

جغرافیا و توسعه شماره ۳۹ تابستان ۱۳۹۴

وصول مقاله: ۱۳۹۱/۰۸/۱۹

تأیید نهایی: ۱۳۹۲/۰۲/۲۰

صفحات: ۱-۱۶

استفاده از مدل تبرید تدریجی عصبی (NDE) در تخمین بار معلق رسوبی و مقایسه‌ی آن با مدل ANFIS و RBF مطالعه موردی: رودخانه گیوی‌چای

دکتر معصومه رجبی^۱، دکتر مهدی فیض‌اله‌پور^۲، دکتر شهرام روستایی^۳

چکیده

در این تحقیق، مدل تبرید تدریجی عصبی (NDE) با بهره‌گیری از ترکیب‌های ورودی مختلف برای تخمین بار معلق رسوبی روزانه به کار گرفته شد. به این منظور در اولین بخش از تحقیق، مدل NDE با استفاده از داده‌های دبی روزانه و بار معلق رسوبی روزهای پیشین تعلیم داده شده و برای تخمین بار معلق رسوبی رودخانه گیوی‌چای مورد استفاده قرار گرفت. در دومین بخش از تحقیق، مدل NDE با استفاده از پارامترهای ضریب تبیین (R^2) و خطای مجذور میانگین مربعات (RMSE) با مدل‌های سیستم استنتاجی فازی عصبی (ANFIS) و تابع پایه شعاعی (RBF) مقایسه گردید. نتایج نشان داد که مدل NDE با برخورداری از مقادیر ضریب تبیین (R^2) معادل ۰/۹۵۸۶ و RMSE معادل ۱۶۰ میلی‌گرم در لیتر در مقایسه با سایر مدل‌ها از قابلیت بهتری در تخمین بار معلق رسوبی برخوردار است. در تخمین حداکثر بار معلق رسوبی نیز مدل NDE، با برخورداری از مقادیر خطای نسبی (RE) معادل ۴۷- درصد به نتایج بهتری دست یافته است. کلیدواژه‌ها: تبرید تدریجی عصبی، پرسپترون چندلایه، منحنی سنجه رسوبی، رودخانه گیوی‌چای.

مقدمه

پیش‌بینی بار رسوبی در طیف وسیعی از مسائل مرتبط با حجم مخازن سدها، بار رسوبی حمل شده در رودخانه‌ها، طراحی کانال‌ها، تخمین ارتفاع پایه‌ی پل‌ها، پیش‌بینی مقادیر شن و ماسه متأثرکننده تعادل بستر رود به کار برده می‌شود (Mcbean et al:1988:63-74). Nakato, 1990:362-379.

بار معلق رسوبی رودخانه‌ها معمولاً از طریق اندازه‌گیری مستقیم یا معادلات تجربی تعیین می‌شود. گرچه اندازه‌گیری مستقیم از درجه اعتبار زیادی برخوردار است، ولی بسیار هزینه‌بر بوده و نمی‌تواند برای سطح وسیعی از رودخانه مورد استفاده قرار گیرد. با این حال اکثر معادلات برآوردکننده‌ی بار معلق رسوبی، نیازمند داده‌های دبی و رسوب حاصل از این اندازه‌گیری‌ها می‌باشند (Ozturk et al, 2001: 643-650). در برخی از تحقیقات تلاش شده تا بین مقادیر رسوب انتقال یافته با شرایط دبی ارتباط برقرار گردد. مک‌بین و همکاران بیان می‌کنند که روابط بین بار معلق رسوبی و دبی به علت عدم وجود روابط نامعلوم همراه‌کننده می‌باشد (Mcbean, 1988: 63-74).

مدل‌های مبتنی بر اصول فیزیکی بر معادلات ساده‌ای استوار بوده و مقادیر دبی و رسوب را به صورت تئوریک شبیه‌سازی نموده و تأثیر دبی و بارش را در فرسایش به صورت روابط تجربی و مدل‌سازی می‌کنند. نمونه‌هایی از این مدل‌ها به وسیله باتورست و رفسگارد ارائه شده است (Bathurst, 1996: 213 - 238; Refsgaard, 1997: 69-97).

این مدل‌ها مبتنی بر اصول و فرایند فیزیکی بوده و به صورت تئوریک از قابلیت محاسبه نوسانات مکانی و توزیع نامتوازن بارش و تبخیر برخوردارند. مدل‌ها نیازمند اطلاعات قابل استفاده درباره‌ی خصوصیات حوضه، تراکم و فراوانی بوده و این پارامترها داده‌های ورودی مدل را تشکیل می‌دهند. در عمل به علت اینکه

توزیع مکانی بارندگی برای اکثر نقاط جهان قابل محاسبه نیست، لذا مدل‌های پراکنش مختلفی به کار برده شده‌اند (Gudal&Mutfuglu, 2001:132-140).

مدل شبکه عصبی مصنوعی (ANN) در سال‌های گذشته به صورت موفقیت آمیزی در مدل‌سازی بارش رواناب، پیش‌بینی دبی، مدل‌سازی آب‌های زیرزمینی، مدل‌سازی کیفی آب، سیاست‌های مربوط به مدیریت منابع آبی، پیش‌بینی بارش، تحلیل‌های سری زمانی بارندگی و بررسی عملکرد مخازن مورد استفاده قرار گرفته است. اکثر فرایندهای هیدرولوژیک درجه وسیعی از نوسانات مکانی و زمانی را به نمایش گذاشته و به وسیله‌ی فرایندهای فیزیکی غیرخطی متأثر شده و این امر استفاده از آنها را در تخمین پارامترها غیرقابل اعتماد نموده است. به این دلیل استفاده از مدل‌های مبتنی بر این اصول از توجیه کافی برخوردار نیست. در دهه‌ی گذشته گام‌های بزرگی در فهم فرایندهای مرتبط با برداشت رسوب و رواناب از طریق مدل‌سازی‌های مختلف صورت پذیرفته است. مدل‌ها بر پایه‌ی نحوه‌ی نمایش فرایندهای فیزیکی به طبقات مختلفی تقسیم شده‌اند. با افزایش شناخت این فرایندها، مدل‌ها به انواع مدل‌های جعبه‌سیاه، مدل‌های مفهومی و مدل‌های مبتنی بر اصول فیزیکی تقسیم شده‌اند. مدل‌های اخیر در شرایط تئوریک دشوار از قابلیت‌های بهتری برخوردار است. طبق نظر گوتام^۲ این مدل نیازمند شمار زیادی از داده‌ها بوده و این امر باعث نامناسب بودن این مدل در شرایط کمبود داده‌ها می‌گردد (Gautam, 2000: 117-136). مدل‌های مفهومی به علت نیاز به تعداد کمی از داده‌ها از چارچوب مفهومی دقیقی برخوردار است. در بین ابزارهای محاسباتی مختلف از قبیل الگوریتم ژنتیک، سیستم‌های تطبیقی چندمتغیره، و شبکه عصبی مصنوعی، مدل شبکه‌ی

1-Artificial neural network

2-Gautam

تایفور و گولدال از روش پرسپترون چندلایه برای پیش‌بینی بار معلق رسوبی بهره گرفته‌اند (Tayfur & Guldal, 2006:69-79). راکووانشی^۶ و همکاران عنوان کرده‌اند که در پیش‌بینی دبی و بار معلق رسوبی حوضه رودخانه‌ی ناگون در هند، مدل ANN به نتایج مطلوبی دست یافته‌اند. به این منظور داده‌های ۵ سال آماری برای تعلیم و داده‌های ۲ سال آماری برای آزمایش مدل به کار گرفته شده است (raghuwanshi et al, 2006:71-79). دهقانی و همکاران با استفاده از منحنی سنج رسوبی و شبکه‌ی عصبی مصنوعی به تخمین بار معلق رسوبی رودخانه دوغ در استان گلستان پرداختند. تحقیق فوق نشان داد که شبکه‌ی عصبی مصنوعی نسبت به منحنی سنج رسوبی به نتایج بهتری دست یافته است (دهقانی و همکاران، ۱۳۸۸: ۵۱-۳۶). دهقانی و همکاران با استفاده از شبکه‌ی عصبی مصنوعی به تخمین بار معلق رسوبی رودخانه بهشت‌آباد پرداختند. نتایج نشان داد که مدل شبکه‌ی عصبی مصنوعی از قابلیت بالایی در تخمین بار معلق رسوبی برخوردار است (دهقانی و همکاران، ۱۳۸۹: ۱۶۸-۱۵۹). با وجود انعطاف‌پذیری بالای مدل ANN در مدل‌سازی سری زمانی هیدرولوژیکی، در صورت وجود حجم وسیعی از داده‌ها در محدوده‌ی یک روز تا چند دهه، مدل نیازمند پردازش حجم وسیعی از داده‌ها بوده و این امر مدل‌سازی را با مشکل مواجه می‌سازد. در این شرایط، سیستم استنتاجی فازی عصبی (ANFIS^۷) برای تخمین داده‌ها در شرایط غیرقابل اعتماد مورد استفاده قرار می‌گیرد. ادغام مدل‌های ANN و ANFIS باعث برخورداری مدل از مزایای هر دو سیستم می‌گردد. مدل ANFIS در برخی تحقیقات از قبلی مدیریت منابع آبی، شبیه‌سازی شرایط اکولوژیک پایدار، شبیه‌سازی آب‌های سطحی (Ocampoduque et al, 2007:634-641).

عصبی مصنوعی بطور گسترده‌ای در مدل‌سازی‌های هیدرولوژیکی استفاده شده است. جین^۱ از روش ANN برای برقراری روابط بین دبی و رسوب روزانه استفاده نموده و به این نتیجه دست یافته که مدل ANN نسبت به منحنی سنج به نتایج بهتری دست یافته است (Jain, 2001:30-37).

تایفور^۲ با به‌کارگیری مدل ANN در تخمین بار رسوبی صفحه‌ای بیان کرده که این مدل نسبت به مدل‌های مبتنی بر اصول فیزیکی از کارایی بهتری برخوردار است (Tayfur, 2002: 879-893).

کیسی^۳ از تکنیک‌های مختلف ANN برای پیش‌بینی بار معلق رسوبی استفاده کرده و به این نتیجه دست یافته که مدل پرسپترون چندلایه نسبت به مدل شبکه عصبی رگرسیونی تعمیم یافته و تابع پایه شعاعی به نتایج بهتری دست یافته است (Kisi, 2004:1025-1040). سیقیزاغلو و کیسی^۴ به بررسی صحت مدل ANN در تخمین و پیش‌بینی داده‌های رسوبی روزانه پرداخته‌اند (Cigizoglu & kisi, 2005:1-16). کیسی برای مدل‌سازی بار معلق رسوبی روزانه از شبکه‌ی عصبی مصنوعی بهره گرفته و به این نتیجه دست یافته که مدل ANN نسبت به مدل منحنی سنج رسوبی از کارایی بهتری برخوردار است (Kisi, 2005: 683-696).

باتاچاریا^۵ با استفاده از تحقیقات چندین محقق از یک نوع الگوریتم برای اصلاح مدل ANN استفاده کرده و صحت سنجی مدل نشان می‌دهد که این مدل نسبت به مدل‌های انتقال رسوب به نتایج بهتری دست یافته است (Bhattacharya et al, 2005:297-302).

سیقیزاغلو و کیسی برای بهبود کارایی مدل ANN از روش‌های مختلفی استفاده کرده‌اند (Cigizoglu & kisi, 2006:221-238).

1-Jain
2-Tayfur
3-Kisi
4-Cigizoglu & kisi
5-Bhattacharya

6-Raghuwanshi
7-Adaptive neuro- fuzzy inference system

این تحقیق بررسی قابلیت و صحت‌سنجی مدل‌های مفهومی و هوش مصنوعی در تخمین بار معلق رسوبی است.

منطقه‌ی مورد مطالعه

حوضه رودخانه‌ی گیوی‌چای با مجموع مساحت ۸۲۷ کیلومترمربع یکی از زیرحوضه‌های آبریز سفیدرود می‌باشد که در مختصات ۴۸ درجه و ۱۴ دقیقه و ۳۰ ثانیه تا ۴۸ درجه و ۳۲ دقیقه و ۳۵ ثانیه طول شرقی و ۳۷ درجه و ۲۵ دقیقه و ۴۰ ثانیه تا ۳۷ درجه و ۵۴ دقیقه و ۳۰ ثانیه عرض شمالی واقع شده است. این حوضه از شمال به حوضه‌ی آبریز قره‌سو و ارتفاعات ترکا، پیله، چاله‌مرز و گنداب، از غرب به حوضه‌ی آبریز رودخانه قرنقو و از شرق به حوضه‌ی آبریز رودخانه‌های آق‌اولر، ناورود و رشته‌کوه‌های تالش و از جنوب به حوضه‌ی آبریز پایاب رودخانه‌ی قزل‌اوزن محدود می‌شود. بطور کلی حوضه‌ی آبریز گیوی‌چای متشکل از رودخانه‌های اصلی به نام‌های هروآباد، آرپاچای و گیوی‌چای می‌باشد که با جهت جنوب‌شرق - شمالغرب جریان یافته و پس از دریافت جریان رودخانه‌های فرعی سنگورچای و رودخانه‌ی گزاز، در ارتفاع ۸۶۰ متر از سطح دریا در بخش جنوب غربی از منطقه خارج می‌شود و به رودخانه‌ی قزل‌اوزن تخلیه می‌گردد.

از نقطه نظر تقسیمات سیاسی حوضه‌ی آبریز گیوی‌چای جزو استان اردبیل محسوب می‌شود. از شهرهای مهم محدوده‌ی حوضه می‌توان خلخال، گیوی، مجره، آل‌هاشم، خوجین، اندبیل، گلستان، مورستان، مصطفی‌لو، خلفه‌لو، قره‌قشلاق، سنگ‌آباد، پرگو، گنجگاه، کهران، یلوجه و کیوان را نام برد. حوضه‌ی رودخانه گیوی‌چای از مناطق فرسایش‌پذیر و مستعد لغزش بوده و به همین علت از مقادیر زیاد بار معلق رسوبی برخوردار است. این فرایند در کنار وقوع طغیان‌های رودخانه، باعث کاهش عمر مفید بندها و کانال‌های

مدل‌سازی دبی جریان (Zounemat kermani et al, 2008: 928-936) و تخمین جریان زیرسطحی (Zounemat kermani et al, 2009: 746- 755) مورد استفاده قرار گرفته است.

تایفور و همکاران با استفاده از الگوریتم منطق فازی و داده‌های شدت بارندگی و داده‌های شیب اقدام به تخمین بار رسوبی نموده‌اند. نتایج تحقیق آنها نشان داد که مدل فازی در شرایطی که حوضه از بارندگی در شدت‌های مختلف و داده‌های شیب متفاوتی برخوردار باشد به نتایج بهتری دست می‌یابد (Tayfur et al, 2003:1249-1256).


کیسی و همکاران از مدل منطق فازی برای تخمین بار معلق رسوبی استفاده کرده و به این نتیجه دست یافته‌اند که مدل فازی می‌تواند در تخمین بار معلق رسوبی بطور موفقیت‌آمیزی مورد استفاده قرار گیرد (Kisi et al, 2006:4351-4362).

لوهانی و همکاران از روش منطق فازی برای مدل‌سازی روابط بین دبی و بار معلق رسوبی استفاده کردند. این مدل در دو ایستگاه واقع در نارمادای هند به کار گرفته شد. نتایج نشان داد که مدل فازی نسبت به مدل SRC به نتایج بهتری دست می‌یابد (Lohani et al, 2007:793-807).

کیسی و همکاران قابلیت مدل فازی عصبی را در پیش‌بینی بار معلق رسوبی در حوضه‌ی کیزیلیرماغ واقع در ترکیه بررسی نمودند (Kisi et al, 2008:1270-1285). نتایج نشان داد که الگوریتم ANFIS نسبت به مدل‌های ANN از قابلیت بهتری در تخمین بار معلق رسوبی برخوردار است. در این تحقیق، کارایی مدل‌های تبرید تدریجی عصبی (NDE¹)، تابع پایه شعاعی (RBF^۲) و سیستم استنتاجی فازی عصبی (ANFIS) در تخمین بار معلق رسوبی رودخانه‌ی گیوی‌چای در شهرستان خلخال مورد بررسی قرار گرفته است. هدف اصلی در

قرار گرفته است. شکل ۱ موقعیت ایستگاه گیوی چای را در جنوب غربی حوضه نشان می‌دهد. برای ایستگاه گیوی چای، داده‌های ۳۶۵ روز سال ۱۳۸۸ برای تعلیم مدل NDE، ANFIS و RBF استفاده شده و داده‌های ۳۶۵ روز سال ۱۳۸۹ برای آزمایش به کار گرفته شده است. پارامترهای آماری دبی و رسوب ایستگاه گیوی چای در جدول ۱ نشان داده شده است.

واقع بر روی این رودخانه می‌گردد. لذا اقدام به برآورد بار معلق رسوبی و تعیین قابلیت هر یک از مدل‌های مورد استفاده در این زمینه شده است. در این تحقیق، داده‌های دبی روزانه و بار معلق رسوبی ایستگاه گیوی چای (۳۷ درجه و ۴۱ دقیقه و ۲۳ ثانیه عرض شمالی و ۴۸ درجه و ۳۲ دقیقه و ۲۶ ثانیه طول شرقی) که از سازمان تمام گردآوری شده مورد استفاده



شکل ۱: موقعیت رودخانه گیوی چای در استان اردبیل

ماخذ: مطالعات میدانی نگارندگان، ۱۳۹۱

جدول ۱: پارامترهای آماری روزانه دبی و رسوب در ایستگاه گیوی چای (۸۹-۱۳۸۸)

نوع داده‌ها	نوع داده	میانگین	انحراف معیار	ضریب چولگی	حداکثر داده	حداقل داده
داده‌های تعلیمی	دبی	۵۴	۱۱۷	۴/۹۳	۱۰۲۹	۰/۴
	رسوب	۳۲۶	۷۹۳	۵/۲۳	۷۶۵۰	۵
داده‌های آزمایشی	دبی	۳۳	۶۳	۲/۹۱	۴۲۶	۰/۲
	رسوب	۲۹۳	۷۶۹/۶	۶/۰۸	۷۳۰۰	۳

ماخذ: مطالعات میدانی نگارندگان، ۱۳۹۱

مواد و روش‌ها

۱۳۸۹ برای آزمایش انتخاب شد. سپس داده‌ها، نرمالیزه شده و وارد مدل‌های مورد استفاده شدند. برای هر یک از مدل‌ها در MATLAB کدهایی نوشته شده و ساختارهای ورودی مختلفی توسط روش آزمون و

در این تحقیق، برای تعیین کارایی هر یک از مدل‌ها در برآورد مقادیر بار معلق رسوبی مقایسه‌ای بین آنها صورت گرفته است. به این منظور ابتدا داده‌های ۳۶۵ روز سال ۱۳۸۸ برای تعلیم و داده‌های ۳۶۵ روز سال

وابسته می‌باشد. عملگر فوق به صورت زیر نمایش داده می‌شود:

$$P_G = (V_{1,G}, \dots, V_{NP,G}) \quad G=0, \dots, G_{max}, \quad \text{معادله ۴:}$$

علاوه بر این هر بردار محتوی پارامتر واقعی D بوده و به صورت زیر بیان می‌گردد:

معادله ۵:

$$V_{iG} = (V_{1,i,G}, \dots, V_{D,i,G}) \quad i=1, \dots, NP \quad G=0, \dots, G_{max}$$

برای برقراری نقطه‌ی شروع برای بهینه‌سازی، مجموعه بایستی ارزش‌گذاری شود. در اغلب شرایط، مجموعه‌ی آغازین به صورت تصادفی از بین محدوده‌ی زیر انتخاب می‌شود:

معادله ۶:

$$V_{j,i,0} = \text{rand}_j[0,1] (v_j^{(U)} - v_j^{(L)}) + v_j^{(L)} \quad i = 1, \dots, NP, j = 1, \dots, D,$$

در اینجا عبارت $\text{rand}_j[0,1]$ به صورت زیر نوشته می‌شود:

معادله ۷:

$$u_{j,i,G+1} = \left\{ \begin{array}{l} \left\{ \begin{array}{l} v_{j,r3,G} + F(v_{j,r1,G} - v_{j,r2,G}) \text{ if } v_j^{(L)} < y_{j,i,G+1} < v_j^{(U)} \\ \text{otherwise } \text{rand}_j[0,1] (v_j^{(U)} - v_j^{(L)}) \end{array} \right\} \text{ if } \text{rand}_j[0,1] \leq CR \\ \text{otherwise } v_{j,i,G} \end{array} \right\}$$

شاخص‌های انتخابی I_1 ، I_2 و I_3 متفاوت از همدیگر بوده و از شاخص در حال اجرا نیز متفاوت می‌باشند. پارامترهای F و CR ، پارامترهای کنترل‌کننده NDE بوده و مشابه پارامتر NP هر دو پارامتر در طول فرایند جستجو، ثابت خواهند ماند. فاکتور F در محدوده‌ی بین $[0.0, 1.0]$ قرار داشته و در محدوده‌های مختلف درجه‌بندی شده است. محدوده‌ی بالایی F به صورت تجربی تعیین می‌گردد.

فاکتور CR به صورت داده‌های متقاطع است که در محدوده $[0.0, 1.0]$ قرار داشته و پارامترهای برداری آزمایشی را کنترل کرده و مقدار برداری $u_{j,i,G+1}$ را به جای بردار $v_{j,i,G}$ جایگزین می‌کند. مقادیر مناسب برای F ، CR و NP معمولاً بعد از چند مرحله آزمون داده‌های مختلف از طریق آزمون و خطا تعیین می‌شود.

خطا تعیین شده و با پارامترهای آماری R^2 و $RMSE^1$ بهترین ساختار ورودی تشخیص داده شد. در نهایت با استفاده از آزمون اطلاعاتی آکائیک (AIC^2) کارایی هر یک از مدل‌ها تعیین گردید. در زیر به تشریح هر یک از مدل‌های مورد استفاده در این تحقیق پرداخته شده است.

مدل تبرید تدریجی عصبی (NDE)

الگوریتم تبرید تدریجی عصبی به عنوان یک نوع الگوریتم بهینه‌سازی تدریجی شناخته می‌شود (Stom & price, 1995: 346, 1997: 341-359) (Lampinen, 2001: 50-57). به صورت کلی تابع بهینه‌سازی به صورت f نشان داده شده و به صورت زیر نمایش داده می‌شود:

$$fV: R^D \rightarrow R, \quad \text{معادله ۱:}$$

در اینجا، R نشان‌دهنده‌ی تعداد واقعی اعداد، D پارامترهای تابع هدف و $F(V)$ داده‌های بهینه‌سازی شده می‌باشد. پارامتر V به صورت زیر بیان می‌گردد:

$$V = V_1, \dots, V_D, V \in R^D, \quad \text{معادله ۲:}$$

فاکتور V ، نشان‌دهنده‌ی بردار فشرده شده‌ی از پارامتر تابع هدف D می‌باشد. در این تحقیق، تابع هدف $F(V)$ نشان‌دهنده‌ی خطای میانگین مربعات بین حجم رسوبات مشاهده شده و محاسبه شده بوده و V_i ، پارامتر زیرمجموعه فازی (تابع عضویت فازی) می‌باشد. معمولاً پارامترهای تابع هدف اشاره به محدوده بالا و پایین $v_i^{(L)}$ و $v_i^{(U)}$ داشته به صورت زیر بیان می‌گردد:

$$v_i^{(L)} \leq v_i \leq v_i^{(U)} \quad i = 1, \dots, D, \quad \text{معادله ۳:}$$

در بین تمام الگوریتم‌های بهینه‌سازی تدریجی، عملگر NDE بر روی مجموعه P_G به عنوان راه‌حل برگزیده انتخاب می‌گردد. راه‌حل برگزیده، منحصر به مجموعه

1-Root mean squared error
2-Akaike information criterion

عنوان سیستم استنتاجی فازی عصبی شناخته می‌شود. مدل ANFIS برای به روز کردن پارامترهای توابع عضویت از دو روش استفاده می‌کند:

- ۱- برقراری وضعیت پس پراکنش برای تمام پارامترها
- ۲- استفاده از مدل ترکیبی که در آن پارامترهای مجموعه عضویت ورودی به منظور تهیه‌ی توابع عضویت خروجی به صورت پس پراکنش تحلیل می‌شوند. در نتیجه‌ی این امر، خطای یادگیری در طول فرایند یادگیری، کاهش می‌یابد. بنابراین اکثر توابع عضویت اولیه بهینه‌سازی شده و در ساختار مدل ANFIS وارد می‌شوند. ساختار مدل ANFIS در شکل ۲ نشان داده شده است. معمولا در مدل ANFIS دو ورودی X و Y و یک خروجی Z در نظر گرفته می‌شود. در مدل فازی، قوانین اگر آن‌گاه به صورت زیر بیان می‌گردد:

Rule1: if x is A1 and y is B1, THEN f1=p1x+q1y+r1, (1)

Rule2: if x is A2 and y is B2, THEN f2=p2x+q2y+r2, (2)

در این معادله، A_1, A_2, B_1, B_2 توابع عضویت ورودی‌های X, Y بوده و p_1, q_1, r_1 و p_2, q_2, r_2 پارامترهای توابع خروجی هستند. توابع مدل ANFIS به صورت زیر می‌باشد. مدل مذکور به شکل زیر تبیین می‌شود:

نحوه‌ی انتخاب پارامترهای کنترل کننده F, CR و NP در تحقیقات لامپینن و زلینکا شرح داده شده است (Lampinen & zelinka, 2000:76-83).


طرح انتخاب شده NDE متفاوت از سایر الگوریتم‌های تبرید تدریجی است. مقادیر تبرید تدریجی از طریق معادله زیر به دست می‌آید:

$$V_{i,G+1} = \begin{cases} U_{i,G+1} & \text{if } f(U_{i,G+1}) \leq f(V_{i,G}) \\ V_{i,G} & \text{otherwise} \end{cases} \quad \text{معادله ۸}$$

بنابراین هر عضو از مجموعه موقت با نقطه مقابل آن در مجموعه فعال مقایسه شد. با فرض اینکه تابع هدف در حال کوچک شدن است، بردار برخوردار از تابع هدف کوچکتر در مجموعه بعدی جای خواهد گرفت. در نتیجه تمام اعضای مجموعه ثانویه نسبت به نقطه مقابل آن در مجموعه فعال به نتایج بهتری دست می‌یابد.

سیستم استنتاجی فازی عصبی (ANFIS)

چانگ با ارائه‌ی یک مدل تعلیمی، از الگوریتم شبکه عصبی مصنوعی و قوانین اگر آن‌گاه فازی در قالب توابع عضویت به صورت ترکیبی در تحلیل پدیده‌ها استفاده کرده است (Jang, 1993: 665-685). این مدل از ساختار شبکه‌ی عصبی مصنوعی استفاده کرده و تحت



شکل ۲: ساختار مدل استنتاجی فازی عصبی (ANFIS)

ماخذ: مطالعات میدانی نگارندگان، ۱۳۹۱

شبکه‌ی عصبی پایه‌ای شعاعی (RBF)

مدل RBF، با استفاده از توابع غیرخطی به طبقه‌بندی داده‌های ورودی قبل از الصاق به شبکه می‌پردازد. این توابع سطحی فضای ورودی را تحت پوشش قرار می‌دهند. لایه‌ی پنهان محتوی شمار یکسانی از گره‌ها در مرکز شبکه می‌باشند. داده‌های غیرصفری فقط در زمانی که داده‌های ورودی در بین سطح کوچکی از فضای داده‌های ورودی واقع شده باشد، مورد استفاده قرار می‌گیرند. با وجود این کاستی، روش فوق به عنوان یکی از روش‌های پیش‌بینی حجم رسوبات استفاده شده است.

انتقال ورودی‌ها در مدل تجربی، مهمترین قسمت مطالعات می‌باشد. انتقال ورودی در مدل RBF به صورت غیرخطی بوده و در غالب یک تابع پایه ای تثبیت شده شعاعی صورت می‌گیرد. بعد از یک رابطه‌ی غیر خطی، ورودی‌های چندبعدی بدون در نظر گرفتن فضای خروجی در تابع پایه‌ای شعاعی، نقش پیش‌بینی‌کننده‌ای را ایفا می‌کنند. با این وجود لایه‌ی خروجی به صورت یک رگرسیون خطی بوده و فقط قابلیت تنظیم پارامترهایی را دارا می‌باشد که از وزن معینی برخوردار باشند این پارامترها به عنوان روش کمترین مربعات شناخته می‌شوند. معادله‌ی برآورد روش RBF به صورت زیر می‌باشد:

$$y(x) = \phi((x-c)^{T\zeta-1}(x-c)), \quad (16)$$

در این فرمول ϕ تابع فعال، C مرکز شبکه و ζ واحد اندازه‌گیری تابع می‌باشد. غالباً واحد متریک، یک عبارت اقلیدسی بوده و برابر معادله فوق می‌باشد:

$$y(x) = \phi\left(\frac{(x-c)^T(x-c)}{r^2}\right), \quad (17)$$

در این معادله، طول اقلیدسی به وسیله‌ی I_j نمایش داده می‌شود که از طریق تفریق بین بردار $y=(y_1, y_2, \dots, y_m)$ و مرکز شعاع $y_i=(w_1, w_2, \dots, w_{mj})$

لایه‌ی ۱: هر گره (node) در این لایه، نشان‌دهنده‌ی درجه‌ی عضویت پارامترهای ورودی می‌باشد.

$$o_{i,1} = \mu A_i(x), i=1,2, \quad (9)$$

$$o_{i,1} = \mu B_{i-1}(y), i=3,4, \quad (10)$$

در این معادله x, y ورودی گره I بوده و $A_i, (B_{i-2})$ مجموعه‌ی فازی مرتبط با این گره می‌باشد. همچنین $O_{I,1}$ درجه عضویت مجموعه فازی می‌باشد. توابع عضویت می‌توانند به شکل زنگوله‌ای، مثلثی و دوزنقه‌ای نمایش داده شوند. توابع زنگوله‌ای شکل با توجه به مجموعه‌های عضویت به صورت زیر برآورد می‌گردند:

$$\mu_{A_i}(x) = \frac{1}{1 + \left| \frac{x-c_i}{a_i} \right|^{2b_i}}, \quad (11)$$

در این معادله، a, b, c پارامترهای مورد استفاده در مدل بوده و در آن حداکثر مقادیر ۱ و حداقل آن صفر در نظر گرفته شده است.

لایه‌ی ۲: هر گره این لایه با برچسب Π نشان داده شده و داده‌های ورودی در آن به صورت زیر پردازش می‌شوند:

$$o_{3,1} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1,2, \quad (12)$$

لایه‌ی ۳: i امین گره این لایه با برچسب N نشان داده شده و از طریق فرمول زیر برآورد می‌گردد:

$$o_{3,1} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1,2, \quad (13)$$

لایه‌ی ۴: در این لایه، داده‌ها از طریق معادله زیر پردازش می‌شوند:

$$o_{4,1} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad (14)$$

لایه‌ی ۵: گره‌ها در این لایه با برچسب Σ نشان داده شده و در آن با جمع تمام داده‌های ورودی، خروجی نهایی برآورد می‌گردد.

$$o_{5,i} = \sum \bar{w}_i f_i = \frac{\sum w_i f_i}{\sum w_i}, \quad (15)$$

پارامتر R^2 تشریح‌کننده‌ی روابط بین مقادیر مشاهداتی و پیش‌بینی شده بوده و پارامتر RMSE به بررسی مقادیر باقیمانده بین مقادیر مشاهداتی و پیش‌بینی شده می‌پردازد. مقادیر RMSE از طریق معادله زیر برآورد می‌گردد:

معادله ۲۱:

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N [S_t \text{ measured} - S_t \text{ predicted}]^2},$$

تخمین بار معلق رسوبی با استفاده از مدل تبرید تدریجی عصبی (NDE)

برای تخمین بار معلق رسوبی رودخانه گیوی چای از ترکیب ورودی زیر استفاده شده است:

(i) Qr_t , (ii) Qr_t , Qr_{t-1} , (iii) Qr_t and Sr_{t-1} ; and (iv) Qr_t , Qr_{t-1} and Sr_{t-1}

در این ترکیب Qr_t و Sr_t به ترتیب دبی و بار معلق رسوبی در t روز می‌باشد. ساختار فوق از طریق کدهایی که در MATLAB نوشته شده، طراحی شده است. ساختارهای مختلف NDE از طریق آزمون و خطا برآورد و مناسب‌ترین ترکیب ورودی تعیین گردید. سپس مدل NDE تست شده و نتایج به دست آمده بوسیله فاکتور RMSE و R^2 مقایسه شد. مقادیر به دست آمده برای R^2 و RMSE در هر یک از ساختارهای ورودی در جدول ۲ نشان داده شده است. آخرین ترکیب ورودی مدل NDE دارای ۳ ند ورودی، ۲ ند پنهان و ۱ ند خروجی است. بر اساس نتایج به دست آمده مشاهده می‌شود که اولین ترکیب ورودی با برخورداری از خطای تبیین ۰/۹۵۸۶ و مجذور خطای میانگین مربعات معادل ۱۶۰ میلی‌گرم در لیتر از بهترین کارایی در تخمین بار معلق رسوبی برخوردار است.

به دست می‌آید و فرمول کلی آن به صورت زیر می‌باشد:

معادله ۱۸:

$$r_j = \|y - Y^j\| = \left[\sum_{i=1}^m (y_i - w_{ij})^2 \right]^{1/2},$$

تابع انتقالی مناسبی که برای تخمین r_j به کار برده می‌شود، از طریق رابطه زیر به دست می‌آید:

$$\phi(r_j) = \phi(\|y - Y^k\|),$$

معادله ۱۹:

نهایتاً لایه‌ی خروجی، یک ترکیب خطی وزن‌دار می‌باشد که از طریق معادله‌ی زیر محاسبه می‌گردد:

معادله ۲۰:

$$\bar{y}(x) = \sum_{j=1}^n c_j^k \phi(r_j) = \sum_{i=1}^n c_i^k = \phi(\|y - Y^k\|),$$

بحث

ارزیابی مدل

برخی از روش‌های ارزیابی از قبیل ضریب همبستگی (p) ، ضریب تبیین (R^2) ، مجموع خطای مربعات و خطای مجذور ریشه مربعات (RMSE) توسط لیگیت و همکاران بطور کامل تشریح شده‌اند. آنها عنوان می‌کنند که برای ارزیابی کامل کارایی مدل بایستی دست‌کم یک شاخص اندازه‌گیری خطای نسبی به عنوان مثال (R^2) و یک شاخص اندازه‌گیری خطای مطلق از قبیل (RMSE) به کار گرفته شود (Legates et al, 1999:233-241).

نش و همکاران عنوان می‌کنند که مدل R^2 که در محدوده‌ی بی‌نهایت تا ۱ قرار می‌گیرد برای داده‌های بزرگتر به نتایج بهتری دست می‌یابد (Nash et al, 1970:282-290).

در این مقاله برای ارزیابی کارایی مدل از فاکتورهای R^2 و RMSE بهره گرفته شده است. بطور خلاصه اگر R^2 و RMSE به ترتیب نزدیک یک و صفر باشند مدل از کارایی بهتری برخوردار است.

جدول ۲: مقادیر RMSE و R^2 هر یک از ساختارهای مدل NDE

R^2	RMSE (mg/l)	ساختارهای NDE	ورودی‌های مدل NDE
۰/۹۵۸۶	۱۶۰	NDE(1,3,1)	Qr_t
۰/۹۲۶۷	۱۷۸	NDE(2,2,1)	Qr_t and Qr_{t-1}
۰/۸۹۵۳	۱۹۲	NDE(2,2,1)	Qr_t and Sr_{t-1}
۰/۹۱۳۱	۱۸۴	NDE(3,2,1)	Qr_t , Qr_{t-1} and Sr_{t-1}

مأخذ: مطالعات میدانی نگارندگان، ۱۳۹۱

مقایسه‌ی مدل‌های مختلف استفاده شده با مدل NDE

در دومین بخش از تحقیق، به منظور ارزیابی قابلیت مدل NDE نسبت به مدل ANFIS و RBF مقایسه‌ای بین آنها صورت گرفت. لیکن قبل از ورود داده‌ها به مدل‌های شبکه‌ی عصبی مصنوعی بایستی پیش‌پردازشی انجام گیرد به این منظور داده‌ها کران‌دار می‌شوند (Goh, 1995:143-151; Master, 1993:426). به این منظور داده‌ها از طریق معادله‌ی زیر در محدوده‌ی ۰/۰۱ تا ۰/۹۹ قرار می‌گیرند.

$$x_s = \frac{0.99(x_i - x_{min})}{(x_{max} - x_{min})} + 0.01, \quad \text{معادله ۲۲}$$

در این معادله، x_s داده‌های ورودی مقیاس‌گذاری شده بوده و x_i و x_{min} به ترتیب داده‌های غیر-مقیاس‌گذاری شده، داده‌های حداقل و حداکثر می‌باشند. پس از این فرایند برای مدل RBF کدی در جعبه ابزار شبکه عصبی MATLAB نوشته شده و ساختارهای ورودی متفاوت با استفاده از فرایند آزمون و خطا تعیین گردید. در مدل RBF شمار متفاوتی از نورون‌های لایه‌ی پنهان و پارامتر بسط یافته آزمون شدند. تعداد لایه‌ی پنهان و پارامتر بسط یافته پس از آزمون شمار متفاوتی از لایه‌های ورودی برای مدل RBF به ترتیب معادل ۱۷ و ۰/۳۹ تعیین گردید. برای مدل ANFIS نیز کدی در جعبه‌ابزار فازی MATLAB

نوشته شد. با استفاده از این کد، ساختارهای ورودی متفاوتی از طریق آزمون و خطا تعیین شد. سپس نتایج به دست آمده برای مدل در هر ساختار ورودی با استفاده از پارامترهای آماری R^2 و RMSE مورد مقایسه قرار گرفت. مقادیر فوق در جدول ۳ نشان داده شده است.

مقادیر به دست آمده پس از مقایسه‌ی مدل‌های NDE، ANFIS و RBF در جدول ۴ نمایش داده شده است. مقایسات صورت گرفته نشان می‌دهد که مدل NDE با مقادیر RMSE و R^2 به ترتیب ۱۶۰ میلی‌گرم در لیتر و ۰/۹۵۸۶ به بهترین نتیجه دست یافته است. مقادیر مشاهداتی و پیش‌بینی شده برای هر یک از مدل‌ها نیز در قالب هیدروگراف و نمودار پراکنش نشان داده شده است. از بررسی نمودارها نیز می‌توان چنین عنوان کرد که مدل NDE نسبت به سایر مدل‌ها از کارایی بهتری برخوردار است.

مقادیر حداکثر بار رسوبی تخمین زده شده توسط هر یک از مدل‌ها نیز در جدول ۵ نشان داده شده است. در کل، در تخمین مقادیر حداکثر رسوبی مدل NDE و ANFIS نسبت به مدل RBF به نتایج بهتری دست یافته‌اند. مدل‌های NDE، ANFIS و RBF مقادیر حداکثر بار رسوبی را به ترتیب ۶۵۴۹، ۶۱۰۱ و ۵۹۸۲ برآورد کرده و مقادیر فوق را معادل ۱۰،۱۶ و ۱۸ درصد کمتر از مقادیر مشاهداتی تخمین زده‌اند.

مقادیر مجموع بار معلق رسوبی نیز به علت اهمیت آن در مدیریت منابع آبی، تخمین زده شده‌اند. مقادیر مجموع بار رسوبی تخمین زده شده برای دوره‌ی آزمایشی در جدول ۶ نشان داده شده است. مقادیر فوق توسط مدل‌های NDE، ANFIS و RBF، به ترتیب حدود ۴۷، ۵۵ و ۷۱ درصد کمتر از مقادیر مشاهداتی (۱۰۶۹۲۲ تن) برآورد گردیده است. مدل NDE در تخمین مقادیر کل بار معلق رسوبی نسبت به سایر

معادله ۳۷ نشان می‌دهد که با افزایش مقدار K مقدار AIC افزایش می‌یابد لیکن اگر مقادیر RMSE کمتر از سایر مدل‌ها باشد مقادیر AIC کمتر خواهد بود. مقادیر AIC برای دوره تست شده در جدول ۷ نشان داده شده است. جدول ۷ نشان می‌دهد که NDE در حوضه رودخانه گیوی چای دارای کمترین مقادیر AIC است.

مدل‌ها به نتایج بهتری دست یافته است. در نهایت برای ارزیابی قابلیت مدل‌های NDE، ANFIS و RBF از سیستم اطلاعاتی آکائیک استفاده شد. معادله مربوط به آکائیک به صورت زیر می‌باشد:

$$\text{معادله ۲۳: } AIC = N \times \ln(RMSE) + 2k,$$

در اینجا N تعداد نمونه‌ها در مجموعه‌ی آزموده شده و K تعداد پارامترهای مدل یا وزن داده‌ها می‌باشد (Akaike, 1974:716-723).

جدول ۳: مقادیر RMSE و R² هر یک از ساختارهای مدل ANFIS

R ²	RMSE(mg/l)	ساختارهای مدل ANFIS	ورودی‌های مدل ANFIS
۰/۹۱۵۲	۲۲۷	۲	Qr _t
۰/۹۰۲۴	۲۴۹	۳ و ۲	Qr _t and Qr _{t-1}
۰/۸۶۲۹	۲۷۱	۲ و ۲	Qr _t and Sr _{t-1}
۰/۸۷۳۲	۲۶۵	۳ و ۲ و ۲	Qr _t , Qr _{t-1} and Sr _{t-1}

مأخذ: مطالعات میدانی نگارندگان، ۱۳۹۱

جدول ۴: کارایی مدل‌های NDE، ANFIS و RBF در دوره‌ی آزمایشی

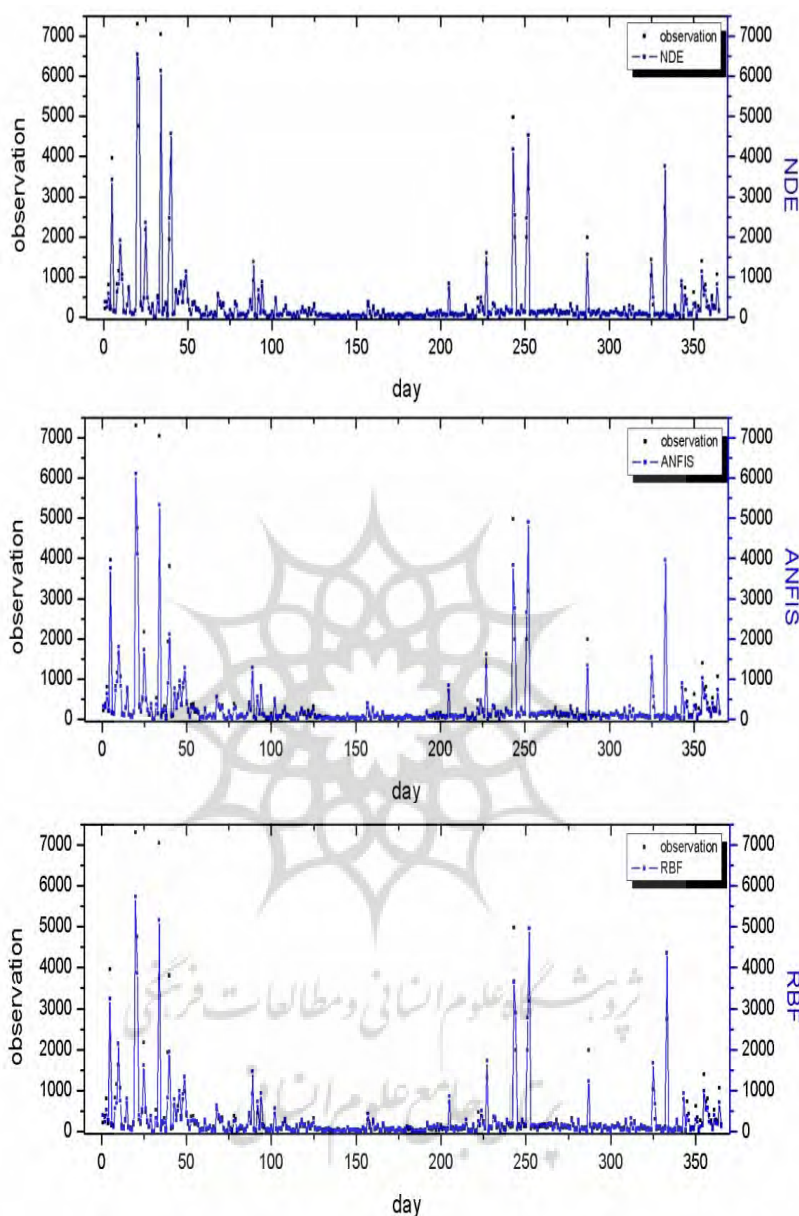
مدل‌ها	NDE	ANFIS	RBF
RMSE(mg/l)	۱۶۰	۲۲۷	۲۶۰
R ²	۰/۹۵۸۶	۰/۹۱۵۲	۰/۸۸۷۲

مأخذ: مطالعات میدانی نگارندگان، ۱۳۹۱

جدول ۵: مقایسه‌ی حداکثر بار معلق رسوبی تخمین زده شده توسط هر یک از مدل‌ها در دوره‌ی آزمایش شده

مقادیر خطای نسبی بر حسب درصد			RBF	ANFIS	NDE	حداکثر بار معلق رسوبی مشاهده شده بیش از ۳۰۰۰ میلی گرم
RBF	ANFIS	NDE				
-۱۸	-۱۶	-۱۰	۵۹۸۲	۶۱۰۱	۶۵۴۹	۷۳۰۰
-۲۶	-۲۴	-۱۲	۵۱۵۳	۵۳۲۵	۶۱۳۲	۷۰۳۶
-۲۶	-۲۳	-۱۶	۳۶۵۴	۳۸۲۵	۴۱۷۶	۴۹۷۷
-۱۷	-۱۳	۲۵	۳۹۲۷	۴۱۰۲	۵۹۳۷	۴۷۴۳
-۱۸	-۱۳	-۵	۳۲۴۵	۳۴۲۱	۳۷۴۹	۳۹۷۰
-۴۸	-۴۴	۲۰	۱۹۴۵	۲۱۰۹	۴۵۷۶	۳۸۰۶
۱۰	۹	۶	۳۴۹۶	۳۴۶۷	۳۳۸۹	۳۱۷۷

مأخذ: مطالعات میدانی نگارندگان، ۱۳۹۱



شکل ۳: مقایسه‌ی مقادیر مشاهداتی و پیش‌بینی شده هر یک از مدل‌ها در دوره‌ی آزمایشی
 مأخذ: مطالعات میدانی نگارندگان، ۱۳۹۱

جدول ۶: مقایسه مجموع مقادیر بار معلق رسوبی تخمین زده شده
 توسط هر یک از مدل‌ها در دوره‌ی آزمایشی

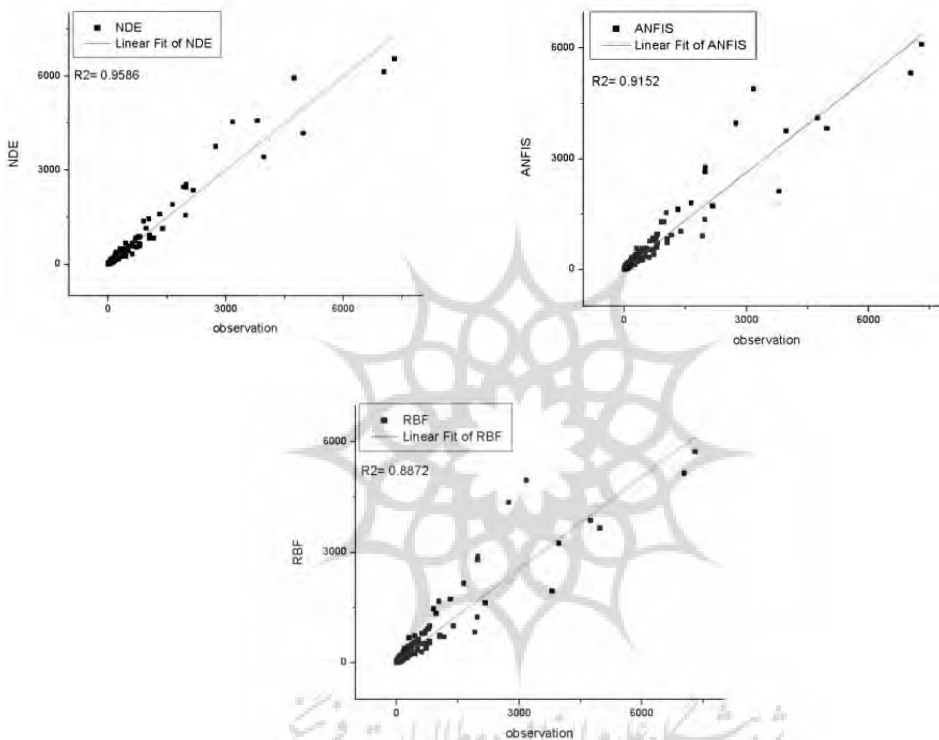
RBF	ANFIS	NDE	مقادیر مشاهداتی	
۱۸۳۶۲۹	۱۶۵۹۹۹	۱۵۷۳۳۹	۱۰۶۹۲۲	مقادیر پیش‌بینی شده
-۷۱	-۵۵	-۴۷		خطای نسبی

مأخذ: مطالعات میدانی نگارندگان، ۱۳۹۱

جدول ۷: مقادیر آکائیک برای هر یک از مدل‌های مورد استفاده

مدل‌ها	RMSE(mg/l)	k	AIC
NDE	۱۶۰	۷	۱۸۶۶
ANFIS	۲۲۷	۹	۱۹۹۸
RBF	۲۶۰	۱۱	۲۰۵۱

مأخذ: مطالعات میدانی نگارندگان، ۱۳۹۱



شکل ۴: نمودار پراکنش مدل‌های مورد استفاده در پیش‌بینی بار معلق رسوبی برای دوره آزمایشی

مأخذ: مطالعات میدانی نگارندگان، ۱۳۹۱

غیرخطی است. این مدل‌ها از مدل پس‌پراکنش برای تنظیم پارامترهای توابع عضویت استفاده می‌کنند (Jang, 1993:665-685). در مدل پس‌پراکنش فرایند تعلیم و به دام انداختن داده‌های حداقل به آسانی صورت می‌پذیرد (Kumar et al, 2002:224-233). الگوریتم تبرید تدریجی باعث ادغام داده‌های تصادفی شده و بنابراین از بیشترین توانایی نسبت به مدل‌های عصبی برخوردار بوده و بدون تاثیر داده‌های حداقل به بهینه‌سازی

در کل مدل NDE ترکیبی از دو مدل ANN و DE بوده و نسبت به مدل‌های ANFIS و RBF از قابلیت بالایی در برقراری روابط بین دبی و بار معلق رسوبی برخوردار است. مدل‌های منحنی سنج رسوبی بین مقادیر لگاریتم رسوب و دبی رابطه رگرسیون خطی برقرار می‌کند. بنابراین این مدل‌ها نیازمند توزیع نرمال داده هستند. این امر یکی از ضعف‌های اصلی این مدل‌هاست. قابلیت اصلی مدل‌های ANFIS و ANN انعطاف‌پذیری و توانایی مدل در برقراری روابط

منابع

- دهقانی، امیراحمد؛ محمدابراهیم زنگانه؛ ابوالفضل مساعدی؛ نسرين کوهستانی (۱۳۸۸). مقایسه تخمین بار معلق به دو روش منحنی سنج رسوب و شبکه‌ی عصبی مصنوعی، علوم کشاورزی و منابع طبیعی ۱۶. صفحات ۵۱-۳۶.

- دهقانی، امیراحمد؛ محمدملک محمدی؛ ابوطالب هزارجریبی (۱۳۸۹). تخمین رسوب معلق رودخانه بهشت‌آباد با استفاده از شبکه عصبی مصنوعی، پژوهش‌های حفاظت آب و خاک. ۱۷. صفحات ۱۶۸-۱۵۹.

- Akaike, H (1974). A new look at the statistical model identification. IEEE Trans. Automat. Control 19(6), 716-723.
- Bathurst, J.c (1996). SHESED: a physically based, distributed erosion and sediment yield component for the SHE hydrological modeling system. J. Hydrol. 175, 213-238.
- Bhattacharya B, price R, Solomatine D (2005). Data-driven modeling in the context of sediment transport. Phys chem. Earth 30: 297-302.
- Cigizoglu, H.K. & Kisi, O (2005). Flow prediction by three back propagation techniques using k- fold partitioning of neural network training data. Nordic Hyrol. 36(1): 1-16.
- Cigizoglu, H. K., Kisi, O (2006). Methods to improve the neural network performance in suspended sediment estimation. Journal of hydrology 317, 221- 238.
- Gautam, M.R., K. Watanabe and H. Saegusa (2000). Runoff analysis in humid forest catchment with artificial neural network. Journal of Hydrology, 235(1-2): 117-136.
- Goh, A.T.C (1995). Back-propagation neural networks for modeling complex systems. Artificial intelligence in Engineering 9, 143-151.
- Guldal, V. & Muftuglu, R.F (2001). 2D unit sediment graph theory. J. Hydrol. Engng 6(2), 132-140.
- Jain, S.K (2001). Development of integrated sediment rating curves using ANNs. Journal of hydraulic Engineering, ASCE 127(1), 30-37.
- Jang, J (1993). ANFIS: adaptive- network-based fuzzy inference system. IEEE Transactions on systems, Man and cybernetics 23(3), 665-685.

داده‌ها می‌پردازد (Mantoglu et al, 2004:209-228)؛ Karterakis et al, 2007:270-282). این امر قابلیت مدل NDE را در تخمین بار معلق رسوبی نشان می‌دهد (Stom&Price, 1995:346; Stom&Price, 1997:341-359).

نتیجه

در این تحقیق، بار معلق رسوبی رودخانه‌ی گیوی جای با استفاده از مدل‌های تبرید تدریجی عصبی (NDE)، سیستم استنتاجی فازی عصبی (ANFIS) و مدل تابع پایه شعاعی (RBF) برآورد شده و در آنها ترکیب‌های مختلفی از متغیرهای هیدرولوژیکی از قبیل دبی و بار معلق رسوبی روزهای پیشین مورد استفاده قرار گرفت. در اولین مرحله از تحقیق، چندین ترکیب ورودی متشکل از دبی روزانه و بار معلق رسوبی روزهای پیشین به عنوان ورودی مدل NDE به کار برده شدند. بررسی‌ها نشان داد که مدل NDE با برخورداری از ۱ لایه‌ی ورودی، ۳ لایه‌ی پنهان و ۱ لایه‌ی خروجی از مقادیر ضریب تبیین (R^2) معادل ۰/۹۵۸۶ و RMSE معادل ۱۶۰ میلی‌گرم در لیتر برخوردار است. در دومین بخش از تحقیق، مدل NDE با مدل‌های ANFIS و RBF مقایسه شدند.

نتایج نشان داد که مدل NDE نسبت به مدل‌های استفاده شده در این تحقیق به نتایج بهتری دست می‌یابد. بعد از تخمین بار معلق رسوبی و مقایسه‌ی نتایج مربوط به هر مدل، مقادیر حداکثر بار رسوبی که در بازه‌ی بالاتر از ۳۰۰۰ میلی‌گرم در لیتر قرار دارد مورد بررسی قرار گرفته و با استفاده از پارامتر آماری خطای نسبی (RE) مورد بررسی قرار گرفتند. نتایج دلالت بر کارایی بهتر مدل NDE در تخمین حداکثر بار معلق رسوبی دارد. در نهایت برای تعیین قابلیت پارامتر RMSE در صحت‌سنجی هر یک از مدل‌ها، از سیستم اطلاعاتی آکائیک (AIC) استفاده شده و مشاهده شد که مدل NDE با برخورداری از مقادیر آکائیک معادل ۱۸۹۹ از قابلیت بهتری برخوردار است.

- Lohani, a.K., Goel, N.K., Bhatia, K.K.S (2007). Deriving Stage- discharge- sediment concentration relationships using fuzzy logic. *Hydrological sciences Journal* 52(4), 793-807.
- Mc Bean, E.A., Al- Nassri, S (1988). Uncertainty in suspended sediment transport curves, *Journal of hydrologic Engineering ASCE* 114(1), 63-74.
- Mantoglu, A., Papantoniou, M., Giannouloupoulos, P (2004). Management of coastal aquifers based on nonlinear optimization and evolutionary algorithms. *J. Hydrol.* 297(1-4), 209-228.
- Masters, T (1993). *Practical Neural network Recipes C++*. Academic press, San Diego, California, USA. pp: 498.
- Nakato, T (1990). Test of selected sediment-transport Formulas. *J. of hydro. Engrg., ASCE*, 116(3), 362-379.
- Nash JE, Sutcliffe JV (1970). River flow forecasting through conceptual models part I-a discussion of principles. *J hydrology*: 10(3): 282-90.
- Ocampo- Duque W, Schuhmacher M, Domingo JL (2007). A neural fuzzy approach to classify the ecological status in surface waters. *Environ pollut.* 148:634-41.
- Ozturk, F., Apaydin, H., & Walling, D.E (2001). Suspended sediment loads through Flood events for streams of sakarya Basin. *Turkish J. Eng. Env. TUBITAK* 25, 643-650.
- Raghuvanshi N, Singh R, Reddy L (2006). Runoff and sediment yield modeling using artificial neural networks: upper Siwane River, India. *J Hydrol Eng*; 11(1): 71-9.
- Refsgaard, J. (1997). parameterization, calibration and validation of distributed hydrological models. *J. Hydrol.* 198, 69-97.
- Storn, R., Price, K.V (1995). Differential Evolution- A simple and Efficient Adaptive scheme for Global optimization over continuous spaces, *Technical Report, TR-95-012, ICSI, March*. Pp: 375.
- Storn, R., Price, K.V (1997). Differential evolution- a simple and efficient heuristic for global optimization and continuous space. *J. Global optim.* 11(4), 341-359.
- Karterakis, S.M., Karatzas, g.P., nikolos, I.K., Papadopoulou, M.P (2007). Application of linear programming and differential evolutionary optimization methodologies for the solution of coastal subsurface water management problems subject to environmental criteria. *J. Hydrol.* 342(3-4), 270-282.
- Kisi, O (2004). Multi- layer perceptrons with Levenberg- marquardt optimization algorithm for suspended sediment concentration prediction and estimation. *Hydrological Sciences Journal* 49(6), 1025-1040.
- Kisi, O (2005). Suspended sediment estimation using neuro- fuzzy and neural network approaches. *Hydrological Sciences Journal* 50(4), 683-696.
- Kisi, O., Karahan, M.E., Sen, Z (2006). River suspended sediment modeling using fuzzy logic approach. *Hydrological processes* 20(20), 4351-4362.
- Kisi, O, Yuksel, I., Dogan, E (2008). Modeling daily suspended sediment of rivers in Turkey using several data driven techniques. *Hydrol. Sci. J.* 53(6), 1270-1285.
- Kumar, M., Raghuvanshi, N.S., Singh, R., Wallender, W.W., Pruitt, W.O (2002). Estimating evapotranspiration using artificial neural network. *J. Irrig. Drain. Eng.* 128(4), 224-233.
- Lampinen, J, Zelinka, I (2000). On stagnation of the differential evolution algorithm. In: Osmera, Pavel (Ed), *proceedings of MENDEL 200, 6th international mendel conference on soft computing, June 7-9 2000, Brno, Czech Republic*. Brno university of Technology, Faculty of Mechanical Engineering, Institute of Automation and computer science, Brno, Czech Republic, PP. 76-83.
- Lampinen, J (2001). Solving problems subject to multiple non linear constraints by the differential evolution. In: *proceeding of MENDEL 2001, 7th international conference on soft computing, June 6-8 2001, brno, Czech Republic*, Brno university of technology, faculty of Mechanical engineering, Institute of Automation and computer science, brno, Czech republic, PP. 50-57. ISBN 80-214-1894-x.
- Legates DR, Mc Cabe JrGJ (1999). Evaluating the use of goodness- of- fit measures in hydrologic and hydro climatic model validation. *Water resour Res.* 35(1): 233-41.

- Sudheer, K.P., Gosain, A.K., Ramasastry, K.S (2003). Estimating actual evapotranspiration from limited climatic data, using neural computing technique. *J.Irrig.Drain. Eng, ASCE* 129(3),214-218.
- Tayfur, G (2002). Artificial neural networks for sheet sediment transport. *Hydrol.Sci.J.*47(6),879- 892.
- Tayfur, G., Ozdemir, S., Singh, V. P (2003). Fuzzy logic algorithm for runoff-induced sediment transport from bare soil surfaces. *Advances in water Resource* 26(12), 1249-1256.
- Tayfur, G., Guldal, V., 2006. Artificial neural networks for estimating daily total suspended sediment in natural streams, *Nordic Hydrology* 37, 69-79.
- Zounemat-Kermani M, Teshnehlab M (2008). Using adaptive neuro-fuzzy inference system for hydrological time series prediction. *Appl soft comput*; 9:28-36.
- Zounemat-Kermani M, Beheshti AA, Ataie-Ashtiani B, Sabbagh-Yazd SR (2009). Estimation of current-induced scour depth around pile groups using neural network and adaptive neuro-fuzzy inference system. *Appl soft comput.* 9: 746-55.

