

انتخاب مناسب‌ترین ورودی‌ها برای مدل شبکه عصبی مصنوعی با استفاده از الگوریتم جامعه مورچگان

محمدجواد زینلی^۱، علی شهیدی^{*۲}

۱. دانشجوی دکتری منابع آب، گروه علوم و مهندسی آب، دانشگاه بیرجند
۲. دانشیار گروه علوم و مهندسی آب، دانشگاه بیرجند

(تاریخ دریافت ۱۹/۰۱/۱۳۹۶؛ تاریخ تصویب ۱۷/۰۴/۱۳۹۶)

چکیده

یافتن مناسب‌ترین ورودی‌ها برای شبکه عصبی و همچنین تعداد مناسب ورودی برای آن یکی از چالش‌هایی است که همواره محققان با آن رویه‌رو هستند. اغلب، بهترین ساختار برای شبکه عصبی نیز به صورت آزمون و خطا مشخص می‌شود و درنهایت با تعریف چند ورودی خاص مدل‌های مختلفی تولید و بررسی می‌شوند. در این تحقیق به مدل‌سازی کیفی جریان رودخانه گدارچای با استفاده از شبکه عصبی مصنوعی پرداخته شده و دو مدل و برای هر مدل چهار سناریو تعریف شد. در هر دو مدل پارامتر هدف مقدار هدایت الکتریکی بوده است. ورودی‌های مدل اول (ANNa) را پارامترهایی تشکیل می‌دهند که بیشترین همبستگی را با پارامتر هدف (EC) داشته‌اند. در مدل دوم (ANNb) مناسب‌ترین پارامترهای ورودی با استفاده از الگوریتم جامعه مورچگان (ACO) مشخص شد. معیارهای به کاررفته در این تحقیق شامل معیارهای میانگین مربعات خطا (MSE)، مجموع مربعات خطا (SSE)، نش-ساتکلیف و ضریب همبستگی بوده است. نتایج نشان داد بهترین مدل ANNa با مقدار MSE برابر ۰/۰۰۱۷ است. ورودی‌های این مدل مجموع کاتیون‌ها، سختی کل و کلسیم است. بهترین مدل ANNa2 با مقدار MSE برابر ۰/۰۰۱۷ است. ورودی‌های این مدل مجموع کاتیون‌ها، سختی کل و کلسیم است. بهترین مدل ANNb، مدل ANNb3 با مقدار MSE برابر ۰/۰۰۱۲ است. ورودی‌های این مدل درصد سدیم، pH و سختی کل است. همچنین، نتایج نشان داد استفاده از الگوریتم جامعه مورچگان برای یافتن بهترین پارامترهای ورودی سبب افزایش کارایی شبکه عصبی در قسمت صحبت‌سنگی و تست در مدل ANNb نسبت به مدل ANNa می‌شود. طبق نتایج به دست آمده به جای آزمون و خطا در یافتن بهترین ورودی‌ها برای شبکه عصبی می‌توان به عنوان گام نخست از پارامترهایی استفاده کرد که بیشترین همبستگی را با پارامتر هدف دارند؛ اما پارامترهایی که با پارامتر هدف همبستگی زیادی دارند، لزوماً بهترین ورودی‌ها برای شبکه نیستند. همچنین، نتایج نشان داد از الگوریتم ACO می‌توان به عنوان روشی برای انتخاب متغیرهای ورودی استفاده کرد و عملکرد شبکه عصبی را بهبود بخشد.

کلیدواژگان: الگوریتم جامعه مورچگان، انتخاب متغیر ورودی، رودخانه گدارچای، شبکه عصبی مصنوعی.

میزان همبستگی این دو پارامتر با EC به ترتیب برابر با $-0/01$ و $-0/41$ بوده است [۴]. کاندا و همکارانش (۲۰۱۶) با هدف بررسی توانایی شبکه عصبی در پیش‌بینی میزان اکسیژن محلول در رودخانه انزویا^۱ در کنیا، از چهار متغیر ورودی دما، کدورت، pH و هدایت الکتریکی استفاده کردند و از شبکه پرسپکترون در مطالعه خود بهره برdenد. نتایج این تحقیق نشان داد از شبکه عصبی مصنوعی می‌توان به عنوان ابزاری مناسب برای پیش‌بینی میزان اکسیژن محلول استفاده کرد [۵]. از طرف دیگر، استفاده از الگوریتم‌های فرالبتکاری در ساختار شبکه عصبی، در بعضی موارد کارایی شبکه را زیاد می‌کند. به طور مثال، سقطفروش و همکارانش (۱۳۹۶) در تحقیقی با هدف ساخت یک مدل شبکه عصبی مصنوعی با قدرت پیش‌بینی زیاد از الگوریتم مورچگان برای یافتن ترکیبی از داده‌های ورودی به گونه‌ای که عوارض نامطلوب ناشی از انفجار، به کمترین مقدار ممکن برسد، بهره برdenد [۶]. فقیه (۱۳۸۹) در تحقیقی الگوریتم ژنتیک و شبکه عصبی را با هم تلفیق کرد و بیان داشت که در بیشتر موارد، این شبکه برتری خود را نسبت به اجرای شبکه عصبی بدون بهینه‌سازی نشان می‌دهد. وی با هدف بررسی کارایی شبکه عصبی مصنوعی در برآورد مکانی بارش ماهانه، از شبکه عصبی با ساختار پرسپکترون چندلایه برای تدوین مدل برآورد مکانی بارش در پنج ایستگاه سینوپتیک و باران‌سنگی، واقع در استان کردستان استفاده کرد. همچنین، از روش الگوریتم ژنتیک برای بهینه‌یابی پارامترهای قابل تنظیم، شامل تابع انتقال، قانون آموزش، مقدار ممنم، تعداد لایه پنهان، تعداد نورون لایه پنهان و تعداد الگوهای استفاده کرد و کارایی این الگوریتم را بررسی کرد. نتایج این تحقیق نشان داد شبکه عصبی در مدل‌سازی و برآورد مکانی بارش ماهانه دقت زیادی دارد و همچنین تلفیق آن با الگوریتم ژنتیک، برای بهینه‌سازی شرایط اجرای شبکه عصبی، مثبت ارزیابی شد و روش تلفیقی در بیشتر موارد برتری خود را نسبت به اجرای شبکه عصبی بدون بهینه‌سازی نشان داد [۷]. سوشا و بلام (۲۰۰۷) در تحقیقی از الگوریتم مورچگان پیوسته در آموزش شبکه عصبی مصنوعی استفاده کردند. نتایج پژوهش آنها نشان داد الگوریتم به کاررفته با الگوریتم‌های مبتنی بر گرادیان برای آموزش شبکه عصبی قابل رقابت است، همچنین الگوریتم به کاررفته در مقایسه با الگوریتم ژنتیک پایه

مقدمه

انتخاب صحیح پارامترهای ورودی سبب افزایش کارایی مدل می‌شود و با مدل‌سازی مناسب نیز می‌توان مقدار پارامتر یا پارامترهای هدف را تخمین زد یا خلاهای آماری را پوشش داد. برای ساخت یک مدل شبکه عصبی مناسب تحقیقات زیادی صورت گرفته است که در بیشتر آنها فقط به آنالیز حساسیت روی ورودی‌های شبکه و همچنین تغییر تعداد نورون‌ها و لایه‌های پنهان بسته می‌شود که در ادامه به تعدادی از این تحقیقات اشاره می‌شود. خوش‌نظر و همکارانش (۱۳۹۱) کارایی شبکه عصبی مصنوعی در پیش‌بینی میزان هدایت الکتریکی رودخانه زرینه‌رود را ارزیابی کردند و برای ساخت مدل شبکه عصبی از پنج مدل با ورودی‌های مختلف استفاده کردند و معیار پذیرش نتایج پیش‌بینی شده در هر یک از ساختارهای شبکه عصبی را معیارهای ضربی تبیین، ریشه میانگین مربعات خطأ و خطای نرمال نسبی قرار دادند [۱]. بازداد و همکارانش (۱۳۹۲) در تحقیقی برخی از پارامترهای کیفی رودخانه جاجرمود تهران و قره‌سوی کرامشان را با استفاده از مدل هیبرید شبکه‌های عصبی – موجکی تخمین زند و در تحقیق خود سناریوهای مختلفی را ارزیابی کردند و سناریوهای دارای کمترین خطأ را به عنوان ساختار بهینه انتخاب کردند [۲]. بزرگ و همکارانش (۲۰۱۶) برای پیش‌بینی کیفیت آب رودخانه از مدل شبکه استفاده کردند. ایشان در تحقیق خود از داده‌های دبی، دما، pH، هدایت الکتریکی، سدیم، پتاسیم، منیزیم، کلسیم، کربنات و بی‌کربنات، سولفات و کلر بهره گرفتند و در انتهای برای پیش‌بینی میزان EC از ورودی‌های کلسیم، منیزیم، سدیم، سولفات و کلر استفاده کردند. این داده‌ها بیشترین میزان همبستگی با پارامتر هدف یعنی هدایت الکتریکی را داشته است. میزان همبستگی کلسیم، منیزیم، سدیم، سولفات و کلر با EC به ترتیب برابر با $0/798$ ، $0/782$ ، $0/983$ و $0/965$ بوده است، در حالی که میزان همبستگی دبی، دما، pH، پتاسیم، کربنات و بی‌کربنات با EC به ترتیب برابر با $0/371$ ، $0/202$ ، $0/157$ و $0/034$ بوده است [۳]. ستاری و همکارانش (۲۰۱۶) در تحقیقی با استفاده از الگوریتم نزدیک‌ترین همسایه و رگرسیون بردار پشتیبان پارامترهای کیفی آب رودخانه لیقوان‌چای را تخمین زند و در تحقیق خود هشت سناریو تعریف کردند که فقط در یکی از آنها از SO_4^{2-} کمترین میزان همبستگی را با EC داشته، استفاده شده است.

گریوه‌داغ در مرزهای ایران و عراق سرچشمه می‌گیرد و از سه شاخه اصلی گادارچای و چم‌غلطان و اشنویه تشکیل می‌شود؛ پس از طی مسافتی به‌سوی شرق و عبور از روستاهای ظلم‌آباد و آق‌طولیله، در ناحیه برده‌زرد جاده مهاباد به ارومیه را قطع می‌کند و در جنوب شرقی بندر حیدرآباد وارد دریاچه ارومیه می‌شود. طول این رودخانه حدود ۹۰ کیلومتر و مساحت حوضه آبریز آن در محل دربند نقده حدود ۸۷۵ کیلومترمربع است. داده‌های استفاده شده در این تحقیق، پارامترهای کیفی آب رودخانه طی سال آبی ۱۳۹۰ تا ۱۳۷۰ به صورت فصلی است. در این رودخانه به صورت متناوب در هر فصل دو تا سه نمونه برداری صورت گرفته است. به‌طور کلی، اندازه‌گیری پارامترهای کیفی رودخانه در ماههای سال به‌طور منظم نبوده و بسته به شرایط آب و هوایی منطقه (وقوع سیلاب یا خشکبودن رودخانه) هر ماه اندازه‌گیری صورت می‌گیرد. داده‌های بررسی شده مربوط به ایستگاه پی‌قلعه است که در موقعیت $23^{\circ} 45^{\prime}$ طول شرقی و $58^{\circ} 36^{\prime}$ عرض شمالی واقع شده است. شکل ۱ حوضه رودخانه گادارچای و موقعیت ایستگاه پی‌قلعه را نشان می‌دهد.

شبکه عصبی مصنوعی پرسپترون

هر شبکه از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه میانی تشکیل شده است. اهرم ارتباطی نورون‌های هر لایه به نورون‌های لایه بعد وزن‌های نورون‌هاست. هر نورون مقادیر ورودی را در وزن خود ضرب کرده و با بایاس جمع می‌کند و حاصل به تابع محرکه انتقال داده می‌شود تا به این وسیله به نورون‌های لایه بعد انتقال داده شود. این عمل در نورون‌های همه لایه‌های شبکه انجام می‌شود تا در نهایت خروجی شبکه به دست آید.

شبکه عصبی پرسپترون چندلایه^۱ (MLP)، شبکه‌ای با الگوریتم پسانشتر خطا است که در جعبه‌ابزار متلب به صورت پیش‌فرض، تابع انتقال^۲ در لایه پنهان از تابع حرکه تائزانت سیگموئید (tansig) و در لایه خروجی از تابع حرکه خطی (purelin) استفاده می‌کند و تابع یادگیری وزن‌ها تابع (learngdm) و تابع آموزش آن تابع لونبرگ مارکوات^۳ (trainlm) است. در این شبکه‌ها

عملکرد مطلوب‌تری داشته است [۸]. امامی و همکارانش (۲۰۱۵) از ترکیب الگوریتم مورچگان و شبکه عصبی در مدل شبکه‌سازی-بهینه‌سازی چنددهدفه استفاده کردند. مدل‌سازی برای کنترل بار آلودگی در مقیاس حوضه‌ای (در حوضه قره‌سو) صورت گرفت و نتایج آن نشان داد روش ترکیبی پیشنهادی زمان محاسبات را تا ۹۰ درصد کاهش می‌دهد [۹]. والذ و همکارانش (۲۰۱۶) در تحقیقی یک شبکه عصبی مدولار (MNN) را برای تشخیص الگو توصیف کردند و بیان داشتند که برای طراحی یک سیستم تشخیص الگو به دقت زیادی نیاز است، بنابراین در تحقیق خود از پارادایم مورچگان برای بهینه‌سازی معماری این شبکه عصبی مدولار برای تشخیص الگو و برای به دست آوردن درصد مناسبی از شناسایی تصویر در کوتاه‌ترین زمان ممکن بهره گرفتند [۱۰]. ژو (۲۰۱۷) در تحقیقی چارچوب مستعمره آموزش بهینه‌سازی شبکه‌های عصبی پیشخور مورچه بر اساس استراتژی انتخاب نخبه‌گرا را پیشنهاد کرد. در الگوریتم یادگیری پیشنهادی وزن لایه‌های درون شبکه طی سه مرحله به دست می‌آید. در مرحله نخست، رسیدن به هدف را برای انتخاب مقدار اولیه پس از تعداد معینی یادگیری با الگوریتم BP، مرحله دوم، استفاده از بهینه‌سازی جامعه مورچگان (ACO) برای تکمیل شبکه یادگیری برای تقریب دقت داده و یادگیری و در مرحله سوم هنگامی که الگوریتم ACO به طور آهسته در حال همگراشدن است، الگوریتم ACO به عنوان پارامتری مانند وزن برای آموزش شبکه استفاده می‌شود [۱۱].

برای یافتن مناسب‌ترین ورودی‌های یک مدل روش‌های متنوعی وجود دارد، اما عموماً محققان از پارامترهایی که با پارامتر هدف، همبستگی زیادی دارند، به عنوان ورودی شبکه استفاده می‌کنند. بهترین ساختار برای شبکه عصبی نیز به صورت آزمون و خطاب مشخص می‌شود و در نهایت با تعریف چند ورودی خاص مدل‌های مختلفی تولید و سپس بررسی می‌شوند. بر این اساس، هدف از تحقیق حاضر بررسی کارایی الگوریتم مورچگان به عنوان روشی برای انتخاب ورودی مدل شبکه عصبی در تخمین پارامترهای کیفی رودخانه است.

مواد و روش‌ها

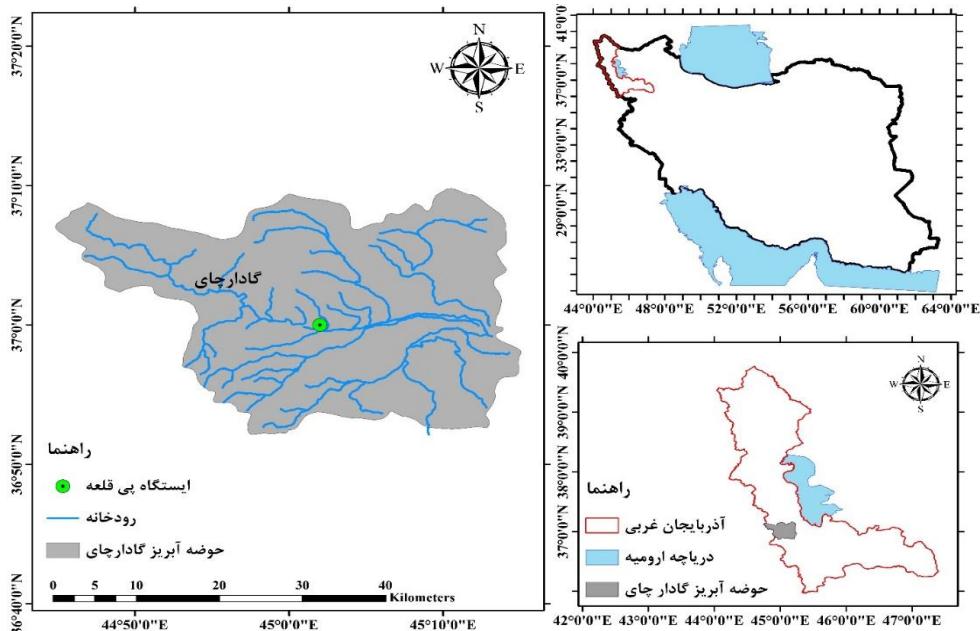
منطقه مطالعه شده

رودخانه گادارچای یا قادر رود از بلندی‌های مرزی

1. Multilayer Perceptron

2. Transfer Function

3. Levenberg Marquardt



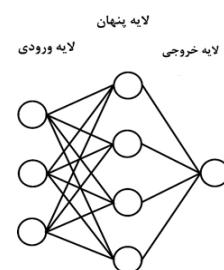
شکل ۱. موقعیت ایستگاه پیقلعه و حوضه رودخانه گدارچای

هستند که برای ارزیابی نتایج مرحله آموزش استفاده می‌شوند و دسته سوم داده‌ها برای تست شبکه ساخته شده اختصاص داده می‌شوند که این گروه از داده‌ها، داده‌های تست هستند. در این تحقیق ۶۰ درصد داده‌های موجود به آموزش، ۲۰ درصد به صحت‌سنجی و ۲۰ درصد باقی‌مانده نیز به تست شبکه اختصاص داده شده است.

الگوریتم جامعه مورچگان

برای حل یک مسئله بهینه‌سازی به کمک الگوریتم جامعه مورچگان، باید گرافی برای مسئله تعریف شود. به‌طور نمونه، در مسئله بهینه‌سازی ورودی‌های شبکه عصبی، گراف ($G = (D, L, C)$) که در آن $D = \{d_1, d_2, \dots, d_n\}$ مجموعه نقاط تصمیم است و $L = \{L_i\}_{i=1}^n$ مجموعه انتخاب‌های i و $(j)_{j=1,2,\dots,n}$ در هر یک از نقاط تصمیم i ($i=1,2,\dots,n$) و $L_i = \{C_{i,j}\}_{j=1}^n$ مجموعه هزینه‌های هر یک از انتخاب‌های j است [۱۳]. گراف مسئله بهینه‌سازی ورودی‌های شبکه عصبی به‌صورت شکل ۳ است. در این تحقیق هر یک از مجموعه نقاط تصمیم (d_i) مجموعه ورودی‌های شبکه عصبی هستند؛ هر یک از مجموعه انتخاب‌ها (j) یکی از ورودی‌های شبکه هستند و تعداد ورودی‌های مدل نیز تعداد نقاط تصمیم (تعداد n) را مشخص می‌کند. به این ترتیب که اگر تعداد ورودی مدل چهار پارامتر باشد، i از یک تا

اطلاعات ورودی توسط نورون‌های ورودی دریافت شده و سپس به نورون‌های لایه پنهان فرستاده می‌شود و پردازش مد نظر روی آنها انجام می‌گیرد و نتیجه به نورون‌های لایه خروجی فرستاده می‌شود تا به عنوان خروجی شبکه نمایش داده شوند [۱۲]. در این تحقیق، شبکه یک لایه پنهان دارد که در آن پنج نورون قرار داده شده است. شکل ۲ نمونه‌ای از یک شبکه پرسپترون چندلایه را نشان می‌دهد.



شکل ۲. ساختار شبکه عصبی پرسپترون چندلایه با یک لایه پنهان

برای به کاربردن این شبکه‌ها، داده‌ها به سه دسته تقسیم می‌شوند. گروه نخست برای آموزش شبکه اختصاص داده می‌شوند که داده‌های آموزش^۱ نامیده می‌شوند و گروه دوم از داده‌ها، داده‌های اعتبارسنجی^۲

جدول ۱. مشخصات آماری پارامترهای جریان رودخانه
گادارچای طی دوره آماری ۱۳۹۰-۱۳۷۰

ردیف	نام پارامتر	واحد	مقدار متوسط	مقدار مینیموم	مقدار مaximum	مقدار میانگین
۱۹/۸۰	هدایت الکتریکی (ds m-1)	$\text{m}^3 \text{s}^{-1}$	۸۶۰	۶۵۰/۱۳	۲۵۷/۶۳	۲۵۷/۶۳
۱۴/۱۸	حریان (mg l⁻¹)	۰/۵۴	۷۳/۴	۰/۵۴	۱۱/۴۳	۰/۵۰
۰/۵۰	قلیائیت (-)		۸/۷	۶/۳	۷/۶۳	۰/۵۶
۱/۵۶	بی‌کربنات (meq l⁻¹)		۲۰/۵	۱/۲	۲۴/۵	۰/۱۶
۰/۱۶	کلر (meq l⁻¹)		۱/۵	۰/۱	۰/۲۶	۰/۳۰
۰/۳۰	سولفات (-)		۲/۳	۰/۰۴	۰/۴۲	۱/۸۶
۱/۸۶	مجموع آئیون‌ها (-)		۲۰/۸	۱/۷۴	۳/۱۴	۰/۵۳
۰/۵۳	کلسیم (meq l⁻¹)		۴/۵	۱/۱	۲/۰۱	۰/۴۶
۰/۴۶	منیزیم (meq l⁻¹)		۳	۰/۱	۰/۷۱	۰/۲۲
۰/۲۲	سدیم (%)		۲/۵۲	۰/۰۶	۰/۲۲	۰/۹۶
۰/۹۶	مجموع کاتیون‌ها (-)		۹/۷۴	۱/۸	۲/۹۶	۰/۱۵
۰/۱۵	نسبت جذب سدیمی (-)		۱/۳۵	۰/۰۶	۰/۱۹	۷۸/۲۳
۷۸/۲۳	سختی کربنات (mg l⁻¹)		۱۰۲۵	۶۰	۱۲۳/۱۸	۴۱/۲۴
۴۱/۲۴	سختی کل (mg l⁻¹)		۳۵۰	۸۰	۱۳۵/۸۷	

با توجه به اینکه تعداد متغیرهای ورودی ۱۳ مورد است، برای مدل‌های با دو، سه، چهار و پنج ورودی تعداد حالات مختلف برای انتخاب متغیرهای ورودی شبکه مطابق روابط ۱ تا ۴ محاسبه می‌شود. با توجه به تعداد حالات بسیار زیاد، باید تعداد مورچه‌ها متناسب با تعداد حالات تعیین شود، زیرا تعداد کم مورچه‌ها سبب خواهد شد که محلهایی از فضای پاسخ‌های ممکن بررسی نشود و از طرفی تعداد زیاد مورچه‌ها مدت زمان اجرای برنامه را زیاد خواهد کرد.

$$C_2^{16} = \frac{16!}{2! \times (16-2)!} = ۱۲۰ \quad (1)$$

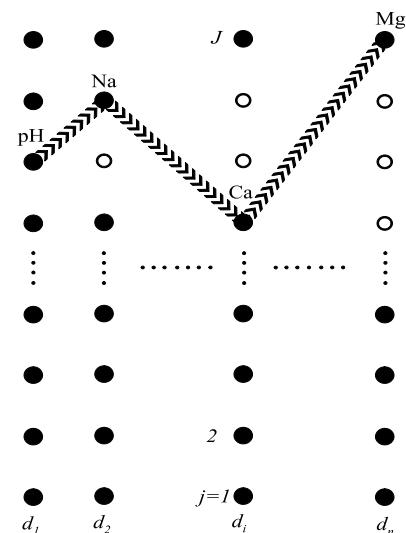
$$C_3^{16} = \frac{16!}{3! \times (16-3)!} = ۵۶۰ \quad (2)$$

$$C_4^{16} = \frac{16!}{4! \times (16-4)!} = ۱۸۲۰ \quad (3)$$

$$C_5^{16} = \frac{16!}{5! \times (16-5)!} = ۴۳۶۸ \quad (4)$$

معیار انتخاب بهترین ورودی‌ها مقدار میانگین مربعات خطای (MSE) مربوط به صحبت‌سنجی است که این معیار به همراه معیارهای مجموع مربعات خطای (SSE)، نش-ساتکلیف (NS) و همبستگی (R) از روابط ۵ تا ۸ محاسبه می‌شود.

چهار خواهد بود. همچنین، باید توجه داشت چون داده‌های ورودی نمی‌تواند تکراری باشد، بنابراین پس از انتخاب یک ورودی (بهطور مثال pH) باید این گره در مجموعه نقاط تصمیم بعدی حذف شود. شکل ۳ این موضوع را روشن ساخته است و گره‌ها (پارامترهای) که می‌توان آنها را انتخاب کرد با دایرة توپر و گره‌هایی که نباید انتخاب شوند به صورت دایرة توخالی نشان داده شده است.



شکل ۳. گراف مربوط به انتخاب پارامترهای ورودی شبکه عصبی (دایره‌های توپر، گره‌های قابل انتخاب و دایره‌های توخالی گره‌های غیرقابل انتخاب اند)

پارامترهای ورودی شبکه عصبی در مستله بهینه‌سازی پارامترهای ورودی در مدل‌سازی شبکه عصبی تعداد ۱۳ پارامتر ورودی وجود داشته و پارامتر هدف، هدایت الکتریکی (EC) است. پارامترهای ورودی نیز دبی، قلیائیت (pH)، کربنات (HCO_3), کلر (Cl), سولفات (SO_4), مجموع آئیون‌ها^۱, مجموع کاتیون‌ها^۲, کلسیم (Ca), منیزیم (Na), سدیم (Mg) نسبت جذب سدیمی^۳ (SAR), سختی موق^۴ ت^۵ یا سختی کربناتی^۶ و سختی کل^۷ هستند که مقدار بیشینه، کمینه، میانگین و انحراف از معیار هریک از این پارامترها در جدول ۱ آورده شده است.

1. Electrical Conductivity

2. Total Anion

3. Total Caution

4. Sodium Adsorption Ratio

5. Temporary Hardness

6. Carbonated Hardness

7. Total Hardness

استفاده شد که دستور "corrcoef" در متلب نیز می‌تواند میزان همبستگی را نشان دهد. نتایج ارزیابی همبستگی بین پارامترها در جدول ۲ آورده شده است. همان‌طور که در این جدول ملاحظه می‌شود، مجموع کاتیون‌ها (TC)، سختی کل (TH)، کلسیم (Ca)، منیزیم (Mg) و سولفات‌ها (SO₄) به ترتیب با مقدار ۰/۹۲، ۰/۸۲، ۰/۹۰ و ۰/۶۰ بیشترین میزان همبستگی را با مقدار هدایت الکتریکی (EC) داشته‌اند. بنابراین، از این پارامترها به عنوان ورودی مدل‌ها استفاده شده و شبکه عصبی، با دو ورودی (ANNa1)، با سه ورودی (ANNa2)، با چهار ورودی (ANNa3) و پنج ورودی (ANNa4) بررسی شد که بهترین نتیجه به دست آمده از پنج مرتبه اجرای هر یک از این مدل‌ها در جدول‌های ۳ و ۴ آورده شده است. جدول ۳ مقادیر معیارهای عملکرد SSE، MSE و NS و R مربوط به صحت‌سنجی و جدول ۴ مقادیر این معیارها را برای تست شبکه نشان می‌دهد. در قسمت صحت‌سنجی و تست بهترین مدل ANNa2 بوده که نمودارهای آن در شکل ۴ الف و ۴ ب آورده شده است.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Q_i - \hat{Q}_i)^2 \quad (5)$$

$$SSE = \sum_{i=1}^n (Q_i - \hat{Q}_i)^2 \quad (6)$$

$$NS = 1 - \frac{\sum_{i=1}^n (Q_i - \bar{Q})^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2} \quad (7)$$

$$R = \frac{n \sum_{i=1}^n (Q_i)(\hat{Q}_i) - \left(\sum_{i=1}^n Q_i \right) \left(\sum_{i=1}^n \hat{Q}_i \right)}{\sqrt{n \left(\sum_{i=1}^n Q_i^2 \right) - \left(\sum_{i=1}^n Q_i \right)^2} \sqrt{n \left(\sum_{i=1}^n \hat{Q}_i^2 \right) - \left(\sum_{i=1}^n \hat{Q}_i \right)^2}} \quad (8)$$

در این روابط Q_i خروجی شبکه و \hat{Q}_i داده‌های مشاهداتی و n تعداد داده‌ها هستند.

نتایج و بحث

برای تحلیل و بررسی ارتباط میان ویژگی‌های کیفی جریان رودخانه گادارچای از روش پیرسون و نرم‌افزار SPSS 19

جدول ۲. همبستگی بین پارامترهای کیفی جریان رودخانه گادارچای

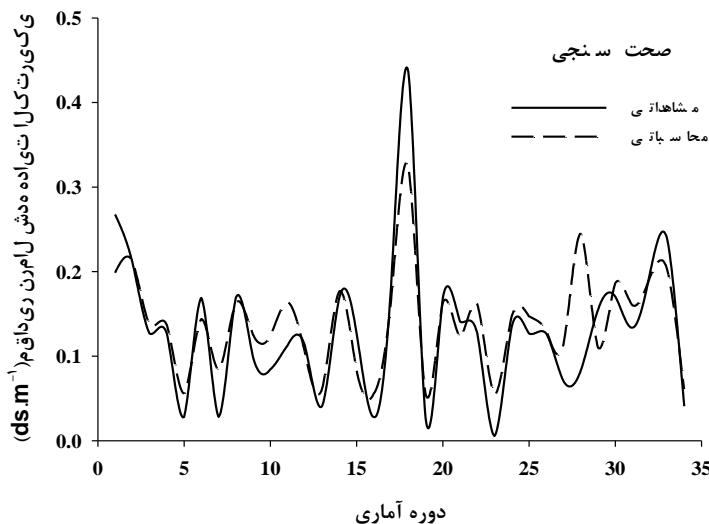
	EC	Q	pH	HCO ₃	Cl	SO ₄	TA	Ca	Mg	Na	TC	SAR	CH	TH
EC	۱/۰۰													
Q	-۰/۲۷	۱/۰۰												
pH	۰/۱۱	-۰/۰۸	۱/۰۰											
HCO ₃	۰/۳۹	-۰/۱۸	۰/۰۵	۱/۰۰										
Cl	۰/۵۷	-۰/۰۲	-۰/۱۴	۰/۲۳	۱/۰۰									
SO ₄	۰/۶۰	-۰/۱۴	۰/۰۵	۰/۱۴	۰/۳۵	۱/۰۰								
TA	۰/۵۴	-۰/۲۰	۰/۰۶	۰/۹۷	۰/۳۷	۰/۳۴	۱/۰۰							
Ca	۰/۸۲	-۰/۳۱	۰/۰۶	۰/۳۶	۰/۴۲	۰/۵۵	۰/۴۹	۱/۰۰						
Mg	۰/۶۷	-۰/۱۹	-۰/۰۱	۰/۲۸	۰/۵۸	۰/۴۵	۰/۴۰	۰/۳۸	۱/۰۰					
Na	۰/۵۷	-۰/۰۸	۰/۰۶	۰/۲۰	۰/۶۴	۰/۵۵	۰/۳۴	۰/۳۹	۰/۳۷	۱/۰۰				
TC	۰/۹۲	-۰/۲۸	۰/۰۳	۰/۳۸	۰/۶۷	۰/۶۶	۰/۵۵	۰/۸۳	۰/۷۹	۰/۶۴	۱/۰۰			
SAR	۰/۳۸	۰/۰۴	۰/۰۵	۰/۱۱	۰/۵۰	۰/۴۴	۰/۲۲	۰/۲۳	۰/۱۹	۰/۹۴	۰/۴۴	۱/۰۰		
CH	۰/۴۱	-۰/۱۸	۰/۰۷	۱/۰۰	۰/۲۳	۰/۴۱	۰/۹۷	۰/۳۷	۰/۲۸	۰/۲۰	۰/۳۹	۰/۱۱	۱/۰۰	
TH	۰/۹۰	-۰/۳۰	۰/۰۳	۰/۳۹	۰/۵۹	۰/۶۱	۰/۵۴	۰/۸۶	۰/۸۰	۰/۴۶	۰/۹۸	۰/۲۵	۰/۴۰	۱/۰۰

جدول ۳. بهترین عملکرد مدل‌های ANNa در پنج مرتبه اجرا برای صحت‌سنجی شبکه

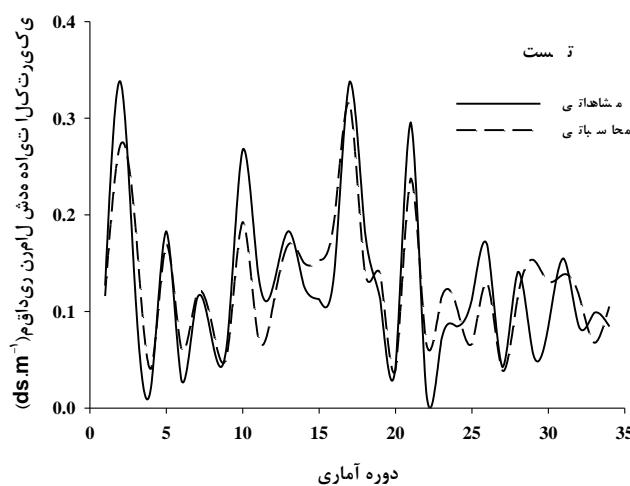
R	صحت‌سنجی			ورودی‌ها	مدل
	NS	SSE	MSE		
۰/۹۰۸۶	۰/۷۹۸۱	۰/۰۷۲۷	۰/۰۰۲۱	TH و TC	ANNa1
۰/۸۵۵۸	۰/۷۱۰۳	۰/۰۶۸۶	۰/۰۰۲۰	Ca و TH, TC	ANNa2
۰/۹۵۴۸	۰/۸۹۹۳	۰/۱۰۹۸	۰/۰۰۳۲	Mg و Ca, TH, TC	ANNa3
۰/۹۲۹۵	۰/۸۶۳۴	۰/۰۸۶۴	۰/۰۰۳۵	SO ₄ و Mg, Ca, TH, TC	ANNa4

جدول ۴. بهترین عملکرد مدل‌های ANNa در پنج مرتبه اجرا برای تست شبکه

تست				ورودی‌ها	مدل
R	NS	SSE	MSE		
۰/۹۰۸۴	۰/۸۲۸۳	۰/۱۰۶۱	۰/۰۰۳۱	TH و TC	ANNa1
۰/۸۶۳۰	۰/۷۴۶۶	۰/۰۵۷۶	۰/۰۰۱۷	Ca و TH ,TC	ANNa2
۰/۸۲۹۹	۰/۶۹۳۱	۰/۰۸۶۵	۰/۰۰۲۵	Mg و Ca ,TH ,TC	ANNa3
۰/۹۳۶۰	۰/۸۶۳۸	۰/۱۴۶۱	۰/۰۰۴۳	SO ₄ و Mg ,Ca ,TH ,TC	ANNa4



(الف)



(ب)

شکل ۴. داده‌های مشاهداتی و محاسباتی مرحله (الف) صحت‌سنجی؛ مرحله (ب) تست مدل ANNa2

می‌یابد. بنابراین، با توجه به نتایج تحقیق، می‌توان گفت که تعداد پارامترهای ورودی باید نه بسیار کم و نه بسیار زیاد باشد، بلکه تعداد سه یا چهار ورودی برای مدل کفایت می‌کند. همچنین، در خصوص قسمت صحتسنجی شبکه عصبی مصنوعی، در همه مدل‌ها الگوریتم مورچگان با انتخاب بهترین ورودی‌ها توانسته است با توجه به معیار MSE کارایی شبکه را به گونه‌چشمگیری افزایش دهد و در قسمت تست شبکه تیز، زمانی که تعداد پارامترها افزایش می‌یابد الگوریتم مورچگان، عملکرد شبکه را بهبود بخشیده است. از سوی دیگر، پارامترهای انتخابی الگوریتم مورچگان، پارامترهایی نظیر کلسیم و درصد سدیم است که میزان همبستگی آنها با هدایت الکتریکی (EC) متفاوت است (همبستگی Ca با EC برابر $12/82$ و میزان همبستگی درصد سدیم با EC برابر $10/0$ است) و بنابراین نتایج نشان می‌دهد پارامترهایی که همبستگی زیادی با پارامتر هدف دارند، الزاماً بهترین ورودی‌ها نخواهند بود؛ اما اگر تعداد ورودی‌ها زیاد نباشد، می‌توان از این پارامترها (پارامترهایی که همبستگی زیادی با پارامتر هدف دارند) به عنوان ورودی مدل شبکه عصبی استفاده کرد. بنابراین، با توجه به نتایج به دست آمده می‌توان الگوریتم مورچگان را به عنوان روشی برای انتخاب ورودی‌ها به حساب آورد. مقایسه دو جدول ۴ و ۶ نیز نشان می‌دهد بهترین مدل ANNa₂ با مقدار MSE= $0/0017$ در قسمت تست بوده، اما در بهترین مدل ANN_b₃، مدل MSE= $0/00123$ در قسمت تست بوده است و الگوریتم ACO با انتخاب مناسب‌ترین پارامترهای ورودی توانسته است عملکرد شبکه عصبی را بهبود بخشد. مقایسه نتایج به دست آمده با رگرسیون مرحله‌ای نیز بر این گفته صحه می‌گذارد.

در ادامه، برای یافتن بهترین پارامترهای ورودی شبکه عصبی مصنوعی، از الگوریتم جامعه مورچگان بهره گرفته شد. ساختار این شبکه نیز مانند شبکه قبلی بوده با این تفاوت که ورودی‌های مدل توسط الگوریتم مورچگان انتخاب شده است. در این مورد نیز مشابه با شبکه قبلی چهار مدل تعریف شده است که ANN_{b1} (با دو ورودی)، ANN_{b2} (با سه ورودی)، ANN_{b3} (با چهار ورودی) و ANN_{b4} (با پنج ورودی) بررسی شده است. در مدل ANN_{b1} مناسب‌ترین پارامترها قلیائیت (pH) و سختی کربناته (CH) بوده است. در مدل ANN_{b2} مناسب‌ترین پارامترها قلیائیت، کلر (Cl) و کربنات (HCO₃) و در مدل ANN_{b3} مناسب‌ترین پارامترها قلیائیت، سختی کل (TH)، کلسیم (Ca) و نسبت جذب سدیمی (SAR) و درنهایت در مدل ANN_{b4} مناسب‌ترین پارامترها مجموع کاتیون‌ها (TC)، مجموع آنیون‌ها (TA)، سدیم (Na) و pH می‌زنند. مقدارهای معمولی مدل‌های مختلف شبکه عصبی در قسمت صحتسنجی و تست نشان می‌دهند. در قسمت صحتسنجی مدل ANN_{b4} و تست مدل ANN_{b3} بهترین عملکرد را داشته است که نمودارهای آن در شکل ۵ الف و ۵ ب آورده شده است.

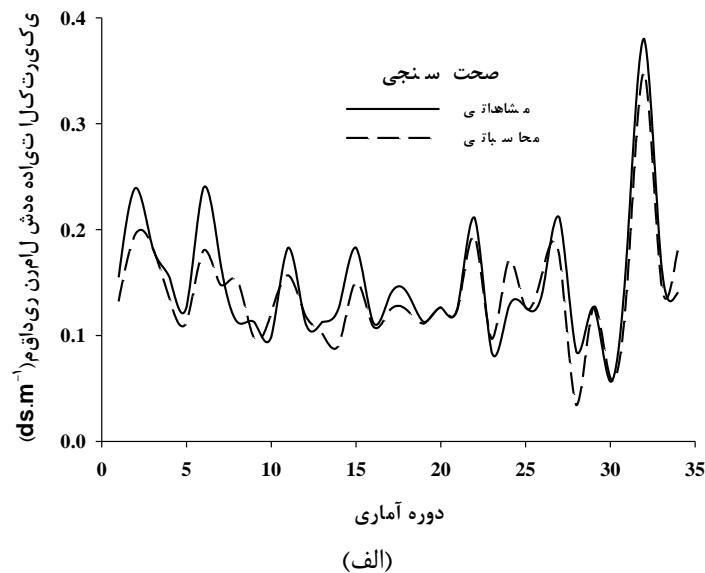
همان‌طور که در جدول‌های ۳ و ۴ ملاحظه می‌شود با افزایش تعداد ورودی‌ها، هم در قسمت صحتسنجی و هم در قسمت تست شبکه مقدار MSE ابتدا کاهش یافته و دوباره افزایش می‌یابد. همچنین، در جدول‌های ۵ و ۶ ملاحظه می‌شود با افزایش تعداد ورودی‌ها، در قسمت صحتسنجی شاهد کاهش مقدار MSE بوده و در قسمت تست شبکه مقدار MSE ابتدا کاهش یافته و دوباره افزایش

جدول ۵. عملکرد مدل‌های ANN_b برای صحتسنجی شبکه

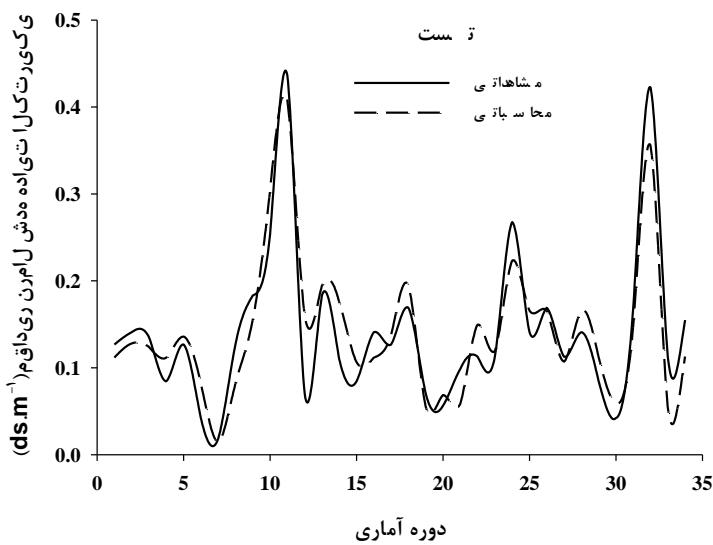
R	NS	SSE	MSE	صحتسنجی		بهترین ورودی‌ها	مدل
				MSE	بهترین ورودی‌ها		
۰/۹۶۰۳۶	۰/۹۲۳۴۹۲	۰/۲۵۰۲۸	۰/۰۰۰۷۳۶	CH و pH	ANN _{b1}		
۰/۹۱۴۰۷۵	۰/۸۳۹۱۷۳	۰/۰۲۴۲۷۵	۰/۰۰۰۷۱۴	HCO ₃ و Cl .pH	ANN _{b2}		
۰/۹۳۶۶۳۶	۰/۸۶۹۹۵۵	۰/۰۲۳۹۴	۰/۰۰۰۷۰۴	SAR و Ca .TH .pH	ANN _{b3}		
۰/۹۰۶۰۳۸	۰/۷۹۷۰۳۷	۰/۰۲۳۸۸۴	۰/۰۰۰۷۰۲	Ca و pH .Na .TA .TC	ANN _{b4}		

جدول ۶. عملکرد مدل‌های ANNb برای تست شبکه

تست				بهترین ورودی‌ها	مدل
R	NS	SSE	MSE		
۰/۹۶۵۵۵۱	۰/۸۶۲۶۰۸	۰/۱۴۰۴۱۵	۰/۰۰۴۱۳	CH و pH	ANNb1
۰/۸۷۳۹۹۹	۰/۷۵۹۰۴۷	۰/۱۲۸۳۴۲	۰/۰۳۷۷۵	HCO ₃ و Cl .pH	ANNb2
۰/۹۱۹۲۲۵	۰/۸۴۹۳۴۷	۰/۰۴۱۸۲۹	۰/۰۰۱۲۳	SAR و Ca .TH .pH	ANNb3
۰/۸۴۶۱۶۳	۰/۶۷۰۴۴۱	۰/۰۷۴۶۶۸	۰/۰۰۲۱۹۶	Ca و pH .Na .TA .TC	ANNb4



(الف)



(ب)

شکل ۵. داده‌های مشاهداتی و محاسباتی مرحله (الف) صحت‌سنجی مدل ANNb4؛ مرحله (ب) تست مدل ANNb3

- prediction: a case study in Aji-chay river, Iran. Stochastic Environmental Research and Risk Assessment, 2016; 30(7):1797-1819.
- [4]. Sattari MT, Rezazadeh Joudi A and Kusiak A. Estimation of water quality parameters with data-driven model. Journal American Water Works Association. 2016; 108:4.
- [5]. Kanda EK, Kipkorir EC and Kosgei JR. Dissolved oxygen modelling using artificial neural network: a case of river nzoia, lake victoria basin, kenya. Journal of Water Security, 2016; 2:1-7.
- [6]. Seght Foroosh A, Monjezi M and Khademi Hamidi J. Optimization of blasting operation using hybrid Neural Network-Ant Colony (Case Study: Delkan Iron Mine). Journal of Modeling and Engineering. 2017; DOI: 10.22075/JME.2017.2449. [Persian]
- [7]. Faghih H. Evaluating artificial neural network and its optimization using genetic algorithm in estimation of monthly precipitation data (case study: Kurdistan region). Journal of Water and Soil Science (Journal of Science and Technology of Agriculture and Natural Resources). 2010. 14(51): 27-44. [Persian]
- [8]. Socha K and Blum C. An ant colony optimization algorithm for continuous optimization: application to feed-forward neural network training. Journal of Neural Computing and Applications. 2007; 16: 235-247.
- [9]. Emami Skardi MJ, Afshar A, Saadatpour M and Solis SS. Hybrid ACO-ANN-based multi-objective simulation-optimization model for pollutant load control at basin scale. Environmental Modeling and Assessment. 2015; 20(1): 29-39.
- [10]. Valdez F, Castillo O and Melin P. Ant colony optimization for the design of modular neural networks in pattern recognition. In Neural Networks (IJCNN), International Joint Conference. 2016; 163-168.
- [11]. Zho G. Ant colony optimization training feed-forward neural network based on elitist selection strategy. Boletín técnico. 2017; 55(1): 200-206.
- [12]. Zeynali MJ, Nikbakht S, Mohammadezapour O. Prediction input flows to Mollasadra reservoir by using artificial neural network. 5th Iranian Water Resources Management Conference. Shahid Beheshti University. 29 Jul 2013. [Persian]
- [13]. Zeynali MJ, Mohammadrezapour O and Foroughi F. Comparison of imperialist competitive algorithm (ICA) and ant colony algorithm (ACO) for optimizing exploitation of Doroudzan reservoir with application of chain constraints approach. Journal of Water and Soil Conservation. 2016; 22(6): 231-243. [Persian]

نتیجه‌گیری

در این مطالعه، مدل سازی کیفی جریان رودخانه گادارچای با استفاده از شبکه عصبی بررسی شد. تعداد ۱۳ پارامتر به عنوان پارامترهای کاندیدای ورودی به مدل و پارامتر EC به عنوان پارامتر هدف در نظر گرفته شد. ابتدا، همبستگی بین پارامترهای برداشت شده با پارامتر هدایت الکتریکی (EC) بررسی شد و تعداد چهار مدل را که ورودی های آنها بیشترین میزان همبستگی را با EC داشته‌اند، در قالب مدل ANNa تعریف و بررسی شد و سپس چهار مدل دیگر در قالب ANNb تعریف شد که پارامترهای ورودی آنها را الگوریتم جامعه مورچگان انتخاب کرده بود. نتایج این تحقیق نشان داد با افزایش تعداد ورودی‌ها، عملکرد شبکه عصبی بهبود خواهد یافت، اما تعداد بسیار زیاد ورودی نیز می‌تواند بر عملکرد شبکه تأثیر منفی بگذارد. همچنین، الگوریتم ACO کارایی شبکه را زیاد می‌کند، به گونه‌ای که مقدار MSE از ۰/۰۰۱۷ در مدل ANNb3 به ۰/۰۰۱۲۳ در مدل ANNa2 می‌رسد که کاهش حدود ۲۸ درصدی در مقدار MSE را نشان می‌دهد. نتایج دیگر این تحقیق نشان می‌دهد زمانی که نمی‌توان از آزمون و خطای برای یافتن بهترین پارامترهای ورودی استفاده کرد، بهتر است از پارامترها بهره جست که بیشترین ضریب همبستگی را با پارامتر هدف دارند؛ اما در این صورت نباید تعداد پارامترهای ورودی زیاد باشد. همچنین، استفاده از الگوریتم مورچگان توانست کارایی شبکه را در قسمت صحتسنجی به میزان درخور توجهی زیاد کند و بنابراین الگوریتم مورچگان را می‌توان به عنوان روشی با کارایی مناسب برای انتخاب ورودی‌های شبکه عصبی به حساب آورد.

منابع

- [1]. Khoshnazar A, Nasrabadi T and Abbasmaedeh P. Evaluating the efficiency of artificial neural network in prediction of electrical conductivity of Zarrinehroud river. Journal of Human and Environment. 2013; 10(22):1-16. [Persian]
- [2]. Banejad H, Kamali M, Amirmoradi K and Olyae E. Forecasting some of the qualitative parameters of rivers using wavelet artificial neural network hybrid (w-ann) model (case study: Jajroud river of Tehran and Gharaso river of Kermanshah). Journal of Health and Environment, 2013; 6(3): 277-294. [Persian]
- [3]. Barzegar R, Adamowski J and Asghari Moghaddam A. Application of wavelet-artificial intelligence hybrid models for water quality