

نشریه تحقیقات کاربردی علوم جغرافیایی سال هجدهم، شماره ۵۱، زمستان ۹۷

طراحی شبکه‌های عصبی فیدبک تکاملی با استفاده از الگوریتم بهینه‌سازی عنکبوتی در برآورد بار معلق (مطالعه موردی: حوضه آبخیز سد کارده)

دریافت مقاله: ۹۶/۴/۳ پذیرش نهایی: ۹۷/۳/۲۹

صفحات: ۱۸۳-۱۹۸

معصومه درمانی: دانشجوی دکترای بیابان‌زدایی، دانشکده کویرشناسی، دانشگاه سمنان، ایران^۱.

m_darmany@yahoo.com

محمد نهتانی: استادیار گروه مرتع و آبخیزداری، دانشگاه زابل، ایران.

m.nohtani@uoz.ac.ir

هایده آرا: استادیار گروه مدیریت مناطق خشک، دانشکده کویرشناسی، دانشگاه سمنان، ایران.

ara338@semnan.ac.ir

علی گلکاریان: استادیار گروه مرتع و آبخیزداری، دانشکده منابع طبیعی و محیط زیست، دانشگاه فردوسی مشهد، ایران.

golkarian@um.ac.ir

سلمان شریف آذری، کارشناس ارشد مدیریت منابع آب، ایران.

S.Sharifazari@gmail.com

چکیده

فرآیندهای فرسایش و انتقال رسوب در رودخانه یکی از مهم‌ترین و پیچیده‌ترین موضوعات مهندسی رودخانه می‌باشد. این فرایند اثرات ویژه‌ای روی شاخص‌های کیفی آب، کنش کف بستر و تخریب کناره‌های رودخانه داشته و همچنین خسارت زیادی به طرح‌های عمرانی وارد می‌کند. عدم تداوم نمونه‌برداری و اندازه‌گیری رسوب در بسیاری از ایستگاه‌های موجود و همچنین نبود آمار دقیقی از میزان رسوب در بسیاری از رودخانه‌های کشور از یک سو و اختلاف شرایط آب و هوایی، هیدرولوژیکی و توپوگرافی از سوی دیگر تهیه و واسنجی مدل‌های فرسایش و رسوب در نقاط مختلف را با مشکل مواجه ساخته است و نیاز به سرمایه مالی، زمانی دارد، اما الگوریتم بهینه‌سازی تکاملی قادر به حل این مشکلات نسبت به روش ریاضی و تجربی است. هدف از انجام تحقیق حاضر تعیین بهترین الگوریتم تکاملی است با انتخاب الگوریتم بهینه‌سازی عنکبوت می‌توان دست به آموزش جدید زد و بهترین الگوی تکاملی را برای ایستگاه هیدرومتری و باران سنجی حوضه آبخیز کارده تعیین کرد و کارآیی شبکه پرسپترون و الگوریتم تکاملی حوضه آبخیز سد کارده را در دوره آماری ۲۴ ساله بررسی کرد. در خاتمه نتایج ثابت کرد الگوریتم بهینه‌سازی عنکبوت اجتماعی با ضریب همبستگی برابر با ۰/۹۷ و میانگین قدر مطلق خطا مساوی با ۰/۷۷ نتایج بهتری در پیش‌بینی بارمعلق حوضه آبخیز کارده دارد.

کلیدواژه‌گان: بارمعلق، حوضه آبخیز سد کارده، الگوریتم تکاملی عنکبوت اجتماعی، شبکه MLP.

۱. نویسنده مسئول: سمنان، دانشگاه سمنان، دانشکده کویرشناسی، گروه بیابان‌زدایی، ۰۹۱۵۰۶۷۶۲۸۲.

مقدمه

رسوب‌گذاری یک رفتار مخرب در سطح عرصه‌های طبیعی و رودخانه‌هاست که منجر به از دست رفتن خاک حاصلخیز کشاورزی به صورت کاهش توان تولیدی و تخریب خصوصیات فیزیکی و شیمیایی خاک و اعمال خسارت هنگفت در طرح‌های منابع آب همچون، تغییر و تخریب ابعاد کانال آبیاری می‌شود، از سوی دیگر رسوب انتقال یافته توسط یک رودخانه به مخازن ظرفیت ذخایر آن‌ها را کاهش داده و بر آب قابل استفاده نیروگاه‌های برق و کاربردهای صنعتی و خانگی تأثیر گذار بوده است (تلوری و همکاران، ۱۳۸۶). از این رومتخصصان همواره در جهت تخمین صحیح بارمعلق رودخانه و دقت روش‌های موجود تلاش کردند. تاکنون روابط گوناگون و پیچیده‌ای به منظور پیش‌بینی میزان انتقال رسوب رودخانه و همچنین سرعت و تنش برشی بحرانی ارائه شده است، اما روابط ارائه شده به دلیل عدم شناخت دقیق و نیز پیچیدگی ساز و کار جابجایی رسوبات در بسیاری از موارد با مقادیر اندازه‌گیری شده تطابق نداشته و در مواقعی نیز میزان مقادیر محاسبه شده از روابط گوناگون تفاوت معنی‌داری بایکدیگر دارد، از سوی دیگر بر هزینه بودن آزمایشات مربوط به نمونه‌برداری رسوبات معلق رودخانه‌ها و همچنین عدم واسنجی روابط محاسباتی محققان را وادار به ارائه پیشنهاد در برقراری روابط مختلف رگرسیون خطی یا غیر خطی بین دبی جریان و بارمعلق رودخانه‌ها کرده است (آسلمان^۱ و کرودر^۲، ۲۰۰۲، ۲۰۰۷). در روش‌های تجربی که از آن‌ها با نام روش‌های آماری نیز یاد می‌شود، روابط بین متغیرها خطی فرض می‌گردد و به دلیل تغییرات زمانی امکان بررسی فرآیندهای هیدرولوژیکی، بطوردقیق وجود ندارد. روشی که در تحقیقات اخیر مورد استفاده محققین قرار گرفته، روش شبکه‌های عصب مصنوعی^۳ (ANN) است. این روش که یک مدل غیر خطی است، جهت شبیه‌سازی و پیش‌بینی فرآیندها و متغیرهای هیدرولوژیکی، امروزه به عنوان یک سیستم هوشمند مورد استفاده قرار می‌گیرد (نورانی و همکاران، ۱۳۸۸). شبکه‌های عصبی مصنوعی می‌توانند به عنوان ابزاری کارآمد جهت برآورد و شبیه‌سازی رسوبات مؤثر واقع شوند (شکاری و همکاران، ۱۳۹۲). محققان مختلف بر دقت بالای این روش درمقایسه با روابط تجربی و رگرسیونی تأکید نمودند. استفاده از شبکه‌های عصبی تکاملی (EA)^۴ به طور گسترده‌ای برای حل مسائل بهینه‌سازی پیچیده استفاده شده است. این روش توانایی بالاتری از روش‌های مرسوم دارد (یانگ^۵، ۲۰۱۰) در این الگوریتم عوامل جستجو به کشف ناشناخته‌ها و کیفیت راه حل و جستجوی راه حل بهینه می‌پردازد.

ملسی^۶ و همکاران (۲۰۱۱) مقدار رسوب معلق در رودخانه‌های می‌سی‌سی‌پی می‌سوری و ریوگراند امریکا را به کمک مدل‌سازی شبکه عصب مصنوعی برآورد نمودند. در این تحقیق از داده‌های روزانه و هفتگی بارش، دبی روز مربوطه و رسوب روز قبل جهت پیش‌بینی رسوب معلق روز مربوطه استفاده گردید، مدل شبکه عصبی با نتایج مدل رگرسیون خطی چند متغیره و مدل آریمای مقایسه شد. پیش‌بینی‌های روزانه نسبت به پیش‌بینی

1. Asselman
2. Crowder
3. Artificial Neural Networks
4. Evolutionary algorithm
5. Yang
6. Melesse

های هفتگی برای هر سه رودخانه به دلیل همبستگی بالاتر در داده‌های هفتگی بهتر بود، مقادیر روزانه با استفاده از ANN برای میسوری ($R^2=0.97$) و می‌سی‌سی‌پی ($R^2=0.96$) بهتر از ریوگراند امریکا از $R^2=0.65$ مدل آریمما بود. ولی^۱ و همکاران (۲۰۱۲) برای مدل‌سازی در میزان بارمعلق رودخانه سمندگان^۲ از تکنیک شبکه عصبی استفاده نمودند؛ در این تحقیق با توجه به نوع ورودی‌ها از دو نوع شبکه عصبی استفاده شد. در اولین نوع شبکه، ورودی و خروجی آن‌ها دبی جریان و دبی رسوب لحظه‌ای است و در نوع دوم از پارامترهای ژئومورفیک (توپوگرافی، پوشش گیاهی)، به عنوان ورودی استفاده گردید، نتایج نشان داد شبکه عصبی مصنوعی نوع دوم نتایج بهتری را ارائه می‌دهد. کاکایی^۳ لافدانی و همکاران (۲۰۱۳) به توانایی عملکرد شبکه‌های عصبی مصنوعی در پیش‌بینی بارمعلق رودخانه دویرج^۴ واقع در غرب ایران پرداختند و از ۱۱ سال آمار، شامل دبی جریان و بارش به عنوان ورودی و از دبی رسوب روزانه به عنوان خروجی مدل استفاده کردند، در نهایت با استفاده از شاخص‌های آماری، ریشه میانگین مربعات، ضریب ناش^۵ و ضریب همبستگی مدل شبکه عصبی نتایج قابل قبول‌تری نسبت به رگرسیون داشت. مصطفی و عیسی^۶ (۲۰۱۴)، به تخمین بارمعلق در رودخانه پاری پراک^۷ مالزی پرداختند، بدین منظور از دو روش با RBF^۸ و MLP^۹ استفاده شد. در نهایت مدل شبکه عصبی پرسپترون چندلایه MLP نتایج نزدیک‌تری در برآورد بارمعلق در رودخانه مورد نظر داشت. سمکل و یومین وانگ^{۱۰} (۲۰۱۶) به بررسی دقت عمل شبکه‌های عصبی در برآورد بارمعلق در طی طوفان^{۱۱} و بادهای شدید رودخانه شیون واقع در جنوب تایوان پرداختند. در این روش سرعت تخلیه آب و رسوب در طی ۸ طوفان به صورت دستی جمع آوری و به عنوان ورودی شبکه MLP و سنج رسوب استفاده شد. نتایج حاصل نشان دهنده برتری شبکه عصبی پرسپترون با بالاترین ضریب همبستگی نسبت به منحنی سنج رسوب بود. دستورانی و همکاران (۱۳۹۱)، به برآورد بار معلق حوضه آبخیز جامشیان در استان کرمانشاه با استفاده از شبکه‌های عصبی و منحنی سنج رسوب پرداختند. نتایج نشان داد که شبکه عصبی از دقت بالاتری نسبت به منحنی سنج رسوب برخوردار است. نایینی و همکاران (۱۳۸۷)، در مطالعه‌ای به تخمین غلظت رسوبات معلق از طریق شبکه عصبی در رودخانه‌های می‌سی‌سی‌پی و کلرادو پرداختند، نوع شبکه پیشخور با الگوریتم پس انتشار خطا^{۱۲} (FF BB) بوده که برای آموزش و آزمون شبکه از ورودی‌هایی شامل دبی جریان، قطر متوسط ذرات و شیب کف بستر استفاده شد. نتایج حاصل شبکه عصبی با منحنی سنج مقایسه شد و بیانگر دقت بیشتر شبکه عصبی بود. اگر چه در تمامی تحقیقات مذکور برتری دقت مدل، متکی بر شبکه عصبی نسبت به روابط تجربی

1. Vali
2. Samangan
3. Kakaei
4. Doirag
5. Nash
6. Mustafa and Isa
7. Pari Peraki
8. Radial basis function
9. Multilayer Perceptron
10. Samkel and yumin wang
11. Storm event
12. Feed Forward Back Propagation

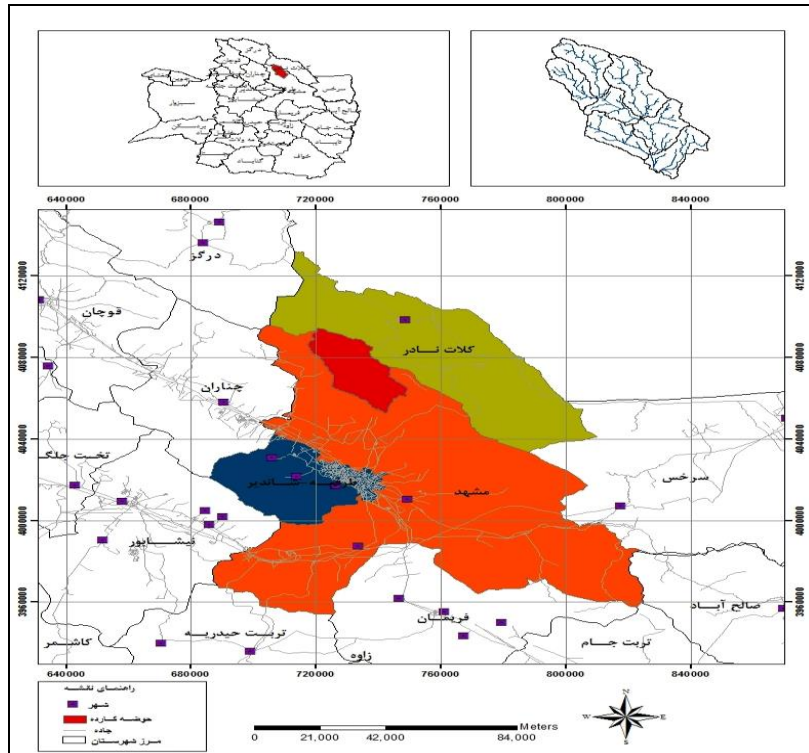
نشان داده شده است، اما نتایج آنچنان که بخواهد با دقت مناسب و با انتظار کاربر به طور موفقیت آمیزی همراه باشد، کاربرد نداشته است. مطالعات کتابخانه‌ای نشان می‌دهد تحقیقات اندکی در خصوص کاربرد الگوریتم اجتماعات عنکبوت در زمینه مهندسی آب صورت گرفته، اما مشابه این الگوریتم به صورت برنامه‌ریزی ژنتیک در این زمینه استفاده شده است.

داننده مهر و همکاران (۱۳۸۹)، به پیش‌بینی بارمعلق رودخانه ليقوان چای واقع در حوضه آبرگیر دریاچه ارومیه برمبنای دبی جریان با برنامه ریزی ژنتیک پرداختند، نتایج حاصل، حاکی از دقت بالای برنامه‌ریزی ژنتیک درمقایسه با شبکه عصبی و کارایی آن در پیش‌بینی بارمعلق رودخانه‌ها می‌باشد. ایتک و کیسیبا^۱ (۲۰۰۸)، مدل‌سازی پدیده حمل رسوب را بر روی دو ایستگاه رودخانه تانگ ابالات مانتانا آمریکا به روش برنامه‌ریزی ژنتیک و مقایسه نتایج حاصله با منحنی سنج رسوب و روش‌های رگرسیونی پرداختند، در این مطالعه روش برنامه‌ریزی ژنتیک به عنوان یک رهیافت مناسب جهت مدل‌سازی رسوبات معلق رودخانه‌ها معرفی شد. لیونگ^۲ و همکاران (۲۰۰۲)، با مدل‌سازی بارش و رواناب با استفاده از روش برنامه‌ریزی ژنتیک بدین نتیجه دست یافتند که پیش‌بینی رفتار بارش-رواناب در حوضه‌های آبریز به کمک برنامه‌ریزی ژنتیک سبب بروز خطای کمتر خواهد شد. هدف از تحقیق حاضر تعیین یک روش مطمئن و سریع بمنظور پیش‌بینی بارمعلق رودخانه‌ها برمبنای الگوریتم بهینه‌سازی عنکبوت می‌باشد. بدین منظور از داده‌های ایستگاه هیدرومتری و باران سنجی سد کارده واقع درخراسان رضوی استفاده شد و دقت نتایج حاصله از الگوریتم تکاملی با نتایج حاصل از کاربرد شبکه عصبی مورد مقایسه قرار گرفت.

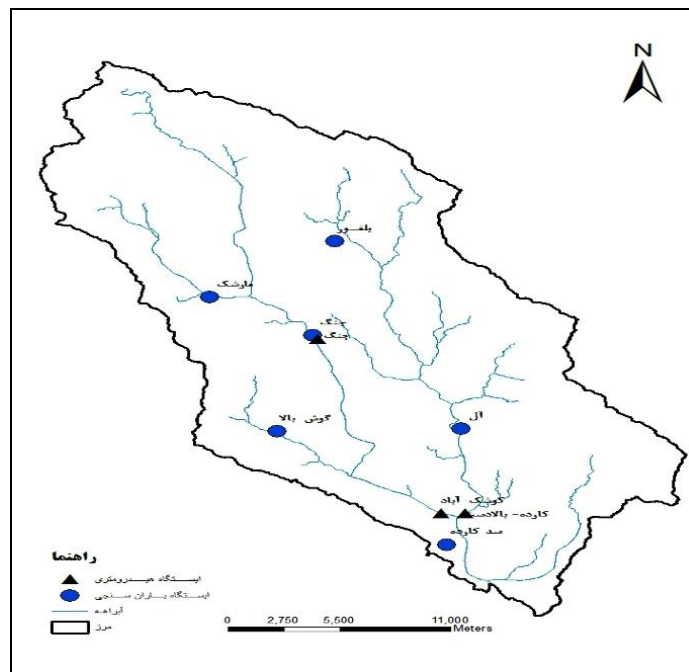
روش تحقیق

حوضه آبخیز سد کارده با مساحت ۵۵۷/۹ کیلومترمربع در شمال شرق شهرستان مشهد در محدوده مختصات جغرافیایی ۵۹ درجه ۲۶ دقیقه و ۳ ثانیه تا ۵۹ درجه ۴۴ دقیقه و ۴۸ ثانیه طول شرقی و ۳۶ درجه ۳۷ دقیقه و ۱۷ ثانیه تا ۳۶ درجه ۵۸ دقیقه و ۲۵ ثانیه عرض شمالی قرار گرفته است. فاصله خروجی حوضه تا شهر مشهد ۴۲ کیلومتر می‌باشد (نادرصفت و سعیدیان، ۱۳۸۹). شکل (۱) موقعیت حوضه آبخیز سد کارده را نشان می‌دهد. شکل (۲) موقعیت ایستگاه هیدرومتری کارده را نشان می‌دهد. حوضه کارده منطقه‌ای کوهستانی با شیب نسبتاً تند می‌باشد. بیشتر سطح حوضه پوشیده از مراتع است که به طور کلی وضعیت این مراتع، متوسط تا ضعیف می‌باشد و مراتع با شرایط خوب را فقط در ارتفاعات می‌توان مشاهده نمود. اقلیم این منطقه براساس روش طبقه‌بندی آمبرژه از نوع نیمه‌خشک سرد می‌باشد

1. Ayték and Kisi
2. Lióng



شکل (۱). موقعیت جغرافیایی سد و حوضه آبخیز کارده (درمانی، ۱۳۹۶)



شکل (۲). موقعیت ایستگاه سد کارده (درمانی، ۱۳۹۷)

روش کار به این صورت است که بعد از اقدامات کتابخانه‌ای و مطالعات دفتری شامل مرور منابع و جمع آوری اطلاعات ایستگاه هیدرومتری و باران سنجی حوضه آبخیز کارده، به استخراج و طبقه‌بندی اطلاعات و مشخص کردن دوره آماری و تعیین کمبودهای اطلاعاتی و آماری اقدام گردید. پس از آن به برآورد رسوب حوضه سد کارده با استفاده از شبکه‌های عصب مصنوعی پرداخته شد. در این روش ابتدا پس از رفع نواقص آماری، داده‌ها به دو سری جهت آموزش و تست تقسیم‌بندی شده، که ۷۵ درصد از داده‌ها جهت آموزش و ۲۵ درصد جهت آزمون شبکه مورد استفاده قرار گرفته است (طهمورث، ۱۳۸۸) سپس برای افزایش سرعت و دقت شبکه، استاندارد کردن داده‌ها با استفاده از رابطه (۱) انجام شد.

رابطه (۱)

$$X_n = \left(\frac{x - x_{\min}}{x - x_{\max}} \right)$$

در آن x داده مشاهده‌ای و X_{\min} , X_{\max} حداقل و حداکثر داده مشاهده شده می‌باشد (کراوس^۱، ۲۰۰۵) پس از نرمال‌سازی و استاندارد کردن داده‌ها نوبت تعیین بهترین مدل برای شبکه عصبی جهت برآورد رسوب بر اساس پارامترهای ورودی شبکه عصبی است، که در این مرحله داده‌های موجود به دو دسته شامل داده‌هایی برای آموزش شبکه، و داده‌هایی برای اعتبار سنجی مدل، تقسیم شده است. نحوه تقسیم‌بندی داده‌ها برای آموزش، آزمون و اعتبار سنجی^۲ بر اساس استفاده از روش تصادفی بوده است (طهمورث، ۱۳۸۸) شبکه عصبی مورد استفاده در این پژوهش شامل شبکه عصبی پرسپترون با کمک الگوریتم بهینه‌سازی عنکبوت اجتماعی می‌باشد.

الگوریتم بهینه‌سازی عنکبوت اجتماعی

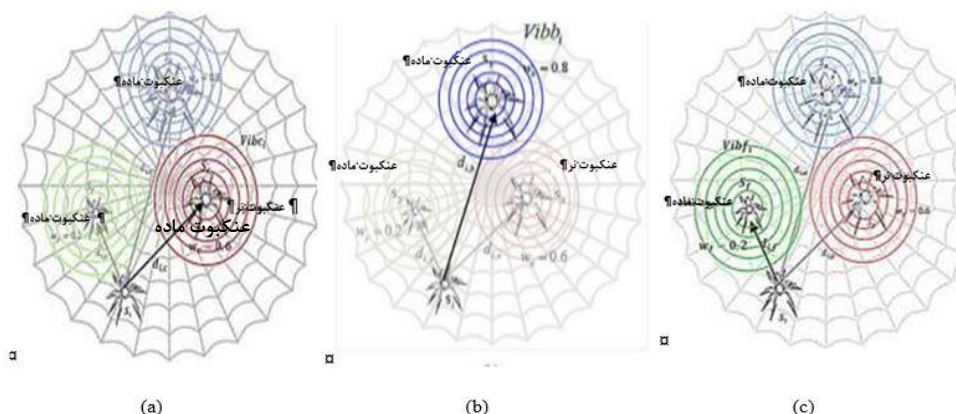
الگوریتم بهینه‌سازی عنکبوت اجتماعی (SSA)^۳ یک روش بهینه‌سازی جدید می‌باشد که در سال ۲۰۱۳ توسط کائوس و همکاران ارائه شده است (کائوس^۴، ۲۰۱۳) عنکبوت یک موضوع تحقیقاتی مهم در مهندسی مصنوعی برای سال‌های بسیاری بوده است. رفتار جستجوگر عنکبوت اجتماعی را می‌توان به عنوان جنبش جمعی عنکبوت‌ها به سمت محل منبع غذایی توصیف کرد. عنکبوت ارتعاشات منتشر شده در شبکه^۵ را برای تعیین جهت بالقوه یک منبع غذایی دریافت و تحلیل می‌کند. از این رفتار طبیعی برای انجام بهینه‌سازی در فضای جستجو به روش SSA استفاده می‌شود. همچنین به عنوان رسانه انتقال ارتعاشات تولید شده توسط عنکبوت عمل می‌کند. هر عنکبوت در وب دارای یک موقعیت و یک برازش^۶ است که نشان دهنده بالقوه یافتن یک منبع غذایی در آن موقعیت می‌باشد. عنکبوت می‌تواند آزادانه در وب حرکت کند، اما وب را نمی‌تواند ترک کند. هنگامی که یک عنکبوت به موقعیت جدیدی حرکت نماید، یک ارتعاش تولید می‌کند که در سراسر وب منتشر می‌شود (کائوس، ۲۰۱۳) اعضای اجتماعی به جنس ماده و جنس نر تقسیم شده است که در آن

1. Krause
2. Cross validation
3. Social Spider Algorithm
4. Cuevas,
5. web
6. Fitness

تعداد جنس ماده بیشتر از جنس نر است، جنس ماده حدود ۹۰ درصد از جمعیت را تشکیل می‌دهد (میرجلیلی، ۲۰۱۵). در طول بهینه‌سازی، عنکبوت با ارتعاش رشته‌ها در وب ارتباط برقرار می‌کند. ارتعاش که یک عنکبوت جنس ماده دریافت می‌کند، با توجه به اندازه عنکبوت و فاصله‌ی عنکبوت‌ها از یکدیگر صرف‌نظر از جنس تعریف شده است. پاسخ جنس ماده به این ارتعاشات بصورت جاذبه یا دافعه است که یا به سمت آن ارتعاش جذب می‌شود و یا از آن دور می‌شود (کائوس، ۲۰۱۳). مدل ریاضی که توسط کائوس و همکاران ارائه شده است در رابطه (۲) آمده است (کائوس و سینگ فائس، ۲۰۱۴).

$$Vibs_i = w_j e^{\frac{d^2}{j,i}} \quad \text{رابطه (۲)}$$

که در آن w وزن عنکبوت‌زام و d فاصله اقلیدسی بین عنکبوت آم-زام است. فرض براین است که عنکبوت جنس ماده قادر به احساس سه ارتعاش از عنکبوت‌ها به شرح ذیل است: نزدیکترین عضو با وزن بالاتر $(Vibc_i)$ - ۲، پیش‌ترین عنکبوت در اجتماع $(Vibb_i)$ - ۳، نزدیکترین عنکبوت نر به عنکبوت ماده که برای آن مناسبتر است $(Vibf_i)$ (کائوس و سینگ فائس، ۲۰۱۴). شکل (۳).



شکل (۳). پیکربندی هر رابطه ویژه: a) Vibbi, b) Vibbi and c) Vibfi

عنکبوت جنس ماده به سمت منشأ ارتعاشات جذب می‌شود و یا از آن دور می‌شود. حرکت جاذبه و یا دافعه بستگی به چند پدیده تصادفی دارد. یک عدد تصادفی ثابت در محدوده $\{0, 1\}$ تولید می‌شود در صورتی که عدد کوچکتر از PF (حد آستانه) باشد جنبش جاذبه و در غیر اینصورت جنبش دافعه است (کائوس، ۲۰۱۳). رابطه (۳).

$$X_i(t+1) = X_i(t) + (\alpha \cdot Vibc_i \cdot (S_c - X_i(t)) + \beta \cdot Vibb_i \cdot (S_b - X_i(t)) + \delta \cdot (r - 0.5)) \quad \text{رابطه (۳)}$$

که در آنها α, β و δ ارزش‌های تصادفی در بازه $\{0 \text{ و } 1\}$ S_c نزدیک‌ترین و بهترین همسایه و S_b عنکبوت پردازش شده می‌باشد. این فرمول زمانی قابل اجرا است که جنس ماده به سمت منشأ ارتعاشات جذب شود. در صورتی- که از منشأ ارتعاشات دور شود از رابطه (۴) استفاده شده است.

$$X_i(t+1) = X_i(t) - (\alpha \cdot \text{Vib}_{c_i} \cdot (S_c - X_i(t)) + \beta \cdot \text{Vib}_{b_i} \cdot (S_b - X_i(t)) + \delta \cdot (r - 0.5)) \quad \text{رابطه (۴)}$$

که در آنها α, β و δ ارزش‌های تصادفی در بازه $\{0 \text{ و } 1\}$ S_c نزدیک‌ترین و بهترین همسایه و S_b عنکبوت پردازش شده می‌باشد. جنس نر به روش‌های مختلف موقعیت خود را بروز رسانی می‌کند (میرجلیلی، ۲۰۱۵). عنکبوت‌ها در ابتدا به دو گروه تقسیم می‌شوند. عنکبوت غالب (N) و مغلوب (ND). عنکبوت (N) یا عنکبوت غالب با وزن بالاتر و تناسب اندام بهتر است و عنکبوت جنس ماده تمایل بیشتری دارد، به سمت ارتعاشات آن جذب شود. در حالی که دیگر عنکبوت تمایل دارد به سمت مرکز جمعیت حرکت کند و به عنوان یک استراژی به استفاده از منابع غذایی که توسط عنکبوت غالب هدر رفته می‌پردازد (کائوس، ۲۰۱۳) این رفتار برگرفته شده از الگوی رفتاری عنکبوت برای پیدا کردن غذا است. بدین ترتیب وزن تمام عنکبوت نر در هر تکرار مشخص می‌شود (میرجلیلی، ۲۰۱۵) موقعیت عنکبوت N از رابطه‌ی (۵) به دست می‌آید و موقعیت عنکبوت ND از رابطه (۶) به دست می‌آید.

$$X_i(t+1) = X_i(t) + (\alpha \cdot \text{Vib}_{f_i} \cdot (S_f - X_i(t)) + \delta \cdot (r - 0.5)) \quad \text{رابطه (۵)}$$

$$X_i(t+1) = X_i(t) + \left(\alpha \frac{\sum_j^N m_j^k \cdot N_f + j}{\sum_j^N N_f} \right) - X_i(t) \quad \text{رابطه (۶)}$$

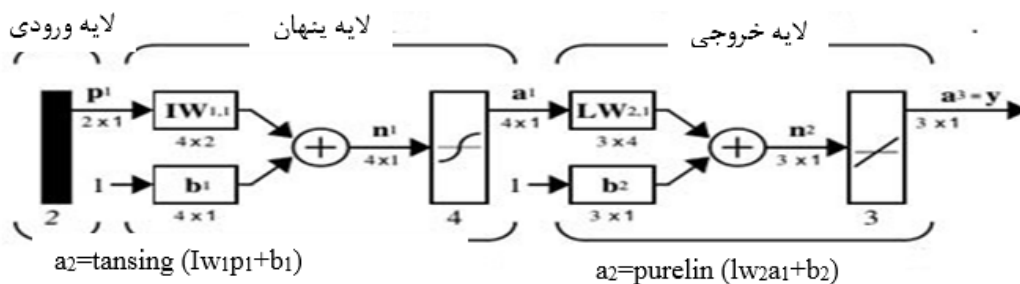
که در آنها S_f نزدیک‌ترین جنس نر و α, β و δ ارزش‌های تصادفی در بازه $\{0 \text{ و } 1\}$ می‌باشند (کائوس و سینگ فانس، ۲۰۱۴). مکانیسم آخر الگوریتم جفت‌گیری است. از این‌رو عنکبوت N در یک شعاع خاص که متشکل از یک یا چند جنس نر و ماده است، شروع به جفت‌گیری می‌کند. بنابراین، یک مکانیسم چرخ‌گردان^۲ به طور تصادفی به انتخاب پدر و مادری متناسب با ارزش‌های خود می‌پردازد. عنکبوت جدید ساخته شده (ترکیبی از ژن‌ها) بر ارزش آن‌ها در مقایسه با بدترین عنکبوت (کمترین وزن و اندام نامناسب) در جامعه محاسبه و مقایسه می‌شود. در صورتیکه عنکبوت جدید بهترین باشد توسط بدترین عنکبوت تولید شده جایگزین می‌شود (میرجلیلی، ۲۰۱۵) کائوس و همکاران الگوریتم SSO را فراهم آوردن که بتوانند نتایج دقیق‌تری را نسبت به الگوریتم ژنتیک و PSO ^۳ داشته باشند. این مشاهدات نیز انگیزه تلاش ما برای ارائه یا آموزش شبکه پس انتشار خطا بر اساس SSA و بررسی عملکرد این الگوریتم در آموزش شبکه عصبی پرسپترون است (کائوس، ۲۰۱۳). در بسیاری از مسائل پیچیده ریاضی که به حل معادلات غیر خطی منجر می‌شود، یک شبکه پرسپترون چند لایه می‌تواند به سادگی با تعریف اوزان و توابع مناسب مورد استفاده قرار گیرد. توابع فعالیت مختلفی به فراخور اسلوب مسئله در نرون‌ها مورد استفاده قرار می‌گیرد. در این نوع شبکه‌ها از یک لایه ورودی جهت اعمال

1 Mirjalili

2 Roulette

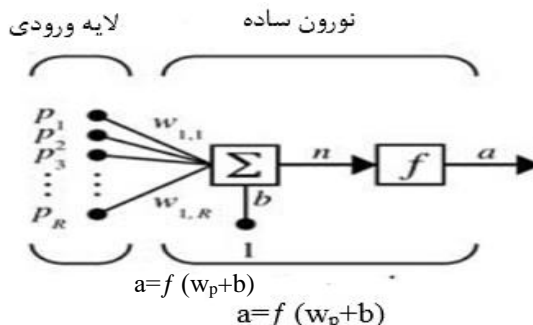
3 particle swarm optimization

ورودی‌های مسئله یک لایه پنهان و یک لایه خروجی که نهایتاً پاسخ‌های مسئله را ارائه می‌نمایند، استفاده می‌شود. گره‌هایی که در لایه ورودی هستند، نرون‌های حسی^۱ و گره‌های لایه خروجی نرون‌های پاسخ دهنده^۲ هستند. در لایه پنهان^۳ نیز نرون‌های پنهان وجود دارند. آموزش این‌گونه شبکه‌ها معمولاً با روش پس انتشار خطا انجام می‌شود. نمونه‌ای از یک شبکه پرسپترون چند لایه در شکل (۴) نمایش داده شده است.



شکل (۴). ساختار پرسپترون چندلایه (ورک^۴، ۱۹۹۲)

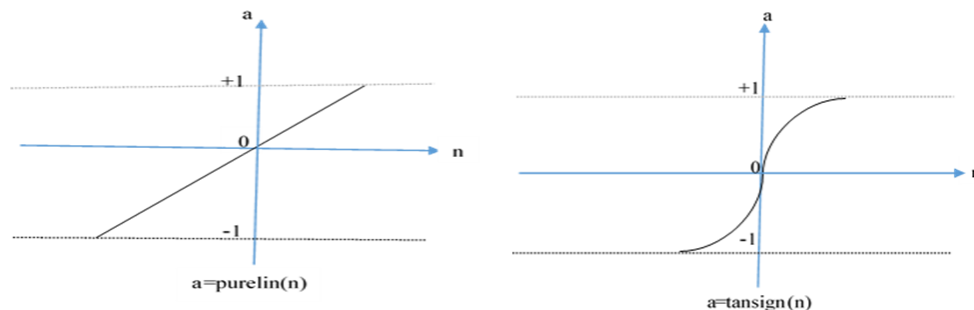
شبکه‌های پرسپترون چند لایه می‌توانند با هر تعداد لایه ساخته و به کار گرفته شوند، یک شبکه پرسپترون سه لایه قادر است هر نوع فضایی را تفکیک کند. این قضیه که قضیه کولموگوروف^۵ نامیده می‌شود، بیانگر مفهوم بسیار مهمی است که می‌توان در ساخت شبکه‌های عصبی از آن استفاده کرد (البرزی، ۱۳۸۳). یک نرون ساده با R ورودی در شکل (۵) نشان داده شده است.



شکل (۵). یک نرون ساده با R ورودی (کیا، ۱۳۹۱)

در شبکه‌های چند لایه اغلب از تابع انتقال logsig استفاده می‌شود. این تابع به ازای ورودی دریافتی در بازه (± 1) (نهایت) خروجی بین ۰ و ۱ تولید می‌کند. گاهی اوقات از تابع انتقال tansig در شبکه‌های چندلایه استفاده می‌گردد. در بعضی موارد نیز از تابع انتقال خطی و توابع محرک دیگر در شبکه‌های BP استفاده می‌شود (کیا، ۱۳۹۱: ۴۰۸). شکل (۶).

1 Sensory
2 Responding
3 Hidden
4 Work
5 Kolmogorov Theorem



شکل (۶). انواع تابع محرک شبکه‌های پس انتشار

معمولا از ابزار اعتبارسنجی متقاطع برای برآورد خوبی مشخصه‌ها و پیش‌بینی و انتخاب مدل مناسب داده‌ها استفاده می‌شود. خطای پیش‌بینی را می‌توان از اختلاف مقادیر پیش‌بینی با مقادیر اصلی بررسی و مدل‌های آماری مورد نظر را به وسیله‌ی این خطا ارزیابی کرد. در صورتی‌که پیش‌بینی کننده خوب عمل کند، تفاوت بین این دو مقدار باید ناچیز باشد (استون^۱، ۱۹۷۴). در این پژوهش از داده‌های دبی جریان، و بارش به عنوان ورودی شبکه و از دبی رسوب برای محاسبه خروجی شبکه استفاده گردید، همچنین مدل با استفاده از یک دسته سری داده‌ها آموزش می‌بیند و با استفاده از اطلاعات حاصل از داده‌ها وزن‌های شبکه تعیین می‌شود (امجدی^۲، ۲۰۰۲). سپس داده‌های حاصل به شبکه رگرسیون چند متغیره وارد شدند و براساس شاخص‌های آماری رابطه (۶ و ۷) ضریب همبستگی (R^2)، میانگین مربعات خطا (RMSE)، مورد تجزیه و تحلیل قرار گرفتند.

$$R^2 = \frac{\sum ((X_{est} - \bar{X}_{est}) \times (X_{obs} - \bar{X}_{obs}))}{\sqrt{\sum ((X_{est} - \bar{X}_{est}))^2 \times \sum ((X_{obs} - \bar{X}_{obs}))^2}} \quad \text{رابطه (۶)}$$

$$RMSE = \sqrt{\sum \frac{(X_{obs} - X_{est})^2}{n}} \quad \text{رابطه (۷)}$$

که در آن‌ها X_{obs} مقادیر اندازه گیری شده، X_{est} مقادیر برآوردی حاصل از شبکه عصبی، X_{obs} میانگین مقادیر مشاهده‌ای X_{est} میانگین مقادیر برآوردی و n تعداد نمونه‌هاست.

نتایج

به منظور تعیین بهترین الگوریتم تکاملی و نورون بهینه در شبکه عصبی پرسپترون دو پارامتر ورودی دبی و بارش را به عنوان ورودی و بعد از آموزش شبکه در نهایت مدل بهینه انتخاب شده است. در این تحقیق از ۱۶۲ داده از سال‌های آماری (۱۳۶۵-۱۳۹۱) شامل دبی و بارش روزانه و رسوب متناطر با دبی و بارش از ایستگاه سد کارده استفاده شد. هدف از انتخاب آن به چالش کشیدن شبکه پیشنهادی و مشاهده عملکرد آن‌هاست، که متناسب با داده‌ها، وزن و تعداد گره‌های موجود در لایه پنهان افزایش یا کاهش می‌یابد. برای تأیید اطلاعات

¹Stone

² Amjadi

خروجی‌های حاصل از شبکه عصبی و الگوریتم بهینه مورد مقایسه قرار گرفتند و این الگوریتم به عنوان بهترین نماینده از الگوریتم تکاملی با استفاده از شاخص‌های آماری انتخاب شد. مقادیر حاصل از الگوریتم SSO در جدول (۴) و مقادیر حاصل از شبکه عصبی MLP در جدول (۳) است. برای تعیین بهترین نتایج هر الگوریتم تکاملی بیش از ۱۰ بار به منظور کاهش خطای مدلسازی و آموزش بهتر شبکه اجرا شد و شبکه عصبی پرسپترون به منظور تعیین نورون بهینه و آموزش شبکه بیش از ۱۰۰۰ بار تکرار شد، و در هر تکرار RMSE شاخص ناش و ضریب تعیین به عنوان معیارهای مقایسه انتخاب شد. معیارهای دیگر در انتخاب بهترین مدل در سیستم اندازه‌گیری صحت طبقه‌بندی است. این معیار به ما بخوبی نشان می‌دهد که چگونه یک الگوریتم در ارائه نتایج دقیق است. صحت طبقه‌بندی با ورودی دبی و بارش در جدول (۴) به ترتیب ۰/۸۶ و ۰/۷۷ محاسبه شده است که نشان می‌دهد، مدل در پیش‌بینی و طبقه‌بندی داده‌ها برای آموزش شبکه با ورودی دبی ۸۶ درصد و با ورودی بارش ۷۷ درصد موفق عمل کرده است.

در جدول (۱) میزان حداکثر بارش و دبی لحظه‌ای و حداکثر و میانگین رسوب واقعی را در ۱۶۲ داده آماری نشان می‌دهد. میانگین رسوب و حداکثر رسوب برآورده شده در جدول (۲) ارائه شده است، بیانگر این است که مدل MLP-SSO نتایج نزدیک‌تری را به داده‌های مشاهده‌ای ارائه می‌دهد. از طرفی رسم رگرسیون و مقایسه خط یک به یک نشان داده است که اریب مدل MLP از مدل MLP-SSO بیشتر می‌باشد. در نتیجه شبکه عنکبوت نتایج موفق‌تری را در برآورد رسوب معلق نشان داده است. در جدول (۲) حداکثر رسوب برآورد شده با مدل MLP-SSO، ۴۳۷۸۵/۹۲ به حداکثر رسوب واقعی ۴۳۷۸۴ نزدیکتر است. همچنین در جدول (۳ و ۴) مدل‌ها با دو ورودی بارش و دبی بررسی شدند، نتایج در هر دو مدل حاکی از آن است مدل با ورودی دبی نتایج بهتری را نسبت به بارش ارائه می‌دهد. در نتیجه ورودی دبی به عنوان بهترین پارامتر اندازه‌گیری بارمعلق در حوضه آبخیز است. در دو ورودی بارش و دبی که نتایج خروجی آن در جدول (۲ و ۳) آمده است نشان داده، مدل MLP-SSO با RMSE برابر با ۷۷۰ و ضریب همبستگی ۰/۹۷ با ورودی دبی نتایج بهتری را برآورد کرده است. از آنجایی که RMSE و R^2 به تنهایی نمی‌تواند پراکندگی حاصل از خروجی شبکه را با مقادیر واقعی نشان دهد، به منظور بهتر کالیبره کردن مدل از خط یک به یک استفاده شده است (شکل ۸) که بین خروجی حاصل از شبکه و داده‌های واقعی خط یک به یک ترسیم شد. این خط نشان دهنده پراکنش داده‌ها در اطراف خط یک به یک است و هرچه داده‌ها در اطراف خط یک به یک بیشتر پراکنده شوند نشان دهنده دقت مدل (نا اریب بودن) است و هرچه داده‌ها از اطراف خط یک به یک دورتر باشند نشان می‌دهد که مدل نسبت به داده‌های واقعی بیش برآورد یا کم برآورد بوده است، به این طریق که اگر داده‌ها در زیر خط یک به یک متمرکز شوند نشان دهنده کم برآورد بودن مدل (خروجی مدل کمتر از داده‌های واقعی) و اگر در بالای خط متمرکز شوند نشان دهنده بیش برآورد بودن مدل (خروجی مدل بیشتر از داده‌های واقعی) می‌باشد. شکل (۹) نشان می‌دهد که بیشتر داده‌ها در اطراف خط یک به یک متمرکز شده‌اند و این نشان دهنده این است که مدل در برآورد بار معلق موفق بوده است.

جدول (۱). داده‌های مشاهده‌ای (۱۳۶۵-۱۳۹۱)

الگو	حداکثر بارش (mm)	حداکثر دبی پیک لحظه‌ای (m ³ /s)	حداکثر دبی روزانه	حداکثر رسوب واقعی (Ton/day)	میانگین رسوب واقعی (Ton/day)
داده‌های مشاهده‌ای	۱۲	*۲۹	۱۵	۴۳۷۸۴	۴۸۵/۰۴

جدول (۲). نتایج مدل‌سازی MLP, MLP SSO

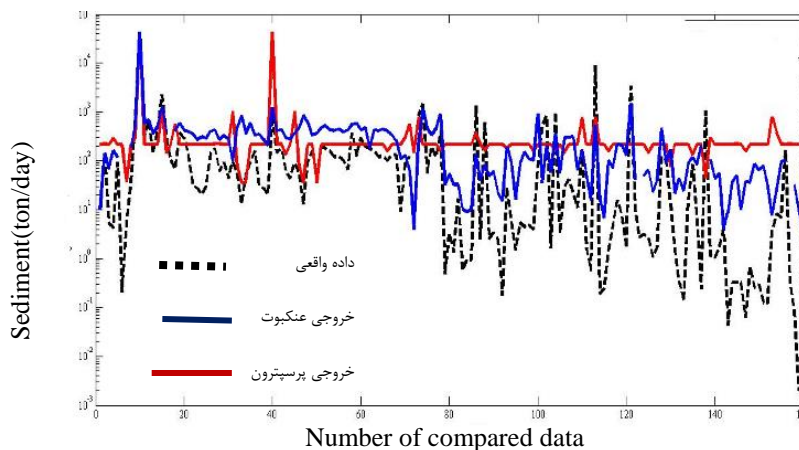
نوع الگو	میانگین رسوب برآورد شده (Ton/day)	حداکثر رسوب برآورد شده (Ton/day)
MLP	۵۲۳/۹	۴۳۵۵۸
*MLP-SSO	۴۶۴/۰۴	۴۳۷۸۵/۹۲

جدول (۳). نتایج حاصل از شبکه عصب مصنوعی پرسپترون بیش از ۱۰۰ تکرار


ورودی	RMSE آموزش	RMSE تست	R آموزش	R کل	نورون بهینه	تابع
*دبی (مترمکعب بر ثانیه)	۷۳۴۰	۷۷۰۹/۰۳	۰/۸۲	۰/۹۷	۱۲	purline
بارش (میلیمتر)	۳۴۶۵/۸	۱۰۲۳۵/۶۴	۰/۶۹	۰/۶۹	۹	tansing

جدول (۴). نتایج آماری الگوریتم تکاملی عنکبوت بیش از ۱۰ تکرار

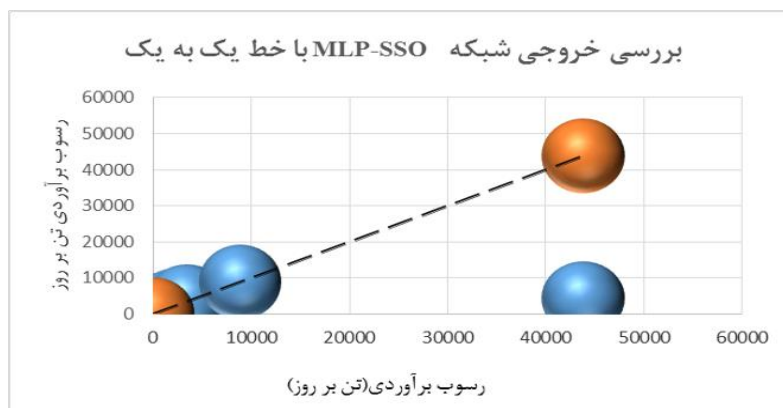
ورودی	RMSE آموزش	RMSE تست	R آموزش	R کل	صحت طبقه بندی
*دبی (مترمکعب بر ثانیه)	۷۲۵	۷۷۰	۰/۸۷	۰/۹۷	۰/۸۶
بارش (میلیمتر)	۳۳۰۲	۱۰۲۱۰	۰/۷۹	۰/۸۰	۰/۷۳



شکل (۷). مقایسه شبیه سازی دو مدل MLP-SSA با MLP (ورودی بارش)



شکل (۸). مقایسه شبیه سازی دو مدل MLP-SSA با MLP (ورودی دبی)



شکل (۹). مقایسه شبیه‌سازی دو مدل MLP-SSA با خط یک به یک ($y=x$)

نتیجه‌گیری

نتایج حاصل از الگوریتم عنکبوت با نتایج مدل MLP مقایسه شد. نتایج نشان داد که روش یادگیری الگوریتم عنکبوت با توجه قابلیت بالای این الگوریتم بسیار مؤثر بوده است. همچنین مشاهده شد نتایج حاصل از MLP-SSA از نقطه نظر صحت طبقه‌بندی نیز دارای دقت بسیار بالا بوده است. زمانیکه صحت طبقه‌بندی ۸۶ درصد است، یعنی ۱۴ درصد از داده‌ها درست طبقه بندی نشده‌اند. از دیگر قابلیت‌های این مدل این است که با کمترین تکرار بهترین نتایج را در زمان کمتر نسبت به روش MLP که در ۱۰۰۰ تکرار بهینه شد، به دست آورد. از مزیت این روش حساس نبودن آن به وجود تعداد معدودی خطا در داده‌های آماری است و در زمان کوتاه‌تر و تکرار کمتر نتایج بهتری را برآورد می‌کند. از مهم‌ترین معایب روش‌های مختلف برآورد رسوب این است که هنوز رابطه‌های جهانی که قادر باشد در تمام حالات و شرایط بخوبی پاسخگو باشد وجود ندارد اما این مدل به‌علت داشتن قابلیت انعطاف بسیار بالا و با ایجاد روابط و توابع غیر خطی توانسته تا حدودی بر این مشکل غالب شود.

در شکل (۸) دو مدل مذکور مقایسه شده‌اند که نشان می‌دهد اختلاف کمتری بین داده‌های مشاهده‌ای و الگوریتم عنکبوت نسبت به مدل پرسپترون بوده است، این نمودار با ورودی دبی، نشان می‌دهد الگوریتم عنکبوت با ورودی دبی نسبت به ورودی بارش نتایج بهتری را ارائه می‌دهد. بنابراین دبی به عنوان مؤثرترین ورودی در رسوب منطقه است. در شکل (۷) اختلاف زیادی بین داده‌های مشاهده‌ای و شبکه پرسپترون نسبت به الگوریتم عنکبوت وجود دارد که تایید کننده نتایج شکل (۸) است با این تفاوت که اختلاف‌ها بیشتر از ورودی بارش نسبت به دبی نشان می‌دهد بارش به تنهایی نمی‌تواند فاکتور خوبی برای برآورد رسوب باشد. با توجه همبستگی بالای دبی و بارش با خروجی (دبی رسوب) این دو پارامتر به عنوان ورودی شبکه انتخاب شده است. در پروژه حاضر دبی جریان، به عنوان تأثیر گذارترین عامل در رسوب معلق معرفی شد. برای صحت نتیجه، دو مدل را با ورودی‌های مختلف بررسی کرده (بارش و دبی) که در نهایت، مشخص شد در هر دو شبکه Mlp و Mlp-SSo با ورودی دبی میزان ریشه میانگین مربعات خطا کمترین مقدار را و بالاترین ضریب همبستگی را نسبت به دیگر مدل‌ها دارد، این نتیجه در روش SSO با ضریب همبستگی بالاتر نیز قابل تأیید است. لذا روش اندازه‌گیری بارمعلق رسوب برپایه اندازه‌گیری رسوب معلق و دبی جریان روش مطمئنی است که مستلزم اندازه‌گیری پیوسته می‌باشد (پاونلی و بیگی، ۲۰۰۴). از آنجایی که پارامترهای آماری پراکندگی مدل را به خوبی نشان نمی‌دهند بهتر است از خط یک به یک هم به منظور پراکندگی داده‌ها و کالیبره کردن مدل استفاده نمود. بر خلاف شبکه پرسپترون که در برآورد دبی پیک ناموفق عمل کرده است شبکه MLP با قابلیت انعطاف‌پذیری بالا در برآورد دبی حداکثر نتایج موفق‌آمیزتری داشته است. گویا به دبی حداکثر وزن کمتری را اختصاص می‌دهد.

منابع

- تلوری، عبدالرسول؛ بیرودیان، نادر، منوچهری، اسماعیل، (۱۳۸۶)، مدل‌سازی تغییرات زمانی رسوب مطالعه موردی حوضه آبخیز گاران در کردستان، فصل‌نامه علمی سازندگی در منابع طبیعی، ۲۰ (۲): ۶۴-۷۰.
- نورانی، وحید؛ اعلمی، محمد تقی؛ خیاوی، خسرو نظام، ابوالواسط؛ نعیمه، صالحی، کامران، (۱۳۸۸)، معرفی مدلی برای تخمین بار معلق رسوب با استفاده از منطق فازی و مقایسه آن با روش‌های کلاسیک و شبکه عصبی، هشتمین کنگره بین‌المللی مهندسی عمران، ۲۱-۲۳ اردیبهشت، دانشگاه شیراز، ایران.
- شکاری، محمد رضا؛ ساداتی نژاد، جواد؛ ولی، عباس علی؛ قاسمیه، هدی؛ قضاوی، رضا، (۱۳۹۲)، کاربرد دو روش شبکه عصبی مصنوعی MLP، RBF در برآورد رسوبات بادی (مطالعه موردی: دشت کرسیا داراب). فصل‌نامه علمی پژوهشی، پژوهش‌های فرسایش محیطی، ۳ (۱۲): ۱-۱۶.
- دستورانی، محمد تقی؛ عظیمی فشی، خسرو؛ طالبی علی؛ اختصاصی، محمد رضا، (۱۳۹۱)، برآورد بارمعلق با استفاده از شبکه‌های عصبی، پژوهش‌نامه مدیریت حوضه آبخیز، ۳ (۶): ۶۱-۷۴.
- نایینی، سید تقی؛ منتظری نمین، مسعود؛ زمانی، محسن؛ سلطانی، فواد، (۱۳۸۷)، تحلیل حساسیت توابع محرک مدل شبکه عصبی مصنوعی در تخمین غلظت رسوبات معلق، چهارمین کنگره ملی مهندسی عمران، ۱۷-۱۹ اردیبهشت، دانشگاه تهران، ۸ صفحه.
- داننده‌مهر، علی؛ علیایی، احسان؛ قربانی، محمدعلی، (۱۳۸۹)، پیش‌بینی بارمعلق رودخانه‌ها بر مبنای دبی جریان با استفاده از برنامه‌ریزی ژنتیک، پژوهش آبخیزداری، ۲۳ (۳): ۴۵-۵۴.
- نادرصفت، محمدحسین؛ سعیدیان، فرشید، (۱۳۸۹)، مطالعه روند سیل خیزی در حوضه‌های آبخیز از طریق بررسی تراوایی و پتانسیل ایجاد رواناب در سازندهای زمین‌شناسی کارده، فصل‌نامه علمی پژوهشی جغرافیا، ۴ (۱۲): ۶۴-۱۹۸.
- طهمورث، محمد؛ احمدی، حسن؛ تقوی، نفیسه و عسگری، محمدحسین، (۱۳۸۸)، مقایسه دقت مدل شبکه‌های عصبی مصنوعی ژئومورفولوژی GANNs و رگرسیون RM در برآورد رسوب طالقان‌رود. پژوهش‌های آبخیزداری، ۳ (۲۲): ۱۹-۲۷.
- صالحی سده، رضا، (۱۳۸۳)، کاربرد شبکه عصبی مصنوعی در پیش‌بینی جریان رودخانه، پایان‌نامه کارشناسی ارشد، عمران آب، دانشکده مهندسی دانشگاه فردوسی مشهد.
- البرزی، محمود، (۱۳۸۸)، آشنایی با شبکه عصبی (ترجمه). چاپ دوم، تهران: موسسه انتشارات علمی دانشگاه صنعتی شریف. ۲۲۰ صفحه.
- کیا، مصطفی (۱۳۹۱). شبکه‌های عصبی در متلب (ترجمه). چاپ دوم، تهران، انتشارات خدمات نشرکیان، صفحه ۴۰۸.

Asselman, N. E. M. (2000), **Fitting and interpretation of sediment rating curves**. Journal of Hydrology, 234 (6): 228-248

Crowder, D. W., Demissie, M and Markus. M. (2007), **the accuracy of sediment loads when log-transformation produce nonlinear sediment load-discharge relationships**. Journal of Hydrology. 336, (12): 250-268

- Yang, X. S. (2010), **Nature-inspired metaheuristic algorithms**. Luniver Press, Beckington. **Second edithon**. University of Cam Bridge, United Kingdom, pp 75.
- Melesse, A. M., Ahmad, S., McClain, M. E., Wang, X and Lim, Y.H. (2011). **Suspended sediment load prediction of river systems: An artificial neural network approach**. Agricultural Water Management, 98 (5): 855- 866.
- Vali, V.V., Ramesht, M.H., Seif, A and Ghazavi, R(2012). **An assessment of the Artificial Neural Networks technique to geomorphologic modeling sediment yield (Case study Samandegan river system)**, Geography and Environmental Planning Journal, 44 (4): 5-9.
- Kakaei Lafdani, E., Moghaddam Nia, A., Ahmadi, A(2013). **Daily suspended sediment load prediction using artificial neural networks and support vector machines**, **Journal of Hydrology**, 478 (26): 50-62
- Mustafa, M.R and Isa, M.H. (2014). **Comparative Study of MLP and RBF Neural Networks for Estimation of Suspended Sediments in Pari River, Perak**, Research Journal of Applied Sciences, Engineering and Technology, 7 (18): 3837-3841.
- Samkele s., tf wala and yu- min wang(2016). Estimating Sediment Disharge using sediment Rating curves and Artifical Neursl Networks in the shiwen River ,Taiwan water, 18 (2): 1-15
- Aytek, A and Kisi, O. (2008). **A genetic programming approach to suspended sediment modeling**. J, Hydrol, 351 (18): 288-298
- Liong, S.Y., Gautam, T.R., Khu, S.T., Babovic, V., Keijzer, M and Muttill, N. (2002). **Genetic programming, A new paradigm in rainfall runoff modeling**, Journal of Water Research, 18 (3): 705-718
- Krause, P., Boyle, D.P. and. Base, F. (2005). **Comparison of different efficiency criteria for hydrological model assessment**. Advances in Geosciences, 5 (12): 89- 97
- Mirjalili, Z., Saremi, SH., Mirjalili, M. (2015). **Designing evolutionary feedforward neural networks using social spider optimization algorithm**, Neural Comput & Applic .PP 123.DOI 10.1007/s00521-015-1847-6
- Cuevas E, Cienfuegos M., Zaldivar D., Perez-Cisneros M (2013). **A swarm optimization algorithm inspired in the behavior of the social-spider**. Expert Syst Appl , 40 (16): 6374–6384.
- Cuevas E., Cienfuegos, M (2014). **A new algorithm inspired in the behavior of the social-spider for constrained optimization**. Exp Syst Appl: Int J. 41 (2): 412–425.
- Stone, M(1974). **Cross-Validity Choice and Assessment of Statistical Predictions**. Journal of the Royal Statistical Society. 36 : 111-133.
- Amjadi, N. (2002). **Introducing intelligence systems**. Semnan University press, pp 300.
- Pavanelli, D and Bigi, A. (2004). **Suspended sediment concentration for three apennine monitored basins**, particle size distribution and physical parameters, In The Agro Environment Congress, Venice, Italy, PP.537-544.