

## مقایسه روش‌های سری زمانی و شبکه عصبی مصنوعی در پیش‌بینی تبخیر-تعرق مرجع (مطالعه موردی: ارومیه)

نسرین آزاد طلاطپه<sup>۱</sup>، جواد بهمنش<sup>۲\*</sup>، مجید منتصری<sup>۳</sup> و وحید رضوردی‌نژاد<sup>۴</sup>

۱- دانشجوی کارشناسی ارشد آبیاری و زهکشی، دانشکده کشاورزی، دانشگاه ارومیه

۲- نویسنده مسئول، دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه

۳- دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه

۴- استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه

تاریخ پذیرش: ۹۳/۴/۸

تاریخ دریافت: ۹۲/۴/۲۵

### چکیده

تبخیر-تعرق یکی از مؤلفه‌های مهم در مصرف منابع آب در بخش کشاورزی می‌باشد. لذا ارائه روشی که پیش‌بینی مناسب و دقیقی از میزان تبخیر-تعرق مرجع را بدهد، می‌تواند در اخذ تصمیم بهینه برای برنامه‌ریزی منابع آب کمک کند. در این تحقیق، روش‌های سری زمانی و شبکه‌های عصبی مصنوعی در پیش‌بینی تبخیر-تعرق مرجع ماهانه در ایستگاه سینوپتیک ارومیه مورد مقایسه قرار گرفتند. بدین منظور در گام نخست بهترین مدل سری زمانی از بین مدل‌های AR و ARMA و بهترین مدل شبکه عصبی از بین شبکه‌های تابع پایه شعاعی (RBF) و پرسپترون چندلایه (MLP) انتخاب گردید. در گام دوم دو مدل انتخاب شده با یکدیگر مقایسه شدند. در مدل‌های شبکه عصبی ذکر شده تاخیرهای ماهانه مختلف از تبخیر-تعرق مرجع به عنوان ورودی شبکه انتخاب گردید. در این فرآیند مقادیر تبخیر-تعرق مرجع ماهانه از سال ۱۳۵۰ تا ۱۳۸۹ با استفاده از روش پنمن مونتیت فائو محاسبه شد. داده‌های مذکور از سال ۱۳۵۰ تا ۱۳۸۴ برای انتخاب بهترین مدل سری زمانی و بهترین ساختار شبکه‌ها استفاده و از داده‌های ۱۳۸۵ تا ۱۳۸۹ به منظور مقایسه روش‌ها استفاده گردید. نتایج نشان داد که مدل AR(11) در بین سایر مدل‌های سری زمانی عملکرد بهتری داشته و مدل RBF دارای خطای کمتری نسبت به مدل MLP بود. مقایسه بهترین مدل سری زمانی (مدل AR(11)) با بهترین مدل شبکه عصبی (مدل RBF) نشان داد که مدل RBF توانست مقادیر تبخیر-تعرق مرجع را در دوره ۱۳۸۵ تا ۱۳۸۹ با خطای کمتری پیش‌بینی کند. مقدار جذر میانگین مربعات خطا در دو مدل AR(11) و RBF به ترتیب ۱/۸۵ و ۰/۹۹۹ میلی-متر در ماه به دست آمد.

کلیدواژه‌ها: تبخیر-تعرق مرجع، شبکه‌های تابع پایه شعاعی، شبکه‌های پرسپترون چندلایه، مدل‌های سری زمانی.

### Comparison of Time Series Methods and Artificial Neural Networks In Reference Evapotranspiration Prediction (Case Study: Urmia)

N. Azad Talatapeh<sup>1</sup>, J. Behmanesh<sup>2\*</sup>, M. Montaseri<sup>3</sup> and V. R.verdinejhad<sup>4</sup>

1- M.Sc. student of Irrigation and Drainage, Agriculture Faculty, Urmia University

2\* - Associate professor of Water Engineering Department, Agriculture Faculty, Urmia University

3- Associate professor of Water Engineering Department, Agriculture Faculty, Urmia University

4- Assistant professor of Water Engineering Department, Agriculture Faculty, Urmia University

Received: 16 July 2013

Accepted: 29 June 2014

### Abstract

Evapotranspiration is one of the important factors in water resources consumption in the agriculture part. Therefore, presenting a method which gives suitable and accurate prediction of reference evapotranspiration can help to take optimum decision for water resource programming. In this research, time series and artificial neural networks methods were compared each other in order to predict the monthly reference evapotranspiration in Urmia synoptic station. To achieve this goal, at the first step, the best time series model between AR and ARMA models and the best

artificial neural networks model between radial basis function (RBF) and multilayer perceptron (MLP) neural networks were selected. In the second step, the two models chosen were compared each other. In the mentioned artificial neural networks, the deferent monthly lags of reference evapotranspiration were used as network input. In this process, the monthly reference evapotranspirations were computed from 1971 to 2010 using FAO Penman-Monteith method. The mentioned dates from 1971 to 2005 were used to select the best time series model and the best structure of networks and the dates from 2006 to 2010 were utilized to compare the methods used. The results showed that the AR(11) model has the best performance among other time series models and the RBF model has the lower error than the MLP model. The comparison of the best time series model (AR(11) model) with the best artificial neural networks model (RBF model) showed that the RBF model could predict the reference evapotranspiration by the lowest error from 1971 to 2010 period. The root mean square error in AR(11) and RBF models was obtained 1.85 and 0.999 mm/month respectively.

**Keywords:** Reference evapotranspiration, Radial basis function networks, Multilayer perceptron neural networks, Time series models.

ایستگاه باجگاه با استفاده از مدل‌های اتورگرسیون-میانگین متحرک تلفیق شده فصلی (SARIMA) مورد مطالعه قرار دادند. نتایج نشان داد که توان دوم ضریب همبستگی بین مقادیر مشاهده شده برای مقیاس زمانی هفتگی و ماهانه به ترتیب برابر ۰/۹۹ و ۰/۹۲ است. فولادمند (۱۳۸۹) مقادیر تبخیر-تعرق گیاه مرجع را در مناطق مختلف استان فارس با استفاده از سری‌های زمانی پیش‌بینی کرد. نتایج او نشان داد که مدل سری زمانی مناسب برای پیش‌بینی تبخیر-تعرق گیاه مرجع در ایستگاه‌های مختلف یکسان نمی‌باشد و در کلیه ایستگاه‌های ذکر شده بین مقادیر محاسبه شده و پیش‌بینی شده تفاوت معنی‌دار وجود ندارد. قهرمان و قره‌خانی (۱۳۹۰) توانمندی مدل‌های ARIMA در برآورد مقادیر روزانه تبخیر از تست را در ایستگاه شیراز مورد مطالعه قرار دادند. نتایج آنها نشان داد که مدل سری زمانی  $ARIMA(1,1,1)$  عملکرد بسیار بهتری نسبت به سایر مدل‌های ARIMA دارد.

امروزه علاوه بر مدل‌های متداول کلاسیک، روش‌های غیر کلاسیک که از ویژگی‌هایی همچون هوشمندی برخوردارند و به شبکه‌های عصبی مصنوعی<sup>۵</sup> (ANN) موسومند برای پیش‌بینی ابداع شده‌اند. شبکه‌های عصبی مصنوعی ساختاری شبیه به مغز انسان دارد و با پردازش روی داده‌های تجربی، قوانین پیچیده و غیرخطی نهفته در ورای داده‌ها را کشف نموده و از آن برای حل مثال‌های مشابه و یا پیش‌بینی مقادیر آتی استفاده می‌نماید. در طی سال‌های اخیر از شبکه‌های عصبی در زمینه پیش‌بینی در علوم مختلف استفاده زیادی شده است. در مطالعات انجام گرفته، داده‌های ورودی به یکی از سه حالت استاتیکی، دینامیکی و ترکیبی به شبکه معرفی می‌شوند. در مدل دینامیکی خروجی مدل در زمان  $t$  به مقادیر یک یا چند گام زمانی قبلی وابسته است. اما در مدل استاتیکی خروجی مدل در زمان  $t$  با توجه به پارامترهایی در زمان  $t$  که به آن‌ها وابسته می‌باشد، محاسبه می‌گردد. در مدل ترکیبی نیز از ترکیب مدل‌های دینامیکی

## مقدمه

تبخیر-تعرق از عمده‌ترین اجزای چرخه هیدرولوژیک است که تخمین درست آن در بسیاری از مطالعات نظیر بیلان هیدرولوژیک آب، طراحی و مدیریت سیستم‌های آبیاری، شبیه‌سازی تولید گیاهی و برنامه‌ریزی و مدیریت منابع آب از اهمیت زیادی برخوردار است. علاوه بر این مقدار تبخیر-تعرق یکی از داده‌های اساسی در طراحی شبکه‌های آبیاری و زهکشی می‌باشد. زیرا طراحی شبکه‌های انتقال اعم از کانال‌های آبرسانی یا زهکشی و نیز سایر قسمت‌های طرح‌های آبی وابسته به مقدار آب مورد نیاز از طریق پدیده تبخیر-تعرق است (قبائی سوق و همکاران، ۱۳۸۹). امروزه با توجه به مسئله بحران آب و نیاز به برنامه‌ریزی دقیق، اطلاع از وضعیت آتی تبخیر-تعرق مرجع و پیش‌بینی آن، می‌تواند به تصمیم‌گیری‌ها برای برنامه‌ریزی منابع آب و روش‌های مدیریتی مناسب برای آینده کمک کند. از جمله ابزار مناسب پیش‌بینی پدیده‌های هواشناسی و هیدرولوژیک استفاده از روش سری‌های زمانی می‌باشد. در روش‌های پیش‌بینی سری زمانی، پیش‌بینی کننده با استفاده از اطلاعات به‌دست آمده از گذشته و با فرض ادامه الگو در آینده الگویی قابل تعمیم را به‌دست می‌آورد.

مدل‌های مختلف آماری مانند مدل‌های خودهمبسته<sup>۱</sup> (AR)، میانگین متحرک<sup>۲</sup> (MA)، خودهمبسته با میانگین متحرک<sup>۳</sup> (ARMA)، آریما<sup>۴</sup> (ARIMA) از جمله مدل‌های سری زمانی هستند که هر یک شامل مجموعه‌ای از مدل‌ها با پارامترهای گوناگون می‌باشند و می‌توانند به عنوان انتخاب‌های ممکن برای مدل‌سازی و پیش‌بینی استفاده گردند (کارآموز و عراقی‌نژاد، ۱۳۸۴). تاکنون تحقیقات متعددی در ارتباط با پیش‌بینی تبخیر-تعرق مرجع با استفاده از مدل‌های سری زمانی انجام گرفته است. شبروانی و هنر (۱۳۹۰) مدل‌سازی و پیش‌بینی مقادیر تبخیر تعرق را برای آینده در

1- Auto Regressive

2- Moving Average

3- Auto Regressive Moving Average

4- Auto Regressive Integrated Moving Average

5- Artificial Neural Networks

گردید. وی در این مطالعه از داده‌های هواشناسی تبخیر سطحی روزانه، دما، تشعشع خورشیدی، رطوبت نسبی و سرعت باد استفاده کرده و ترکیبات مختلفی از پارامترها به عنوان ورودی اعمال شد. نتایج نشان داد که وقتی برای ساخت و آزمایش مدل پارامترهای ورودی بیشتری در نظر گرفته می‌شود در مقایسه با حالت تک پارامتری همخوانی بهتری مشاهده می‌گردد. این مطالعه نشان داد که مدل‌سازی بر پایه شبکه عصبی مصنوعی می‌تواند به عنوان یک رویکرد جایگزین و کارآمد برای تخمین تبخیر روزانه از مخازان اعمال گردد. اخماج<sup>۷</sup> (۲۰۱۲) عملکرد شبکه عصبی را در تخمین تبخیر-تعرق با استفاده از داده‌های هواشناسی دو ایستگاه در لیبی بررسی کرد. وی در این مطالعه روش تبخیر از تشت را به عنوان روش مرجع در محاسبه تبخیر-تعرق استفاده کرده و مدل شبکه عصبی را در مقابل روش‌های بلانی کریدل، روش تابشی و پنمن اصلاح شده مقایسه کرد. در این مطالعه داده‌های هواشناسی متوسط درجه حرارت، متوسط رطوبت نسبی و ساعات روشنایی به عنوان ورودی شبکه عصبی در نظر گرفته شد. نتایج نشان داد که مدل شبکه عصبی عملکرد بهتری نسبت به روش‌های تابشی و بلانی کریدل داشت و شبکه عصبی به دلیل داده‌های ورودی کمتر نسبت به روش پنمن اصلاح شده کارایی بیشتری دارد. خوشحال و مکرم (۲۰۱۲) برای پیش‌بینی تبخیر-تعرق مرجع در دشت اقلید ایران از شبکه عصبی MLP<sup>۸</sup> استفاده کردند. آن‌ها در این مطالعه از داده‌های هواشناسی معادله پنمن موتیث طی سال‌های ۲۰۰۰ تا ۲۰۱۰ به عنوان ورودی شبکه و مقادیر تبخیر-تعرق مرجع محاسبه شده توسط معادله پنمن موتیث را به عنوان خروجی شبکه استفاده کردند. نتایج نشان داد که مدلی که در آن از داده‌های دمای حداکثر و حداقل، تابش خورشیدی، رطوبت نسبی و سرعت باد به عنوان ورودی استفاده می‌شود بهترین عملکرد را دارد. در زمینه استفاده از مدل دینامیکی در پیش‌بینی تبخیر-تعرق مرجع می‌توان به کار آرچانا و شریواستاوا<sup>۹</sup> (۲۰۱۰) اشاره کرد که در آن نامبردگان با استفاده از شبکه عصبی مصنوعی، تبخیر-تعرق مرجع را در منطقه MRP command پیش‌بینی کردند. آن‌ها در این مطالعه از داده‌های ماهانه ژانویه ۱۹۸۶ تا دسامبر ۲۰۰۵ استفاده کرده و ترکیبات مختلف داده‌های ورودی تبخیر-تعرق مرجع را تا تأخیر چهار ماه به کار بردند. آن‌ها در نهایت به این نتیجه رسیدند که مدلی که در آن از داده‌های تبخیر-تعرق مرجع با تأخیر سه ماه استفاده گردید بهترین نتیجه را نشان می‌دهد. کفیل و ضیانتبار احمدی (۱۳۸۵) با به‌کارگیری روش‌های شبکه عصبی مصنوعی و سری زمانی، روش سری‌های زمانی و شبکه عصبی مصنوعی را به ترتیب برای بررسی دوره‌های کوتاه مدت و بلند مدت پیشنهاد کردند.

و استاتیکی استفاده می‌شود. برای نمونه اُکان<sup>۱</sup> (۲۰۱۱) در بررسی کارایی الگوریتم لونبرگ مارکوآرت<sup>۲</sup> شبکه عصبی در مدل‌سازی جریان ورودی ماهانه به سد دمیرکپرو در ترکیه از ورودی‌های مختلف دینامیکی و استاتیکی شامل بارندگی، درجه حرارت و جریان ورودی با تأخیرهای مختلف استفاده کرد. نتایج این بررسی ضمن تأکید بر کارایی الگوریتم لونبرگ مارکوآرت در مدل‌سازی جریان، نشان داد که کمترین خطای مدل زمانی به‌دست می‌آید که داده‌های درجه حرارت ماه  $t$ ، بارندگی ماه‌های  $t-1$  و  $t-2$  و جریان ماه  $t-1$  به عنوان ورودی در نظر گرفته می‌شود. همچنین فتحی و همکاران (۱۳۸۸) سری زمانی آورد ماهانه ورودی به سد وحدت سندج را با استفاده از شبکه عصبی مصنوعی مدل‌سازی کردند. آن‌ها در این تحقیق از شبکه‌های استاتیکی (با ورودی دما و بارندگی در زمان  $t$ )، دینامیکی (با ورودی دبی در زمان‌های  $t-1$  و  $t-2$ ) و شبکه ترکیبی (با ورودی بارندگی هر ماه و دبی دو ماه قبل) استفاده کردند. نتایج نشان داد که انطباق خوبی مابین مقادیر پیش‌بینی شده و داده‌های مشاهداتی با شبکه عصبی ترکیبی وجود دارد. همچنین نتایج نشان داد که مدل شبکه عصبی دینامیکی مقدار آورد ماهانه را با دقت بالاتری نسبت به مدل استاتیکی پیش‌بینی می‌کند. در کارهایی که تاکنون در زمینه پیش‌بینی تبخیر-تعرق مرجع با استفاده از شبکه عصبی انجام گرفته، اغلب از مدل‌های استاتیکی استفاده شده است. آدلوی و همکاران<sup>۳</sup> (۲۰۱۲) با استفاده از شبکه عصبی SOM<sup>۴</sup> مدلی برای تخمین تبخیر-تعرق مرجع در ایستگاه هواشناسی ریکارتن دانشگاه هریوت وات انگلستان ارائه دادند. آن‌ها در این مطالعه از ترکیبات داده‌های هواشناسی از جمله درجه حرارت، درصد رطوبت، سرعت باد، تابش خورشیدی و ساعات آفتابی طی سال‌های ۱۹۹۷ تا ۲۰۰۶ استفاده کردند. آن‌ها در نتایج خود نشان دادند که تخمین تبخیر-تعرق گیاه مرجع با استفاده از مدل SOM حتی در شرایطی که داده‌های ورودی کمی در اختیار است (مانند درجه حرارت حداکثر و حداقل) نتایج مشابهی با محاسبات فرمول پنمن موتیث فائو دارد. در یک مطالعه دیگر، ارزیابی عملکرد شبکه عصبی مصنوعی در تخمین تبخیر-تعرق مرجع در سه ایستگاه هواشناسی در یونان توسط دیامانتوپولو و همکاران<sup>۵</sup> (۲۰۱۱) انجام گرفت. آن‌ها در این مطالعه از داده‌های روزانه حداکثر، حداقل و متوسط درجه حرارت، متوسط درصد رطوبت نسبی، متوسط سرعت باد و تابش خالص خورشیدی به عنوان ورودی مدل استفاده کردند. نتایج مطالعات آن‌ها نشان داد که تنها با استفاده از حداکثر، حداقل و متوسط درجه حرارت می‌توان با استفاده از مدل شبکه عصبی مقادیر تبخیر-تعرق مرجع روزانه را تخمین زد. قابلیت مدل‌سازی شبکه عصبی مصنوعی در پیش‌بینی تبخیر از یک مخزن در هند توسط گوئل<sup>۶</sup> (۲۰۰۹) بررسی

- 1- Okkan
- 2- Levenberg-Marquardt
- 3- Adeloye *et al.*
- 4- Self-Organizing Map
- 5- Diamantopoulou *et al.*
- 6- Goel

- 7- Ekhmaj
- 8- Multilayer perceptron
- 9- Archana and Shrivastava



شکل ۱- موقعیت منطقه مورد مطالعه

مونتیت فائو که بنابر توصیه آلن و همکاران<sup>۱</sup> (۱۹۹۸) بهترین روش محاسبه تبخیر-تعرق مرجع می‌باشد و این روش، در هر دو شرایط خشک و مرطوب در مقابل سایر روش‌های تخمین تبخیر-تعرق گیاه مرجع مورد بررسی قرار گرفته و نتایج خوبی در مقایسه با داده‌های آزمایشگاهی با استفاده از آزمایش‌های دقیق لایسیمی داده است (آدلوئی و همکاران، ۲۰۱۲)، محاسبه شد.

### مدل‌های سری زمانی

الگوهای سری زمانی که برای پیش‌بینی تبخیر-تعرق مرجع در این مطالعه استفاده شده است مدل‌های خطی خودهمبستگی (AR) و میانگین متحرک خودهمبسته (ARMA) می‌باشد. اساس مدل  $AR(p)$  بر پایه زنجیره مارکوف در زنجیره زمانی بنا شده است. یک سری زمانی از زنجیره مارکوف تبعیت می‌کند اگر هر داده ثبت شده سری زمانی  $t$  با زمان بعد و یا زمان قبل از خود مرتبط باشد. این مدل از مدل‌های متداول استوکاستیک است و همان‌گونه که از نام آن مشخص می‌باشد، بر روی جملات خود رگرسیون‌گیری را اعمال می‌کند و البته این رگرسیون‌گیری روی مقادیر گذشته  $Z_t$  انجام می‌گیرد. با در نظر گرفتن یک سری زمانی نرمال و استاندارد  $Z_t$ ، شکل کلی مدل خودهمبستگی  $AR(p)$  و مدل میانگین متحرک خودهمبسته  $ARMA(p,q)$  به ترتیب به صورت روابط (۱) و (۲) می‌باشد:

$$Z_t = \sum_{i=1}^p (\varphi_i Z_{t-i}) + \varepsilon_t \quad (1)$$

$$Z_t = \sum_{i=1}^p (\varphi_i Z_{t-i}) - \sum_{j=1}^q (\theta_j \varepsilon_{t-j}) + \varepsilon_t \quad (2)$$

با توجه به مجهول بودن اطلاعات جوی در آینده برای برنامه‌ریزی منابع آب و مدیریت آبیاری در مزرعه نیاز است تا به گونه‌ای تبخیر-تعرق مرجع در دوره‌های زمانی متفاوت پیش‌بینی گردد. از این رو ارائه روشی که بتواند پیش‌بینی مناسب و دقیقی از میزان تبخیر-تعرق مرجع را بدهد، می‌تواند در تصمیم‌گیری‌ها و روش‌های مدیریتی مناسب برای آینده کمک کند. تاکنون در منطقه مورد بررسی، مقایسه کارایی مدل‌های سری زمانی و شبکه‌های عصبی مصنوعی در پیش‌بینی تبخیر-تعرق مرجع صورت نگرفته است. لذا در تحقیق حاضر سعی شده است کارایی مدل‌های سری زمانی در مقایسه با مدل‌های شبکه عصبی مصنوعی در مدل‌سازی و پیش‌بینی تبخیر-تعرق مرجع در ایستگاه سینوپتیک ارومیه مورد مقایسه قرار گیرد.

### روش کار

#### منطقه مورد مطالعه

در این مطالعه برای محاسبه تبخیر-تعرق مرجع، از داده‌های ایستگاه سینوپتیک ارومیه با دوره آماری ۴۰ ساله (۸۹-۱۳۵۰) استفاده شده است. این ایستگاه در عرض جغرافیایی ۳۷ درجه و ۳۲ دقیقه شمالی و طول جغرافیایی ۴۵ درجه و ۵ دقیقه شرقی و در ارتفاع ۱۳۳۰ متری از سطح دریا قرار دارد. ارومیه از نظر تقسیم‌بندی اقلیمی آمبرژه دارای اقلیم نیمه‌خشک سرد و براساس طبقه‌بندی دومارتن دارای اقلیم نیمه‌خشک میانه می‌باشد. سردترین ماه‌های سال دی و بهمن و گرم‌ترین ماه‌های سال تیر و مرداد است. شکل (۱) موقعیت منطقه مورد مطالعه را نشان می‌دهد. پس از جمع‌آوری داده‌های مورد نیاز محاسبه تبخیر-تعرق مرجع از جمله درجه حرارت، درصد رطوبت، ساعات آفتابی و سرعت باد و پس از تکمیل و تصحیح داده‌ها، تبخیر-تعرق مرجع ماهانه با استفاده از روش پنمن

### شبکه‌های عصبی مصنوعی

اساس کار شبکه عصبی بر مبنای شبیه‌سازی عملکرد مغز انسان بوده و در مقیاس خیلی کوچک می‌تواند مانند شبکه‌های زیستی قدرت یادگیری داشته و این یادگیری را تعمیم دهد. مهمترین بخش یک شبکه زیستی، نرون می‌باشد. نرون‌ها سلول‌های تشکیل‌دهنده دستگاه عصبی انسان هستند. هر شبکه عصبی از تعداد زیادی گره و پیوندهای جهت‌دار که گره‌ها را به هم ارتباط می‌دهند تشکیل شده است. این گره‌ها در چند لایه به نام لایه ورودی، مخفی و خروجی آرایش داده شده‌اند. در پیش‌بینی سری‌های زمانی، ورودی‌های شبکه عصبی مصنوعی، مشاهدات با وقفه سری زمانی است و خروجی شبکه، مقادیر آتی آن‌ها می‌باشد. در واقع اگر مشاهدات گذشته به صورت سری باشد، آنگاه شبکه عصبی مصنوعی تابع زیر را تقریب و طرح‌ریزی می‌کند:

$$y_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-n}) \quad (۶)$$

که در آن  $y$ : مشاهده زمان  $t$  ام است.

تاکنون شبکه‌های عصبی مختلفی ارائه شده است. در این مطالعه دو شبکه از معروف‌ترین آن‌ها، شبکه‌های MLP (شبکه پرسپترون چندلایه) و RBF<sup>۵</sup> (شبکه با تابع پایه شعاعی) مورد استفاده قرار گرفته و با یکدیگر مقایسه شده‌اند.

### شبکه‌های پرسپترون چند لایه (MLP)

یک شبکه عصبی MLP معمولاً از چند لایه و نرون تشکیل می‌یابد. اولین و پایین‌ترین لایه، لایه ورودی است که در آن اطلاعات خارجی دریافت می‌گردد. آخرین یا بالاترین لایه، لایه خروجی است که در آن حل مسئله انجام می‌گیرد. لایه ورودی و خروجی توسط یک یا چند لایه واسطه که لایه میانی یا پنهان نامیده می‌شود، جدا می‌شوند. نرون‌های موجود در لایه‌های همجوار معمولاً به طور کامل توسط کمان‌های غیر حلقوی از لایه پایین به لایه بالا به هم مرتبط می‌شوند. در تحقیق حاضر برای مدل‌سازی با استفاده از شبکه‌های MLP از یک شبکه سه لایه پیشخور استفاده شده است. یک تابع محرک سیگموئید (تانژانت هیپربولیک) در لایه پنهان و یک تابع محرک خطی در لایه خروجی به کار رفته است. از میان روش‌های مختلف آموزش، الگوریتم لوبنبرگ مارکوارت، به دلیل همگرایی سریع‌تر در آموزش شبکه، در تحقیق حاضر انتخاب شده است.

### شبکه‌های با تابع پایه شعاعی (RBF)

شبکه‌های RBF نوعی شبکه عصبی پیشخور بوده و ساختار آن‌ها شبیه شبکه‌های MLP می‌باشد. شبکه‌های RBF نیازمند نرون‌های بیشتری نسبت به شبکه‌های استاندارد پیشخور با الگوریتم

که در این روابط  $p$  و  $q$ : رسته یا مرتبه مدل،  $\varphi_i$  و  $\theta_j$ : ضرایب مدل و  $\varepsilon_t$ : سری تصادفی نرمال و استاندارد می‌باشد.

با توجه به فرضیه‌های اساسی در مدل‌سازی سری‌های زمانی یعنی نرمال بودن و ایستایی، قبل از مدل‌سازی باید از نرمال و ایستا بودن سری داده‌ها اطمینان حاصل کرد. سازمان هواشناسی جهانی به منظور مطالعه روند و بررسی ایستا بودن داده‌ها، آزمون اسپیرمن را پیشنهاد کرده است (مک‌قی<sup>۱</sup>، ۱۹۸۵). در این مطالعه برای آزمون ایستایی داده‌ها از آزمون مذکور استفاده شده است. روش انجام این آزمون به این صورت است که پس از مرتب کردن نزولی داده‌ها، با استفاده از شماره ردیف مقادیر مرتب شده  $(r_{ii})$ ، ردیف سال وقوع  $(t_{ii})$  و تعداد داده  $(n_{ii})$  ضریب گرایش  $t_r$  با استفاده از رابطه (۳) و سپس پارامتر  $t_u$  از رابطه (۴) محاسبه می‌شود:

$$t_r = 1 - \frac{6 \sum_{i=1}^{n_u} (t_{ii} - r_{ii})^2}{n_u^3 - n_u} \quad (۳)$$

$$t_u = t_r \left[ \frac{n_u - 2}{1 - t_r^2} \right]^{1/2} \quad (۴)$$

در این آزمون در صورتی که مقدار قدر مطلق  $t_u$  از مقدار  $t$  استیوننت با درجه آزادی  $n-2$  کمتر باشد نشان می‌دهد که داده‌ها فاقد گرایش هستند. در این تحقیق برای بررسی نرمال بودن داده‌ها از رسم گرافیکی داده‌ها در نمودار توزیع نرمال استفاده شده است. به این صورت که پس از محاسبه مقدار برازشی توزیع نرمال برای داده‌های استاندارد شده، حد بالا و حد پایین خط برازشی در سطح اطمینان ۹۵ درصد محاسبه شده است. سپس خط برازشی به همراه حدود اطمینان رسم شده است. در صورتی که داده‌های مشاهده‌ای استاندارد شده در اطراف خط برازشی و در محدوده اطمینان قرار گیرند می‌توان نتیجه گرفت که داده‌ها دارای توزیع نرمال می‌باشند. در نهایت برای تعیین مرتبه مدل از آزمون آکائیکه<sup>۲</sup> (AICC<sup>۲</sup>) طبق رابطه (۵) استفاده شده است (هوئینگ و همکاران<sup>۴</sup>، ۲۰۰۶):

$$AICC = -2 \log L_z(\hat{\psi}) + 2n \frac{(p+q+1)}{n-p-q-2} \quad (۵)$$

در این رابطه  $p$  و  $q$ : رسته یا مرتبه مدل،  $n$ : تعداد داده و  $L_z(\hat{\psi})$ : پارامتر حداکثر لایکلیت نامیده می‌شود. این روش با استفاده از آزمون و خطا بوده و هر مدلی که AICC کمتری داشته باشد، برازش بهتری خواهد داشت. در این تحقیق برای محاسبه مقدار AICC و ضرایب مدل از نرم افزار ITSM2000 استفاده گردید.

- 1- McGhee
- 2- Akaike's method
- 3- Akaike Information Criteria Corrected
- 4- Hoeting et al.

ورودی‌های سناریوی منتخب به عنوان ورودی شبکه MLP، تعداد نرون‌های لایه مخفی به گونه‌ای از طریق آزمون و خطا در ۴۲۰ داده اولیه انتخاب شد که مقدار جذر میانگین مربعات خطا در دو مجموعه آموزش و صحت سنجی کمینه گردد. با استفاده از این تعداد نرون در لایه مخفی، مقادیر تبخیر-تعرق مرجع ماهانه در سال‌های ۱۳۸۵ تا ۱۳۸۹ پیش‌بینی شده و مقدار جذر میانگین مربعات خطا مربوط به مقادیر پیش‌بینی شده و محاسبه شده، برای مقایسه عملکرد شبکه‌های RBF و MLP محاسبه گردید. در نهایت عملکرد مدل‌های سری زمانی و شبکه عصبی مصنوعی در پیش‌بینی تبخیر-تعرق مرجع ماهانه با یکدیگر مقایسه شد.

### نتایج و بحث

نتایج آزمون ایستایی با استفاده از آزمون اسپیرمن در جدول (۱) ارائه شده است. همان‌گونه که این جدول نشان می‌دهد مقدار قدر مطلق آماره آزمون  $t_{ii}$  از مقدار  $t$  استیودنت در سطح اطمینان ۹۹ درصد کمتر بوده و داده‌ها فاقد روند هستند. همچنین برای آزمون نرمال بودن داده‌ها با استفاده از رسم گرافیکی داده‌ها در نمودار توزیع نرمال، خط برازشی توزیع نرمال به همراه حدود اطمینان (در سطح اطمینان ۹۵ درصد) و داده‌های مشاهده‌ای در شکل (۲) نشان داده شده است. با توجه به این که داده‌های مشاهده‌ای در محدوده اطمینان خط نرمال قرار گرفته اند، می‌توان نتیجه گرفت که داده‌ها دارای توزیع نرمال می‌باشند. پس از اطمینان از نرمال و ایستا بودن داده‌ها، مرتبه‌های مختلف مدل‌های AR و ARMA بر روی داده‌های ماهانه تبخیر-تعرق مرجع در سری داده‌های ارزیابی (داده‌های سال‌های ۱۳۵۰ تا ۱۳۸۴) برازش داده شده و مقادیر AICC محاسبه گردید. نتایج این محاسبات در جدول (۲) ارائه شده است. همان‌گونه که این جدول نشان می‌دهد مدل AR(11) با داشتن کمترین مقدار AICC معادل ۱۰۸۱/۶۳، بهترین مدل سری زمانی می‌باشد.

جدول (۳) نتایج شبکه RBF در پیش‌بینی تبخیر-تعرق مرجع ماهانه را در ۱۱ سناریو نشان می‌دهد. در این جدول مقادیر جذر میانگین مربعات خطا، میزان اختلاف بین مقادیر پیش‌بینی شده توسط مدل و مقادیر محاسبه شده از طریق روش پنمن موتیث فائو در سال‌های ۱۳۸۵ تا ۱۳۸۹ را نشان می‌دهد. در این سناریوها مقادیر گستره و تعداد توابع انتقال بر اساس حداقل بودن مقدار جذر میانگین مربعات خطا در سری داده‌های ارزیابی (۳۵ سال ابتدایی) در دو مجموعه آموزش و صحت‌سنجی کمینه گردد. همان‌طور که این جدول نشان می‌دهد سناریوی چهارم که در آن از داده‌های تبخیر-تعرق مرجع تا پنج ماه تأخیر به عنوان ورودی شبکه RBF نظر گرفته شد کمترین خطا را در میان سایر سناریوها دارا می‌باشد. مطالعات آرچانا و شریواستاوا (۲۰۱۰) در پیش‌بینی تبخیر-تعرق مرجع با استفاده از شبکه عصبی مصنوعی در منطقه ام‌آرپی کامند نشان داد مدلی که در آن از داده‌های تبخیر-تعرق مرجع با تأخیر سه ماه استفاده گردید بهترین نتیجه را نشان می‌دهد.

پس‌انتشار خطا می‌باشند ولی اغلب این شبکه‌ها را می‌توان در زمانی کوتاه‌تر نسبت به زمان مورد نیاز به شبکه‌های پیشخور آموزش داد. این نوع شبکه الگوی ورودی  $\pi$  بعدی را با استفاده از گره‌های واقع در لایه مجاور به یک الگوی خروجی  $z$  بعدی نگاشت می‌کند. لایه ورودی مقادیر ورودی را به هر یک از گره‌های لایه پنهان ارسال می‌کند. هر یک از گره‌های واقع در لایه پنهان (نرون‌ها) با یک تابع انتقال  $f$  مشخص می‌شوند که سیگنال‌های ورودی را انتقال می‌دهند. در مطالعه حاضر تأخیرهای مختلف داده‌های تبخیر-تعرق مرجع ماهانه، از ۲ تا ۱۲ تأخیر در ۱۱ سناریو به عنوان ورودی شبکه در نظر گرفته شد. مدت اطلاعات کل دوره مورد مطالعه شامل ۴۸۰ ماه بود که از این تعداد ۴۲۰ ماه (۳۵ سال اولیه) برای انتخاب بهترین مدل سری زمانی و بهترین ساختار شبکه‌ها و ۶۰ ماه (پنج سال انتهایی) برای مقایسه روش‌ها استفاده شد. در یک شبکه معمولاً داده‌ها به دو مجموعه آموزش و آزمون تقسیم می‌شوند. مجموعه آموزش برای آموزش و گسترش شبکه به کار گرفته می‌شود؛ ولی مجموعه آزمون برای ارزیابی توانایی تعمیم مدل بکار می‌رود. در این مطالعه در ۴۲۰ داده ارزیابی، ۸۰ درصد داده‌ها به عنوان نمونه آموزشی و ۲۰ درصد داده‌ها به عنوان داده‌های صحت‌سنجی استفاده شد.

### معیارهای ارزیابی

در این پژوهش برای تعیین بهترین ساختار مدل و مقایسه مدل‌های مختلف از معیارهای ارزیابی جذر میانگین مربعات خطا<sup>۱</sup> (RMSE) و ضریب تبیین ( $R^2$ ) (روابط ۷ و ۸) استفاده گردید:

$$RMSE = \sqrt{\frac{\sum (X_o - X_p)^2}{n}} \quad (7)$$

$$R^2 = \frac{\sum (X_o - \bar{X}_o)(X_p - \bar{X}_p)}{\sqrt{\sum (X_o - \bar{X}_o)^2 \sum (X_p - \bar{X}_p)^2}} \quad (8)$$

که در این روابط  $X_o$ : مقدار مشاهده‌ای،  $X_p$ : مقدار شبیه‌سازی شده و  $n$ : تعداد داده‌ها می‌باشد.


در این مطالعه با استفاده از برنامه‌نویسی در محیط متلب ۲۰۱۲ مقادیر گستره<sup>۲</sup> و تعداد توابع انتقال در شبکه RBF در هر سناریو با استفاده از برنامه بهینه‌یابی به گونه‌ای انتخاب شد که جذر میانگین مربعات خطا در سری داده‌های ارزیابی (۳۵ سال ابتدایی) در دو مجموعه آموزش و صحت‌سنجی کمینه گردد. با بکارگیری ترکیب به‌دست آمده از مقادیر گستره و تعداد توابع انتقال در هر سناریو، مقادیر تبخیر-تعرق مرجع ماهانه از سال ۱۳۸۵ تا ۱۳۸۹ تولید شده و مقدار جذر میانگین مربعات خطا مربوط به مقادیر پیش‌بینی شده از طریق مدل و مقادیر محاسبه شده از طریق معادله پنمن موتیث فائو برای انتخاب بهترین سناریو محاسبه گردید. سپس با بکارگیری

1- Root Mean Square Error

2- Spread Root Mean Square Error

**جدول ۱- نتایج آزمون اسپیرمن بر روی داده‌های تبخیر-تعرق مرجع**

آزمون اسپیرمن	مقدار آماره آزمون	مقدار t استیودنت در سطح اطمینان ۹۹ درصد	نتیجه آزمون
اسپیرمن	-۲/۴۷	۲/۷۴	سری زمانی ایستا می باشد



شکل ۲- خط توزیع نرمال، حدود اطمینان و داده‌های مشاهده‌ای

**جدول ۲- مقادیر AICC در مدل‌های مختلف برازش داده شده بر سری استاندارد ماهانه**

مدل	AICC	مدل	AICC	مدل	AICC
AR(1)	۱۰۹۹/۴۴	AR(9)	۱۰۸۸/۸۰	ARMA(2,2)	۱۰۸۶/۶۰
AR(2)	۱۰۹۳/۳۲	AR(10)	۱۰۸۲/۰۱	ARMA(3,1)	۱۰۸۹/۸۷
AR(3)	۱۰۸۷/۰۱	AR(11)	۱۰۸۱/۶۳	ARMA(3,2)	۱۰۸۸/۸۸
AR(4)	۱۰۸۸/۳۷	AR(12)	۱۰۸۳/۳۹	ARMA(3,3)	۱۰۹۶/۶۲
AR(5)	۱۰۸۷/۱۱	AR(13)	۱۰۸۵/۵۱	ARMA(1,3)	۱۰۹۱/۰۶
AR(6)	۱۰۸۵/۵۵	ARMA(1,1)	۱۰۸۸/۶۴	ARMA(2,3)	۱۰۸۸/۲۸
AR(7)	۱۰۸۷/۵۴	ARMA(1,2)	۱۰۹۰/۰۴		
AR(8)	۱۰۸۹/۰۴	ARMA(2,1)	۱۰۹۰/۸۳		

**جدول ۳- نتایج کلی شبکه RBF در پیش‌بینی تبخیر-تعرق مرجع ماهانه در سناریوهای مختلف**

RMSE	تعداد توابع انتقال	گستره	پارامترهای ورودی شبکه	شماره سناریو
۱/۰۹۴	۳۷	۲۳	Eto(t-1),Eto(t-2)	۱
۱/۰۵۶	۳۹	۲۳	Eto(t-1),Eto(t-2),Eto(t-3)	۲
۱/۰۱۰	۷۶	۳۸	Eto(t-1),Eto(t-2),Eto(t-3),Eto(t-4)	۳
۰/۹۹۹	۷۳	۵۲	Eto(t-1),Eto(t-2),Eto(t-3),Eto(t-4),Eto(t-5)	۴
۱/۰۷۴	۷۸	۷۰	Eto(t-1),Eto(t-2),Eto(t-3),Eto(t-4),Eto(t-5),Eto(t-6)	۵
۱/۰۷۱	۷۸	۶۵	Eto(t-1),Eto(t-2),Eto(t-3),Eto(t-4),Eto(t-5),Eto(t-6),Eto(t-7)	۶
۱/۴۴۷	۸۴	۷۸	Eto(t-1),Eto(t-2),Eto(t-3),Eto(t-4),Eto(t-5),Eto(t-6),Eto(t-7),Eto(t-8)	۷
۱/۵۴۵	۶۰	۴۹	Eto(t-1),Eto(t-2),Eto(t-3),Eto(t-4),Eto(t-5),Eto(t-6),Eto(t-7),Eto(t-8),Eto(t-9)	۸
۱/۴۶۸	۳۸	۵۰	Eto(t-1),Eto(t-2),Eto(t-3),Eto(t-4),Eto(t-5),Eto(t-6),Eto(t-7),Eto(t-8),Eto(t-9),Eto(t-10)	۹
۱/۴۹۰	۵۴	۴۲	Eto(t-1),Eto(t-2),Eto(t-3),Eto(t-4),Eto(t-5),Eto(t-6),Eto(t-7),Eto(t-8),Eto(t-9),Eto(t-10),Eto(t-11)	۱۰
۱/۵۶۳	۴۴	۴۹	Eto(t-1),Eto(t-2),Eto(t-3),Eto(t-4),Eto(t-5),Eto(t-6),Eto(t-7),Eto(t-8),Eto(t-9),Eto(t-10),Eto(t-11),Eto(t-12)	۱۱

## جدول ۴- مقایسه خطای بهترین مدل شبکه عصبی و بهترین مدل سری زمانی

نوع مدل	جذر میانگین مربعات خطا
شبکه RBF	۰/۹۹۹
مدل سری زمانی (AR(11))	۱/۸۵

(RBF) و بهترین مدل سری زمانی ارائه شده و در شکل (۳) مقادیر تبخیر-تغرق مرجع شبیه‌سازی شده توسط بهترین مدل‌های سری زمانی و شبکه عصبی با مقادیر محاسبه شده از طریق معادله پنمن مونتیت فائو ارائه شده است. همچنین شکل (۴) نیز میزان همبستگی مقادیر پیش‌بینی شده و مقادیر محاسبه شده از طریق معادله پنمن مونتیت فائو را در مدل‌های سری زمانی و شبکه عصبی مصنوعی نشان می‌دهد.

با توجه به شکل‌های (۳) و (۴) می‌توان نتیجه گرفت که شبکه‌های عصبی مصنوعی مقادیر تبخیر-تغرق مرجع را با دقت بالاتری نسبت به مدل‌های سری زمانی شبیه‌سازی می‌کنند. هرچند مدل‌های سری زمانی نیز دارای دقت قابل قبولی می‌باشند. نتایج مطالعات فولادمند (۱۳۸۹) در نقاط مختلف استان فارس و شیروانی و هنر (۱۳۹۰) در ایستگاه باجگاه نیز نشان داد که مدل‌های سری زمانی می‌توانند داده‌های تبخیر-تغرق مرجع را با دقت قابل قبولی مدل‌سازی و پیش‌بینی کنند. همچنین نتایج مطالعات قهرمان و قره‌خانی (۱۳۹۰) در رابطه با تبخیر از تشت در ایستگاه شیراز نیز تأییدکننده این موضوع می‌باشد. اما همان‌طور که جدول (۴) نشان می‌دهد، شبکه‌های عصبی عملکرد بهتری نسبت به مدل‌های سری زمانی در شبیه‌سازی و پیش‌بینی تبخیر-تغرق مرجع ماهانه در ایستگاه سینوپتیک ارومیه دارند.

همان‌گونه که در شکل (۳) مشاهده می‌شود، بیشترین اختلاف مدل‌های AR(11) و RBF در مقادیر حداکثر تبخیر-تغرق مرجع می‌باشد و مدل RBF توانسته است مقادیر حداکثر را با خطای کمتری نسبت به مدل AR(11) پیش‌بینی نماید. در مدل AR(11) مقادیر تبخیر-تغرق بیشتر از مقدار محاسبه شده از طریق معادله پنمن مونتیت فائو شبیه‌سازی شده است. با توجه به اینکه در طرح‌های آبی مقدار حداکثر تبخیر-تغرق مرجع سالانه مبنای محاسبات ظرفیت طراحی سیستم‌های انتقال و پخش آب می‌باشد، پیش‌بینی حداکثر تبخیر-تغرق سالانه از اهمیت ویژه‌ای برخوردار است و تخمین بیش از حد آن، هزینه اضافی را بر طرح‌های آبی اجبار کرده و پیش‌بینی کمتر از مقدار مورد نیاز موجب وارد شدن صدمه به گیاه بخصوص محصولات حساس به تنش آبی، در زمان اوج نیاز آبی خواهد شد.

در شبکه MLP نیز، تعداد نرون‌های لایه مخفی بر اساس حداقل بودن مقدار جذر میانگین مربعات خطا در ۴۲۰ داده اولیه در دو مجموعه آموزش و صحت‌سنجی از طریق آزمون و خطا به دست آمد. طبق نتایج به دست آمده تعداد ۱۶ نرون در لایه مخفی در سناریوی چهار کمترین مقدار جذر میانگین مربعات خطا را در سری داده‌های ارزیابی (از سال ۱۳۸۵ تا ۱۳۸۹) داشت. با استفاده از این تعداد نرون در لایه مخفی، ۶۰ ماه تبخیر-تغرق مرجع با استفاده از این شبکه تولید شده و مقدار جذر میانگین مربعات خطا مربوط به مقادیر پیش‌بینی شده از طریق مدل و مقادیر محاسبه شده با روش پنمن مونتیت فائو، ۱/۱۸ میلی‌متر در ماه به دست آمد. از طرفی همان‌گونه که جدول (۳) نشان داد، مقدار جذر میانگین مربعات خطا در داده‌های پنج سال انتهایی دوره مورد مطالعه، در شبکه RBF، ۰/۹۹۹ میلی‌متر در ماه می‌باشد. این نتایج نشان می‌دهد که شبکه RBF نسبت به شبکه MLP عملکرد بهتری داشته و مقادیر تبخیر-تغرق مرجع را با خطای کمتری شبیه‌سازی و پیش‌بینی می‌کند. این نتایج موافق نتایج سینگ و دتو<sup>۱</sup> (۲۰۰۷) در بررسی کارایی شبکه‌های عصبی مختلف در پیش‌بینی جریان روزانه در رودخانه نارمادا در هند می‌باشد که نشان دادند مدل RBF عملکرد بهتری نسبت به سایر مدل‌های GRNN<sup>۲</sup>، FFBP<sup>۳</sup> و ANFIS<sup>۴</sup> در پیش‌بینی رواناب در تمام فصل‌ها دارد. همچنین نتایج مطالعه آن‌ها نشان داد که دبی اوج توسط مدل RBF نسبت به سایر مدل‌ها با دقت بیشتری مدل‌سازی شد. اما بر خلاف این نتایج، صیادی و همکاران (۱۳۸۸) در مقایسه عملکرد شبکه‌های عصبی RBF و MLP در برآورد تبخیر-تغرق گیاه مرجع در ایستگاه تبریز با استفاده از ورودی‌های استاتیکی داده‌های هواشناسی نشان دادند که شبکه‌های MLP نسبت به RBF در تخمین تبخیر-تغرق گیاه مرجع از دقت نسبتاً بیشتری برخوردارند و تنها مزیت شبکه‌های RBF زمان کمتر مورد نیاز برای آموزش می‌باشد.

به منظور مقایسه عملکرد مدل‌های سری زمانی با شبکه‌های عصبی مصنوعی، با استفاده از بهترین مدل سری زمانی (مدل AR(11)) مقادیر تبخیر-تغرق مرجع از سال ۱۳۸۵ تا ۱۳۸۹ به صورت ماهانه تولید و با نتایج مدل RBF مقایسه گردید. در جدول (۴) مقدار خطای بهترین مدل شبکه عصبی مصنوعی (شبکه


1- Singh and Deo

2- Feed Forward Back Propagation

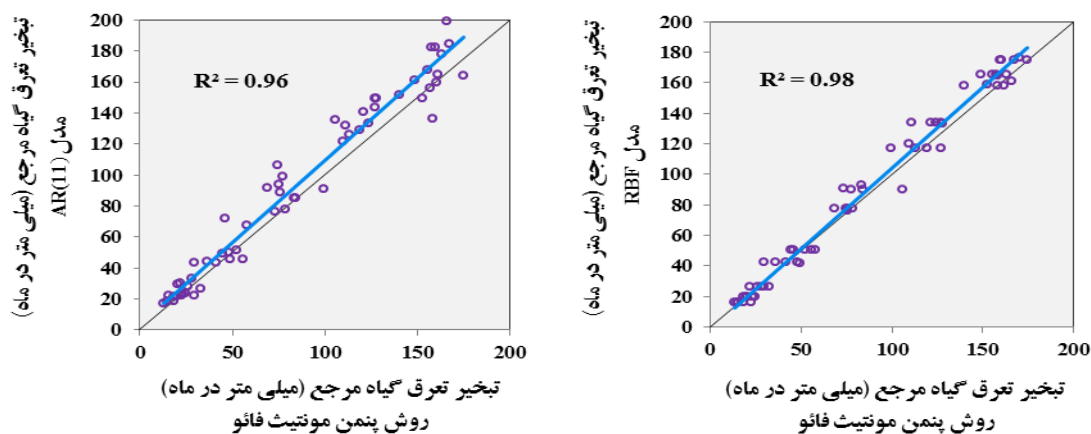
3- Generalized Regression Neural Network

4- Adaptive Neuro-Fuzzy Inference Systems





شکل ۳- مقایسه مقادیر تبخیر-تعرق مرجع شبیه‌سازی شده توسط بهترین مدل‌های سری زمانی (AR(11) و شبکه عصبی (RBF) با مقادیر محاسبه شده از طریق معادله پنمن مونتیث فائو (PM)



شکل ۴- میزان همبستگی مقادیر پیش‌بینی شده و مقادیر محاسبه شده از طریق معادله پنمن مونتیث فائو در مدل AR(11) و مدل RBF

دارد. کاستلانو مندوز و همکاران<sup>۱</sup> (۲۰۰۴) بر این باورند که شبکه‌های عصبی مصنوعی توانایی بیشتری در پیش‌بینی‌های کوتاه‌مدت دارند چرا که نتایج مطالعه آن‌ها نشان داد که مدل سری زمانی در پیش‌بینی‌های ماهانه عملکرد بهتری دارند. بنابراین انجام مطالعات بعدی در زمینه مقایسه کارایی شبکه‌های عصبی مصنوعی و سری زمانی در پیش‌بینی تبخیر-تعرق مرجع در مقیاس‌های زمانی مختلف پیشنهاد می‌گردد.

### سپاسگزاری

بدینوسیله از اداره هواشناسی ارومیه که اطلاعات لازم را در اختیار این تحقیق قرار دادند قدردانی می‌گردد.

### نتیجه‌گیری و پیشنهادها

نتایج این تحقیق نشان داد که مدل سری زمانی AR(11) نتایج بهتری در مقایسه با دیگر مدل‌های خطی داشت، همچنین نتایج پیش‌بینی تبخیر-تعرق مرجع با استفاده از مدل‌های شبکه عصبی نشان داد که مدل RBF دارای خطای کمتری نسبت به مدل MLP بود. در شبکه‌های مذکور از داده‌های تبخیر-تعرق مرجع با پنج ماه تاخیر به عنوان ورودی شبکه استفاده گردید. مقایسه بهترین مدل سری زمانی خطی (مدل AR(11) با بهترین مدل شبکه عصبی (مدل RBF) نیز نشان داد که مدل RBF مقادیر تبخیر-تعرق مرجع را در دوره ۱۳۸۵ تا ۱۳۸۹ با خطای کمتری پیش‌بینی کرد.

برخی از مطالعات نشان می‌دهند که عملکرد مدل‌های سری زمانی و شبکه عصبی مصنوعی به مقیاس زمانی مورد مطالعه بستگی

## منابع

- ۱- شیروانی، ا. و ت. هنر. ۱۳۹۰. کاربرد مدل‌های سری‌های زمانی برای پیش‌بینی تبخیر-تعرق در ایستگاه باجگاه. مجله پژوهش آب ایران، ۵ (۸): ۱۴۲-۱۳۵.
- ۲- صیادی، ح، اولاد غفاری، ا، فعالیان، ا. و ع. اشرف صدرالدینی. ۱۳۸۸. مقایسه عملکرد شبکه‌های عصبی RBF و MLP در برآورد تبخیر-تعرق گیاه مرجع. مجله دانش آب و خاک، ۱۹ (۱): ۱-۱۲.
- ۳- فتحی، پ، محمدی، ی. و م. همایی. ۱۳۸۸. مدلسازی هوشمند سری زمانی آورد ماهانه ورودی به سد وحدت سندج. مجله آب و خاک (علوم و صنایع کشاورزی)، ۲۳ (۱): ۲۰۹-۲۲۰.
- ۴- فولادمند، ح. ۱۳۸۹. پیش‌بینی ماهانه تبخیر-تعرق مرجع گیاه مرجع در استان فارس. مجله دانش آب و خاک، ۲۰ (۴): ۱۶۹-۱۵۷.
- ۵- قبائی سوق، م، مساعدی، ا، حسام، م. و ا. هزارجریبی. ۱۳۸۹. ارزیابی تاثیر پیش‌پردازش پارامترهای ورودی به شبکه عصبی مصنوعی (ANNs) با استفاده از روش‌های رگرسیون گام به گام و گاما تست به منظور تخمین سریع‌تر تبخیر و تعرق روزانه. نشریه آب و خاک، ۲۴ (۳): ۶۲۴-۶۱۰.
- ۶- قهرمان، ن. و ا. قره‌خانی. ۱۳۹۰. ارزیابی مدل‌های تصادفی سری زمانی در برآورد تبخیر از تشت (مطالعه موردی: ایستگاه شیراز). مجله پژوهش آب در کشاورزی، ۲۵ (۱): ۷۵-۸۱.
- ۷- کارآموز، م. و ش. عراقی نژاد. ۱۳۸۴. هیدرولوژی پیشرفته. انتشارات دانشگاه صنعتی امیرکبیر، ۴۶۴ صفحه.
- ۸- کفیل، م. و م. ضیاتیبار احمدی. ۱۳۸۵. مقایسه دو روش شبکه عصبی مصنوعی و سری زمانی در پیش‌بینی میزان جریان رودخانه. دومین کنفرانس مدیریت منابع آب ایران، دانشگاه صنعتی اصفهان، ۱۸۴ صفحه.
- 9- Adeloje, A. j., Rustum, R. and I. D. Kariyama. 2012. Neural computing modeling of the reference crop evapotranspiration. *Environmental Modelling and Software*, 29: 61-73.
- 10-Allen, R. G., Pereira, L. S., Raes, D. and M. Smith. 1998. Crop evapotranspiration. Guidelines for computing crop water requirements. Irrigation and Drainage Paper 56. UN-FAO, Rome, Italy.
- 11-Archana, C. and R. K. Shrivastava. 2010. Reference crop evapotranspiration estimation using artificial neural networks. *International Journal of Engineering Science and Technology*, 2(9): 4205-4212.
- 12-Castellano-Mendez, M., Gonzalez- Manteiga, W., Febrero- Bande, M., Prada-Sanchez, J. M. and R. Lozano-Calderon. 2004. Modelling of monthly and daily behavior of the run off the Xallas river using Box-Jenkins and neural networks methods. *Journal of Hydrology*, 296: 38-58.
- 13-Diamantopoulou, M. J., Georgiou, P. E. and D. D. Papamichail. 2011. Performance evaluation of artificial neural networks in estimating reference evapotranspiration with minimal meteorological data. *Global NEST Journal*, 13(1): 18-27.
- 14-Ekhmaj, A. I. 2012. Prediction of evapotranspiration using artificial neural networks model. UMT 11<sup>th</sup> International Annual Symposium on Sustainability Science and Management. Terengganu, Malaysia.
- 15-Goel, A. 2009. ANN based modeling for prediction of evaporation in reservoirs. *International Journal of Engineering Transactions A: Basics*, 22 (4):351-358.
- 16-Hoeting, J., Davis, R., Merton, A. and S. Thompson. 2006. Model selection for geostatistical models. *Ecological Applications*, 16(1): 87-98.
- 17-Khoshhal, J. and M. Mokarram. 2012. Model for prediction of evapotranspiration using MLP neural network. *International Journal of Environmental Sciences*, 3(3): 1000-1009.
- 18-McGhee, J. 1985. Introductory statistics. West Publishing Company.

- 19-Okkan, U. 2011. Application of levenberg-marquardt optimization algorithm based multilayer neural networks for hydrological time series modeling. *International Journal of Optimization and Control: Theories and Applications*, 1(1):53-63.
- 20-Singh, P. and M. C. Deo. 2007. Suitability of different neural networks in daily flow forecasting. *Applied Soft Computing*, 7: 968–978.