

کاربرد شبکه عصبی موجک در تخمین دمای متوسط هوا شهرستان ساری

بابک شاهی نژاد، رضا دهقانی*

۱. استادیار گروه مهندسی آب، دانشگاه لرستان
۲. دانشجوی دکترای سازه‌های آبی، دانشگاه لرستان

چکیده

دمای هوا که در ایستگاه‌های هواشناسی استاندارد اندازه‌گیری می‌شود یکی از توصیف‌کننده‌های اصلی وضعیت محیط زمین است. بنابراین برآورد و تخمین دقیق دمای متوسط روزانه در هر منطقه یکی از پیش‌نیازهای مهم برای برنامه‌ریزی کشاورزی و نیز مدیریت منابع آب می‌باشد که به روش‌های مختلفی همچون مدل‌های تجربی، نیمه تجربی و هوشمند قابل انجام است. در این پژوهش کاربرد شبکه عصبی موجک به منظور برآورد متوسط دمای روزانه هوا در ایستگاه ساری مورد بررسی و ارزیابی قرار گرفته و کارایی آن با مدل شبکه عصبی مصنوعی مقایسه گردید. جهت مدل‌سازی از داده‌های دماگزار ایستگاه هواشناسی ساری واقع در استان مازندران استفاده شد. پارامتر رطوبت نسبی، دمای بیشینه، دمای کمینه، سرعت باد و تبخیر در مقیاس زمانی روزانه در طی سال آبی (۱۳۸۲-۱۳۹۲) بعنوان ورودی شبکه و دمای متوسط روزانه هوا به عنوان خروجی شبکه انتخاب گردید. معیارهای ضریب همبستگی، ریشه میانگین مربعات خطا و ضریب نش ساتکلایف برای ارزیابی و مقایسه عملکرد مدل‌ها مورداستفاده قرار گرفت. مقایسه نتایج نشان داد مدل شبکه عصبی موجک عملکرد بهتری نسبت به مدل شبکه عصبی مصنوعی در مدل‌سازی دارد، بگونه‌ای که مدل شبکه عصبی موجک با بالاترین ضریب همبستگی (۰/۹۹۹)، ریشه میانگین مربعات خطا (۰/۰۰۱) و نیز بیشترین معیار نش ساتکلایف (۰/۹۹۸) در مرحله صحت‌سنجی در اولویت قرار گرفت. در مجموع نتایج نشان داد مدل شبکه عصبی موجک در تخمین بیشتر مقادیر دقت بالایی از خود نشان داده است.

کلمات کلیدی: تخمین، دمای هوا، شبکه عصبی مصنوعی، شبکه عصبی موجک، ساری

مقدمه

پیش‌بینی دمای متوسط هوا اهمیت فراوانی در زمینه مدیریت منابع آب، کشاورزی، آبرسانی و بسیاری از مسائل روزمره دارد. دمای هوا همچنین یکی از مؤلفه‌های ورودی مدل‌های ارزیابی اراضی و نیز مدل‌های هیدرولوژیکی و اکولوژیکی می‌باشد. از سوی دیگر به دلیل اینکه آب و هوا تأثیر شگرفی بر روی حیات اجتماعی و فردی انسان‌ها دارد، مراکز علمی زیادی در سطح جهان، پژوهش بر روی مسائل مختلف آب و هوایی را به عنوان اولویت اساسی خود مطرح می‌نمایند. پیش‌بینی اقلیمی وضع هوا با دیدگاه بررسی چگونگی تغییرات روزانه وضعیت جو در لایه پایین از مهم‌ترین کارهایی است که در این مراکز انجام می‌گیرد (تشنه‌لب و منشی، ۱۳۸۲). دما و بارش از مهم‌ترین و اساسی‌ترین عناصر اقلیمی هستند که در تعیین نقش و پراکنش سایر عناصر اقلیمی نقش برجسته‌ای دارند. از آنجایی که دما نقش اساسی را در پهنه‌بندی‌ها و طبقه‌بندی‌های اقلیمی ایفا می‌کند، لذا نوسان‌ها و تغییرات آن نیز از اهمیت زیادی برخوردار است. نقش دمای هوا در افزایش تبخیر و تعرق، کاهش آب‌های سطحی و زیرزمینی، گسترش انواع بیماری‌ها، آتش‌سوزی جنگل‌ها، فرآیند ذوب یخچال‌ها و بروز خشکسالی و کم‌آبی بر کسی پوشیده نیست (حسینی، ۱۳۸۸). دمای متوسط روزانه هوا از مهم‌ترین پارامترهای اقلیمی است که در ایستگاه‌های هواشناسی به دو روش دقیق و تقریبی قابل محاسبه است. در روش تقریبی میانگین دماهای بیشینه و کمینه روزانه به عنوان دمای متوسط روزانه در نظر گرفته می‌شود. در حالی که در روش دقیق داده‌های دمانگار مورد استفاده قرار گرفته و دمای متوسط روزانه از طریق انتگرال‌گیری از منحنی تغییرات روزانه دما محاسبه می‌شود. پژوهش‌ها نشان می‌دهد که دقت روش اول در مقیاس روزانه کم و حتی با مقدار واقعی به ۳ درجه اختلاف نیز می‌رسد. در عوض روش دوم دقیق و با مقدار واقعی اختلاف بسیار ناچیزی دارد که در حد دقت انتگرال‌گیری است (حبیبی و همکاران، ۱۳۸۷). بنابراین پیش‌بینی مقدار دقیق متوسط روزانه دما اهمیت فراوانی خواهد داشت. امروزه سیستم‌های هوشمند به‌طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می-

گیرد، که روش شبکه عصبی موجک (WNN^1) و شبکه عصبی مصنوعی (ANN^2) از جمله‌ی این روش‌ها به شمار می‌روند. شبکه‌های عصبی مصنوعی با الهام از سیستم پردازش اطلاعات مغز طراحی شده‌اند و توانایی آن‌ها در تقریب الگوهای یک مساله سبب افزایش دامنه کاربرد این شبکه‌ها شده است. در سال‌های اخیر استفاده از روش‌های هوشمند در مطالعات هیدرولوژیکی مورد توجه پژوهشگران قرار گرفته است. برای نمونه در پژوهشی بنی حبیب و همکاران (۱۳۸۶) بمنظور تخمین بیشینه دمای هوای حوضه آبریز دریاچه ارومیه از مدل شبکه عصبی مصنوعی و تصاویر ماهواره‌ای نوا استفاده نمودند و به این نتیجه رسیدند که مدل شبکه عصبی مصنوعی نسبت به روش رگرسیون چند متغیره کارایی بهتری دارد. همچنین قربانی و همکاران (۱۳۸۸) مدل‌های هوش مصنوعی را جهت تخمین بیشینه، متوسط و کمینه دمای شهر تبریز به کار بردند و نشان دادند که سیستم استنتاج عصبی-فازی تطبیقی نسبت به مدل شبکه عصبی مصنوعی و برنامه‌ریزی ژنتیک از دقت بالاتری برخوردار است. از سوی دیگر نتایج حاصل از پژوهش صلاحی و همکاران (۱۳۸۹) که جهت پیش‌بینی دمای حداکثر شهرستان اردبیل از مدل شبکه عصبی مصنوعی استفاده نمودند نشان داد شبکه عصبی مصنوعی عملکرد قابل قبولی در تخمین دمای هوا دارد. امامی فر و همکاران (۱۳۹۳) برای برآورد متوسط روزانه دمای هوا بر اساس داده‌های دمای سطح زمین سنجنده مودیس از مدل‌های درختی M5 و شبکه عصبی مصنوعی استفاده کردند و مقایسه نتایج نشان داد مدل شبکه عصبی مصنوعی دقت بیشتری را دارا می‌باشد. وانگو دینگ (Wang and Ding., 2003) با بررسی قابلیت‌های مدل مدل شبکه عصبی موجکی به این نتیجه رسیدند که این مدل دقت و طول زمان پیش‌بینی را افزایش می‌دهد و در نتیجه برای پیش‌بینی‌های هیدرولوژیکی بسیار مفید می‌باشد. اوکان (Okkan., 2012) مدل شبکه عصبی موجکی برای پیش‌بینی جریان ورودی به مخزن سد کمیر در ترکیه مورد بررسی قرار داده و نشان داد که شبکه عصبی موجکی یک مدل

¹ Wavelet Neural Network

² Artificial Neural Network

دقت کار افزایش می‌یابد بسامدهای مراحل پایین‌تر تجزیه، نویز بیشتری دارند، ولی با افزایش سطح تجزیه از میزان نویز کاسته شده و سیگنال نرم‌تر می‌شود (Wang et al., 2000)، می‌باشد.

داده‌ها و روش‌ها

منطقه مورد مطالعه

شهر ساری از شمال به دریای مازندران، از جنوب به سلسله جبال البرز، از مشرق به نکا و بهشهر و از جنوب به قائمشهر منتهی می‌شود که این شهر واقع در کوهپایه‌های رشته کوه البرز دارای دو بخش کوهستانی و دشت بوده و در طول جغرافیایی " ۲۶' ۳۷° ۵۳ درجه تا " ۲۵' ۴۴° ۵۴ و عرض‌های جغرافیایی " ۱۸' ۲۸° ۳۶ تا " ۹' ۴۱° ۳۶ درجه واقع شده است. مساحت شهرساری ۳۹۲۳ کیلومتر مربع می‌باشد. آب و هوای این شهر در تابستان‌ها معتدل و نمناک و در زمستان‌ها نسبتاً سرد و خشک است. همچنین بخش‌های جنوبی کوهستانی شهرساری دارای زمستان‌های دراز و بسیار سرد می‌باشد. بادهایی که از نواحی غربی می‌وزد باعث برودت و سردی هوا گشته و گاهی موجب ریزش برف می‌گردد. میانگین بارش سالانه ساری برابر با ۷۸۹ میلی‌متر است. توزیع مکانی آن از غرب به شرق با کاهش همراه است درحالی‌که توزیع زمانی آن وضعیتی کما بیش منظم دارد که حداکثر بارندگی در پائیز و حداقل آن در بهار اتفاق می‌افتد. در شکل ۱ موقعیت جغرافیایی شهرستان ساری مرکز استان مازندران که اطلاعات آن‌ها برای انجام این پژوهش مورد استفاده واقع شده است، قابل مشاهده است. بدین منظور جهت مدلسازی از پارامترهای رطوبت نسبی (RH)، دمای بیشینه (T.max)، دمای کمینه (T.min)، سرعت باد (WV) و تبخیر (ET) بعنوان ورودی و دمای متوسط هوا (T) به عنوان پارامتر خروجی مدل در دوره زمانی روزانه، سال ۱۳۸۲-۱۳۹۲ برای ایستگاه هواشناسی ساری بکار برده شد.

مناسب برای پیش‌بینی جریان ورودی به مخزن سد بوده و می‌تواند نسبت به سایر روش‌ها عملکرد قابل قبولی داشته باشد. رامانا و همکاران (Ramana et al., 2013) شبکه عصبی موجک را به منظور پیش‌بینی بارش ماهانه ایستگاه دارجلینگ در کوهپایه‌های هیمالیا به کار بردند و نشان دادند که مدل شبکه عصبی موجک عملکرد بهتری نسبت به مدل شبکه عصبی مصنوعی دارد. شریفی و همکاران (Sharifi et al., 2016) با استفاده از سه مدل شبکه عصبی مصنوعی، برنامه ریزی بیان ژن و شبکه عصبی موجک به پیش‌بینی میزان تابش خورشیدی ایستگاه‌های تبریز، ارومیه پرداختند و نشان دادند مدل شبکه عصبی موجک از دقت و عملکرد قابل قبولی در پیش‌بینی تابش خورشیدی برخوردار است. کارتیکا و دکا (Karthika and Deka., 2016) در پژوهشی دمای متوسط روزانه حوضه شیموگا واقع در هند را با استفاده از داده‌های سرعت باد، رطوبت نسبی، تعداد ساعات آفتابی و بارش توسط مدل فازی و شبکه عصبی موجک پیش‌بینی کردند. نتایج نشان داد مدل شبکه عصبی موجک در پیش‌بینی دمای متوسط روزانه عملکرد بهتری نسبت به مدل فازی دارد. در مجموع با توجه به پژوهش‌های انجام‌شده و ذکر این نکته که شهرستان ساری یکی از مهم‌ترین ایستگاه‌های هواشناسی در شمال کشور را دارا و مهم‌ترین منبع تأمین‌کننده تولید محصولات کشاورزی بوده است تغییرات دمای هوای این منطقه بر روی رشد و نمو محصولات کشاورزی تاثیر بسزایی دارد، بنابراین مدل‌سازی دقیق دمای متوسط روزانه در این شهرستان به منظور افزایش کارایی اقدامات مدیریت هیدرولوژیک منطقه ضروری است. لذا هدف از این پژوهش تخمین دقیق میزان متوسط دمای روزانه هوا در ایستگاه ساری با استفاده از شبکه عصبی موجک که با جدا نمودن سیگنال به فرکانس‌های بالا و پائین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل‌توجهی بالا می‌برد. سیگنال‌های بالا گذر و پایین گذر حاصل از تجزیه موجک، برازش بسیار خوبی با معادلات مجموع سینوسی دارند که هر چه تعداد مراتب این معادلات بیشتر می‌شود،



شکل ۱- موقعیت محدوده مطالعاتی

می‌شوند را نیز بصورت زیر بیان نمود (Safavi and Romagnoli, 1997):

$$(\Psi) \Psi_{m,k}(x) = 2^{-m/2} \Psi(2^{-m}x - k) \quad m, k \in \mathbb{Z}$$

در حالت کلی همه توابع فیزیکی را می‌توان به کمک ویولت‌ها و توابع مقیاس به صورت زیر بیان نمود (Wang et al., 2000):

$$(\Psi) f(x) = f_0(x) + \sum_{m=-\infty}^0 \sum_{k=-\infty}^{\infty} d_{m,k} \Psi_{m,k}(x)$$

$$(\Psi) f_0(x) = \sum_k a_{0,k} \phi_{0,k}(x)$$

روابط فوق بیان می‌دارند که هر تابع فیزیکی را می‌توان ابتدا به کمک تعدادی توابع مقیاس در رزولوشن صفر تقریب زد و سپس به کمک توابع ویولت در رزولوشن‌های مختلف آن تقریب را تا میزان دقت مورد نظر ادامه داد. شبکه عصبی ویولت بر مبنای روابط (۳) و (۴) شکل می‌گیرد و دارای الگوریتم‌های آموزش مخصوص خود می‌باشد که در پژوهش وانگ و همکاران (Wang et al., 2000) به صورت کامل مورد بررسی قرار گرفته است. لازم به ذکر است در حالت کلی خانواده ویولت‌های پیوسته نیز به صورت زیر بیان می‌شود:

$$(\Psi) \Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad a, b \in \mathbb{R}$$

و تبدیل ویولت برای توابع پیوسته به وسیله رابطه زیر محاسبه می‌شود:

$$W_{a,b}(f) = \tilde{f}_{(a,b)} = \langle \Psi_{a,b}(t), f(t) \rangle = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \Psi^*\left(\frac{t-b}{a}\right) dt$$


شبکه عصبی موجک

شبکه‌های عصبی مبتنی بر ویولت که ویولت نامیده می‌شوند از ترکیب دو تئوری ویولت‌ها و شبکه‌های عصبی وجود آمده‌اند (Safavi and Romagnoli, 1997). این شبکه‌ها هم از مزایا و ویژگی‌های شبکه‌های عصبی برخوردارند و هم جذابیت‌ها و انعطاف‌پذیری‌ها و مبانی ریاضی مستحکم ویولت‌ها و آنالیز چند مقیاسی را دارا می‌باشند. در ویولت‌ها از دو دسته توابع ویولت و توابع مقیاس^۱ استفاده می‌شود. یک خانواده از توابع مقیاس $\phi(x)$ به صورت زیر معرفی می‌شوند.

$$(\Psi) \phi_{m,k}(x) = 2^{-m/2} \phi(2^{-m}x - k) \quad m, k \in \mathbb{Z}$$

اگر $\phi(x)$ را یک تابع مقیاس مادر در نظر بگیریم، مقادیر 2^m و k به ترتیب مربوط به گسترش و انتقال تابع مقیاس مادر هستند. توابع مقیاس رزولوشن m و $\phi_{m,k}(x)$ در اصل پایه‌های متعامد فضای برداری v_m در رزولوشن m می‌باشند. به عبارتی فضای برداری v_m حاوی کلیه تقریب‌های تابع $f(x)$ با رزولوشن m و توسط توابع $\phi_{m,k}(x)$ می‌باشد. بنابراین فضاهای برداری $\{v_m\}$ حاوی تقریب‌های مختلف تابع $f(x)$ در رزولوشن‌های مختلف می‌باشند. حال اگر w_m را فضای برداری متعامد با v_m در رزولوشن m فرض کنیم آنگاه می‌تواند دسته‌ای دیگر از پایه‌های متعامد فضای w_m که ویولت $\Psi(x)$ نامیده


¹ Scaling functions



شکل ۲- نمای کلی یک شبکه عصبی موجک سه لایه‌ای

شبکه عصبی مصنوعی

امروزه شبکه عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد (Hornik.,1988). ساختار شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال‌دهنده و وسیله‌ای برای تهیه کردن داده‌ها، لایه خروجی شامل مقادیر پیش‌بینی شده توسط شبکه و لایه میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها است. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چندلایه^۱ انجام گرفت. در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس‌انتشار خطا^۲ با ساختار شبکه پیش‌خور^۳ و تعداد سه لایه به طور رضایت بخشی در حل مسائل پیچیده مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد (Nourani et al.,2009). از رایج‌ترین توابع محرک استفاده شده در شبکه‌های انتشار برگشتی می‌توان توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کرد (Nourani et al.,2011). نمونه‌ای از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل ۳ نشان داده شده است.



شکل ۳- نمای کلی یک شبکه عصبی مصنوعی سه لایه

در اینجا پارامتر a به‌عنوان پارامتر گسترش و متناسب با فرکانس می‌باشد (به عبارت دیگر پارامتر تأخیر کوچک متناظر با فرکانس بالا و پارامتر تأخیر بزرگ متناظر با فرکانس پایین می‌باشد) و پارامتر b به‌عنوان پارامتر انتقال و متناسب با زمان می‌باشد.

تلفیق تئوری موجک با مفاهیم شبکه عصبی منجر به ایجاد شبکه عصبی موجک می‌گردد و بکارگیری آن می‌تواند جایگزین مناسبی در شبکه‌های عصبی پیش‌خور جهت تخمین و تقریب توابع غیرخطی اختیاری باشد. شبکه‌های عصبی پیش‌خور دارای تابع فعال‌سازی سیگموئید در لایه پنهان می‌باشند. در حالی که در شبکه‌های عصبی موجک، توابع موجک به‌عنوان تابع فعال‌سازی لایه پنهان شبکه پیش‌خور در نظر گرفته می‌شوند در این شبکه‌ها هر دو پارامتر انتقال و تغییر مقیاس موجک‌ها در کنار وزن‌هایشان بهینه می‌گردند. در مجموع گام‌های مهم در آموزش و صحت سنجی شبکه عصبی موجک به صورت زیر است.

الف) داده‌های ورودی به دو دسته جهت آموزش شبکه و صحت‌سنجی مورد استفاده قرار می‌گیرند.

ب) موجک مادر با احراز شرایط یاد شده پس از اعمال ضرایب انتقال و مقیاس مناسب به موجک فرزند تبدیل می‌شود.

ج) توابع فعال‌سازی نرون‌های لایه پنهان شبکه عصبی با انواع موجک‌های فرزند جایگزین می‌شود.

د) شبکه عصبی ویولت ایجادشده با استفاده از مجموعه داده‌های مربوط به آموزش شبکه، آموزش داده می‌شود.

عملکرد کلی شبکه موجک با تجزیه و تحلیل نحوه تخمین داده‌های صحت سنجی مورد بررسی قرار می‌گیرد. و با رضایت‌بخش بودن عملکرد شبکه مرحله آموزش به اتمام می‌رسد. در غیر این صورت مراحل قبل تا دستیابی به بهترین حالت مورد ارزیابی قرار می‌گیرد (کاوه و ایرانمنش، ۱۳۸۴). نمونه‌ای از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل ۲ نشان داده شده است.

¹ Multi-Layer Perceptron

² Back Propagation (BP)

³ Feed Forward

معیارهای ارزیابی

به منظور ارزیابی دقت و کارایی مدل‌ها، از نمایه‌های ضریب تبیین (R^2)، جذر میانگین مربعات خطا (RMSE) و ضریب نش‌ساتکلیف (NS) به صورت زیر محاسبه شد. مقادیر بهینه برای این سه معیار به ترتیب یک، صفر و یک می‌باشند.

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad (7)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (8)$$

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad -\infty \leq NS \leq 1 \quad (9)$$

در روابط بالا، x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی i ام، N تعداد گام‌های زمانی، \bar{x} و \bar{y} نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی می‌باشند. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی - محاسباتی نسبت به زمان نیز جهت مقایسه و تحلیل بیشتر نتایج استفاده شده است.

نتایج و بحث

در این پژوهش به منظور مدل‌سازی متوسط دمای هوای متوسط روزانه از مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی استفاده شد. پارامتر رطوبت نسبی (RH)، دمای بیشینه (T.max)، دمای کمینه (T.min)، سرعت باد (WV) و تبخیر (ET) بعنوان ورودی و دمای متوسط هوا (T) به عنوان پارامتر خروجی مدل در دوره زمانی روزانه، سال ۱۳۹۲-۱۳۸۲ برای ایستگاه هواشناسی ساری بکار برده شد. هدف کلی از مدل‌های هوشمند بیان ارتباط بین متغیرهایی است که یافتن پیچیدگی آنها در طبیعت کاری دشوار با عدم قطعیت بالا است. دمای متوسط روزانه از پارامترهای مهم هواشناسی است که تخمین آن در گام‌های زمانی آینده از اهمیت بالایی برخوردار است. به این منظور در جهت کاهش خطا و همچنین برآورد پارامتر دمای متوسط هوای روزانه با دقت بالا با استفاده از کمترین پارامترهای ورودی روش ذکر شده مورد استفاده قرار گرفت

که در مقایسه با روش‌های تقریبی بمراتب عملکرد بهتری را ارائه خواهد داد. هدف از این پژوهش دریافت این پیچیدگی طبیعی بین پارامترهای هواشناسی و ارائه مدل جهت پیش‌بینی در آینده است و از آنجاییکه دمای متوسط روزانه از اهمیت بالاتری نسبت به دیگر پارامترها برخوردار می‌باشد بنابراین این پارامتر بعنوان متغیر هدف انتخاب شد. در جدول ۱ ویژگی‌های آماری پارامتر استفاده شده، ارائه شده است. لازم به ذکر است جهت مدل‌سازی ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد باقی‌مانده جهت تست، بصورت تصادفی، که گستره وسیعی از انواع داده‌ها را پوشش دهد، انتخاب شد (Kisi and Karahan, 2006; Nagy et al, 2002). در این میان یک نکته مهم در آموزش شبکه‌های عصبی نرمال‌سازی داده‌ها قبل از استفاده در مدل می‌باشد این عمل خصوصاً وقتی دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود (Zhu et al., 2007). برای نرمال‌سازی داده‌ها از رابطه‌ی ۱۰ استفاده شد.

$$X_n = 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (10)$$

که در آن X_n مقدار نرمال شده‌ی داده‌ی ورودی X_i ، X_{\max} و X_{\min} نیز به ترتیب مقادیر حداقل و حداکثر ورودی مورد نظر می‌باشد.

یکی از مهمترین مراحل در مدل‌سازی، انتخاب ترکیب مناسبی از متغیرهای ورودی است. در مدل‌های هوشمند انتخاب ورودی‌های اولیه مناسب و تاثیرگذار در پدیده بمنظور آموزش ماهیت سازوکار حاکم بر پدیده باعث بهبود عملکرد خواهد شد بنابراین در الگوسازی دمای متوسط روزانه شهرستان ساری نیز سعی گردید تا موثرترین داده‌های مشاهداتی به عنوان داده‌های آموزشی انتخاب شود. بدین منظور ترکیب‌های مختلفی از پارامتر ورودی به‌منظور دستیابی به مدل بهینه جهت تخمین متوسط دمای هوا استفاده شد که در جدول ۲ آمده است.

جدول ۱- محدوده پارامتر مورد استفاده جهت آموزش و صحت‌سنجی داده‌ها

پارامتر مدل	آموزش			صحت‌سنجی		
	کمینه	میانگین	بیشینه	کمینه	میانگین	بیشینه
RH(%)	۲۵/۳۳۳	۷۶/۱۷۸	۱۰۰	۲۷/۶۶۶	۷۵/۹۲۱	۱۰۰
T.max(°C)	-۵	۲۱/۲۷۶	۴۰	۱	۲۴/۳۵۱	۳۸
T.min(°C)	-۱۷	۱۰/۴۷۳	۲۸	-۱۵	۷/۷۴۷	۱۷
WV(km/h)	۰/۴۰۰	۲/۷۸۰	۷/۶۰۰	۰/۵۰۰	۲/۸۴۲	۵/۸۰۰
ET(mm)	۰	۲/۸۷۰	۱۵	۰	۲/۸۰۵	۱۱/۴۰۰
T(°C)	-۶	۱۵/۸۷۵	۳۳	-۴	۱۶/۵۴۹	۲۶

جدول ۲- ترکیب‌های منتخب پارامتر ورودی مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی

شماره	ساختار ورودی	خروجی
۱	RH(t)	T(t)
۲	RH(t), T _{min} (t)	T(t)
۳	RH(t), T _{min} (t), T _{max} (t)	T(t)
۴	RH(t), T _{min} (t), T _{max} (t), WV(t)	T(t)
۵	RH(t), T _{min} (t), T _{max} (t), WV(t), ET(t)	T(t)

نتایج شبکه عصبی موجک

به منظور تخمین میزان دمای متوسط هوای شهرستان ساری از مدل شبکه عصبی موجک با تعداد نرون‌های متفاوت استفاده شد. در مدل عصبی موجکی ابتدا موجک مناسب (سیملت) انتخاب گردید. سپس با اعمال تبدیل روی داده‌ها، ضرایب تقریب و جزئیات آن‌ها استخراج گردید و داده‌ها بوسیله تابع موجک کلاه مکزیکی به عنوان تابع فعال‌سازی که مشتق دوم تابع گوسی بوده، تبدیل می‌یابند. جهت آموزش شبکه از الگوریتم گرادیان نزولی استفاده شد که در یادگیری شبکه‌های عصبی و حداقل سازی مقدار خطا و تنظیم پارامتر شبکه بکار گرفته می‌شود. در این روش با توجه به جدول ۳ ساختار شماره ۵ بصورت شبکه‌ای با ۷ نرون در لایه پنهان اول با بیشترین ضریب همبستگی $R=0/999$ ، جذر میانگین مربعات خطا برابر $0/01$ درجه سانتی‌گراد و ضریب نش‌ساتکلیف برابر با $0/998$ در مرحله صحت‌سنجی به عنوان بهترین ساختار در فرآیند شبیه‌سازی انتخاب شد. هدف در مدل‌های هوشمند همچون شبکه عصبی موجک کم کردن میزان خطا جهت پیش‌بینی می

باشد و افزایش و کاهش تعداد نرون‌های موجود در لایه‌های پنهان با توجه به همگرا شدن مدل به کمترین خطای ممکن نسبت به سایر ساختارها صورت می‌گیرد همانطور که در جدول ۳ مشاهده می‌شود شبکه عصبی موجک به طور مطلوبی تعمیم داده‌شده و در نتیجه توانسته داده‌های بخش صحت‌سنجی را بخوبی داده‌های بخش آموزش اجرا نماید (کاوه و ایرانمنش، ۱۳۸۴). همچنین با توجه به جدول ۳ مشاهده می‌گردد شبکه عصبی موجک عملکرد بالایی در تخمین دمای هوای متوسط روزانه شهرستان ساری حتی در صورت استفاده از تنها یک پارامتر ورودی نیز از خود نشان داده است که این امر سبب می‌شود در مناطقی که نواقص آماری وجود دارد این شبکه با در اختیار داشتن پارامترهای ورودی حداقل نظیر رطوبت نسبی عملکرد قابل قبولی در پیش‌بینی دمای هوای متوسط روزانه داشته باشد. همان‌طور که در شکل ۴-ب مشخص است تطابق مطلوبی بین مقادیر محاسباتی دمای هوا مربوط به مرحله صحت‌سنجی مدل شبکه عصبی موجک با مقادیر مشاهداتی وجود دارد. بگونه‌ای که با توجه به نمودار ۴-الف قابلیت بالای این مدل در

خطا مشخص گردید. روند کار با تعداد نرون های کم آغاز و افزودن نرون های اضافی تا زمانی ادامه می یابد که افزایش نرون های بیشتر تأثیری در بهبود خطا نداشته باشد، همان طور که در جدول ۴ مشاهده می شود ساختار شماره ۵ دارای ۸ نرون در لایه پنهان با ضریب همبستگی ۰/۹۷۵، جذر میانگین مربعات خطا ۰/۰۱۴ درجه سانتی گراد و ضریب نش ساتکلیف ۰/۸۳۷ در مرحله صحت سنجی نسبت به سایر ساختارها جهت مدل سازی دمای هوا در مقیاس زمانی روزانه مناسب تر خواهد بود. از سوی دیگر در شکل ۵-الف نمودار بهترین مدل حاصل شده برای داده های بخش صحت سنجی نشان داده شده است. که در این شکل تغییرات مقادیر محاسباتی و مشاهداتی نسبت به زمان ارائه شده است. همانطور که مشاهده می شود مدل شبکه عصبی مصنوعی در تخمین اکثر مقادیر عملکرد قابل قبولی داشته است همچنین همانطور که در شکل ۵-ب مشخص است بیشتر مقادیر تخمینی و مشاهداتی به غیر از چند نقطه روی خط نیمساز قرار گرفته و این امر دلالت بر برابری مقادیر مشاهداتی و محاسباتی بر اساس خط $(y=x)$ است. که با نتایج آیشک و همکاران (Abhishek et al., 2012) و صف شکن و همکاران (۱۳۹۰) همخوانی دارد در تبیین این نتایج می توان بیان نمود با توجه به ساختار شبکه های عصبی مصنوعی، ویژگی عمده آن سرعت بالای پردازش، توانایی یادگیری الگو، توانایی تعمیم الگو پس از یادگیری، انعطاف پذیری در برابر خطاهای ناخواسته و عدم ایجاد اختلال قابل توجه در صورت بروز اشکال در بخشی از اتصال ها به دلیل توزیع وزن های شبکه است.


تخمین اکثر مقادیر مشهود است که این امر با نتایج شریفی و همکاران (Sharifi et al., 2016) و بانژاد و همکاران (۱۳۹۲) همخوانی دارد. در تبیین این نتایج می توان بیان نمود تبدیل موجکی با جدا نمودن سیگنال به فرکانس های بالا و پائین ویژگی های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می برد. سیگنال های بالا گذر و پایین گذر حاصل از تجزیه موجک، برازش بسیار خوبی با معادلات مجموع سینوسی دارند که هر چه تعداد مراتب این معادلات بیشتر می شود، دقت کار افزایش می یابد بسامدهای مراحل پایین تر تجزیه، نویز بیشتری دارند، ولی با افزایش سطح تجزیه از میزان نویز کاسته شده و سیگنال نرم تر می شود.

نتایج شبکه عصبی مصنوعی

تابع تانژانت هیپربولیک متداول ترین شکل از توابع محرک است، که در این تحقیق از آن برای ساخت لایه خروجی شبکه های عصبی مصنوعی استفاده گردید. برای آموزش شبکه های پرسپترون چندلایه از الگوریتم آموزش پس انتشار خطا بنام الگوریتم لونبرگ - مارکواریت به دلیل همگرایی سریع تر در آموزش شبکه، استفاده شد. همچنین از ترکیبات مختلف توابع محرک در لایه مخفی استفاده گردید. تعداد تکرارهای لازم در فرآیند یادگیری شبکه ۱۰۰۰ در نظر گرفته شده و عملکرد شبکه به کمک معیار میانگین مربعات خطا مورد ارزیابی قرار گرفته است. تعداد نرون های موجود در لایه های ورودی و خروجی با توجه به ماهیت مساله مورد بررسی مشخص شده، حال آنکه تعداد نرون های موجود در لایه پنهان با سعی و خطا در جهت کاهش مقدار


جدول ۳- ساختار و توابع محرک بهینه در مدل سازی شبکه های عصبی موجک در مراحل آموزش و صحت سنجی

شماره ساختار	تابع محرک	آموزش			صحت سنجی				
		لایه خروجی	لایه پنهان	NS	RMSE	R	NS	RMSE	R
۱	کلاه مکزیکی	خطی	کلاه مکزیکی	۰/۹۶۸	۰/۰۱۲	۰/۹۸۸	۰/۹۹۶	۰/۰۰۵	۰/۹۹۷
۲	کلاه مکزیکی	خطی	کلاه مکزیکی	۰/۹۶۵	۰/۰۱۴	۰/۹۸۷	۰/۹۹۵	۰/۰۰۴	۰/۹۹۶
۳	کلاه مکزیکی	خطی	کلاه مکزیکی	۰/۹۶۰	۰/۰۲۰	۰/۹۸۵	۰/۹۹۰	۰/۰۰۸	۰/۹۹۴
۴	کلاه مکزیکی	خطی	کلاه مکزیکی	۰/۹۶۶	۰/۰۱۵	۰/۹۸۶	۰/۹۹۳	۰/۰۰۷	۰/۹۹۵
۵	کلاه مکزیکی	خطی	کلاه مکزیکی	۰/۹۷۰	۰/۰۱۰	۰/۹۹۰	۰/۹۹۸	۰/۰۰۱	۰/۹۹۹



شکل ۴- نمودار حاصل از مقادیر بهینه مدل شبکه عصبی موجک برای داده‌های مرحله صحت سنجی (الف) مقادیر محاسباتی و مشاهداتی نسبت به زمان (ب) نمودار پراکنش میان مقادیر مشاهداتی و محاسباتی جدول ۴- ساختار و توابع محرک بهینه در مدل‌سازی شبکه‌های عصبی مصنوعی در مراحل آموزش و صحت سنجی

شماره	ساختار	تابع محرک		آموزش			صحت سنجی		
		لایه پنهان	لایه خروجی	NS	RMSE (°C)	R	NS	RMSE (°C)	R
۱	۱-۲-۱	تانژانت هیپربولیک	خطی	۰/۸۰۱	۰/۰۴۵	۰/۸۸۵	۰/۸۲۶	۰/۰۲۰	۰/۹۱۸
۲	۲-۳-۱	تانژانت هیپربولیک	خطی	۰/۸۰۵	۰/۰۴۱	۰/۸۲۲	۰/۸۲۷	۰/۰۳۶	۰/۹۰۴
۳	۳-۴-۱	تانژانت هیپربولیک	خطی	۰/۸۰۱	۰/۰۴۱	۰/۸۲۶	۰/۸۳۰	۰/۰۳۲	۰/۹۰۷
۴	۴-۵-۱	تانژانت هیپربولیک	خطی	۰/۷۸۹	۰/۰۳۷	۰/۸۷۰	۰/۸۳۲	۰/۰۲۵	۰/۹۱۴
۵	۵-۸-۱	تانژانت هیپربولیک	خطی	۰/۸۲۰	۰/۰۲۱	۰/۹۶۳	۰/۸۳۷	۰/۰۱۴	۰/۹۷۵



شکل ۵- نمودار حاصل از مقادیر بهینه مدل شبکه عصبی مصنوعی برای داده‌های مرحله صحت سنجی (الف) مقادیر محاسباتی و مشاهداتی نسبت به زمان (ب) نمودار پراکنش میان مقادیر مشاهداتی و محاسباتی

مقایسه عملکرد مدل‌ها

خوبی می‌توانند میزان دمای هوای شهرستان ساری را شبیه‌سازی کنند. همانطور که در شکل ۶ نتایج هر دو مدل نسبت به مقادیر مشاهداتی در طی زمان نشان داده شده است مدل شبکه عصبی مصنوعی در تخمین نقاط بیشینه و کمینه

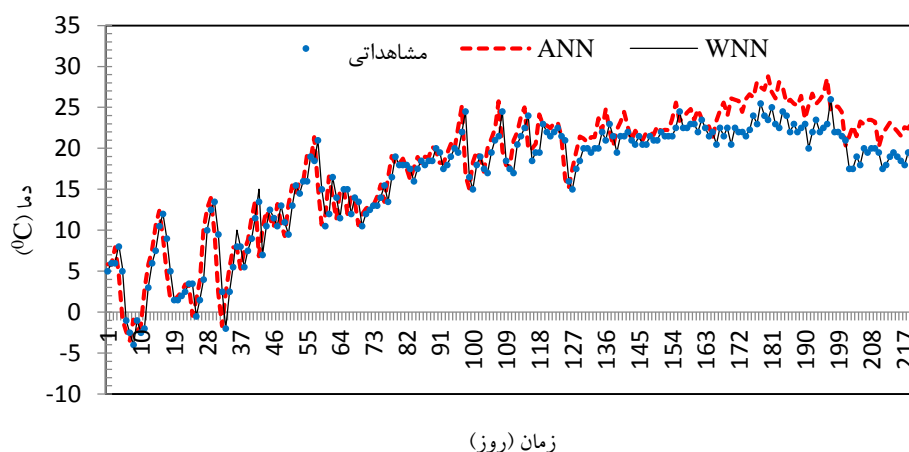
در ادامه با انتخاب جواب بهینه هرکدام از مدل‌ها و مقایسه آن‌ها با یکدیگر مشخص شد، هر دو مدل با دقت

قدرت تعمیم شبکه می‌شود (Abhishek et al., 2012). از سوی دیگر مدل شبکه عصبی موجک در تخمین اکثر مقادیر عملکرد قابل قبولی از خود نشان داده است بگونه ای که کلیه مقادیر را نزدیک به مقدار واقعی تخمین زده و بخوبی تعمیم داده شده است که توانسته داده‌های بخش صحت سنجی را بخوبی داده‌های بخش آموزش اجرا نماید (Wang et al., 2000).

ضعیف عمل کرده و این نقاط را خارج از مقدار واقعی‌شان تخمین زده است که این نتایج با یافته‌های قربانی و همکاران (۱۳۸۸) همخوانی دارد در تبیین این نتایج میتوان بیان نمود وزن‌های اولیه در الگوریتم پس از انتشار خطا بصورت تصادفی انتخاب گردیده و شبکه با توزیع خطای بدست آمده روی وزن‌های قبلی و تکرار در فرآیند آموزش شبکه، آموزش می‌بیند که سبب کند شدن آموزش شبکه و کاستن

جدول ۵- مقایسه نتایج آموزش و صحت سنجی مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی

صحت سنجی			آموزش			مدل
R ²	RMSE (⁰ C)	NS	R ²	RMSE (⁰ C)	NS	
۰/۹۷۰	۰/۰۱۰	۰/۹۹۰	۰/۹۹۸	۰/۰۰۱	۰/۹۹۹	شبکه عصبی موجک
۰/۸۲۰	۰/۰۲۱	۰/۹۶۳	۰/۸۳۷	۰/۰۱۴	۰/۹۷۵	شبکه عصبی مصنوعی



شکل ۶- مقایسه مقادیر پیش‌بینی شده با استفاده از شبکه عصبی موجک و شبکه عصبی مصنوعی با مقادیر دمای هوای روزانه برای داده‌های مرحله صحت سنجی

با دمای هوای تخمین زده شده در مدل‌های مذکور (شبکه عصبی موجک و شبکه عصبی مصنوعی)، با استفاده از معیارهای خطا مورد مقایسه قرار گرفت. نتایج حاصل از پژوهش نشان داد افزایش تعداد پارامتر موثر در مدل‌های مختلف جهت شبیه سازی موجب عملکرد بهتر در تخمین میزان درجه حرارت دمای هوا می‌شود. علاوه بر آن مشاهده گردید در مدل شبکه عصبی موجک با داشتن حداقل

نتیجه گیری

در این تحقیق تلاش شد تا عملکرد مدل‌های شبکه جهت شبیه سازی میزان درجه حرارت دمای هوای شهرستان ساری با استفاده از داده‌های روزانه ایستگاه هواشناسی ساری در طی دوره آماری ۱۳۸۲-۱۳۹۲ مورد ارزیابی قرار گیرد. مدل‌های به کار گرفته شده شامل شبکه عصبی موجک و شبکه عصبی مصنوعی بودند. مقادیر دمای هوا مشاهداتی

- artificial intelligence, *Journal of Soil and Water*, Vol.20, No.3, pp.87-104
6. Habibi, M., Rezaei Pajand, H., and M. Farzandi, 2008, Model to estimate the average daily temperature in arid and semi-arid Iran, *Iran Water Resources Research*, Vol.4, No.1, pp.70-74
 7. Hornik, K, 1998, Multilayer feed-forward networks are universal approximators, *Neural Networks*, Vol.2, No.5, pp. 359–366.
 8. Hosseini, S. A, 2009, Estimation of maximum temperatures in Ardabil city by using artificial neural network theory, *Researcher University of Ardabil, Natural Geography Department*.
 9. Karthika, B.S., and P. C. Deka, 2016, Modeling of Air Temperature using ANFIS by Wavelet Refined Parameters, *International Journal of Intelligent Systems and Applications*, Vol.8, No.1, pp.25-34
 10. Kaveh, A., and A. Iran Manesh, 2005, *Artificial Neural Networks in Structural Optimization*, Third Edition. Publications Building and Housing Research Center.
 11. Kisi, O., Karahan, M., and Z. Sen, 2006, River suspended sediment modeling using fuzzy logic approach, *Hydrol Process*, Vol.20, No.2, pp. 4351-4362.
 12. Nagy, H., Watanabe, K., and M. Hirano, 2002, Prediction of sediment load concentration in rivers using artificial neural network model, *Journal of Hydraulics Engineering*, Vol.128, No.4, pp.558-559.
 13. Nourani, V., Kisi, Ö., and M. Komasi, 2011, Two hybrid artificial intelligence approaches for modeling rainfall–runoff process, *Journal of Hydrology*, Vol.402, No.2, pp.41–59.
 14. Nourani, V., Alami, M. T., and M. H. Aminfar, 2009, A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation, *Engineering Applications of Artificial Intelligence*, Vol.22, No.2, pp.466–472.
 15. Okkan, U, 2012, Wavelet neural network model for reservoir inflow prediction, *Journal of Scientia Iranica*, Vol.4, No.2, pp.1445–1455
 16. Safavi, A.A., and J. A. Romagnoli, 1997, Application of wavelet-based neural networks to modelling and optimisation of an experimental distillation column, (*IFAC Journal of Engineering Applications of Artificial Intelligence*, Vol.10, No.3, pp. 301-313
 17. Safshekan, F., Pir Moradian, N., and R. A. Sharifian, 2011, Simulation of rainfall-پارامترهای ورودی قادر به پیش بینی دمای متوسط هوا با دقت بالایی می باشد. که این موضوع بخصوص در ایستگاه هایی که با نواقص آماری مواجه می باشند می تواند کمک شایانی به برآورد پارامتر مورد نظر نماید. با توجه به معیارهای ارزیابی، دو مدل مورد بررسی می‌تواند با دقت نسبتاً بالایی دمای هوا را پیش‌بینی نمایند. دقت بالای شبکه عصبی موجک ناشی از تجزیه سیگنال با کمک تابع گسسته موجک، منجر به ساده‌تر شدن این سیگنال‌ها شده و باعث ایجاد برتری محسوس نسبت به مدل شبکه عصبی مصنوعی می‌باشد. در مجموع نتایج این پژوهش نشان می‌دهد استفاده از مدل شبکه عصبی موجک می‌تواند در زمینه تخمین دمای هوای روزانه در طی ۱۰ سال آماری برای سایر مناطق نیز مورد استفاده قرار گرفته و به عنوان گامی در راستای اتخاذ تصمیمات مدیریتی مناسب در جهت بهبود منابع آب، کشاورزی و آبرسانی محسوب شود.

منابع

1. Abhishek, K., Singh, M. P., Ghosh, S., and A. Anand, 2012, Weather Forecasting Model using Artificial Neural Network, *Journal of Procedia Technology*, Vol.4, No.4, pp. 311-318
2. Banejad, H., Kamali, M., Amir Moradi, K., and A. Oliaei, 2013, Forecasting Some of the Qualitative Parameters of Rivers Using Wavelet Artificial Neural Network Hybrid (W-ANN) Model (Case of study: Jajroud River of Tehran and Gharaso River of Kermanshah), *Journal of Health and Environment*, Vol. 6, No.3, pp. 277-294
3. Bani Habib, M. A., Rahimi Khob, A., and A. Arabi, 2007, The maximum daily temperature estimation using artificial neural networks and satellite images Nova (Case Study: Orumiyeh Lake basin), *Journal of Environmental Science and Technology*, Vol.9, No.3, pp.185-202
4. Emamifar, S., Rahimi Khob, A., and A. A. Nourozi, 2014, Evaluation of the M5 model tree and artificial neural network to estimate the average daily air temperature on land surface temperature data from MODIS sensor, *Iran Soil and Water Research*, Vol.45, No.4, pp.423-433
5. Ghorbani, M. A., Shiri, J., and H. Kazemi, 2009, Estimated maximum, medium and minimum air temperatures in Tabriz using

- regional Conference on Climate Change Conference. University of Esfahan
21. Tokar, A.S., and P. A. Johnson, 1999, Rainfall- Runoff modeling using artificial neuralnetworks, *Journal of Hydrology Engineering*, Vol.3, No.2, pp.232-239.
 22. Venkata Ramana, R., Krishna, B., Kumar, S. R., and N. G. Pandey, 2013, Monthly Rainfall Prediction Using Wavelet Neural Network Analysis, *Water Resources Management*, Vol.27, No.10, pp.3697-3711
 23. Wang, D., Safavi, A. A., and J. A. Romagnoli, 2000, Wavelet-based adaptive robust M-estimator for non-linear system identification, *AIChE Journal*, Vol.46, No.8, pp.1607-1615
 24. Wang, W., and J. Ding, 2003, Wavelet Network Model and Its Application to the Prediction of Hydrology, *Nature and Science*, Vol.1, No.1, pp.67-71.
 25. Zhu, Y. M., Lu, X.X., and Y. Zhou, 2007, Suspended sediment flux modeling with artificial neural network: An example of the longchuanjiang river in the upper yangtze catchment, *Geomorphology*, Vol.84, No.4, pp.111-125.
 - runoff hydrograph according to the time pattern of rainfall and the use of artificial neural network in the famous Kasilian Basin. *Engineering Sciences Iranian Journal of Watershed Management*, Vol.5, No.15, pp. 1-10
 18. Salahi, B., Hosseini, S. A., Shangi Moghanlo, H., and B. Sobhani, 2010, Maximum temperatures predicted using artificial neural network model: A Case Study of Ardabil city. *Journal of Geographical Research*, Vol.25, No.3, pp.57-78
 19. Sharifi, S.S., Rezaverdinejad, V., and V. Nourani, 2016, Estimation of Daily Global Solar Radiation using Wavelet Regression, ANN, GEP and Empirical Models: A Comparative Study of Selected Temperature-Based Approaches, *Journal of Atmospheric and Solar-Terrestrial Physics*, Vol.149. No.3, pp.131-145
 20. Teshneh Lab, M., and M. Monshi, 2003, Prediction of meteorological parameters using fuzzy neural network based on the education parameters Tully, third and first