

مقایسه مدل های خودهمبسته شبکه عصبی مصنوعی دینامیک و استاتیک در پیش بینی جریان ماهانه ورودی به مخزن سد دز

محمد ابراهیم بنی حبیب^۱

محمد ولی پور^۲

سید محمودرضا بهبهانی^۳

تاریخ پذیرش: ۸۷/۵/۴

تاریخ دریافت: ۸۷/۳/۱۱

چکیده

در مقاله حاضر قابلیت مدل خود همبسته شبکه عصبی مصنوعی دینامیک برای پیش‌بینی جریان ماهانه ورودی مخزن سد دز ارزیابی شده و نتایج به دست آمده با مدل خودهمبسته شبکه عصبی مصنوعی استاتیک مقایسه شده است. در تحقیقات قبل مقایسه مدل های استاتیک و دینامیک در شبکه های عصبی مصنوعی صورت نگرفته است. ضمناً تحقیق حاضر از حیث خودهمبستگی مدل شبکه عصبی مصنوعی، دارای نوآوری می باشد. در این تحقیق آبدهی های ماهانه بین سال های ۱۳۳۴ تا ۱۳۸۰ استفاده شده است. به طوری که آمار مربوط به ۴۲ سال اول برای آموزش مدل ها و ۵ سال اخیر برای پیش‌بینی مدل ها استفاده گردید. ساختار های مختلف برای مدل های شبکه عصبی مصنوعی استاتیک و دینامیک با مقایسه شاخص جذر متوسط مربع خطا بررسی گردید. در ابتدا با استفاده از داده های مهر ۱۳۳۴ تا شهریور ۱۳۷۶ در مرحله آموزش مدل ها بهترین ساختار مدل های شبکه عصبی مصنوعی استاتیک و دینامیک به دست آمد. سپس بر اساس ساختارهای بهینه، جریان ماهانه ورودی به مخزن سد دز پیش‌بینی شده و با داده های مشاهده‌ای مهر ۱۳۷۶ تا شهریور ۱۳۸۱ مقایسه گردید. در این تحقیق همچنین دوتایع تابع فعالیت شعاعی و سیگموئیدی و تعداد نرون های مختلف در لایه میانی، بررسی شد. نتایج نشان داد که بهترین مدل در پیش‌بینی جریان ورودی به مخزن سد دز، مدل خودهمبسته شبکه عصبی مصنوعی با تابع فعالیت سیگموئیدی و تعداد ۱۷ نرون در لایه میانی می باشد. مدل های خودهمبسته شبکه عصبی مصنوعی استاتیک و دینامیک با تابع فعالیت سیگموئیدی جریان ورودی به مخزن سد دز را از ۵ سال قبل پیش‌بینی می نمایند.

واژه های کلیدی: پیش‌بینی جریان ورودی به مخزن سد، سد دز، مدل خودهمبسته شبکه عصبی مصنوعی.

۱- استادیار گروه مهندسی آبیاری و زهکشی دانشگاه تهران* (مسئول مکاتبات)

۲- دانش آموخته کارشناسی ارشد مهندسی آبیاری و زهکشی دانشگاه تهران

۳- دانشیار گروه مهندسی آبیاری و زهکشی دانشگاه تهران

مقدمه

استفاده کرد. نتایج نشان داد که غیرخطی بودن مدل‌های شبکه عصبی مصنوعی در بعضی موارد منجر به بهبود دقت پیش‌بینی می‌شود (۲). ساهو^۲ و ری^۳ در سال ۲۰۰۶ پیش‌بینی جریان برای یک رودخانه هاوایی را با استفاده از منحنی‌های دبی-اشل و شبکه‌های عصبی انجام دادند. نتایج حاکی از برتری مدل شبکه عصبی مصنوعی نسبت به روش منحنی‌های دبی-اشل به خصوص زمانی که رفتار جریان رودخانه تغییر می‌کند، بود (۳). کارآموز و همکاران نیز در تحقیقی مدل‌های پایه شبکه عصبی مصنوعی را برای پیش‌بینی سیلاب‌ها تعیین کردند. این کار به عنوان بخشی از سیستم هشدار سیل برای شهر اهواز انجام یافت. سه نوع مختلف شبکه‌های عصبی مصنوعی: شبکه عصبی پرسپترون چند لایه^۴ به عنوان یک شبکه ایستا، شبکه عصبی بازگشت‌کننده المان^۵ و شبکه عصبی تأخیر زمانی به عنوان شبکه دینامیک مورد بررسی قرار گرفتند. مقایسه نتایج پیش‌بینی نشان داد که شبکه عصبی دینامیک به شکل قابل توجهی بهتر عمل می‌کند. نتایج نشان‌دهنده ارزش قابل توجه استفاده از شبکه‌های عصبی مصنوعی به عنوان ابزاری مؤثر در پیش‌بینی سیل است (۴). توث^۶ و همکاران از مدل‌های شبکه عصبی مصنوعی و آرما برای پیش‌بینی بارندگی استفاده کردند. نتایج نشان از موفقیت هر دو مدل در پیش‌بینی بارندگی کوتاه‌مدت برای پیش‌بینی سیلاب‌های زمان واقعی داشت (۵). Kisi و Cigizoglu نیز به کمک شبکه عصبی مصنوعی دینامیک موفق به پیش‌بینی جریان ماهانه ورودی، ذخیره و تبخیر حوضه رودخانه کاناک‌دره^۷ شدند. نتایج برای ذخیره ماهانه و همچنین تبخیر ماهانه رضایت‌بخش بود ولی پیش‌بینی جریان ورودی ماهانه دقت کمتری نسبت به ذخیره و تبخیر ماهانه داشت. آن‌ها از دو تابع فعالیت شعاعی و سیگموئیدی در شبکه عصبی مصنوعی دینامیک استفاده کردند. نتایج

برآورد هرچه دقیق‌تر جریان ماهانه ورودی به مخزن سد به دلیل اهمیتی که در مدیریت و بهره‌برداری از مخزن، تولید انرژی برقی و طراحی سازه‌های کنترل‌کننده دارد، از موضوعات مهم مدیریت منابع آب محسوب می‌شود. در این تحقیق جریان ماهانه ورودی به مخزن سد دز با دو مدل خودهمبسته شبکه عصبی مصنوعی دینامیک و خودهمبسته شبکه عصبی مصنوعی استاتیک پیش‌بینی گردیده است. یکی از مدل‌های معروف جعبه سیاه که دهه اخیر شاهد کاربردهای موفقیت‌آمیز آن در زمینه پیش‌بینی جریان رودخانه بوده‌ایم، مدل شبکه عصبی مصنوعی می‌باشد. شبکه‌های عصبی مصنوعی جزء سیستم‌های دینامیکی هوشمند مدل-آزاد هستند که مبتنی بر داده‌های تجربی بوده و با پردازش روی این داده‌ها، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند (۱). استفاده از شبکه‌های عصبی مصنوعی در زمینه‌های مختلف هیدرولوژی رواج بسیار یافته است که در ادامه به برخی از آن‌ها اشاره می‌شود.

Tawfik در سال ۲۰۰۲ تقابل پیش‌بینی خطی و غیرخطی را در جریانات رودخانه نیل مورد بررسی قرار داد. از آن جا که مصر تقریباً به طور کلی به خاطر تأمین حدود ۹۵٪ از آب‌های مورد نیاز خود وابسته به رودخانه نیل است، سد بلند آسوان در بالاترین نقطه رودخانه نقش مهمی دارد. به طوری که با هر تصمیمی برای رهاسازی، آب از دست رفته بازیافت نشده و مقدار قابل توجهی خواهد بود. بنابراین، پیش‌بینی‌های بلندمدت و کوتاه‌مدت جریانات نیل برای مدیریت بهتر مخزن دارای اهمیت فراوانی است. مدل‌های خودهمبسته^۱ (AR) متعددی برای پیش‌بینی جریان ورودی به مخزن سد آسوان استفاده شدند. ولی اکثر این مدل‌ها در پیش‌بینی شکست خوردند، چرا که نقطه پیک جریان در ماه‌های جولای، آگوست و سپتامبر به شدت تغییر می‌کرد. به عقیده او این عدم دقت در پیش‌بینی به خطی بودن مدل‌های AR برمی‌گردد. به همین منظور از مدل شبکه عصبی مصنوعی استاتیک به جهت ساختار غیرخطی

2- Sahoo

3- Ray

4- Multilayer perceptron

5- Elman recurrent neural network

6- Toth

7- Canak Dere

1- Auto Regressive

ایران، جزئی از حوضه آبریز خلیج فارس می‌باشد. این حوضه در محدوده بین 35° , 32° تا 07° , 34° عرض جغرافیایی شمالی و 20° , 48° تا 20° , 50° طول جغرافیایی شرقی در جنوب غربی ایران واقع شده است. شکل ۱ موقعیت عمومی حوضه آبریز رودخانه دز، شبکه زهکشی و ایستگاه هیدرومتری تله زنگ را نشان می‌دهد.

حوضه دز از غرب به حوضه کرخه از شمال به حوضه قره‌چای و زاینده‌رود و از شرق و جنوب به حوضه کارون محدود است. در این تحقیق به منظور پیش‌بینی آبدهی ایستگاه ورودی به مخزن سد (ایستگاه تله‌زنگ) از داده‌های خود ایستگاه استفاده شده است و به همین دلیل مدل‌های استفاده شده در این تحقیق خودهمبسته نامیده می‌شوند. به منظور پیش‌بینی آمار آبدهی ایستگاه هدف (ایستگاه تله‌زنگ) در محل ورودی به مخزن سد (دز) در مقیاس ماهانه، طول دوره آماری آبدهی ماهانه این ایستگاه از سال آبی ۱۳۳۵-۱۳۳۴ تا سال آبی ۱۳۸۱-۱۳۸۰ انتخاب شده است. در واقع آمار مورد استفاده شامل ۵۶۴ داده می‌باشد که از مهر ماه سال ۱۳۳۴ شروع شده و به شهریور ۱۳۸۱ ختم می‌شود.

روش‌ها

در این تحقیق از دو مدل خودهمبسته شبکه عصبی مصنوعی استاتیک و دینامیک به منظور پیش‌بینی جریان ورودی ماهانه ایستگاه تله‌زنگ استفاده شده و کلیه مراحل لازم در محیط نرم افزار MATLAB برنامه نویسی شده است. شبکه عصبی مصنوعی استفاده شده در این تحقیق دارای یک لایه ورودی، یک لایه میانی و یک لایه خروجی است. علت انتخاب این ساختار ۳ لایه قابلیت بالای این دسته از شبکه‌ها در تخمین روابط پیچیده می‌باشد (۹). تفاوت شبکه‌های عصبی مصنوعی استاتیک و دینامیک، مربوط به استفاده از خروجی مدل به عنوان ورودی می‌باشد. در شبکه‌های دینامیک، خروجی مدل با تأخیر، به عنوان یک ورودی وارد شبکه می‌شود ولی در شبکه عصبی مصنوعی استاتیک از خروجی مدل به عنوان ورودی استفاده نمی‌شود. در این تحقیق از شبکه عصبی

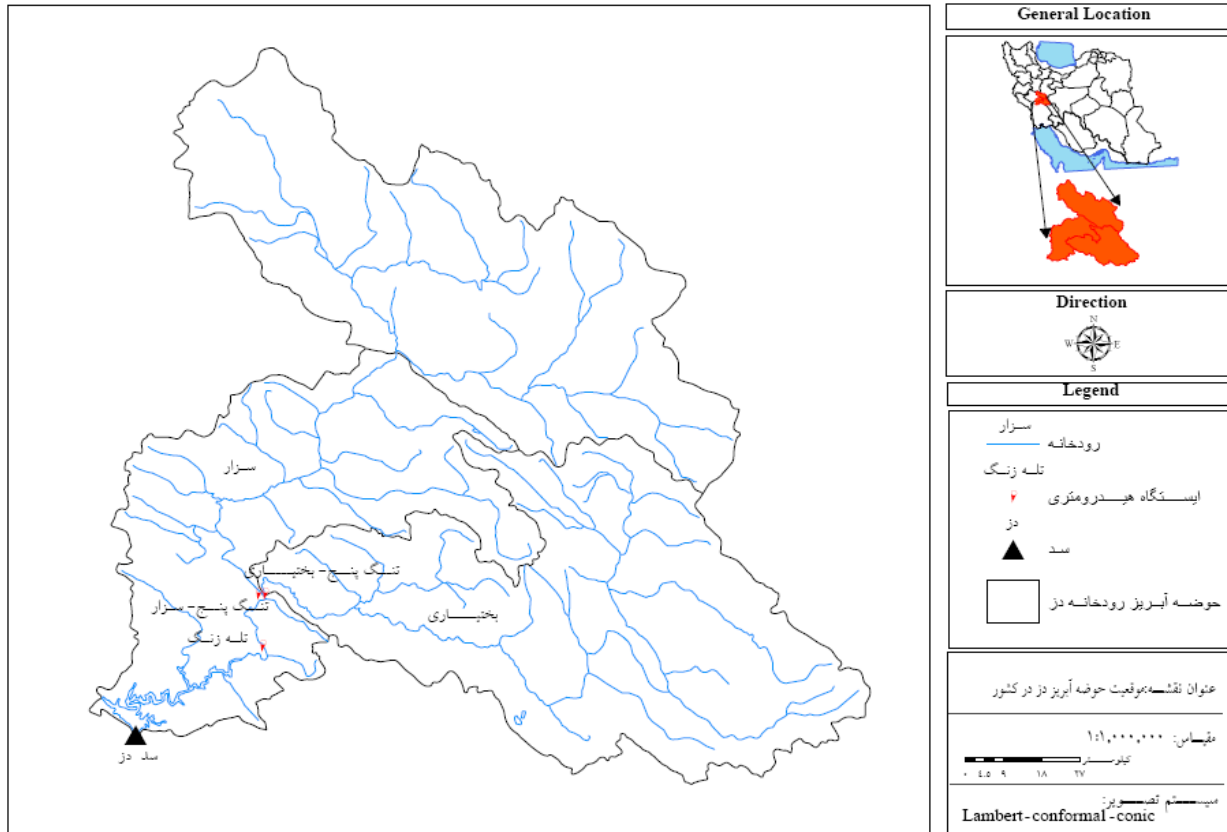
تحقیق آنان نشان داد که تابع فعالیت سیگموئیدی بر تابع فعالیت شعاعی برتری دارد (۶). بنی حبیب و همکاران نیز پیش‌بینی جریان ورودی به مخزن سد دز را در دو مقیاس زمانی روزانه و ماهانه با استفاده از مدل شبکه عصبی مصنوعی استاتیک و مدل رگرسیون خطی معمولی براساس آمار آبدهی ایستگاه‌های هیدرومتری واقع در بالادست ایستگاه مورد نظر که بر روی انشعاب‌های فرعی و اصلی رودخانه قرار دارند، انجام دادند. نتایج به دست آمده دلالت بر عملکرد بهتر مدل شبکه عصبی مصنوعی استاتیک نسبت به مدل رگرسیون خطی در پیش‌بینی جریان ماهانه و روزانه ورودی به مخزن سد داشت (۷). محمدی و همکاران در سال ۲۰۰۵ جریان ورودی به مخزن سد کرج را با استفاده از داده‌های ذوب برف و به کمک روش‌های شبکه عصبی مصنوعی، آرپما و آنالیز رگرسیون پیش‌بینی کردند. ۶۰٪ جریان ورودی به سد بین آوریل تا ژوئن اتفاق می‌افتاد، بنابراین پیش‌بینی جریان ورودی در این فصل برای عملکرد سد بسیار مهم بود. بیشتر جریان ورودی در بهار به علت ذوب برف ناشی از باران‌های نازل شده در زمستان حوضه بود. نتایج نشان داد که به طور معنی‌داری، شبکه عصبی مصنوعی دارای خطای کمتری در مقایسه با سایر روش‌ها بود (۸). بنابراین با توجه به تحقیقات صورت گرفته که به مواردی از آن‌ها اشاره شد، می‌توان به کارایی شبکه‌های عصبی مصنوعی در زمینه پیش‌بینی و مدل‌سازی فرآیندهای هیدرولوژیکی نسبت به سایر مدل‌های آماری از جمله رگرسیون خطی و غیرخطی معمولی پی برد. استفاده از شبکه عصبی مصنوعی دینامیک در پیش‌بینی خودهمبسته جریان ماهانه ورودی به مخزن سد در تحقیقات قبلی انجام نگردیده است. لذا هدف این تحقیق پیش‌بینی جریان ورودی به مخزن سد دز با استفاده از مدل‌های خودهمبسته شبکه عصبی مصنوعی استاتیک و دینامیک و مقایسه این دو مدل براساس آمار آبدهی ایستگاه تله‌زنگ واقع در بالادست سد دز می‌باشد.

مواد

حوضه آبریز دز بخشی از ارتفاعات زاگرس میانی را دربر می‌گیرد. این حوضه از لحاظ تقسیم‌بندی کلی حوضه ای

و نیز لایه پنهان با توابع فعالیت شعاعی و سیگموئیدی

دارای اریب و لایه پنهان با توابع فعالیت شعاعی و سیگموئیدی



شکل ۱- موقعیت عمومی منطقه مورد مطالعه در کشور و ایستگاه هیدرومتری تله زنگ

برای هر واحد لایه مخفی، مقدار اولیه (W_{ij}^{old}) به صورت اتفاقی بین -0.5 و 0.5 اختیار می‌شود. سپس این مقدار به صورت زیر بهبود داده می‌شود (۱۰).

$$W_{ij}^{new} = \beta W_{ij}^{old} / \|W_{ij}^{old}\| \quad (2)$$

به منظور دسته بندی داده های مورد استفاده در شبکه عصبی مصنوعی، آمار آبدی ماهانه از مهر ۱۳۳۴ تا شهریور ۱۳۸۱ به صورت Q1 تا Q564 مرتب شدند. یعنی Q1 مشخص کننده دبی در مهر ماه ۱۳۳۴ و بقیه داده ها نیز به همین ترتیب دبی ماهانه های بعدی می باشد. با توجه به این که شبکه عصبی مصنوعی نیاز به دو مجموعه آموزشی (جهت یادگیری) و آزمایشی (جهت پیش بینی) دارد و این که هر مجموعه شامل دو دسته داده، ورودی و هدف می شود، لذا تقسیم بندی داده ها به این صورت بود که در مجموعه

استفاده شده است. انتخاب مقادیر اولیه وزن ها و اریبها تأثیر زیادی بر روی سرعت شبکه و رسیدن آن به جواب مطلوب دارد. Nguyen و Widrow روشی را پیشنهاد کردند که به واسطه آن انتخاب مقادیر اولیه وزن ها و اریبها بهتر از انتخاب تصادفی آن ها است (۱۰). آنها این کار را با تحلیل چگونگی انجام عمل تقریب زدن توابع توسط یک شبکه دو لایه انجام دادند، استفاده از این روش باعث دستیابی به شبکه ای بهتر از حیث سرعت یادگیری (تعداد تکرارهای کمتر جهت یادگیری) می شود. لذا در این تحقیق از تابع Nguyen-Widrow به منظور مقداردهی اولیه وزن ها استفاده شد. اگر n تعداد نرون های لایه ورودی و p تعداد نرون های لایه مخفی و β فاکتوری به صورت رابطه ۱ باشد،

$$\beta = 0.7^n \sqrt{p} \quad (1)$$

اریب‌ها و نیز تأثیر تأخیر خروجی (در شبکه دینامیک) سیکل ذکر شده تا رسیدن به خطای قابل قبول تکرار می‌شود (۱۰).
تعداد نرون‌های لازم در لایه مخفی حل یک مسأله، در شبکه‌های عصبی مصنوعی به صورت عمومی مشخص نیست و باید به روش تجربی تعیین گردد. ولی می‌توان اظهار داشت که اگر تعداد آن‌ها از حدی کمتر باشد (چنان چه در این تحقیق هم مشاهده شد) ممکن است یادگیری به طور کامل انجام نشود. این حالت به نام برازش ناقص^۳ معروف است و به این معنی است که وزن‌ها و اریب‌هایی که شبکه بتواند به وسیله آن‌ها خروجی‌های منطقی نزدیک به پاسخ‌های صحیح تولید کند، موجود نیست. در مقابل، حالت بیش برازش^۴ ممکن است پیش آید. در این حالت تعداد نرون‌های به کار گرفته شده بیش از حد لازم است. البته در این حالت می‌توان با بالاتر بردن سطح خطاهای هدف، مانع از ایجاد نواسانات شدید و نامطلوب در یادگیری شد و بدین‌نحو از آموزش زیادی شبکه جلوگیری به عمل آورد. نرون‌های بیشتر در لایه‌های مخفی باعث ایجاد درجات آزادی بیشتری در شبکه می‌گردند. (متغیرهای بیشتری باید بهینه شوند) و زمان آموزش بیشتر و ماتریس وزن و بردار اریب بزرگتر می‌گردد، ولی در عین حال نرون‌های بیشتر به معنی احتمال بیشتر برای یافتن جواب و حل مسأله و شانس بیشتر برای به دام نیفتادن در کمینه‌های محلی^۵ است (۱۰). در بخش ۵ نتایج مربوط به حالت برازش ناقص و بیش برازش آورده شده است. از طرف دیگر ثابت شده است که در صورتی که تعداد نرون‌های لایه مخفی کوچکتر یا مساوی تعداد ورودی‌ها باشد، نتایج بهتری را خواهد داد (۱۰). لذا در این تحقیق با آزمون‌های مختلف بهترین تعداد نرون در لایه مخفی به دست آمد. به این ترتیب که ابتدا برای ساختارهای ثابت تعداد نرون‌های لایه میانی ۱۰، ۲۰، ۳۰ تا ۵۹ در نظر گرفته شد. سپس برای بهترین ساختار ۲۰ نرون مربوط به آن محدوده، یکی یکی امتحان گردید که به دلیل ننگجیدن حجم نتایج تمامی ساختارها (برای انتخاب بهترین تعداد نرون)، در

آموزشی برای داده‌های ورودی^۱ از Q1 تا Q264 و برای داده‌های هدف^۲ از Q445 تا Q504 استفاده نموده و در مجموعه آزمایشی (پیش‌بینی) برای داده‌های ورودی از Q265 تا Q444 و برای داده‌های هدف از Q505 تا Q564 استفاده کردیم. به دلیل این‌که تعداد داده‌های ورودی در دو مجموعه آموزشی و آزمایشی باید یکسان باشد لذا در اجرای نهایی مدل‌ها ماتریس‌های ورودی هر کدام شامل ۱۸۰ داده بود که به صورت ۳ بردار ۶۰ تایی که در زیر آمده است مشخص شدند:

$$\begin{bmatrix} Q_{85} & Q_{145} & Q_{205} \\ Q_{86} & Q_{146} & Q_{206} \\ Q_{87} & Q_{147} & Q_{207} \\ \vdots & \vdots & \vdots \\ Q_{144} & Q_{204} & Q_{264} \end{bmatrix} \quad \text{مجموعه آموزشی:}$$

$$\begin{bmatrix} Q_{265} & Q_{325} & Q_{385} \\ Q_{266} & Q_{326} & Q_{386} \\ Q_{267} & Q_{327} & Q_{387} \\ \vdots & \vdots & \vdots \\ Q_{324} & Q_{384} & Q_{444} \end{bmatrix} \quad \text{مجموعه آزمایشی:}$$

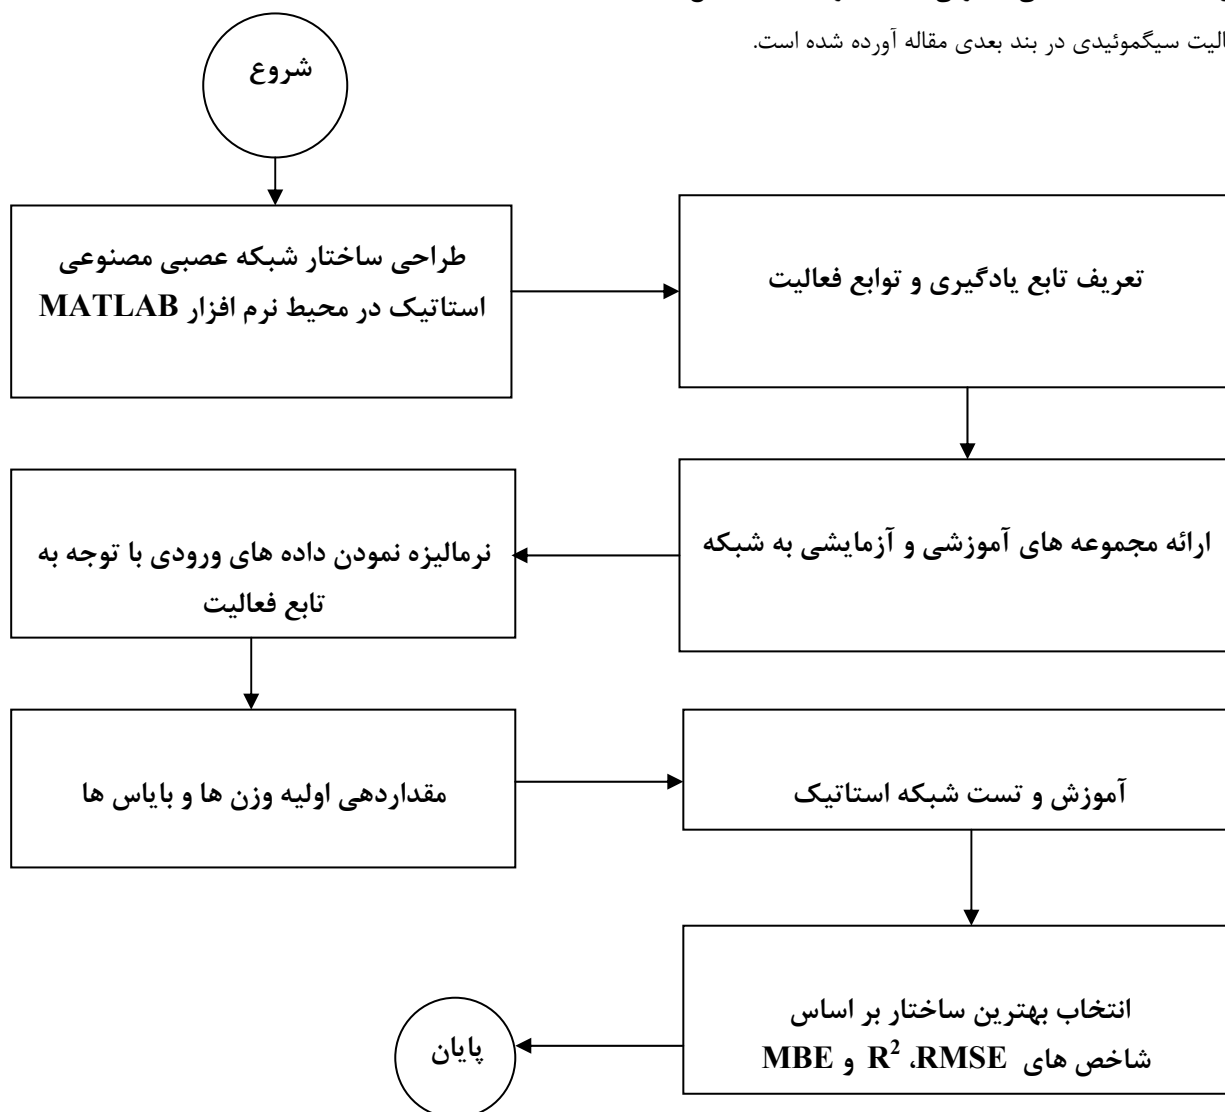
یعنی در مجموعه آموزشی برای محاسبه اولین داده هدف (Q445) از داده‌های Q85، Q145 و Q205 که هر ۴ داده متعلق به یک ماه به‌خصوص می‌باشند، استفاده شد و برای بقیه داده‌ها و نیز مجموعه آزمایشی به طریق مشابه عمل شد. در واقع سیکل یادگیری در شبکه عصبی مصنوعی به این صورت است که ابتدا وزن‌های اولیه و اریب‌ها به داده‌های ورودی مجموعه آموزشی اختصاص یافته و با ورود آن‌ها به لایه مخفی (تأثیر تعداد نرون‌ها) و استفاده از تابع آموزش و توابع فعالیت عمل آموزش شبکه با مقایسه داده‌های ورودی و داده‌های هدف و برقراری ارتباط بین آن‌ها انجام می‌گیرد. سپس برای داده‌های جدید (داده‌های ورودی مجموعه آزمایشی) پیش‌بینی صورت می‌گیرد و با اصلاح وزن‌ها و

3- Under fitting
4- Over fitting
5- Local minimum

1- Input data
2- Target data

شکل ۲ فلوجارت مراحل انجام محاسبه توسط مدل خودهمبسته شبکه عصبی مصنوعی دینامیک را نشان می دهد.

این مقاله به دلیل برتری تابع فعالیت سیگموئیدی بر تابع فعالیت شعاعی، تنها نتایج مربوط به ساختارهای مدل خودهمبسته شبکه عصبی مصنوعی استاتیک و دینامیک با تابع فعالیت سیگموئیدی در بند بعدی مقاله آورده شده است.



شکل ۲- مراحل محاسبات توسط مدل خودهمبسته شبکه عصبی مصنوعی دینامیک

با توجه به تابع فعالیت مراحل بعدی را تشکیل می دهد. سپس وزن های اولیه و اربب ها به داده های ورودی مجموعه آموزشی اختصاص یافته و با ورود آنها به لایه مخفی (تأثیر تعداد نرون ها) و استفاده از تابع آموزش و توابع فعالیت عمل آموزش شبکه با مقایسه داده های ورودی و داده های هدف و برقراری ارتباط بین آنها انجام می گیرد. سپس برای داده های جدید (داده های

الگوریتم مراحل انجام محاسبه توسط مدل خودهمبسته شبکه عصبی مصنوعی دینامیک به صورت زیر است:

ابتدا ساختار شبکه عصبی مصنوعی دینامیک در محیط نرم افزار MATLAB طراحی می شود. سپس تابع یادگیری و توابع فعالیت تعریف می شوند. ارائه مجموعه های آموزشی و آزمایشی به شبکه و نرمالیزه نمودن داده های ورودی

$$F_i = \sum_{i=1}^n E_i / i \quad (5)$$

$$C_v = \left(\sqrt{\sum_{i=1}^n (E_i - \bar{E})^2 / n} \right) / \bar{E} \quad (6)$$

که در آن‌ها، E_i خطای نسبی در ماه i و F_i میانگین خطای نسبی تراکمی در ماه i ، \bar{E} میانگین خطای نسبی و C_v ضریب تغییرات خطای نسبی است.

نتایج و بحث

جدول ۱ شاخص $RMSE / \bar{Q}_{oi}$ آموزشی و پیش-بینی مدل‌های خودهمبسته شبکه عصبی مصنوعی استاتیک و دینامیک را با هر دو تابع فعالیت شعاعی و سیگموئیدی نشان می‌دهد. با توجه به این جدول مشخص می‌شود که مدل‌های خودهمبسته شبکه عصبی مصنوعی دینامیک به کار رفته در این تحقیق به دلیل تأثیر تأخیر خروجی به عنوان ورودی شبکه و افزایش قدرت یادگیری شبکه، نسبت به مدل‌های خود همبسته شبکه عصبی مصنوعی استاتیک در هر دو مرحله آموزش و پیش‌بینی، برتری دارند.

تأثیر انتخاب تابع فعالیت مناسب در جدول ۱ نشان داده شده است. با انتخاب یک تابع فعالیت سیگموئیدی، پیش-بینی به نحو مطلوبی انجام می‌گیرد ولی با انتخاب یک تابع فعالیت نامناسب (شعاعی) دقت پیش‌بینی به طور قابل توجهی کاهش می‌یابد. با توجه به جدول ۱ به دلیل این که شبکه‌های عصبی مصنوعی با تابع فعالیت سیگموئیدی بر شبکه‌های عصبی مصنوعی با تابع فعالیت شعاعی در هر دو مدل استاتیک و دینامیک برتری دارند، لذا شاخص $RMSE / \bar{Q}_{oi}$ داده‌های آموزشی و پیش‌بینی برای شبکه‌های عصبی مصنوعی با تابع فعالیت سیگموئیدی و تعداد نرون‌های مختلف لایه میانی، محاسبه و جهت بررسی در جدول ۲ ارائه شده است.

ورودی مجموعه آزمایشی) پیش‌بینی صورت می‌گیرد و با اصلاح وزن‌ها و اربها، خروجی مدل با یک تأخیر به عنوان ورودی به شبکه وارد می‌شود و سیکل ذکر شده تا رسیدن به خطای قابل قبول تکرار می‌شود (۱۰). الگوریتم مراحل انجام محاسبه توسط مدل خودهمبسته شبکه عصبی مصنوعی استاتیک دقیقاً مشابه مدل خودهمبسته شبکه عصبی مصنوعی دینامیک می‌باشد، با این تفاوت که در مرحله اصلاح وزن‌ها و اربها، خروجی مدل به عنوان ورودی به شبکه وارد نمی‌شود.

معیار انتخاب بهترین ساختار در بین مدل‌های شبکه عصبی مصنوعی

به منظور انتخاب بهترین ساختار در بین شبکه‌های عصبی مصنوعی از شاخص جذر متوسط مربع خطای مدل‌ها به صورت زیر استفاده شد:

$$RMSE = \sqrt{\sum_{i=1}^n (Q_{ci} - Q_{oi})^2 / n} \quad (3)$$

که در آن $RMSE$: جذر متوسط مربع خطا، i : شماره ماه، Q_{ci} : دبی محاسباتی در ماه i ، Q_{oi} : دبی مشاهده‌ای در ماه i و n : تعداد داده‌ها است. در نهایت برای قابل مقایسه بودن نتایج این تحقیق با سایر تحقیقات مشابه از شاخص خطای $RMSE / \bar{Q}_{oi}$ استفاده شده است که \bar{Q}_{oi} مشخص‌کننده دبی متوسط مشاهده‌ای است. شایان ذکر است مقدار \bar{Q}_{oi} برای دوره آموزش داده‌های ۴۴۵ تا ۵۰۴ را شامل شده و m^3/s و $335/7$ و برای دوره پیش‌بینی داده‌های ۵۰۵ تا ۵۶۴ را شامل شده و $199/9m^3/s$ بود. همچنین برای مشخص کردن خطای زمانی و تعیین بهترین مدت زمان پیش‌بینی، از ۳ شاخص زیر استفاده شده است.

$$E_i = |Q_{ci} - Q_{oi}| / Q_{oi} \quad (4)$$

جدول ۱- مقایسه نهایی مدل‌های استفاده شده جهت پیش‌بینی جریان ورودی به مخزن سد دز در ایستگاه تله زنگ

پیش‌بینی $RMSE / \bar{Q}_{oi}$	آموزش $RMSE / \bar{Q}_{oi}$	نام مدل
۰/۶۳۸	۰/۷۴۳۶	مدل خودهمبسته شبکه عصبی مصنوعی دینامیک با تابع فعالیت سیگموئیدی
۰/۶۶۳	۰/۸۰۴۶	مدل خودهمبسته شبکه عصبی مصنوعی استاتیک با تابع فعالیت سیگموئیدی
۰/۸۴	۰/۸۲۱۱	مدل خودهمبسته شبکه عصبی مصنوعی دینامیک با تابع فعالیت شعاعی
۱/۰۰۱۹	۱/۱۰۰۹	مدل خودهمبسته شبکه عصبی مصنوعی استاتیک با تابع فعالیت شعاعی

جدول ۲- تأثیر تعداد نرون‌های لایه مخفی در دقت پیش‌بینی

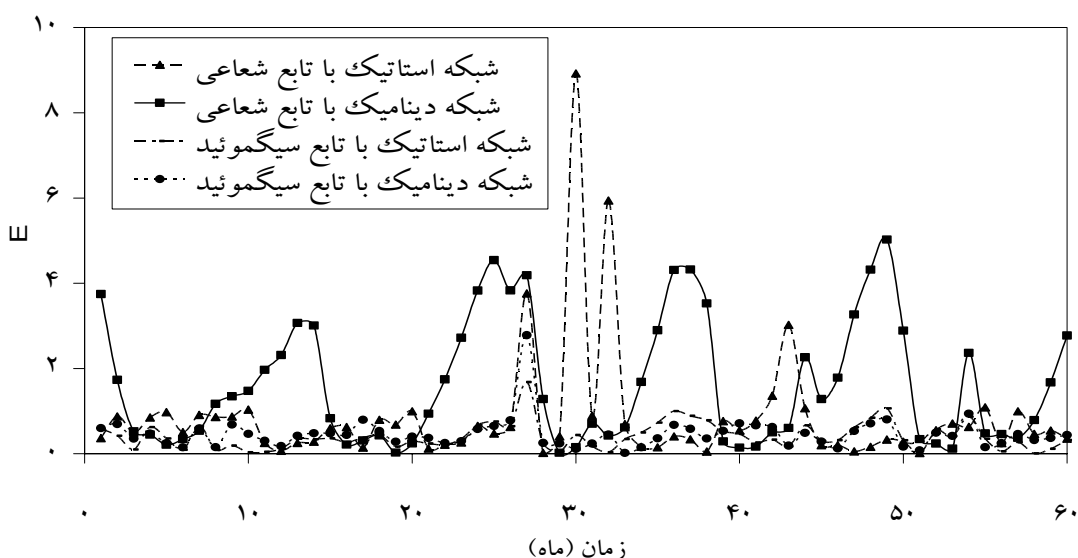
پیش‌بینی $RMSE / \bar{Q}_{oi}$	آموزش $RMSE / \bar{Q}_{oi}$	تعداد نرون (های) لایه میانی	نوع شبکه عصبی	پیش‌بینی $RMSE / \bar{Q}_{oi}$	آموزش $RMSE / \bar{Q}_{oi}$	تعداد نرون (های) لایه میانی	نوع شبکه عصبی
۰/۷۳۲۷	۰/۹۳۵۱	۱۰	دینامیک	۰/۷۹۷۷	۰/۹۷۸۶	۱۰	استاتیک
۰/۹۱۹۲	۰/۶۲۸	۲۰	دینامیک	۰/۸۳۶۵	۰/۹۵۹۲	۲۰	استاتیک
۰/۷۹۱۶	۰/۷۷۳۵	۳۰	دینامیک	۱/۰۰۲۸	۰/۸۵۸۳	۳۰	استاتیک
۰/۸۵۶	۰/۸۴۸۴	۴۰	دینامیک	۰/۸۶۶۲	۱/۰۴۰۳	۴۰	استاتیک
۰/۸۱۱۱	۰/۶۷۶	۵۰	دینامیک	۰/۸۲۲۸	۰/۸۴۲	۵۰	استاتیک
۰/۹۵۸۶	۰/۹۰۲۱	۵۹	دینامیک	۰/۹۷۶۷	۰/۸۴۳۵	۵۹	استاتیک
۰/۷۳۲۴	۰/۸۸۴	۱	دینامیک	۰/۸۱۷۹	۰/۹۹۶۳	۱	استاتیک
۰/۷۴۸۵	۱/۰۱۱۵	۲	دینامیک	۰/۷۹۷۶	۰/۹۲۸	۲	استاتیک
۰/۷۹۲۶	۰/۹۱۷۳	۳	دینامیک	۰/۷۵۷۷	۰/۷۹۳۷	۳	استاتیک
۰/۸۲۲۸	۰/۸۴۸۸	۴	دینامیک	۰/۸۱۱۹	۰/۷۸۳۲	۴	استاتیک
۰/۷۳۳۸	۰/۸۰۶۶	۵	دینامیک	۰/۸۱۹۹	۰/۸۸۳۱	۵	استاتیک
۰/۷۱۳۲	۰/۸۸۰۵	۶	دینامیک	۰/۶۶۳	۰/۸۰۴۶	۶	استاتیک
۰/۸۰۱۲	۰/۹۱۶۳	۷	دینامیک	۰/۷۷۲۲	۰/۸۹۴۹	۷	استاتیک
۰/۷۳۹۸	۰/۷۴۸۹	۸	دینامیک	۰/۷۴۹۲	۰/۸۷۶۲	۸	استاتیک
۰/۶۶۸۶	۰/۷۴۷۹	۹	دینامیک	۰/۸۷۶۸	۰/۹۴۶۲	۹	استاتیک
۰/۷۲۵	۰/۷۷۰۸	۱۱	دینامیک	۰/۸۹۹۸	۰/۷۵۵	۱۱	استاتیک
۰/۷۳۶۷	۰/۷۶۱۳	۱۲	دینامیک	۰/۷۶۵۱	۰/۹۵۵۹	۱۲	استاتیک
۰/۷۹۰۸	۰/۸۴۴۶	۱۳	دینامیک	۰/۷۰۷۲	۰/۸۶۱۷	۱۳	استاتیک
۰/۷۸۳	۰/۹۴۲۱	۱۴	دینامیک	۰/۸۱۷۸	۰/۷۱۲	۱۴	استاتیک
۰/۸۰۱۷	۰/۹۷۱۴	۱۵	دینامیک	۰/۸۶۲۶	۰/۶۵۵۲	۱۵	استاتیک
۰/۸۲۱۶	۰/۸۴۹۷	۱۶	دینامیک	۰/۸۱۹۷	۰/۷۵۶۵	۱۶	استاتیک
۰/۶۳۸	۰/۷۴۳۶	۱۷	دینامیک	۰/۸۲۰۲	۰/۶۴۷۴	۱۷	استاتیک
۰/۸۵۰۶	۰/۹۲۳۶	۱۸	دینامیک	۰/۸۴۸۳	۰/۸۴۲۴	۱۸	استاتیک
۰/۷۴۸۱	۱/۰۴۴	۱۹	دینامیک	۰/۸۸۳۸	۰/۷۵۷۸	۱۹	استاتیک

و در نتیجه این مدل مناسبتر است. جدول ۳ حداقل میزان شاخص‌های E و F ، ماه وقوع این مقادیر و میزان شاخص C_v را برای دوره پیش‌بینی نشان می‌دهد. برای مقایسه بهتر شاخص‌های E و F در دوره پیش‌بینی می‌توان به ترتیب از شکل‌های ۳ و ۴ استفاده کرد. به منظور بررسی تغییرات زمانی پیش‌بینی از روابط (۴)، (۵) و (۶) استفاده شده و بهترین مدت زمان پیش‌بینی برای مدل‌ها به دست آمد.

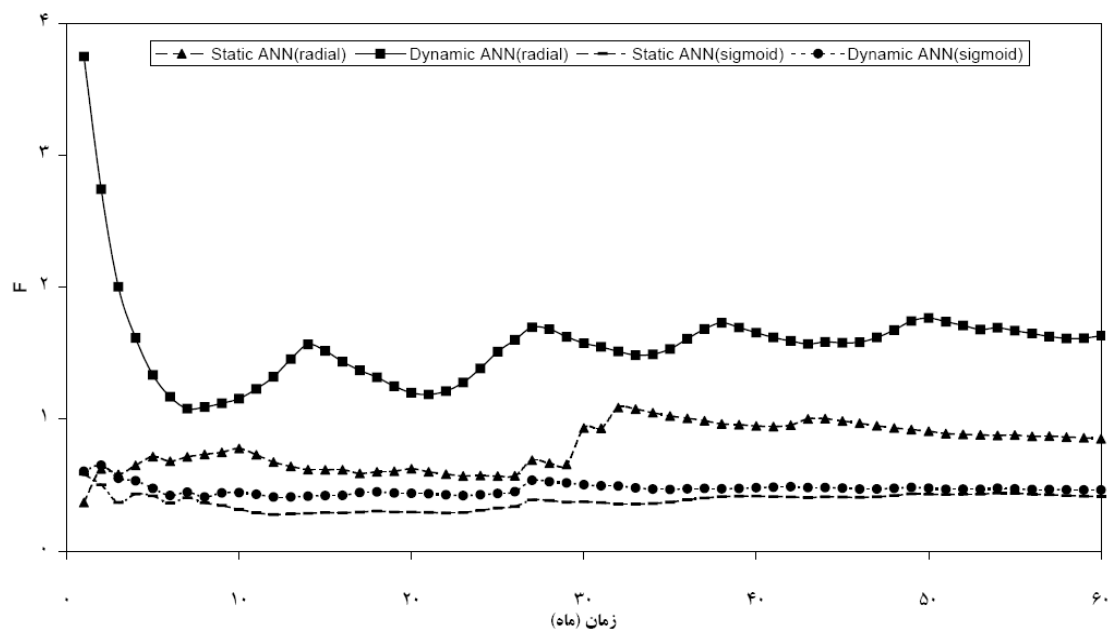
همان طور که از جدول ۲ معلوم است، در هر دو شبکه استاتیک و دینامیک با تعداد نرون‌های بیشتر از ۲۰ به دلیل حالت بیش برآزش دقت پیش‌بینی کاهش یافته و نیز در شبکه استاتیک با تعداد نرون‌های کمتر از ۶ و در شبکه دینامیک با تعداد نرون‌های کمتر از ۱۷ به دلیل برآزش ناقص پیش‌بینی درستی انجام نمی‌شود. بررسی این جدول نشان می‌دهد که شاخص $RMSE/\bar{Q}_{oi}$ آموزش و پیش‌بینی مدل خودهمبسته شبکه عصبی مصنوعی دینامیک با تابع فعالیت سیگموئیدی و تعداد ۱۷ نرون در لایه پنهان (میانی) کمتر بوده

جدول ۳- حداقل میزان شاخص‌های E و F و ماه وقوع آنها در دوره پیش‌بینی

نام مدل	E_{min}	ماه وقوع	\bar{E}	F_{min}	ماه وقوع	C_v
مدل خودهمبسته شبکه عصبی مصنوعی دینامیک با تابع فعالیت سیگموئیدی	۰/۰۲۰۵	خرداد سال سوم	۰/۴۶۲	۰/۴۰۹۱	شهریور سال اول	۰/۷۹۴۳
مدل خودهمبسته شبکه عصبی مصنوعی استاتیک با تابع فعالیت سیگموئیدی	۰/۰۰۸۴	تیر سال پنجم	۰/۴۱۳۴	۰/۲۷۵۵	شهریور سال اول	۰/۷۳۸۲
مدل خودهمبسته شبکه عصبی مصنوعی دینامیک با تابع فعالیت شعاعی	۰/۰۲۵۲	بهمن سال سوم	۱/۶۳۱۷	۱/۰۷۸۶	فروردین سال اول	۰/۸۸۸۶
مدل خودهمبسته شبکه عصبی مصنوعی استاتیک با تابع فعالیت شعاعی	۰/۰۱۶۶	آذر سال پنجم	۰/۸۴۹۸	۰/۳۶۷۲	مهر سال اول	۱/۶۳۸۶



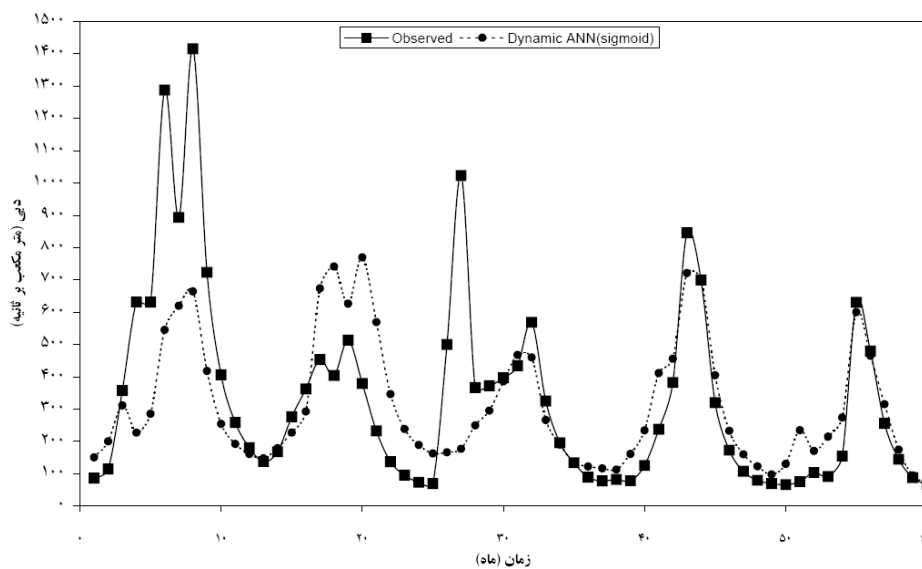
شکل ۳- تغییرات شاخص E مدل‌های به کار رفته در تحقیق در دوره پیش‌بینی



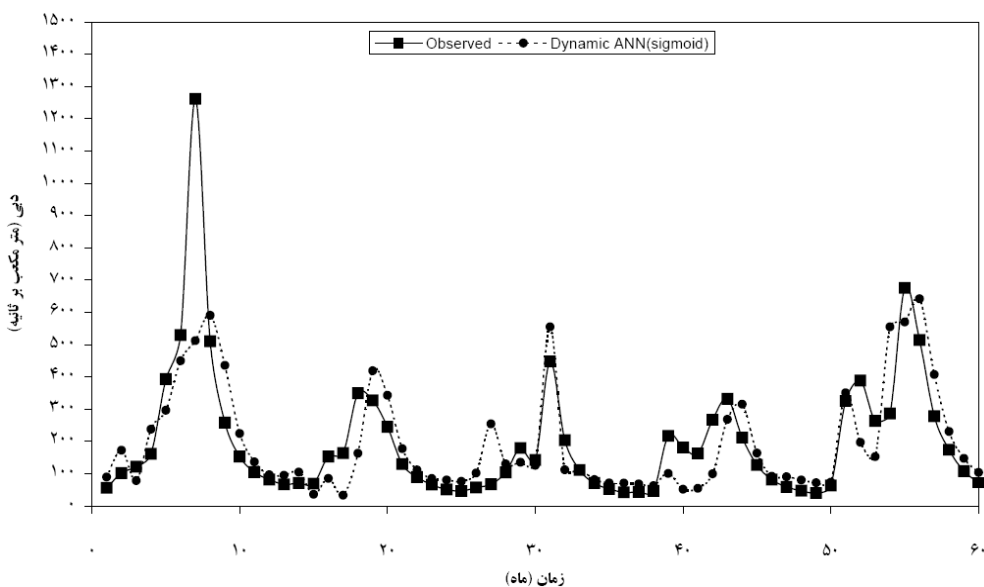
شکل ۴- تغییرات شاخص F مدل‌های به کار رفته در تحقیق در دوره پیش‌بینی

خطای نسبی و ضریب تغییرات خطای نسبی مدل‌های خودهمبسته شبکه عصبی مصنوعی با تابع فعالیت سیگموئیدی نسبت به مدل‌های خودهمبسته شبکه عصبی مصنوعی با تابع فعالیت شعاعی نشان دهنده تغییرات کمتر خطا برای مدل‌های خودهمبسته شبکه عصبی مصنوعی با تابع فعالیت سیگموئیدی بوده و بر برتری مدل‌های خودهمبسته شبکه عصبی مصنوعی با تابع فعالیت سیگموئیدی نسبت به مدل‌های خودهمبسته شبکه عصبی مصنوعی با تابع فعالیت شعاعی دلالت دارد. با توجه به بحث‌های یاد شده مدل خودهمبسته شبکه عصبی مصنوعی دینامیک با تابع فعالیت سیگموئید و ۱۷ نرون در لایه میانی به عنوان مدل برتر انتخاب می‌شود. شکل‌های ۵، ۶ و ۷ نتایج مدل برتر را به ترتیب در دوره‌های آموزش و پیش‌بینی با داده‌های مشاهده‌ای مقایسه می‌کنند.

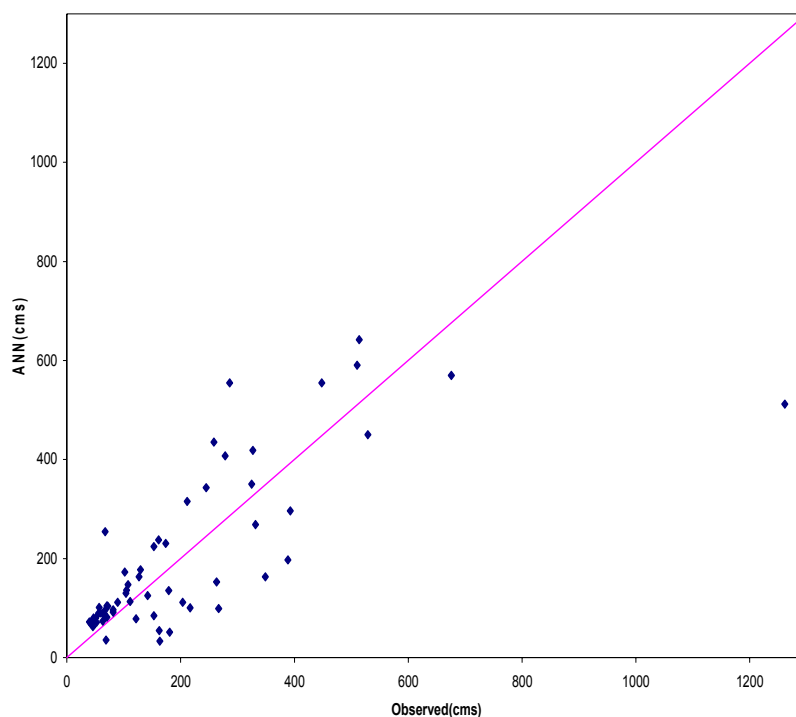
بررسی جدول ۳ و نیز شکل‌های ۳ و ۴ مقادیر کمتر شاخص‌های E و F را برای مدل‌های خودهمبسته شبکه عصبی مصنوعی با تابع فعالیت سیگموئیدی نسبت به مدل‌های خودهمبسته شبکه عصبی مصنوعی با تابع فعالیت شعاعی نشان می‌دهد. شکل ۳ نشان می‌دهد که تغییرات خطای نسبی در مدل‌های خودهمبسته شبکه عصبی مصنوعی با تابع فعالیت سیگموئیدی نسبت به مدل‌های خودهمبسته شبکه عصبی مصنوعی با تابع فعالیت شعاعی کمتر بوده و بر اساس جدول ۳ ضریب تغییرات این مدل‌ها نیز کمتر می‌باشد. شکل ۴ نشان می‌دهد که میانگین خطای نسبی تراکمی در مدل‌های خودهمبسته شبکه عصبی مصنوعی با تابع فعالیت سیگموئیدی نوسانات کمتری دارد. به عبارت دیگر مدل‌های خودهمبسته شبکه عصبی مصنوعی با تابع فعالیت سیگموئیدی به نوعی ایستایی در خطا رسیده‌اند. همچنین مقدار کمتر میانگین



شکل ۵- مقایسه مدل خودهمبسته شبکه عصبی مصنوعی دینامیک در دوره آموزش با هیدروگراف مشاهده‌ای



شکل ۶- مقایسه مدل خودهمبسته شبکه عصبی مصنوعی دینامیک در تحقیق در دوره پیش‌بینی با هیدروگراف مشاهده‌ای



شکل ۷- مقایسه داده های مشاهده‌ای با مدل برتر شبکه عصبی مصنوعی در دوره پیش‌بینی بدون

در نظر گرفتن زمان وقوع

شبکه عصبی مصنوعی استاتیک با تابع فعالیت سیگموئیدی به ترتیب 0.67 ، 0.75 و 0.75 نسبت به مدل خودهمبسته شبکه عصبی مصنوعی دینامیک با تابع فعالیت شعاعی کاهش یافته است. دو مدل با دو ساختار متفاوت و دو تابع فعالیت متفاوت نیز قابل مقایسه می‌شوند. از آن جا که تنها تفاوت ساختارهای استاتیک و دینامیک مربوط به تأخیر خروجی است، می‌توان با توجه به نتایج به تأثیر بیشتر تابع فعالیت نسبت به تأخیر خروجی در دقت پیش‌بینی پی برد.

در نهایت مدل شبکه عصبی مصنوعی دینامیک با تابع فعالیت سیگموئیدی و تعداد ۱۷ نرون در لایه پنهان (میانی) با شاخص $RMSE/Q_{test}$ معادل 0.638 ، به عنوان بهترین مدل در پیش‌بینی جریان ورودی به مخزن سد دز در ایستگاه تله‌زنگ انتخاب می‌شود. بعد از این مدل به ترتیب مدل‌های شبکه عصبی مصنوعی استاتیک با ۶ نرون در لایه میانی و تابع فعالیت سیگموئیدی و بعد از آن مدل شبکه عصبی مصنوعی دینامیک با تابع فعالیت شعاعی و تعداد ۲۷ نرون در لایه میانی در رده دوم و سوم پیش‌بینی قرار گرفتند. در نهایت

با توجه به جدول ۳ میزان شاخص‌های E_{min} ، \bar{E} و C_v در مدل خودهمبسته شبکه عصبی مصنوعی استاتیک با تابع فعالیت سیگموئیدی نسبت به مدل خودهمبسته شبکه عصبی مصنوعی استاتیک با تابع فعالیت شعاعی نزدیک به 0.50 کاهش یافته است. میزان شاخص \bar{E} و F_{min} نیز در مدل خودهمبسته شبکه عصبی مصنوعی دینامیک با تابع فعالیت سیگموئیدی نسبت به مدل خودهمبسته شبکه عصبی مصنوعی دینامیک با تابع فعالیت شعاعی به ترتیب بیش از 0.60 و 0.50 کاهش یافته که این موارد نشان دهنده کاهش قابل توجه خطا در مدل‌های خودهمبسته شبکه عصبی مصنوعی با تابع فعالیت سیگموئیدی نسبت به مدل‌های خودهمبسته شبکه عصبی مصنوعی با تابع فعالیت شعاعی داشته و مزیت استفاده از تابع فعالیت سیگموئیدی را آشکار می‌سازد. مقایسه مدل خودهمبسته شبکه عصبی مصنوعی استاتیک با تابع فعالیت سیگموئیدی با مدل خودهمبسته شبکه عصبی مصنوعی دینامیک با تابع فعالیت شعاعی در جدول ۳ نشان می‌دهد که میزان شاخص‌های E_{min} ، \bar{E} و F_{min} در مدل خودهمبسته

با تابع فعالیت سیگموئیدی آبدهی مدت زمان ۵ سال آینده را با دقت مناسبی پیش‌بینی کرد.

جمع بندی و نتیجه گیری

در این مقاله قابلیت مدل‌های خود همبسته شبکه عصبی مصنوعی استاتیک و دینامیک در پیش‌بینی جریان ورودی به مخزن سد دز در ایستگاه تله زنگ مقایسه شده است. آمار آب دهی ماهانه مربوط به ۴۲ سال از ایستگاه هیدرومتری تله زنگ جمع آوری شده و برای آموزش مدل‌ها مورد استفاده قرار گرفت. سپس با استفاده از داده‌های ۵ سال اخیر درستی پیش‌بینی مدل‌ها مورد بررسی قرار گرفت. با جمع بندی بررسی‌های انجام شده در این مقاله، می‌توان نتیجه‌گیری‌های زیر را به عمل آورد:

- مدل‌های خود همبسته شبکه عصبی مصنوعی دینامیک به کار رفته در این تحقیق به دلیل تاثیر تاخیر خروجی به عنوان یک ورودی به شبکه و افزایش قدرت یادگیری شبکه، نسبت به مدل‌های خود همبسته شبکه عصبی مصنوعی استاتیک در هر دو مرحله آموزش و پیش‌بینی، برتر می‌باشند.
- تاثیر انتخاب تابع فعالیت و تعداد نرون‌های مناسب لایه میانی در این مقاله به خوبی مشخص شد. چرا که با انتخاب تابع فعالیت و تعداد نرون‌های مناسب، پیش‌بینی به نحو مطلوبی انجام می‌گیرد ولی با انتخاب تابع فعالیت و تعداد نرون‌های نامناسب دقت پیش‌بینی به طور قابل توجهی کاهش می‌یابد. تعداد مناسب نرون‌های لایه میانی برای شبکه‌های استاتیک و دینامیک به ترتیب ۶ و ۱۷ بوده و تابع فعالیت مناسب سیگموئید می‌باشد.
- تغییرات خطای نسبی، میانگین خطای نسبی تراکمی و ضریب تغییرات خطای نسبی در مدل‌های خود همبسته شبکه عصبی مصنوعی با تابع فعالیت سیگموئیدی نسبت به مدل‌های خود همبسته شبکه عصبی مصنوعی با تابع فعالیت شعاعی کمتر بود که

مدل شبکه عصبی مصنوعی استاتیک با تابع فعالیت شعاعی و تعداد چهار نرون در لایه مخفی (میانی) در رتبه چهارم قرار گرفت. بنابراین مدل‌های خودهمبسته شبکه عصبی مصنوعی دینامیک به کار رفته در این تحقیق به دلیل تأثیر تأخیر خروجی به عنوان یک ورودی به شبکه و افزایش قدرت یادگیری شبکه، نسبت به مدل‌های خودهمبسته شبکه عصبی مصنوعی استاتیک در هر دو مرحله آموزش و پیش‌بینی، برتر می‌باشند.

همان طور که از شکل‌های ۵، ۶ و ۷ مشخص می‌شود، مشکل مدل‌های شبکه عصبی مصنوعی خطای نسبتاً قابل توجه پیش‌بینی آبدهی حداکثر ماهانه می‌باشد. در شبکه‌های عصبی مصنوعی به دلیل این که داده‌های ورودی به صورت سه بردار ۶۰ تایی به شبکه وارد می‌شوند (هر بردار از لحاظ آماری ادامه بردار قبلی است) که هر بردار مربوط به پنج سال می‌باشد که با مهر سال اول شروع شده و به شهریور سال پنجم ختم می‌شود. در نتیجه برای پیش‌بینی هر ماه علاوه بر این که به ارتباط یک ماه به یک ماه هر دسته ۶۰ تایی توجه می‌شود، به ارتباطی که هر داده در این دسته ۶۰ تایی با دو دسته دیگر دارد نیز توجه می‌شود. به تعبیر بهتر اگر نوع ارتباط بین داده‌ها را به عنوان یک پارامتر هیدرولوژیکی در نظر بگیریم، مدل شبکه عصبی مصنوعی از دو پارامتر هیدرولوژیکی (ارتباط یک ماه به یک ماه هر دسته ۶۰ تایی و ارتباطی که هر داده در این دسته ۶۰ تایی با دو دسته دیگر دارد) استفاده می‌کند. این امر نشان می‌دهد که شبکه‌های عصبی مصنوعی در پیش‌بینی‌های بلند مدت عملکرد بهتری دارند. این موضوع در شکل‌های ۵ و ۶ تأیید می‌شود. زیرا هرچه در این شکل‌های به سمت نقاط انتهایی دوره پیش می‌رویم، دقت پیش‌بینی نقاط پیک افزایش می‌یابد. با توجه به شکل‌های ۳ تا ۶ و نیز جدول ۳ انتخاب بهترین مدت زمان پیش‌بینی دشوار می‌باشد ولی با توجه به این که هر چه به سمت انتهایی دوره پنج ساله پیش‌بینی، پیش می‌رویم، نوسان‌ها کم شده و حتی دقت پیش‌بینی‌ها (به خصوص در نقاط پیک) افزایش می‌یابد، نتیجه می‌گیریم که می‌توان با مدل خودهمبسته شبکه عصبی مصنوعی دینامیک

Paper, Decision Making in Urban and Civil Engineering, USA.

5. Toth, E., A. Brath, A. Montanari, (2000), "Comparison of short-term rainfall predication models for real-time flood forecasting", Journal of Hydrology 239, PP. 132-147.

6. Kisi, I., Kerem Cigizoglu, (2005), "Reservoir Management Using Artificial Neural Networks", 14th. Reg Directorate of DSI(State Hydraulic Works) Istanbul/Turkey.

۷. بنی حبیب، م. ا.، موسوی، س. م.، جمالی، ف. س.،

(۱۳۸۷)، "مدل شبکه عصبی مصنوعی برای بررسی

همبستگی مکانی و زمانی بین ایستگاه‌ها در پیش

بینی جریان ورودی به مخزن سد"، سومین کنفرانس

مدیریت منابع آب ایران، تبریز.

8. Mohammadi, K., H. R. Eslami and Sh. Dayyani Dardashti, (2005), "Comparison of Regression ARIMA and ANN Models for Reservoir Inflow Forecasting using Snowmelt Equivalent(A Case Study of Karaj)", Journal of Agriculture Science Technology.

۹. گودرزوند چگینی، ا.، (۱۳۸۴)، "جعبه ابزارهای

"MATLAB"، انتشارات ناقوس.

۱۰. آوریده، ف.، (۱۳۷۷)، "کاربرد هیدروانفورماتیک در

انتقال رسوب"، پایان‌نامه کارشناسی ارشد، دانشگاه

صنعتی امیرکبیر، تهران.

این موضوع بر برتری مدل‌های خود همبسته شبکه

عصبی مصنوعی با تابع فعالیت شعاعی دلالت دارد.

بررسی عوامل یاد شده نشان می‌دهد استفاده از

مدل خود همبسته شبکه عصبی مصنوعی دینامیک

با تابع فعالیت سیگموئیدی برای پیش‌بینی آبدهی ۵

سال آینده مناسب است.

قدردانی

این مقاله نتیجه طرح پژوهشی دانشگاه تهران بوده و

بدین وسیله از مدیریت دانشگاه تهران برای فراهم سازی امکان

این تحقیق قدردانی می‌شود.

منابع

۱. منهاج، م. ب.، (۱۳۷۷)، «شبکه‌های عصبی

مصنوعی»، انتشارات دانشگاه صنعتی امیرکبیر.

2. Tawfik, M., (2003), "Linearity versus non-linearity in forecasting Nile River flows", Advances in Engineering Software 34, PP. 515-524.

3. Sahoo G. B. and Ray C., (2006), "Flow forecasting for a Hawaii stream using rating curves and neural networks", Journal of Hydrology, PP., 63-80.

4. Karamouz M., Razavi S. and Araghinejad Sh. (2005), "Application of Artificial Neural Networks in Flood Estimation", Conference Proceeding