

## **Performance Analysis of NAR Model for Short and Long Term Drought Forecasting in Arid Regions**

Z. Arjmandi Harat<sup>1</sup>, M.A. Asadi Zarch<sup>2\*</sup>

1. MSc of Watershed Management, Faculty of Natural Resources, Yazd University, Yazd, Iran
2. Assistant Professor, Faculty of Natural Resources, Yazd University, Yazd, Iran

\* Corresponding Author: amin.asadi@yazd.ac.ir

Received date: 05/05/2021

Accepted date: 13/06/2021



[10.22034/JDMAL.2021.246303](https://doi.org/10.22034/JDMAL.2021.246303)

### **Abstract**

Drought forecasting is of particular importance in water resources management. Drought forecasting allows planners to schedule for reducing the negative impacts of drought as well as to adapt to it. Drought prediction is more important in arid regions. Because these areas are inherently water scarce and the consequences of drought in these areas are more severe. Due to the high variabilities of the temporal and spatial distribution of precipitation in these areas, the frequency of drought is higher and results in more difficulty to model and predict drought. In this study, since drought time series is nonlinear and cyclic, nonlinear autoregressive neural networks (NARs) were used to predict short-term and long-term drought in Yazd synoptic station from 2006 to 2018. Reconnaissance Drought Index (RDI) which in addition to precipitation, considers potential evapotranspiration to monitor droughts, for one, three, and six months timescales was calculated. Potential evapotranspiration was calculated using the FAO-Penman-Monteith method. The results of short-term (one month) drought prediction presented that the model provides high performance in predicting three and six months RDI values. The results of long-term (13-years) drought forecasting (without access to real drought data from 2006 to 2018) indicated that RDI values in dry months show best fit to real values in three months' timescale. To improve the efficiency of the model in the long-term drought forecasting, long-term precipitation and potential evapotranspiration (without model access to real data from 2006 to 2018) were predicted. RDI values were then calculated based on the predicted precipitation and potential evapotranspiration data. The results showed that the prediction accuracy increased in one and three months scales. Also, on six months' timescale, RDI data were more accurately predicted in dry months.

**Keywords:** Precipitation; Potential evapotranspiration; FAO-Penman-Monteith; Yazd; RDI





## بررسی کارآیی مدل NAR در پیش‌بینی کوتاه‌مدت و بلندمدت خشکسالی در مناطق خشک

زهره ارجمندی هرات<sup>۱</sup>، محمد امین اسدی زارچ<sup>۲\*</sup>

۱. دانش آموخته کارشناسی ارشد مهندسی آبخیزداری، دانشکده منابع طبیعی و کویرشناسی، دانشگاه یزد، یزد، ایران.

۲. استادیار، گروه مرتع و آبخیزداری، دانشکده منابع طبیعی و کویرشناسی، دانشگاه یزد، یزد، ایران.

\* نویسنده مسئول: [amin.asadi@yazd.ac.ir](mailto:amin.asadi@yazd.ac.ir)

تاریخ دریافت: ۱۴۰۰/۰۲/۱۵ تاریخ پذیرش: ۱۴۰۰/۰۳/۲۳

doi [10.22034/JDMAL.2021.246303](https://doi.org/10.22034/JDMAL.2021.246303)

### چکیده

در مدیریت منابع آب، پیش‌بینی خشکسالی در مناطق خشک اهمیت زیادی دارد. چون به برنامه‌ریزان فرصت می‌دهد تا برای کاهش تاثیر منفی خشکسالی، سازگاری با آن را برنامه‌ریزی کنند. با توجه به تغییرپذیری زیاد زمانی و مکانی بارش در این مناطق، فراوانی وقوع خشکسالی بیشتر و مدل‌سازی و پیش‌بینی خشکسالی در این مناطق سخت‌تر است. در پژوهش حاضر با توجه به ماهیت غیرخطی و چرخه‌ای سری‌های زمانی خشکسالی، از شبکه‌های عصبی خود رگرسیون غیرخطی (NARs) برای پیش‌بینی کوتاه‌مدت و بلندمدت خشکسالی ایستگاه همدیدی یزد در دوره ۲۰۰۶ تا ۲۰۱۸ استفاده شد. همچنین شاخص RDI که علاوه بر بارش، تبخیر و تعرق پتانسیل را نیز در پایش خشکسالی در نظر می‌گیرد، در سه مقیاس یک، سه و شش ماهه محاسبه گردید. تبخیر و تعرق پتانسیل با استفاده از روش فائو-پنمن-مانتیت محاسبه شد. نتایج پیش‌بینی کوتاه مدت (یک ماهه) خشکسالی نشان‌داد مدل کارآیی زیادی در پیش‌بینی مقدارهای RDI سه و شش ماهه دارد. نتایج پیش‌بینی بلندمدت خشکسالی که بدون دسترسی مدل به داده‌های واقعی خشکسالی در دوره ۲۰۰۶ تا ۲۰۱۸ انجام شد، نشان داد مقدار RDI در ماه‌های خشک در مقیاس سه ماهه تطابق بهتری با مقدار واقعی نسبت به دیگر مقیاس‌های زمانی دارد. برای ارتقا کارآیی مدل در پیش‌بینی بلند مدت خشکسالی، مقدارهای بارش و تبخیر و تعرق پتانسیل به صورت بلندمدت و بدون دسترسی مدل به داده‌های واقعی دوره ۲۰۰۶ تا ۲۰۱۸، پیش‌بینی شد. سپس مقادیر RDI بر اساس داده‌های پیش‌بینی شده بارش و تبخیر و تعرق پتانسیل، محاسبه گردید. نتایج نشان داد دقت پیش‌بینی در مقیاس یک و سه ماهه افزایش می‌یابد. همچنین در مقیاس شش ماهه داده‌های RDI در ماه‌های خشک با دقت بیشتری پیش‌بینی شد.

واژگان کلیدی: بارش؛ تبخیر و تعرق پتانسیل؛ فائو-پنمن-مانتیت؛ یزد؛ شاخص RDI



## ■ مقدمه

خشکسالی کاهش قابل توجه بارش در دوره‌ای معین است و ممکن است با عواملی مانند افزایش دما و تبخیر تشدید شود. خشکسالی در همه مناطق آب و هوایی اتفاق می‌افتد. این پدیده منجر به کاهش منابع آب در دسترس شده و بر روی رطوبت خاک، آب‌های سطحی و سفره‌های آب زیرزمینی تأثیر می‌گذارد (۴). تقاضای جهانی برای آب شیرین طی دهه‌های گذشته به دلیل افزایش سریع جمعیت افزایش یافته است. بحران کمبود آب و خشکسالی از مهمترین مشکلاتی است که بشر در سال‌های اخیر با آن روبرو شده است (۱۶). انواع خشکسالی همانند هواشناسی، کشاورزی، هیدرولوژیک و اقتصادی-اجتماعی با کمبود بارندگی همراهند (۲۴). خشکسالی یکی از مهمترین نگرانی‌های مدیران محلی و منطقه‌ای در سراسر جهان، به ویژه در مناطقی که با کمبود آب مواجه هستند، می‌باشد (۲۸). در واقع میزان آسیب‌پذیری جوامع مختلف در برابر تأثیر خشکسالی به عوامل متعددی از جمله میزان منابع آب موجود بستگی دارد (۲۳). مناطق خشک و فراخشک با توجه به محدودیت شدیدی که در منابع آب در دسترس دارند، دارای بوم‌نظام ضعیف و حساسی هستند. این ویژگی موجب می‌شود این مناطق آسیب‌پذیری بیشتری نسبت به سایر اقلیم‌ها در مواجهه با خشکسالی داشته باشند (۵).

آماده‌سازی و برنامه‌ریزی برای مقابله با اثرات زیان‌بار این رویداد به اطلاعات مربوط به گستردگی، شدت و مدت خشکسالی بستگی دارد. بنابراین، پایش خشکسالی در برنامه‌ریزی، طراحی و مدیریت سیستم‌های منابع آب بسیار حیاتی است. این اطلاعات را می‌توان با شاخص‌های خشکسالی بدست آورد که اطلاعات کمی در مورد ویژگی‌های خشکسالی را در اختیار تصمیم‌گیرندگان قرار می‌دهد. چنین اطلاعات کمی در پایش خشکسالی بسیار مفید است (۱۷). در واقع شاخص‌های خشکسالی برای پایش خشکسالی و با تلفیق متغیرهای آب و هوایی مانند بارش، تبخیر و تعرق و دما ایجاد شده‌اند (۳۰) و با ساده‌سازی توابع پیچیده اقلیمی، شدت، گسترش، مدت و فراوانی خشکسالی‌ها را کمی می‌کنند (۲۵).

شاخص‌های خشکسالی هواشناسی انحراف متغیرهای اقلیمی را در یک دوره زمانی معین از شرایط نرمال محاسبه می‌کنند (۲۲). شاخص‌های خشکسالی اقلیمی از پارامترهای اقلیمی متفاوتی برای کمی کردن خشکسالی بهره می‌برند. برخی از شاخص‌ها فقط براساس بارش هستند و برخی دیگر علاوه بر بارش، پارامترهای موثر دیگری مانند تبخیر و تعرق پتانسیل را نیز در نظر می‌گیرند. در بررسی حاضر، به منظور کمی‌سازی خشکسالی از شاخص RDI<sup>۱</sup> بهره‌گیری شد. این شاخص علاوه بر بارش، تبخیر و تعرق پتانسیل را نیز در پایش خشکسالی در نظر می‌گیرد (۲۷). تشدید چرخه هیدرولوژیک یکی از پیامدهای تغییر اقلیم است که موجب می‌شود بزرگی، فراوانی وقوع و وسعت مناطق تحت تأثیر رویدادهای حدی آب و هوایی مانند خشکسالی افزایش یابد (۱۰). وقوع خشکسالی‌ها به طور قابل توجهی از نظر تعداد و شدت در طی چند دهه گذشته افزایش یافته است و مردم بیش از هر خطر طبیعی دیگر برای مدت زمان طولانی تحت تأثیر قرار گرفته‌اند (۲۵). پژوهش‌های اخیر نشان می‌دهد روند گرم شدن زمین در آینده نیز ادامه خواهد داشت (۲۱). بنابراین انتظار می‌رود به دلیل وقوع گرمایش جهانی و تغییر اقلیم، رخداد‌های خشکسالی و اثرات آنها بر روی جامعه و محیط شدیدتر شود (۲۴). پیش‌بینی می‌شود کمبود آب ناشی از عدم تعادل مکانی و زمانی بین تأمین و تقاضای آب در شرایط آب و هوایی گرم‌تر شدیدتر شود (۲۵).

تأمین پایدار آب یکی از الزامات اساسی برای بقا و توسعه جوامع بشری است (۱۴). اثرهای تغییر اقلیم بر قابلیت دسترسی به آب و تقاضای آب همراه با فشارهای مستقیم ایجاد شده توسط افزایش جمعیت، تغییر کاربری اراضی، آلودگی و اقدامات نامناسب مدیریت آب، احتمالاً منابع آب سطحی و زیرزمینی را کاهش می‌دهد و در نتیجه رقابت برای آب را افزایش خواهد داد (۲۰، ۷). پیش‌بینی خشکسالی یکی از اقدامات مهمی است که می‌تواند به برنامه‌ریزی صحیح جهت تأمین پایدار آب منجر شود (۱۹). پیش‌بینی خشکسالی یکی اجزا مهم مدیریت بهینه منابع آب می‌باشد که به مدیران و برنامه‌ریزان بخش آب کمک

می‌کند تا اثرات شدید کمبود آب ناشی از وقوع خشکسالی را کاهش دهند (۲). از این رو، محققان به دنبال پیش‌بینی خشکسالی با استفاده از روش‌های مختلف و برآورد نتایج آن به منظور مدیریت و انجام اقدامات مناسب در مقابل این پدیده هستند (۱۸).

شبکه‌های عصبی مصنوعی از روش‌های متداول برای شبیه‌سازی و پیش‌بینی تغییرات مؤلفه‌های اقلیمی مانند وقوع پدیده خشکسالی هستند (۱۱). این شبکه‌ها مدل‌های ریاضی و انعطاف‌پذیری هستند که می‌توانند در مدل‌سازی سیستم‌های پیچیده به کار برده شوند و می‌توانند یک نگاهت غیرخطی بین ورودی‌ها و خروجی‌ها ارائه دهند (۱۳). برای پیش‌بینی موثر داده‌های غیرخطی، محققان استفاده از شبکه‌های عصبی مصنوعی (ANN) را با داده‌های هیدرولوژیک گسترش داده‌اند (۳). نتایج نشان داده است روش‌های داده محور بر اساس کاربرد شبکه‌های عصبی مصنوعی دارای قابلیت‌های قابل توجهی در زمینه پیش‌بینی قابل اعتماد خشکسالی هستند (۲). بنابراین، کاربرد شبکه‌های عصبی مصنوعی در علوم هیدرولوژیکی به‌طور ویژه شامل پیش‌بینی وقایع خشکسالی است (۲۹). در پژوهش حاضر با توجه به ماهیت غیرخطی و چرخه‌ای سری‌های زمانی خشکسالی، از شبکه‌های عصبی خود رگرسیون غیرخطی (NARS<sup>۲</sup>) برای پیش‌بینی وقوع خشکسالی استفاده گردیده است. نتایج نشان داده است شبکه‌های NAR از کارایی قابل قبولی در پیش‌بینی سری‌های زمانی برخوردار هستند (۱۵). این مدل‌ها می‌توانند در پیش‌بینی داده‌های غیرخطی موثر هستند (۸). تاکنون مطالعاتی برای پیش‌بینی خشکسالی با استفاده از مدل NAR انجام گرفته است. اما مطالعه‌ای که همزمان قابلیت این مدل را در پیش‌بینی کوتاه‌مدت و بلندمدت خشکسالی در مناطق خشک مورد بررسی قرار دهد، یافت نشد. پراکنش بارش در مناطق خشک و فراخشک بسیار ناهمگون است. هدف از پژوهش حاضر، بررسی قابلیت مدل‌های شبکه‌های عصبی مصنوعی NAR در پیش‌بینی کوتاه‌مدت و بلندمدت خشکسالی در این مناطق است. در پیش‌بینی خشکسالی بلندمدت، علاوه بر پیش‌بینی

## ■ مواد و روش‌ها

### منطقه مورد بررسی و داده‌ها

پژوهش حاضر با استفاده از آمار ایستگاه هواشناسی همدید یزد، مستقر در شهرستان یزد انجام شد. استان یزد با مساحت حدود  $131575 \text{ km}^2$  در قسمت مرکزی فلات ایران قرار دارد. این استان در  $29^\circ 35'$  تا  $35^\circ 7'$  عرض شمالی و  $52^\circ 50'$  تا  $58^\circ 16'$  طول شرقی واقع شده است (شکل ۱). مرتفع‌ترین و پست‌ترین منطقه استان به ترتیب در قسمت جنوب غربی (شیرکوه با ارتفاع حدود  $4075 \text{ m}$ ) و ارتفاع  $950 \text{ m}$  در شمال تا شمال شرقی استان واقع شده است. شهرستان یزد در ارتفاع حدود  $1200 \text{ m}$  از سطح دریا قرار دارد. در مجموع، ارتفاعات از غرب به شرق استان کاهش یافته و به همان نسبت وسعت شوره زارها و کویرها از غرب به شرق افزایشی است. ایستگاه هواشناسی همدید یزد با بیش از ۶۰ سال آمار، دارای طولانی‌ترین دوره آماری در بین ایستگاه‌های استان یزد است. در پژوهش حاضر از داده‌های بارش، دمای حداقل، حداکثر و میانگین، سرعت باد، ساعات آفتابی و رطوبت نسبی ثبت شده در ایستگاه هواشناسی یزد با طول دوره آماری ۵۸ سال در مقیاس ماهانه از ژانویه ۱۹۶۱ معادل دی ماه ۱۳۳۹ تا دسامبر ۲۰۱۸ معادل آذر ماه ۱۳۹۷، استفاده گردید. لازم به ذکر است اختلاف ماه‌های میلادی و شمسی حداکثر ۱۱ روز می‌باشد. از بین متغیرهای مذکور، فقط داده‌های ساعات آفتابی نقص قابل توجه داشت که با استفاده از روابط رگرسیونی بین دمای متوسط و ساعات آفتابی در ماه‌های بدون نقص و اعمال آن برای ماه‌های با نقص آماری، بازسازی داده‌های ناقص ساعات آفتابی انجام شد.

### روش پژوهش

محاسبهٔ تبخیر و تعرق پتانسیل با استفاده از روش فائو-پنمن-مانتیث



پیش‌بینی می‌کند و برای پیش‌بینی بیش از یک گام زمانی، باید داده‌های واقعی متغیر مورد پیش‌بینی در تعداد گام‌های زمانی مورد پیش‌بینی به جز گام زمانی آخر در اختیار مدل قرار گیرد تا از هر مقدار واقعی در هر گام برای پیش‌بینی مقدار متغیر در گام بعدی استفاده شود (۱۲). بنابراین در این حالت مقادیر RDI یک، سه و شش ماهه در دوره ۱۹۶۱ تا ۲۰۱۸ (دی ماه ۱۳۳۹ تا آذر ماه ۱۳۹۷) در اختیار مدل قرار گرفت و دوره دی ۱۳۸۴ تا آذر ۱۳۹۷ به عنوان دوره پیش‌بینی در نظر گرفته شد. همانگونه که ذکر گردید، بیشینه اختلاف ماه‌های میلادی و شمسی ۱۱ روز می‌باشد.

### پیش‌بینی بلندمدت خشکسالی

در پژوهش حاضر، مدل NAR برای پیش‌بینی تعداد گام زمانی دلخواه<sup>۴</sup> نیز مورد استفاده قرار گرفت (شکل ۴). در این روش، شبکه NAR مقدار پیش‌بینی شده در گام زمانی حاضر را برای پیش‌بینی متغیر مورد مطالعه در گام زمانی بعدی مورد استفاده قرارداد (۹). در واقع مدل NAR برای پیش‌بینی تعداد گام زمانی دلخواه، پیش‌بینی گام‌های زمانی آینده را در یک فرایند مرحله به مرحله<sup>۵</sup> انجام داد. در ابتدا مقدار  $x_{t+1}$  با استفاده از  $p$  مقدار گذشته  $x_{t+1-p}, \dots, x_{t-1}, x_t$  پیش‌بینی شد.


در این رابطه  $f$  یک تابع غیر خطی از متغیرهای توصیفی یا رگرسورها<sup>۱</sup> می‌باشد که توابع متفاوتی می‌تواند انتخاب شود. در پژوهش حاضر از شبکه عصبی پیشخور به دلیل دقت بالای آن در مدل‌سازی فرایندهای غیرخطی استفاده شده است.  $y(t)$  مقدار پیش‌بینی شده پارامتر هدف توسط مدل در زمان  $t$  با استفاده از  $p$  داده گذشته از سری داده‌های پارامتر هدف است. از آنجا که در مرحله آموزش، خروجی‌های سیستم واقعی موجود بود، خروجی‌های سیستم واقعی در ورودی مدل استفاده گردید. در حالت استفاده از خروجی‌های سیستم واقعی، شبکه عصبی دارای ساختار پیش‌سو بوده و به آن مدل سری موازی گفته می‌شود. برای آموزش شبکه از الگوریتم  $GDX^2$  استفاده شده است (۳).

### پیش‌بینی کوتاه‌مدت خشکسالی

در حالت عادی مدل NAR تنها برای یک گام زمانی<sup>۳</sup> پیش‌بینی را انجام می‌دهد (شکل ۳). در این حالت در ابتدا مقدار  $x_{t+1}$  با استفاده از  $p$  مقدار گذشته  $x_{t+1-p}, \dots, x_{t-1}, x_t$  پیش‌بینی می‌شود. سپس مقدار  $x_{t+2}$  بر اساس  $p$  مقدار قبلی  $x_{t+1-p}, \dots, x_{t-1}, x_t, x_{t+1}$  مقدار واقعی متغیر مورد پیش‌بینی در گام زمانی  $t+1$  می‌باشد. بنابراین در این حالت مدل فقط یک گام زمانی پیش‌رو را



شکل ۲. مدل NAR مورد استفاده در آموزش شبکه (۸)



شکل ۳. مدل NAR برای پیش‌بینی یک گام زمانی (۸)

3 One step-ahead prediction  
4 Multistep-ahead prediction  
5 Step by step

1 Regressors  
2 Gradient descent with momentum and adaptive learning rate backpropagation

در نتیجه مقادیر RDI در دوره ۲۰۰۶ تا ۲۰۱۸ نیز در اختیار مدل قرار گرفت. بنابراین در این حالت مدل NAR تنها برای یک گام زمانی پیش‌بینی خشکسالی را انجام می‌دهد. بنابراین با کاهش تعداد گام زمانی پیش‌بینی، انتظار می‌رود دقت مدل افزایش یابد. تعداد لایه‌های پنهان در این شبکه بین ۱۱ تا ۳۰ انتخاب گردید. همچنین زمان تأخیر بین ۱ تا ۲۴ ماه در نظر گرفته شد. سپس شبکه NAR برای هر یک از ترکیب‌های یاد شده اجرا شد. در مرحله بعد خروجی‌های پیش‌بینی شده RDI توسط هر یک از مدل‌ها با مقادیر RDI مشاهداتی مقایسه و ضریب  $R^2$  برای هر یک از مدل‌ها محاسبه گردید. سپس بالاترین میزان  $R^2$  برای هر مقیاس زمانی مشخص و شبکه مربوطه به‌عنوان مناسب‌ترین شبکه انتخاب شد (جدول ۱). مدل NAR با یک گام زمانی پیش‌بینی در مقیاس زمانی یک ماهه با تعداد لایه‌های پنهان ۲۹ و زمان تأخیر ۲۴ ماه بیشترین مقدار همبستگی را نشان داد ( $R^2$  برابر ۰/۵۴۵) (جدول ۱). شکل (۶) خروجی‌های مدل مذکور را در مقایسه با مقادیر RDI واقعی نشان می‌دهد. ماه‌های مرطوب با دقت نسبتاً مناسبی پیش‌بینی شدند. ماه‌های خشک در مواردی نسبتاً مناسب پیش‌بینی شد. در مواردی هم پیش‌بینی انجام شده همراه با بزرگ‌نمایی یا کوچک‌نمایی بوده است.

اجرای مدل NAR با ترکیب‌های مختلف از تعداد لایه‌های پنهان بین ۱۱ تا ۳۰ و زمان‌های تأخیر متفاوت ۱ تا ۲۴ ماه برای مقیاس سه ماهه نشان داد مدل با ترکیب تعداد لایه‌های پنهان ۲۳ و زمان تأخیر ۱۰ ماه دارای بالاترین کارایی با  $R^2$  برابر ۰/۹۱۹ بود. نتایج مدل مذکور در مقایسه با مقادیر واقعی در شکل (۷) نمایش داده شده است. پیش‌بینی‌های مدل تطابق قابل قبولی با مقادیر RDI واقعی در طول دوره ۲۰۰۶ تا ۲۰۱۸ در ایستگاه همدیدی یزد دارد. لازم به ذکر است تطابق مقادیر شبیه‌سازی شده و واقعی هم در ماه‌های خشک و هم در ماه‌های مرطوب نسبتاً قابل قبول است. در مقیاس زمانی شش ماهه، شبکه با تعداد لایه‌های پنهان ۱۱ و زمان تأخیر ۲۴ ماه دارای بالاترین  $R^2$  با مقدار ۰/۹۵۷ می‌باشد (شکل ۸). تطابق مناسبی بین داده‌های پیش‌بینی شده خشکسالی و مقدار خشکسالی مشاهده شده در ماه‌های خشک و مرطوب وجود دارد.

سپس مقدار  $X_{t+2}$  بر اساس  $p$  مقدار قبلی که مقدار پیش‌بینی شده برای  $X_{t+1}$  را نیز شامل می‌شد  $(X_{t+1-p}, \dots, X_{t-1}, X_t, X_{t+1})$ ، پیش‌بینی شد. این فرایند تا پیش‌بینی آخرین مقدار  $X_{t+h}$  ادامه یافت.  $h$  تعداد گام زمانی مورد نظر برای پیش‌بینی است.

در پژوهش حاضر با توجه به طول دوره پیش‌بینی ۲۰۰۶ تا ۲۰۱۸ که برابر ۱۳ سال و در نتیجه ۱۵۶ ماه بود، تعداد گام زمانی پیش‌بینی ۱۵۶ در نظر گرفته شد. همانگونه که ذکر شد، در مطالعه حاضر داده‌های RDI در دوره ۲۰۰۶ تا ۲۰۱۸ در اختیار مدل قرار نگرفت. تعداد لایه‌های پنهان شبکه بین ۱۱ تا ۳۰ انتخاب گردید. همچنین زمان تأخیر شبکه نیز بین ۱ تا ۲۴ ماه در نظر گرفته شد. سپس شبکه برای هر یک از ترکیب‌های یاد شده اجرا شد و خروجی‌های پیش‌بینی شده RDI توسط هر یک از مدل‌ها با مقدار RDI مشاهداتی مقایسه و ضریب تعیین  $R^2$  محاسبه شد. سپس بیشترین مقدار  $R^2$  برای هر مقیاس زمانی مشخص و شبکه مربوطه به‌عنوان مناسب‌ترین شبکه انتخاب شد.

## ■ نتایج و بحث


### تبخیر و تعرق پتانسیل ایستگاه همدیدی یزد در طول دوره مورد مطالعه

مقادیر تبخیر و تعرق پتانسیل و همچنین دمای حداقل، دمای حداکثر، سرعت باد، ساعات آفتابی و رطوبت نسبی ماهانه ایستگاه یزد در طول دوره آماری ۱۹۶۱-۲۰۱۸ در شکل (۵) نمایش داده شده است. از بین پارامترهای دمای حداقل و حداکثر، رطوبت نسبی، سرعت باد و ساعات آفتابی، تغییرات مقادیر ماهانه تبخیر و تعرق پتانسیل ایستگاه یزد در طول دوره مورد مطالعه با نوسان‌های مقدار سرعت باد انطباق بیشتری دارد.

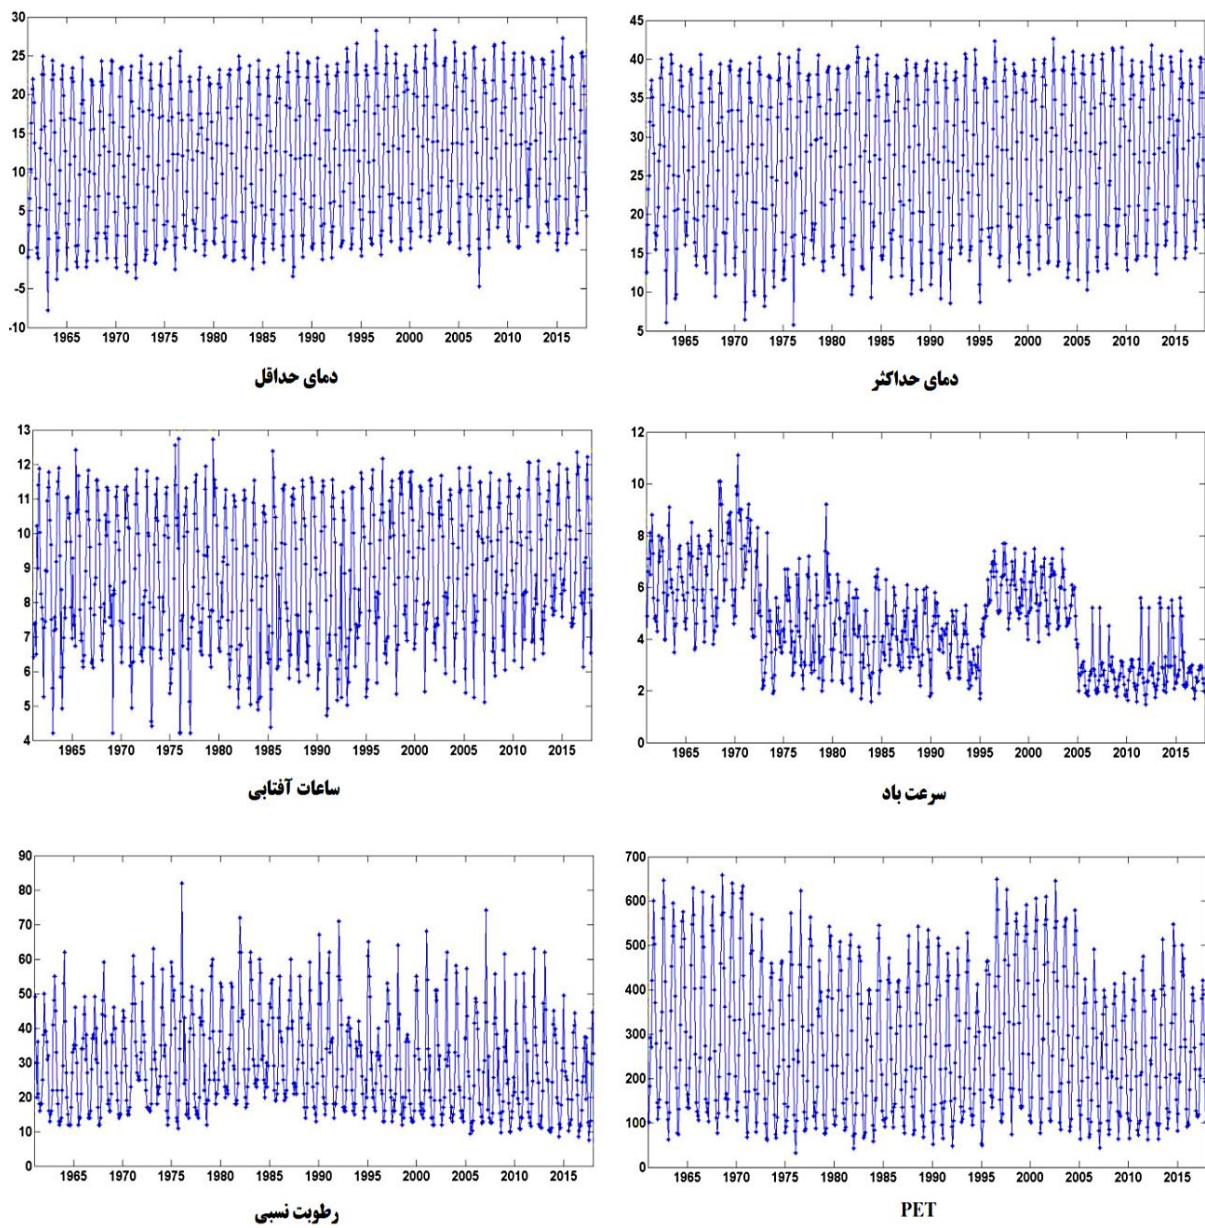
### پیش‌بینی کوتاه مدت خشکسالی با استفاده از مدل شبکه عصبی NAR

برای سنجش توانایی مدل NAR در پیش‌بینی کوتاه مدت خشکسالی، یک‌ماهه، در مناطق خشک تعداد گام زمانی پیش‌بینی یک گام معادل یک ماه در نظر گرفته شد.





شکل ۴. مدل NAR برای پیش‌بینی تعداد گام زمانی دلخواه (۸)



شکل ۵. دمای حداقل، دمای بیشینه، ساعات آفتابی، سرعت باد، رطوبت نسبی و تبخیر و تعرق پتانسیل ماهانه ایستگاه همدیدی یزد در طول دوره آماری ۱۹۶۱-۲۰۱۸




جدول ۱. مقدار ضریب تعیین ( $R^2$ ) بین RDI یک ماهه مشاهده شده و پیش‌بینی شده در دوره ۲۰۰۶ تا ۲۰۱۸ توسط مدل شبکه عصبی NAR با پیش‌بینی یک گام زمانی با زمان‌های تأخیر و تعداد لایه‌های متفاوت

تعداد لایه پنهان	زمان تأخیر	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲
۱۱	۰/۲۸۲	۰/۲۷۶	۰/۲۴۷	۰/۲۵۴	۰/۳۲۶	۰/۳۸۳	۰/۴۴۳	۰/۴۰۲	۰/۴۸۹	۰/۴۳۳	۰/۴۷۴	۰/۴۰۵	
۱۲	۰/۲۷۷	۰/۲۹۴	۰/۳۲۶	۰/۳۰۷	۰/۳۳۲	۰/۳۹۲	۰/۴۴۲	۰/۴۷۷	۰/۴۸۴	۰/۴۲	۰/۳۹۵	۰/۴۴۹	
۱۳	۰/۳۳	۰/۳۲۵	۰/۲۷۳	۰/۳۰۳	۰/۴	۰/۲۵۷	۰/۳۵۲	۰/۳۷۸	۰/۳۳۷	۰/۴۵۲	۰/۴۲۷	۰/۳۹۵	
۱۴	۰/۲۵۷	۰/۲۹	۰/۲۳۴	۰/۳۰۳	۰/۲۹۲	۰/۳۵۳	۰/۴۳۲	۰/۴۷۴	۰/۳۸۱	۰/۴۳۹	۰/۳۶۹	۰/۳۲۸	
۱۵	۰/۲۹۶	۰/۳۲۲	۰/۲۷۳	۰/۳۳۱	۰/۳۴۴	۰/۳۲۳	۰/۴۴	۰/۴۴۷	۰/۳۶	۰/۴۲۳	۰/۳۶۵	۰/۲۸	
۱۶	۰/۳۲۵	۰/۳۰۴	۰/۳۰۹	۰/۱۰۶	۰/۲۹۷	۰/۳۸۸	۰/۳۴۱	۰/۴۱۸	۰/۴۳۲	۰/۳۷۸	۰/۴۴	۰/۴۳۲	
۱۷	۰/۲۳۶	۰/۲۲۴	۰/۲۶۷	۰/۳۰۹	۰/۳۷۴	۰/۳۵۸	۰/۳۶۷	۰/۴۱۹	۰/۴۵۴	۰/۴۴۶	۰/۴۲۵	۰/۴۵۸	
۱۸	۰/۲۷۳	۰/۲۵۵	۰/۲۷۵	۰/۲۵۳	۰/۳۳۷	۰/۳۰۵	۰/۳۴۷	۰/۴۲۲	۰/۴۰۶	۰/۳۹۹	۰/۴۲	۰/۳۴۱	
۱۹	۰/۳۲۶	۰/۲۷۶	۰/۲۵۸	۰/۲۲۳	۰/۲۶۴	۰/۴۱۹	۰/۴۵۸	۰/۴۶۹	۰/۴۳۸	۰/۳۴۷	۰/۴۴	۰/۴۳۱	
۲۰	۰/۳۳۵	۰/۳۰۹	۰/۲۸۶	۰/۲۳۴	۰/۳۳۲	۰/۳۵۸	۰/۳۷۲	۰/۴۰۲	۰/۴۱۴	۰/۳۵۵	۰/۴۷	۰/۴۷۴	
۲۱	۰/۳۳۱	۰/۲۵۱	۰/۲۳۴	۰/۲۸۴	۰/۲۹۹	۰/۲۸۵	۰/۳۷۹	۰/۳۷۷	۰/۳۷۶	۰/۳۹۳	۰/۳۸۲	۰/۳۸۴	
۲۲	۰/۳۲	۰/۳۵۵	۰/۲۶۵	۰/۲۸	۰/۳۱۶	۰/۳۴	۰/۴۰۴	۰/۲۳۲	۰/۴۵۲	۰/۴۸۴	۰/۴۱۵	۰/۵۱۲	
۲۳	۰/۳۱۷	۰/۳۱۷	۰/۲۳۷	۰/۱۱۵	۰/۳۷۸	۰/۳۸۳	۰/۲۸۱	۰/۳۹۵	۰/۳۹	۰/۳۵۸	۰/۵۱۹	۰/۳	
۲۴	۰/۳۲۷	۰/۲۹۵	۰/۲۷	۰/۱۰۳	۰/۳۶۶	۰/۳۷۱	۰/۳۸۴	۰/۴۱	۰/۳۵	۰/۳۶۸	۰/۳۵۲	۰/۳۵	
۲۵	۰/۳۴۷	۰/۲۵۶	۰/۳۰۷	۰/۳۲۲	۰/۳۶۳	۰/۳۵۷	۰/۴۱۷	۰/۴۳۴	۰/۳۷۷	۰/۴۲۱	۰/۳	۰/۴۵۶	
۲۶	۰/۳۲۴	۰/۲۴۷	۰/۲۷۹	۰/۲۳۶	۰/۲۸۹	۰/۳۶۷	۰/۴۸۳	۰/۴۶۶	۰/۴۲	۰/۲۴۸	۰/۲۵۲	۰/۴۷۳	
۲۷	۰/۲۷۸	۰/۲۶۱	۰/۱۹۳	۰/۲۱۸	۰/۳۹	۰/۲۵۲	۰/۴۶۱	۰/۳۴۸	۰/۴۰۳	۰/۴۰۳	۰/۴۷۶	۰/۳۷۲	
۲۸	۰/۳۳۹	۰/۲۴۵	۰/۲۶۲	۰/۱۸۸	۰/۲۸۷	۰/۳۶۲	۰/۳۲۵	۰/۳۴۶	۰/۳۵۹	۰/۵۰۱	۰/۱۵۴	۰/۴	
۲۹	۰/۳۴۲	۰/۳۱	۰/۲۶۳	۰/۱۵۹	۰/۳۰۳	۰/۳۷۷	۰/۳۴۲	۰/۳۷	۰/۴۸۸	۰/۳۶	۰/۳۵۹	۰/۴۱۷	
۳۰	۰/۲۸۵	۰/۳۳۸	۰/۱۸۷	۰/۲۷۷	۰/۲۱۴	۰/۳۸۵	۰/۴۱۸	۰/۳۸۴	۰/۳۸۵	۰/۲۴۶	۰/۲۴۶	۰/۱۹	

ادامه جدول ۱. مقدار ضریب تعیین ( $R^2$ ) بین RDI یک ماهه مشاهده شده و پیش‌بینی شده در دوره ۲۰۰۶ تا ۲۰۱۸ توسط مدل شبکه عصبی NAR با پیش‌بینی یک گام زمانی با زمان‌های تأخیر و تعداد لایه‌های متفاوت


تعداد لایه پنهان	زمان تأخیر	۱۳	۱۴	۱۵	۱۶	۱۷	۱۸	۱۹	۲۰	۲۱	۲۲	۲۳	۲۴
۱۱	۰/۴۴۹	۰/۳۹۱	۰/۵۱۲	۰/۳۰۹	۰/۵۲۲	۰/۳۳۱	۰/۴۵۸	۰/۴۹۷	۰/۴۹۳	۰/۳۱۵	۰/۴۶	۰/۴۶۶	
۱۲	۰/۵۲۱	۰/۵۱	۰/۴۷۸	۰/۳۹۹	۰/۴۸۴	۰/۵۳۱	۰/۳۴۱	۰/۴۴۴	۰/۳۹۶	۰/۳۴۸	۰/۳۳۸	۰/۵۳۶	
۱۳	۰/۳۹۵	۰/۳۹۷	۰/۴۴۲	۰/۴۱۸	۰/۳۸۸	۰/۴۱۷	۰/۴۶۷	۰/۴۱۶	۰/۴۵۶	۰/۳۷۴	۰/۳۵۵	۰/۳۹۹	
۱۴	۰/۲۹۶	۰/۴۳	۰/۴۱۷	۰/۲۴۳	۰/۴۵۹	۰/۴۱۴	۰/۵۱۷	۰/۴۶۲	۰/۲۶۸	۰/۴۰۳	۰/۵۲۲	۰/۴۶۷	
۱۵	۰/۲۶۴	۰/۴۲۹	۰/۴۴۷	۰/۴۵۲	۰/۳۸۱	۰/۲۹۹	۰/۲۸۳	۰/۴۳۴	۰/۳۹۶	۰/۲۳۴	۰/۵۱۱	۰/۵۳۲	
۱۶	۰/۴۹۶	۰/۴۹۷	۰/۴۴۲	۰/۳۳۵	۰/۳۳۳	۰/۴۸۶	۰/۳۶۵	۰/۴۸۹	۰/۴۴۱	۰/۴۶۵	۰/۳۵	۰/۴۵۳	
۱۷	۰/۲۵۴	۰/۴۳۲	۰/۴۴	۰/۴۴۹	۰/۳۶۸	۰/۳۲۲	۰/۱۴۴	۰/۳۴	۰/۳۵۴	۰/۳۹	۰/۵۰۹	۰/۴۵۹	
۱۸	۰/۲۳	۰/۲۹۶	۰/۴۲	۰/۴۵۸	۰/۴۳۷	۰/۳۲۹	۰/۴۲۵	۰/۲۴۷	۰/۴۳۵	۰/۴۶۵	۰/۲۳۹	۰/۳۳۴	
۱۹	۰/۴۱۱	۰/۴۵۹	۰/۲۷	۰/۳۶۳	۰/۳۷۷	۰/۴۰۴	۰/۳۸۱	۰/۲۳۹	۰/۲۹۲	۰/۳۳۲	۰/۳۸۱	۰/۴۸	
۲۰	۰/۳۰۴	۰/۰۰۶	۰/۴۱۶	۰/۴۵۱	۰/۳۴۶	۰/۳۲۴	۰/۴۰۹	۰/۴۳۶	۰/۳۲۸	۰/۳۵۸	۰/۱۴۷	۰/۲۱۳	
۲۱	۰/۲۱۳	۰/۴۶۱	۰/۳۸۵	۰/۳۶۲	۰/۴۲۲	۰/۲۶۹	۰/۴۱۶	۰/۴۴۲	۰/۲۶۴	۰/۳۷۴	۰/۳۲۶	۰/۴۳۴	
۲۲	۰/۲۶	۰/۴۲	۰/۳۳۷	۰/۱۴۹	۰/۳۳۱	۰/۴۶۲	۰/۴۷۳	۰/۳۷۴	۰/۳۷۸	۰/۲۵۲	۰/۱۰۲	۰/۴۹	
۲۳	۰/۴۲۷	۰/۳۹۶	۰/۴۶۴	۰/۳۴۲	۰/۲۲۵	۰/۲۴۶	۰/۳۵۲	۰/۳۵۴	۰/۳۴۵	۰/۴۲۲	۰/۱۶۳	۰/۴۵۲	
۲۴	۰/۳۸۷	۰/۳۱۸	۰/۲۶۷	۰/۱۴۱	۰/۳۶۷	۰/۳۲	۰/۴۱۴	۰/۳۶۶	۰/۲۵۲	۰/۳۵۳	۰/۲۸۹	۰/۴۳۳	
۲۵	۰/۴۶۶	۰/۳۴۱	۰/۲۸۸	۰/۴۰۲	۰/۳۹۲	۰/۲۲۲	۰/۴۱۵	۰/۲۸	۰/۳۲۹	۰/۳۱۷	۰/۳۹۶	۰/۵۱۷	
۲۶	۰/۲۴	۰/۲۲۲	۰/۲۴۴	۰/۳۶	۰/۳۱۴	۰/۳۰۳	۰/۲۱۱	۰/۱۸۳	۰/۵۰۲	۰/۳۵۹	۰/۱۸۵	۰/۲۷۱	
۲۷	۰/۲۴۳	۰/۳۶۶	۰/۲۳۹	۰/۴۷۷	۰/۲۵۷	۰/۴۷۸	۰/۲۲۸	۰/۳۷۴	۰/۴۴	۰/۳۱۳	۰/۲۲۷	۰/۳۱۷	
۲۸	۰/۳۴۱	۰/۱۱۷	۰/۳۸۸	۰/۳۵۶	۰/۲۹	۰/۲۹۱	۰/۳۹۱	۰/۲۰۶	۰/۲۹۱	۰/۳۳۳	۰/۴۲	۰/۵۴۹	
۲۹	۰/۴۳	۰/۲۵۶	۰/۳۸۵	۰/۴۳۵	۰/۳۹۴	۰/۲۷۲	۰/۱۰۱	۰	۰/۳۳۸	۰/۴۳۲	۰/۳۳۸	۰/۵۴۵	
۳۰	۰/۲۶۱	۰/۳۳۲	۰/۴۶۲	۰/۲۱۸	۰/۳۶۹	۰/۲۶۶	۰/۵۳۴	۰/۴۲۸	۰/۱۸۳	۰/۳۲۶	۰/۲۴۷	۰/۳۵۴	




شکل ۶. مقایسه مقدار RDI پیش‌بینی شده توسط مدل شبکه عصبی NAR با پیش‌بینی یک گام زمانی و مقدار مشاهداتی در مقیاس یک ماهه در طول دوره آماری ۲۰۰۶ تا ۲۰۱۸

مقیاس‌های یک ماهه، سه ماهه و شش ماهه را نمایش می‌دهد. نتایج نشان‌دهنده همبستگی قابل قبولی بین مقادیر RDI مشاهداتی و مقادیر پیش‌بینی شده توسط شبکه عصبی NAR با یک گام زمانی پیش‌بینی در مقیاس‌های زمانی سه و شش ماهه می‌باشد.

همانگونه که انتظار می‌رفت، دقت مدل با افزایش مقیاس زمانی خشکسالی از یک ماه به شش ماه و در نتیجه کاهش نوسان، به طور قابل توجهی افزایش می‌یابد. جدول (۲) میزان همبستگی بین داده‌های مشاهداتی و پیش‌بینی شده با استفاده از NAR با یک گام زمانی پیش‌بینی در



شکل ۷. مقایسه مقدار RDI پیش‌بینی شده با پیش‌بینی یک گام زمانی با مقدار مشاهداتی در مقیاس سه ماهه در طول دوره آماری ۲۰۰۶ تا ۲۰۱۸



شکل ۸. مقایسه مقدار RDI پیش‌بینی شده با پیش‌بینی یک گام زمانی و مقدار مشاهداتی در مقیاس شش ماهه در طول دوره آماری ۲۰۰۶ تا ۲۰۱۸

جدول ۲. مقایسه ضریب تعیین ( $R^2$ ) بین RDI پیش بینی شده با استفاده از مدل شبکه عصبی NAR با یک گام زمانی پیش بینی و خشکسالی‌های مشاهداتی در مقیاس‌های یک ماهه، سه ماهه و شش ماهه

مقیاس زمانی	ضریب تعیین ( $R^2$ )
RDI یک ماهه	۰/۵۴۵
RDI سه ماهه	۰/۹۱۹
RDI شش ماهه	۰/۹۵۷

مرطوب نسبتاً مناسب پیش‌بینی کرده است. مقدار  $R^2$  بین RDI شش ماهه مشاهده شده و پیش‌بینی شده توسط مدل شبکه عصبی NAR با زمان تأخیر ۱ تا ۲۴ ماه و تعداد لایه های پنهان ۱۱ تا ۳۰ در جدول ۳ ارائه شده است. در مقیاس شش ماهه مدل NAR با تعداد لایه‌های پنهان ۲۲ و زمان تأخیر ۱۷ ماه دارای بالاترین میزان کارایی با  $R^2$  برابر ۰/۷۱۹ می‌باشد. مقایسه مقدار RDI مشاهده شده و RDI پیش‌بینی شده با استفاده از مدل شبکه عصبی مصنوعی NAR با تعداد لایه‌های مذکور در شکل ۱۱ نمایش داده شده است. ماه‌های نرمال و مرطوب به‌خوبی پیش‌بینی شده‌اند. اما ماه‌های خشک با دقت کمتری پیش‌بینی شده‌اند. میزان همبستگی بین داده‌های مشاهداتی و پیش‌بینی شده در مقیاس‌های یک ماهه، سه ماهه و شش ماهه در جدول ۴ ارائه شده است. همبستگی نسبتاً مناسبی بین داده‌های مشاهداتی و داده‌های پیش‌بینی شده شبکه عصبی NAR در مقیاس‌های زمانی سه و شش ماهه مشاهده می‌شود.


#### پیش‌بینی بلندمدت خشکسالی با استفاده از پیش‌بینی بلندمدت بارش و تبخیر و تعرق پتانسیل

پیش‌بینی خشکسالی می‌تواند از طریق پیش‌بینی بارش و تبخیر و تعرق پتانسیل و سپس محاسبه مقادیر شاخص RDI آینده انجام گیرد. در پژوهش حاضر، بارش و تبخیر و تعرق پتانسیل با استفاده از ترکیب‌های اشاره شده قبلی، ۱۱ تا ۳۰ لایه پنهان و ۱ تا ۲۴ ماه تأخیر، برای دوره ۲۰۰۶ تا ۲۰۱۸ پیش‌بینی شدند. گام زمانی پیش‌بینی در این مرحله مانند پیش‌بینی بلندمدت خشکسالی ۱۵۶ در نظر گرفته شد. بنابراین فقط داده‌های بارش و تبخیر و تعرق پتانسیل در دوره ۱۹۶۱ تا ۲۰۰۵ در اختیار مدل قرار گرفت.


#### پیش‌بینی بلندمدت خشکسالی با استفاده از مدل شبکه عصبی NAR

برای پیش‌بینی بلندمدت خشکسالی، مقادیر RDI دوره ۱۹۶۱ تا ۲۰۱۸ محاسبه گردید. سپس داده‌های حاصل از محاسبه شاخص RDI در دوره ۱۹۶۱ تا ۲۰۰۵ برای آموزش، ارزیابی و تست وارد مدل NAR شد. با توجه به طول دوره پیش‌بینی، ۲۰۰۶ تا ۲۰۱۸ برابر ۱۵۶ ماه، تعداد گام زمانی پیش‌بینی ۱۵۶ در نظر گرفته شد. بنابراین در این بخش مقادیر RDI در دوره ۲۰۰۶ تا ۲۰۱۸ در اختیار مدل قرار نگرفت.

مدل NAR با ۱۵۶ گام پیش‌بینی برای پیش‌بینی RDI یک ماهه در دوره ۲۰۰۶ تا ۲۰۱۸ برای ترکیب‌های مختلف مورد بررسی قرار گرفت. بر اساس نتایج، در این حالت مدل NAR با تعداد لایه‌های پنهان ۲۱ و زمان تأخیر ۱۱ ماه دارای بیشترین مقدار کارایی با  $R^2$  برابر ۰/۴۴۲ است. مقایسه مقادیر RDI مشاهده شده و RDI پیش‌بینی شده با بهره‌گیری از مدل NAR مذکور در دوره ۲۰۰۶ تا ۲۰۱۸ در شکل ۹ نمایش داده شده است. مدل مذکور مقادیر RDI در ماه‌های خشک را تا حدی بهتر از ماه‌های مرطوب پیش‌بینی کرده است. مقدار ضریب تعیین ( $R^2$ ) بین RDI سه ماهه مشاهده شده و پیش‌بینی شده توسط مدل شبکه عصبی NAR با ترکیب زمان‌های تأخیر ۱ تا ۲۴ ماه و تعداد لایه‌های پنهان ۱۱ تا ۳۰ نشان می‌دهد که مدل دارای ۱۴ لایه پنهان و زمان تأخیر ۱۰ ماه دارای بیشترین مقدار همبستگی ( $R^2 = ۰/۶۵۶$ ) است. مقایسه مقادیر RDI مشاهده شده و RDI پیش‌بینی شده با استفاده از مدل شبکه عصبی مصنوعی NAR با ترکیب مذکور در مقیاس زمانی سه ماهه را در دوره ۲۰۰۶ تا ۲۰۱۸ در شکل ۱۰ ارائه شده است. مدل مذکور مقادیر RDI را در برخی ماه‌های خشک و



شکل ۹. مقایسه مقادیر RDI پیش‌بینی شده و مشاهداتی در مقیاس یک ماهه در طول دوره آماری ۲۰۰۶ تا ۲۰۱۸.



شکل ۱۰. مقایسه مقدار RDI پیش‌بینی شده و مشاهداتی در مقیاس سه ماهه در طول دوره آماری ۲۰۰۶ تا ۲۰۱۸.

جدول ۳. مقدار ضریب تعیین ( $R^2$ ) بین RDI شش ماهه مشاهده شده و پیش‌بینی شده توسط مدل شبکه عصبی NAR با زمان تأخیر

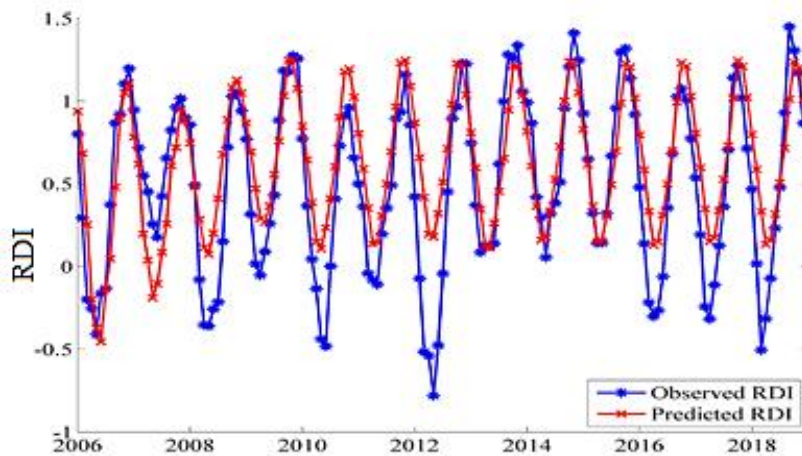
و تعداد لایه‌های متفاوت

تعداد لایه پنهان	زمان تأخیر	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲
۱۱	۰	۰/۰۰۲	۰/۱۶۹	۰/۲۶۸	۰/۷۰۶	۰/۲۷	۰/۰۰۳	۰/۳۳۲	۰/۱۷	۰/۲۶	۰/۳۱۱	۰/۲۰۲	
۱۲	۰/۰۰۱	۰	۰/۲۲۹	۰/۲۱۲	۰/۷۶۳	۰/۱۱۹	۰/۷۰۱	۰/۵۰۸	۰/۲۸۵	۰/۰۰۱	۰/۲۷۹	۰/۱۰۷	
۱۳	۰	۰/۰۰۲	۰/۰۵۵	۰	۰/۳۷۳	۰/۵۴	۰/۲۲	۰/۴۳۸	۰/۰۳	۰/۱۱۴	۰/۲۵۴	۰/۲۱۱	
۱۴	۰	۰/۰۳	۰/۱۵	۰/۲۴۸	۰/۰۶۳	۰/۰۴۳	۰	۰/۲۷۳	۰/۲۱	۰	۰/۰۱	۰	
۱۵	۰/۰۱۲	۰/۰۰۳	۰/۱۰۱	۰/۲۵۳	۰/۰۱	۰/۰۸	۰/۴۸۸	۰/۱۱۷	۰/۰۶۱	۰/۰۰۲	۰/۴۹۴	۰/۴۵۴	
۱۶	۰/۰۰۱	۰/۰۰۳	۰/۲۵۲	۰/۱۶۳	۰/۰۰۹	۰/۰۰۲	۰/۰۴۵	۰/۳۹۴	۰/۰۱۱	۰/۰۱۲	۰	۰/۴۱۵	
۱۷	۰/۰۰۱	۰/۰۰۱	۰/۲۸۶	۰/۶۷۸	۰/۱۹۹	۰/۴۳۱	۰/۴۸۱	۰	۰/۴۱	۰/۱۶۱	۰/۲۰۱	۰/۲۱۱	
۱۸	۰/۰۰۲	۰/۰۰۸	۰/۳۲۲	۰/۰۰۶	۰/۲۵۸	۰/۷۲۲	۰/۵۳۱	۰	۰/۷۲۲	۰/۰۰۶	۰/۱۵	۰/۲۸۶	۰/۵۹۱
۱۹	۰/۰۱	۰/۱۱	۰	۰/۵۱۸	۰/۰۰۲	۰/۰۰۶	۰/۵۲۷	۰/۰۰۵	۰/۰۹۸	۰/۱۶۵	۰/۲۹	۰/۱۷۷	
۲۰	۰/۰۰۱	۰/۰۰۱	۰/۱۵۲	۰/۱۰۷	۰/۷۳۱	۰/۰۲۷	۰/۱۸۲	۰/۰۱۲	۰	۰/۰۱۲	۰	۰/۲۶	
۲۱	۰/۰۲۱	۰	۰/۰۳۶	۰/۲۱۱	۰/۰۲۳	۰/۵۰۹	۰/۱۴۴	۰/۰۸۹	۰/۱۶۶	۰/۰۸۳	۰/۳۷۱	۰/۰۰۳	
۲۲	۰/۰۱۱	۰/۰۰۹	۰/۰۹۲	۰/۰۲۱	۰/۷۱	۰/۲۰۸	۰/۳۰۲	۰/۵۹۹	۰/۱۶۲	۰/۰۰۴	۰/۴۳۲	۰/۱۷۱	
۲۳	۰/۰۰۸	۰/۲۳۲	۰	۰/۴۳	۰/۲۹۵	۰/۵۱۸	۰/۶۲۸	۰/۱۱۳	۰/۰۷	۰/۳۱۷	۰/۰۰۳	۰/۰۷۴	
۲۴	۰/۰۰۸	۰	۰/۱۸۸	۰/۴۳	۰/۶۶۸	۰/۲۸	۰/۳۸	۰/۰۲۴	۰/۰۰۴	۰/۰۰۱	۰/۵۲۳	۰/۵۸۱	
۲۵	۰/۰۰۶	۰/۰۰۲	۰/۳۲۷	۰/۰۰۸	۰/۰۸۲	۰/۵۴۹	۰/۱۰۴	۰/۰۱۵	۰/۰۲۱	۰/۰۹۲	۰/۰۷۸		
۲۶	۰/۰۲	۰/۰۲۱	۰/۳۸	۰	۰/۲۵۱	۰/۰۱	۰/۷۰۵	۰/۰۳۷	۰/۱۶	۰/۱۳۲	۰/۱۸	۰/۱۳۳	
۲۷	۰/۰۱	۰/۰۰۵	۰/۰۰۸	۰/۱۶۵	۰/۲۱۵	۰/۲۰۴	۰/۴۴	۰/۲۲	۰/۰۰۷	۰	۰/۰۲۷	۰/۳۹۷	
۲۸	۰/۰۰۱	۰/۰۰۱	۰/۱۰۷	۰/۱۰۲	۰/۰۱	۰/۵۶	۰/۶۶۶	۰/۰۰۵	۰/۰۰۱	۰/۰۴۴	۰	۰/۴۲۴	
۲۹	۰/۰۲۵	۰/۰۰۵	۰/۴۴۷	۰/۲۳۵	۰/۰۱۹	۰/۰۱۵	۰/۴۹۲	۰/۲۲۵	۰/۱۴۱	۰/۰۰۳	۰/۰۰۸	۰/۵۷	
۳۰	۰	۰	۰/۰۸۲	۰/۰۰۳	۰/۰۷۳	۰/۴۱۳	۰/۴۱۴	۰/۴۱۴	۰	۰/۱۷۶	۰/۳۰۳	۰/۵۳۲	

ادامه جدول ۳. مقدار ضریب تعیین ( $R^2$ ) بین RDI شش ماهه مشاهده شده و پیش‌بینی شده توسط مدل شبکه عصبی NAR با زمان

تأخیر و تعداد لایه‌های متفاوت

تعداد لایه پنهان	زمان تأخیر	۱۳	۱۴	۱۵	۱۶	۱۷	۱۸	۱۹	۲۰	۲۱	۲۲	۲۳	۲۴
۱۱	۰/۰۰۲	۰/۲۸۷	۰/۱۸۲	۰/۴۳۷	۰/۰۶	۰/۰۹۲	۰/۰۴۵	۰/۰۳	۰/۰۷۱	۰/۰۳۳	۰/۰۴۸		
۱۲	۰/۳۲۶	۰/۱۳۶	۰/۰۷	۰/۰۷	۰/۰۰۷	۰/۶۹۴	۰/۰۲۹	۰/۵۹۴	۰/۰۲۲	۰/۰۳۳	۰/۱۱۹	۰/۰۰۱	۰/۰۱۲
۱۳	۰/۱۳۴	۰	۰/۰۲۴	۰/۰۰۷	۰/۲۷	۰/۶۰۵	۰/۴۳۱	۰/۱۴۷	۰/۱۰۶	۰/۱۳۲	۰/۰۴۵	۰/۱۳۶	
۱۴	۰/۲۷۳	۰/۰۲۱	۰/۰۱۴	۰/۱۵۹	۰/۴۸۲	۰/۳۵۵	۰/۲۷۸	۰/۰۰۲	۰/۰۲۳	۰/۵۱۷	۰/۱۵۲	۰/۴۶۹	
۱۵	۰/۱۴۳	۰/۲۲۲	۰/۰۳۷	۰/۱۶۵	۰/۰۷۱	۰/۱۱	۰/۳۷۸	۰/۱۴۵	۰/۰۳۲	۰/۱۱۹	۰/۱۰۸	۰/۰۶۴	
۱۶	۰/۳۱۵	۰/۴۷۵	۰/۳۵۱	۰/۴۸۷	۰/۰۱	۰/۵۵۵	۰/۰۰۱	۰/۱۴۸	۰/۰۱۱	۰/۰۰۵	۰/۰۰۳	۰/۴۹	
۱۷	۰/۰۵۹	۰/۰۷۳	۰	۰/۴۳۱	۰/۵۱۲	۰/۶۶۷	۰/۶۵۱	۰/۰۰۳	۰/۳۰۷	۰/۲۱۳	۰	۰/۰۰۱	
۱۸	۰/۰۸۲	۰	۰/۱۴	۰/۰۱۹	۰/۰۰۶	۰/۰۴۵	۰/۶۲۸	۰/۰۱۱	۰/۱۱۵	۰/۶۳۹	۰/۱۹	۰/۰۰۷	
۱۹	۰/۳۴۹	۰/۲۳۱	۰	۰/۱۹۷	۰/۳۹۶	۰/۱۵۳	۰/۲۶۸	۰/۰۰۲	۰	۰/۰۷۳	۰	۰/۰۰۸	
۲۰	۰/۰۹۲	۰/۱۳۵	۰/۰۰۸	۰/۰۹۲	۰/۰۴۲	۰/۲۵۸	۰/۰۴۳	۰/۱۹۷	۰/۰۲۶	۰/۴۸۸	۰/۰۰۶	۰/۰۰۷	
۲۱	۰/۰۳۸	۰/۰۶۹	۰/۲۸۷	۰/۳۰۴	۰/۰۰۲	۰/۱۷۱	۰/۰۰۱	۰/۰۰۱	۰/۴۴۵	۰	۰/۰۰۲	۰/۰۱۲	
۲۲	۰/۰۰۳	۰	۰/۱۸۸	۰/۱۵۱	۰/۷۱۹	۰/۰۲۳	۰/۰۳۸	۰/۰۲۱	۰/۳۷۳	۰/۰۱۶	۰/۰۱۸	۰/۰۰۹	
۲۳	۰/۲۷۳	۰/۱۵۲	۰/۳۶۳	۰/۳۵۶	۰/۲۶۱	۰/۲۹۶	۰/۱۴۱	۰/۱۹۳	۰/۰۰۱	۰/۰۰۱	۰/۰۰۳	۰/۰۱	
۲۴	۰/۶۲۶	۰/۴۶۹	۰/۰۶۱	۰/۳۱۵	۰/۰۰۱	۰/۵۵۲	۰/۰۹	۰	۰/۰۰۵	۰/۰۰۴	۰/۵۱۵	۰	
۲۵	۰/۱۳۵	۰/۰۱۶	۰/۰۵۲	۰/۱۱	۰/۳۵۷	۰	۰/۲۶۹	۰/۰۲۳	۰/۰۲۴	۰/۱۴۳	۰/۰۱۴	۰/۳۹۹	
۲۶	۰	۰/۰۱۲	۰/۰۱	۰/۱۳۴	۰/۶۴	۰/۳۰۷	۰	۰/۰۰۹	۰/۰۳۱	۰/۳۵۶	۰/۰۰۲	۰/۰۲۸	
۲۷	۰/۰۴۶	۰/۰۴۶	۰/۰۰۵	۰/۰۰۳	۰/۳۳۳	۰/۰۰۶	۰/۱۱۱	۰/۱۴	۰/۰۱۴	۰/۰۰۳	۰	۰/۰۱۵	
۲۸	۰/۰۰۲	۰/۰۰۲	۰/۱۱۶	۰/۱۴۹	۰/۵۰۱	۰/۰۱	۰/۰۳۵	۰	۰/۰۲۵	۰	۰/۰۰۶	۰/۰۰۴	
۲۹	۰/۱۶۲	۰/۰۸	۰	۰/۲۳۷	۰/۰۲۲	۰/۴۸۷	۰/۲۹۸	۰/۰۱۸	۰	۰/۰۰۲	۰/۰۱۸	۰/۰۱	
۳۰	۰/۰۴۶	۰/۱۴۹	۰/۰۱۴	۰/۵۷۳	۰/۰۱۱	۰/۵۸۶	۰/۰۲۶	۰/۰۸۹	۰/۰۰۳	۰/۰۳۷	۰	۰/۰۰۲	



شکل ۱۱. مقایسه مقدار RDI پیش‌بینی شده و مشاهداتی در مقیاس شش ماهه در طول دوره آماری ۲۰۰۶ تا ۲۰۱۸

جدول ۴. مقایسه ضریب تعیین  $R^2$  بین RDI پیش‌بینی شده و خشکسالی‌های مشاهداتی در مقیاس‌های یک ماهه،

سه ماهه و شش ماهه

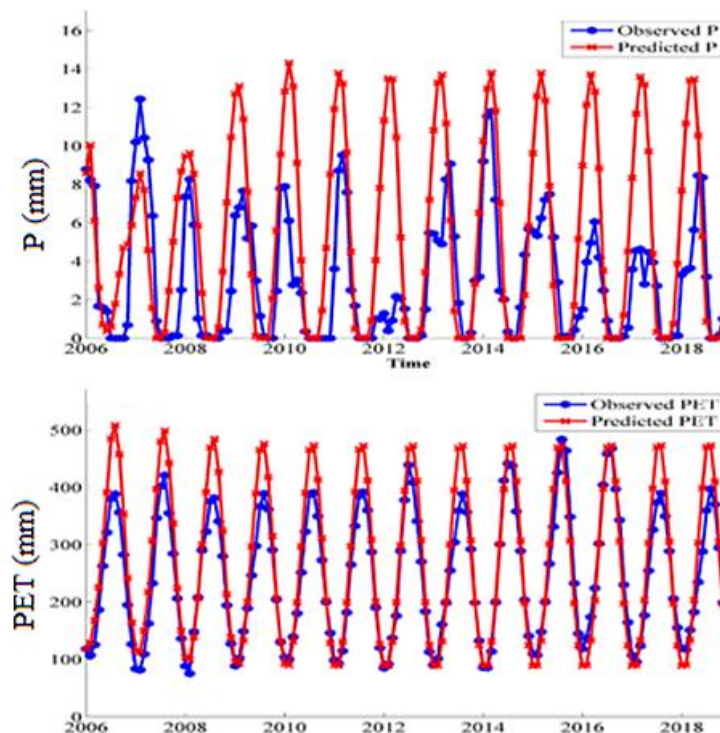
مقیاس زمانی	ضریب تعیین ( $R^2$ )
RDI یک ماهه	۰/۴۴۲
RDI سه ماهه	۰/۶۵۶
RDI شش ماهه	۰/۷۱۹

دوره ۲۰۰۶ تا ۲۰۱۸ با هم مقایسه شده‌اند (شکل ۱۲). RDI محاسبه شده بر پایه بارش و تبخیر و تعرق پتانسیل پیش‌بینی شده در مقیاس‌های یک، سه و شش ماهه به ترتیب در اشکال (۱۳) تا (۱۵) با مقادیر واقعی مقایسه شده‌اند. بر اساس نتایج، مقادیر RDI پیش‌بینی شده در ماه‌های خشک با دقت مناسبتری نسبت به ماه‌های مرطوب پیش‌بینی شده است. در مقیاس سه ماهه نیز ماه‌های خشک با دقت قابل قبول تری پیش‌بینی شده‌اند. در مقیاس شش ماهه در ماه‌های خشک و مرطوب مقدار RDI به طور نسبتاً مناسبی پیش‌بینی شده‌اند.

در پایان کارایی ترکیب‌های مختلف مدل برای پیش‌بینی بلندمدت بارش و تبخیر و تعرق پتانسیل در مقیاس‌های زمانی یک، سه و شش ماهه مورد بررسی قرار گرفت. مقدار  $R^2$  و ساختار مدل با بیشترین کارایی در مقیاس‌های زمانی مختلف برای بارش و تبخیر و تعرق پتانسیل محاسبه شد (جدول ۵). کارایی مدل‌ها در پیش‌بینی تبخیر و تعرق پتانسیل در تمام مقیاس‌های زمانی به طور قابل توجهی از بارش بیشتر بود. با توجه به پراکنش زمانی بسیار نامنظم بارش در مناطق خشک، وقوع این امر قابل انتظار است. برای نمونه، مقدار پیش‌بینی شده و واقعی بارش و تبخیر و تعرق پتانسیل در مقیاس زمانی سه ماهه در


جدول ۵. مقایسه ضریب تعیین ( $R^2$ ) بین بارش و تبخیر و تعرق پتانسیل با مقدار مشاهداتی در مقیاس‌های یک ماهه، سه ماهه و شش ماهه در دوره ۲۰۰۶ تا ۲۰۱۸

PET			P			پارامتر
تعداد لایه پنهان	$R^2$	زمان تأخیر (ماه)	تعداد لایه پنهان	$R^2$	زمان تأخیر (ماه)	مقیاس زمانی
۱۹	۰/۹۲۲	۷	۲۹	۰/۲۹۶	۱۲	یک ماهه
۱۱	۰/۹۴۲	۱۴	۲۶	۰/۴۴۹	۱۰	سه ماهه
۲۷	۰/۹۰۵	۹	۱۳	۰/۵۷۲	۷	شش ماهه




شکل ۱۲. مقایسه بارش و تبخیر و تعرق پتانسیل پیش‌بینی شده با مقدار واقعی در دوره ۲۰۰۶ تا ۲۰۱۸






شکل ۱۳. مقایسه مقدار RDI محاسبه شده بر پایه بارش و تبخیر و تعرق پتانسیل پیش‌بینی شده و مشاهداتی در مقیاس یک ماهه در طول دوره آماری ۲۰۰۶ تا ۲۰۱۸



شکل ۱۴. مقایسه مقدار RDI محاسبه شده بر پایه بارش و تبخیر و تعرق پتانسیل پیش‌بینی شده و مشاهداتی در مقیاس سه ماهه در طول دوره آماری ۲۰۰۶ تا ۲۰۱۸



شکل ۱۵. مقایسه مقادیر RDI محاسبه شده بر اساس بارش و تبخیر و تعرق پتانسیل پیش‌بینی شده با مشاهداتی در مقیاس شش ماهه در طول دوره آماری ۲۰۰۶ تا ۲۰۱۸

برای پیش‌بینی بلندمدت خشکسالی، مدل با پیش‌بینی ۱۵۶ گام زمانی پیش رو (۲۰۰۶ تا ۲۰۱۸ که برابر ۱۳ سال است) اجرا گردید. بنابراین این حالت بدون دسترسی مدل به داده‌های واقعی خشکسالی دوره ۲۰۰۶ تا ۲۰۱۸ انجام شد. نتایج نشان داد مقادیر RDI در ماه‌های خشک در مقیاس سه ماهه، تطابق بهتری با مقادیر واقعی نسبت به دیگر مقیاس‌های زمانی دارد.

در پژوهش حاضر همچنین مقادیر بلند مدت RDI به طور غیرمستقیم از طریق پیش‌بینی بلندمدت مقادیر بارش و تبخیر و تعرق پتانسیل پیش‌بینی گردید. در این مورد نیز مدل به داده‌های واقعی بارش و تبخیر و تعرق پتانسیل در دوره ۲۰۰۶ تا ۲۰۱۸ دسترسی نداشت. مقادیر RDI بر اساس داده‌های بارش و تبخیر و تعرق پیش‌بینی شده، محاسبه شد. نتایج نشان داد دقت پیش‌بینی در مقایسه با پیش‌بینی مستقیم RDI در مقیاس یک و سه ماهه بهبود یافته است. در مقیاس شش ماهه، دقت مدل در حالت پیش‌بینی مستقیم و غیرمستقیم تقریباً یکسان است، اما در حالت غیر مستقیم داده‌های RDI در ماه‌های خشک با دقت بالاتری پیش‌بینی شده‌اند.

با توجه به نتایج ذکر شده، مدل NAR کارایی لازم برای پیش‌بینی خشکسالی در مناطق خشک را دارا می‌باشد. بنابراین توجه به کارایی نسبتاً مناسب مدل NAR، پیشنهاد می‌گردد کارایی مدل  $NARX^1$  که با ساختار غیرخطی علاوه بر داده‌های هدف، از داده‌های کمکی نیز بهره‌گیری می‌کند، مورد آزمون قرارگیرد. همچنین پیشنهاد می‌شود کارایی مدل NAR با دیگر مدل‌های پیش‌بینی مانند مدل‌های جهانی اقلیم و مدل‌های سری زمانی در پیش‌بینی خشکسالی در مناطق خشک مقایسه شود.

با توجه به ضریب تعیین ( $R^2$ ) بین مقادیر واقعی و محاسبه‌شده RDI بر پایه بارش و تبخیر و تعرق پتانسیل پیش‌بینی شده (جدول ۶)، تطابق مقادیر پیش‌بینی شده و واقعی در مقیاس یک و سه ماهه نسبت به پیش‌بینی مستقیم مقادیر RDI (جدول ۴) اندکی افزایش یافته است. در مقیاس شش ماهه مقادیر  $R^2$  در هر دو حالت تقریباً با هم برابر است. مقایسه اشکال (۹) تا (۱۱) با اشکال (۱۳) تا (۱۵) نشان می‌دهد پیش‌بینی RDI به طور غیرمستقیم بر اساس محاسبه RDI بر اساس بارش و تبخیر و تعرق پتانسیل پیش‌بینی شده، مقادیر RDI در ماه‌های خشک را نسبتاً با دقت بیشتری نسبت به روش پیش‌بینی مستقیم RDI، پیش‌بینی می‌کند.

#### نتیجه‌گیری

در بررسی حاضر، تبخیر و تعرق پتانسیل ماهانه ایستگاه همدیدی یزد در دوره ۱۹۶۱ تا ۲۰۱۸ با بهره‌گیری از مدل فائو-پنمن-مانتیت محاسبه شد. سپس مقدار یک، سه و شش ماهه RDI در دوره فوق محاسبه شد. در پژوهش حاضر از مدل شبکه مصنوعی NAR برای پیش‌بینی کوتاه‌مدت و بلندمدت خشکسالی ایستگاه یزد در دوره ۲۰۰۶ تا ۲۰۱۸ استفاده شد. برای آموزش شبکه از الگوریتم آموزش GDX استفاده گردید. در مرحله بعد مقادیر پیش‌بینی شده با مقادیر واقعی مقایسه شدند. در پیش‌بینی کوتاه مدت، مدل NAR فقط یک گام زمانی پیش‌رو را پیش‌بینی می‌کند. بنابراین داده‌های واقعی دوره پیش‌بینی در اختیار مدل قرار گرفت. نتایج پیش‌بینی کوتاه‌مدت خشکسالی نشان داد مدل کارایی قابل قبولی در پیش‌بینی مقادیر RDI سه و شش ماهه دارد.

جدول ۶. مقایسه ضریب تعیین  $R^2$  بین RDI محاسبه شده بر پایه بارش و تبخیر و تعرق پتانسیل پیش‌بینی شده با مشاهداتی در

مقیاس‌های یک ماهه، سه ماهه و شش ماهه در دوره ۲۰۰۶ تا ۲۰۱۸

ضریب تعیین ( $R^2$ )	مقیاس زمانی
۰/۴۶۹	RDI یک ماهه
۰/۶۶۴	RDI سه ماهه
۰/۷۱۶	RDI شش ماهه

<sup>1</sup> Nonlinear autoregressive network with exogenous inputs

## ■ References

1. Allen, R.G., Pereira, L.S., Raes, D., & Smith, M. (1998). Crop evapotranspiration. fao irrigation and drainage paper 56, *Food and Agriculture Organization*, Rome.
2. Alsumaiei, A.A., & Alrashidi, M.S., (2020). Hydrometeorological drought forecasting in hyper-arid climates using nonlinear autoregressive neural networks. *Water*, 12(9), 2611.
3. Asadi, M., (2019). Potential evapotranspiration prediction using nonlinear autoregressive model with exogenous input (NARX) (case study, Yazd Province, Iran). *Aridbiome*, 8(2), 37-49. (in Farsi)
4. Asadi, M.A., Jamnezhad, F., Ekhtesasi, M.R., & Hosseini, S.Z. (2020). Investigating the effects of drought and land-use changes on quantity and quality of groundwater resources: a case study of Darab plain. *Desert Ecosystem Engineering Journal*, 9(28), 89-102. (in Farsi)
5. Asadi Zarch, M.A., (2017). Analyzing climate change effects on drought occurrence in Yazd province, Iran. *Desert Management*, 5(9), 74-90 (in Farsi).
6. Asadi Zarch, M.A., Sivakumar, B. Sharma, A. (2015). Droughts in a warming climate: A global assessment of standardized precipitation index (SPI) and reconnaissance drought index (RDI). *Hydrology*, 526, 183–195.
7. Bates, B.C., Kundzewicz, Z.W., Wu, S., Palutikof, J.P. (2008). Climate change and water. Intergovernmental Panel on Climate Change, Geneva.
8. Blanchard. T., Samanta, B., (2020). Wind speed forecasting using neural networks. *Wind Engineering*, 44(1), 33–48.
9. Cheng H., Tan PN., Gao J., Scripps J. (2006). Multistep-ahead time series prediction. In: Ng WK., Kitsuregawa M., Li J., Chang K. (eds) *Advances in Knowledge Discovery and Data Mining. PAKDD 2006. Lecture Notes in Computer Science*, vol 3918. Springer, Berlin, Heidelberg.
10. Dai, A. (2011). Drought under global warming: a review. *WIREs Climate Change*, 2(1), 45-65.
11. Djerbouai, S., & Souag-Gamane, D. (2016). Drought Forecasting Using Neural Networks, Wavelet Neural Networks, and Stochastic Models: Case of the Algerois Basin in North Algeria. *Water Resources Management*, 30, 2445–2464.
12. Dong, G., Fataliyev, K., Wang, L., (2013). *One-step and multi-step ahead stock prediction using backpropagation neural networks*. 9th International Conference on Information, Communications & Signal Processing, pp. 1-5.
13. Eivazi, M., Mosaedi, A., Dehghani, A.A., (2012). Comparison of different approaches for predicting SPI. *Water and Soil Conservation*, 16(2), 145-167 (in Farsi).
14. Katko, T.S., Hukka, J.J. (2015). Social and economic importance of water services in the built Environment: Need for more structured thinking. *Procedia Economics and Finance*, 21, 217-223.
15. Kirbas, I. (2018). *NAR based forecasting interface for time series analysis: T-seer*. IV International Conference on Engineering and Natural Science (ICENS), 144-149.
16. Lindsay, J., Dean, A.J., Supski, S. (2017). Responding to the millennium drought: comparing domestic water cultures in three Australian cities. *Regional Environmental Change*, 17(2), 565–577.
17. Mahmoudi, P., Rigi, A., Miri Kamak, M.A (2019). Comparative study of precipitation-based drought indices with the aim of selecting the best index for drought monitoring in Iran. *Theoretical and Applied Climatology*, 137(3-4), 3123–3138.

18. Mokhtarzad, M., Eskandari, F., Jamshidi Vanjani, N. et al. (2017). Drought forecasting by ANN, ANFIS, and SVM and comparison of the models. *Environmental Earth Sciences*, 76, 729 (2017).
19. Nguyen, V., Li, Q., Nguyen, L., (2017). Drought forecasting using ANFIS- a case study in drought prone area of Vietnam. *Paddy Water Environ*, 15, 605–616.
20. Noorisameleh, Z., Khaledi, S.H., Shakiba, A., Zeaiean Firouzabadi, P., Gough, W.A., Mirza, M.M.Q. (2020). Comparative evaluation of impacts of climate change and droughts on river flow vulnerability in Iran. *Water Science and Engineering*, 13(4), 265-27.
21. Pachauri, R.K., et al. (2014). Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change.
22. Rehana, S., Sireesha Naidu, G. (2021). Development of hydro-meteorological drought index under climate change Semi-arid river basin of Peninsular India. *Hydrology*, 594, 125973.
23. Shilenje, Z.W., Ongoma, V., Njagi, M. (2019). Applicability of combined drought index in drought analysis over north eastern Kenya. *Natural Hazards*, 99, 379–389.
24. Singh, R.M., Shukla, P. (2020). Drought characterization using drought indices and El Nino effects. *National Academy Science Letters*, 43, 339–342.
25. Surendran, U., Kumar, V., Ramasubramoniam, S. et al. (2017). Development of drought indices for semi-arid region using drought indices calculator (DrinC) – a case study from madurai district, a semi-arid region in India. *Water Resources Management*, 31, 3593–3605.
26. Tsakiris, G., Nalbantis, I., Pangalou, D., Tigkas, D., Vangelis, H. (2008). *Drought meteorological monitoring network design for the Reconnaissance Drought Index (RDI)*. 1st International Conference Drought Management: Scientific and Technological Innovations. Zaragoza, Spain. 12–14 June 2008. pp. 57–62.
27. Tsakiris G, Vangelis H (2005) Establishing a drought index incorporating evapotranspiration. *European Water*, 9/10, 3–11.
28. Van Loon, A.F, Van Lanen, H.A.J. (2013). Making the distinction between water scarcity and drought using an observation-modeling framework. *Water Resources Research*, 49, 1483–1502.
29. Vidyarthi, V.K., Jain, A. (2020). Knowledge extraction from trained ANN drought classification model. *Hydrology*, 585, 124804.
30. Wei, W., Zhang, J., Zhou, L. et al. (2021). Comparative evaluation of drought indices for monitoring drought based on remote sensing data. *Environmental Science and Pollution Research*, 28, 20408–20425.