



فصلنامه علمی-پژوهشی

پژوهش‌های فرسایش محیطی

سال سوم، شماره ۱۲، زمستان ۱۳۹۲، صص ۱-۱۶

www.magazine.hormozgan.ac.ir

## کاربرد دو روش شبکه عصبی مصنوعی MLP، RBF در برآورد رسوبات بادی (مطالعه موردی: دشت کرسیا داراب)

محمد رضا شکاری<sup>۱\*</sup>، سیدجواد ساداتی نژاد<sup>۲</sup>، عباسعلی ولی<sup>۳</sup>، هدی قاسمیه<sup>۴</sup>، رضا قضاوی<sup>۵</sup>

۱- دانشجوی دکتری بیابان‌زدایی، دانشگاه کاشان، shekari.reza@gmail.com

۲- دانشیار دانشکده علوم و فنون نوین، دانشگاه تهران، Jsadatinejad@ut.ac.ir

۳- استادیار دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان، vali@kashanu.ac.ir

۴- استادیار دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان، h.ghasemieh@kashanu.ac.ir

۵- استادیار دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان، ghazavi@kashanu.ac.ir

### چکیده

به دلیل عدم وجود ایستگاه‌های سنجش میزان رسوب در فرایند فرسایش بادی، تخمین میزان بار رسوب در زمینه این فرایند امری ضروری و مهم تلقی می‌شود. شبکه‌های عصبی مصنوعی می‌توانند به عنوان ابزاری کارآمد جهت برآورد و شبیه‌سازی رسوبات موثر واقع شوند. در این تحقیق از دو نوع شبکه عصبی مصنوعی پرسپترون چند لایه و شبکه عصبی شعاعی برای برآورد و برازش مقدار رسوبات بادی در منطقه کرسیا شهرستان داراب استفاده گردید. در این شبیه‌سازی که با دو روش پرکاربرد شبکه عصبی پرسپترون چند لایه و شبکه عصبی شعاعی صورت گرفت، در ابتدای امر میزان رسوبات بادی توسط تله‌های رسوب‌گیر نمونه‌برداری شد و با پارامترهای اقلیمی نظیر متوسط سرعت باد، تبخیر، بارندگی، رطوبت نسبی، دمای کمینه، دمای بیشینه، دمای متوسط و درصد پوشش گیاهی به ترتیب به عنوان متغیر وابسته و مستقل ورودی به مدل جهت شبیه‌سازی رسوبات انتخاب گردید. نتایج حاصل از عملکرد مدل‌ها نشان داد که شبکه عصبی پرسپترون چند لایه (پیشخور با الگوریتم پس انتشار خطا) با تکنیک یادگیری گرادیان دوگانه درجه‌بندی نسبت به شبکه عصبی شعاعی به ترتیب با ضریب تعیین ۰/۹۵ و ریشه میانگین مربعات خطای ۰/۰۲ و ضریب تعیین ۰/۹۰ و ریشه میانگین مربعات خطای ۰/۴۰ در برآورد رسوبات بادی از دقت و کارایی بالاتری برخوردار می‌باشد. البته لازم به ذکر است که مزیت مهم شبکه عصبی مصنوعی پرسپترون چند لایه انعطاف‌پذیری بیشتر نسبت به شبکه عصبی شعاعی می‌باشد.

### واژه‌های کلیدی:

شبکه عصبی MLP، شبکه عصبی RBF، شبیه‌سازی، تله رسوب‌گیر، رسوبات بادی

## مقدمه

فرسایش و رسوب گذاری فرایندی است که سبب از دست رفتن خاک حاصلخیز سطحی و همچنین انتقال رسوبات می شود که باعث ایجاد مشکلاتی از قبیل خسارت تأسیسات، کاهش میدان دید در جاده ها، آلودگی هوا، پر شدن مخازن سدها و ... می شود (احمدی، ۱۳۸۷). این پدیده مانند سایر پدیده های طبیعی مورد توجه دانشمندان جهان قرار گرفته، و در دهه های اخیر سعی و تلاش زیادی در زمینه کمی کردن معیارهای شناسایی این پدیده به عمل آمده است. جهت کمی کردن رسوبات از روش های اندازه گیری مستقیم و غیرمستقیم استفاده می شود. در فناوری اندازه گیری مستقیم، دبی ذرات انتقال یافته به وسیله باد را در یک مکان ثابت نمونه گیری می کنند و در فناوری غیرمستقیم، اندازه گیری پی در پی ارتفاع سطح خاک که با نشان دار کردن رسوبها با ردیاب عناصری مانند مواد رادیو اکتیو و ... و تعیین سرعت حرکت در واحد زمان انجام می شود. اندازه گیری مستقیم رسوبات بادی به علت فقدان ایستگاه های رسوب سنجی در کشور یکی از مشکلات مهم تحقیقات در این زمینه محسوب می شود. برای رفع مشکلات و پیچیدگی های این اندازه گیری ها از پیش بینی و برآورد به وسیله مدل ها می توان بهره جست. بنابراین به وسیله مدل ها می توان جنبه های ویژه ای از واقعیت پیچیده ی یک سیستم را تبیین و بررسی کرد. در عصر حاضر به منظور برآورد رسوبات بادی از مدل ها و فرمول های تجربی متنوعی استفاده می شود که شبکه های عصبی مصنوعی می تواند یکی از مهم ترین این مدل ها به شمار رود. شبکه عصبی مصنوعی همانند مغز انسان از تعداد بسیار زیادی سلول عصبی به نام نرون تشکیل شده است. نرون ها توسط اتصالاتی به نام سیناپس به یکدیگر متصل می شوند که قادرند پیام های (سیگنال) عبوری از خود را تقویت یا تضعیف کنند و می توان آن ها را به عنوان اتصالات وزن دار در نظر گرفت. با استفاده از شبکه ی عصبی مصنوعی مناسب و انتخاب صحیح وزن ها و توابع فعال ساز فرایندهای خطی و غیرخطی قابل برآورد و شبیه سازی است. بدین ترتیب این مدل ها می توانند جایگزین مناسبی نسبت به سایر مدل ها برای تخمین و برآورد رسوبات بادی ارائه شوند. این شبکه ها قادرند میزان رسوبات را با استفاده از متغیرهای جوی و خصوصیات آب و هوایی به عنوان متغیرهای منطقه ای و همچنین متغیر پوشش گیاهی، را در مکان و زمان با دقت قابل قبولی پیش بینی و برآورد کنند. امروزه روش شبکه عصبی کاربرد وسیعی در علوم مختلف دارد. در علم مهندسی آب و خاک در سال های اخیر به این روش توجه زیادی شده است، که از جمله آن می توان به موارد ذیل اشاره کرد:


تقی زاده مهرجردی و همکاران (۱۳۸۸) با استفاده از شبکه عصبی مصنوعی و رگرسیون چند متغیره ظرفیت تبادل کاتیونی خاک را در منطقه خضراباد یزد پیش بینی نمودند، که با وجود رابطه خطی مابین ورودی ها و خروجی ها شبکه عصبی مصنوعی از عملکرد بهتری نسبت به مدل رگرسیونی چند متغیره برخوردار بود. ولی و همکاران (۱۳۸۹) به بررسی عملکرد شبکه عصبی مصنوعی در برآورد بار رسوب رودخانه ای پرداختند و ضرایب عملکرد مدل در استفاده از شبکه های عصبی مصنوعی از امتیاز بالاتری نسبت به روش های رایج مدل سازی برخوردار بود و در نتیجه ایشان شبکه های عصبی مصنوعی را به عنوان یک ابزار قوی پیش بینی رفتارهای سیستم آبرفتی رودخانه ای معرفی نمودند. دستورانی و همکاران (۱۳۹۱) کارایی شبکه های عصبی مصنوعی (مدل پرسترون چند لایه) را جهت پیش بینی رسوب معلق مورد ارزیابی کردند و با منحنی سنج رسوب مقایسه دادند. نتایج ایشان حاکی از دقت و عملکرد بالای شبکه های عصبی مصنوعی نسبت به منحنی سنج رسوب می باشد. Ardicioglo at all, 2007 از شبکه عصبی مصنوعی برای برآورد رسوبات معلق استفاده کردند. آن ها از دو الگوریتم متفاوت شبکه عصبی برای این کار بهره گرفتند و نتایج حاصله را با رگرسیون خطی چندگانه مقایسه کردند و اعلام نمودند که شبکه عصبی نوع پیشخور نتیجه بهتری را نشان می دهد. همچنین zhu at all, 2007 از شبکه عصبی مصنوعی برای شبیه سازی ماهیانه جریان رسوبات معلق استفاده کردند. Hamidi, N. & N. Kayaalp, 2008 از شبکه عصبی مصنوعی برای برآورد میزان رسوبات معلق در رودخانه دجله استفاده کردند. Melesse at all, 2011 مقدار رسوب معلق در رودخانه های می سی سی پی، میسوری و ریوگراند آمریکا را به کمک مدل سازی شبکه عصبی مصنوعی پرسترون چند لایه برآورد نمودند. در این تحقیق از داده های روزانه و هفتگی بارش، دبی روز مربوطه و روز قبل و رسوب روز قبل جهت پیش بینی رسوب معلق روز مربوطه استفاده گردید. نتایج مدل شبکه عصبی مصنوعی با نتایج مدل رگرسیون خطی چند متغیره و مدل آریمای مقایسه شد.

نتایج خروجی مدل شبکه عصبی به مراتب از دقت بالاتری نسبت به نتایج مدل‌های دیگر بود. نتایج تحقیقات فوق نشان داد که روش شبکه عصبی از برتری قابل قبولی نسبت به سایر روش‌ها برخوردار می‌باشد. صیادی و همکاران (۱۳۸۸) برای برآورد میزان تبخیر و تعرق از مقایسه دو شبکه عصبی MLP و RBF بهره جستند و به این نتیجه رسیدند که شبکه عصبی MLP دارای دقت نسبتاً بیشتری نسبت به RBF می‌باشد بنابراین مدل شبکه عصبی مصنوعی می‌تواند جایگزین مناسبی برای تخمین و برآورد رسوبات بادی نسبت به سایر مدل‌های ارائه شده باشد. هدف از این تحقیق ارزیابی و مقایسه کارایی دو روش رایج شبکه عصبی مصنوعی در برآورد و شبیه‌سازی رسوبات بادی منطقه کرسیای داراب با استفاده از متغیرهای اقلیمی و پوشش گیاهی می‌باشد.

## ۲- مواد و روش

### ۱-۲- معرفی منطقه مورد مطالعه

منطقه مورد مطالعه به مساحت ۱۰۰۰ هکتار در ۱۷ کیلومتری شمال غرب شهرستان داراب (دشت کرسیا) که در جنوب شرقی استان فارس و در محدوده‌ی جغرافیایی ۲۸ درجه و ۴۴ دقیقه تا ۲۸ درجه و ۴۷ دقیقه عرض شمالی و از ۵۴ درجه و ۲۲ دقیقه تا ۵۴ درجه و ۲۴ دقیقه طول شرقی واقع شده است. متوسط بارندگی سالانه‌ی منطقه، ۲۸۰ میلی‌متر و متوسط درجه‌ی حرارت سالانه، ۲۲ درجه‌ی سانتی‌گراد است. میانگین حداکثر درجه‌ی حرارت، ۳۰ درجه‌ی سانتی‌گراد و میانگین حداقل درجه‌ی حرارت، ۱۴ درجه‌ی سانتی‌گراد است. متوسط تبخیر سالانه در این منطقه، ۳۳۰۰ میلی‌متر و متوسط رطوبت نسبی ۴۳ درصد است. شکل (۱) موقعیت منطقه مورد مطالعه را نشان می‌دهد.



شکل ۱- موقعیت منطقه مورد مطالعه

دشت کرسیای (داراب) از رسوبات دوره کواترنری تشکیل شده، به علت تأثیر گنبد نمکی و اثرات با آن بر روی این رسوبات از لحاظ کشاورزی دارای محدودیت می‌باشد و تیپ‌های غالب پوشش گیاهی منطقه بیشتر گونه‌های شورپسند می‌باشند (ولی و همکاران، ۱۳۸۵). گنبد نمکی داراب همانند سایر گنبد‌های نمکی سری هرمز که در زاگرس رخمون دارند، دارای سن اینفرا کامبرین می‌باشد که رسوبات و لایه‌های روی خود را پشت سر گذاشته و به سطح زمین رسیده است. از این رو این پدیده را می‌توان به گروه سوم عوامل (تکتونیک و زمین ساخت) ربط داد.

### ۲.۲. مطالعات میدانی نمونه‌برداری رسوب

پس از بازدید صحرایی از منطقه جهت بررسی مقدماتی و به دست آوردن دید کلی منطقه، بر اساس گونه‌های غالب مشاهده شده در هر منطقه بر اساس روش حداقل سطح، اندازه‌ی نمونه ۱۰ مترمربع تعیین می‌گردد. سپس تعداد نمونه‌ی لازم ۳۰ عدد تعیین می‌شود و از روش نمونه‌برداری کاملاً تصادفی با استفاده از پلات برای تیپ‌بندی اقدام می‌گردد که پس از

استقرار پلات، لیست گونه‌های موجود در هر پلات و درصد پوشش آن‌ها یادداشت می‌گردد. لازم به ذکر است که هدف از این تیپ‌بندی مختصر، تنها انتخاب نقاطی جهت انجام نمونه‌برداری از رسوبات و یافتن اطلاعاتی از تأثیر پوشش گیاهی در به دام انداختن رسوبات می‌باشد. نمونه‌برداری از رسوبات بادی جهت استفاده در شبیه‌سازی مدل، به وسیله تله‌های رسوب‌گیر انجام می‌شود. تله رسوب‌گیر طراحی شده این پژوهش مشابه رسوب‌گیر MDCO<sup>۱</sup> است که آقای گوسنز از آن به عنوان نمونه‌برداری مناسب جهت انجام تحقیقات بیابانی یاد می‌کند (Goossens at all, 2000). شکل (۲) نمایی از رسوب‌گیر MDCO نشان می‌دهد.



شکل ۲- نمونه‌هایی از رسوب‌گیر MDCO طراحی شده جهت نمونه‌برداری از رسوبات

این رسوب‌گیر شامل یک سینی فلزی دایره‌ای شکل به مساحت ۲۸۲۶ سانتی‌متر مربع می‌باشد و داخل سینی‌ها با سنگ‌هایی با قطر تقریباً یکسان ( $d=1/5$  cm) پر شده است. هنگامی که رسوبات وارد تله‌ی رسوب‌گیر می‌شوند، این سنگ‌ها مانع از خروج رسوبات از داخل ظرف می‌شوند (شکاری، ۱۳۹۰). در ۳ سایت گیاهی و در طی ۱۲ دوره (۵ روزه) به مدت دو ماه (خرداد و تیر ماه) نمونه‌برداری با قرار دادن تله رسوب‌گیر، نمونه‌های رسوب برداشت شد و با استفاده از ترازوی دیجیتال با دقت ۰/۰۱ توزین گردید. همچنین داده‌های هواشناسی به عنوان یکی از پارامترهای ورودی به مدل از ایستگاه تحقیقات هواشناسی شهرستان داراب تهیه گردید. در این مقاله جهت اجرای مدل‌های شبکه عصبی از نرم‌افزار SPSS<sup>۲</sup> کمک گرفته شد.

### ۳- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی، دارای دو مرحله‌ی کاری یادگیری یا آموزش و به یاد آوردن یا آزمودن می‌باشند. در مرحله‌ی آموزش تعدادی داده‌ی نمونه به عنوان مجموعه‌ی آموزش یا الگوی آموزشی به شبکه اعمال می‌شود. وزن‌ها را به گونه‌ای تنظیم می‌کند که به اندازه‌ی کافی، خروجی مدل به خروجی صحیح (هدف) نزدیک گردد. موفقیت در آموزش، به وسیله‌ی یک تابع خطا، اندازه‌گیری می‌گردد. در مدت آموزش، وزن‌ها به گونه‌ای تغییر می‌یابند که خطا کاهش یابد و آموزش هنگامی پایان می‌یابد که خطا به یک مقدار حداقل برسد. در مرحله‌ی آزمون، یک الگوی ورودی به شبکه اعمال می‌شود و شبکه، خروجی متناظر با آن را محاسبه کرده و ارائه می‌نماید.

<sup>۱</sup> Marble Dust Collector

<sup>۲</sup> Statistical package for social science

۳.۱. روش شبکه عصبی MLP<sup>۳</sup>

شبکه عصبی مصنوعی همانند مغز انسان از تعداد بسیار زیادی سلول عصبی به نام نرون تشکیل شده است. نرون‌ها توسط اتصالاتی به نام سیناپس به یکدیگر متصل می‌شوند که قادرند پیام‌های (سیگنال) عبوری از خود را تقویت یا تضعیف کنند و می‌توان آن‌ها را به عنوان اتصالات وزن‌دار در نظر گرفت. با استفاده از شبکه‌ی عصبی مصنوعی مناسب و انتخاب صحیح وزن‌ها و توابع فعال‌ساز فرایندهای خطی و غیرخطی قابل شبیه‌سازی است. شبکه عصبی بر روی متغیرهای ورودی پردازش را به صورت موازی انجام داده و انتقال اطلاعات از یک لایه به لایه دیگر به صورت سری پشت سرهم انجام می‌شود. هر شبکه از سه لایه ورودی، میانی یا مخفی و لایه خروجی تشکیل شده است. یکی از متداول‌ترین انواع شبکه‌های عصبی، پرسپترون چند لایه می‌باشد و به دلیل اینکه الگوریتم آموزش آن معمولاً پس انتشار است، به آن پس انتشار نیز گفته می‌شود. روش شبکه عصبی پرسپترون توسط روزنبلات مطرح شد. لایه‌ی ورودی فقط به عنوان واسطه‌ای با دنیای خارج عمل می‌کند و هر گره آن یک ورودی را بدون تغییر به نرون‌های لایه‌ی بعدی می‌فرستد. بنابراین تعداد گره‌ها در لایه‌ی ورودی (R)، برابر با تعداد متغیرهای مستقل می‌باشد. تعداد نرون‌های لایه‌ی خروجی (S)، تعداد متغیرهای وابسته‌ی مورد نظر را نشان می‌دهد و تعداد گره‌های هر لایه بستگی به پیچیدگی مسئله خواهد داشت (Beale, R., & Jackson, T., 1990).

لایه‌های پنهان در ناحیه‌ی بین لایه‌ی ورودی و خروجی قرار می‌گیرند که تعداد لایه‌های پنهان نرون‌های یک لایه، کاملاً به نرون‌های لایه‌ی مجاور، متصل شده‌اند. یعنی هر نرون لایه‌ی پنهان، به همه‌ی گره‌های لایه‌ی ورودی و گره‌های یک لایه‌ی مشخص انجام نمی‌گیرد و اطلاعات در جهت پیکان نشان داده شده (همیشه به سمت جلو) حرکت می‌کنند. این نوع شبکه‌ها، اصطلاحاً پیشخور نامیده می‌شوند.

در گام اول، هر ورودی  $p_i$  ( $i=1,2,\dots,R$ )، در وزن منسوب به آن ( $W_{ji}$ ) ضرب می‌شود و با دیگر ورودی‌ها و مقدار آستانه-ی  $b_j$  جمع می‌گردد. به عبارت دیگر، مجموع وزن‌دار ورودی‌ها به اضافه‌ی آستانه، محاسبه می‌شود و مقدار خالص  $n$  به دست می‌آید. مقدار آستانه در واقع جایگزین نرونی با مقدار واحد و وزن مربوطه‌ی  $b$  می‌شود که عملکردی مانند عرض از مبدأ دارد (Hagan, 1996).

$$n_j = W_{j1} \cdot P_1 + W_{j2} \cdot P_2 + \dots + W_{jR} \cdot P_R + b_j = \sum_{i=1}^R W_{ji} \cdot P_i + b_j \quad (1)$$

که هر کدام از این پارامترها عبارت‌اند از:

$P_i$  (1,2,3, ... R): مقدار ورودی نرون  $i$ ام

$W_{ji}$  (1,2,3, ... R): مقدار وزن اتصال بین نرون  $i$ ام با لایه قبل

$b_j$ : وزن مربوط به بایاس برای نرون  $j$ ام

در گام دوم، تابع فعال‌سازی به صورت  $f$ ، بر روی  $n$  اعمال می‌گردد تا خروجی نرون  $a$  به دست آید.

$$a_j = f(n_j) \quad (2)$$

که هر کدام از پارامترها عبارت‌اند از:

$a_j$ : برابر است با مقدار خروجی با ازای نرون  $j$ ام

$f$ : تابع آستانه نرون  $j$ ام

$n_j$ : مقدار خالص خروجی نرون  $j$ ام

در مورد نرون‌های لایه‌ی خروجی نیز الگوریتم به صورت مشابه با لایه‌ی پنهان پیاده‌سازی می‌گردد. تابع فعال‌ساز برای همه‌ی نرون‌های یک لایه‌ی مشخص، یکسان می‌باشد. معروف‌ترین توابع فعال‌ساز مورد استفاده در پرسپترون‌های چند لایه،

<sup>۳</sup> Multiple layer perceptron

برای لایه‌های پنهان، تابع سیگموئید و برای لایه‌ی خروجی تابع همانی هستند که معادلات توابع سیگموئید و همانی به ترتیب در فرمول‌های ۳ و ۴ نشان داده شده است.

$$f(n_j) = \left[ \frac{1}{1 + e^{-n_j}} \right] \quad (۳)$$

$$f(n_j) = n_j \quad (۴)$$

### ۲،۳. روش شبکه عصبی RBF<sup>۴</sup>

یکی دیگر از انواع شبکه‌های عصبی مصنوعی، شبکه‌های RBF هستند. نخستین تحقیقات روی این شبکه در سال ۱۹۸۵ توسط Paul صورت گرفت و در سال ۱۹۹۲ توسط Laight، ادامه یافت. این شبکه‌ها روش متفاوتی نسبت به شبکه‌های معروف‌تر عصبی نظیر MLP ارائه می‌کنند. شبکه‌های RBF در حل بسیاری از مسائل متفاوت، به ویژه در مسائل طبقه‌بندی، الگوشناسی و تحلیل سری‌های زمانی به کار رفته‌اند (Haykin, 1990).

لایه‌ی اول لایه‌ی ورودی است و فقط نقش انتقال ورودی‌ها به لایه‌ی پنهان را دارد. لایه‌ی بعدی لایه‌ی پنهان است که در شبکه‌ی RBF تعداد نرون زیادی دارد. هر نرون لایه [j] در لایه‌ی پنهان، یک الگوریتم مشخص را پیاده‌سازی می‌نماید که از دو گام تشکیل شده است:

در گام اول، تفاضل هر ورودی  $p_i$  ( $i=1,2,\dots,R$ ) نسبت به وزن منسوب به آن ( $W_{ij}$ ) محاسبه می‌شود و تحت عمل تابع فاصله‌ی اقلیدسی یا نرم قرار گرفته و در نهایت با ضرب مقدار حاصله در مقدار آستانه، مقدار  $n$  به دست می‌آید.

$$b_i n_j = \|p_i - w_{ji}\| \quad (۵)$$

فاصله‌ی اقلیدسی طبق رابطه‌ی ۶ زیر تعریف می‌گردد:

$$\|x\| = \sqrt{x^T x} \quad (۶)$$

بنابراین یکی از تفاوت‌های شبکه‌ی RBF با شبکه‌ی MLP، در رابطه‌ی تعریف شده برای مقدار  $n$  است که در اولی تفاضل فاصله‌ی اقلیدسی بردار ورودی با بردار وزن و در شبکه‌ی MLP حاصل ضرب داخلی این دو بردار می‌باشد. در گام دوم، تابع فعال‌ساز  $f$ ، بر روی  $n$  اعمال می‌گردد تا خروجی نرون به دست آید. معروف‌ترین توابع فعال‌ساز مورد استفاده در شبکه‌های RBF، برای لایه‌ی پنهان، توابع گوسی نمایی و برای لایه‌ی خروجی تابع همانی هستند. تابع گوسی نمایی به صورت رابطه‌ی ۷ تعریف می‌گردد:

$$F(n_j) = \exp(-n_j)^2 \quad (۷)$$

از ویژگی‌های مثبت شبکه‌های RBF، یادگیری سریع، امکان آموزش با کم‌ترین مجموعه داده‌های اولیه، تعیین اندازه‌ی بهینه شبکه توسط خود الگوریتم و عدم وجود مشکل حداقل‌های محلی می‌باشد.

### ۴. آماده سازی داده‌های ورودی به مدل

در مدل‌سازی قبل از ورود داده‌ها به مدل باید یک سری پردازش بر روی داده‌های ورودی صورت گیرد. در صورتی که داده‌ها به صورت خام وارد مدل شوند به علت تغییر زیاد داده‌ها خروجی مدل متفاوت خواهد بود. لذا در ابتدا لازم است که داده‌ها معیار سازی شوند یعنی بایستی داده‌ها بین ۰ و ۱ مطابق رابطه (۸) استانداردسازی شوند (مختاری، ۱۳۸۰).

<sup>۴</sup> Radial basic function



بنابراین داده‌های ورودی با توجه به میزان داده‌های حداکثر و حداقل استاندارد شدند. داده‌ها پس از پیش‌بینی به مقدار اولیه برگردانده شدند تا با مقدار مشاهده شده مقایسه شوند. این عمل که نرمالیزه کردن داده‌ها خوانده می‌شود از روش‌های استانداردسازی دیگر کاربردی‌تر می‌باشد.

$$N_i = \frac{R_i - \text{Mini}}{\text{Maxi} - \text{Mini}} \quad (8)$$

که در آن بیش‌ترین و کمترین داده‌های واقعی  $\text{Mini}$  و  $\text{Maxi}$ ، مقدار استاندارد شده داده واقعی  $N_i$ ، مقدار واقعی داده  $R_i$  می‌باشد.

#### ۵. تعیین ساختار بهینه و ارزیابی عملکرد مدل

در شبکه‌ی عصبی ساختار شبکه شامل نوع ورودی‌ها و خروجی‌ها، تعداد لایه‌های مخفی و تعداد نرون‌ها در هر لایه مخفی، نوع تابع فعال‌سازی و نوع الگوریتم آموزشی می‌باشد. تعیین تعداد لایه‌ها و تعداد نرون‌ها در هر لایه و همچنین نحوه ارتباط آن‌ها با یکدیگر از مواردی است که در معماری شبکه از اهمیت برخوردار است. معیار خاصی برای تعیین تعداد لایه‌ها و تعداد نرون‌ها در لایه میانی ارائه نشده است ولی معمولاً از روش سعی و خطا استفاده می‌شود. لایه‌های میانی ممکن است یک یا چند عدد باشند که به نوع داده‌ها و میزان خطای شبکه بستگی دارد همچنین تعداد نرون‌ها در لایه مخفی نقش مهمی در کارایی مدل شبکه‌ی عصبی بازی می‌کند. در این پژوهش ترکیب متفاوت پارامترهای ورودی و تعداد لایه‌های مخفی با یک خروجی خاص (آورد رسوب) مورد آزمایش قرار گرفته و از ریشه میانگین مربعات خطای مدل شبکه عصبی مصنوعی برای انتخاب ساختار بهینه استفاده شد. ارزیابی عملکرد مدل‌ها و دقت پیش‌بینی به وسیله معیارهای سنجش خطا و دقت مورد بررسی قرار می‌گیرد. معیارهای مورد استفاده در این تحقیق شامل موارد زیر می‌باشند:

#### ۵-۱- ضریب تعیین ( $R^2$ )

معیاری بدون بعد و بهترین مقدار آن برابر یک می‌باشد رابطه (۹) نحوه محاسبه آن را نشان می‌دهد (صدقت کردار، ۱۳۸۷).

$$R^2 = \frac{\sum_1^K X_K Y_K}{\sqrt{\sum_1^K X_K^2 \sum_1^K Y_K^2}}$$

در این رابطه  $XK$  مقادیر مشاهداتی،  $YK$  مقدار برآورد شده، و  $K$  تعداد داده‌ها می‌باشد.

#### ۲.۵. ریشه میانگین مربعات خطا (RMSE)

از این شاخص جهت سنجش میزان خطا استفاده می‌شود. این شاخص بیان‌کننده میزان اختلاف داده‌های واقعی و داده‌های محاسبه شده می‌باشد که هر چه میزان آن به صفر نزدیک‌تر باشد نشان‌دهنده خطای کمتر و قابل‌قبول بودن مدل می‌باشد. رابطه (۱۰) نحوه محاسبه آن را بیان می‌کند (تقی زاده مهرجردی، ۱۳۸۸).

(۱۰)


$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{act} - \bar{y}_{est})^2}{n}}$$

$y_{act}$ : مقادیر مشاهده شده،  $\bar{y}_{est}$ : میانگین مقادیر پیش‌بینی شده،  $n$ : تعداد کل داده‌ها


در این تحقیق از ضریب تعیین  $R^2$  برای سنجش دقت مدل‌ها و از شاخص ریشه میانگین مربعات خطا برای سنجش میزان خطای مدل استفاده گردید.

### ۳- نتایج

مقادیر رسوب برداشت شده توسط تله‌های رسوب‌گیر در طی ۱۲ دوره نمونه‌برداری به گرم در مترمربع در سه سایت گیاهی در نمودارهای (۱، ۲ و ۳) قابل مشاهده می‌باشد.




نمودار ۱- میزان رسوب اندازه‌گیری شده در سایت هالکنوم در طی دوره آماری



نمودار ۲- میزان رسوب اندازه‌گیری شده در سایت شورگزر در طی دوره آماری







نمودار ۳- میزان رسوب اندازه‌گیری شده در سایت جگن در طی دوره آماری

همان طور که نمودارهای فوق نشان می‌دهند در این سه سایت نمونه‌برداری توزیع رسوبات متفاوت می‌باشد، بطوریکه بیش‌ترین رسوبات برداشت‌شده در سایت هالکنوموم و کمترین میزان رسوب در سایت جگن اندازه‌گیری گردید. همچنین در مدت ۱۲ دوره نمونه‌برداری در دوره‌های ۵ و ۹ سرعت باد حداکثر می‌باشد و علت کمتر بودن میزان رسوبات دوره ۵ نسبت به دوره‌های ۸ به بعد به علت وجود بارندگی مربوط به دوره قبل از آن می‌باشد. پایین بودن میزان رسوب در دوره‌های ۴ و ۶ نیز به علت وجود بارندگی در منطقه می‌باشد. در ابتدای دوره نمونه‌برداری میزان رسوبات برداشت‌شده تقریباً حالت ثابتی داشته است اما در دوره‌های ۴-۵-۶ به علت وجود نوسانات بارندگی میزان رسوب نیز پایین می‌باشد هرچند سرعت باد بالا باشد. نمونه بارز و عینی آن دوره ۵ می‌باشد. دوره‌های ۸-۱۲ به علت افزایش نسبی در میزان سرعت باد، دما، تبخیر و همچنین کاهش میزان بارندگی، رطوبت نسبی میزان رسوب بیشتری نسبت به دوره‌های ماقبل خود دارد. هدف از اندازه‌گیری رسوبات و کمی کردن آن مقایسه این رسوبات با رسوبات شبیه‌سازی شده توسط شبکه‌های عصبی می‌باشد. در این پژوهش میزان رسوب شبیه‌سازی شده توسط شبکه‌های عصبی با مقادیر رسوب برداشت‌شده توسط تله‌های رسوب‌گیر مقایسه شدند. معماری شبکه‌ی عصبی پرسپترون چند لایه این گونه انتخاب شد که تابع تبدیل لایه میانی، تانژانت هایپربولیک و تابع تبدیل لایه خروجی سیگموئید استفاده گردید. این شبکه عصبی از سه لایه تشکیل شده که عبارت‌اند از ۱- لایه ورودی، شامل چند نرون است که در این پژوهش، ۷ نرون یا پارامتر ورودی می‌باشد. ۲- لایه پنهان، شامل تعدادی نرون متغیر است که تعداد بهینه آن‌ها از طریق حداقل شدن خطای آزمایش و تکرار آن تعیین می‌گردد. ۳- لایه خروجی، که شامل ۱ نرون می‌باشد که همان میزان رسوب پیش‌بینی شده است. داده‌های ورودی به مدل از نظر برخی معیارهای آماری از قبیل میانگین، انحراف معیار، و ضریب چولگی با هم مقایسه شدند. سپس داده‌ها وارد مدل‌سازی شدند و میزان رسوب مشاهده‌ای به عنوان متغیر وابسته و پارامترهای سرعت باد، بارش، پوشش گیاهی، تبخیر، رطوبت نسبی، دمای ماکزیمم، دمای مینیمم و دمای متوسط به عنوان متغیرهای مستقل مدل در نظر گرفته شد. تعداد کل آمار در نظر گرفته شده ۱۲ رویداد رسوب است، که ۸ عدد آن‌ها در آموزش شبکه و ۴ جهت آزمایش (کنترل اعتبار) به کار گرفته شده‌اند. تابع انتقال لایه مخفی تانژانت هایپربولیک و تابع انتقال جهت لایه خروجی سیگموئید می‌باشد و تعداد ۱ لایه ورودی و ۷ نرون در آن و یک لایه خروجی و یک نرون در آن، تعداد لایه‌های مخفی یک لایه با ۳ نرون تعیین گردید. الگوریتم آموزش در هر همه مدل‌های شبکه عصبی پس انتشار خطا روش گرادیان دوگانه درجه‌بندی شده انتخاب گردید. خصوصیات شبکه در هر

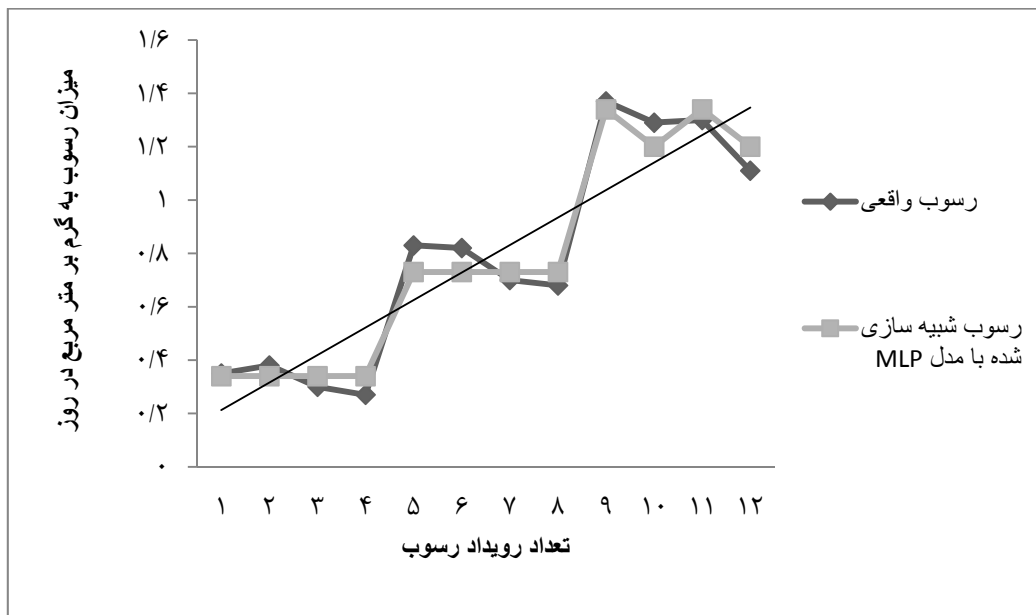
سه تیپ یکسان در نظر گرفته شد. نمودارهای (۴، ۵ و ۶) نمودارهای رسوبات شبیه‌سازی را با رسوبات مشاهده‌ای توسط شبکه عصبی MLP نشان می‌دهد. نتایج حاصل از عملکرد شبکه پرسپترون چند لایه در جدول (۱) بیان شده است.



نمودار ۴- نمودار شبیه‌سازی شده نسبت به نمودار مشاهده‌شده در تیپ گیاهی *Halocnemum*



نمودار ۵- نمودار شبیه‌سازی شده نسبت به نمودار مشاهده‌شده در سایت گیاهی *Tamarix*



نمودار ۶- نمودار شبیه‌سازی شده نسبت به نمودار مشاهده شده در سایت گیاهی *juncus*


بار دیگر به منظور مدل‌سازی و پیش‌بینی رسوبات بادی در تیپ‌های گیاهی از شبکه‌ی عصبی RBF استفاده گردید. در این روش نیز متغیرهای مستقل و وابسته مانند روش قبل انتخاب گردید. تعداد کل آمار و داده‌های آموزش و تست در این روش نیز مانند شبکه عصبی MLP انتخاب شدند. در این مدل تابع انتقال، لایه‌ی مخفی Softmax و تابع انتقال، لایه‌ی خروجی Identity بود که نسبت به شبکه عصبی MLP متفاوت بود. نمودارهای (۷، ۸ و ۹) نمودار شبیه‌سازی شده نسبت به نمودار مشاهده شده توسط شبکه RBF را نشان می‌دهند.



نمودار ۷- نمودار شبیه‌سازی شده نسبت به نمودار مشاهده شده در سایت گیاهی *Halocnemum*



نمودار ۸- نمودار شبیه‌سازی شده نسبت به نمودار مشاهده شده در سایت گیاهی *Tamarix*



نمودار ۹- نمودار شبیه‌سازی شده نسبت به نمودار مشاهده شده در سایت گیاهی *Juncous*

نتایج حاصل از عملکرد این مدل نیز در جدول (۱) آمده است. نتایج به خوبی بیانگر دقت و عملکرد بالای شبکه‌های عصبی مصنوعی می‌باشد.

جدول ۱- نتایج ارزیابی مدل‌ها

مدل	مدل	عملکرد مدل	سایت گیاهی
MLP	RBF	RMSE	Halocnemum Strobilaceum
۰/۰۲	۰/۷۱	R <sub>۲</sub>	
۰/۹۵	۰/۸۸	RMSE	Tamarix Aphylla
۰/۰۷	۰/۴۰	R <sub>۲</sub>	
۰/۹۳	۰/۹۰	RMSE	Juncus Jerardi
۰/۰۶	۰/۶۴	R <sub>۲</sub>	
۰/۹۱	۰/۸۷		

شبکه عصبی مصنوعی MLP در مقایسه با شبکه عصبی RBF از دقت بیشتر برخوردار می‌باشد و همچنین میزان خطای کمتری دارد. این مطلب به خوبی در تحقیقات صیادی و اولاد غفاری بیان شده است. ایشان میزان تبخیر و تعرق اندازه‌گیری شده را با تبخیر و تعرق برآورد شده توسط شبکه‌های عصبی مقایسه نمودند نتایج ایشان نشان داد شبکه‌های عصبی مصنوعی از دقت و عملکرد بالایی برخوردارند و همچنین از مقایسه دو شبکه عصبی مصنوعی MLP و RBF شبکه عصبی MLP از دقت نسبتاً بیشتری برخوردار می‌باشد.

شبکه عصبی MLP در مقایسه با شبکه عصبی RBF از انعطاف بیشتری برخوردار است که به عنوان مزیت این شبکه محسوب می‌شود. با توجه به انعطاف‌پذیری شبکه عصبی MLP به منظور تعیین بهترین معماری شبکه عصبی، این شبکه از نظر تعداد لایه مخفی، تعداد نرون لایه مخفی، تعداد مجموعه آموزش، الگوریتم آموزش، تعداد لایه ورودی، تعداد نرون لایه ورودی، تعداد الگوهای آموزش (رویداد رسوب) مورد آزمون قرار گرفت و مدلی با یک لایه پنهان و تعداد ۱۱ نرون، یک لایه ورودی با ۷ نرون در آن، تابع فعال‌سازی لایه میانی تانژانت هایپربولیک و لایه خروجی سیگموئید، تعداد ۸ رویداد رسوب برای آموزش و تعداد ۴ رویداد رسوب برای تست شبکه، با الگوریتم آموزش پس انتشار خطا روش گرادیان دوگانه درجه‌بندی شده به عنوان بهترین راندمان شبکه در برآورد میزان رسوب می‌باشد. شبکه‌های عصبی مصنوعی در مقایسه با مدل‌های دیگر می‌توانند در مدت زمان کوتاه‌تر و با دقت نسبتاً بالایی میزان رسوب برآورد کنند. مزیت دیگر این شبکه‌ها حساس نبودن آن‌ها نسبت به داده‌های کم ورودی به مدل در مقایسه با مدل‌های دیگر می‌باشد.

#### ۴- نتیجه‌گیری

شبکه‌های عصبی مصنوعی می‌توانند به عنوان ابزاری کارآمد در جهت برآورد و شبیه‌سازی رسوبات موثر واقع شوند. در این تحقیق از دو نوع شبکه عصبی مصنوعی برای برآورد و برازش مقدار رسوبات بادی در منطقه مورد مطالعه استفاده گردید. با در نظر گرفتن مقادیر رسوب مشاهده‌ای به عنوان مقادیر هدف در آموزش شبکه‌های عصبی، شبکه‌های متفاوتی با سناریوهای مختلف ایجاد شد و عملکرد آن‌ها مورد بررسی قرار گرفت. با بررسی‌های صورت گرفته مشخص شد که می‌توان با استفاده از عملکرد مدل‌ها مقدار رسوب به صورت روزانه، ماهانه در منطقه‌ی مورد مطالعه را از پارامترهای مذکور با دقت قابل قبولی برآورد نمود. شبکه‌های عصبی مصنوعی نسبت به مدل‌های دیگر عملکرد و کارایی بهتری دارد و نتایج Ardicioglo at all, 2007 این مطلب را به خوبی بیان کرده است آن‌ها از شبکه عصبی مصنوعی برای برآورد رسوبات معلق استفاده کردند و از دو الگوریتم متفاوت شبکه عصبی برای این کار بهره گرفتند و نتایج حاصله را با

رگرسیون خطی چندگانه مقایسه کردند و اعلام نمودند که شبکه عصبی مصنوعی نتیجه بهتری را نشان می‌دهد. همچنین تحقیق دستورانی و همکاران (۱۳۹۰) با نتایج بخشی از این تحقیق مطابقت دارد ایشان کارایی شبکه‌های عصبی مصنوعی (مدل پرسپترون چند لایه) را جهت پیش‌بینی رسوب معلق مورد ارزیابی کردند و با منحنی سنج رسوب مقایسه نمودند. نتایج ایشان حاکی از دقت عملکرد بالای شبکه‌های عصبی مصنوعی نسبت به منحنی سنج رسوب می‌باشد نتایج این تحقیق حکایت از عملکرد و کارایی و قدرت بالای دو روش شبکه عصبی در پردازش داده‌ها و شبیه‌سازی و برآورد رسوبات دارد که در این میان شبکه‌های MLP نسبت به شبکه عصبی RBF از دقت عملکرد نسبتاً بیشتری در برآورد مقادیر رسوب برخوردار بودند. همچنین انعطاف‌پذیری این شبکه نیز بیشتر می‌باشد. نتایج تحقیقات صیادی و همکاران (۱۳۸۸) برای برآورد میزان تبخیر و تعرق از مقایسه دو شبکه عصبی MLP و RBF نشان داد که شبکه عصبی MLP از دقت نسبتاً بیشتری برخوردار می‌باشد که با نتایج این تحقیق مطابقت دارد. بنابراین می‌توان اظهار داشت شبکه عصبی پرسپترون چند لایه MLP با توجه به کارایی بالای آن با ضریب تعیین ۰/۹۵ و ریشه میانگین مربعات خطای ۰/۲۰ به عنوان یک روش مناسب جهت برآورد رسوبات بادی در منطقه‌ی کرسیای داراب باشد و عملکرد آن به عنوان ابزار قوی در برآورد و پیش‌بینی پذیرفته شود. طبیعتاً با گذشت زمان در سال‌های آتی و افزایش اطلاعات در دسترس، دقت این شبکه نیز افزایش یافته و برای پیش‌بینی‌های سالانه و بلندمدت نیز کاربرد خواهد داشت.

۱. احمدی، ح.، ژئومرفولوژی کاربردی، جلد ۲، فرسایش بادی، ۱۳۸۷. انتشارات دانشگاه تهران، ۷۰۶ ص.
۲. تقی‌زاده مهرجردی، ر.، ش. محمودی، ا. حیدری، و ع. اکبر زاده. ۱۳۸۸. پیش‌بینی ظرفیت تبادل کاتیونی خاک با استفاده از شبکه عصبی و رگرسیون چند متغیره در منطقه خضراآباد، مجله پژوهش در علوم خاک، جلد ۵، شماره ۱، تابستان ۱۳۸۸، ۱۱-۱ ص.
۳. دستورانی، م.ت.، خ. عظیمی فشی، ع. طالبی، و م.ر. اختصاصی، ۱۳۹۱. برآورد رسوبات معلق با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: حوزه آبخیز جامیشان استان کرمانشاه). پژوهشنامه مدیریت حوزه آبخیز دانشگاه علوم کشاورزی و منابع طبیعی ساری، سال سوم، پاییز و زمستان، شماره ۶، ۶۱-۷۴ ص.
۴. شکاری، م.ر.، ۱۳۹۰. کاربرد شبکه‌های عصبی مصنوعی در مدل‌سازی رسوبات معلق بادی"، پایان‌نامه کارشناسی ارشد، دانشگاه کاشان، دانشکده منابع طبیعی و علوم زمین.
۵. صداقت‌کردار، ع.، و ا. فتاحی، ۱۳۸۷. شاخص‌های پیش‌آگاهی خشکسالی در ایران. مجله جغرافیا و توسعه دانشگاه سیستان و بلوچستان، ج ۶، ش ۱۱، ۷۶-۵۹ ص.
۶. صیادی، ح.، و ا. اولاد غفاری، ۱۳۸۸. مقایسه عملکرد شبکه‌های عصبی MLP و RBF در برآورد تبخیر و تعرق گیاه مرجع. مجله دانش آب و خاک، دانشکده کشاورزی، دانشگاه تبریز، ج ۱۹، ش ۱، ۱۲-۱ ص.
۷. مختاری، م.، ۱۳۸۰. کاربردهای Matlab و Simulink در مهندسی، چاپ اول، ترجمه صمدی بخارایی، مرکز انتشارات خراسان، ۱۸۰ ص.
۸. ولی، ع.، ۱۳۸۵. تأثیر گونه‌های *Juncus gerardi* و *Halocnemum strobilaceum* بر برخی خصوصیات خاک محیط ریشه (مطالعه موردی در دشت شوره‌زار کرسیای داراب)، مجله علوم و فنون کشاورزی و منابع طبیعی، شماره ۱، صفحه ۲۶۳.
۹. ولی، ع.، م. معیری، م.ح. رامشت، و ن. معتمدی‌نیا، ۱۳۸۹. تحلیل مقایسه عملکرد شبکه‌های عصبی مصنوعی و مدل‌های رگرسیونی پیش‌بینی رسوب معلق مطالعه موردی: حوزه آبخیز اسکندری واقع در حوزه آبریز زاینده‌رود، مجله پژوهش‌های جغرافیای طبیعی دانشگاه تهران، شماره ۷۱، ۳۰-۲۱ ص.
10. Ardicioglo, M., O. Kisi and T. Haktanir., 2007. Suspended sediment prediction using two different feed-forward back-propagation algorithms. *Canadian Journal of Civil Engineering*, 34(1): 120-125.
11. Beale, R., And Jackson, T., 1990. Neural computing, Adam Hilger, USA.
12. Goossens D., And Z. Offer., 2000. Wind tunnel and "eld calibration of six aeolian dust samplers. *Atmospheric Environment*, 34(1043-1057).
13. Hagan, M.T., 1996. Neural Network desing, pws publishing co., Boston.
14. Hamidi, N., and N. Kayaalp., 2008, Estimation of the amount of suspended sediment in the Tigris River using artificial neural networks. *Clean*, 36(4): 380- 386.
15. Haykin, s., 1990. Neural Network, prentice-Hall Inc., New Jersey.
16. Melesse, A.M., S. Ahmad., M.E. McClain, X. Wang, and Y.H. Lim., 2011. Suspended sediment load prediction of river systems: An artificial neural network approach. *Agricultural Water Management*, 98(5): 855-866.
17. Zhu, Y.M., X.X. Lu., and Y. Zhou., 2007. Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the Upper Yangtze Catchment. *Geomorphology*, 84: 111-125.





Quarterly Journal of  
Environmental Erosion Researches  
No. 12, winter 2014, pp: 1-16  
www.magazine.hormozgan.ac.ir

## Application of Two Methods of Artificial Neural Network MLP, RBF for Estimation of Wind of Sediments (Case Study: Korsya of Darab Plain)

Shekari. M.R<sup>1\*</sup>, Sadati Nejad. J<sup>2</sup>, Vali. A<sup>3</sup>, Ghasemiye. H<sup>4</sup>, Ghazavi. R<sup>5</sup>

- 1- \*Corresponding Author: PhD student, University of Kashan
- 2- Associate professor, Faculty of New Sciences and Technologies, University of Tehran
- 3- Assistant Professor, Faculty of Natural Resources and Earth Sciences, University of Kashan
- 4- Assistant Professor, Faculty of Natural Resources and Earth Sciences, University of Kashan
- 5- Assistant Professor, Faculty of Natural Resources and Earth Sciences, University of Kashan

### Abstract

The lack of sediment gauging stations in the process of wind erosion, caused of estimate of sediment be process of necessary and important. Artificial neural networks can be used as an efficient and effective of tool to estimate and simulate sediments. In this paper two model multi-layer perceptron neural networks and radial neural network was used to estimate the amount of sediment in Korsya of Darab city. The simulations were performed with two methods common artificial neural network Initially, the sediment was sampled with sediment traps afterward by climatic factors such as average wind speed, evaporation, precipitation, relative humidity, minimum temperature, maximum temperature, average temperature and Percentage of vegetation, respectively, as the dependent variable and independent input to the model was chosen to simulate the sediment. The Results of the performance model show that MLP neural network (feedforward Back propagation algorithm) with learning technique of Calibrated dual gradient Compared to radial Neural Network Respectively with coefficient of determination .95 , Roots mean square error .02 and coefficient of determination .90 , Roots mean square error .40 for estimate of wind deposits were the higher efficiency and accurate. Course, it should be noted that an important advantage of the artificial neural network Multilayer Perceptron to Neural Network Radial is more flexibility.

### Keywords:

Neural Network MLP, Neural Network RBF, Simulation, Sediment Traps, Sediment Wind