



دانشگاه صنعتی امیرکبیر
(پلی تکنیک تهران)

دوره چهل و شش، شماره ۱، تابستان ۱۳۹۳، صفحه ۱ تا ۱۰
Vol. 46, No. 1, Summer 2014, pp. 1-10



نشریه علمی - پژوهشی امیرکبیر (مهندسی عمران و محیط زیست)
Amirkabir Journal of Science & Research (Civil & Environmental Engineering)
(AJSR - CEE)

تولید مصنوعی جریان رودخانه با استفاده از شبکه‌های عصبی مصنوعی

مصطفی یگانه‌فرد^۱، باقر ذهبیون^{۲*}

۱- کارشناسی‌ارشد، دانشکده مهندسی عمران و محیط زیست، دانشگاه علم و صنعت ایران
۲- استادیار، دانشکده مهندسی عمران و محیط زیست، دانشگاه علم و صنعت ایران

(دریافت ۱۳۸۸/۱۰/۲۱، پذیرش ۱۳۹۱/۸/۲۰)

چکیده

در این مطالعه قابلیت مدل‌های شبکه عصبی مصنوعی در زمینه تولید مصنوعی جریان ارزیابی شده است. مدلی که برای تولید مصنوعی به کار رفته با ترکیب مدل شبکه عصبی و یک مؤلفه تصادفی با توزیع نرمال ایجاد شده است. در توسعه مدل از شبکه عصبی چندلایه تغذیه پیشرفتی با الگوریتم آموزشی انتشار برگشتی خطا استفاده شده است. بر این اساس، مدل سری‌های بلندمدت و تا ۳۰۰ سال جریان مصنوعی روزانه در رودخانه خرسان را فقط با استفاده از آمار روزانه جریان مشاهداتی در این رودخانه تولید نموده است. به منظور ارزیابی قابلیت مدل در تولید جریان از مقایسه آماره‌های پایه از قبیل میانگین، انحراف معیار و چولگی و آماره‌های معرف دوام در سری‌های زمانی از قبیل آماره‌های خودهمبستگی در سری‌های تولیدی و مشاهداتی استفاده شده است. نتایج، بیانگر توانایی مدل در زمینه تولید مصنوعی جریان و قابلیت شبکه‌های عصبی مصنوعی در تولید مصنوعی مقادیر روزانه جریان است.

کلمات کلیدی

شبکه‌های عصبی مصنوعی، سری زمانی، تولید سنتزی جریان، مؤلفه تصادفی، ویژگی‌های آماری.

* نویسنده مسئول و عهدہ دار مکاتبات Email: Bagher@iust.ac.ir

۱- مقدمه

با توجه به کمبود منابع آب در پهنه وسیعی از کشور و فصلی بودن بیش تر رودخانه‌ها، کنترل و مدیریت آب‌های سطحی اهمیت و حساسیت فوق‌العاده‌ای دارد و نیاز مبرمی به شناسایی و مدل‌سازی رفتار رودخانه‌ها و شریان‌های آبی برای برنامه‌ریزی‌های بلندمدت و استفاده بهتر از پتانسیل‌های آنها وجود دارد. مقدار رواناب در یک مقطع از رودخانه، از مهم‌ترین متغیرهای هیدرولوژیکی حوضه محسوب می‌شود. دسترسی به سری‌های زمانی رواناب به منظور انجام بررسی‌های پایه در ارائه طرح‌های آبی، تحلیل پیامدهای زیست‌محیطی، کنترل سیل و طراحی و مدیریت انواع سازه‌های هیدرولیکی و مسائل مدیریت و برنامه‌ریزی سیستم‌های منابع آب، بسیار اهمیت دارد [۱۹].

در بسیاری موارد، سری‌های مقادیر جریان مشاهداتی و ثبت شده در یک نقطه از رودخانه محدود و کوتاه است. با اکتفا به این سری‌های مشاهداتی، ویژگی‌های آماری جریان را با قابلیت اطمینان اندکی می‌توان تخمین زد. برای مثال در سیاست‌گذاری به منظور بهره‌برداری از یک مخزن با روش برنامه‌ریزی دینامیکی استوکاستیک و ماتریس انتقال احتمالاتی، به‌ویژه هنگامی که تابع هدف حداکثرسازی سود باشد، نقشی کلیدی دارد. تخمین این ماتریس با در اختیار داشتن یک سری طولانی و بلندمدت از جریان، به‌طور قابل اطمینان‌تری میسر است [۲۱].

لاکس [۱۳]، به محدودیت‌های ناشی از به‌کارگیری داده‌های مشاهداتی برای شبیه‌سازی رفتار آینده مجموعه‌های منابع آب در طراحی‌ها و استراتژی‌های مختلف اشاره نموده و بهبود طراحی و تصمیم‌گیری را با بکارگیری و آزمون سناریوهای مختلف تولیدی بیان می‌نماید. براس و رودریگز [۵] ضمن تاکید به عدم قطعیت زیاد و طبیعت تصادفی متغیرهای هیدرولوژیکی بیان نموده‌اند که استفاده و اکتفا به داده‌های مشاهداتی به‌تنهایی، نتایج ضعیفی را در پی دارد. در این شرایط ممکن است به بسط، تطویل آمار و در نظر گرفتن سناریوهای محتمل آتی به کمک سری‌های مشاهداتی نیاز باشد که این مهم با مدل‌سازی و تولید مقادیر میسر می‌شود.

یکی از رایج‌ترین روش‌های مدل‌سازی سری‌های زمانی هیدرولوژیکی و تولید سنتزی جریان، مدل‌های اتورگرسیو میانگین متحرک [۴] هستند [۱۹]. اگر چه از این مدل‌ها در تولید مصنوعی زیاد استفاده شده است، با این حال همواره نتایج مطلوبی را در بازتولید ویژگی‌های آماری داده‌های مشاهداتی در پی نداشته‌اند. از طرف دیگر بیش‌تر این روش‌ها در تحلیل سری زمانی، با فرض خطی بودن روابط بین متغیرها توسعه یافته‌اند.

روابط خطی بین متغیرها فرض درستی نیست و به بهترین

نتیجه منجر نمی‌شود [۱۲]. آن‌چه در جهان واقعی رخ می‌دهد نشان‌دهنده آن است که تغییرات زمانی متغیرها و پدیده‌های هیدرولوژیکی از نظم و قاعده ساده‌ای پیروی نمی‌نمایند و روابط میان متغیرها، اغلب بسیار پیچیده و غیرخطی هستند [۱۹]- [۲۱]. بنابراین نگرش‌های خطی برای توصیف رفتار چنین پدیده‌هایی در بیش‌تر موارد نادرست و ناکارآمد است. روش‌های غیرخطی کلاسیک به حجم عظیمی از اطلاعات متنوع نیازمند هستند که به‌طور معمول در دسترس نیستند. هم‌چنین دقت این مدل‌ها نیز از حد خاصی بیش‌تر نیست [۱۹]. بنابراین به‌کارگیری مدل‌هایی که بتوانند به‌طور منعطف و کارآمدتر طبیعت پیچیده و غیرخطی این پدیده‌ها را مدل نمایند، ضروری به نظر می‌رسد. یکی از روش‌های جدید، شبکه‌های عصبی مصنوعی هستند که از قابلیت بالایی در مدل‌سازی چنین پدیده‌هایی برخوردارند. بسیاری از مطالعات نشان داده‌اند که مدل‌های شبکه‌عصبی مصنوعی با مدل‌های قدیمی‌تر قابل رقابت هستند و حتی بهتر از آن‌ها جریان رودخانه را مدل‌سازی می‌کنند [۱۶]-[۱۷]-[۱۹].

رامان و سانیل کومار [۱۹]، یک مدل شبکه عصبی را به‌منظور مدل‌سازی سری‌های زمانی چندمتغیره به‌کار برده‌اند و نتایج خود را با مدل‌های آرما^۱ مقایسه نمودند. هدف در این مطالعه، تولید سنتزی جریان ماهانه ورودی به دو مخزن در حوضه‌ای در جنوب هند است. آن‌ها در این مطالعه توسط مدل شبکه عصبی به نتایج بهتری نسبت به مدل‌های تصادفی آرما رسیدند. اکوا-ریوریا [۱۸]، یک مدل با استفاده از شبکه‌های عصبی به‌منظور تولید سنتزی سری چندمتغیره جریان توسعه دادند. مدل از دو مؤلفه تشکیل شده بود. شبکه عصبی به‌عنوان مؤلفه جبری و مؤلفه با توزیع نرمال تصادفی، دو مؤلفه این مدل بودند. مؤلفه شبکه عصبی با استفاده از جریان‌های ماهانه مشاهداتی در دو ماه قبل برای دو مخزن موردنظر به تولید جریان در ماه جاری هر دو مخزن می‌پرداخت و سپس با مؤلفه تصادفی که از ماتریس واریانس و کوواریانس سری‌های مشاهداتی در محل دو مخزن بدست آمده است، جمع شده مقدار جریان در ماه بعد را تولید می‌نمود. مدل ایجادشده توسط این محققین با مدل اتورگرسیو مرتبه دو^۲ از طریق آماره‌های مختلف مقایسه شد و در پایان عملکرد بهتر مدل شبکه عصبی نتیجه گرفته شد. سارما و احمد [۲۱]، با هدف تولید سنتزی جریان‌های ماهانه رودخانه‌ای واقع در هیمالیا و در شمال براهماپوترا، مدلی با استفاده از شبکه عصبی ایجاد کردند. خروجی شبکه عصبی با افزودن یک مقدار تصادفی متناسب با انحراف معیار مقادیر مشاهداتی جریان در ماه جاری اصلاح شده و مقدار دبی ماهانه در ماه جاری تولید می‌شد. نتایج با مدل توماس-فیرینگ و آرما مقایسه و برتری مدل شبکه عصبی نسبت به دو مدل دیگر، در تولید جریان نشان داده شده

است.


پردازش می‌شود تا مقدار خروجی یا سیگنال خروجی سلول یا نرون همانطور که در رابطه (۲) ارائه شده، محاسبه شود. این روند از نرون‌های پردازشی در لایه پنهان آغاز و تا محاسبه سیگنال خروجی نرون در لایه خروجی که همان پاسخ شبکه است، ادامه می‌یابد:

$$net = \bar{P} \cdot \bar{W} + bias = \sum p_i \cdot w_i + bias \quad (1)$$

$$a = f(W_p + b) \quad (2)$$

شبکه‌های عصبی انواع و ساختارهای مختلفی دارند که یکی از آن‌ها شبکه‌های عصبی پرسپترون چندلایه^۱ است. این شبکه از متداول‌ترین آرایش‌های شبکه‌های عصبی است.

مایر و داندی [۱۴] با بررسی ۴۳ مقاله با موضوع کاربرد شبکه‌های عصبی در مدل‌سازی متغیرهای موجود در مجموعه‌های منابع آب که در سال‌های اخیر انجام شده‌اند، نتیجه گرفتند که در ۹۵ درصد موارد از شبکه‌های تغذیه پیشرفتی و بیش‌تر از الگوریتم انتشار برگشتی خطا به‌منظور آموزش شبکه استفاده شده است. در این شبکه عصبی همه واحدها یا سلول‌ها دو به دو به یکدیگر متصل هستند. سلول‌ها در هر لایه به یکدیگر متصل نخواهند بود، ولی به همه سلول‌های لایه‌های قبل و بعد خود متصل هستند. روند جریان سیگنال در این شبکه در مسیر رو به جلو انجام می‌شود. شکل (۱)، ساختار کلی این شبکه را نشان می‌دهد:



شکل (۱): ساختار شبکه پرسپترون چندلایه

در این تحقیق از این شبکه‌ها و تابع تحریک سیگموئید که در آموزش به راحتی می‌تواند به کار گرفته شود، استفاده شده است. بر اساس تجربیات اخیر استفاده از تابع سیگموئید تک‌قطبی^۱، با مرز صفر تا یک می‌تواند به سریع‌ترین حالت، آموزش ببیند و خطای پیش‌بینی مطلوبی داشته باشد [۱۸]. تابع سیگموئید، مقدار ورودی‌اش را که از منهای بینهایت تا مثبت بینهایت تغییر می‌کند به‌گونه‌ای فشرده می‌نماید که مقدار خروجی این تابع بین صفر و یک قرار گیرد. رابطه کلی این تابع به‌صورت رابطه (۳) بیان می‌شود:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

در این مطالعه سعی شده از داده‌های رواناب مشاهداتی در مقیاس روزانه در حوزه‌ای واقع در جنوب غربی کشورمان، در ساخت مدلی با استفاده از شبکه‌های عصبی مصنوعی برای تولید سری‌های بلندمدت روزانه جریان استفاده شود. با میانگین‌گیری از سری‌های تولیدی و ایجاد سری‌هایی در مقیاس روزانه، ماهانه و سالانه توانایی مدل با استفاده از آماره‌های مختلف ارزیابی شده است.

۲- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی مدل‌های ریاضیاتی از مغز انسان هستند. یک شبکه عصبی، سیستم پردازشگر اطلاعاتی است که از واحدهای پردازش‌گر متصل به یکدیگر به نام نرون، تشکیل یافته‌اند. این نرون‌ها به طور موازی و همزمان کار می‌کنند و می‌توانند نظم و الگوهای موجود درون حجم عظیم ورودی‌های مبهم و به‌ظاهر بی‌نظم را استخراج نمایند [۹]. این مدل‌ها می‌توانند آموزش دیده و کار خاصی را بر اساس تجربه و یادگیری خود انجام دهند [۸]. در رابطه با استفاده و کاربرد شبکه‌های عصبی در هیدرولوژی، مرور جامعی توسط مایر و دندی [۱۴] و نیز کمیته مامور مرجع [۲]-[۳] انجام شده است.

نرون، کوچک‌ترین واحد پردازش‌گر اطلاعات در شبکه است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد. این نرون‌ها در گروه‌هایی کنار هم قرار گرفته و لایه‌ها را تشکیل می‌دهند. در هر شبکه عصبی سه نوع لایه وجود دارد که شامل لایه ورودی^۲، لایه میانی^۳ یا پنهان و لایه خروجی^۴ است. لایه ورودی فقط نقش معرفی ورودی‌ها به شبکه را دارد. پردازش‌ها در لایه یا لایه‌های پنهان یا میانی انجام می‌شود و در لایه خروجی، مقادیر خروجی یا پاسخ شبکه تولید می‌شوند. نرون‌ها در هر لایه با اتصالات وزن‌دار، به هم مرتبط هستند و وزن آن‌ها در ابتدا اغلب به‌صورت تصادفی انتخاب شده و سپس بر اساس مطابق الگوریتمی که تمایل به حداقل رساندن خطا دارد (الگوریتم یادگیری) تغییر نموده و تنظیم می‌شوند.

به هر نرون، دسته‌ای از ورودی‌ها به‌صورت بردار ورودی $\vec{X} = (x_1, x_2, \dots, x_n)$ و $\vec{P} = (P_1, P_2, \dots, P_R)$ اعمال می‌شوند. هر ورودی در وزن متناظرش ضرب می‌شود، سپس همه ورودی‌ها با یکدیگر جمع می‌شوند و ورودی خالص نرون حاصل می‌شود. اگر دسته وزن‌ها به‌صورت بردار $\vec{W} = (w_1, w_2, \dots, w_n)$ و $\vec{W} = (w_1, w_2, \dots, w_n)$ نشان داده شوند، مقدار خالص ورودی^۵ همان‌طور که در رابطه (۱) ارائه شده است، از ضرب بردارهای \vec{X} و \vec{W} بعلاوه مقدار بایاس، به‌دست می‌آید و سپس این مقدار توسط تابع انتقال یا تحریک f ،

۲-۱- آموزش شبکه‌های عصبی

برای آن که بتوان از شبکه برای مدل کردن فرایند موردنظر استفاده نمود، باید آن را آموزش داد تا با یک دسته مشخص از ورودی‌ها، دسته خروجی‌های موردنظر را بتواند تولید کند. در فرآیند آموزش شبکه، بایاس‌ها و وزن‌های ارتباطی در یک شبیه‌سازی پیوسته بهینه می‌شوند تا خطا در خروجی شبکه به یک مقدار قابل قبول همگرا شود. شرایط مطلوب شبکه هنگامی است که شبکه قادر به پاسخ‌گویی صحیح به داده‌های ارائه شده در بخش آموزش^{۱۰} شبکه و نیز داده‌هایی که از آن‌ها در آموزش شبکه استفاده نشده یا همان داده‌های بخش آزمایش^{۱۱} باشد.

به‌طور معمول بخش عمده داده‌ها برای آموزش و بخش کم‌تری به‌منظور آزمون و ارزیابی شبکه در تشخیص الگوی پنهان در داده‌ها استفاده می‌شوند. گفتنی است که پس از آزمون و ارزیابی شبکه در تشخیص الگوی مشاهدات، با توجه به اینکه مدل به‌منظور تولید جریان توسعه داده می‌شود، گام نهایی در ارزیابی مدل با کمک ویژگی‌های آماری مقادیر تولیدشده و مشاهده‌شده و مقایسه آنها با یکدیگر انجام می‌شود. در الگوریتم انتشار برگشتی خطا که از متداول‌ترین روش‌های آموزش شبکه‌های چندلایه پرسپترون است، خروجی‌های محاسباتی با خروجی‌های هدف که همان مقادیر مشاهداتی هستند، مقایسه می‌شود و به‌منظور حداقل‌سازی خطاهای ایجاد شده، کار با گسترش عقب‌گرد خطا در کل شبکه و اصلاح وزن‌ها، تا زمانی که خطا به میزان قابل قبولی کاهش یابد، ادامه می‌یابد. الگوریتم انتشار برگشتی خطا به اشکال مختلفی ارائه شده که به‌طور تقریبی همه آن‌ها از شیب تابع عملکرد، به‌منظور تعیین تغییرات لازم در وزن‌ها استفاده می‌نمایند. روش لونیگ-مارکاردت از بهترین و کاراترین این روش‌ها است [۱۱] که در بسته نرم‌افزاری مطلب نیز با نام ال-ام^{۱۲} وجود دارد و در این تحقیق نیز به کمک نرم‌افزار مطلب به‌کار گرفته شده است. در این تحقیق، تابع عملکرد در آموزش شبکه‌ها، تابع میانگین مجموع مربعات خطاها^{۱۳} در نظر گرفته شده است. هم‌چنین به‌منظور ارزیابی عملکرد شبکه‌ها علاوه بر معیار میانگین مجموع مربعات خطاها که در رابطه (۴) ارائه شده، از معیار ضریب همبستگی R^2 و معیار ضریب نکویی برازش^{۱۴} ارائه شده در روابط (۵) و (۶)، نیز استفاده شده است:

$$R^2 = \frac{\left[\sum_{i=1}^n (Q_{obs} - Q_{obs-ave})(Q_{cal} - Q_{cal-ave}) \right]^2}{\left[\sum_{i=1}^n (Q_{obs} - Q_{obs-ave}) \right] \left[\sum_{i=1}^n (Q_{cal} - Q_{cal-ave}) \right]} \quad (۵)$$

$$NSC = 1 - \frac{\sum_{i=1}^n (Q_{obs} - Q_{cal})}{\sum_{i=1}^n (Q_{obs} - Q_{obs-ave})} \quad (۶)$$

که در آن n ، تعداد داده‌های مشاهداتی و تولیدشده و Q_{obs} ، Q_{cal} ، $Q_{obs-ave}$ و $Q_{cal-ave}$ به‌ترتیب مقادیر دی‌های مشاهداتی و محاسباتی و میانگین مقادیر مشاهداتی و محاسباتی شبکه هستند. هر چه مقادیر میانگین مربعات خطاها که مقدار مطلوب صفر است، کم‌تر و مقدار R^2 و NSC به ۱ نزدیک‌تر باشد، نشان‌دهنده عملکرد بهتر مدل است.

۳- مطالعه موردی و توصیف داده‌ها

در این مطالعه، از مقادیر میانگین روزانه جریان در ایستگاه «بارز» بر روی رودخانه خرسان یکی از سرشاخه‌های اصلی رود کارون، در جنوب غربی کشور و در موقعیت طول جغرافیایی شرقی $۲۵'$ ، ۵۰° و عرض جغرافیایی شمالی $۳۱'$ ، ۳۱° استفاده شده است. ارتفاع این ایستگاه از سطح دریا ۸۱۵ متر است. مساحت حوضه منتهی به این ایستگاه ۸۹۰۰ کیلومتر مربع است. بخش عمده حوضه کوهستانی بوده و ارتفاع بلندترین نقطه آن در کوه دنا در حدود ۴۴۳۷ متر از سطح دریا و متوسط ارتفاع حوضه برابر ۲۳۹۸ متر از سطح دریا است. طول رودخانه خرسان ۲۳۰ کیلومتر و ارتفاع سرچشمه آن از سطح دریا ۲۹۰۰ متر است. نقشه منطقه و ایستگاه موردنظر در شکل (۲) آورده شده است

$$MSE = \frac{1}{n} \sum_{i=1}^n (Q_{obs} - Q_{cal})^2 \quad (۴)$$

$$w_{v,T} = \log(x_{v,T}) \quad (7)$$

که در آن $x_{v,T}$ ، مقادیر رواناب روزانه دیده شده در روز T و در سال v است. در گام بعد مقادیر $w_{v,T}$ طبق رابطه (۸) استاندارد می‌شود:

$$y_{v,T} = \frac{w_{v,T} - w_T}{\sigma_T} \quad (8)$$

که در آن w_T و σ_T مقادیر میانگین و انحراف معیار $w_{v,T}$ هستند و $y_{v,T}$ میانگین صفر و انحراف معیار واحد خواهد داشت. در گام آخر تبدیل اصلاح شده ویلسون-هیلفرتی که برای همه مقادیر و ضرایب چولگی معتبر است و از رابطه (۹) پیروی می‌نماید، انجام شد:


$$z_{v,T} = \frac{6}{\gamma_T} \left\{ \left[\frac{\gamma_T y'_{v,T}}{\sigma_T} + 1 \right]^{\frac{1}{3}} - 1 \right\} + \frac{\gamma_T}{6} \quad (9)$$

در رابطه فوق γ_T ، ضریب چولگی سری داده‌های خام و $y'_{v,T}$ از رابطه (۱۰) محاسبه می‌شود:

$$y'_{v,T} = \begin{cases} \max \left[y_{v,T} - \frac{2}{\gamma_T}, \gamma_T > 0 \right] \\ \min \left[y_{v,T} - \frac{2}{\gamma_T}, \gamma_T < 0 \right] \end{cases} \quad (10)$$

در داده‌های مشاهداتی میانگین، انحراف معیار و چولگی سری خام به ترتیب برابر با $0.129/1$ ، $1.134/1$ و $0.4/1$ بوده و پس از تبدیل به $0.11/1$ ، $0.14/1$ و $0.11/1$ تغییر یافته‌اند. در پایان داده‌های تبدیل یافته با استفاده از رابطه (۱۱) به مقیاس $0.1/1$ تا $0.9/1$ برده شدند تا برای معرفی به شبکه‌های عصبی در مراحل آموزش و آزمایش آماده شوند. مقیاس‌بندی داده‌ها ضروری نیست [۱۰]. با این حال مقیاس‌بندی و انتقال اعداد به یک محدوده، بسیار توصیه شده است [۱۵]. اگر مقادیر به کرانه‌های برد تابع تحریک انتقال داده شوند، اصلاح وزن‌ها بی‌نهایت کوچک شده و آموزش شبکه با مشکل مواجه می‌شود [۷]. به‌طور کلی مقیاس‌بندی و بردن اعداد به یک محدوده در روند آموزش موثر است [۱۵].

$$x'_i = 0.8 \times \frac{(x - x_{\min})}{x_{\max} - x_{\min}} + 0.1 \quad (11)$$



شکل (۲): موقعیت جغرافیایی رودخانه و ایستگاه بارز

طول داده‌های به کار رفته در این مطالعه شامل ۳۰ سال داده روزانه رواناب در ایستگاه مذکور که از ۱ مهر سال ۱۳۵۰ الی ۱ مهر ۱۳۸۰ است. منبع داده‌ها، شرکت مدیریت منابع آب بوده است. میانگین و انحراف معیار داده‌ها به ترتیب برابر با $129/1$ و $134/1$ است که مقدار داده‌ها از 28 تا 1747 مترمکعب بر ثانیه متغیر بوده است. داده‌ها دارای چولگی مثبت بالایی برابر با $0.4/1$ هستند. نسبت داده حداکثر و حداقل نسبت به مقدار میانگین به ترتیب برابر $13/5$ و $0.2/1$ است.

۴- آماده‌سازی داده‌ها

کن و یردلن [۶] در مطالعه خود اظهار می‌کنند، از آن‌جا که روش مدل‌سازی به کمک شبکه عصبی، یک روش داده‌محور است و در این تکنیک‌ها درک قبلی از روابط بین متغیرها وجود ندارد برای عملکرد بهتر این مدل‌ها یک تحلیل اولیه روی شرایط داده‌ها، نرمال‌سازی و به مقیاس در آوردن متغیرها بهتر است انجام گیرد.

در این تحقیق از روش‌های تبدیل آماری رایج برای نرمال‌سازی داده‌ها استفاده شده است. تبدیل‌های مختلفی مانند جذر و توان و لگاریتمی انجام شد. هر یک از تبدیل‌های گفته شده به کمک نرم‌افزارهای اکسل ۲۰۰۷ و برنامه جانبی ایکس استات ۲۰۰۳^{۱۵}، انجام شد، اما در نهایت بهترین نتایج بر اساس روش‌های آماری آزمون نکویی برازش کای-مربع از تبدیل ویلسون-هیلفرتی^{۱۶} به دست آمد. در این روش ابتدا با استفاده از تبدیل لگاریتمی و بر اساس رابطه (۷) لگاریتم داده‌های خام محاسبه می‌شوند:

ورودی و ساختار لایه‌بندی شبکه (آماده شدن شبکه برای استفاده) از آن در تولید داده‌های روزانه استفاده شده است. در تولید سری‌های جریان با استفاده از شبکه عصبی که یک مدل جبری^{۱۷} است، دیده می‌شود که شبکه پس از تولید چندین روز به تکرار مقادیر تولیدشده قبلی می‌پردازد. این اتفاق زمانی رخ می‌دهد که شبکه مقادیری را مشابه قبل تولید نماید و در تولید مقادیر بعدی از آنها استفاده نماید. برای جلوگیری از این تکرار در تولید، یک جزء تصادفی باید در مدل دیده شود به واسطه به‌کار بردن مؤلفه تصادفی^{۱۸} است که مدل به‌عنوان یک ابزار کاربردی برای تولید سنتزی سری زمانی جریان می‌تواند مطرح شود و عدم قطعیت موجود در پدیده را می‌تواند اعمال کند.

به‌منظور تولید مقادیر جریان، ابتدا مقدار جریان‌های ورودی معلوم مورد نیاز به شبکه وارد شده و خروجی شبکه به‌دست می‌آید. این خروجی مقدار دبی در روز جاری است. سپس این مقدار با مؤلفه تصادفی جمع شده تا مقدار تولیدی جریان در روز جاری توسط مدل به‌دست آید. در صورتی‌که با افزودن مقدار تصادفی، دبی منفی شود، مقدار آن با حداقل دبی مشاهداتی در این روز جایگزین می‌شود. در مرحله بعد و برای تولید مقدار جریان در روز بعد مقدار تولید شده در کنار مقادیر دبی در روزهای قبل که در این مرحله هم‌چنان مقادیری مشاهده شده هستند، به‌عنوان ورودی به شبکه وارد شده و خروجی مانند گام قبل با مقدار تصادفی جمع شده و این مرحله به تعداد مورد نیاز تکرار می‌شود تا سری با طول دلخواه تولید شود. در اصل بعد از چند بار انجام مرحله اخیر ورودی‌های شبکه همگی مقادیر تولید شده خواهند بود که در تولید جریان روزهای آتی مورد استفاده قرار می‌گیرند. در این تحقیق ۳۰۰ سال داده روزانه جریان مطابق آن‌چه گفته شد، تولید شده است.

مؤلفه تصادفی مدل بصورت $\sigma v \varepsilon t$ در نظر گرفته شده که در آن εt یک جزء تصادفی نرمال استاندارد با میانگین صفر و σv واریانس واحد بوده و به‌عنوان انحراف معیار سری ماهانه باقی‌مانده‌ها است. بنابراین σv ، ۱۲ مقدار خواهد داشت که برای تولید داده روزانه رواناب در ایام هر ماه از مقدار σv همان ماه در تولید مقدار تصادفی استفاده شده است.

پس از آنکه شبکه عصبی آموزش داده شد، از مقادیر خطاها یا باقی‌مانده‌های پیش‌بینی در شبکه محاسبه شده و با میانگین‌گیری در مقیاس ماهانه سری باقی‌مانده‌ها^{۱۹} بدست آمده است. با انجام یک تحلیل آماری، نرمال بودن با استفاده از آزمون کلموگروف-اسمیرنوف و استقلال باقی‌مانده‌ها با رسم توابع همبسته‌نگار^{۲۰} مورد بررسی قرار گرفته است. میانگین باقی‌مانده‌ها صفر بوده و از توزیع نرمال پیروی می‌نماید. هم‌چنین برای تأخیرهای از یک تا ده همبسته‌نگار رسم شده که بیانگر

در این مطالعه ابتدا از داده‌ها به‌صورت اولیه و نیز تبدیل‌یافته در توسعه شبکه‌ها استفاده شده است و اثر تبدیل و نرمال‌سازی داده‌ها بر روند آموزش و عملکرد شبکه‌ها در عمل مورد آزمون قرار گرفته است.

۵- توسعه شبکه‌های عصبی

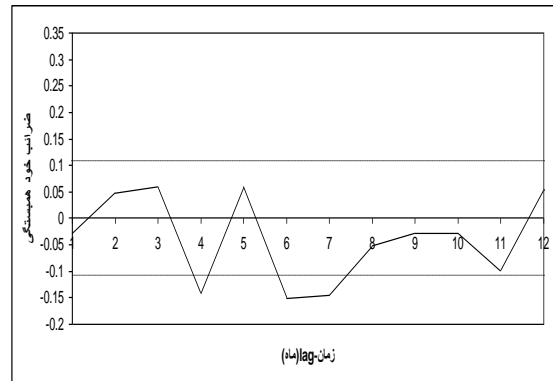
پس از آماده‌سازی داده‌ها، بردارهای آموزشی که متشکل از ورودی‌ها و خروجی‌های موردنظر شبکه هستند، به شبکه ارائه شدند. شبکه‌های عصبی جزء روش‌های داده‌محور هستند و می‌توانند ورودی‌های اصلی و اثرگذار را شناسایی نمایند، اما در صورتی که تعداد زیادی از ورودی‌های بالقوه موثر به شبکه ارائه شوند تا شبکه ورودی‌های مهم‌تر را تعیین نماید، زمان آموزش و ساخت بسیار طولانی می‌شود. هم‌چنین در اثر افزایش عوامل و وزن‌ها، بهینه شدن شبکه نیز (به علت پیچیده‌تر شدن رویه خطا و افزایش کمینه‌های محلی) دور از دسترس و دشوار خواهد شد. بنابراین بردار ورودی‌ها با ترکیبات مختلف و متشکل از مقدار دبی در روز جاری تا ۱۰ روز قبل و میانگین و انحراف معیار داده‌ها در روز جاری و روز بعد در ساخت شبکه مورد آزمون قرار گرفت. خروجی شبکه نیز دبی روز بعد در نظر گرفته شده است. متغیر دیگری که با هر ترکیب از ورودی تغییر داده می‌شود، تعداد نرون‌های لایه پنهان بود. تعداد نرون‌ها در لایه پنهان تا زمانی که عملکرد شبکه بهبود قابل توجهی از خود نشان می‌داد، افزایش داده می‌شدند. با توجه به تغییرات میزان خطا تعداد ۱۰۰۰ سعی یا اپوک در آموزش شبکه‌ها شد، زیرا با افزایش این مقدار سعی بهبود عملکرد شبکه بسیار ناچیز بوده است.

مراحل فوق برای داده‌های خام (به‌صورت اولیه) و داده‌های تبدیل یافته انجام شد. دیده شد که خطا در شبکه‌هایی که با استفاده از داده‌های خام آموزش می‌دید به‌صورت قابل توجهی از شبکه‌هایی که با داده‌های تبدیل‌یافته آموزش می‌دید، بیش‌تر است. در پایان شبکه آموزش‌دیده با داده‌های تبدیل‌یافته، با یک لایه مخفی متشکل از ۸ نرون مخفی، در حالتی که در بردار ورودی علاوه بر مقادیر جریان تا ۴ روز قبل، دو مقدار انحراف معیار و میانگین جریان در روز آتی نیز استفاده شد، به‌طور نسبی و با محاسبه توابع ارزیابی عملکرد که در روابط (۴)، (۵) و (۶) ارائه شده است، دقت بیش‌تری داشتند. نکته قابل توجه این‌که در انتخاب تعداد ورودی‌ها و وزن‌ها، رابطه نسبی بهبود عملکرد شبکه به تعداد پارامترهای افزوده شده باید در نظر گرفته شود [۱۸].

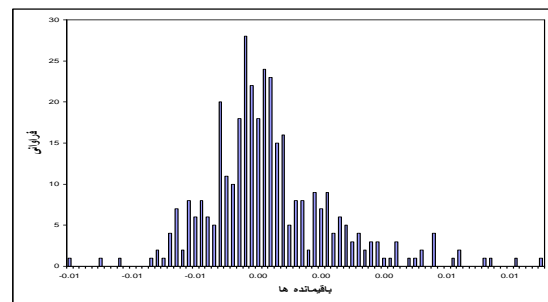
۶- تولید مصنوعی جریان

پس از آموزش شبکه‌ها و تعیین شدن آرایش مناسب مقادیر

استقلال مانده‌ها است. همبسته‌نگار و هیستوگرام فراوانی باقی‌مانده‌ها در شکل‌های (۳) و (۴) ارائه شده است.



شکل (۳): نمودار همبسته‌نگار سری باقی‌مانده‌ها



شکل (۴): نمودار هیستوگرام فراوانی سری باقی‌مانده‌ها

(۳) ارائه شده است.

جدول (۱): ویژگی‌های آماری سری‌های روزانه مشاهداتی و تولیدی

	میانگین (cms)	انحراف معیار (cms)	چولگی	خودهمبستگی با تاخیر ۱
مشاهداتی	۱۲۹/۱	۱۳۱/۸	۴/۱	۰/۸۶
تولیدی	۱۳۱/۶	۱۲۶/۲	۲/۸	۰/۹۵

جدول (۲): ویژگی‌های آماری سری‌های ماهانه مشاهداتی و تولیدی

	میانگین (cms)	انحراف معیار (cms)	چولگی	خودهمبستگی با تاخیر ۱
مشاهداتی	۱۲۹/۱	۱۰۶	۱/۹۹	۰/۶۹
تولیدی	۱۳۱/۶	۱۰۸/۶	۱/۷۴	۰/۶۷

جدول (۳): ویژگی‌های آماری سری‌های سالانه مشاهداتی و تولیدی

	میانگین (cms)	انحراف معیار (cms)	چولگی	خودهمبستگی با تاخیر ۱
مشاهداتی	۱۲۹/۱	۴۹/۲	۰/۳۵	-۰/۰۴
تولیدی	۱۳۱/۶	۴۰/۹	۰/۱۸	-۰/۱۱


جدول (۴): ویژگی‌های آماری سری‌های ماهانه مشاهداتی و تولیدی به تفکیک در هر ماه

ماه	میانگین مشاهداتی (cms)	میانگین تولیدی (cms)	انحراف معیار مشاهداتی (cms)	انحراف معیار تولیدی (cms)
مهر	۵۱/۲	۵۰/۱	۱۱/۸	۱۱/۶
آبان	۶۰/۸	۵۹/۵	۲۱/۶	۲۰/۷
آذر	۹۷/۵	۹۵/۸	۸۰/۹	۷۳/۶
دی	۱۱۶	۱۱۰	۹۰/۳	۸۴/۷
بهمن	۱۵۰	۱۶۰	۱۰۳	۱۰۵
اسفند	۲۳۵	۲۴۰	۱۳۵	۱۳۷
فروردین	۲۸۱	۲۸۷	۱۳۴	۱۳۶
اردیبهشت	۲۰۴	۲۱۲	۹۲/۶	۹۴/۴
خرداد	۱۳۱	۱۳۷	۵۲	۵۶/۹
تیر	۹۹/۳	۱۰۱	۳۶/۴	۳۵/۴
مرداد	۷۴/۶	۷۵/۸	۲۵/۹	۲۵/۳
شهریور	۵۵/۲	۵۷/۴	۱۶	۱۶/۵

۷- ارزیابی مدل

به منظور ارزیابی توانایی مدل در زمینه تولید مصنوعی جریان، سری‌های روزانه مشاهداتی و تولیدی، هر دو در مقیاس زمانی ماهانه و سالانه از راه میانگین‌گیری داده‌های روزانه، تهیه شدند. سپس با استفاده از آماره‌های مختلف و مقایسه منحنی‌های تداوم جریان و منحنی تحلیل قله سیلاب‌های روزانه توانایی مدل مورد ارزیابی قرار گرفته است. آماره‌ها و ویژگی‌هایی از دو سری تولیدی و مشاهده‌ای که در این تحقیق محاسبه و با یکدیگر مقایسه شده عبارتند از:

آماره‌های پایه $[20]$: میانگین، انحراف معیار و چولگی برای سری‌های مشاهداتی و تولیدی روزانه، ماهانه و سالانه و در مقیاس اولیه یعنی متر مکعب بر ثانیه محاسبه شده است و در جداول (۱) تا (۳) ارائه شده است. همچنین برای سری‌های ماهانه مشاهداتی و تولیدی در جدول (۴) مشخصات آماری گفته شده برای هر ماه آورده شده است. آماره‌های مربوط به دوام در سری $[20]$: آماره‌های خودهمبستگی برای سری‌های مشاهداتی و تولیدی برای داده‌های استاندارد شده محاسبه شدند. این ضرایب برای یک تأخیر در گام زمانی و برای سری‌های مشاهداتی و تولیدی روزانه، ماهانه و سالانه در جدول‌های (۱) تا



شکل (۶): تابع توزیع فراوانی گامبل برای حداکثرهای سالانه در داده‌های روزانه


۸- نتیجه‌گیری

در این مطالعه، توانایی مدل‌های شبکه عصبی مصنوعی در مورد تولید مصنوعی مقادیر جریان روزانه مورد بررسی قرار گرفت. بدین منظور مدلی بر اساس شبکه‌های عصبی ایجاد و با استفاده از یک تولیدکننده اعداد نرمال تصادفی از آن در تولید سری‌های بلندمدت جریان برای رودخانه خرسان و با استفاده از ۳۰ سال داده‌های روزانه مشاهداتی در این رودخانه استفاده شد. شبکه عصبی از نوع چندلایه تغذیه پیشرفتی بوده و با استفاده از الگوریتم انتشار برگشتی خطاها آموزش داده شد. با استفاده از داده‌های روزانه رواناب در چند روز قبل و انحراف معیار و میانگین در روز بعد، مقادیر جریان توسط شبکه محاسبه و این مقدار با یک مقدار تصادفی که متناسب با انحراف معیار سری خطاها یا باقی‌مانده‌ها در شبکه آموزش دیده است، جمع شده تا مقدار جریان تولیدی در روز بعد بدست آید. با این روش ۳۰۰ سال داده روزانه تولید و با استفاده از آماره‌های اصلی و متعارف و همچنین منحنی‌های تداوم جریان و تحلیل آماری مقادیر پیک با سری مشاهداتی مقایسه شده است.

همان‌گونه که در جداول و نمودارهای ارائه شده پیداست، مدل به خوبی می‌تواند ویژگی‌های آماری سری مشاهداتی را بازتولید نماید. همچنین منحنی‌های تداوم جریان برابری خوبی با یکدیگر داشته‌اند. اما به نظر می‌رسد مدل در شبیه‌سازی مقادیر قله سیلاب‌ها عملکرد چندان قابل قبولی نداشته است. استفاده از متغیرهای موثر دیگر در فرایند تشکیل رواناب، به منظور توسعه شبکه می‌تواند در تحقیقات آتی بررسی و در تولید مصنوعی جریان به کار گرفته شود. همچنین به کارگیری و ارزیابی انواع دیگر شبکه‌ها در زمینه تولید مصنوعی می‌تواند بیش‌تر بررسی شود. در رابطه با تولید مصنوعی دیگر متغیرهای هیدرولوژیکی نیز، قابلیت شبکه‌های عصبی قابل بررسی است.

تداوم جریان^{۲۳} (منحنی دبی کلاسه): بررسی دیگری که به منظور ارزیابی توانایی مدل در این تحقیق انجام شده است، ترسیم و مقایسه منحنی‌های تداوم جریان برای سری‌های تولیدی و مشاهداتی است. منحنی تداوم جریان رابطه بین جریان و درصدی از مواقع که دبی جریان در سری مورد نظر جریان برابر یا بزرگتر از یک مقدار مشخص است را به تصویر می‌کشد. در منحنی تداوم جریان مقادیر ۹۰ درصد و بیش از آن به عنوان مشخصه جریان‌های کم، کاربرد زیادی دارند. منحنی تداوم جریان تسلسل تاریخی رویدادها را نشان نمی‌دهد، اما در بیش‌تر موارد برای تعیین پتانسیل تأمین آب، به‌ویژه در رودخانه‌های بدون کنترل مورد استفاده قرار می‌گیرد.

در این تحقیق، منحنی‌های تداوم جریان برای هر دو سری تولیدی و مشاهداتی در نمودار شکل (۵) رسم و با یکدیگر مقایسه شده‌اند. در جدول (۵) نیز مقادیر مشخصی از جریان و درصد روزهایی که جریان از آن مقادیر بیش‌تر است، برای هر دو سری تولیدی و مشاهداتی ارائه شده است.



شکل (۵): منحنی‌های تداوم جریان برای سری‌های روزانه تولیدی و مشاهداتی

جدول (۵): مقادیر دبی و درصد اوقات متجاوز از این مقادیر

	درصد اوقات متجاوز از			
	۹۰	۵۰	۳۰	۱۰
مشاهداتی (CMS)	۵۵/۵	۱۰۶/۵	۱۵۱	۲۵۰/۵
تولیدی (CMS)	۵۷	۱۱۴/۵	۱۵۷/۵	۲۶۲/۵

تحلیل مقادیر حداکثر: در این مطالعه با کمک توزیع حدی گامبل مقادیر حداکثرهای روزانه در یک سری ۳۰ ساله تولیدی و مشاهداتی به همراه احتمالات وقوع آنها در شکل (۶) ارائه شده است:

- Lehtokangas, M., Saarinen, J., Kaski, K. [۱۲] ۹- تقدیر و تشکر
 نویسندگان مقاله، مراتب تشکر و قدردانی خود را از همفکری آقای محمدرضا خزائی و نیز همکاری شرکت مدیریت منابع آب در تهیه داده‌های موردنیاز تحقیق اعلام می‌نمایند.
- Loucks, D.P., Stedinger, J.R., & Haith, D.A. [۱۳] ۱۰- مراجع
- Maier, H.R. & Dandy, G.C. [۱۴] [۱] منهاج، محمدباقر؛ "هوش محاسباتی" (جلد اول: مبانی شبکه‌های عصبی)، انتشارات دانشگاه صنعتی امیرکبیر، تهران، ۱۳۷۹.
- Masters, T. [۱۵] [۲] ASCE Task Committee, "Artificial Neural Networks in Hydrology, I: Preliminary Concepts", Journal of Hydrologic Engineering, pp. 115-123, 2000.
- Minns, A.W., Hall, M.J. [۱۶] [۳] ASCE Task Committee, "Artificial Neural Networks in Hydrology, II: Hydrologic Applications", Journal of Hydrologic Engineering, pp. 124-137, 2000.
- Mohammadi, K., Eslami, H. R., & Dardashti, Sh. [۱۷] [۴] Box, G. E. P., & Jenkins, G. M. "Time Series Analysis Forecasting & Control", Holden-Day Press, USA, 1970.
- Ochoa-Riveria, J.C., Garcia-bartual, R., & Reu J. [۱۸] [۵] Bras, R. L., Rodríguez-Iturbe, I. "Random functions & hydrology", Addison-Wesley, Massachusetts, 1985.
- Raman, H., & Sunilkumar, N. [۱۹] [۶] Can, I., Yerdelen, I.C. "Stochastic modeling of Karasu River (Turkey) using the methods of Artificial Neural Networks", Hydrology Days, pp. 138-144, 2007.
- Salas, J.D., Delleur, J.W., Yevjevich, V. & Lane, W.L. [۲۰] [۷] Dawson, C.W., Wilby, R. "An artificial neural network approach to rainfall-runoff modeling", Hydrological Sciences Journal, pp. 47-66, 1998.
- Sarma, A.K., Ahmed, J.A. [۲۱] [۸] Govindaraju, R. S. "Artificial neural networks in hydrology I: Preliminary concepts", Journal of Hydrologic Engineering, pp. 115-123, 2000.
- [۹] Hinton, G. E. "How neural networks learn from experience", Sci. Amer., pp. 144-151, 1992.
- [۱۰] Karunanithi, N., Grenney, W.J., Whitley, D., Bovee, K. "Neural networks for river flow prediction", Journal of Computing in Civil Engineering, pp. 201-220, 1994.
- [۱۱] Kisi, O. "Daily River Flow Forecasting Using Artificial Neural Networks & Auto-Regressive Models", Turkish J. Eng. Env. Sci., pp. 9-20, 2005.

۱۱- زیر نویس ها

-
- ^۱ ARMA
 - ^۲ AR(2)
 - ^۳ Input Layer
 - ^۴ Hidden Layer
 - ^۵ Output Layer
 - ^۶ Net
 - ^۷ Activation Function
 - ^۸ Multi Layer Perceptron
 - ^۹ Uni Polar Sigmoid Activation Function
 - ^{۱۰} Training Set
 - ^{۱۱} Testing Set
 - ^{۱۲} LM
 - ^{۱۳} Mean Squared Errors (MSE)
 - ^{۱۴} Nash and Sutcliffe Coefficient
 - ^{۱۵} Xstat2003
 - ^{۱۶} Wilson and Hilferty
 - ^{۱۷} Deterministic
 - ^{۱۸} Random Component
 - ^{۱۹} Residual Series
 - ^{۲۰} Correlogram
 - ^{۲۱} Basic Statistics
 - ^{۲۲} Series Persistence Statistics