



## برآورد تبخیر از سطح مخزن با استفاده از مدل شبکه‌ی عصبی مصنوعی (مطالعه‌ی موردی، سد میناب)

محمد حسین جهانگیر<sup>۱\*</sup>، احمد نوحه‌گر<sup>۲</sup>، کیوان سلطانی<sup>۳</sup>  
وصول مقاله: ۱۳۹۶/۰۱/۱۴ تأیید نهایی مقاله: ۱۳۹۷/۰۶/۱۴

### چکیده

تبخیر به عنوان یکی از پارامترهای طبیعی به علت نقش مهمی که در خروج آب از دسترس بشر دارد، همواره مورد توجه کارشناسان و محققان بوده است. در این پژوهش سعی شده است تا با بکارگیری مدل شبکه‌ی عصبی مصنوعی در برآورد تبخیر از سطح دریاچه‌ی سد میناب، میزان دقت مدل مورد ارزیابی قرار گیرد. برای بررسی روند تغییرات پارامترهای مؤثر بر تبخیر برای اطلاعات ۱۹ ساله موجود، با استفاده از رگرسیون غیرخطی بهترین برازش از بین نقاط موجود برای داده‌ها ترسیم و روند کلی تغییرات پارامترهای مؤثر بر تبخیر مشخص شده است. همچنین برای مدل‌سازی تبخیر با استفاده از شبکه‌ی عصبی مصنوعی از آمار ۱۹ ساله، از سال ۱۳۷۴ تا ۱۳۹۲ استفاده و بهترین ساختار برای محاسبه‌ی میزان تبخیر از سطح دریاچه‌ی سد میناب انتخاب شده است. در این ساختار لایه‌ی اول و دوم دارای ۵ نورون می‌باشند که با ۱۰۰۰ تکرار برای محاسبه‌ی آن، بهترین نتیجه به دست آمد. ضرایب آماری به دست آمده از تحلیل با استفاده از شبکه‌ی عصبی مصنوعی در انتخاب بهترین ساختار مورد توجه قرار گرفت که در این ساختار ضریب همبستگی با مقدار  $0/8941$  دارای بیشترین مقدار در بین آزمون‌های دیگر است و مقادیر خطا برای داده‌های آموزش و آزمایش نیز به ترتیب برابر با  $0/0011$  و  $0/0082$  است که پس از این ساختار، ساختارهای ANN (۳،۷،۱)، ANN (۴،۱۰،۱)، ANN (۴،۱۱،۱)، ANN (۵،۳،۱) دارای مقادیر ضریب همبستگی و خطای قابل قبولی در تعیین مقدار تبخیر از دریاچه‌ی سد میناب می‌باشند.

کلمات کلیدی: شبکه‌ی عصبی مصنوعی، تبخیر سطحی، برازش غیرخطی، ضریب همبستگی، سد میناب.

۱- استادیار گروه انرژی‌های نو محیط زیست، دانشکده‌ی علوم و فنون نوین، دانشگاه تهران، تهران، ایران (نویسنده‌ی مسئول).  
E-mail: mh.jahangir@ut.ac.ir

۲- استاد گروه برنامه‌ریزی مدیریت و آموزش محیط زیست، دانشکده‌ی محیط زیست، دانشگاه تهران، تهران، ایران.

۳- دانشجوی کارشناسی ارشد، دانشکده‌ی علوم و فنون نوین، دانشگاه تهران، تهران، ایران.

## مقدمه

تأثیر خشکسالی بر بخش‌های مختلف، یکسان نمی‌باشد. در شرایطی که مناطق مختلف کشور با کاهش محسوس بارندگی مواجه شده‌اند، تأثیر آن بر منابع آب هنوز ملموس نشده و یا کاهش منابع آب‌های سطحی تأثیری بر تولیدات کشاورزی نداشته باشد (ستاری و همکاران، ۱۳۹۵). افزایش یا کاهش در سری‌های زمانی هیدرولوژیکی می‌تواند به وسیله‌ی تغییر در عوامل بارش، تبخیر، دما و... توصیف گردد (نورانی، ۱۳۹۵). مدلسازی تبخیر از سطح مخازن به منظور پیش‌بینی میزان تبخیر از سطح و میزان هدر رفت آب از طریق تبخیر و آب خارج شده از دسترس و برنامه‌ریزی صحیح و کاربردی در جهت کاهش میزان این تبخیر و برآورد اقتصادی آن کار حائز اهمیت می‌باشد. با این پیش‌بینی می‌توان تصمیمات کاربردی و اقتصادی به منظور کاهش تبخیر و در پی آن افزایش میزان آب در دسترس و افزایش بازدهی و تولید محصول را اتخاذ نمود (ما و همکاران<sup>۱</sup>، ۲۰۱۱؛ نورانی و سیاح فرد، ۱۳۹۲). مدل‌های آماری و تجربی مرسوم اگرچه ابزاری اساسی در نشان دادن متغیرهای هیدرولوژیکی و درک قوانین و مقررات حاکم بر یک سیستم هستند، اما محدودیت‌های زیادی دارند که استفاده از این مدل‌ها را برای کاربران دشوار و پرهزینه کرده است (دیسوال و پال<sup>۲</sup>، ۲۰۰۸). سنگینی حجم محاسبات و زمان بر بودن انجام آنها خصوصاً در پدیده‌هایی نظیر سیل که به صورت ناگهانی اتفاق می‌افتد همه ساله باعث ایجاد خسارت‌های مالی و جانی فراوانی می‌شود (جهان‌بخش اصل و همکاران، ۱۳۹۰؛ باباعلی و دهقانی، ۱۳۹۶). پس در این راستا کارشناسان و متخصصان با بکارگیری مدل‌های هوشمند در وقت و هزینه صرفه‌جویی کرده و نتایج قابل قبولی را در زمان مناسب از داده‌های موجود به دست آورند (تابش و دینی، ۲۰۱۰؛ بابامیری و دین‌پژوه، ۱۳۹۵). در چند سال اخیر مدل‌های هوش مصنوعی (AI<sup>۳</sup>) به طور گسترده در تخمین پارامترهای هیدروژئولوژیکی مورد استفاده قرار گرفته‌اند (ندیری و

1- Ma et al.,

2- Deswal and Pal

3- Artificial Intelligence

یوسفزاده، ۱۳۹۶) یکی از این ابزارهای پرکاربرد و هوشمند، شبکه‌ی عصبی مصنوعی<sup>۱</sup> می‌باشد که با برقراری روابط مناسب بین متغیرهای ورودی در کمترین زمان ممکن به خروجی قابل قبولی رسیده و رابطه را با ابزار خروجی برقرار کرده و نتیجه را در بهترین حالت ممکن به کارشناسان ارائه می‌دهد (رجایی و همکاران<sup>۲</sup>، ۲۰۱۰). در این راستا مطالعاتی نیز در دنیا انجام گرفته است که از جمله آنها می‌توان به مطالعه‌ی تأثیر ترکیبات مختلف پارامترهای اقلیمی بر تلفات تبخیر مخزن سد اشاره کرد (دیسوال و پال، ۲۰۰۸). همچنین یک مدل ANN برای تخمین میزان تبخیر آب موجود در خاک محیط گلخانه در چین به کار گرفته شده است که نتایج، دقت بالای این روش را نشان می‌دهد. طبری و همکاران نیز در تحقیق خود برای تخمین میزان تبخیر از تشتک در ناحیه‌ای با اقلیم نیمه خشک در ایران، مدل‌های ANN و رگرسیونی را به کار برده‌اند که نتایج، برتر بودن مدل شبکه‌ی ANN را به مدل رگرسیونی در تخمین نزدیک به واقعیت نشان می‌دهد (طبری و همکاران<sup>۳</sup>، ۲۰۱۰). علیپور و نساجی‌زاده در سال ۲۰۱۱ تحقیقی در شهر بروجرد انجام دادند و میزان تبخیر روزانه را با استفاده از شبکه‌ی عصبی مصنوعی مدل‌سازی نمودند که بهترین ساختار (5-4-1) ANN با MSE برابر ۰/۰۰۶۷۱۶ و  $R^2$  برابر با ۰/۷۲۵۳۹۸ شناخته شد (علیپور و نساجی‌پور، ۲۰۱۱). با توجه به تحقیقات انجام گرفته مدل شبکه‌ی عصبی دارای نتایج قابل قبول در برابر مدل‌های عددی و مرسوم می‌باشد و درصد خطا را به میزان قابل توجهی کاهش می‌دهد.

### مواد و روش‌ها

#### – منطقه‌ی مورد مطالعه

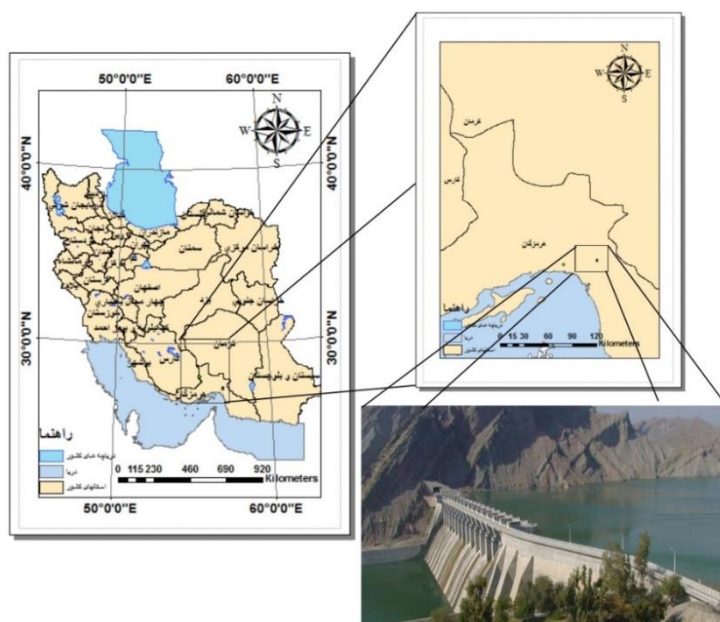
سد میناب با ارتفاع ۵۹ متر، عرض پی و تاج سد به ترتیب ۵۸ متر و ۳ متر و ترازهای تاج در حداکثر ارتفاع آب و تراز نرمال آب مخزن به ترتیب ۱۰۰/۵، ۹۹/۴ و ۹۸/۵ متر از سطح دریا در استان هرمزگان قرار گرفته است. زمین‌شناسی، انواع سنگ‌های رسوبی

1- Artificial Neural Networks (ANNs)

2- Rajaei et al.,

3- Tabari et al.,

محل سد که به صورت متناوب قرار گرفته‌اند، به صورت ترکیبی از ماسه سنگ، ماسه سنگ مارنی، ماسه سنگ سیلتی، مارن ماسه‌ای (لای سنگ ماسه‌ای) مارن (لای سنگ، گل سنگ)، مارن رسی (لای سنگ رسی)، سنگ‌های مزبور مربوط به دوره‌ی الیگومیوسن (فارس) می‌باشند. از جمله اهداف احداث این سد می‌توان به محافظت مناطق زیر کشت در مقابل سیلاب‌ها، تنظیم آب رودخانه، آبیاری نخلستان‌ها براساس سیستم جدید آبیاری با توجه به شرایط طبیعی و محدودیت‌های آن، توسعه و افزایش سطح زیر کشت، مقابله با خطرات شوری زمین به‌علت ارتباط آب‌های شور زیرزمینی با سطح خاک، علاوه بر آبیاری ده‌هزار هکتار از زمین‌ها و باغ‌های مصرفی میناب، قسمت عمده‌ی آب شهر بندرعباس را نیز تأمین می‌کند.



شکل (۱) موقعیت مکانی و جغرافیایی سد میناب (استان هرمزگان)

در این تحقیق از میانگین بارندگی بر حسب میلی‌متر (mm)، درجه حرارت بر حسب درجه‌ی سانتی‌گراد (°C)، سرعت باد بر حسب متر بر ثانیه (m/s)، مساحت سطح دریاچه

برحسب کیلومتر ربع ( $\text{km}^2$ ) استفاده شده است و تمامی این اطلاعات در مقیاس ماهانه می‌باشند که این اطلاعات در بعد روزانه ورودی‌های اصلی شبکه‌ی عصبی مورد بحث را تشکیل می‌دهند. در ادامه نمودارهای مربوط به داده‌های ماهانه در بین بازه‌ی سال‌های ۱۳۷۴ تا ۱۳۹۲ به شبکه‌ی عصبی با استفاده از نرم‌افزار MATLAB رسم گردیده و بهترین برازش با استفاده از روابط غیرخطی برای هریک از آنها ارائه شد.

#### – روندیابی غیرخطی داده‌های هواشناسی


قبل از پرداختن به بحث مدلسازی و انتخاب مدل بهینه برای مناطق مورد بحث بهترین برازش غیرخطی از بین پارامترهای مؤثر بر تبخیر به دست آمده است برای منطقه‌ی مورد مطالعه برازش نمودار برای داده‌های دما ( $^{\circ}\text{C}$ )، بارندگی (mm)، سرعت باد ( $\text{Km/h}$ )، مساحت سطح دریاچه ( $\text{Km}^2$ ) و تبخیر (mm) انجام گرفت که نتایج و روابط به دست آمده برای هریک در ادامه آورده شده است.

#### – تغییر درجه حرارت ( $^{\circ}\text{C}$ )


با توجه به شکل (۲) تغییرات درجه حرارت طی سال‌های مورد بررسی در سد میناب به صورت منظم تغییر کرده و نمودار برازش داده شده برای این داده‌ها نوسان زیادی ندارد. جهت برازش داده‌ها در این نمودار از چندجمله‌ای درجه ۴ استفاده گردید که نسبت به سایر برازش‌ها دارای بیشترین ضریب همبستگی با مقادیر ۰/۸۹۴ می‌باشد.

#### – تغییر کمیت بارندگی (mm)

با توجه به خشک بودن منطقه مقادیر بارندگی بسیار کم و در خیلی از ماه‌ها صفر است که این مورد در شکل (۳) نیز مشخص است. با برازش نموداری درجه ۳ در بین داده‌های بارندگی مشخص است که این داده‌ها دارای نوسانات کم بوده و روند نسبتاً ثابتی را دنبال می‌کند ( $R^2=0/424$ ).




شکل (۲) تغییرات درجه حرارت هوا برحسب درجه سانتیگراد (۱۳۷۴-۱۳۹۲)



شکل (۳) تغییرات بارندگی برحسب میلی متر (۱۳۷۴-۱۳۹۲)

#### - تغییر سرعت وزش باد (Km/h)


با توجه به شکل (۴) مشخص است سرعت باد در سد میناب نوسانات زیادی داشته است، اما برازش نموداری روند ثابتی را دنبال کرده است. بهترین برازش برای این داده‌ها چندجمله‌ای درجه ۳ با ضریب همبستگی ۰/۹۸۵ می‌باشد.




شکل (۴) تغییرات سرعت باد برحسب کیلومتر بر ساعت (۱۳۷۴-۱۳۹۲)

– تغییر مساحت سطح دریاچه ( $km^2$ )

با توجه به شکل (۵) تغییرات سطح دریاچه در سطح میناب دارای نوسانات زیادی بوده است بطوری که از سال ۱۹۹۸ این مقداری کاهش پیدا کرده و تا سال ۲۰۰۶ این روند ادامه داشته است و از سال ۲۰۰۶ سیر صعودی را پیش گرفته و در بین سال‌های ۲۰۱۰ تا ۲۰۱۴ مقدار آن روبه کاهش گذارده است. بهترین برازش بر این نمودار، یک چندجمله‌ای از درجه ۴ با ضریب همبستگی ۰/۸۵۲ می‌باشد.



شکل (۵) تغییرات سطح دریاچه برحسب کیلومتر مربع (۱۳۷۴-۱۳۹۲)



شکل (۶) تغییرات تبخیر از سطح دریاچه برحسب میلی‌متر (۱۳۷۴-۱۳۹۲)

#### – روند تبخیر سطحی (mm)

با توجه به شکل (۶) سطح دریاچه این سد نوسانات تبخیر شبیه به نوسانات سطح دریاچه‌ی سد میناب می‌باشد و همانند نمودار برازشی برای سطح دریاچه‌ی سد میناب بهترین برازش برای تبخیر از نوع چندجمله‌ای درجه ۴ با ضریب همبستگی ۰/۷ می‌باشد (شکل ۶).


#### – روش شبکه‌ی عصبی مصنوعی

یک شبکه‌ی عصبی مصنوعی از سه لایه‌ی اصلی که عبارتند از لایه‌ی ورودی، لایه‌ی مخفی (لایه‌ی میانی) و لایه‌ی خروجی، تشکیل شده است (تراوره و همکاران، ۲۰۱۰). لایه‌ای که نتایج حاصل از تجزیه و تحلیل مدل از آن پدید می‌آید لایه‌ی خروجی مدل است (شکل ۷). لایه‌ی میانی نیز به‌عنوان پردازشگر مدل عمل کرده و گره‌های پردازشگر در این مرحله قرار دارند (ما و همکاران، ۲۰۱۰). در ساختار شبکه‌ی عصبی و برقراری رابطه بین ورودی‌ها جهت رسیدن به نتایج مطلوب از توابع انتقال مختلفی کمک گرفته

1- Traore et al.,



می‌شود. از جمله پرکاربردترین این توابع می‌توان تابع نمایی، سری فوریه و سری تیلور را نام برد. سری فوریه بسطی است که هر تابع متناوب را به صورت حاصل جمع تعدادی نامتناهی از توابع نوسانی ساده (سینوسی، کسینوسی یا تابع نمایی مختلط) بیان می‌کند (فلیکس کلین<sup>۱</sup>، ۱۹۷۹). سری تیلور یا بسط تیلور نمایش یک تابع به صورت مجموع بی‌نهایت جمله است که از مشتق‌های تابع در یک نقطه به دست می‌آید که اگر سری را دور نقطه صفر گسترش داده شود، سری مک‌لارن نامیده می‌شود (توماس جرج<sup>۲</sup>، ۱۹۹۶). در شبکه‌ی عصبی از این روابط و نظیر آنها برای برقراری رابطه منطقی بین ورودی‌ها و خروجی‌ها استفاده می‌شود تا کمترین خطا در محاسبه‌ی خروجی‌های مدل پدید آید. یکی از ساده‌ترین و در عین حال کارآمدترین چیدمان‌های پیشنهادی برای استفاده در مدل‌سازی عصب‌های واقعی مدل پرسپترون چندلایه<sup>۳</sup> یا به اختصار MLP می‌باشد، که از یک لایه‌ی ورودی، یک یا چند لایه‌ی پنهان و یک لایه‌ی خروجی تشکیل یافته است. در این ساختار، تمام نرون‌های یک لایه به تمام نرون‌های لایه‌ی بعد متصل‌اند. این چیدمان اصطلاحاً یک شبکه با اتصالات کامل را تشکیل می‌دهد. شکل زیر شمای یک شبکه‌ی پرسپترون سه لایه را نشان می‌دهد (ردی<sup>۴</sup>، ۲۰۰۷).



شکل (۷) ساختار شبکه‌ی عصبی مصنوعی با لایه‌های ورودی، خروجی و میانی (مخفی)

- 1- Felix Klein
- 2- George Thomas
- 3- Multi Layer Perceptron
- 4- Reddy

می‌توان استنباط نمود که تعداد نرون‌های هر لایه، مستقل از تعداد نرون‌های دیگر لایه‌ها می‌باشد. در این روش میزان تغییر وزن‌ها در هر گام عبارت است از:

$$\Delta W_{ji} = -\eta \frac{\partial E}{\partial w_{ji}} \quad \text{رابطه‌ی (۱)}$$

در رابطه‌ی (۱) آن  $\eta$  ثابت اصلاح وزن‌ها می‌باشد. این ثابت نرخ همگرایی الگوریتم را تعیین می‌کند (ذوقی و سعیدی، ۲۰۱۱). به منظور یافتن میزان اصلاح وزن‌ها در هر مرحله نیز از فرمول زیر استفاده می‌گردد که مشتق خطا بر حسب وزن‌ها می‌باشد.

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial O_j} \cdot \frac{\partial O_j}{\partial w_{ji}} \quad \text{رابطه‌ی (۲)}$$

به‌وضوح می‌توان دید که خروجی تابع تحریک عصب فقط به ورودی و وزن‌های متناظر بستگی دارد. با فرض اینکه تابع خروجی، سیگموئید باشد می‌توان خروجی عصب  $z$  را به‌صورت زیر نوشت:

$$O_j(\bar{x}, \bar{w}) = \text{sgm}(A_j(\bar{x}, \bar{w})) = \frac{1}{1 + e^{A_j}} \quad \text{رابطه‌ی (۳)}$$

خطای کلی شبکه را به فرم مجموع خطای تک‌تک عصب‌های لایه‌ی خروجی را می‌توان به صورت زیر نوشت:

$$E(\bar{x}, \bar{w}, \bar{d}) = \sum_j E_j(\bar{x}, \bar{w}, d_j) = \sum_j (O_j(\bar{x}, \bar{w}) - d_j)^2 \quad \text{رابطه‌ی (۴)}$$

در نهایت نیز با توجه به اینکه شبکه عصبی مصنوعی دارای سه لایه‌ی ورودی، خروجی و پنهان است رابطه‌ی نهایی اصلاح وزن‌ها به‌صورت زیر خواهد بود (ذوقی و سعیدی، ۲۰۱۱):

$$\frac{\partial E}{\partial w_{ji}} = 2(O_j - d_j)O_j(1 - O_j)w_{ji} \quad \text{رابطه‌ی (۵)}$$

## بحث و نتایج

### – مدلسازی شبکه‌ی عصبی مصنوعی برای سد میناب

جهت استفاده از شبکه‌ی عصبی مصنوعی در برآورد تبخیر از سد میناب از اطلاعات روزانه در بین سال‌های ۱۹۹۸ تا ۲۰۱۴ به نرم‌افزار MATLAB معرفی گردید. به این منظور از درصد رطوبت نسبی، سرعت باد (km/s)، درجه حرارت محیط (°C) و مساحت سطح دریاچه (Km<sup>2</sup>) به عنوان ورودی و تبخیر (mm) به عنوان خروجی استفاده گردید. در شبکه‌ی عصبی اطلاعات به دو دسته آموزش و آزمایش تقسیم گردید. برای این عمل در مدلسازی موجود ۸۰٪ ورودی‌ها را برای آموزش ۲۰٪ باقیمانده جهت آزمون مدل بکار گرفته و خطای هر یک محاسبه شد (جدول ۱).

در اینجا نیز ساختارهای مناسب برای مدلسازی شبکه‌ی عصبی تبخیر برای سد میناب با رنگ تیره مشخص گردید و بهترین ساختار ANN(5,5,1) با ضریب همبستگی ۰/۸۹۴۱ و مقدار خطای آموزش ۰/۰۰۱۱ و آزمایش ۰/۰۰۸۲ می‌باشد.

### – ارزیابی نمودار همپوشانی داده‌ها برای ساختار ANN[5,5,1]


به این منظور داده‌های واقعی و مدلسازی شده به ترتیب با رنگ‌های قرمز (دایره) و آبی (مربع) رسم گردیده که نزدیکی و همپوشانی این نمودارها نشان از دقت بالای مدلسازی دارد. در سری زیر نمودارهای مربوط به داده‌های آموزش و آزمایش رسم گردیده است.

### – بررسی داده‌های آموزش

برای مدلسازی شبکه‌ی عصبی ۸۰٪ داده‌ها جهت آموزش به صورت تصادفی توسط نرم‌افزار MATLAB انتخاب گردید. یکی از نمودارهای بسیار مهمی که در مدلسازی شبکه‌ی عصبی بکار گرفته می‌شود، نمودار مقادیر واقعی و مقادیر به دست آمده تبخیر با استفاده از شبکه‌ی عصبی مصنوعی برای داده‌های آموزش می‌باشد (شکل ۸).


جدول (۱) خطا و ضریب همبستگی به دست آمده توسط شبکه‌ی عصبی مصنوعی

ردیف	خطا MSE (آموزش)	خطای MSE (آزمایش)	ضریب همبستگی	ساختار شبکه	ردیف	خطای MSE (آموزش)	خطای MSE (آزمایش)	ضریب همبستگی	ساختار شبکه
۱	۰/۰۰۱۷	۰/۰۰۱۲	۰/۸۴۶۸	ANN (4,1,1)	۲۵	۰/۰۰۱۷	۰/۰۰۱۸	۰/۸۴۶۸	ANN (2,1,1)
۲	۰/۰۰۱۷	۰/۰۰۰۹۹	۰/۸۵۱	ANN (4,2,1)	۲۶	۰/۰۰۱۲	۰/۰۰۱۸	۰/۸۵۱	ANN (2,2,1)
۳	۰/۰۰۱۶	۰/۰۰۱۱	۰/۸۴۹۹	ANN (4,3,1)	۲۷	۰/۰۰۱۲	۰/۰۰۱۷	۰/۸۴۹۹	ANN (2,3,1)
۴	۰/۰۰۱۶	۰/۰۰۰۹۹	۰/۸۵۹۶	ANN (4,4,1)	۲۸	۰/۰۰۱۲	۰/۰۰۱۷	۰/۸۵۹۶	ANN (2,4,1)
۵	۰/۰۰۹۷	۰/۰۰۳۴	۰/۸۵۲۹	ANN (4,5,1)	۲۹	۰/۰۰۱۲	ANN(2,5, 1)	۰/۸۵۲۹	ANN(2,5, 1)
۶	۰/۰۰۹۳	۰/۰۰۳۱	۰/۸۵۹	ANN (4,6,1)	۳۰	۰/۰۰۱۱	ANN(2,6, 1)	۰/۸۵۹	ANN(2,6, 1)
۷	۰/۰۰۹۸	۰/۰۰۳۲	۰/۸۷۱۴	ANN (4,7,1)	۳۱	۰/۰۰۱	ANN(2,7, 1)	۰/۸۷۱۴	ANN(2,7, 1)
۸	۰/۰۰۱۵	۰/۰۰۱۱	۰/۸۷۷۱	ANN (4,8,1)	۳۲	۰/۰۰۱	ANN (2,8,1)	۰/۸۷۷۱	ANN (2,8,1)
۹	۰/۰۰۱۵	۰/۰۰۱	۰/۸۴۷۸۹	ANN (4,9,1)	۳۳	۰/۰۰۱۲	ANN (2,9,1)	۰/۸۴۷۸۹	ANN (2,9,1)
۱۰	۰/۰۰۱۴	۰/۰۰۰۹۲	۰/۸۵۵۸	ANN (4,10,1)	۳۴	۰/۰۰۱۱	ANN (2,10,1)	۰/۸۵۵۸	ANN (2,10,1)
۱۱	۰/۰۰۱۵	۰/۰۰۰۸۸	۰/۸۵۷۹	ANN (4,11,1)	۳۵	۰/۰۰۱۱	ANN (2,11,1)	۰/۸۵۷۹	ANN (2,11,1)
۱۲	۰/۰۰۱۴	۰/۰۰۰۹۳	۰/۸۶۵۷	ANN (4,12,1)	۳۶	۰/۰۰۱۲	ANN (2,12,1)	۰/۸۶۵۷	ANN (2,12,1)
۱۳	۰/۰۰۱۸	۰/۰۰۱۱	۰/۸۴۲۲	ANN (5,1,1)	۳۷	۰/۰۰۱۳	ANN (3,1,1)	۰/۸۴۲۲	ANN (3,1,1)
۱۴	۰/۰۰۱۶	۰/۰۰۱۱	۰/۸۴۲۷	ANN (5,2,1)	۳۸	۰/۰۰۱۳	ANN (3,2,1)	۰/۸۴۲۷	ANN (3,2,1)
۱۵	۰/۰۰۱۵	۰/۰۰۰۱	۰/۶۳۵۸	ANN (5,3,1)	۳۹	۰/۰۰۳۸	ANN (3,3,1)	۰/۶۳۵۸	ANN (3,3,1)
۱۶	۰/۰۰۹۵	۰/۰۰۳۳	۰/۶۹۹۹	ANN (5,4,1)	۴۰	۰/۰۰۳۳	ANN (3,4,1)	۰/۶۹۹۹	ANN (3,4,1)
۱۷	۰/۰۰۱۱	۰/۰۰۰۸۲	۰/۸۴۲۳	ANN (5,5,1)	۴۱	۰/۰۰۱۲	ANN (3,5,1)	۰/۸۴۲۳	ANN (3,5,1)
۱۸	۰/۰۰۱۵	۰/۰۰۰۸۶	۰/۷۱۰۴	ANN (5,6,1)	۴۲	۰/۰۰۳۵	ANN (3,6,1)	۰/۷۱۰۴	ANN (3,6,1)
۱۹	۰/۰۰۸۹	۰/۰۰۳۴	۰/۸۸۴۹	ANN (5,7,1)	۴۳	۰/۰۰۱	ANN (3,7,1)	۰/۸۸۴۹	ANN (3,7,1)
۲۰	۰/۰۰۸۴	۰/۰۰۳۲	۰/۸۶۳۳	ANN (5,8,1)	۴۴	۰/۰۰۱۱	ANN (3,8,1)	۰/۸۶۳۳	ANN (3,8,1)
۲۱	۰/۰۰۱۴	۰/۰۰۰۹	۰/۸۷۵۸	ANN (5,9,1)	۴۵	۰/۰۰۰۹۹	ANN (3,9,1)	۰/۸۷۵۸	ANN (3,9,1)
۲۲	۰/۰۰۱۴	۰/۰۰۱۱	۰/۸۹۶۸	ANN (5,10,1)	۴۶	۰/۰۰۰۸۴	ANN (3,10,1)	۰/۸۹۶۸	ANN (3,10,1)
۲۳	۰/۰۰۷۸	۰/۰۰۳۳	۰/۸۷۶۶	ANN (5,11,1)	۴۷	۰/۰۰۰۱	ANN (3,11,1)	۰/۸۷۶۶	ANN (3,11,1)
۲۴	۰/۰۰۱۴	۰/۰۰۰۹۳	۰/۸۷۴۷	ANN (5,12,1)	۴۸	۰/۰۰۰۱	ANN (3,12,1)	۰/۸۷۴۷	ANN (3,12,1)



شکل (۸) نمودار داده‌های دیده‌بانی و مدلسازی در مرحله‌ی آموزش، ANN[5,5,1]

در شکل (۸) به علت زیاد بودن اطلاعات، همپوشانی داده‌ها به‌خوبی مشخص نیست به همین علت به صورت تصادفی روزهای ۳۳۰۰ تا ۳۴۰۰ در نرم‌افزار بزرگ‌نمایی گردید تا نتایج به دست آمده بهتر مشخص گردد (شکل ۹).




شکل (۹) نمودار داده‌های دیده‌بانی مدلسازی در مرحله آموزش برای روزهای ۱۶۰۰ تا ۱۸۰۰، ANN[5,5,1]


همانطور که در شکل (۹) مشاهده می‌شود داده‌های محاسبه شده توسط شبکه‌ی عصبی مصنوعی و داده‌های واقعی اندازه‌گیری شده تا حد قابل قبولی به یکدیگر نزدیک بوده و در برخی نقاط دارای همپوشانی می‌باشند که این امر نشان‌دهنده‌ی دقت مناسب مدل شبکه‌ی عصبی مصنوعی جهت مدلسازی تخبیر از سد میناب می‌باشد.

– بررسی داده‌های آزمایش

همانگونه که ذکر شد ۸۰٪ داده‌ها در بخش آموزش مورد استفاده قرار گرفت و نمودارهای مربوط به آن رسم شد. ۲۰٪ باقی‌مانده نیز جهت آزمایش مدل به دست آمده توسط شبکه‌ی عصبی مصنوعی بکار گرفته می‌شود که همانند داده‌های آموزش روزهای ۶۵۰ تا ۷۵۰ بزرگنمایی گردیده که نشان‌دهنده‌ی همپوشانی اطلاعات و تأیید مدلسازی به وسیله‌ی داده‌های آموزش می‌باشد (اشکال ۱۰ و ۱۱).




شکل (۱۰) نمودار داده‌های دیده‌بانی و مدلسازی در مرحله آزمایش، ANN[5,5,1]



شکل (۱۱) نمودار داده‌های دیده‌بانی مدلسازی در مرحله آزمایش برای روزهای ۱۶۰۰ تا ۱۸۰۰، ANN[5,5,1]


– نمودار نهایی همپوشانی داده‌ها

روش دیگری که جهت بررسی دقت مدل شبکه‌ی عصبی مصنوعی از آن استفاده می‌گردد، ترسیم داده‌های واقعی و محاسبه شده و نزدیکی این داده‌ها به خطی با  $X$  و  $Y$  برابر می‌باشد. در نمودار داده‌های واقعی و به دست آمده بر روی محور افقی و عمودی قرار دارد که هر چه این داده‌ها روی هم بیافتند، نتیجه بهتر خواهد بود. (شکل‌های ۱۲ و ۱۳).



شکل (۱۲) داده‌های واقعی و مدلسازی برای داده‌های آموزش

با توجه به شکل‌های (۱۲) و (۱۳)، مقادیر محاسباتی و اندازه‌گیری شده تبخیر برای سد میناب در داده‌های آموزش و آزمایش تا حدود زیادی دارای همپوشانی می‌باشند که این نکته دقت مناسب شبکه عصبی مصنوعی در برآورد تبخیر در این سد را نشان می‌دهد.



شکل (۱۳) داده‌های واقعی و مدلسازی شده برای داده‌های آزمایش

## نتیجه‌گیری

قبل از پرداختن به مسئله مدل‌سازی به روش شبکه‌ی عصبی مصنوعی، روندیابی تبخیر و داده‌های ورودی به شبکه‌ی عصبی یعنی سطح دریاچه، دما، سرعت باد و بارش با استفاده از روابط غیرخطی انجام گرفت. مسئله دیگر مورد پژوهش در این تحقیق برآورد میزان تبخیر از سطح دریاچه‌ی سد به روش شبکه‌ی عصبی مصنوعی می‌باشد. با توجه به جدول (۱) و ضرایب همبستگی و خطاهای ارائه شده در آن، می‌توان نتیجه گرفت که مدل‌سازی شبکه‌ی عصبی مصنوعی در صورت استفاده از دو لایه‌ی مخفی، که لایه‌ی اول و دوم دارای ۵ نورون می‌باشد با تعداد تکرار ۱۰۰۰، دارای بیشترین ضریب همبستگی با مقدار  $0/8941$  در بین آزمون‌های دیگر است و مقادیر خطا برای داده‌های آموزش و آزمایش به ترتیب برابر با مقادیر  $0/0011$  و  $0/0082$  می‌باشد. پس از آن ساختارهای ANN (۳،۷،۱)، ANN (۴،۱۰،۱)، ANN (۴،۱۱،۱)، ANN (۵،۳،۱) نیز دارای مقادیری قابل قبولی از ضریب همبستگی و خطا در تعیین مقدار تبخیر از دریاچه سد میناب می‌باشند. جهت بهتر مشخص شدن موضوع نمودارهای همپوشانی داده‌های آموزش و آزمایش با داده‌های اندازه‌گیری رسم گردید که نتایج این نمودارها نیز حکایت از دقت بالای مدل در برآورد تبخیر دارد و مقادیر محاسبه شده دارای همپوشانی قابل قبولی با داده‌های واقعی است. پس می‌توان نتیجه گرفت این مدل توانایی پیش‌بینی میزان تبخیر از سطح دریاچه‌ی میناب را با دقت بالا دارا می‌باشد و با بکارگیری آن، می‌توان در جهت اعمال برنامه‌های صحیح و مناسب در امر مدیریت و کاهش این پدیده‌ی طبیعی گام‌های مؤثری برداشت.



### منابع

- باباعلی حمیدرضا و رضا دهقانی (۱۳۹۶)، پیش‌بینی دبی سیلابی با استفاده از شبکه‌ی عصبی موجک، مجله‌ی هیدروژئومورفولوژی، دوره‌ی ۳، شماره‌ی ۱۱، صص ۱۶۸-۱۴۹.
- بابامیری، امید و یعقوب دین‌پژوه (۱۳۹۵)، مقایسه و ارزیابی بیست روش تخمین تبخیر-تعرق گیاه مرجع مبتنی بر سه دسته‌ی کلی دمای هوا، تابش خورشید و انتقال جرم در حوضه‌ی آبریز دریاچه‌ی ارومیه، نشریه‌ی علوم آب و خاک- علوم و فنون کشاورزی و منابع طبیعی، دانشگاه اصفهان، ۲۰ (۷۷)، صص ۱۴۵-۱۶۱.
- ستاری، محمدتقی؛ میرعباسی نجف‌آبادی، رسول و مسعود علیمحمدی (۱۳۹۵)، کاربرد مدل درختی M5 در پیش‌بینی خشکسالی (مطالعه‌ی موردی: مراغه، ایران)، مجله‌ی هیدروژئومورفولوژی، دوره‌ی ۲، شماره‌ی ۷، صص ۱۵۹-۱۴۱.
- ندیری، عطاالله و سعید یوسف‌زاده (۱۳۹۶)، مقایسه‌ی کارایی مدل‌های شبکه‌ی عصبی مصنوعی، منطق فازی و سیستم استنتاج نرو-فازی تطبیقی در تخمین هدایت هیدرولیکی آبخوان دشت مراغه-بناب، مجله‌ی هیدروژئومورفولوژی، دوره‌ی ۳، شماره‌ی ۱۰، صص ۲۱-۴۰.
- نورانی، وحید؛ آزاد، نرگس؛ قاسم‌زاده، مهسا و الناز شرقی (۱۳۹۵)، بررسی تأثیر پارامترهای هیدروکلیماتولوژیکی آبی‌چای بر تغییرات تراز آب دریاچه‌ی ارومیه با استفاده از مدل ترکیبی موجک-من‌کندال، مجله‌ی هیدروژئومورفولوژی، دوره‌ی ۲، شماره‌ی ۷، صص ۱۵۹-۱۴۱.
- Deswal, Surinder, and Mahesh Pal. (2008), **Artificial neural network based modeling of evaporation losses in reservoirs**, International Journal of Mathematical, Physical and Engineering Sciences, No. 4, PP.177-181.
- Ma, Lili; Yun Wu, Jianwei Ji and Chaoxing He. (2011), **The prediction model for soil water evaporation based on BP neural network**, Conference on Intelligent Computation Technology and Automation (ICICTA), International, Vol. 2, PP. 276-280.

- Felix Klein.(1979), **Development of mathematics in the 19th century**, Mathsci Press Brookline, Translated by M. Ackerman from Vorlesungen uber die Entwicklung der Matematik im 19 Jahrhundert, Springer, Berlin.
- Rajaei, T., Mirbagheri, S. A., Nourani, V., and Alikhani, A. (2010), **Prediction of daily suspended sediment load using wavelet and neurofuzzy combined model**, International Journal of Environmental Science & Technology, 7, No.1, PP. 93-110.
- Reddy, T. Agami. (2007), **Application of a generic evaluation methodology to assess four different chiller FDD methods** (RP-1275), HVAC&R Research Vol.13, No. 5, PP. 711-729.
- Tabari, H., Marofi, S., and Sabziparvar, A.A. (2010), **Estimation of daily pan evaporation using artificial neural network and multivariate non-linear regression**, Irrigation Science, Vol.28, No.5, PP. 399-406.
- Tabesh, M., and Dini, M. (2010), **Forecasting daily urban water demand using artificial neural networks, a case study of Tehran urban water**, J. of Water and Wastewater, Vol. 21, No.1, PP. 84-95. (In Persian)
- Thomas, George B., Jr. Finney, Ross L.(1996), **Calculus and Analytic Geometry (9th ed.)**, Addison Wesley, ISBN: 0-201-53174-7.
- Traore, Seydou, Yu-Min Wang, and Tienfuan Kerh.(2010), **Artificial neural network for modeling reference evapotranspiration complex process in Sudano-Sahelian zone**, Agricultural Water Management , Vol.97, No. 5, PP. 707-714.
- Zoqi, M.J., and Saeedi, M. (2011), **Modeling leachate generation using artificial neural networks**, J. of Water and Wastewater, Vol. 22, No.1, PP. 76-84.