

تعیین مناسب‌ترین روش منحنی سنجه و مقایسه آن با شبکه عصبی مصنوعی به منظور برآورد رسوبات معلق (مطالعه موردی: استان لرستان)

❖ محسن یوسفی*؛ کارشناس ارشد آبخیزداری، دانشکده منابع طبیعی و کویرشناسی، دانشگاه یزد، ایران
❖ فاطمه برزگری؛ عضو هیئت‌علمی دانشکده کشاورزی دانشگاه پیام نور، ایران

چکیده

برآورد میزان رسوبات معلق در رودخانه‌ها از ابعاد مختلف کشاورزی، حفاظت خاک، سدسازی، حیات آبریان، و همچنین جنبه‌های مختلف تحقیقاتی اهمیت فراوانی دارد. روش‌های مختلفی برای بررسی و برآورد رسوبات معلق رودخانه‌ها وجود دارد که البته توانایی این روش‌ها در برآورد رسوبات متفاوت است. هدف از این مطالعه برآورد رسوبات معلق رودخانه با استفاده از شبکه عصبی پیش‌خور پس‌انتشار خطا با الگوریتم آموزشی لونیبرگ-مارکوارت و مقایسه نتایج با بهترین ترکیب منحنی سنجه رسوب و ضرایب اصلاحی است. در این مطالعه از آمار دبی و رسوب متناظر ده ایستگاه استان لرستان به صورت روزانه، ماهانه، فصلی، و دسته‌بندی‌شده استفاده شد. نتایج نشان داد از بین انواع مختلف منحنی سنجه و ضرایب اصلاحی استفاده‌شده، که جمعاً شامل بیست ترکیب بود، ترکیب منحنی سنجه ماهانه و ضرایب اصلاحی MUVE بر اساس ضریب ناش-ساتکلیف و شاخص دقت مناسب‌تر است. در مرحله بعد، نتایج حاصل از برآورد رسوب با مناسب‌ترین منحنی سنجه با نتایج حاصل از شبکه عصبی با استفاده از ضریب ناش-ساتکلیف و مجذور میانگین مربعات خطا مقایسه شد. نتایج نشان‌دهنده مناسب‌بودن شبکه عصبی پیش‌خور پس‌انتشار خطا در قیاس با منحنی سنجه رسوب است.

واژگان کلیدی: الگوریتم لونیبرگ-مارکوارت، رسوبات معلق، شبکه عصبی، منحنی سنجه.

مقدمه

فرایند رسوب‌گذاری در شبکه رودخانه‌ها پیامدهایی همچون ایجاد جزایر رسوبی در مسیر رودخانه‌ها و در نتیجه کاهش ظرفیت انتقال جریان‌های سیلابی، کاهش عمر مفید سدها و ظرفیت ذخیره مخازن، خوردگی تأسیسات سازه‌های رودخانه‌ای و وارد شدن خسارات به ابنیه آبی و مزارع، و بسیاری مشکلات دیگر را در بر دارد [۱]. به منظور اجرای برنامه‌های حفاظت خاک و کاهش رسوب‌زایی و همچنین محاسبه و طراحی دقیق حجم سدهای رسوب‌گیر و مخزنی، اطلاع از میزان رسوب تولیدی یک حوضه آبخیز ضرورت دارد [۱]. از طرفی، پدیده فرسایش و انتقال رسوب از پیچیده‌ترین مسائل هیدرودینامیکی است که تعیین دقیق معادلات حاکم بر آن به دلیل تأثیر پارامترهای مختلف به‌آسانی میسر نیست. پارامترهای متعدد دخیل در تولید و انتقال رسوبات معلق رودخانه‌ای به همراه پیچیدگی‌های زیاد و روابط غیرخطی بین این پارامترها با یکدیگر و همچنین با ورودی‌ها و خروجی‌های سیستم آبخیز باعث شده پیش‌بینی دقیق مقدار رسوب معلق بسیار مشکل باشد. در دهه‌های گذشته، به دلیل وجود چنین مشکلاتی، هیدرولوژیست‌ها و محققان سعی کرده‌اند مدل‌های ساده‌شده و تجربی را برای پیش‌بینی و محاسبه خصوصیات مختلف و مهم حوضه‌های آبخیز مانند رسوب و رواناب و غیره به‌کار گیرند. منحنی سنجه رسوب از جمله این روش‌هاست که به‌وفور در دهه‌های اخیر در مطالعات مربوط به این زمینه به‌چشم می‌خورد، از جمله این مطالعات می‌توان به برخی مطالعات [۲، ۴، ۱۸، ۲۸، ۲۹] اشاره کرد. در دهه‌های اخیر در زمینه مدل‌سازی

طبیعت پیشرفت‌هایی انجام پذیرفته و سعی شده از روش‌هایی استفاده شود که شرایط طبیعی را تا حدودی درک کنند. یکی از روش‌هایی که در بسیاری از علوم از جمله هیدرولوژی گسترش یافته کاربرد روش‌های محاسبات نرم نظیر شبکه‌های عصبی مصنوعی است. شبکه‌های عصبی توانایی خوبی در شبیه‌سازی پدیده‌های پیچیده و غیرخطی در زمینه‌های مختلف نشان داده‌اند. در مدل‌سازی رسوب معلق نیز، همان‌گونه که ذکر شد، پیچیدگی‌های خاصی وجود دارد و روش‌های تجربی ساده اغلب قادر به شبیه‌سازی مناسب آن نیستند. بنابراین، ارزیابی روش‌هایی چون شبکه عصبی در این پدیده و مقایسه آن با روش‌های ساده موجود می‌تواند به حل این مشکل کمک کند. از جمله مطالعات انجام‌یافته در این زمینه می‌توان موارد زیر را برشمرد:

در مطالعه‌ای در حوضه خوارستان، اولویت شبکه عصبی مصنوعی در برآورد بار معلق نسبت به منحنی سنجه رسوب تأیید شد [۲۷]. به منظور برآورد رسوبات معلق در حوضه آبخیز جامیشان استان کرمانشاه از شبکه عصبی مصنوعی استفاده شد. نتایج نشان داد شبکه عصبی مصنوعی نتایج قابل قبولی برای شبیه‌سازی بار معلق ارائه می‌کند و در مقایسه با منحنی سنجه رسوب از دقت بسیار زیادی برخوردار است [۱]. بر اساس نتایج مطالعه‌ای در زمینه بررسی غلظت رسوب معلق در رودخانه کرخه با استفاده از شبکه عصبی بهترین روش آموزش شبکه عصبی الگوریتم لونیگ-مارکوآرت و بهترین ساختار شبکه دو لایه میانی با سه نرون در هر لایه معرفی شد [۱۵]. در تحقیقی به منظور برآورد بار معلق رودخانه آجی‌چای از زمین‌آمار و شبکه عصبی مصنوعی استفاده شد؛ بر

شبکه عصبی مصنوعی استفاده شده است، تنها شکل متداول منحنی سنجه، یعنی منحنی سنجه یک خطی و روش دسته‌بندی داده‌ها، مبنای مقایسه قرار گرفته است که خالی از اشکال نیست. بنابراین، در تحقیق حاضر مناسب‌ترین منحنی سنجه از بین انواع منحنی سنجه رسوب روزانه، فصلی، ماهانه، و حد وسط دسته‌ها انتخاب و با اعمال ضریب اصلاحی مناسب ارتقا داده شد. سپس، در مقایسه با شبکه عصبی بررسی شد.

۲. روش‌شناسی

۱.۲. موقعیت منطقه مورد مطالعه

استان لرستان در غرب ایران در محدوده جغرافیایی $۲۲^{\circ} ۵۱'$ تا $۴۶^{\circ} ۳۰'$ طول شرقی و $۳۷^{\circ} ۳۲'$ تا $۲۲^{\circ} ۳۴'$ عرض شمالی قرار گرفته است. به منظور اجرای این تحقیق از آمار دبی و رسوب متناظر ده ایستگاه هیدرومتری واقع در محدوده مورد مطالعه استفاده شد. شکل ۱ نشان‌دهنده موقعیت منطقه و جدول ۱ بیانگر مشخصات ایستگاه‌های مورد مطالعه است.

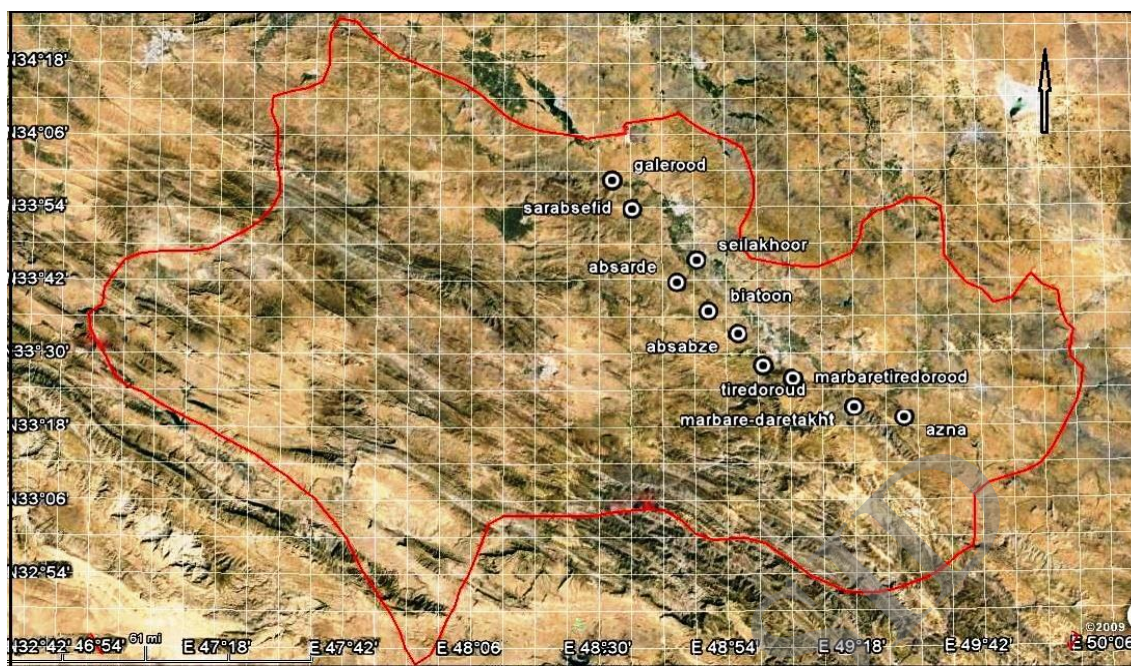
۲.۲. تهیه و تدوین داده‌های مورد بررسی در

مطالعه

در این مطالعه از داده‌های دبی به عنوان ورودی و رسوب به عنوان خروجی مدل‌ها استفاده شد. داده‌های رسوب ایستگاه‌ها در بازه زمانی ۱۳۷۵ - ۱۳۸۵ به صورت روزانه، ماهانه، حد وسط دسته‌ها (دسته‌بندی شده)، و فصلی استفاده شد. ۷۰ درصد داده‌ها به عنوان داده‌های آموزش و ۳۰ درصد به منظور آزمون مدل در نظر گرفته شد [۱].

اساس نتایج این مطالعه، هر دو مدل کریجینگ و کوکریجینگ در منطقه مورد مطالعه جوابگو بودند و روش کوکریجینگ در مقایسه با روش کریجینگ در برآورد مکانی بار معلق ماهانه نتایج بهتری ارائه کرد [۳۰]. به منظور مقایسه کارایی مدل‌های شبکه عصبی مصنوعی و رگرسیون در پیش‌بینی بار رسوب جریان در حوضه آبخیز سمندگان مطالعه‌ای انجام شد؛ نتایج آن نشان داد چنانچه پارامترهای ژئومورفولوژیکی نظیر شاخص ناهمواری، شاخص گردی، و شاخص تراکم زه‌کشی در مدل‌سازی وارد شوند، نتایج ارزیابی آن‌ها مناسب‌تر می‌شود [۳۱]. برتری شبکه عصبی مصنوعی نسبت به منحنی سنجه رسوب در برآورد بار معلق رودخانه در حوضه رودخانه بهشت‌آباد نیز گزارش شده است [۱۱]. این دو روش (منحنی سنجه رسوب و شبکه عصبی مصنوعی) در رودخانه دوغ استان گلستان نیز به منظور برآورد رسوب معلق مقایسه و بررسی شد؛ نتایج این بررسی نیز مؤید ارجحیت شبکه عصبی مصنوعی نسبت به روش منحنی سنجه رسوب با و بدون دسته‌بندی داده‌هاست [۱۰].

در مطالعه دیگری برای برآورد بار معلق رودخانه کرج از منطق فازی و شبکه عصبی استفاده شد. نتایج این تحقیق بیانگر عملکرد مناسب‌تر منطق فازی نسبت به دو روش شبکه عصبی مصنوعی و منحنی سنجه رسوب است [۲۶]. در مطالعه‌ای برای برآورد رسوب معلق دو رودخانه در امریکا از شبکه عصبی مصنوعی، عصبی-فازی، رگرسیون غیرخطی، و منحنی سنجه رسوب استفاده شد؛ نتایج این بررسی نیز شبکه عصبی مصنوعی را نسبت به سایر روش‌ها مناسب‌تر نشان داد [۲۵]. بررسی تحقیقات پیشین بیانگر آن است که هرچند از مقایسه منحنی سنجه و



شکل ۱. موقعیت منطقه مورد مطالعه

جدول ۱. مشخصات ایستگاه‌های مورد مطالعه

ارتفاع حوضه (m)	مساحت حوضه (Km ²)	حداکثر رسوب (تن در روز)	عرض جغرافیایی	طول جغرافیایی	ایستگاه‌ها
۱۴۵۰	۳۴۰۰	۳۲۲۰,۳۳	۳۳-۲۸-۴۵	۴۵-۰۳-۴۹	تیره- درود
۱۴۵۰	۲۶۵۵	۱۲۴۱,۰۶۹	۳۳-۲۸-۲۸	۲۹-۰۴-۴۹	ماریره- دورود
۱۲۹۰	۳۴۵	۲۳۷۸,۸۴	۳۳-۳۳-۵۲	۳۱-۵۸-۴۸	آب سبزه
۱۸۰۰	۲۱۸۵	۱۹۰۹۸,۹۱	۳۳-۲۲-۴۰	۱۳-۲۳-۴۹	ماریره- دره تخت
۱۸۳۰	۲۰۱۰	۴۹۸,۲۳	۳۳-۲۴-۰۱	۱۰-۲۴-۴۹	ازنا
۱۵۷۰	۲۲۳	۱۶۲۳,۱۹	۳۳-۴۴-۱۴	۱۶-۴۵-۴۸	آبسرده
۱۴۹۰	۱۳۶۳	۱۳۱۱۷,۰۷	۰۰-۴۷-۳۳	۰۱-۴۸-۴۸	سیلاخور
۲۰۰۰	۶۰,۴	۳۰,۷۷	۴۹-۵۴-۳۳	۲۴-۳۵-۴۸	گله‌رود
۱۹۸۰	۶۴,۶	۳۷,۷۹	۱۵-۵۴-۳۳	۵۷-۳۵-۴۸	سراب سفید
۱۶۲۰	۱۲۰	۲۱۷,۷۴	۲۵-۴۲-۳۳	۵۵-۵۸-۴۸	بیاتون

پرداخته شد. به منظور استانداردسازی از رابطه ۱ در بازه ۰/۱ - ۰/۹ استفاده شد [۱۴].

(۱)

$$T = T_{\min} + (T_{\max} - T_{\min})(X - X_{\min}) / (X_{\max} - X_{\min})$$

به دلیل پراکنش زیاد داده‌های رسوب نسبت به داده‌های دبی، قبل از ورود این داده‌ها به شبکه عصبی، نخست به استانداردسازی داده‌های رسوب

انتخاب می‌شوند [۷، ۲۳]. شبکه‌های عصبی مصنوعی از جمله مدل‌های شبیه‌سازی است که می‌تواند با دقتی درخور توجه واقعیت‌های موجود را به تصویر بکشد و راهکار مناسبی برای برآورد و مدل‌سازی باشد [۱۷]. شکل ۲ نشان‌دهنده ساختار شبکه عصبی پیش‌خور پس‌انتشار خطاست.

۴.۲. الگوریتم لونبرگ-مارکوآرت


برای برآورد پارامترهای شبکه عصبی الگوریتم‌های زیادی وجود دارد. این الگوریتم‌ها به الگوریتم‌های آموزشی یا یادگیری معروف‌اند. الگوریتم پس‌انتشار لونبرگ-مارکوآرت از این جمله‌اند. الگوریتم پس‌انتشار دارای متغیرهای زیادی است و معمولاً الگوریتم لونبرگ-مارکوآرت نسبت به پس‌انتشار مؤثرتر است. این الگوریتم در مواقعی که از شاخص حداقل مربعات برای گزینش مدل‌ها استفاده می‌شود شاخص مناسبی است [۱۳]. ولی اشکال عمده روش لونبرگ-مارکوآرت نیاز آن به نگهداری ماتریس‌های حجیم در حافظه است که به فضای زیادی نیاز دارد [۱۶].

T مقادیر نرمال‌شده داده‌های واقعی، X داده‌های رسوب مشاهده‌شده واقعی، X_{\min} و X_{\max} کمینه و بیشینه داده‌های واقعی، و T_{\min} و T_{\max} بیشینه و کمینه داده‌های هدف است که در اینجا به ترتیب 0.9 و 0.1 است.

۳.۲. مدل شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی الگویی برای پردازش اطلاعات‌اند که با تقلید از شبکه عصبی بیولوژیکی مثل مغز انسان ساخته شده‌اند. عنصر کلیدی این الگو ساختار جدید سیستم پردازش اطلاعات آن است که از تعداد زیادی عنصر نورون با ارتباطات قوی داخلی، که هماهنگ با هم برای حل مسائل مخصوص کار می‌کنند، تشکیل شده است [۶].

روش شبکه عصبی مصنوعی دارای مزایایی در مقایسه با روش‌های آماری است [۵]. مثلاً، شبکه عصبی وابسته به چگونگی توزیع آماری داده‌ها نیست و به بررسی داده‌ها از لحاظ آماری و نرمال‌بودن داده‌ها نیازی ندارد. علاوه بر آن، روش شبکه عصبی مصنوعی برای آنالیز صحت داده‌ها به بررسی‌های کمتری در قیاس با روش‌های آماری نیاز دارد. متغیرهای آماری متناسب با داده‌ها در زمان کمتری



شکل ۲. شبکه عصبی پیش‌خور پس‌انتشار خطا

۵.۲. منحنی سنجه رسوب

بخش مهمی از مطالعات در زمینه رسوب معلق به استفاده از منحنی سنجه رسوب بازمی‌گردد. برای ترسیم منحنی سنجه رسوب از روش اداره اصلاح اراضی آمریکا^۱ استفاده می‌شود. در روش USBR با انتقال داده‌های هم‌زمان دبی جریان و غلظت رسوب معلق متناظر با آن بر روی صفحه مختصات لگاریتمی و رسم بهترین خط از بین ابر داده‌ها، بر مبنای روش حداقل مربعات، معادله‌نمایی منحنی سنجه رسوب به صورت رابطه ۲ به دست می‌آید [۱۸].

$$\varphi_s = a\varphi_w^b \quad (2)$$

که پارامترهای آن عبارت‌اند از:

φ_s غلظت رسوب بر حسب میلی‌گرم در لیتر یا تن در روز، φ_w دبی جریان بر حسب متر مکعب بر ثانیه، a و b ضرایب ثابت معادله.

اما، این رابطه به علت داشتن اریب در بیشتر مواقع نتوانسته غلظت رسوب در دبی‌های مختلف جریان را به خوبی نشان دهد [۲۴، ۳]. اریب در واقع باعث شده تا مقدار باقی‌مانده‌ها (اختلاف بین مقادیر مشاهده‌ای و محاسباتی) توزیع نرمالی نداشته باشد و مقدار آن بیشتر از صفر شود [۲۱]. اریب منحنی سنجه از دو عامل نشئت می‌گیرد: عامل اول، که مربوط به ذات منحنی سنجه است، به دلیل تغییر شکل معادله از حالت لگاریتمی به حالت طبیعی مدل رگرسیون خطی است؛ عامل دوم اریب ناشی از عمل برون‌یابی برای برآورد رسوب دبی‌های بالاست [۲، ۱۸، ۲۸]. متأسفانه، در اغلب ایستگاه‌های هیدرومتری به دلیل فقدان امکانات پیشرفته نمونه‌گیری فشرده سهم

نمونه‌گیری از دبی‌های بالا بسیار کم است که این مورد بر خطای روش مذکور می‌افزاید [۲، ۴، ۲۹]. برای اینکه رابطه سنجه رسوب برآورد دقیق‌تر و اریب کمتری نشان دهد محققان تا کنون روش‌های مختلفی به کار برده‌اند. در این زمینه ضرایب اصلاحی شامل $QMLE$ ، $Smearing$ ، FAO و $MVUE$ در راستای بهبود منحنی‌های سنجه پیشنهاد شده است [۲، ۴]. تعریف این ضرایب در پی می‌آید.

۶.۲. انواع منحنی سنجه رسوب و ضرایب

اصلاحی مربوط به آن‌ها

مدل یک‌خطی

در روش منحنی سنجه رسوب یک‌خطی، داده‌های موجود از اندازه‌گیری رسوب و دبی متناظر با آن به صفحه مختصات لگاریتمی منتقل می‌شود و بهترین خط برازش بر مبنای روش حداقل مربعات خطا از میان آن‌ها عبور داده می‌شود. سپس، یک رابطه رگرسیونی به صورت معادله توانی^۲ استخراج می‌شود که به منحنی سنجه رسوب یک‌خطی معروف است [۲، ۴].

مدل ماهانه

در این مدل برآورد رسوب معلق مشابه مدل یک‌خطی است، ولی داده‌ها در بازه زمانی ماهانه مطالعه می‌شود.

مدل فصلی

در این مدل برآورد رسوب معلق مشابه مدل خطی است، ولی داده‌ها در بازه زمانی فصلی مطالعه می‌شود.

2. power regression

1. United State Bureau of Reclamation (USBR)

مدل حد وسط داده‌ها

در این روش نخست دبی‌های جریان به تعدادی دسته (معمولاً ۱۰ تا ۱۲ دسته) تقسیم می‌شود و برای دبی متوسط هر دسته میانگین رسوب همان دسته تعیین می‌شود و منحنی سنجه رسوب با استفاده از میانگین دسته‌های دبی و میانگین دسته‌های رسوب متناظر با آن‌ها به دست می‌آید [۲، ۴، ۱۹، ۲۸]. در تحقیق حاضر برای برآورد رسوب معلق بر اساس مدل حد وسط دسته‌ها نخست دبی‌های جریان بر اساس دامنه تغییرات به دوازده دسته تقسیم شد و برای متوسط هر دسته دبی میانگین رسوب همان دسته تعیین شد.

ضریب اصلاحی فائو

روش فائو برای تعدیل ارقام و نزدیک کردن مقادیر محاسباتی به مقادیر مشاهده‌ای برای مناطق خشک و نیمه‌خشک مطرح شده است [۲۰]. در این روش ضریب α به عنوان فاکتور اصلاحی به صورت زیر جایگزین ضریب a در رابطه USBR شده است (رابطه ۳) [۲].

$$Q_s = \alpha Q_w^b \quad (3)$$

فاکتور اصلاحی α از رابطه ۴ به دست می‌آید.

$$\alpha = \frac{\bar{Q}_s}{\bar{Q}_w^b} \quad (4)$$

که در آن \bar{Q}_s میانگین دبی‌های رسوب نمونه‌های مشاهده‌ای (میلی‌گرم در لیتر یا تن در روز) و \bar{Q}_w میانگین دبی جریان نمونه‌های مشاهده‌ای (متر مکعب بر ثانیه) است.

ضریب اصلاحی پارامتری^۱

برای اصلاح خطای ناشی از تبدیل لگاریتمی داده‌ها، ضریب اصلاحی زیر پیشنهاد شده است (رابطه ۵) که s مقدار انحراف معیار داده‌هاست [۲۹].

$$CF_1 = \exp(2.65s^2) \quad (5)$$

ضریب اصلاحی غیرپارامتری

با توجه به این نکته که منحنی سنجه باعث برآورد کمتر مقدار رسوب می‌شود، فاکتور اصلاحی غیرپارامتری زیر موسوم به ضریب Smearing برای تصحیح مقدار رسوب ارائه شده است [۲۲] (روابط ۶ و ۷).

$$CF_2 = \frac{1}{n} \sum 10^{\epsilon_i} \quad (6)$$

$$\epsilon_i = \frac{1}{n} \log C_o - \log C_e \quad (7)$$

در این روابط، ϵ_i خطای برآورد، C_e غلظت رسوب برآوردی (تن در روز)، C_o غلظت رسوب مشاهده‌ای (تن در روز)، و n تعداد مشاهده‌ها است.

ضریب اصلاحی MVUE^۲

روابط ۸ تا ۱۰ مربوط به ضریب اصلاحی MVUE است.

$$V = \frac{1}{N} + \left[\frac{(\ln(Q_x) - Q_{\text{Bar}})^2}{Q_{\text{Var}}} \right] \quad (8)$$

$$g_{mi} = \left(\frac{m+1}{2m} \right) \left[(1-V)S^2 \right] \quad (9)$$

$$CF_{\text{MVUE}} = \left[\frac{\sum_{i=1}^n g_{mi}}{n} \right] \quad (10)$$

در روابط فوق، g_{mi} تابع فینی که در حقیقت نقش ضریب اصلاحی نمونه i را دارد. m درجه

1. QMLE
2. Minimum Variance Unbiased Estimator

$$P = \frac{\sum_{i=1}^n (SSC_o / SSC_e)_i}{n} \quad (12)$$

در روابط ۱۱ و ۱۲، n تعداد نمونه‌های رسوب مورد بررسی، SSC_e غلظت رسوب برآوردی، SSC_o غلظت رسوب مشاهده‌ای، SSC_m متوسط مقادیر مشاهده‌ای رسوب، P شاخص صحت، و NS معیار ناش - ساتکلیف است.

۸.۲. مقایسه منحنی سنجه منتخب و شبکه

عصبی

به منظور اعتبارسنجی نتایج حاصل از برآورد رسوب با منحنی سنجه منتخب در مرحله قبل و نتایج حاصل از برآورد رسوب با شبکه عصبی از معیار ناش ساتکلیف و مجذور میانگین مربعات خطا (RMSE) استفاده شد (روابط ۱۱ و ۱۳).

$$RMSE = \frac{\sum_{i=1}^n (SSC_o - SSC_e)_i}{n} \quad (13)$$

در رابطه ۱۳، n تعداد نمونه‌های رسوب مورد بررسی، SSC_o غلظت رسوب مشاهده‌ای، SSC_e غلظت رسوب برآوردی، و $RMSE$ مجذور میانگین مربعات خطاست. مقدار $RMSE$ همواره مثبت است و هر چه به صفر نزدیک‌تر باشد نشان‌دهنده عملکرد بهتر مدل است.

۳. نتایج

در این مطالعه به منظور مقایسه مدل شبکه عصبی با نتایج منحنی سنجه رسوب، نخست هر یک از انواع منحنی سنجه رسوب، شامل منحنی سنجه فصلی، یک‌خطی، ماهانه، و حد وسط دسته‌ها (جانسون)

آزادی معادله رگرسیونی $(n-1)$ ، S^2 خطای استاندارد، V تابعی از متغیرهای توزیعی، Q_{Bar} متوسط دبی‌های مشاهده‌ای، Q_{Var} واریانس دبی‌های جریان، Q_x مقدار دبی مشاهده‌ای نمونه i ، و CF_{MVUE} مقدار ضریب اصلاحی $MVUE$ است [۸].

۷.۲. انتخاب بهترین ترکیب منحنی سنجه و

ضریب اصلاحی

پس از به‌کارگیری ضرایب اصلاحی برای انواع منحنی سنجه رسوب، با استفاده از ۳۰ درصد باقی‌مانده داده‌ها و معیارهای ناش - ساتکلیف و شاخص صحت بهترین ترکیب منحنی سنجه و ضریب اصلاحی انتخاب شد و برای کاربرد در مرحله بعد، یعنی مقایسه با شبکه عصبی، به کار رفت.

معیار ناش - ساتکلیف (NS)

معیار ناش - ساتکلیف (رابطه ۱۱) از منفی بی‌نهایت تا یک تغییر می‌کند و هر چه به یک نزدیک‌تر باشد برآورد دقیق‌تر است [۱۲].

(۱۱)

$$NS = 1 - \left[\frac{\sum_{i=1}^n (SSC_o - SSC_e)_i^2}{\sum_{i=1}^n (SSC_o - SSC_m)_i^2} \right]$$

شاخص صحت (P)

نسبت مقدار برآوردی به مقدار مشاهده‌ای به عنوان شاخص صحت قلمداد می‌شود (رابطه ۱۲) و هر چه به یک نزدیک‌تر باشد صحت پیش‌بینی بالاتر است [۲].

1. Nash & Sutcliffe
2. Precision Index

(ماهانه) است. ذکر این نکته لازم است که در حالت‌هایی که ضریب اصلاحی MUVE بر اساس شاخص‌های آماری به عنوان ضریب مناسب انتخاب نشد، اختلاف بسیار کمی با ضرایب اصلاحی دیگر داشت که این امر موجب شد ضریب اصلاحی MUVE مناسب‌ترین ضریب در همه ایستگاه‌های مورد مطالعه در نظر گرفته شود.

بعد از انتخاب مناسب‌ترین ترکیب منحنی سنجه و ضریب اصلاحی، به منظور مدل‌سازی رسوب با شبکه عصبی، داده‌های رسوب به صورت روزانه، فصلی، ماهانه، و دسته‌بندی شده از طریق مدل شبکه عصبی پیش‌خور پس‌انتشار خطا بررسی شد. جدول ۳ بیانگر نتایج حاصل از اعتبارسنجی منحنی سنجه منتخب و شبکه عصبی با استفاده از معیارهای ناش ساتکلیف و مجذور میانگین مربعات خطاست.

ترسیم و اعتبارسنجی شد. نتایج نشان داد منحنی‌های سنجه مورد استفاده خطای بسیار زیادی دارند. بنابراین، با استفاده از ضرایب اصلاحی متداول شامل QMLE، MUVE، FAO، Smearing به پایین آوردن خطا و اصلاح منحنی‌های سنجه اقدام شد. نتایج نشان داد از بین منحنی سنجه‌های مورد استفاده در این مطالعه منحنی سنجه ماهانه بهتر از سایرین است. جدول ۲ نتایج اعمال ضرایب اصلاحی در بهبود مناسب‌ترین منحنی سنجه (منحنی سنجه ماهانه) را نشان می‌دهد. برای هر ایستگاه بهترین مدل مدلی است که مقدار P و NS مربوط به آن به عدد یک نزدیک‌تر باشد (این مقادیر در هر ردیف مقایسه و مشخص شده‌اند).

همان‌طور که از جدول ۲ پیداست، در بیشتر ایستگاه‌ها ضریب اصلاحی MUVE مناسب‌ترین ضریب اصلاحی در بهبود منحنی سنجه منتخب

جدول ۲. نتایج اعمال ضرایب اصلاحی در مدل منحنی سنجه رسوب ماهانه (مناسب‌ترین منحنی سنجه)


MVUE		CF2		CF1		FAO		بدون ضریب		مدل	ایستگاه
NS	P	NS	P	NS	P	NS	P	NS	P		
۰٫۹۶	۰٫۳۱	-۵۷٫۸	۲٫۲	-۵۶٫۲	۲٫۷۸	-۲٫۵۸	۱۲٫۰۸	۰٫۸۷۵	۳۱٫۸۸	تیره- دورود	
-۲٫۶۴	۰٫۸۴	-۵۳٫۵۶	۰٫۸۵	-۳۹٫۱۷	۱٫۸۷	-۲۷٫۵	۰٫۳۶	-۲۶٫۱۵۱	۲٫۵۲	ماریره- دورود	
۰٫۹۴۸	۰٫۴۲	۵۹٫۵	۱٫۴۵	۵۱٫۹۸	۳٫۹۳	۰٫۰۹۸	۱٫۷۴	۰٫۸۹	۵٫۹۴	آب‌سبزه	
۰٫۹۲۷	۰٫۳۳	-۲۴۵	۱٫۸۰	-۲۴۰٫۸	۲٫۵۸	۰٫۹۹۹	۱۴٫۱۹	۰٫۹۲۲	۷۶٫۸۲	ازنا	
۰٫۹۸	۰٫۷۷	-۶۱٫۸۳	۶٫۲۵	-۶۳٫۰۹	۱٫۱۲	۰٫۴۱	۲٫۳۸	۰٫۹۷	۱۷٫۵۸	آب‌سرد	
۰٫۸۳	۰٫۳۱	-۶۷٫۲۳	۰٫۲۱	-۶۵٫۵۲	۰٫۲۹	۰٫۱۷۶	۰٫۵۶	۰٫۷۴۸	۱۴٫۷۲	سیلاخور	
۰٫۱۲	۰٫۸۲	-۶۸٫۳۷	۰٫۵۷	-۴۶٫۰۹	۲٫۰۳	-۱۱٫۵۱	۴٫۱۹	-۹٫۹۶	۱٫۶۷	گله‌رود	
۰٫۲۷۷	۰٫۴۱	-۷۶٫۸۹	۰٫۶	-۷۳٫۳۹	۰٫۷۲	-۰٫۳۴	۰٫۴۲	۰٫۰۳۳	۲٫۸۷	سراب سفید	
۰٫۹۸	۴	-۶۲٫۷۵	۰٫۱۱	-۶۱٫۲۶	۰٫۳۷	-۳٫۱۷	۲٫۰۴	۰٫۲۵	۴۸٫۳۸	بیاتون	
۰٫۹۹	۰٫۰۱۲	-۴۹۱	۱٫۹	-۴۶۶	۲٫۹	۰٫۹۷	۵٫۵	۰٫۹۷	۲۷٫۹۶	ماریره- دره تخت	

جدول ۳. مقایسه و اعتبارسنجی شبکه عصبی و منحنی سنجه در به کارگیری داده‌های فصلی، یک‌خطی، ماهانه، و دسته‌بندی شده رسوب معلق

منحنی سنجه رسوب		شبکه عصبی مصنوعی		مدل‌ها	نام ایستگاه
مجدور میانگین مربعات خطا	ضریب ناش- ساتکلیف	مجدور میانگین مربعات خطا	ضریب ناش- ساتکلیف		
۰/۰۴	۰/۹	۰/۰۰۹۴	۰/۹۲	فصلی	تیره- درود
۰/۰۳	۰/۷۶	۰/۰۰۹۲	۰/۸۱	یک‌خطی	
۰/۰۲۴	۰/۹۶	۰/۰۰۴۶	۰/۹۹	ماهانه	
۰/۰۹	۰/۸۱	۰/۰۰۰۴	۰/۸۷	جانسون	ماریره- دورود
۰/۰۱۸	-۲/۸-	۰/۰۰۰۸۸	-۲/۲	فصلی	
۰/۰۲۰	-۲/۵-	۰/۰۰۰۰۱۶	-۰/۴۵	یک‌خطی	
۰/۰۳	-۲/۶۴	۰/۰۰۰۰۳۲	-۱/۰۵	ماهانه	آب‌سبزه
۰/۰۱۶	-۱/۵	۰/۰۰۰۰۴۸	-۱/۴۴	جانسون	
۰/۰۲۸	۰/۸۹	۰/۰۰۰۰۷۷	۰/۷۸	فصلی	
۰/۱۲	۰/۶۷	۰/۰۰۰۰۹۱	۰/۷۵	یک‌خطی	ماریره- دره تخت
۰/۰۲۴	۰/۹۴۸	۰/۰۰۰۰۰۵۴	۰/۹۸	ماهانه	
۰/۳۴	۰/۴۲	۰/۰۰۰۰۲۴	۰/۸۱	جانسون	
۰/۰۱۹	۰/۹۱	۰/۰۰۰۰۰۳۱	۰/۸۷	فصلی	ازنا
۰/۰۲۳	۰/۹۷	۰/۰۰۰۰۱۸	۰/۸۹	یک‌خطی	
۰/۰۲۲	۰/۹۹	۰/۰۰۰۰۰۰۸۹	۰/۹۹	ماهانه	
۰/۰۲۰	۰/۸۶	۰/۰۰۰۰۰۰۲۱	۰/۹۵	جانسون	آب‌سرد
۰/۱۸	۰/۸۳	۰/۰۰۰۰۰۲	۰/۹۵	فصلی	
۰/۳۱	۰/۷۶	۰/۰۰۰۰۳۱	۰/۸۴	یک‌خطی	
۰/۰۲۲	۰/۹۲۷	۰/۰۰۰۰۰۰۱۱	۰/۹۸	ماهانه	سیلاخور
۰/۳۵	۰/۶۸	۰/۰۰۰۰۰۲۷	۰/۸۹	جانسون	
۰/۱۵	۰/۸۷	۰/۰۰۰۰۰۰۳	۰/۹۷	فصلی	
۰/۱	۰/۸۲	۰/۰۰۰۰۰۷۹	۰/۹۳	یک‌خطی	گله‌رود
۰/۲۳	۰/۹۸	۰/۰۰۰۰۳۹	۰/۸۹	ماهانه	
۰/۰۱۲	۰/۹۷	۰/۰۰۰۰۰۸	۰/۹۴	جانسون	
۰/۱۸	۰/۵۴	۰/۰۰۰۰۰۷۲	۰/۸۴	فصلی	سراب سفید
۰/۳۹	۰/۳۹	۰/۰۰۰۰۰۱۱	۰/۹۳	یک‌خطی	
۰/۰۳۷	۰/۸۳	۰/۰۰۰۰۰۸	۰/۷۹	ماهانه	
۰/۳۱	۰/۴۸	۰/۰۰۰۰۰۱	۰/۸۹	جانسون	بیاتون
۰/۱۱	۰/۰۸	۰/۰۰۰۰۲۶	۰/۶	فصلی	
۰/۳۱	-۲/۴	۰/۰۰۰۰۲۵	-۱/۲	یک‌خطی	
۰/۱۸	۰/۱۲	۰/۰۰۰۰۸۸	۰/۸	ماهانه	سراب سفید
۰/۲۹	-۱/۷	۰/۰۰۰۰۷۵	۰/۷۵	جانسون	
۰/۲	۰/۲۵	۰/۰۰۰۰۱۴	۰/۷۵	فصلی	
۰/۱۴	۰/۲	۰/۰۰۰۰۳۵	۰/۷۸	یک‌خطی	بیاتون
۰/۰۶۹	۰/۲۷۷	۰/۰۰۰۰۷۲	۰/۹۳	ماهانه	
۰/۱۳	۰/۱۸	۰/۰۰۰۰۳۴	۰/۸۲	جانسون	
۰/۱۹	۰/۵۸	۰/۰۰۰۰۰۹۶	۰/۸۷	فصلی	بیاتون
۰/۲۱	۰/۵۴	۰/۰۰۰۰۰۲۹	۰/۷۶	یک‌خطی	
۰/۰۲۳	۰/۹۸	۰/۰۰۰۰۰۸۸	۰/۹۹	ماهانه	
۰/۱۹	۰/۶	۰/۰۰۰۰۰۱۹	۰/۸۵	جانسون	

دره تخت با مدل منحنی سنجه ماهانه با ضریب اصلاحی MUVE و شبکه عصبی پیش‌خور پس‌انتشار خطای شبیه‌سازی شده مقایسه شد. همان‌طور که از شکل ۳ پیداست، رسوب ماهانه شبیه‌سازی شده با شبکه عصبی در مقایسه با منحنی سنجه ماهانه از تطابق بیشتری با رسوب مشاهده‌شده برخوردار است.

همان‌طور که از جدول ۳ پیداست، در ۷۰ درصد موارد (ایستگاه‌هایی که با کادر قرمز مشخص شده‌اند)، مدل‌های ساخته‌شده با داده‌های ماهانه از خطای کمتری برخوردار بودند؛ در ضمن، در همه موارد شبکه عصبی توانایی بیشتری در مدل‌سازی رسوب دارد و دارای اعتبار بیشتری است. در شکل ۳، به عنوان نمونه، رسوب مشاهده‌شده در ایستگاه



شکل ۳. مقایسه نتایج صحت‌سنجی شبیه‌سازی رسوب با مدل شبکه عصبی و منحنی سنجه ماهانه با مقادیر رسوب مشاهده‌شده

نسبت به سایر منحنی‌های سنجه دارای اعتبار بیشتری در برآورد رسوب معلق است. در مرحله بعد داده‌های فصلی، روزانه، ماهانه، و دسته‌بندی شده به مدل شبکه عصبی پیش‌خور پس‌انتشار خطا با الگوریتم آموزشی لونبرگ مارکوآرت اعمال شد. اعتبار نتایج حاصل از مدل شبکه عصبی با مدل منتخب منحنی سنجه رسوب با استفاده از شاخص‌های آماری مجذور میانگین مربعات خطا و ضریب ناش-ساتکلیف مقایسه شد. نتایج حاکی از مناسب بودن شبکه عصبی پیش‌خور پس‌انتشار خطا با الگوریتم آموزشی لونبرگ مارکوآرت در برآورد

۴. بحث و نتیجه‌گیری

در این تحقیق به منظور انتخاب بهترین منحنی سنجه برای برآورد بار معلق رودخانه، نخست نتایج منحنی‌های سنجه رسوب فصلی، روزانه، ماهانه، و حد وسط دسته‌ها با اعمال ضرایب اصلاحی بهبود یافت. سپس، از بین انواع منحنی سنجه و ضرایب اصلاحی موجود مناسب‌ترین ترکیب با استفاده از شاخص‌های آماری ضریب ناش-ساتکلیف و شاخص صحت انتخاب شد. نتایج این مرحله بیانگر آن است که منحنی سنجه ماهانه با ضریب اصلاحی

شد. سپس، در مقایسه با شبکه عصبی بررسی شد. بر اساس نتایج تحقیق حاضر، می توان ادعا کرد رسوب معلق ماهانه در مقایسه با رسوب فصلی، دسته بندی شده، و روزانه با خطای کمتری در مدل سازی همراه است. خطای کمتر رسوب معلق ماهانه در مقایسه با رسوب روزانه در مدل سازی به دلیل متوسط گیری از رسوب و کاهش نوسانات شدید روزانه است و عملکرد بهتر رسوب ماهانه در مقایسه با رسوب فصلی و دسته بندی شده نیز مربوط به مقیاس زمانی کوچک تر و مشاهدات زیادتر در مقطع زمانی ماهانه است.

رسوبات معلق در منطقه مورد مطالعه است. نتایج مطالعه حاضر با بررسی های برخی مطالعات [۹، ۱۰، ۲۵، ۲۷] هم خوانی دارد. البته، ذکر این نکته لازم است که در مطالعات مذکور هرچند از مقایسه منحنی سنجه و شبکه عصبی مصنوعی استفاده شده است، فقط شکل متداول منحنی سنجه، یعنی منحنی سنجه یک خطی، مبنای مقایسه قرار گرفته است که خالی از اشکال نیست. بنابراین، در تحقیق حاضر نخست مناسب ترین منحنی سنجه از بین منحنی سنجه رسوب روزانه، فصلی، ماهانه، و حد وسط دسته ها انتخاب و با اعمال ضریب اصلاحی مناسب ارتقا داده

Archive of SID

References

- [1] Akbari, Z. (2010). Performance of the decision tree and regression model to estimate the amount of sediment in the dam area of Ilam, Master's thesis, Department of Natural Resources desert Studies, Yazd University (In Farsi).
- [2] Arabkhedri, M., Hakimkhani, Sh. and Varvani, J. (2004). The Validity of extrapolation methods in estimation of annual mean suspended sediment yield (17 Hydrometric Stations), *Journal of Agricultural Science and Natural Resources*, 11(3), 123-131 (In Farsi).
- [3] Asselman, N.E.M. (2002). Fitting and interpretation of sediment rating curves, *Journal of Hydrology*, 234, 228-248.
- [4] Barzegar, F. (2004). Comparison of methods to estimate suspended sediment (Case Study: Qezel Ozan), MSc Thesis, Department of Natural Resources, Tehran University, 120pp (In Farsi).
- [5] Basheer, I.A. and Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application, *Journal of Microbiological Methods*, 43, 3-31.
- [6] Bauer, P., Nouak, S. and Winkler, R. (2007). Fuzzy Mathematical Methods for soil survey and Land Evaluation, *Journal of soil science*, 40, 477-492.
- [7] Caniani, D., Pascale, S., Sdao, F. and Sole, A. (2008). Neural networks and landslide susceptibility: a case study of the urban area of Potenza, *Natural Hazards*, 45, 55-72.
- [8] Cohn, T.A., Caulder, D.A., Gilroy, E.J., Zynjuk, L.D. and Summers, R.M. (1992). The validity of a sample statistical model for estimation fluvial constituent loads: an empirical study involving nutrient loads entering Chesapeake Bay, *Water Resource Research*, 28(9), 2353-2363.
- [9] Dastorani, M.T., Azimi Fashi, Kh., Talebi, A. and Ekhtesasi, M.R. (2012). Suspended sediment estimation using Artificial Neural Network (Case Study: Jamyshan watershed in Kermanshah), *The third year of watershed management Journal*, 6, 61-74 (In Farsi).
- [10] Dehghani, A., Zanganeh, M., Mosaedi, A. and Kohestani, N. (2009). Comparison Estimate suspended load with two method Sediment Rating curve and Artificial Neural Network (Case Study: Dough River, Golestan Province), *Issue science agriculture and natural source*, 16(1), 266-276 (In Farsi).
- [11] Dehghani, A., Mohammad Malik, M. and Hezarjarib, A. (2010). Behesht Abad river suspended sediment estimation using artificial neural networks, *Journal of Soil and Water Conservation*, 17(1), 159-168 (In Farsi).
- [12] Feiznia, S., Ghafari, G., Karimizadeh, K. and Tabatabaezadeh, M. (2011). Determination of the Most Suitable Method for Estimation of Suspended Sediment in Hydrometric Stations Upland of Latian and Taleghan Dams, *Journal of Natural Environment, Iranian Journal of Natural Resources*, 64(3), 231-242 (In Farsi).
- [13] Hagan, M.T., Demuth, H.B. and Beale, M.H. (1996). *Neural Network Design*, global book store, (Spring, TX, U.S.A.), ISBN: 0971732108 / 0-9717321-0-8, 734 pp.
- [14] Hajebakhsh, P. (2011). Bed sediment load estimated using regression decision trees and comparison with experimental method, MSC Thesis, Civil Faculty, Yazd University (In Farsi).
- [15] Hasonizadeh, H., Fazlalizadeh, M., Nekoyi, F and Shirdeli, A. (2012). Prediction density sediment in Karkheh River with use from neural network software, *International conference 9th engineering river*, Ahwaz, Chamran University (In Farsi).

- [16] Heikki Koivo, N. (2008). NEURAL NETWORKS: Basics using MATLAB Neural Network Toolbox, http://staff.ttu.ee/~jmajak/Neural_networks_basics_.pdf. 59 pp.
- [17] Hsu, K., Gupta, H.V. and Sorooshian, S. (1995). Artificial neural network modeling of the rainfall-runoff process, *Water Resources Research*, 31(10), 2517-2530.
- [18] Iadanza, C. and Napolitano, F. (2006). Sediment transport time series in the Tiber River, *Physics and Chemistry of the Earth*, 31, 1212-1227.
- [19] Jansson, M.B. (1996). Estimating a sediment rating curves of the Reventazon River at Palamo using logged mean loads within discharge classes, *Journal of Hydrology*, 183(4), 227-241.
- [20] Jones, K.R., Berney, O., Carr, D.P., and Barret, E.C. (1981). Arid zone hydrology for agricultural development, *FAO Irrigation and Drainage Paper*, 37, 271.
- [21] Kao, Sh.J., Lee, T.Y., and Milliman, J.D. (2005). Calculating highly fluctuated suspended sediment fluxes from mountainous rivers in Taiwan, *TAO*, 16(3), 653-675.
- [22] Koch, R.W. and Smillie, G.M. (1986). Comment on river loads underestimated by rating curves, *Water Resources Research*, 22(13), 2121-2122.
- [23] Lee, S., Ryu, J.H., Lee, M.J. and Won, J.S. (2006). The Application of artificial neural networks to landslide susceptibility mapping at Jan hung, Korea, *Mathematical Geology*, 38(2), 199-220.
- [24] Mosaedi, A. (1998). Hydrological sizing of sediment reservoir system for irrigation and water supply. Ph.D. Thesis, Faculty of Civil Eng, Technical University of Budapest, Hungary, 101pp.
- [25] Rajaei, T., Mirbagheri, S.A. and Kermani, M.Z. (2009). Daily suspended sediment concentration simulation using ANN and neuro-fuzzy models, *Science of the total environment*, 407, 4916-4927.
- [26] Salajegheh, A. and Fathabadi, A. (2009). Assessment Possible Estimate suspended load Karaj River with beneficiary from fuzzy-logic and neural network, *Range and Watershed (Iran natural source)*, 62(2), 271-282 (In Farsi).
- [27] Shabani, M. and Shabani, N. (2012). Estimation of Daily Suspended Sediment Yield Using Artificial Neural Network and Sediment Rating Curve in Kharestan Watershed, Iran, *Australian Journal of Basic and Applied Sciences*, 6(12), 157-164.
- [28] Telvari, A. (2003). The relationship between suspended sediment and certain properties in the area Dez and Karkheh Basin, *Research and development*, 56-57, 56-61 (In Farsi).
- [29] Thomas, R.B. (1985). Estimating total suspended sediment yield with probability sampling, *Water Resources Research*, 21(9), 1381-1388.
- [30] Toloie, S., Hossenzadeh, D., Ghorbani, M., Fakherifard, A., and Salmasi, F. (2011). Estimate temporal and spatial suspended load river Ajichai with use from Geostatistics and Artificial neural network, *Issue science water and soil*, 21(4), 93-104 (In Farsi).
- [31] Vali, A., Ramesht, M., Siff, A. and Ghazavi, R. (2011). Comparison efficiency Artificial Neural Network models and regression for prediction flow sediment load (Case Study: catchment basin Samandegan), *Issue Geographic and Environment Schematization*, 44(4), 19-34 (In Farsi).