



"مقاله پژوهشی"

ارزیابی تاثیر تبدیلات لگاریتمی و توابع هدف بر میزان کارائی مدل‌های شبکه عصبی در برآورد بار رسوب معلق (مطالعه موردی: حوزه آبخیز سراب قره‌سو، رودخانه قوری چای)

محمودرضا طباطبائی^۱ و سید احمد حسینی^۲

۱- دانشیار پژوهشی پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران، (نویسنده مسوول: taba1345@hotmail.com)

۲- استادیار پژوهشی پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

تاریخ ارسال: ۹۹/۰۱/۱۰ تاریخ پذیرش: ۹۹/۰۲/۰۸

صفحه: ۱۳۳ تا ۱۴۶

چکیده مبسوط

مقدمه و هدف: برآورد صحیح بار رسوب معلق رودخانه‌ها، نقش مهمی در مسائل مربوط به مدیریت منابع آب، آبخیزداری و علوم وابسته دارد. با توجه به دامنه وسیع تغییرات رسوب معلق در فصول مختلف سال و همچنین ماهیت به شدت غیرخطی و پیچیده آن، لازم است از روش‌هایی مناسب که می‌توانند چنین پدیده‌هایی را شبیه‌سازی و برآورد نمایند، استفاده شود.

مواد و روش‌ها: از تبدیل لگاریتمی داده‌ها و الگوریتم بهینه‌سازی ازدحام ذرات چند هدفه (MOPSO)، در آموزش بهینه مدل‌های شبکه عصبی استفاده شد. بدین منظور در ابتدا، با کمک شبکه عصبی بدون ناظر (SOM)، داده‌های دبی جریان و دبی رسوب معلق ایستگاه هیدرومتری مورد مطالعه (دوره آماری ۱۳۹۵-۱۳۶۴) خوشه‌بندی و سپس با نمونه‌گیری از خوشه‌ها، مجموعه داده‌های مورد نیاز برای آموزش و آزمون مدل‌های شبکه عصبی تهیه گردید. پس از آن، به منظور ارزیابی تاثیر به کارگیری تبدیلات لگاریتمی و الگوریتم بهینه‌سازی MOPSO، سه سناریو تعریف شد. در سناریوی اول، داده‌های اولیه (بدون تبدیل لگاریتمی) و الگوریتم گرادین مینا رایج در آموزش مدل‌های شبکه عصبی (پس انتشار خطا)، در سناریوی دوم، الگوریتم پس انتشار خطا و تبدیلات لگاریتمی و در سناریوی سوم، از تبدیلات لگاریتمی و الگوریتم MOPSO، در آموزش مدل‌های شبکه عصبی استفاده گردید.

یافته‌ها: ارزیابی و مقایسه نتایج صحت سنجی مدل‌ها نشان داد که به کارگیری تبدیلات لگاریتمی و الگوریتم MOPSO، با کاهش خطای RMSE و درصد اریبی (PBIAS) از ۴۹ تن در روز و ۲۱- درصد، در بهترین مدل از سناریو اول، به ۳/۳ تن در روز و ۳/۶- درصد، در بهترین مدل از سناریو سوم، کارائی مدل‌ها را افزایش داده است. از دیگر نتایج پژوهش، عدم برآورد ارقام منفی برای رسوب معلق بوده که یکی از خطاهای رایج در استفاده از مدل‌های شبکه عصبی در برآورد رسوب معلق است.

نتیجه‌گیری: استفاده از توابع هدف چندگانه، امکان حساس نمودن مدل‌ها به برآورد دقیق‌تر رسوب معلق در جریان‌های کم یا زیاد را فراهم نموده سبب می‌شوند، شاخص‌های صحت‌سنجی و اریبی مدل‌های داده مینا بهبود یابند.

واژه‌های کلیدی: بهینه‌سازی چند هدفه ازدحام ذرات، تابع هدف، رسوب معلق، رودخانه قوری چای

مقدمه

برآورد صحیح بار رسوب معلق^۱ رودخانه‌ها، نقش مهمی در مسائل مربوط به مدیریت منابع آب، آبخیزداری و علوم وابسته دارد. با توجه به دامنه وسیع تغییرات رسوب معلق در فصول مختلف سال و همچنین ماهیت به شدت غیرخطی و پیچیده آن، لازم است از روش‌هایی مناسب که می‌توانند چنین پدیده‌هایی را شبیه‌سازی و برآورد نمایند، استفاده شود. در این رابطه در سال‌های اخیر، استفاده از مدل‌های هوشمند نظیر مدل‌های شبکه عصبی مصنوعی، نروفازی، برنامه‌ریزی بیان ژن، الگوریتم‌های تکاملی و نظایر آن، بسیار رایج شده است که در ادامه به برخی از آن‌ها اشاره می‌شود. کاکائی لمدانی و همکاران (۲۳)، توانائی مدل‌های شبکه عصبی، ماشین بردار پشتیبان و منحنی سنجه‌ی رسوب در برآورد رسوب معلق روزانه رودخانه دویرج واقع در غرب ایران را مورد بررسی قرار دادند. آن‌ها از داده‌های بارش و دبی جریان به‌عنوان ورودی، و از دبی رسوب به‌عنوان خروجی، استفاده نمودند. بهترین ورودی‌ها برای هر دو مدل شبکه عصبی و ماشین بردار پشتیبان، با استفاده از الگوریتم ژنتیک و آزمون گاما تعیین گردید. نتایج، حاکی از برتری مدل‌های هوشمند در برآورد رسوب روزانه نسبت به مدل رگرسیونی منحنی سنجه‌ی رسوب بود. کیسی و ازکان (۲۶) به‌منظور مدل‌سازی رسوب معلق در رودخانه‌ی ایل^۲ در کالیفرنیا، داده‌های دو ایستگاه در سال‌های ۱۹۶۶ تا ۱۹۷۷ را مورد بررسی قرار

دادند. در مطالعه‌ی انجام‌شده، چهار روش رگرسیونی خطی وزن دار، روش ماشین بردار پشتیبان، شبکه‌ی عصبی مصنوعی و منحنی سنجه‌ی رسوب مورد بررسی و مقایسه قرار گرفت. نتایج نشان داد که مدل شبکه‌ی عصبی مصنوعی در مقایسه با سایر مدل‌ها، برآورد بهتری از رسوب معلق داشته است. جوشی و همکاران (۲۲) بیان کردند که غلظت رسوب معلق با ویژگی‌های هیدرولوژیکی حوزه آبخیز رابطه غیرخطی داشته لذا، استفاده از روش‌های سنتی منحنی سنجه‌ی رسوب نمی‌تواند برآورد صحیحی از غلظت رسوب معلق داشته باشد. در نتیجه از روش‌های مبتنی بر شبکه‌ی عصبی مصنوعی، برای مدل‌سازی رسوب استفاده کردند. چپانگ و همکاران (۱۰) در حوزه آبخیز گودوین کریک^۳ در آمریکا، برای برآورد بار رسوب معلق، از شبکه عصبی مصنوعی، ماشین بردار پشتیبان و مدل رگرسیونی استفاده نمودند. در این پژوهش، از دبی جریان به‌عنوان داده ورودی، و از بار رسوب معلق به عنوان داده خروجی در مدل‌سازی استفاده گردید. نتایج تحقیق نشان داد که کارایی مدل‌های هوشمند بهتر از مدل رگرسیونی بوده است. سایر مطالعات و پژوهش‌های دیگر در این زمینه نیز نشان می‌دهند که کارائی مدل‌های هوشمند در برآورد رسوب معلق، بیشتر از روش‌های رگرسیونی می‌باشد (۴۵،۳۷،۱۶،۶،۹).

علیرغم کارائی مدل‌های شبکه عصبی مصنوعی در شبیه‌سازی و برآورد متغیرهای هیدرولوژیکی، استفاده از این

1- Suspended Sediment Load

2- Eel

3- Goodwin Creek

مربعات خطا^۷ (SSE)، میانگین مربعات خطا^۸ (MSE)، ریشه میانگین مربعات خطا^۹ (RMSE)، شاخص کارایی ناش-ساتکلایف^{۱۰} (NSE) و نظایر آن، که از مربعات خطا استفاده می‌نمایند، سبب حساس نمودن مدل‌ها به مقادیر بالای یک متغیر (مثلاً حداکثر جریان) شده و در مقابل، تابع میانگین قدر مطلق خطا^{۱۱} (MAE)، نسبت به مقادیر زیاد جریان حساسیت کمتری داشته و در نتیجه عملکرد مدل را یکنواخت‌تر می‌نماید (۳۴، ۲۹، ۱۲). در مجموع، دقت واسنجی چند هدفه می‌تواند با استفاده از انتخاب یک تابع هدف از هر گروه بهبود یابد (۳۴، ۴۲).

یکی دیگر از روش‌های مناسب در آموزش بهتر مدل‌های شبکه عصبی، استفاده از تبدیلات داده توسط توابع لگاریتمی است. در این ارتباط، چنانچه تفاوت مقادیر بیشینه و کمینه داده‌ها زیاد باشد و تنها از استانداردسازی داده‌ها به‌منظور پیش پردازش داده‌ها استفاده شود، نتیجه آن، آموزش ضعیف این گونه مدل‌ها خواهد بود. در چنین شرایطی، تبدیلات لگاریتمی داده قبل از استانداردسازی آن‌ها توصیه می‌شود (۲۱، ۴۴). لازم به‌ذکر است که نظیر چنین حالتی، اغلب در داده‌های رسوب‌سنجی ایستگاه‌های هیدرومتری کشور که دارای چولگی بالا نیز هستند رخ می‌دهد. در پژوهش‌هایی که لاک و همکاران (۳۱) و آکیل و همکاران (۴) به‌ترتیب برای شبیه‌سازی و پیش‌بینی بارش و رواناب انجام دادند، از تبدیلات لگاریتمی داده‌ها، به‌منظور آموزش بهتر مدل‌های هوشمند استفاده نمودند که موجب افزایش دقت نتایج گردید. با توجه به پژوهش‌های انجام‌شده، هدف از پژوهش حاضر، بررسی تاثیر تبدیلات لگاریتمی و به‌کارگیری توابع هدف مختلف در آموزش مدل‌های شبکه عصبی و مقایسه و ارزیابی نتایج آن‌ها، در برآورد بار رسوب معلق رودخانه قوری‌چای، در محل ایستگاه هیدرومتری کوزه توپراقی می‌باشد.

مواد و روش‌ها

منطقه مورد مطالعه و داده‌های مورد استفاده

پژوهش حاضر در حوزه آبخیز سراب قره‌سو در استان اردبیل، بر روی رودخانه قوری‌چای و در محل ایستگاه هیدرومتری کوزه توپراقی انجام شده است (شکل ۱).

مدل‌های هوشمند نیز با چالش‌هایی روبرو است که از آن جمله می‌توان به تعیین بهینه تعداد نرون‌ها و لایه‌ها، مقادیر بهینه وزن و بایاس و نوع توابع فعال‌سازی اشاره نمود که واسنجی مناسب آن‌ها به روش آزمون و خطا، ضمن کارایی کم، منجر به صرف زمان زیاد می‌شود. در این رابطه با توجه به آنکه در بهینه‌سازی پارامترهای شبکه عصبی، الگوریتم‌های تکاملی (نظیر الگوریتم ژنتیک، PSO^۱) می‌توانند راه‌حل‌های مناسبی را ارائه نموده و توابع هدف مختلفی را در آن‌ها به‌کار گرفت لذا، در بهینه‌سازی آموزش مدل‌های شبکه عصبی از این توانمندی می‌توان استفاده نمود. در این رابطه، گو و ونگ (۱۸) بار رسوب معلق رودخانه زرد^۲ را با استفاده از شبکه عصبی تابع پایه شعاعی^۳ که پارامترهای آن توسط الگوریتم PSO بهینه شده بود شبیه‌سازی نمودند. کیسی و همکاران (۲۷) به‌منظور شبیه‌سازی کیفیت آب زیرزمینی (SO₄ و SAR)، از الگوریتم‌های تکاملی PSO و DE^۴ برای آموزش و بهینه‌سازی پارامترهای مدل‌های شبکه عصبی (به‌ترتیب مدل‌های ANN-PSO و ANN-DE) استفاده نمودند. در پژوهشی دیگر، ایتهاج و بنکدار (۱۵) از الگوریتم‌های PSO و رقابت استعماری^۵ (ICA) در برآورد عدد فرود^۶ استفاده کردند. نتایج نشان داد که الگوریتم ICA، نتایج بهتری داشته است. آلتونکیناک (۲) به‌منظور برآورد رسوب معلق رودخانه می‌سی‌سی‌پی ضرایب مدل منحنی سنج رسوب را با کمک الگوریتم ژنتیک بهینه‌سازی نمود. نتایج ارزیابی مدل‌ها (مدل منحنی سنج مرسوم و بهینه‌شده با الگوریتم ژنتیک) نشان داد که مدل بهینه‌شده با الگوریتم ژنتیک از کارایی بیشتری برخوردار است. طباطبائی و همکاران (۴۳) نیز از الگوریتم PSO تک هدفه به‌منظور بهینه‌سازی آموزش مدل‌های شبکه عصبی در برآورد رسوب معلق رودخانه نیرچای استان اردبیل استفاده نمودند. نتایج حاصله نشان داد که کارائی مدل‌های هیبریدی شبکه عصبی و الگوریتم PSO، بیشتر از مدل‌های مرسوم شبکه عصبی است.

تعداد و نوع توابع هدف به‌کار رفته در واسنجی یا آموزش مدل‌های داده‌منا (رگرسیون یا هوشمند) نیز نقش مهمی در کارائی و عملکرد آن‌ها در شبیه‌سازی و برآورد متغیرهای مورد مطالعه دارد (۳۲). در این ارتباط، توابع هدفی نظیر مجموع

1- Particle Swarm Optimization
4- Differential Evolution
7- Sum of Square Error (SSE)
10- Nash-Sutcliffe Efficiency (NSE)

2- Yangtze River
5- Imperialist Competitive Algorithm (ICA)
8- Mean Square Error (MSE)
11- Mean Absolute Error (MAE)

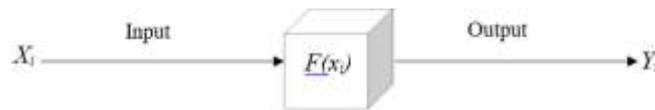
3- Radial Basis Function (RBF)
6- Froude Number
9- Root Mean Square Error (RMSE)

است. به منظور اطلاع بیشتر در تهیه داده‌های همگن و مشابه به مراجع ۴۰، ۴۱، ۴۲ و ۴۳ مراجعه گردد.

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی^۳، از سیستم عصبی مغز انسان الهام گرفته و قادر به پردازش اطلاعات هستند. مدل‌های ANNs می‌توانند به عنوان مدل جعبه سیاه در نظر گرفته شوند که با دادن یک ورودی، یک خروجی تولید می‌کنند (۴۴) (شکل ۲).

(۳۳). در این راستا، تعیین تعداد خوشه‌های بهینه، توسط شاخص ارزیابی دیویس-بولدین^۱ انجام گرفته است (۲۸). به منظور تحلیل نتایج آماری حاصل از خوشه‌بندی داده‌ها در سه مجموعه آموزش، ارزیابی متقاطع و آزمون، علاوه بر مقایسه پارامترهای آماری (میانگین، انحراف معیار، چولگی و...) از آزمون ناپارامتری دو نمونه‌ای کلموگروف-اسمیرنوف^۲ برای بررسی یکسان بودن توزیع داده‌های دو مجموعه استفاده شده

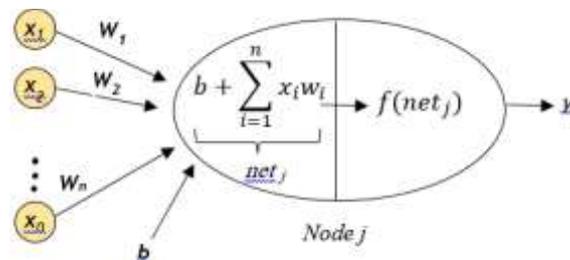


شکل ۲- مدل جعبه سیاه (تيفور (۴۴))
Figure 2. Black box model (Tayfur (44))

۳- هر اتصال، وزنی داشته که نشان‌دهنده نیروی آن اتصال است.

۴- هر گره، مجموع وزنی سیگنال‌های ورودی را با به کار بردن یک تبدیل غیرخطی که تابع محرک^۷ نامیده می‌شود، به سیگنال خروجی تبدیل می‌نماید (۳، ۴۸).

شکل ۳، ساختار یک نرون فرضی (Node j) را نشان می‌دهد. متغیرهای ورودی (x_i)، وزن‌ها (w_i)، بایاس (b) و f تابع تحریک (فعال‌سازی) نرون می‌باشد. در این نرون، مجموع سیگنال‌های ورودی (net_j) به داخل تابع فعال‌سازی یا تابع محرک (f) نرون ارسال شده، توسط آن تابع، به یک مقدار خروجی (y) نگاشت^۸ می‌شود.



شکل ۳- ساختار یک نرون فرضی (تيفور (۴۴))
Figure 3. The structure of a hypothetical neuron (Tayfur (44))

معلق استفاده شده است که در آن نرون‌ها به صورت موازی و در کنار هم، عمل می‌کنند (شکل ۴).

در این پژوهش، از شبکه عصبی مصنوعی با ناظر (پرسترون چندلایه رو به جلو^۹) برای شبیه‌سازی رسوب

1- Davies-Bouldin Index

2- Two-Sample Kolmogorov-Smirnov Test (KS)

3- Artificial Neural Networks (ANNs)

4- Node

5- Neuron

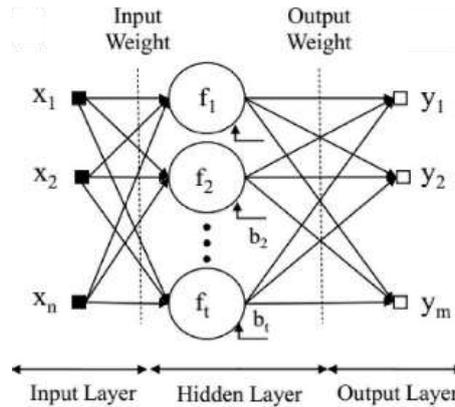
6- Links

7- Activation Function

8- Net Information

9- Map

10- Feed Forward Multi-Layer Perceptron (FFMLP)



شکل ۴- شکل کلی شبکه‌های عصبی مصنوعی پیش‌رو (تایفور (۴۴))
Figure 4. The general form of feed forward artificial neural networks (Tayfur (44))

آموزش مدل شبکه عصبی با استفاده از الگوریتم بهینه‌سازی چند هدفه MOPSO^۳

در پژوهش حاضر، به منظور آموزش مدل‌های شبکه عصبی، افزون بر الگوریتم پس انتشار خطا، از الگوریتم بهینه‌سازی ازدحام ذرات چند هدفه (MOPSO)، برای بهینه‌سازی متغیرهای مدل‌های شبکه عصبی (بردار وزن‌ها و بایاس‌ها) استفاده شده است. در این ارتباط در ادامه، مفاهیم بهینه‌سازی چند هدفه و الگوریتم MOPSO به اختصار بیان می‌شود. به منظور درک بهتر این الگوریتم لازم به ذکر مجدد است که، منظور از توابع هدف، توابع اندازه‌گیری مقدار خطا (نظیر RMSE، MAE و...) مورد استفاده در فرآیند آموزش و پاسخ یا راه‌حل یا ذره، بردار وزن‌ها و بایاس‌های مدل شبکه عصبی است. همچنین منظور از شایستگی یک راه‌حل، مقدار محاسبه شده تابع هدف در صورت به‌کارگیری آن راه‌حل در شبکه عصبی است. مسائل بهینه‌سازی از نظر تعدد توابع هدف و معیارهای بهینه‌سازی به دو دسته تک هدف و چند هدفه تقسیم می‌شوند. در مسائل بهینه‌سازی تک هدفه، هدف از حل مسئله، تنها بهبود یک شاخص عملکرد است که مقدار کمینه یا بیشینه آن، کیفیت پاسخ به دست‌آمده را به‌طور کامل منعکس می‌کند. اما در برخی موارد نمی‌توان صرفاً با اتکا به یک شاخص، پاسخ مناسبی را برای مسئله بهینه‌سازی به دست آورد. در این نوع مسائل لازم است که مقادیر چندین تابع هدف یا شاخص عملکرد و به‌طور هم‌زمان، بهینه گردند که به این روش بهینه‌سازی، بهینه‌سازی چندهدفه اطلاق می‌شود (۳۹). در چنین شرایطی، یافتن پاسخی که تمام اهداف را بهینه سازد تقریباً غیرممکن است و لذا باید تلاش گردد تا مجموعه‌ای از راه‌حل‌ها (مجموعه پارتو یا جبهه پارتو) با مطلوبیت نسبی^۴ برای همه اهداف تعیین شود (۱۳، ۴۶). به این ترتیب، در مجموعه بهینه پارتو، هیچ یک از راه‌حل‌ها بر دیگری غالب نیستند (راه‌حل‌های نامغلوب) و حرکت از یک نقطه (پاسخ یا راه‌حل) به نقطه دیگر، یک تابع هدف را بهتر نموده و تابع هدف دیگر را بدتر می‌نماید (۴۷). اغلب الگوریتم‌های بهینه‌سازی چندهدفه، از مفهوم غلبه در جستجو و جو راه حل‌ها استفاده می‌کنند. فرض نمائید F ، کل فضای

شبکه‌های عصبی چندلایه، از یک لایه ورودی (در ارتباط با داده‌های ورودی)، یک یا چندلایه پنهان (جهت سازمان‌دهی نرون‌ها) و یک لایه خروجی (در رابطه با داده خروجی) تشکیل می‌شوند. در این نوع از شبکه‌های عصبی، جهت جریان داده، از لایه ورودی به سمت لایه پنهان و از لایه پنهان به سمت لایه خروجی بوده و از این نظر به آن‌ها شبکه‌های عصبی روبه‌جلو یا پیش‌خور گفته می‌شود. به منظور آموزش شبکه عصبی، مقدار خطا در جهت بیش‌ترین شیب تابع خطا محاسبه شده و این مقدار، به لایه‌های قبل (لایه یا لایه‌های پنهان) فرستاده شده تا با تنظیم مجدد مقادیر وزن نرون‌ها، مقدار خطا را کاهش دهند (قانون دلتا) رابطه‌ی ۱ (۴۴):

$$w_{ij}^{new} = w_{ij}^{old} - \eta \frac{\partial E}{\partial w_{ij}} \quad (1)$$

که در آن: w_{ij}^{new} و w_{ij}^{old} به ترتیب وزن بین نرون‌های i و j قبل و بعد از یک تکرار معین، η نرخ یادگیری و E تابع خطا است.

آموزش شبکه و کاهش خطا تا ایجاد همگرایی در شبکه ادامه می‌یابد. شبکه‌های عصبی می‌توانند دارای چندین لایه پنهان باشند با این وجود، تحقیقات انجام‌شده نشان می‌دهد که شبکه‌های عصبی پیش‌خور، با دارا بودن یک لایه پنهان، قادر به تقریب‌زدن هر نوع تابع غیرخطی می‌باشند (۲۰). در این پژوهش، از یک شبکه عصبی پرسپترون سه لایه (یک لایه ورودی، یک لایه پنهان و یک لایه خروجی) استفاده شده و تعداد بهینه نرون‌ها با سعی و خطا تعیین گردید. به منظور آموزش شبکه عصبی از روش لوبنبرگ مارکواردت^۱ (LM) به دلیل کارایی و همگرایی سریع‌تر در آموزش شبکه و اثبات کارآمدی آن در تخمین رسوب رودخانه‌ای (۲۵) استفاده گردید. توابع فعال‌سازی در نرون‌های لایه پنهان و لایه خروجی، به ترتیب سیگنویید^۲ یا تانژانت هایپربولیک^۳ و خطی در نظر گرفته شد. در پژوهش حاضر در آموزش مدل‌های شبکه عصبی، از داده‌های دبی جریان (Q_w) به‌عنوان متغیر ورودی (تخمین‌گر مدل) و از بار رسوب معلق (Q_s) به‌عنوان متغیر خروجی استفاده شده است.

1- Levenberg-Marquardt Algorithm (LM)

4- Multi-Objective Particle Swarm Optimization

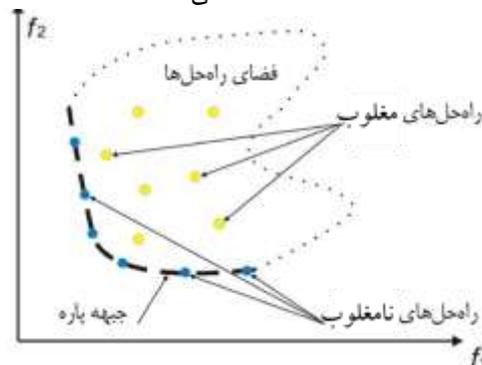
2- Sigmoid (Sig)

5- Pareto Front

3- Hyperbolic Tangent (TanSig)

6- Pareto Optimal Set

روش‌های فراوانی تاکنون برای حل مسائل بهینه‌سازی چندهدفه ارائه شده است که در حالت کلی می‌توان آن‌ها را به دو دسته الف) روش‌های کلاسیک، که اغلب مسأله چند هدفه را به یک مسأله یک هدفه تقلیل می‌دهند و ب) روش‌های تکاملی، که مسأله بهینه‌سازی چندهدفه را به صورت چندهدفه و هم‌زمان حل می‌نمایند، طبقه‌بندی نمود. روش اخیر (ب)، مبنای محاسبه و ارزیابی الگوریتم بهینه‌سازی MOPSO است. به منظور آشنائی با این الگوریتم، ابتدا لازم است الگوریتم بهینه‌سازی ازدحام ذرات تک‌هدفه PSO معرفی گردد. الگوریتم PSO، یکی از روش‌های بهینه‌سازی تکاملی و تکنیک جستجو است، اولین بار توسط کندی و ابراهام در سال ۱۹۹۵ میلادی معرفی گردید (۲۴). شکل ۵، مفهوم جبهه پارتو و راه‌حل‌های نامغلوب و مغلوب را در یک مسئله بهینه‌سازی دو هدفه از نوع کمینه‌سازی نشان می‌دهد.



شکل ۵- مفهوم جبهه پارتو و راه‌حل‌های نامغلوب و مغلوب در یک مسئله بهینه‌سازی دو هدفه از نوع کمینه‌سازی (ترجمه شده از دلوگوسز (۱۴))

Figure 5. Concept of Pareto front and dominated and non-dominated solutions in a two-objective minimization problem (Translated from Dlugosz (14))

در تدوین این روش، از حرکات جمعی و گروهی پرندگان و یا ماهی‌ها (به آن‌ها ذرات هم گفته می‌شود) در رسیدن به غذا الگوبرداری شده است. این روش، یکی از روش‌های موثر در هوش ازدحامی یا هوش گروهی^۱ به حساب می‌آید. پرندگان تنها با تنظیم حرکت فیزیکی خود و با اجتناب از تصادم به دنبال غذا می‌گردند. در این الگوریتم، هر پرنده به عنوان یکی از اعضای گروه از تجربه قبلی خود و یافته‌های سایر اعضا برای یافتن غذا بهره می‌برد. این روش مشارکت و تسهیم اطلاعات بین اعضای گروه، یک از مزیت‌های اصلی این الگوریتم نسبت به جستجوی رقابتی است. الگوریتم PSO، با یک گروه از جواب‌های تصادفی (راه‌حل‌ها) شروع به کار می‌کند، سپس برای یافتن جواب بهینه، با به‌روزر کردن موقعیت و سرعت هر ذره، به جستجو در فضای مسئله می‌پردازد. هر ذره به صورت چندبعدی (بسته به طبیعت مسئله) با دو مقدار V_{id} و X_{id} که به ترتیب معرف مکان و سرعت مربوط به بعد d ام از n امین ذره هستند، تعریف می‌شود. در هر مرحله از حرکت جمعیت، هر ذره با توجه به دو مقدار بهترین، به روز می‌شود. اولین مقدار بهترین، بهترین موقعیت خود ذره است که تا به حال آن را تجربه نموده است (مقدار تابع هدف یا شایستگی ذره در این موقعیت کمترین است). این مقدار،

بهترین فردی^۲ است و $pbest$ نامیده می‌شود. مقدار بهترین دیگری که توسط PSO به دست می‌آید، بهترین موقعیتی است که توسط جمعیت ذرات به دست آمده است. این مقدار، بهترین کلی^۳ است و $gbest$ نام دارد. پس از یافتن دو مقدار $pbest$ و $gbest$ ، هر ذره، سرعت و مکان جدید خود را با استفاده از روابط ۳ و ۴ به روز می‌کند (۲۴):

$$V_i(t+1) = \omega V_i(t) + C_1 * rand_1(pbest_i(t) - x_i(t)) + C_2 * rand_2(gbest_i(t) - x_i(t))$$

$$x_i(t+1) = x_i(t) + V_i(t+1) \quad (۴)$$

در روابط فوق:

$gbest$ ، نشان‌دهنده بهترین موقعیتی است که توسط جمعیت ذرات به دست آمده و $pbest$ بهترین موقعیت خود ذره است که تا به حال آن را تجربه نموده است، t ، نمایانگر تعداد تکرار، c ، ثابت شتاب و $rand1$ و $rand2$ اعدادی تصادفی در بازه $[0, 1]$ می‌باشند. ضرایب $C1$ و $C2$ ، به ترتیب پارامتر شناختی (تجربه شخصی) و پارامتر اجتماعی (تجربه جمعی) بوده و شیب حرکت در جستجوی محلی را مشخص می‌نمایند. مقدار این دو ضریب در بازه $[0, 2]$ تعیین می‌گردد. ضریب ω ،

جدید جایگزین ذره قبلی می‌شود. gbest نیز در هر تکرار، از بین پاسخ‌های غالب موجود در مخزن انتخاب می‌گردد. به‌طور خلاصه، ترتیب اجرای الگوریتم MOPSO به‌شرح زیر است (۳۶):

- ۱- تعیین مؤلفه‌های لازم برای اجرای الگوریتم MOPSO.
- ۲- جمعیت اولیه ایجاد می‌شود. ۳- بهترین تجربه شخصی هر ذره تعیین می‌شود. ۴- اعضای نامغلوب جمعیت جداسازی و در مخزن ذخیره می‌شوند. ۵- هر ذره از میان اعضای مخزن یک رهبر را انتخاب می‌کند و حرکت خود را انجام می‌دهد. ۶- بهترین تجربه‌ی شخصی هر کدام از ذرات به‌روز می‌شوند. ۷- اعضای نامغلوب جدید به مخزن افزوده می‌شوند. ۸- اعضای مغلوب مخزن حذف می‌شوند. ۹- در صورتی که شرایط خاتمه محقق نشده باشد، الگوریتم از شماره ۵ به بعد تکرار می‌شود.

در پایان عملیات بهینه‌سازی توسط الگوریتم MOPSO، جواب‌هایی تولید می‌شوند که می‌توان متناسب با شرایط تصمیم‌گیری مسئله، یکی از آن‌ها را انتخاب نمود. برخی از پارامترهای بکار رفته در الگوریتم MOPSO در پژوهش حاضر به‌همراه مقادیر پیش‌فرض آن‌ها، در جدول ۲ ذکر شده است:

جدول ۲- پارامترهای الگوریتم MOPSO

پارامتر	تعداد ذرات	تعداد تکرار	C1	C2	ω	تعداد ذرات مخزن
مقدار	۳۰	۷۰۰	۱/۵	۲/۵	۰/۹	۲۰

خوشه‌بندی داده‌ها نیز از رابطه ۹ برای استاندارد نمودن داده‌ها استفاده گردید.

$$z = 0.1 + (0.8 * \frac{X_i - X_{imin}}{X_{imax} - X_{imin}}) \quad (9)$$

$$z = \left(\frac{1.8(X_i - X_{imin})}{X_{imax} - X_{imin}} \right) - 0.9 \quad (10)$$

در این روابط، Z ، متغیر استاندارد شده، X_i ، متغیر اولیه، X_{imax} و X_{imin} به ترتیب مقادیر کمینه و بیشینه متغیر X_i می‌باشند.

شایان ذکر است که چنانچه اختلاف مقادیر حداقل و حداکثر یک متغیر زیاد باشد، لازم است قبل از استانداردسازی داده‌ها، از تبدیلات لگاریتمی به‌منظور مقیاس نمودن داده‌ها استفاده نمود (۴۴) (رابطه ۱۱):

$$Q_w \quad Q_s \rightarrow Z \begin{cases} Z_w \\ Z_s \end{cases} \quad (11)$$

که در آن، Q_s و Q_w بترتیب داده‌های دبی جریان و دبی رسوب معلق و Z_s و Z_w مقادیر مقیاس شده با استفاده از تابع لگاریتمی (پایه ۱۰) می‌باشد.

داده‌های مقیاس شده سپس می‌توانند استاندارد گردند. در این رابطه، به‌دلیل چولگی زیاد داده‌های رسوب‌سنجی ایستگاه مورد مطالعه، داده‌ها در ابتدا تبدیل مقیاس شده سپس با توجه به نوع تابع محرک شبکه‌های عصبی استاندارد شدند.

ضریب اینرسی بوده که به‌صورت خطی کاهش یافته و معمولاً در بازه [۰، ۱] تعریف می‌گردد.

حرکت ذرات در این الگوریتم، تا زمانی که شروط معین شده برای خاتمه حرکت محقق نشده باشد ادامه می‌یابد. این شروط می‌تواند رسیدن به حد قابل قبولی از مقدار خطا، تعداد نسل، زمان و... باشد.

الگوریتم چندهدفه MOPSO توسط کونلو در سال ۲۰۰۴ و بر مبنای تولید جواب پارتوئی توسعه یافته است (۱۱). در مقایسه با الگوریتم PSO، در این الگوریتم، ویژگی جدیدی به نام مخزن^۱ اضافه شده است که اعضای آن، راه‌حل‌های نامغلوب مسئله و بیانگر جبهه‌ی پارتو می‌باشند. هنگامی که ذرات (راه‌حل‌ها) حرکتی را انجام می‌دهند، یک عضو از مخزن را به‌عنوان رهبر انتخاب می‌کنند. در الگوریتم MOPSO انتخاب pbest و gbest بر اساس مکانیزم خاصی انتخاب می‌شود. در این روش، pbest تنها زمانی بروز می‌شود که ذره جدید مقدار قبلی آن را مغلوب کند. به‌عبارت دیگر در هنگام بروز رسانی، چنانچه ذره جدید یافت‌شده، بر بهترین مکان قبلی ذره غالب شود این ذره جایگزین pbest آن ذره می‌گردد. بر عکس، اگر ذره جدید مغلوب شود هیچ بروز رسانی در مورد pbest انجام نمی‌شود. چنانچه هیچ یک از ذره‌ها غالب نشوند، به‌صورت تصادفی و با احتمال مساوی ذره

همچنین در بهینه‌سازی چندهدفه مدل‌های شبکه عصبی، از دو تابع هدف با انتخاب یک تابع هدف از گروه الف (توابع MSE یا RMSE، برای تأکید بر رسوبات معلق بالا) و یک تابع هدف از گروه ب (توابع MAE یا LOGE، برای تأکید بر رسوبات معلق پائین) استفاده شده است، رابطه‌های ۵ تا ۸:

$$MSE = \frac{1}{N} \times \sum_{j=1}^N (O_j - S_j)^2 \quad (5)$$

$$RMSE = \sqrt{\frac{1}{N} \times \sum_{j=1}^N (O_j - S_j)^2} \quad (6)$$

$$MAE = \frac{\sum_{j=1}^N |O_j - S_j|}{N} \quad (7)$$

$$LOGE = \sqrt{\frac{1}{N} \times \sum_{j=1}^N (\log(\frac{O_j}{S_j}))^2} \quad (8)$$

در رابطه‌های فوق، O_j و S_j به ترتیب دبی رسوب معلق مشاهده‌ای و برآورد شده (تن در روز) و N ، تعداد داده‌های معرفی شده به مدل (داده‌های بخش آموزش) می‌باشند.

استاندارد سازی داده‌ها و تبدیلات لگاریتمی

در آموزش مدل‌های شبکه عصبی مصنوعی و یا در استفاده از توابع فاصله در عملیات خوشه‌بندی، لازم است از داده‌های بی‌بعد شده، استفاده شود (۴۴). در پژوهش حاضر، از رابطه‌های ۹ و ۱۰ برای استاندارد نمودن داده‌ها در بازه‌های [۰/۱-۰/۹] و [۰/۹-۰/۹] به ترتیب برای استفاده در توابع محرک (فعال‌سازی) سیگموئید و تانژانت هایپربولیک به‌کار رفته در مدل‌های شبکه عصبی، استفاده شده است. در عملیات

سناریوهای مدل‌سازی

در پژوهش حاضر، الگوریتم‌های لونیگ مارکواردت (LM) و MOPSO، به‌منظور آموزش مدل‌های شبکه عصبی و توابع سیگموئید (Sig) و تانژانت هایپربولیک (TanSig)، به‌عنوان توابع فعال‌سازی آن‌ها مورد استفاده قرار گرفته است. همچنین از تبدیلات لگاریتمی، در پیش پردازش داده‌ها (قبل از استانداردسازی داده‌ها) استفاده شده است تا تاثیرات به کارگیری یا عدم به‌کارگیری آن در افزایش یا کاهش صحت

جدول ۳- اسامی مدل‌های شبکه عصبی

Table 3. Names of Neural Network Models

نام مدل	الگوریتم آموزش	تابع فعال‌سازی	تبدیلات لگاریتمی
سناریو ۱			
ANN-LM-Sig	LM	Sig	-
ANN-LM-Tan	LM	TanSig	-
سناریو ۲			
ANN-LM-Sig-Log	LM	Sig	✓
ANN-LM-Tan-Log	LM	TanSig	✓
سناریو ۳			
ANN-MOPSO-Sig-Log	MOPSO	Sig	✓
ANN-MOPSO-Tan-Log	MOPSO	TanSig	✓

نتایج و بحث

نتایج خوشه‌بندی و تحلیل آماری داده‌ها

با استفاده از خوشه‌بندی SOM و محاسبه شاخص دیویس-بولدین، تعداد بهینه خوشه‌ها برای مجموعه داده‌های تحت مطالعه ایستگاه هیدرومتری کوزه‌توپراقی تعداد ۱۲ عدد محاسبه گردید (شکل ۶).

نتایج پارامترهای آماری (معیارهای مرکزیت و پراکندگی داده‌ها) و نتایج مربوط به مقایسه توزیع داده‌ها (نتایج آزمون KS) در سه مجموعه داده‌های آموزش، اعتبارسنجی متقاطع و آزمون برای ایستگاه هیدرومتری کوزه‌توپراقی در جدول ۴ و ۵ آمده است. همانطور که در جدول ۴ و ۵ نشان داده شده است، سعی گردیده تا با کمک خوشه‌بندی و نمونه‌گیری از داده‌ها، متغیرهای دبی جریان و رسوب معلق در سه مجموعه داده، هم به لحاظ خلاصه آماری و هم از نظر توزیع فراوانی، حتی المقدور شبیه به هم باشند. در جدول ۵، حرف h، آماره آزمون KS در نرم‌افزار MATLAB بوده و زمانی که $h=0$ ، به این معنی است که فرضیه نول^۴ رد نشده (تائید فرض H_0 آزمون) و در سطح خطای یک درصد^۵ (سطح اطمینان ۹۹ درصد) توزیع داده‌ها در هر دو مجموعه، یکسان و مشابه می‌باشند.

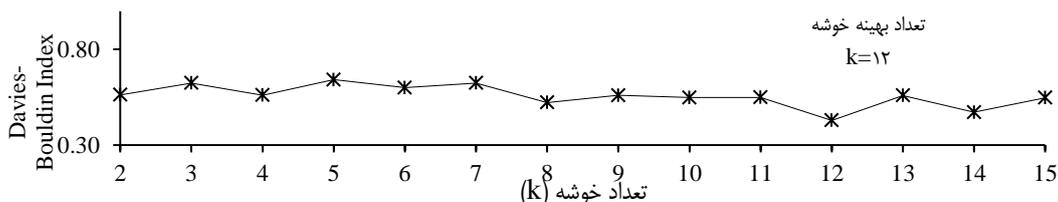
صحت‌سنجی و ارزیابی مدل‌ها

به‌منظور صحت‌سنجی و مقایسه نتایج حاصل از مدل‌های مختلف شبکه عصبی، علاوه بر رابطه‌های ۶ و ۷، از شاخص اریبی (بایاس) (رابطه ۱۲) به‌منظور اندازه‌گیری مقدار بیش برآوردی^۱ (مقادیر منفی شاخص) یا کم برآوردی^۲ (مقادیر مثبت شاخص) و از شاخص اشتباه معیار تخمین^۳ (رابطه ۱۳) نیز استفاده شده است.

$$PBIAS = \frac{\sum_{i=1}^n (S_O - S_M)}{\sum_{i=1}^n (S_O)} * 100 \quad (12)$$

$$S_{XY} = \sqrt{\frac{\sum_{i=1}^n (S_M - S_O)^2}{n-2}} \quad (13)$$

در این پژوهش، به‌منظور پیاده‌سازی الگوریتم‌های MOPSO، تدوین مدل‌های مختلف شبکه عصبی مصنوعی، خوشه‌بندی داده‌ها، نمونه‌گیری از خوشه‌ها و سایر تحلیل‌های آماری، از نرم‌افزار MATLAB نسخه R2015b استفاده شده است.



شکل ۶- تعیین تعداد بهینه خوشه‌ها با استفاده از خوشه‌بندی SOM و شاخص دیویس-بولدین در ایستگاه هیدرومتری کوزه‌توپراقی
Figure 6. Determination of optimal number of clusters using SOM neural network and Davis-Bouldin index at the Koze-Topraghi hydrometric station

1- Overestimation
4- Null (H_0)

2- Underestimation
5- $\alpha=1\%$

3- Standard Error of the Estimate

جدول ۴- پارامترهای آماری مجموعه داده‌های آموزش، اعتبارسنجی متقاطع و آزمون ایستگاه هیدرومتری کوزه توپراقی
Table 4. Statistical parameters of training, cross validation and test data sets of the Koze-Topraghi hydrometric station

متغیرهای مدل و مجموعه داده‌ها	پارامترهای آماری				
	میانگین	انحراف معیار	حداکثر	حداقل	چولگی
مجموعه آموزش مجموعه اعتبارسنجی متقاطع مجموعه آزمون	دبی جریان (Q _w) (m ³ /s)				
	۱/۳۸	۲/۳۷	۱۱/۸۱	۰/۰	۲/۲۵
	۱/۳۸	۲/۶۱	۱۱/۶۸	۰/۰	۲/۶۶
مجموعه آموزش مجموعه اعتبارسنجی متقاطع مجموعه آزمون	دبی رسوب معلق (Q _s) (ton/day)				
	۸۶/۴۲	۲۵۶/۲۳	۱۸۰۰/۳۳	۰/۰	۴/۲۸
	۴۷/۵۳	۱۴۳/۵۴	۵۹۸/۴۳	۰/۰۲	۳/۳
مجموعه آموزش مجموعه اعتبارسنجی متقاطع مجموعه آزمون	شاخص نرم‌افزار (h)				
	۳۸/۷۹	۱۰۵/۵۳	۴۹۲/۰۳	۰/۰	۳/۴۳
	۳۸/۷۹	۱۰۵/۵۳	۴۹۲/۰۳	۰/۰	۳/۴۳

جدول ۵- نتایج آزمون ناپارامتری دو نمونه‌ای KS بر روی مجموعه داده‌های آموزش، اعتبارسنجی متقاطع و آزمون در ایستگاه هیدرومتری کوزه توپراقی
Table 5. KS two-sample nonparametric test results on training, cross validation, and test data sets at Koze-Topraghi hydrometric station

متغیر	مجموعه‌های مورد مقایسه	P-value	اماره D _c یا k	شاخص نرم‌افزار (h)
دبی جریان (Q _w) (m ³ /s)	آموزش-اعتبارسنجی متقاطع	۰/۹۷	۰/۱**	۰
دبی جریان (Q _w) (m ³ /s)	آموزش-آزمون	۰/۷۳	۰/۱۴**	۰
دبی جریان (Q _w) (m ³ /s)	اعتبارسنجی متقاطع-آزمون	۰/۶۶	۰/۱۹**	۰
دبی رسوب معلق (Q _s) (ton/day)	آموزش-اعتبارسنجی متقاطع	۰/۶۴	۰/۱۵**	۰
دبی رسوب معلق (Q _s) (ton/day)	آموزش-آزمون	۰/۸۵	۰/۱۳**	۰
دبی رسوب معلق (Q _s) (ton/day)	اعتبارسنجی متقاطع-آزمون	۱/۰۰	۰/۰۶**	۰

** معنی‌داری در سطح خطا (α = ۱٪) با اطمینان ۹۹ درصد

نتایج مدل‌سازی

خطا در مدل‌های شبکه عصبی داشته است. به‌عنوان مثال مقایسه شاخص RMSE در دو مدل ANN-LM-Sig- و ANN-LM-Sig-Log، به‌ترتیب در سناریو ۱ و ۲، نشان می‌دهد که به‌کارگیری تبدیلات لگاریتمی سبب کاهش مقدار خطا از ۴۹/۰۸ تن در روز در مدل اول به ۳۱/۷۶ تن در روز در مدل دوم به‌میزان ۱۷/۳۲ تن در روز شده است. در مدل ANN-LM-Tan (سناریو ۱)، مقدار کاهش این شاخص از ۸۷/۷۷ تن در روز به ۳۲/۱۶ تن در روز در مدل ANN-LM-Tan-Log (سناریو ۲) و به‌میزان ۵۵/۶۱ تن در روز بوده است. بررسی و مقایسه دیگر شاخص‌های صحت‌سنجی (MAE، Sxy) و اریبی (PBIAS) نیز حکایت از بهبود شاخص‌ها دارند. لذا تاثیر به‌کارگیری تبدیلات لگاریتمی مثبت ارزیابی می‌شود.

نتایج صحت‌سنجی و آزمون مدل‌های مختلف شبکه عصبی مصنوعی با مجموعه داده‌های آزمون، در جدول ۶ خلاصه شده است. همان‌طور که نتایج جدول ۶ نشان می‌دهد، تبدیلات لگاریتمی داده‌ها و به‌کارگیری الگوریتم بهینه‌سازی MOPSO در آموزش و بهینه‌سازی مدل‌ها، تاثیرات مثبتی در شاخص‌های صحت‌سنجی و مقدار اریبی (بایاس) مدل‌ها داشته است که در ادامه، به اختصار در مورد آن‌ها توضیحاتی بیان می‌شود:

الف- تاثیر تبدیلات لگاریتمی داده در صحت‌سنجی مدل‌ها: تبدیلات لگاریتمی داده، تاثیر مثبت زیادی در کاهش مقدار

جدول ۶- نتایج ارزیابی مدل‌های شبکه عصبی در برآورد بار رسوب معلق ایستگاه هیدرومتری کوزه توپراقی برای مجموعه داده‌های آزمون
Table 6. Evaluation results of neural network models for estimation of suspended sediment load of the Koze-Topraghi Hydrometric Station for test data set

نام مدل	MAE (تن در روز)	RMSE (تن در روز)	Sxy (تن در روز)	PBIAS (درصد)
سناریو ۱				
ANN-LM-Sig	۱۸/۳۷	۴۹/۰۸	۵۰/۹۳	-۲۱/۰۸
ANN-LM-Tan	۲۷/۶۲	۸۷/۷۷	۹۱/۰۸	-۳۲/۰۵
سناریو ۲				
ANN-LM-Sig-Log	۱۲/۰۰	۳۱/۷۶	۳۲/۹۶	۱۹/۷۷
ANN-LM-Tan-Log	۱۱/۷۵	۳۲/۱۶	۳۳/۳۸	۲۱/۴۸
سناریو ۳				
ANN-MOPSO-Sig-Log	۱۱/۹	۳۰/۰۷	۳۱/۲	-۱۰/۲۴
ANN-MOPSO-Tan-Log	۱۰/۹۹	۳۰/۳۱	۳۱/۴۵	-۶/۳۰

رسوب معلق، برآورد ارقام منفی است که معمولاً در دبی‌های کم‌جریان اتفاق می‌افتد (۸،۳۳،۳۶). برآورد مقادیر رسوب منفی قابل قبول نبوده و اساساً بی‌معناست. جدول ۷، نمونه‌هایی از برآورد رسوب معلق مدل ANN-LM-Sig که در آن، مقادیر منفی رسوب تولید شده است را نشان می‌دهد. در مقابل، ارقام

ب- تاثیر تبدیلات لگاریتمی در جلوگیری از برآورد ارقام منفی: علاوه بر تاثیر مثبت تبدیلات لگاریتمی در بهبود شاخص‌های صحت‌سنجی و بایاس مدل‌ها، این تبدیلات، مانع از تولید ارقام منفی در برآورد رسوب معلق شده‌اند. در این رابطه، یکی از مشکلات مدل‌های شبکه عصبی در برآورد

ارایی مدل‌ها را نیز کاهش دهد. در این رابطه، پس از آنکه تاثیر تبدیلات لگاریتمی در بهبود نتایج مدل‌های شبکه عصبی ANN-LM-Sig-Log و ANN-LM-Sig-Log مشخص گردید، از الگوریتم بهینه‌سازی چندهدفه MOPSO، در بهینه‌سازی ماتریس وزن‌ها و بایاس مدل‌های شبکه عصبی استفاده گردید. در این ارتباط پس از سعی و خطای فراوان، از بین چندین تابع هدف، دو تابع RMSE و MAE، به‌عنوان بهترین توابع هدف در بهینه‌سازی چندهدفه مدل‌ها مورد استفاده قرار گرفتند.

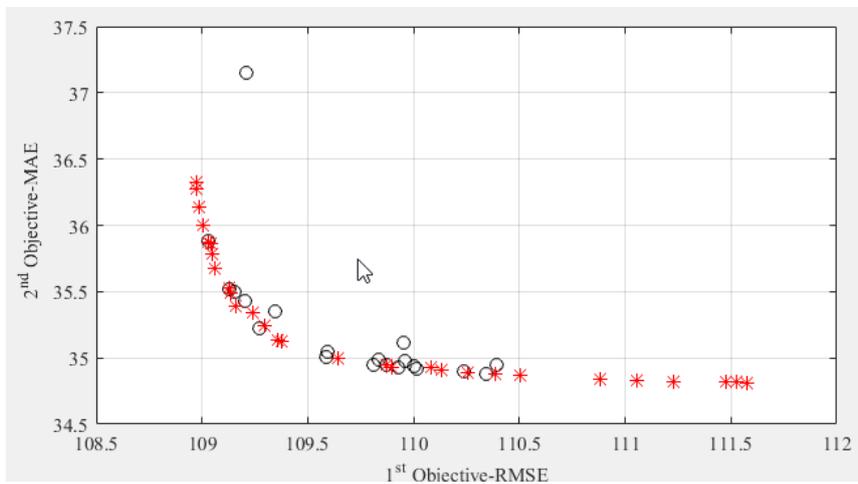
برآورد شده رسوب این نمونه‌ها در مدل ANN-LM-Sig-Log (که از تبدیلات لگاریتمی استفاده نموده است) مثبت می‌باشد. مشابه چنین وضعیتی در مدل‌های ANN-LM-Tan-Log و ANN-LM-Tan-Log نیز وجود داشته که در جدول مذکور قابل مشاهده می‌باشند. ج- تاثیر بکارگیری الگوریتم MOPSO در آموزش و بهینه‌سازی مدل‌های شبکه عصبی: همانطور که نتایج مدل‌های شبکه عصبی در سناریو ۳ نشان می‌دهند (جدول ۶)، به‌کارگیری الگوریتم MOPSO توانسته است ضمن بهبود شاخص‌های صحت‌سنجی، مقدار

جدول ۷- تاثیر بکارگیری تبدیلات لگاریتمی داده‌ها در صحت ارقام رسوب برآوردشده مدل‌های شبکه عصبی در دبی‌های کم‌جریان
Table 7. The Impact of applying logarithmic data transformations on the accuracy of estimated sediment values of neural network models in low flow discharges

متغیر	نمونه ۱	نمونه ۲	نمونه ۳	نمونه ۴	نمونه ۵
دبی جریان مشاهده‌ای (m ³ /s)	۰/۳۴	۰/۰۶	۰/۰۴	۰/۰۳	۰/۰۲
دبی رسوب معلق مشاهده‌ای (ton/day)	۳/۵۵	۰/۰۶	۰/۵۱	۰/۰۲	۰/۲۱
دبی رسوب معلق محاسبه‌ای در مدل ANN-LM-Sig (ton/day)	-۰/۲۶	-۳/۶۷	-۳/۹۶	-۳/۹۸	-۴/۱۱
دبی رسوب معلق محاسبه‌ای در مدل ANN-LM-Sig-Log (ton/day)	۱/۴۵	-۰/۳۴	-۰/۲	-۰/۱۹	-۰/۱
دبی جریان مشاهده‌ای (m ³ /s)	۰/۰۵۸	۰/۰۳۵	۰/۰۳۴	۰/۰۲۳	۰/۰۲۱
دبی رسوب معلق مشاهده‌ای (ton/day)	۰/۰۵۹	۰/۵۰۵	۰/۰۲	۰/۲۰	۰/۱۴۳
دبی رسوب معلق محاسبه‌ای در مدل ANN-LM-Tan (ton/day)	-۱۳/۸۶	-۱۹/۸۶	-۲۰/۱۲	-۲۲/۹۹	-۲۳/۵۲
دبی رسوب معلق محاسبه‌ای در مدل ANN-LM-Tan-Log (ton/day)	۰/۳۲	۰/۲۰	۰/۱۹	۰/۱	۰/۰۹

که با ستاره قرمز رنگ نشان داده شده‌اند، راه‌حل‌های نامغلوب، و نقاطی که با دایره‌های کوچک سیاه رنگ مشخص شده‌اند، راه‌حل‌های مغلوب مسئله می‌باشند.

شکل ۷، جبهه بهینه پارتو، به‌همراه دو تابع هدف RMSE و MAE (محور افقی تابع هدف و محور عمودی تابع هدف MAE) در آن را نشان می‌دهد. در این شکل، نقاطی



شکل ۷- جبهه بهینه پارتو به‌همراه دو تابع هدف RMSE و MAE. ستاره‌های قرمز رنگ، راه‌حل‌های نامغلوب و دایره‌های سیاه‌رنگ، راه‌حل‌های مغلوب مسئله می‌باشند

Figure 7. Pareto optimal front with two objective functions RMSE and MAE, The red stars are non-dominated solutions, and black circles are dominated solutions to the problem

معلق را ضروری می‌نماید. در پژوهش حاضر سعی گردید تا برای برخی از مشکلات اشاره‌شده فوق، راه‌حل‌های مناسبی ارائه گردد. در این رابطه، روش‌هایی به‌منظور پیش پردازش داده‌ها معرفی گردید. استفاده از تبدیلات لگاریتمی داده‌ها، قبل از نرمال‌سازی آن‌ها، یکی از نکات مهمی است که لازم است محققان، به آن توجه نمایند. استفاده از تبدیلات لگاریتمی، تاثیر بسزائی در افزایش کارایی مدل‌ها داشته و عدم

در جمع‌بندی نهائی، وجود کیفیت و کمیت نامناسب داده‌های رسوب‌سنجی ایستگاه‌های هیدرومتری کشور (وجود چولگی زیاد، فراوانی زیاد داده‌های مربوط به دبی پایه، کمبود داده‌های سیلابی، تعداد کم رکوردهای ثبت شده) از یک‌سو، و حاکم بودن روابط پیچیده و به شدت غیرخطی بین آن‌ها و دیگر متغیرهای حوزه‌های آبخیز از سوی دیگر، اتخاذ تصمیم در به‌کارگیری شیوه‌های مناسب در فرآیند مدل‌سازی رسوب

دقیق تر رسوب معلق در جریان‌های کم یا زیاد را فراهم نموده سبب می‌شوند، شاخص‌های صحت‌سنجی و ارزیابی مدل‌های داده مبنا بهبود یابند. در این رابطه، همان‌طور که در نتایج صحت‌سنجی و ارزیابی مدل‌ها نشان داده شد، استفاده از الگوریتم MOPSO، ضمن بهبود شاخص‌های صحت‌سنجی، تاثیر زیادی در شاخص ارزیابی (PBIAS) مدل‌ها داشته به نحوی که با به‌کارگیری این الگوریتم بهینه‌سازی، مقدار خطای بیش برآوردی مدل از $21/08$ - درصد در بهترین مدل از سناریو اول (ANN-LM-Sig)، به $6/3$ - درصد در بهترین مدل از سناریو سوم (ANN-MOPSO-Tan-Log) به مقدار $14/8$ درصد کاهش یافته است. این نتایج با نتایج کارهای مولتا (۳۴)، بکلی و نیکلو (۵)، چودهاری و سیل (۷)، افستراتیادیس و کوتسویانیس (۱۶) و ارکن و گودال (۱۷) و طباطبائی و همکاران (۴۲)، همخوانی دارد.

با توجه به نتایج به‌دست‌آمده از پژوهش حاضر و به‌منظور بهینه‌سازی مدل‌های شبکه عصبی مصنوعی، استفاده از دیگر الگوریتم‌های بهینه‌سازی چندهدفه نظیر الگوریتم ژنتیک چندهدفه با مرتب‌سازی نامغلوب (NSGA-II)، پیشنهاد می‌شود. همچنین به‌منظور افزایش کارایی مدل‌های داده مبنا در برآورد رسوب معلق رودخانه‌ها، استفاده از دیگر متغیرهای موثر در تولید رواناب و رسوبدهی حوزه‌های آبخیز، نظیر بارش، دما و سطح پوشش گیاهی، به‌عنوان متغیرهای پیش‌بینی‌کننده رسوب معلق پیشنهاد می‌شود.

تشکر و قدردانی

پژوهش انجام‌شده با حمایت مالی و معنوی پژوهشکده حفاظت خاک و آبخیزداری انجام شده است که بدین‌وسیله از کلیه حمایت‌ها و عزیزانی که ما را در این راه کمک نموده‌اند، تشکر می‌شود.

به‌کارگیری آن سبب می‌گردد تا مقادیر رسوب برآورد شده مدل‌های شبکه عصبی برای جریان‌های پائین، اغلب منفی محاسبه گردد. وجود این امر موجب می‌شود تا صحت‌سنجی و ارزیابی مدل‌ها به‌درستی انجام نشود. نتایج گرفته شده از پژوهش حاضر در این زمینه، با نتایج لاک و همکاران (۳۱)، آکیل و همکاران (۴) و حاجی آبادی و همکاران (۱۹) مطابقت می‌نماید.

از نکات مهم دیگر، توجه به قدرت تعمیم‌دهی مدل‌های داده مبنا است که تا اندازه زیادی وابسته به داده‌های استفاده شده در فرآیند واسنجی یا آموزش آن‌ها است. این داده‌ها بایستی به‌گونه‌ای انتخاب شوند تا ضمن آنکه معرف داده‌ها در کل دوره آماری هستند، با دیگر مجموعه‌های داده (نظیر مجموعه‌های ارزیابی متقاطع یا آزمون)، مشابه و از توزیع یکسان برخوردار باشند. در این راستا در پژوهش حاضر، با استفاده از شبکه عصبی نگاشت خود سازمان‌ده، اقدام به تهیه مجموعه‌های همگن و مشابه از داده‌ها، برای آموزش و آزمون مدل‌ها گردید، که نتایج این بخش از پژوهش، با کار لی و همکاران (۳۰) مطابقت می‌نماید.

نکته حائز اهمیت دیگر آنکه، الگوریتم‌های پایه مورد استفاده در آموزش مدل‌های شبکه عصبی، به‌طور معمول، مبتنی بر روش‌های گرادیان خطا بوده که از تکنیک‌های جستجوی محلی استفاده می‌نمایند و لذا، همواره در معرض خطر گیر افتادن در نقاط بهینه محلی قرار دارند. در پژوهش حاضر سعی گردید، تا از الگوریتم بهینه‌سازی چندهدفه MOPSO به‌منظور آموزش مدل‌های شبکه عصبی استفاده شود. استفاده از این الگوریتم، از یک‌سو سبب می‌گردد تا آموزش مدل‌های شبکه عصبی در کمینه‌های محلی تابع خطا متوقف نگردد، و از سوی دیگر، به‌کارگیری همزمان چندین تابع هدف در فرآیند آموزش مدل‌ها را ممکن می‌سازد. استفاده از توابع هدف چندگانه، امکان حساس‌نمودن مدل‌ها به برآورد

منابع

- Alpa, M. and H.K. Cigizoglu. 2007. Suspended sediment load simulation by two artificial neural network methods using hydrometeorological data. *Environmental Modeling and Software*, 22(1): 2-13.
- Altunkaynak, A. 2009. Sediment load prediction by genetic algorithms. *Advances in Engineering Software*, 40(9): 928-934.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. 2000. Artificial neural networks in hydrology, I: preliminary concepts. *Journal of Hydrologic Engineering*, 5(2): 115-123.
- Aqil, M., I. Kita, A. Yano and S. Nishiyama. 2007. A comparative study of artificial neural networks and neuro-fuzzy in continuous modeling of the daily and hourly behavior of runoff. *Journal of Hydrology*, 337(1-2): 22-34.
- Bekele, E.G. and J.W. Nicklow. 2007. Multi-objective automatic calibration of SWAT using NSGA-II. *Journal of Hydrology*, 341(3): 165-176.
- Buyukyildiz, M. and S.Y. Kumcu. 2017. An estimation of the suspended sediment load using adaptive network based fuzzy inference system, support vector machine and artificial neural network models. *Water Resources Management*, 31: 1343-1359.
- Choudhury, P. and B.S. Sil. 2010. Integrated water and sediment flow simulation and forecasting models for river reaches. *Journal of Hydrology*, 385(1): 313-322.
- Cigizoglu, H.K. 2004. Estimation and forecasting of daily suspended sediment data by multi-layer perceptrons. *Advances in Water Resources*, 27(2): 185-195.
- Chen, X.Y. and K.W. Chau. 2016. A hybrid double feedforward neural network for suspended sediment load estimation. *Water Resources Management*, 30: 2179-2194.

- ۱۴۴ ارزیابی تاثیر تبدیلات لگاریتمی و توابع هدف بر میزان کارائی مدل‌های شبکه عصبی در برآورد بار رسوب معلق
10. Chiang, J.L., K.J. Tsai, Y.R. Chen, M.H. Lee and J.W. Sun. 2014. Suspended Sediment Load Prediction using Support Vector Machines in the Goodwin Creek Experimental Watershed. In EGU General Assembly Conference Abstracts, 16: 5285.
 11. Coello, C.A.C., G.T. Pulido and M.S. Lechuga. 2004. Handling multiple objectives with particle swarm optimization. *IEEE Transactions on Evolutionary Computation*, 8(3): 256-279.
 12. Criss, R.E. and W.E. Winston. 2008. Do Nash values have value? Discussion and alternate proposals. *Hydrological Processes*, 22(14): 2723.
 13. Deb, K. 2001. *Multi-objective optimization using evolutionary algorithms*, Wiley, New York, USA, 512 pp.
 14. Dlugosz, A. 2016. Multi-objective optimization of the UAV wing by means of evolutionary computations. *Mechanics*, 22(6): 530-536.
 15. Ebtehaj, I. and H. Bonakdari. 2016. Assessment of evolutionary algorithms in predicting non-deposition sediment transport. *Urban Water Journal*, 13: 499-510.
 16. Efstratiadis, A. and D. Koutsoyiannis. 2010. One decade of multi-objective calibration approaches in hydrological modelling: a review. *Hydrological Sciences Journal-Journal Des Sciences Hydrologiques*, 55(1): 58-78.
 17. Ercan, M.B. and J.L. Goodall. 2016. Design and implementation of a general software library for using NSGA-II with SWAT for multi-objective model calibration. *Environmental Modelling and Software*, 84: 112-120.
 18. Guo, W. and H. Wang. 2010. August PSO optimizing neural network for the Yangtze River sediment entering estuary prediction. In 2010 6th International Conference on Natural Computation, 4: 1769-1772
 19. Hajiabadi, R., S. Farzin and Y. Hassanzadeh. 2016. Intelligent models performance improvement based on wavelet algorithm and logarithmic transformations in suspended sediment estimation. *Journal of Water and Soil*, 30(1): 112-124 (In Persian).
 20. Hornik, K., M. Stinchcombe and H. White. 1989. Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5): 359-366.
 21. Jain, A., R.K. Bhattacharjya and S. Sanaga. 2004. Optimal design of composite channels using genetic algorithm. *Journal of Irrigation and Drainage Engineering*, 130(4): 286-295
 22. Joshi, R., K. Kumar and V.P.S. Adhikari. 2016. Modelling suspended sediment concentration using artificial neural networks for Gangotri glacier. *Hydrological Processes*, 30(9): 1354-1366.
 23. Kakaei Lafdani, E., A. Moghaddam Nia and A. Ahmadi. 2013. Daily suspended sediment load prediction using artificial neural networks and support vector machines. *Journal of Hydrology*, 478: 50-62.
 24. Kennedy, J. and R. Eberhart. 1995. Particle Swarm Optimization, *IEEE Transactions On Evolutionary Computation*, 8(3): 1942-1948.
 25. Kisi, O. and J. Shiri. 2012. River suspended sediment estimation by climatic variables implication: Comparative study among soft computing techniques. *Computers and Geosciences*, 43(2): 73-82.
 26. Kisi, O. and C. Ozkan. 2017. A new approach for modeling sediment-discharge relationship: Local weighted linear regression. *Water Resources Management*, 30(2): 1-23.
 27. Kisi, O., A. Keshavarzi, J. Shiri, M. Zounemat-Kermani and E.S.E. Omran. 2017. Groundwater quality modeling using neuro-particle swarm optimization and neuro-differential evolution techniques. *Hydrology Research*, 48(2017): 1508-1519.
 28. Kaufman, L. and P.J. Rousseeuw. 2009. *Finding groups in data: an introduction to cluster analysis*. John Wiley and Sons, New York, USA, 344: 342 pp.
 29. Legates, D.R. and G.J. McCabe. 1999. Evaluating the use of "goodness of fit" measures in hydrologic and hydroclimatic model validation. *Water Resources Research*, 35(1): 233-241.
 30. Li, X., M.H. Nour, D.W. Smith and A.A. Prepasc. 2010. Neural networks modeling of nitrogen export: model development and application to unmonitored boreal forest watersheds. *Environmental Technology*, 31(5): 495-510.
 31. Luk, K.C., J.E. Ball and A. Sharma. 2000. A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting. *Journal of Hydrology*, 227(1-4): 56-65.
 32. Krause, P., D.P. Boyle and F. Bäse. 2005. Comparison of different efficiency criteria for hydrological model assessment. *Advances in Geosciences*, 5: 89-97.
 33. May, R.J., H.R. Maier and G.C. Dandy. 2010. Data splitting for artificial neural networks using SOM-based stratified sampling. *Neural Networks*, 23: 283-294.
 34. Muleta, M.K. 2011. Model performance sensitivity to objective function during automated calibrations. *Journal of hydrologic engineering*, 17(6): 756-767.
 35. Mustafa, M.R., M.H. Isa and R.B. Rezaur. 2012. Artificial neural networks modeling in water resources engineering: infrastructure and applications. *World Academy of Science, Engineering and Technology*, 6(2): 317-325.
 36. Parhizkari, M. 2019. Multi-objective operation optimization of hydropower reservoirs by MOPSO Case study: Karun Dam 5. *Iran Water Resources Research*, 15(1): 250-255 (In Persian).

37. Rajaei, T., S.A. Mirbagheri, M. Zounemat-Kermani and V. Nourani. 2009. Daily suspended sediment concentration simulation using ANN and neuro-fuzzy models. *Science of the Total Environment*, 407(17): 4916-4927.
38. Samantaray, S. and D.K. Ghose. 2018. Evaluation of suspended sediment concentration using descent neural networks. *Procedia Computer Science*, 132: 1824-1831.
39. Schmitt, L.M. 2001. Theory of genetic algorithms. *Theoretical Computer Science*, 259(1-2): 1-61.
40. Tabatabaei, M., K. Solaimani, M.H. Roshan and A. Kaviani. 2015. Estimation of Daily Suspended Sediment Concentration using Artificial Neural Networks and Data Clustering by Self-Organizing. *Journal of Watershed Management Research*, 5(10): 98-116 (In Persian).
41. Tabatabaei, M., A. Salehpour Jam and S.A. Hosseini. 2019. Presenting a New Approach to Increase the Efficiency of the Sediment Rating Curve Model in Estimating Suspended Sediment Load in Watersheds (Case Study: Mahabad-Chai River, Lake Urmia Basin, West Azarbajejan Province, Iran). *Journal of Watershed Management Research*, 10(19): 181-193 (In Persian).
42. Tabatabaei, M., A. Salehpour Jam and S.A. Hosseini. 2019. Suspended sediment load prediction using non-dominated sorting genetic algorithm II. *International Soil and Water Conservation Research*, 7(2): 119-129.
43. Tabatabaei, M., A. Salehpour Jam and J. Mossafaei. 2020. Improvement of the efficiency of artificial neural network model in suspended sediment simulation using particle swarm optimization algorithm, DOI: 10.22092/ijwmse.2019.125871.1638 (In Persian).
44. Tayfur, G. 2012. *Soft computing in water resources engineering: Artificial neural networks, fuzzy logic and genetic algorithms*. WIT Press, Dorset, UK, 288 pp.
45. Ulke, A., G. Tayfur and S. Ozku. 2009. Predicting suspended sediment loads and missing data for gediz river, Turkey. *Journal of Hydrologic Engineering*, 14(9): 954-965.
46. Villalta, C.C. 2009. *Multi-objective Optimization Approach for Land Use Allocation Based on Water Quality Criteria*, Ph.D. Dissertation. The Puerto Rico University, Mayagüez, Puerto Rico, 276 pp.
47. Yee, K.Y., A.K. Ray and G.P. Rangaiah. 2003. Multi-objective optimization of industrial styrene reactor. *Computers and Chemical Engineering*, 27: 111-130.
48. Zealand, C.M., D.H. Burn and S.P. Simonovic. 1999. Short term streamflow forecasting using artificial neural networks. *Journal of Hydrology*, 214(1): 32-48.

Evaluation of the Effect of Logarithmic Transformations and Objective Functions on the Performance of Neural Network Models in Estimation of Suspended Sediment Load (Case Study: Sarab Ghare So Watershed, Ghorichai River)

Mahmoudreza Tabatabaei¹ and Seyed Ahmad Hosseini²

1- Associate Professor, Soil Conservation and Watershed Management Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Tehran, Iran,

(Corresponding author: taba1345@hotmail.com)

2- Assistant Professor, Soil Conservation and Watershed Management Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Tehran, Iran

Received: 29 March, 2020

Accepted: 27 April, 2020

Extended Abstract

Introduction and Objective: Accurate estimation of river suspended sediment load (SSL) has an important role in water resources, watershed management and related sciences. Due to the high fluctuations of SSL in different seasons of the year as well as its severely nonlinear and complexity nature, it is necessary to use appropriate methods that can simulate and estimate such phenomena.

Material and Methods: In this study, data log transformation and multi-objective particle swarm optimization (MOPSO) algorithm were used for optimal training of neural network models. For this purpose, at first, by using unsupervised neural network (SOM), data of flow discharge and suspended sediment load of the studied hydrometric station (Statistical Period 1995-2016) were clustered. Then, by sampling the clusters, the data set needed to train and test the neural network models were prepared. After it, three scenarios were defined to evaluate the impact of applying logarithmic transformations and MOPSO optimization algorithm. In the first scenario, the initial data (without logarithmic transformation) and the common base gradient algorithm in training neural network models (error propagation), in the second scenario, the error propagation algorithm and the logarithmic transforms, and in the third scenario, the logarithmic transforms and the MOPSO algorithm, was used to train neural network models.

Results: Evaluation and comparison of the model validation results showed that applying a logarithmic transforms and MOPSO algorithm, by reducing RMSE error and bias percentage (PBIAS) from 49 ton/day and -21%, in the best model of the first scenario, to 30.3 ton/day and -6.3%, in the best model of scenario III, increased the efficiency of the models. Other results of the study are non-estimation of negative values for suspended sediment, which is one of the common errors in using neural network models in estimating suspended sediment.

Conclusion: The use of multiple objective functions makes it possible to sensitize the models to more accurately estimate the suspended sediment at low or high flows, thus improving the validation and skewness indices of the base data models.

Keywords: Ghorichai River, MOPSO, Objective Function, Suspended Sediment