نظر گرفته شد:

$$Q_t, Q_{t-1} \quad 1-$$

$$Q_{t-1}, Q_{t-2} \quad 2-$$


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

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

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

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 خطا (RMSE)، ضریب هم‌بستگی (Correlation Coefficient) و کم‌ترین مجموع مربعات خطا 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			تعداد نوزون لایه مخفی	ترکیبات مختلف ورودی مدل	شماره ترکیب
غلظت بار معلق			غلظت بار معلق					
R	SSE × 10 <sup>۵</sup>	RMSE	R	SSE × 10 <sup>۴</sup>	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	۶/۸۰۲	۱۵/۷۲	۶	$C_{t-1}, C_{t-2}, Q_{t-1}, Q_{t-2}$	۲
۰/۷۵۲	۲/۸۸۵	۳۳/۲۵	۰/۹۷	۶/۹۹۶	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	۶/۲۲۹	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	۶/۲۱۳	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			تعداد نرون لایه منحنی	ترکیبات مختلف ورودی مدل	شماره ترکیب
غلظت بار معلق			غلظت بار معلق					
R	SSE $\times 10^5$	RMSE	R	SSE $\times 10^3$	RMSE			
۰/۸۹۵	۲/۱۸۲	۲۴/۴۳	۰/۹۴۳	۱۱/۲۵	۵/۴۶۲	۳	$C_{t-1}, Q_{t-1}$	۱
۰/۹۲۲	۱/۶۳۱	۲۱/۰۹۲	۰/۹۹۰	۸/۴۰۶	۴/۵۸۶	۵	$C_{t-1}, C_{t-2}, Q_{t-1}, Q_{t-2}$	۲
۰/۸۵۵	۳/۳۱۶	۳۰/۰۹	۰/۹۹۲	۸/۹۳۷	۴/۶۳۵	۸	$C_{t-1}, C_{t-2}, C_{t-3}, Q_{t-1}, Q_{t-2}, Q_{t-3}$	۳
۰/۹۲۵	۱/۵۸۶	۲۰/۸۲	۰/۹۷۴	۹/۰۸	۴/۸۸۷	۵	$C_{t-1}, Q_t, Q_{t-1}$	۴
۰/۹۴۱	۱/۲۸۹	۱۸/۷۴۱	۰/۹۹۳	۷/۵۶۵	۴/۳۲۷	۷	$C_{t-1}, C_{t-2}, Q_t, Q_{t-1}, Q_{t-2}$	۵
۰/۸۹۳	۲/۳۹۱	۲۵/۵۳۴	۰/۹۸۹	۸/۶۲	۴/۵۴	۹	$C_{t-1}, C_{t-2}, C_{t-3}, Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	۶
۰/۷۰۲	۴۹/۸۵۱	۶۷۸/۹۷	۰/۶۲۶	۱۹۶/۵۴	۲۶۷۶/۸۷	-	روش منحنی سنج رسوب	



شکل ۴ غلظت رسوب مشاهداتی و محاسباتی از روش‌های شبکه عصبی و منحنی سنج در ایستگاه فریپورت برای داده‌های آزمایشی

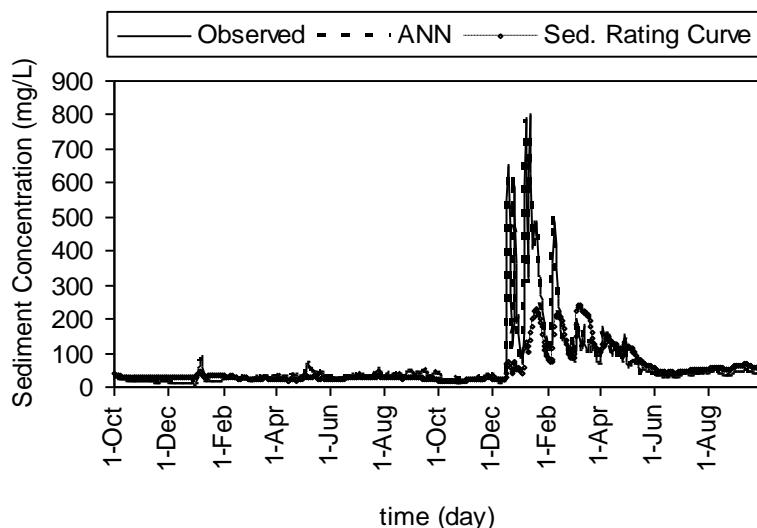
از بین ترکیبات مختلف ورودی، برای هر دو ایستگاه فریپورت و ساکرامنتو، ترکیب پنجم نسبت به حالات دیگر دارای نتایج بهتری است. در شکل (۴) غلظت بار معلق، اندازه‌گیری و محاسبه شده از روش‌های شبکه عصبی و منحنی سنج

با توجه به جدول‌ها دیده می‌شود که مقادیر SSE و RMSE برای مدل‌ها خیلی کم‌تر از نتایج روش منحنی سنج است و ضریب هم‌بستگی نیز برای اکثر مدل‌های عصبی بهتر از روش منحنی سنج بوده و نزدیک به یک است. با توجه به نتایج، دیده می‌شود 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 مسأله و بهبود نتایج، از تکنیک توقف زود هنگام استفاده شد. در زیر، نتایج به دست 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 غلظت رسوبی 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 غلظت رسوب مشاهداتی و محاسباتی از روش های شبکه عصبی و منحنی سنجه در ایستگاه ساکرامنتو برای داده های آموزشی



شکل ۶ غلظت رسوب 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 می دهند.

در این تحقیق برای جلوگیری از بیش برآزش 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 بازه های زمانی مجموعه های آموزشی، اعتباری و آزمایشی، در هر ایستگاه یکی است. در این حالت نیز بر روی پیکر بندی 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 می آید، مسأله بیش برآزش یا یادگیری اضافی (Over Training) است. در این حالت حین آموزش شبکه، مقدار خطا در مجموعه آموزشی به مقدار بسیار کمی می رسد، ولی در هنگام معرفی داده های جدید برای آزمایش، خطای مدل زیاد می شود؛ یعنی شبکه در فاز آموزشی، روند داده ها را یاد نگرفته بلکه از بر کرده، در نتیجه وزن ها بهینه نشده و از این رو نتایج، قابل تعمیم به فاز آزمایشی نمی باشد. برای رفع این مشکل از تکنیکی به نام توقف زودهنگام استفاده می شود [16]. در این تکنیک که در بسیاری از حالات، بهتر از روش های مرتب سازی (regularization) است [17]، داده ها به سه مجموعه آموزشی، اعتباری (Calibrating Set) و آزمایشی تقسیم بندی می شوند. در ابتدای آموزش، از مقدار خطا در هر دو مجموعه آموزشی و اعتباری کاسته می شود. در ادامه آموزش، در صورتی که شبکه شروع به بیش برآزش کند، خطا در مجموعه اعتبار دهنده شروع به افزایش می کند. 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 می پذیرد. در این روش، مجموعه داده های اعتباری، توانایی تعمیم 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 آموزشی			مجموعه اعتباری			مجموعه آزمایشی			تعداد روزهای آموزش	تعداد دوره های آموزش
غلطت بار معلق			غلطت بار معلق			غلطت بار معلق				
Corr	SSE $\times 10^5$	RMSE	Corr	SSE $\times 10^5$	RMSE	Corr	SSE $\times 10^5$	RMSE		
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	-	سنجه

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

مجموعه آموزشی			مجموعه اعتباری			مجموعه آزمایشی			نورون لایه مخفی	حالت ترکیبات ورودی (الف)
غلظت بار معلق			غلظت بار معلق			غلظت 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	۰/۷۹۵	۱۳/۷۹	۰/۵۸۳	۵۲/۸۴	۸۵/۰۲	-	سنجه




شکل ۷ ایستگاه فریبورت، داده‌های آزمایشی

با توجه به جدول‌ها، در ایستگاه فریبورت، مقادیر SSE، RMSE و Corr برای مجموعه آزمایشی برای ترکیب چهارم، به ترتیب برابر با ۲۰/۴۸، ۱۰<sup>۵</sup>\*۱/۱۴۸ و ۰/۹۲۷ به دست آمده است؛ در حالی که در قسمت قبل این تحقیق، طبق جدول (۱)، این مقادیر به ترتیب برابر با ۲۱/۸۳۱، ۱۰<sup>۵</sup>\*۱/۳۱ و ۰/۹۱۶ به دست آمده بودند. در ایستگاه ساکرامنتو نیز این مقادیر برای مجموعه آزمایشی برای ترکیب پنجم، به ترتیب برابر با ۱۵/۲۸، ۱۰<sup>۵</sup>\*۰/۸۹۵ و ۰/۹۷۱ به دست آمده؛ در حالی که در قسمت قبل طبق جدول (۲)، این مقادیر برابر با


۱۸/۷۴۱، ۱۰<sup>۵</sup>\*۱/۲۸۹ و ۰/۹۴۱ به دست آمده بود. همان‌طور که مشاهده می‌شود، استفاده از تکنیک توقف زود هنگام در بهبود نتایج، مؤثر بوده است. اگر این مقایسه را برای سایر ترکیبات ورودی نیز انجام دهیم، دیده می‌شود که در همه 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 زود هنگام برای ترکیبات حالت (الف) داده شده است. در شکل (۷)، غلظت بار معلق، اندازه‌گیری و محاسبه شده است.


نشریه مهندسی عمران دانشگاه فردوسی مشهد



شکل ۸ ایستگاه ساکرامنتو، داده‌های آزمایشی



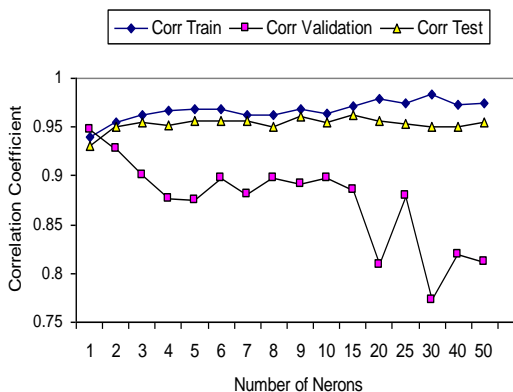
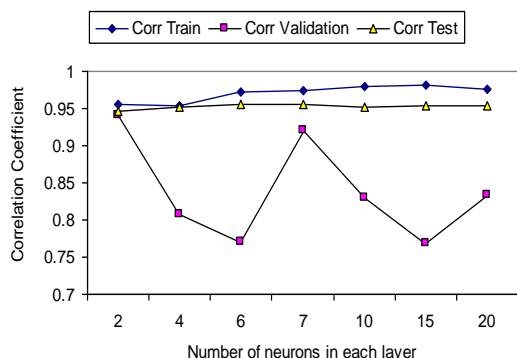
شکل ۱۰ RMSE در برابر تعداد نورون لایه مخفی (یک لایه)



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

در شکل‌های (۹، ۱۰ و ۱۱)، تغییرات SSE، RMSE و Corr 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 سنج در ایستگاه فریبورت 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 سنج بسیار دقیق‌تر است.




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

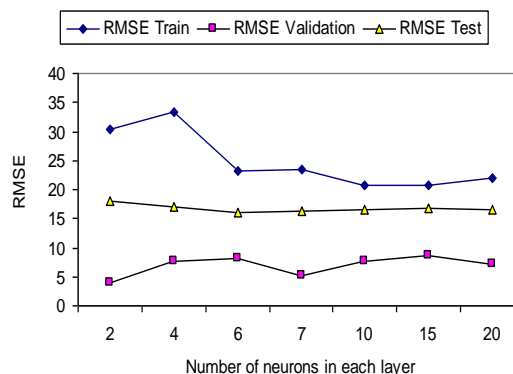
شکل ۱۱ Corr در برابر تعداد نورون لایه مخفی (شبکه یک لایه)

با توجه به شکل‌های (۹، ۱۰ و ۱۱) مشاهده می‌شود که بهترین جواب تست برای شبکه‌ای با ۹ نورون در لایه مخفی به دست می‌آید. در ابتدا که تعداد نورون لایه مخفی کم است، خطای مدل برای آزمایش زیاد می‌باشد، ولی با افزایش تعداد نورون از خطای مدل کاسته می‌گردد. با مقایسه SSE نتایج مجموعه تست در شکل‌های (۹ و ۱۲) و RMSE نتایج مجموعه آزمایشی در شکل‌های (۱۰ و ۱۳) و هم‌چنین Corr نتایج مجموعه آزمایشی در شکل‌های (۱۱ و ۱۴)، دیده می‌شود که مدل ایجاد شده با دو لایه مخفی، برتری خاصی نسبت به مدل ایجاد شده با یک لایه مخفی نداشته و تقریباً دارای همان جواب‌های شبکه دارای یک لایه مخفی است. از طرفی شبکه دو لایه، دارای اتصالات زیادی بوده و در نتیجه زمان زیادی صرف تحلیل مسأله می‌شود. نتایج این مقایسه، توانایی و کارایی به کارگیری شبکه‌هایی با یک لایه مخفی در تقریب توابع را نشان می‌دهد.

در این قسمت نتایج حاصله از ترکیبات حالت (ب) نیز آورده می‌شود. همان‌طوری که گفته شد، اهمیت این ترکیب، زمانی بیشتر روشن می‌شود 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.

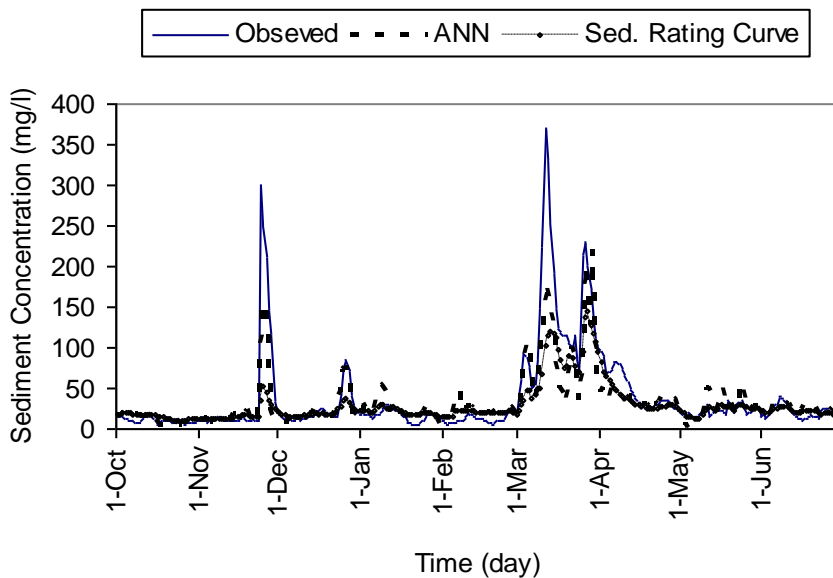
با توجه به نتایج جداول (حالتی که داده‌ها به سه مجموعه آموزشی و اعتباری و آزمایشی، تقسیم شده اند). دیده می‌شود که از بین ترکیبات مختلف ورودی

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


مجموعه تست			مجموعه اعتباری			مجموعه آموزشی			تورون لایه مخفی	ترکیبات ورودی حالت (ب)
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	۴۰/۸۷	۰/۸۳۳	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			تورون لایه مخفی	ترکیبات ورودی حالت (ب)
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

### نتیجه گیری

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

در این تحقیق، توانایی و کارایی شبکه‌های عصبی مصنوعی در پیش بینی 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  $t$ ،  $t-1$ ،  $t-2$  و  $t-3$  استفاده می‌کند و در ایستگاه ساکرامنتو مدل ترکیب سوم که از داده‌های دبی جریان در گام‌های زمانی  $t$ ،  $t-1$  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.

پیش بینی می‌کند. با توجه به توانایی‌های شبکه‌های عصبی مصنوعی در ارتباط غیرخطی ورودی و خروجی سیستم‌ها، مدل ایجاد شده در این تحقیق توانسته است عملکرد موفق‌تری در برازش سطح بر فضای چند بعدی مسأله داشته باشد. دیده شد که استفاده از تکنیک توقف زودهنگام، دقت پیش بینی مدل را (به‌ویژه در پیک‌ها) افزایش می‌دهد. از مقایسه نتایج مدل با روش منحنی‌سنج نیز مشخص شد که مدل شبکه عصبی در کل فرآیند پیش بینی، 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  $t$  و  $t-1$  و غلظت بار معلق در گام زمانی  $t-1$  استفاده می‌کند و در ایستگاه ساکرامنتو، مدلی که از دبی جریان در گام زمانی  $t$  و  $t-1$

## 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 مشفق، 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، منہاج، 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 بجزستان، "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).