



Modelling Ungauged Basins Using Remote Sensing (RS) Data and Artificial Neural Networks (ANNs) (Case Study: Ardabil Plain Basin)

A. Akbari Majd¹, J. Azizi Mobasr^{2*}, A. Rasulzadeh³,
and M. Hasanpour Kashani⁴

Abstract

Although rainfall-runoff modelling is not considered a big challenge recently, it is still one of the challenging issues for researchers in the basin or sub-basins without statistical data. One of the new methods in this field is the use of remote sensing techniques and the use of machine learning (artificial intelligence). In this research, to calculate the runoff in the basins without data, two basins were used including the basins for the Samian and the Amoghein hydrometric stations in Ardabil plain. The first station was chosen as the outlet of the Ardabil Plain basin for model training and calibration and the second station was used as the basin without data for verification and testing. Modelling was done using 9 input parameters including air pressure, vegetation cover index (low and high cover), soil temperature, ground surface temperature, soil water volume, runoff, evaporation potential and precipitation. Also, a parameter related to the observational data of the stations was used as an output. Modelling was done using four models of NARX, ANN-ACO, ANN-GA, ANN-PSO and the accuracy of the models were evaluated using MSE, R2, RMSE, NSE and MAE. The results showed that the NARX model is clearly superior to other models with an accuracy of 0.001, 0.86, 0.039, 0.855 and 0.015 respective to the above-mentioned measures. Remote sensing methods combined with artificial intelligence can respond to hydrologists' challenges in data-scarce and ungauged basins around the world due to their ability to provide high-precision results.

Keywords: GIS, RS, NARX, ANN, Ungauged Basins, Runoff Precipitation Curve.

Received: August 7, 2023

Accepted: October 31, 2023

مدل سازی رواناب در حوضه های فاقد آمار با استفاده از داده های سنجش از دور (RS) و شبکه های عصبی مصنوعی (ANNs) (مطالعه موردی: حوضه دشت اردبیل)

امین اکبری مجد^۱، جوانشیر عزیزی مبصر^{۲*}، علی رسولزاده^۳
و مهسا حسینیور کاشانی^۴

چکیده

اگرچه اخیراً مدل سازی بارش-رواناب چالش بزرگی به حساب نمی آید، اما این مورد همچنان در حوضه و یا زیرحوضه های فاقد آمار یکی از مسایل چالش برانگیز برای محققان این حوزه است. یکی از روش های نوین در این زمینه استفاده از تکنیک های سنجش از دور و استفاده از یادگیری ماشین (هوش مصنوعی) بوده است. در این تحقیق برای محاسبه رواناب در حوضه های فاقد آمار، از دو حوضه شامل حوضه ایستگاه هیدرومتری سامیان و حوضه ایستگاه هیدرومتری عموقین در دشت اردبیل استفاده شد. ایستگاه اول به عنوان خروجی حوضه دشت اردبیل و برای آموزش و واسنجی مدل و از ایستگاه دوم به عنوان حوضه فاقد آمار برای صحت سنجی و آزمون، انتخاب شدند. مدل سازی با استفاده از ۹ پارامتر ورودی شامل فشار هوا، شاخص پوشش گیاهی (پوشش کم و زیاد)، دمای خاک، دمای سطح زمین، حجم آب خاک، رواناب، پتانسیل تبخیر و بارش انجام شد. همچنین، از یک پارامتر مربوط به آمار مشاهداتی ایستگاه ها، به عنوان خروجی استفاده شد. مدل سازی با استفاده از چهار مدل شامل NARX، ANN-ACO، ANN-GA، ANN-PSO انجام و برای ارزیابی دقت مدل ها از آماره های MSE، R²، RMSE، NSE و MAE استفاده شد. نتایج نشان دادند که مدل NARX به ترتیب با دقت ۰/۰۰۱، ۰/۸۶، ۰/۰۳۹، ۰/۸۵۵ و ۰/۰۱۵ به وضوح نسبت به سایر مدل ها از برتری بسیار خوبی برخوردار است. با توجه به امکان دستیابی به نتایجی با دقت بالا و با توجه به وجود حوضه های کم آمار و فاقد آمار در سرتاسر جهان، استفاده از روش های سنجش از دور در ترکیب با هوش مصنوعی می تواند بخشی از چالش های هیدرولوژیست ها را پاسخ دهد.

کلمات کلیدی: GIS، NARX، حوضه های فاقد آمار، سنجش از دور، شبکه عصبی مصنوعی، منحنی بارش رواناب.

تاریخ دریافت مقاله: ۱۴۰۲/۵/۱۶

تاریخ پذیرش مقاله: ۱۴۰۲/۸/۹

1- Master's Student of Water Resources, Department of Water Science and Engineering, University of Mohaghegh Ardabili, Ardabil, Iran. Email: amin.a.m.ce@gmail.com

2- Associate Professor, Department of Water Science and Engineering, Range & Watershed Management, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil, Iran. Email: ja.mobaser22@gmail.com

3- Professor, Department of Water Science and Engineering, Range & Watershed Management, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil, Iran.

4- Assistant Professor, Department of Water Science and Engineering, Range & watershed Management, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil, Iran.

*- Corresponding author

Doi: [10.22034/IWRR.2023.182141](https://doi.org/10.22034/IWRR.2023.182141)

۱- دانشجوی کارشناسی ارشد منابع آب، گروه علوم و مهندسی آب دانشگاه محقق اردبیلی، اردبیل، ایران.

۲- دانشیار گروه مهندسی آب دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران.

۳- استاد گروه مهندسی آب دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران.

۴- استادیار گروه مهندسی آب دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران.

*- نویسنده مسئول
بحث و مناظره (Discussion) در مورد این مقاله تا پایان بهار ۱۴۰۳ امکانپذیر است.



رویکرد گام به گام را برای تنظیم مدل‌های رودخانه برای حوضه‌های بزرگ رودخانه‌ای، بدون نیاز به داده‌های اندازه‌گیری را در سراسر جهان ارائه دهند (Maswood et al., 2016; Tarpanelli et al., 2018). آن‌ها برای تخمین دبی روزانه رودخانه پو، با ادغام داده‌های سنجش از دور و شبکه عصبی مصنوعی به این نتیجه رسیدند که تفکیک زمانی در داده‌های سنجش از دور برای به دست آوردن و تخمین دقیق دبی، از وضوح مکانی مهم‌تر است. Meresa (2019) نیز در پژوهشی به مقایسه مدل‌سازی انجام شده توسط سه روش شامل: روش شماره منحنی (مدل تجربی)، شبکه عصبی مصنوعی و مدل هیدروژیکی HEC-HMS برای استخراج منحنی فراوانی سیل در حوضه آبریز رودخانه کیسک در اتیوپی پرداخته است. او برای این کار، داده‌های مورد نیاز را از طریق سنجش از دور استخراج کرد. (He et al., 2021) با استفاده از اطلاعات سنجش از دور برای آموزش الگوریتم یادگیری عمیق استفاده کردند که در این تحقیق کارایی یک الگوریتم یادگیری ماشین با استفاده از داده‌های مشاهده‌ای، بر روی حوضه رودخانه هانجیانگ در چین به عنوان مطالعه موردی ارزیابی شد. Guan et al. (2020) شش مدل بارندگی ساخته شده از مدل‌های ماهواره‌ای را که به طور گسترده مورد استفاده قرار می‌گرفتند را در مقابل داده‌های مشاهداتی اداره هواشناسی چین ارزیابی کردند و تأثیر آن‌ها را بر روی چهار مدل مختلف هیدروژیکی که در بالادست حوضه فوقانی رودخانه زرد در چین واقع شده بود را بررسی کردند. در مطالعه‌ای دیگر Huang et al. (2020) نشان دادند که پتانسیل زیادی در استفاده از داده‌های سنجش از دور تصحیح شده برای کالیبره کردن مدل‌های هیدروژیکی (بدون نیاز به داده‌های اندازه‌گیری جریان) برای تخمین سری‌های زمانی رواناب روزانه و ماهانه در حوضه‌های اندازه‌گیری نشده و مناطق با اندازه‌گیری کم وجود دارد. (Xue et al., 2022) نیز با استفاده از داده‌های شاخص تفاوت نرمال شده پوشش گیاهی (NDVI)^۱ دریافت شده از سامانه MOD13A2، بارش دریافت شده از سامانه TRMM3B43، دمای سطح زمین دریافت شده از سامانه MOD11A2، تبخیر و تعرق دریافت شده از سامانه MOD16A2 و داده‌های ایستگاه هیدروژیکی را به عنوان داده‌های ورودی برای برآورد رواناب ماهانه در بالادست حوضه رودخانه هیه در چین از سال ۲۰۰۱ تا ۲۰۱۶ استفاده کردند. (Tiwari et al., 2022) در مطالعه‌ای استفاده از شبکه‌های مختلف مدل NARX^۲ جهت برآورد رواناب در حوضه‌های فاقد آمار را پیشنهاد دادند. در این تحقیق از داده‌های مشاهداتی بر روی سد کولار در هند استفاده کردند و با توجه به نتایج آماره‌های RMSE و NSE مدلی با استفاده از شبکه WGNARX^۳ بهترین کارایی را در حوضه مورد مطالعه داشت. Nogueira Filho

برآورد رواناب‌های سطحی علاوه بر اینکه در مطالعات هیدرولوژی کاربرد دارد، در طراحی مخازن و سدها جهت مدیریت منابع آب هم کاربرد دارد، و باید پیش‌بینی دقیقی از آن صورت گیرد. (Merz et al., 2004; Post, 2009). اگرچه محققین در سرتاسر جهان در مدل‌سازی بارش-رواناب به موفقیت‌های قابل قبولی دست یافته‌اند، اما همچنان پیش‌بینی یا برآورد رواناب در حوضه و یا زیرحوضه‌های فاقد ایستگاه‌های اندازه‌گیری (فاقد آمار) یکی از مسایل چالش برانگیز برای محققان این حوزه است (Nogueira Filho et al., 2022). همچنین، علاوه بر وجود یا عدم وجود ایستگاه‌های اندازه‌گیری، سنجش برخی پارامترها مانند تبخیر، نفوذ و جریان‌های زیرسطحی به خودی خود دشوار است (Kanishka et al., 2020; Wagener et al., 2004). مدل‌های مفهومی بارش-رواناب برای کاربردهای مختلفی از جمله مطالعه فرآیندهای هیدروژیکی (Bingeman et al., 2006)، تخمین رواناب و تعادل آب حوضه (Xu, 1999)، تخمین آمار متغیرهای هیدروژیکی در حوضه‌های آبریز فاقد آمار (Goswami et al., 2006; Young, 2007) و ارزیابی اثرات کاربری زمین و تغییرات آب و هوایی بر رواناب (Akhtar et al., 2008; Li et al., 2007) مورد استفاده قرار گرفته است. از آنجایی که مدل‌های مفهومی بارش - رواناب دارای پارامترهای نسبتاً کمی هستند، می‌توان آن‌ها را به راحتی برای پیش‌بینی رواناب در حوضه‌های فاقد آمار استفاده کرد (Merz et al., 2004; Oudin et al., 2008). در دهه‌های اخیر، تکنیک‌های سنجش از دور که از طریق آن کمبودهای داده‌های مشاهداتی را می‌توان جبران کرد، چشم‌انداز روشنی را برای مناطق فاقد آمار فراهم می‌کند (Shen et al., 2020). با فرض کالیبره کردن این مجموعه داده‌ها و بهره‌گیری از تکنیک‌های همسان‌سازی داده‌ها، امکان بازسازی فرآیندهای اقلیمی تاریخی به صورت سری‌زمانی‌های بلند مدت میسر می‌شود (He et al., 2021). این کار منجر به موفقیت بزرگی در مناطق کم داده شده است (Bastola et al., 2014; Guan et al., 2020).

(Bastola et al., 2012) در تحقیقی برای بررسی دو پارامتر کلیدی، شامل بارندگی و تبخیر و تعرق بالقوه به منظور شبیه‌سازی جریان در حوضه دریاچه چاد اشاره نمود که پس از شبیه‌سازی دقت مدل از طریق یک مدل هیدروژیکی تجربی مورد ارزیابی قرار دادند. همچنین، در پژوهش‌هایی دیگر مدل‌سازی پیشرفته بر روی حوضه گنگ، برهماپوترا و مغنا به منظور بهره‌گیری در حوضه‌های فاقد آمار با استفاده از سنجش از دور ماهواره‌ای، انجام شد که محققین توانستند یک

در ترکیب شبکه‌های عصبی مصنوعی با داده‌های سنجش از دور برای محاسبه رواناب، انتظار می‌رود نتایج این تحقیق دقت برآورد دبی را بر اساس مدل‌های منتخب بهبود بخشد و یک روش جایگزین مؤثر برای شبیه‌سازی و پیش‌بینی رواناب بویژه در حوضه‌های فاقد آمار باشد.

۲- مواد و روش‌ها

انجام این تحقیق در پنج بخش یا مرحله انجام شد که در بخش اول، منطقه مورد مطالعه معرفی شده، سپس بخش دوم به جمع‌آوری و داده‌های مورد نیاز اشاره دارد. در بخش سوم مدل‌های مورد استفاده برای مدل‌سازی جریان شرح داده شده است. در بخش چهارم مراحل و روش کار بیان شده و بخش پنجم معیارهای ارزیابی مورد استفاده در تحلیل مدل‌ها را تشریح کرده است. تمامی مدل‌های تحلیل شده و شرح داده شده در این تحقیق، جریان رواناب را با گام زمانی روزانه محاسبه می‌کنند.

۲-۱- منطقه مورد مطالعه

مطالعه حاضر در محدوده حوضه دشت اردبیل انجام شد. دشت اردبیل در منطقه مرکزی استان اردبیل و در شرق فلات آذربایجان و شمال غرب ایران قرار دارد و با مساحتی در حدود ۱۲۹۱ کیلومتر مربع، در محدوده مختصات $38^{\circ}00'50''$ تا $38^{\circ}31'10''$ شمالی و $48^{\circ}09'00''$ تا $48^{\circ}39'00''$ شرقی واقع شده است. این دشت که شهر اردبیل، مرکز استان، را در خود جای داده است، به سبب واقع شدن در حوضه رودخانه قره‌سو، جزئی از حوضه رودخانه‌ی مذکور محسوب می‌شود (شکل ۱)، (Amirahmadi et al., 2013; Rostamzadeh et al., 2015; Sobhani et al., 2022).

et al. (2022) در تحقیق مدل‌سازی بارش-رواناب در حوضه‌های فاقد آمار را با استفاده از شبکه LSTM^۴ بررسی کردند. در این تحقیق شبکه LSTM در برابر شبکه عصبی سنتی (FFNN)^۵ و یک مدل‌های هیدرولوژیکی در ایالت سنارا، واقع در شمال شرقی برزیل مورد بررسی قرار گرفته‌است. در این تحقیق مدل FFNN نسبت به سایر مدل‌ها کاملاً برتر بود. (Noor et al. (2017) در این تحقیق نشان دادند که مدل NARX می‌تواند با موفقیت سیل را ۲۴ ساعت قبل، بر اساس میزان بارندگی فعلی مدل‌سازی کند. (Kalra et al. (2023) در مطالعه‌ای چارچوبی را برای شبیه‌سازی بارش-رواناب در یک حوضه فاقد آمار با استفاده از سنجنده‌های بارش ماهواره‌ای توسعه داده و یک نقشه دشت سیلابی تهیه کردند. در این تحقیق برای شبیه‌سازی و مدل‌سازی فعل و انفعالات بین بارندگی، رواناب و وسعت منطقه سیلاب در منطقه مورد مطالعه پیشنهادی، از مدل‌های HEC-RAS و HEC-HMS استفاده کردند. (Mishra et al. (2022) در مطالعه‌ای در ایالت بنگال غربی هند با استفاده از سنجش از دور و GIS^۶ در تولید و ادغام نقشه‌های منطقه‌ای مختلف، به‌ویژه کاربری اراضی، پوشش و گروه خاک هیدرولوژیک برای استخراج عدد منحنی که در تخمین رواناب استفاده می‌شود، بهره بردند. در این تحقیق مشاهده شد که بین رواناب مشاهداتی و شبیه‌سازی شده همبستگی بالایی وجود دارد، که نشان‌دهنده قابلیت مدل SCS-CN برای تخمین رواناب با استفاده از سنجش از دور و GIS در حوضه‌های مختلف فاقد آمار است.

در این تحقیق دقت مدل‌های شبکه عصبی مصنوعی شامل مدل NARX و شبکه‌های عصبی مصنوعی بهینه‌شده با الگوریتم‌های فراابتکاری، با استفاده از داده‌های سنجش از دور برای شبیه‌سازی فرآیند بارش-رواناب بررسی شد. از طرفی به سبب تحقیقات بسیار کم

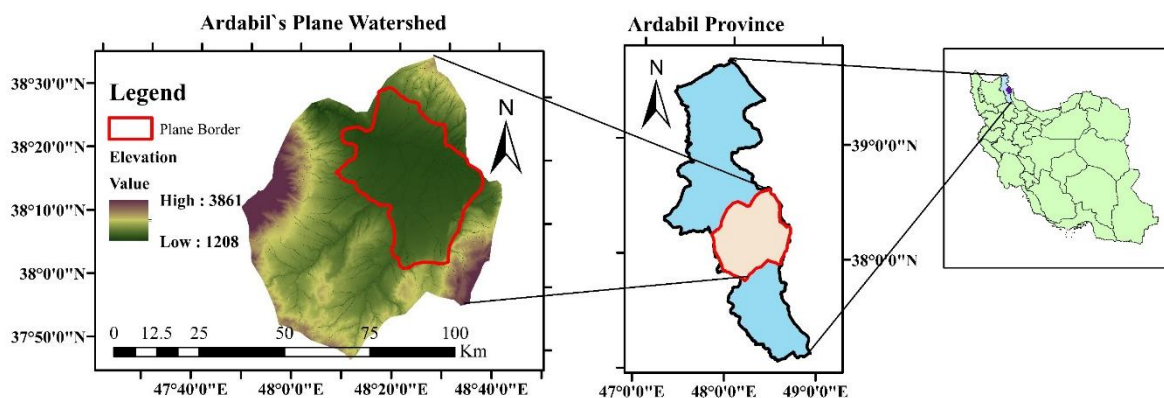


Fig. 1- Ardabil's Plane Watershed
شکل ۱- محدوده حوضه دشت اردبیل

GEE^۹ بارگذاری شد و تصاویر جمع آوری شده از سال ۱۳۸۸ تا ۱۳۹۸ در منطقه مورد مطالعه استخراج شد. سپس باندهای فشارهوا، شاخص پوشش گیاهی، دمای خاک، دمای سطح زمین، حجم آب خاک، رواناب، پتانسیل تبخیر و بارش از محصول ERA5 انتخاب شدند (جدول ۱). داده‌های روزانه به صورت سری‌زمانی و برای هر عامل برای استفاده به عنوان ورودی مدل به دست آمد.

۲-۳- مدل‌سازی

در این تحقیق، از دو ساختار متفاوت از ANN شامل، شبکه عصبی NARX به معنی یک شبکه عصبی غیرخطی خودرگرسیو با ورودی‌های خارجی و شبکه‌های عصبی بهینه شده با الگوریتم‌های فراابتکاری را استفاده شد. مدل NARX یک شبکه پویا بازگشتی با اتصالات پس‌خور است که چندین لایه از شبکه عصبی را دربر می‌گیرد، یکی از مزایای شبکه‌های NARX، قابلیت مدیریت روابط غیرخطی بین ورودی‌ها و خروجی‌ها است. آن‌ها همچنین می‌توانند برای پیش‌بینی در چند گام‌زمانی در آینده استفاده شوند، جایی که شبکه برای پیش‌بینی چندین گام‌زمانی آینده به طور همزمان آموزش داده می‌شود (Fabio et al., 2022; Lin et al., 1997; Noor et al., 2022; Shao et al., 2017). در مقابل، شبکه‌های عصبی بهینه شده با الگوریتم‌های فراابتکاری مانند GA^{۱۰}، PSO^{۱۱} و ACO^{۱۲} در واقع الگوریتم‌های بهینه‌سازی تقریبی هستند که راهکار گیرافتادن الگوریتم‌های ابتکاری در نقاط بهینه محلی رفع می‌کنند و به دلیل امکان مدیریت روابط خطی و غیرخطی بین ورودی‌ها و خروجی‌ها، قابلیت کاربرد در طیف گسترده‌ای از مسایل را دارند (Balamurugan et al., 2015; Bianchi et al., 2009).

در سطح حوضه مورد مطالعه و از بین ایستگاه‌های هیدرومتری، ایستگاه سامیان در شکل ۲-۱، به عنوان خروجی بخش عمده‌ای از حوضه برای ساخت و واسنجی مدل و ایستگاه عموقین در شکل ۲-۲، برای آزمایش و صحت‌سنجی مدل انتخاب شد.

۲-۲- اطلاعات و داده‌ها

در این تحقیق از دو سری اطلاعات استفاده شد؛ سری اول، مربوط به داده‌های مشاهداتی در ایستگاه‌های هیدرومتری منتخب بوده، که عبارت است از دبی روزانه ایستگاه و سری دوم داده‌هایی که از طریق سنجش از دور استخراج شده‌است. متغیرهای اصلی که از پایگاه‌های داده سنجش از دور با گام زمانی روزانه استخراج می‌شوند و عبارتند از: فشار هوا در سطح زمین، شاخص پوشش گیاه (کم و زیاد)، دمای تا عمق ۷ سانتی‌متری خاک، دمای ارتفاع ۲ متری سطح زمین، حجم آب موجود در خاک، رواناب، پتانسیل تبخیر و بارش. داده‌های آب و هوایی مذکور از مجموعه داده‌های محصول (ERA5-Land) استخراج شد (Muñoz Sabater et al., 2019). ERA5-Land اکثر پارامترها را با ERA5 به اشتراک می‌گذارد که با استفاده از پیشرفته‌ترین مدل‌سازی‌ها، کیفیت داده‌ها را برای مدل‌های عددی پیش‌بینی آب و هوا (NWP)^{۱۳} تضمین می‌کند (Muñoz-Sabater et al., 2021). سامانه GEE به طور گسترده برای اهداف مختلفی مانند تغییرات جنگلی، تغییرات منابع آب‌های سطحی و تخمین عملکرد محصول استفاده می‌شود (Gorelick et al., 2017). این پلت‌فرم می‌تواند به سرعت تصاویر بزرگ را در دسته‌بندی‌های دلخواه با استفاده از رابط برنامه‌نویسی جاوا اسکریپت آنلاین (API)^{۱۴} پردازش کند (Xue et al., 2022). در ادامه، داده‌های برداری برای منطقه مورد مطالعه در

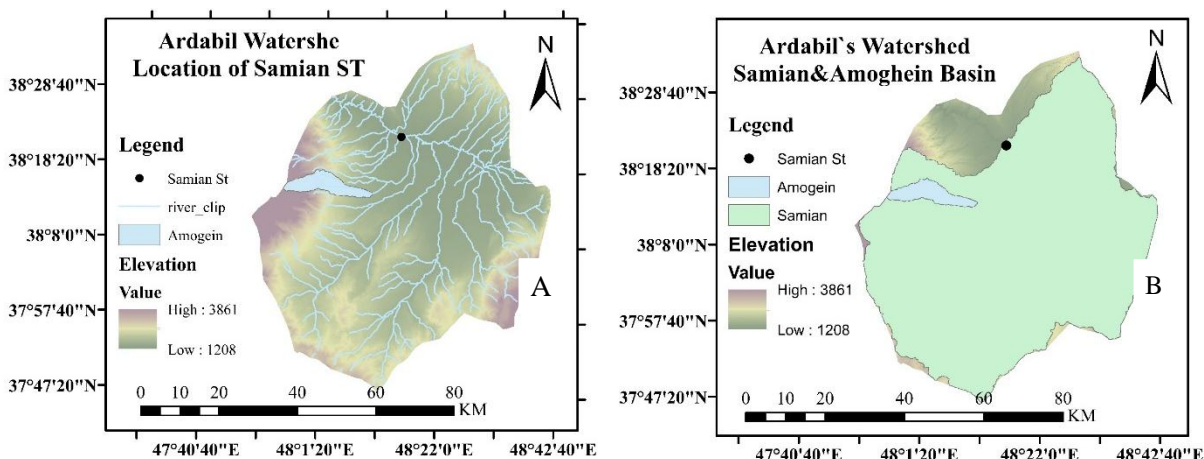


Fig. 2- Ardabil Plane Watershed (A) and Location of Stream gauges (B)
شکل ۲- حوضه دشت اردبیل (A) و موقعیت ایستگاه‌های هیدرومتری در سطح حوضه (B)

Table 1- Summary of the data products used in models

جدول ۱- لیست پارامترهای ورودی مورد استفاده در مدل‌ها

Provider	Product	Parameter Number	Parameter (Band)	Unit	Resolution (meter)	Date of data acquisition	Temporary resolution
ECMWF Climate Reanalysis	ERA5- Land Daily	1	surface pressure	Pa	11132	2009-2019	Daily
		2	Leaf area index - low vegetation	area fraction			
		3	Leaf area index - high vegetation	area fraction			
		4	Soil temperature level 1	K			
		5	Temperature 2m	K			
		6	Volumetric soil water layer 1	volume fraction			
		7	Runoff sum	m			
		8	Potential evaporation sum	m			
		9	Total precipitation sum	m			

مارکوارت (LM)^{۱۳} که به طور گسترده برای پیش‌بینی سری‌های زمانی با استفاده از شبکه‌های عصبی مصنوعی به کار برده می‌شود، بهره گرفته شد (Alsumaiei, 2020; Levenberg, 1944). دلیل عمده استفاده‌ی رایج از این الگوریتم سرعت و همگرایی پایدار آن است (Yu, H et al. (2011).

۲-۳-۲- مدل الگوریتم ژنتیک برای بهینه‌سازی شبکه عصبی مصنوعی (ANN-GA)^{۱۴}

الگوریتم‌های ژنتیک، الگوریتم‌هایی هستند که برای بازسازی اصول تکامل بیولوژیکی در سیستم ژنتیک طبیعی طراحی شده‌اند که به عنوان روش نمونه‌گیری تصادفی شناخته می‌شود. پیشنهاد استفاده از این الگوریتم اولین بار توسط (Fraser 1957a, 1957b) مطرح شد و بعدها به سبب تحقیقات (Holland (1992) الگوریتم ژنتیک به محبوبیت رسید. این الگوریتم می‌تواند به منظور شناسایی مسایل دشوار در توابع هدف که ویژگی‌های پیچیده‌ای مثل چندگونه بودن، غیردایمی بودن، غیرقابل تشخیص و غیره دارند، به کار برده شود. این الگوریتم‌ها، یک سری راه‌حل‌ها را مدیریت و دستکاری می‌کنند و جست‌وجوی خود را برای راه‌حل‌های عمده در مورد «بقای تاکتیک‌های مناسب» انجام می‌دهند (Kisi et al., 2017).

۲-۳-۳- مدل الگوریتم ازدحام ذرات برای بهینه‌سازی شبکه عصبی مصنوعی (ANN-PSO)^{۱۵}

الگوریتم PSO را می‌توان برای بهینه‌سازی مسایلی در هیدرولوژی به کار برد. این روش می‌تواند یک الگوریتم بالقوه برای آموزش ANN‌های پرسپترون چند لایه باشد (Kisi et al., 2017; Rezaei

شبکه‌های عصبی مصنوعی رابطه غیرخطی پیچیده بین بارندگی و رواناب را شناسایی می‌کنند. اکثر مدل‌ها ماهیت نالیستا دارند و در تجزیه و تحلیل مربوط به تغییرات زمانی مناسب نیستند. این وضعیت را می‌توان با استفاده از شبکه‌های عصبی پویا مانند NARX، برطرف کرد (Tiwari et al., (2022). به همین سبب در این تحقیق ابتدا مدل‌سازی توسط این مدل NARX انجام و نتیجه آن با سایر الگوریتم‌های فراابتکاری مقایسه شد.

۲-۳-۱- مدل شبکه NARX

شبکه‌های NARX یک نوع پویا و تکرار شونده از شبکه‌های عصبی مصنوعی هستند. براساس جهت جریان اطلاعات و پردازش، می‌توان شبکه‌های عصبی مصنوعی را در دسته‌های مختلف طبقه‌بندی کرد. به عنوان مثال در شبکه‌های عصبی پیش‌خور (FFNN) گره‌های حاضر در لایه‌ها، با یک جریان اطلاعات یک جهته به هم‌دیگر مرتب می‌شوند، اما در شبکه‌های تکراری، مانند NARX، اطلاعات در جهت‌های جلو و عقب جریان می‌یابند که امکان اتصال بین نرون‌ها در لایه‌های مشابه یا قبلی را فراهم می‌کند (Hydrology (2000). رابطه مدل NARX به صورت زیر می‌باشد:

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n_y), u(t-1), u(t-2), \dots, u(t-n_u)) \quad (1)$$

که در آن $u(t)$ و $y(t)$ مقادیر سری‌زمانی ورودی و خروجی هستند. n_y و n_u لایه‌های ورودی و خروجی شبکه هستند و f تابع غیرخطی برازش ساخته‌شده توسط شبکه FFNN است. مدل NARX با کد سری‌زمانی شبکه عصبی در MATLAB@2022a پیاده‌سازی شد (MATLAB 2013). در پژوهش حاضر از الگوریتم لونبرگ-

et al., 2020). روابط زیر مربوط به مؤلفه سرعت ذره و بهترین مکان ذره برای الگوریتم PSO بهترین ذره سراسری که در آن کل ازدحام به عنوان همسایه هر موجود در نظر گرفته می‌شود، تعریف شده‌اند:

$$v_{ij}(t+1) = v_{ij}(t) + c_1 r_{1j}(t)[y_{ij}(t) - x_{ij}(t)] + c_2 r_{2j}(t)[\hat{y}_j(t) + x_{ij}(t)] \quad (2)$$

که $v_{ij}(t)$ سرعت ذره i در دامنه $z = 1, \dots, n_x$ و در گام زمانی t است؛ $x_{ij}(t)$ موقعیت یا مکان ذره i در گام زمانی t است و c_1 و c_2 ثابت‌های مثبت ضرایب شتاب و r_{1j} و r_{2j} هم متغیر تصادفی در دامنه $[0, 1]$ هستند و f تابع برازش است.

$$y_i(t+1) = \begin{cases} y_i(t) & \text{if } f(x_i(t+1)) \geq f(y_i(t)) \\ x_i(t+1) & \text{if } f(x_i(t+1)) < f(y_i(t)) \end{cases} \quad (3)$$

۲-۳-۴- مدل الگوریتم بهینه‌ساز کلونی مورچگان (ANN-ACO)^{۱۶}

روش ACO دارای دو تکنیک اصلی شامل روش پیوسته و گسسته است. ACO پیوسته (ACOR)^{۱۷} برای مسائلی بهینه‌سازی فضای جست‌وجوی پیوسته، به‌طور موفقیت‌آمیزی مورد استفاده قرار گرفته است (Rezaei et al., 2020; Toksarı, 2007; Yu et al., 2007). احتمال انتخاب مسیر طبق رابطه (۴) تعیین شد (Deneubourg et al., 1987; Pasteels et al., 1987).

$$p_1(m+1) = \frac{(m_1 + k)^h}{(m_1 + k)^h + (m_2 + k)^h} = 1 - p_2(m+1) \quad (4)$$

در این رابطه، m شمارنده تعداد تکرار، p_1 احتمال انتخاب مسیر یک، m_1 و m_2 به ترتیب تعداد مورچه‌های موجود در مسیر یک و دو، k درجه جذب به سوی مسیر جست و جو نشده و h تمایل به استفاده در فراموشی است.

۲-۴- روش انجام کار

برای انجام مدل‌سازی مطابق بخش (۲-۲) و در مرحله اول سری زمانی پارامترهای منتخب با استفاده از اطلاعات سنجش از دور و بوسیله سامانه GEE، از طریق اطلاعات ماهواره‌ای سنجنده ERA5 برای دو حوضه متفاوت به نام‌های حوضه ایستگاه هیدرومتری سامیان و حوضه ایستگاه هیدرومتری عموقین استخراج شدند. سپس سری زمانی داده‌های استخراجی از طریق سنجش از دور به عنوان داده‌های ورودی و آمار دبی مشاهداتی در ایستگاه‌های هیدرومتری منتخب، به عنوان پارامتر هدف انتخاب شد. از اطلاعات ایستگاه سامیان برای آموزش و واسنجی مدل‌ها و از اطلاعات ایستگاه عموقین برای ارزیابی و

صحت‌سنجی استفاده شد. در مرحله بعد، باتوجه به ارتباطی که بین بارش و رواناب وجود دارد، تأخیرهای مناسب در گام‌زمانی، مابین داده‌های ورودی و خروجی با استفاده از همبستگی متقابل بررسی شد (Adamowski et al., 2010; Hydrogeol, 2010; Jemcov et al., 2009; Joo et al., 2002; Padilla et al., 1995; Panagopoulos et al., 2006). در مرحله سوم داده‌ها نرمال شد (Basheer et al., 2000; Khalili et al., 2014) و در مرحله بعدی، داده‌ها به صورت تصادفی به سه دسته، شامل ۷۰ درصد برای آموزش، ۱۵ درصد برای اعتبارسنجی و ۱۵ درصد برای آزمون تقسیم‌بندی شدند. پس از تعیین مناسب‌ترین ساختار، در مرحله پنجم، الگوریتم شبکه عصبی با استفاده از اطلاعات ایستگاه سامیان آموزش داده شد؛ در این مرحله تعیین ساختار و معماری شبکه‌های عصبی تا رسیدن به مناسب‌ترین نتیجه شامل تعیین تابع فعال‌ساز، الگوریتم آموزش، تعداد لایه‌های میانی و تعداد نرون‌ها است که این بخش با تکرار و با آزمون و خطای ترکیب‌های مختلف انجام شد (Affandia et al., 2007; Gaur et al., 2013; Guang-Bin, 2003; Khaki et al., 2015; Li et al., 2019; Mirarabi et al., 2019; Trichakis et al., 2011). در نهایت سنجش کارایی مدل‌های ساخته شده با استفاده از داده‌های ایستگاه عموقین انجام شد. این مراحل همان‌گونه که بیان شد ابتدا برای مدل NARX، سپس با رعایت تشابه در ساختار برای سه الگوریتم شبکه عصبی فراابتکاری نیز تکرار شد.

۲-۵- آماره‌های ارزیابی

آماره‌های ارزیابی مورد استفاده در تحقیق شامل میانگین مربع خطا (MSE)^{۱۸} (Hyndman et al., 2006) R^2 (Casella, 2002; Draper et al., 1998; Glantz et al., 1990)، ضریب کارایی نش-ساتنکلیف (NSE)^{۱۹} (Nash et al., 1970)، ضریب همبستگی (r)، جذر میانگین مربع خطا (RMSE)^{۲۰} و میانگین خطای مطلق (MAE)^{۲۱} (Hyndman et al., 2006) است.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_o - Y_m)^2 \quad (5)$$

$$RSS: \sum_{i=1}^n (Y_o - Y_m)^2 \quad (6)$$

$$TSS: \sum_{i=1}^n (Y_o - \bar{Y}_o)^2 \quad (7)$$

$$R^2 = 1 - \frac{RSS}{TSS} \quad (8)$$

$$NSE = 1 - \frac{\sum_{t=1}^T (Y_o - Y_m)^2}{\sum_{t=1}^T (Y_o - \bar{Y}_o)^2} \quad (9)$$

$$r = \rho_{Y_o, Y_m} = \frac{cov(Y_o, Y_m)}{\sigma_{Y_o} \cdot \sigma_{Y_m}} \quad (10)$$

$$RMSE = \sqrt{MSE} \quad (11)$$

عصبی می‌رسد. برای این منظور ابتدا داده‌ها نرمال‌سازی شدند. سپس باتوجه به اینکه دبی مشاهده‌ای، حاصل از رواناب جاری‌شده در نتیجه بارش اتفاق افتاده در سطح حوضه است (Hernández-Bedolla et al., 2023; Trenberth et al., 2007)، همبستگی متقابل مابین دبی مشاهده‌ای و داده‌های بارش در سطح حوضه مطابق شکل ۱۳، بررسی شد. در این شکل باتوجه به اولین اوج در سمت منفی نمودار در گام سوم، جهت مدل‌سازی تا ۳ گام زمانی (تأخیر سه روزه مابین پارامترهای ورودی و خروجی) استفاده شد و از بهترین نتیجه به‌دست آمده در این مرحله و متناسب با تأخیر در گام‌زمانی که مابین ورودی‌ها و خروجی در مدل NARX بدست آمد، در سایر مدل‌ها نیز استفاده شد.

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_o - Y_m| \quad (12)$$

در این روابط: \bar{Y}_o میانگین داده‌ای مشاهده‌ای: Y_m خروجی مدل: Y_o : داده مشاهده‌ای، n : تعداد داده‌ها، cov : کوواریانس و σ_{Y_o} & σ_{Y_m} : انحراف معیار پارامترهای هستند.

۳- نتایج و بحث

با استخراج سری زمانی‌های مورد نیاز برای ساخت مدل از طریق سامانه GEE در شکل‌های ۳ الی ۱۲، نوبت به آموزش شبکه‌های




Fig. 3- Observational daily flow in Samian Stream gauge
شکل ۳- دبی مشاهده‌ای در ایستگاه هیدرومتری سامیان




Fig. 4- Mean of surface atmospheric pressure over Samian Basin
شکل ۴- میانگین فشار هوا در سطح حوضه ایستگاه سامیان




Fig. 5- Mean of leaf area index for low vegetation in Samian Basin
شکل ۵- میانگین شاخص پوشش گیاهی (پوشش کم) در سطح حوضه ایستگاه سامیان




Fig. 6- Mean of leaf area index for high vegetation in Samian Basin
 شکل ۶- میانگین شاخص پوشش گیاهی (پوشش زیاد) در سطح حوضه ایستگاه سامیان




Fig. 7- Mean of soil temperature (0-7 cm) in Samian Basin
 شکل ۷- میانگین دمای خاک تا عمق ۷ سانتی متر در سطح حوضه ایستگاه سامیان




Fig. 8- Mean of air temperature at 2m above the surface of land in Samian Basin
 شکل ۸- میانگین دمای هوا تا فاصله ۲ متری از سطح حوضه ایستگاه سامیان




Fig. 9- Mean of volume of water in soil (0-7 cm) in Samian Basin
 شکل ۹- میانگین حجم آب موجود در خاک تا عمق ۷ سانتی متر در سطح حوضه ایستگاه سامیان




Fig. 10- Mean of runoff in Samian Basin
 شکل ۱۰- میانگین رواناب در سطح حوزه ایستگاه سامیان




Fig. 11- Mean of potential evaporation in Samian Basin
 شکل ۱۱- میانگین پتانسیل تبخیر در سطح حوزه ایستگاه سامیان




Fig. 12- Mean of precipitation in Samian Basin
 شکل ۱۲- میانگین بارش در سطح حوزه ایستگاه سامیان




Fig. 13- Cross correlation between observational flow and precipitation
 شکل ۱۳- همبستگی متقابل دبی مشاهده‌ای در ایستگاه سامیان با بارش استخراجی

۳-۱- مدل NARX

ساخته شده توسط مدل NARX در جدول ۲ ارائه شده است، که با توجه به آماره‌های ارزیابی استفاده شده در این تحقیق، شبیه‌سازی با تأخیر زمانی دو روزه مناسب‌ترین وضعیت ارزیابی شد.

Thapa et al. (2020) در تحقیقی مشابه از مدل NARX در پیش‌بینی رواناب حاصل از ذوب برف استفاده کردند، نتایج حاصل برای آزمون مدل، در این تحقیق با استفاده از آماره‌های MAE، RMSE، R^2 و NSE انجام شده بود که مقادیر آن‌ها به ترتیب ۰/۳۱۲، ۰/۹۹۵ و ۰/۹۸۹ گزارش شده است، که در با مقایسه با نتایج تحقیق حاضر، مشاهده می‌شود که آماره‌ها از دقت بیش‌تری برخوردار هستند که علت آن را می‌توان در استفاده از داده‌های مشاهداتی در ترکیب داده‌های ورودی دانست. همچنین، Amisigo et al. (2008) دبی ماهانه رواناب در حوضه ولتا در غرب آفریقا را با استفاده از مدل NARX و NARMAX پیش‌بینی کردند، که در آن تحقیق رواناب ماهانه با استفاده از آماره NSE به طور متوسط برابر با ۸۸ درصد گزارش شد که با نتایج مطالعه حاضر شباهت دارد.

همانگونه که اشاره شد در مرحله اول، مدل‌سازی با استفاده از مدل NARX انجام گرفت. در این مدل تعداد لایه‌های میانی با انجام تکرارهای متعدد، ۱۵ لایه انتخاب و بررسی ساختار مدل با سه گام زمانی تأخیر بین داده‌های ورودی و خروجی انجام شد که نتیجه آن به شرح شکل‌های A-۱۴، A-۱۵ و A-۱۶ است، این نمودارها نشان‌دهنده میزان همبستگی بین داده‌های مشاهداتی و خروجی مدل است. یعنی از ضریب همبستگی برای سنجش اولیه کارایی مدل استفاده شد تا پس از بدست آمدن بیش‌ترین مقدار همبستگی، ساختار شبکه‌ها جهت مدل‌سازی نهایی شود. در مرحله بعد شبکه ساخته شده، با داده‌های حوضه ایستگاه عموقین که از آن‌ها در مرحله اول و ساخت مدل استفاده نشده بود، صحت‌سنجی شد که نتیجه آن در شکل‌های B-۱۴، B-۱۵، B-۱۶ ارائه شده است.

با تکمیل تمامی مراحل و دستیابی به مدل بهینه، گام آخر برای بررسی کارایی مدل ساخته شده است که برای این منظور از داده‌های ایستگاه عموقین استفاده شد. خلاصه نتایج صحت‌سنجی و آزمایش مدل

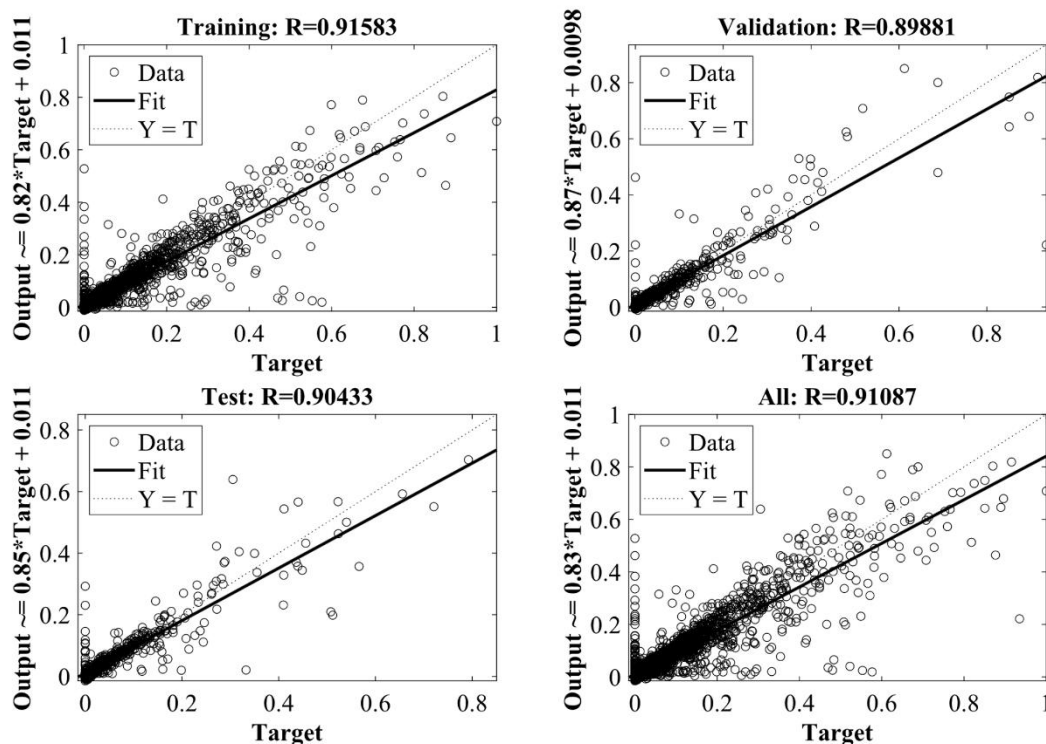


Fig. 14-A- Regression diagram of NARX model with a one lag time for Samian Basin
 شکل ۱۴- A- رگرسیون ساخت مدل NARX با یک گام زمانی تأخیر حوضه ایستگاه سامیان

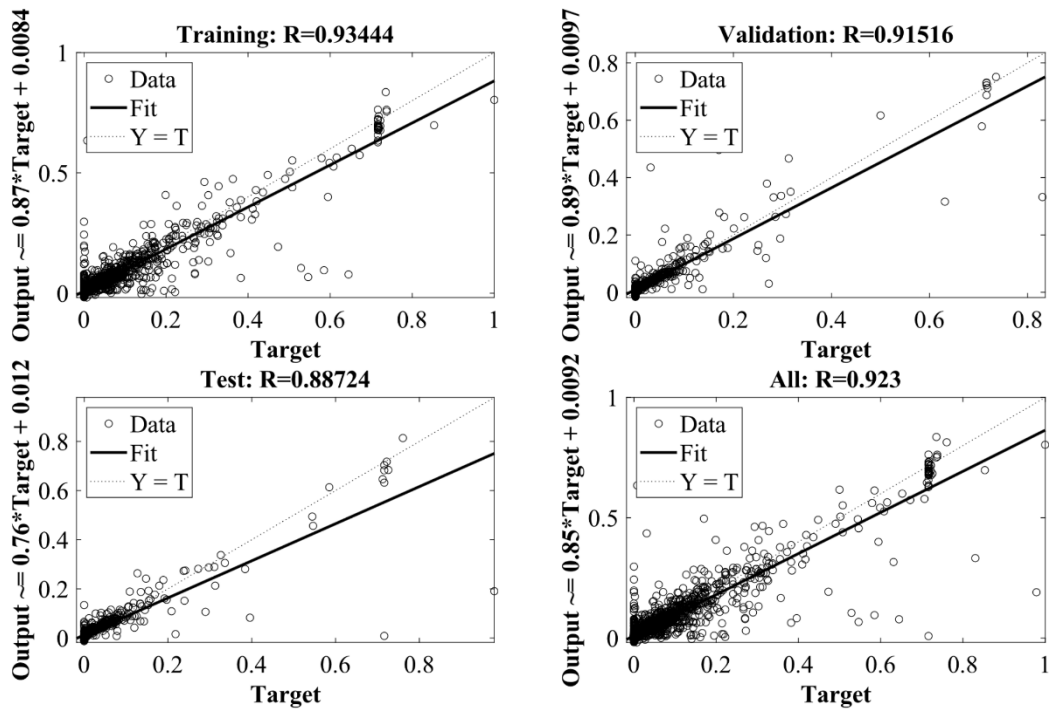


Fig. 14- B- Regression diagram of NARX model with a one lag time for Amoghein Basin
 شکل ۱۴- B - رگرسیون ساخت مدل NARX با یک گام زمانی تأخیر حوضه ایستگاه عموقین

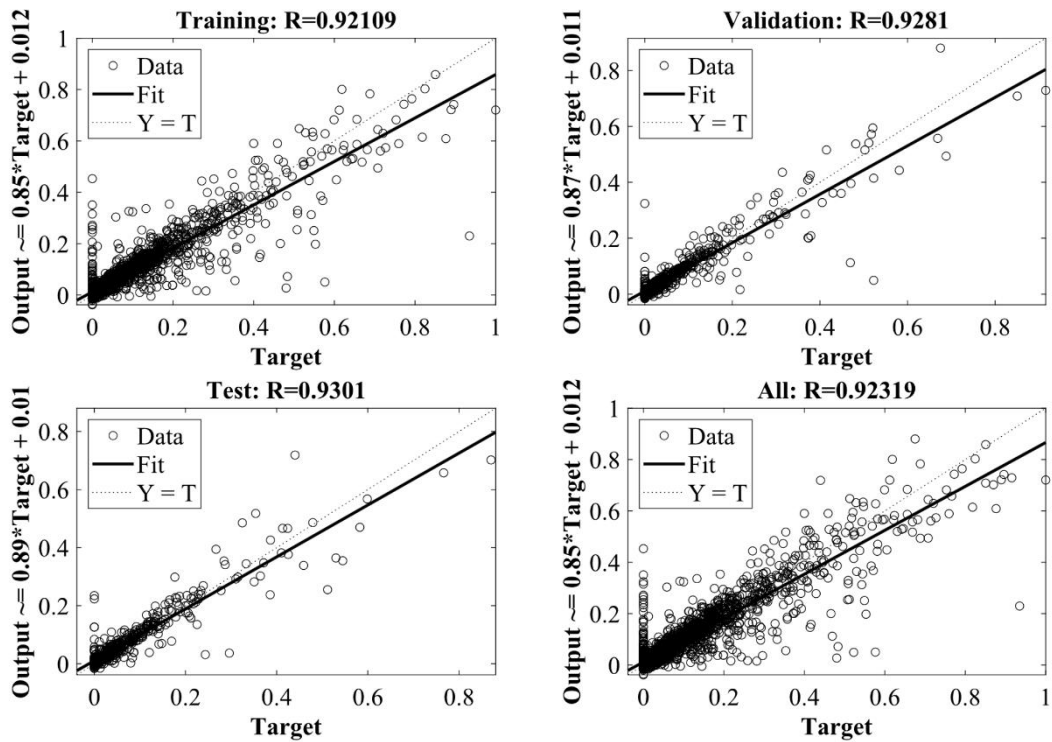


Fig. 15- A- Regression diagram of NARX model with two lag times for Samian Basin
 شکل ۱۵- A - رگرسیون ساخت مدل NARX با دو گام زمانی تأخیر حوضه ایستگاه سامیان

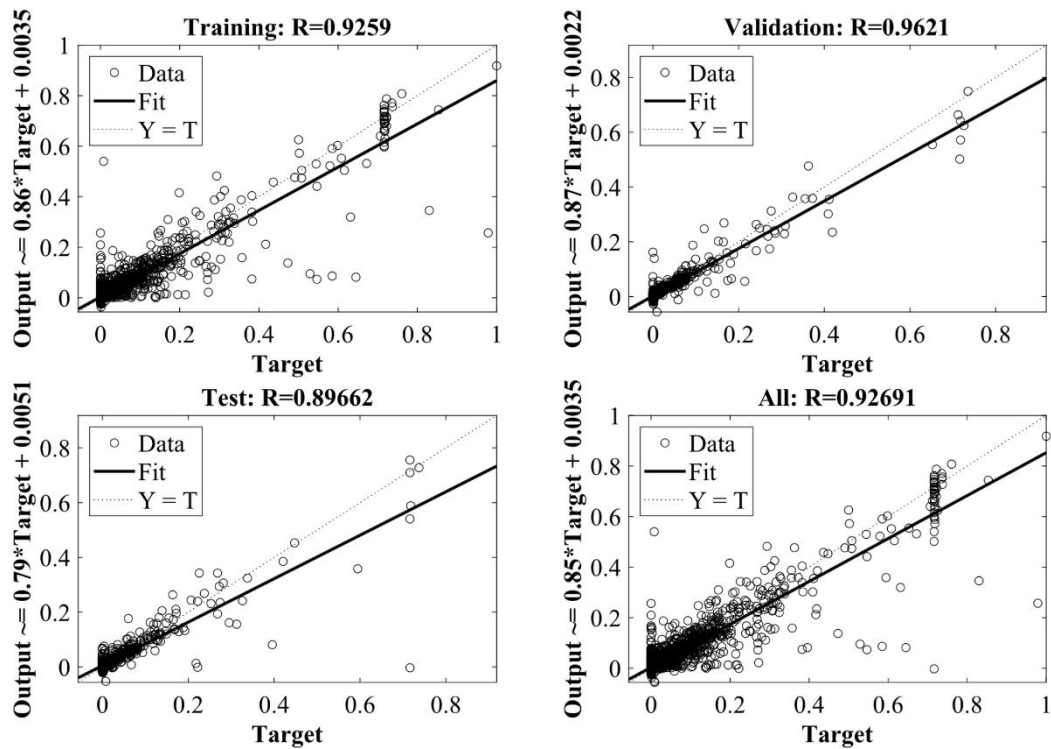


Fig. 15- B- Regression diagram of NARX model with two lag times for Amoghein Basin
 شکل ۱۵- B- رگرسیون ساخت مدل NARX با دو گام زمانی تأخیر حوضه ایستگاه عموقین

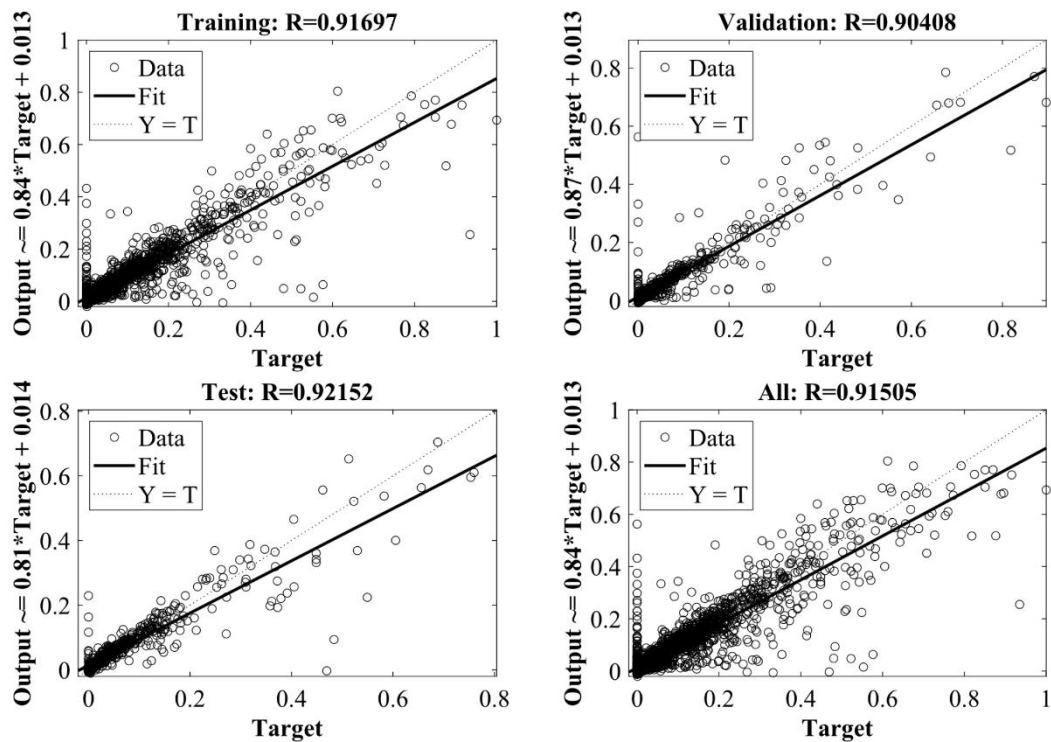


Fig. 16- A- Regression diagram of NARX model with three lag times for Samian Basin
 شکل ۱۶- A- رگرسیون ساخت مدل NARX با سه گام زمانی تأخیر حوضه ایستگاه سامیان

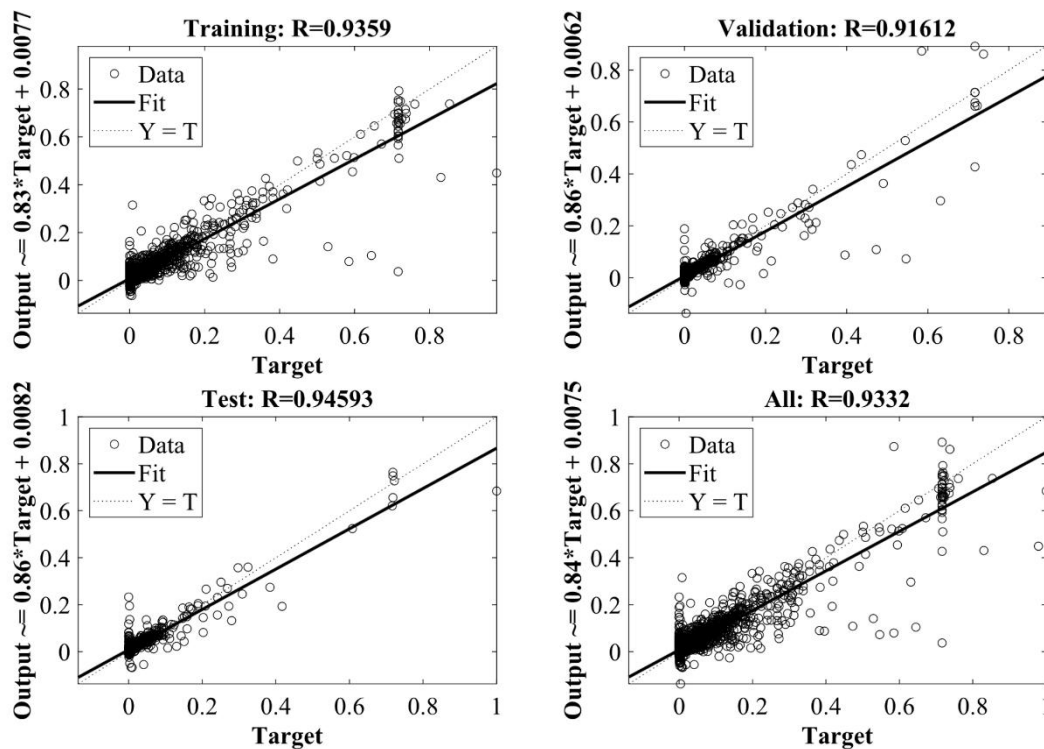


Fig. 16- B- Regression diagram of NARX model with three lag times for and Amoghein Basin

شکل ۱۶- B- رگرسیون ساخت مدل NARX با سه گام زمانی تأخیر حوضه ایستگاه عموقین

Table 2- Accuracy of the NARX model in predicting the observed discharge in Amoghein Basin

جدول ۲- بررسی دقت مدل NARX در پیش‌بینی سری‌زمانی دبی مشاهده‌ای ایستگاه عموقین

Amoghein Basin	Time Lag	NARX				
		MSE	R ²	RMSE	NSE	MAE
	1 Day	0.002	0.85	0.040	0.824	0.016
Calculated Value	2 Days	0.001	0.86	0.039	0.855	0.015
	3 Days	0.001	0.86	0.038	0.086	0.014

۱۵۰ بار، آموزش شبکه انجام گرفت، نهایتاً با نتیجه یکی از تکرارها که دقت بالایی داشت مطابق شکل A-۱۷، ارزیابی شبکه با داده‌های ایستگاه عموقین مورد آزمون قرار گرفت (شکل B-۱۷). این نمودارها مشابه مدل NARX نیز نشان‌دهنده میزان همبستگی مابین داده‌های مشاهداتی و خروجی مدل جهت تشخیص مناسب‌ترین ساختار است.

در مدل ANN-GA نیز مشابه مدل ANN-ACO تعداد لایه‌ها ۱۵ لایه در نظر گرفته شده، اندازه جمعیت ۵۵ عدد و با تعداد تکرار ۱۵۰ بار آموزش شبکه انجام گرفت، سرانجام با نتیجه یکی از تکرارها که دقت بالایی داشت (شکل A-۱۸)، ارزیابی شبکه با داده‌های ایستگاه عموقین مورد ارزیابی قرار گرفت (شکل B-۱۸).

علاوه بر آن Whyte et al. (2011) و Shao et al. (2022) در تحقیقات مشابهی با استفاده از مدل NARX به شبیه‌سازی مدل بارش-رواناب و بررسی کارایی شبکه‌های عصبی در این زمینه پرداختند؛ در این تحقیق‌ها برای بررسی عملکرد مدل‌ها از آماره NSE استفاده شده است. مقدار آن‌ها در شرایط مرطوب در تحقیق اول برابر با ۰/۸۸۶ و در تحقیق دوم بین ۰/۷ تا ۰/۹ گزارش شده است. نتایج این تحقیق‌ها هم مستند به آماره NSE مشابه تحقیق حاضر است.

۳-۲- مدل‌های ANN-ACO، ANN-GA و ANN-PSO

در مدل ANN-ACO مشابه مدل NARX تعداد لایه‌ها ۱۵ لایه در نظر گرفته شده، اندازه جمعیت بین ۵ تا ۵۰ عدد تغییر و با تعداد تکرار

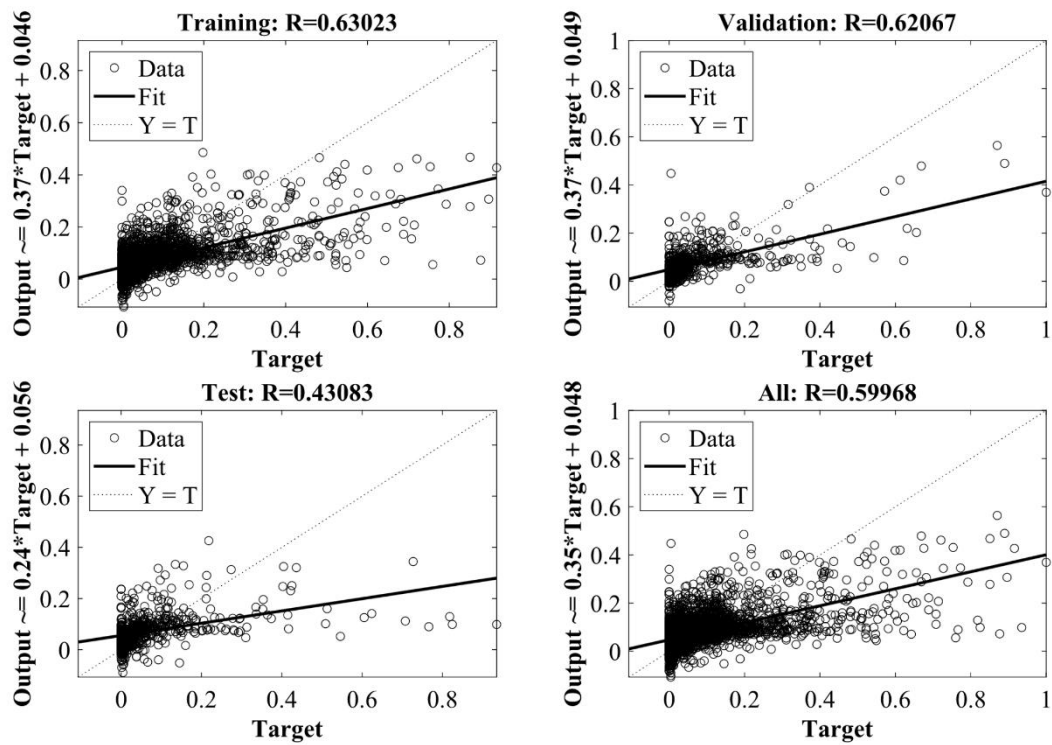


Fig. 17- A- Regression of ANN-ACO model with two lag times for Samian Basin
 شکل ۱۷- A- رگرسیون مدل ANN-ACO با دو گام زمانی تأخیر حوضه ایستگاه سامیان

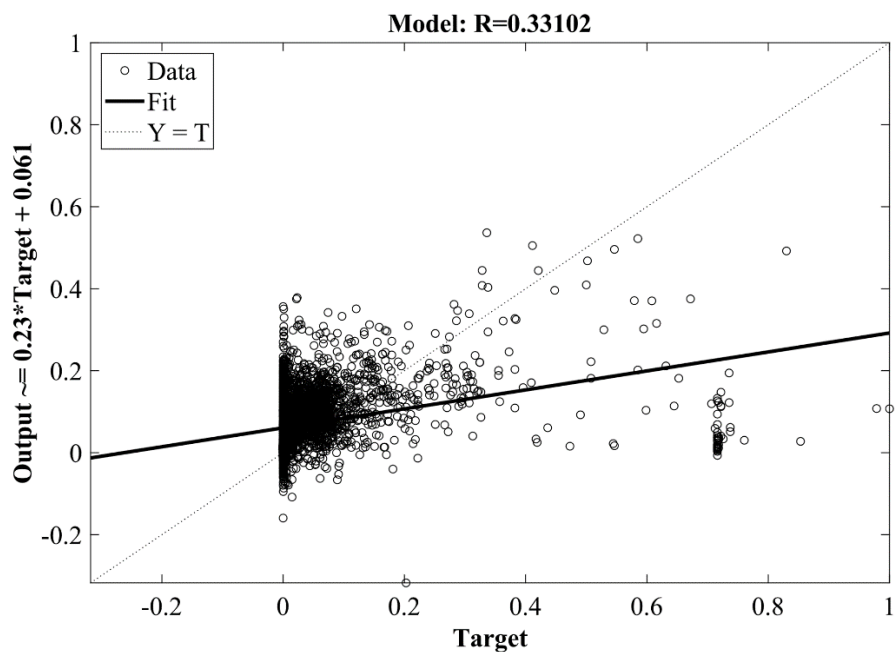


Fig. 17- B- Regression of ANN-ACO model with two lag times for Amogheh Basin
 شکل ۱۷- B- رگرسیون مدل ANN-ACO با دو گام زمانی تأخیر حوضه ایستگاه عموقین

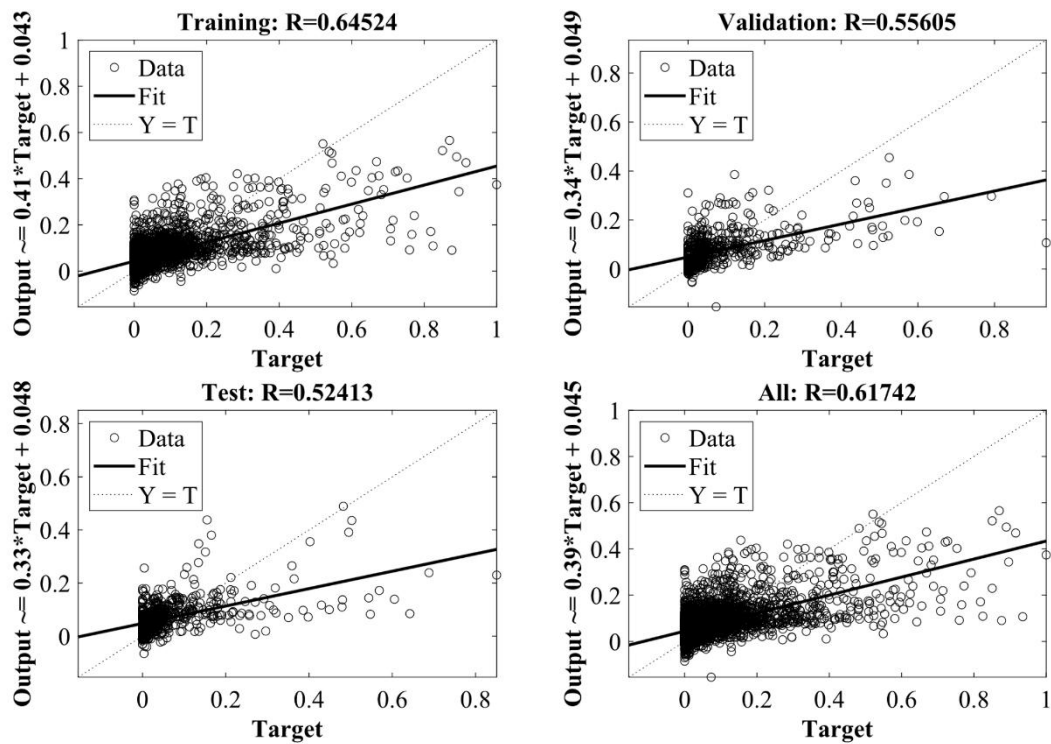


Fig. 18- A- Regression of ANN-GA model with two lag times for Samian Basin
 شکل ۱۸- A- رگرسیون مدل ANN-GA با دو گام زمانی تأخیر حوضه ایستگاه سامیان




Fig. 18- B- Regression of ANN-GA model with two lag times for Amogheh Basin
 شکل ۱۸- B- رگرسیون مدل ANN-GA با دو گام زمانی تأخیر حوضه ایستگاه عموقین

بالایی داشت مطابق شکل ۱۹-۱۹، ارزیابی شبکه با داده‌های ایستگاه عموقین ارزیابی شد (شکل ۱۹-۱۹).

در مدل ANN-PSO نیز مشابه مدل‌های قبلی تعداد لایه‌ها ۱۵ لایه در نظر گرفته شد، اندازه جمعیت ۵۰ عدد و با تعداد تکرار ۱۵۰ بار آموزش شبکه انجام گرفت، در پایان با نتیجه یکی از تکرارها که دقت

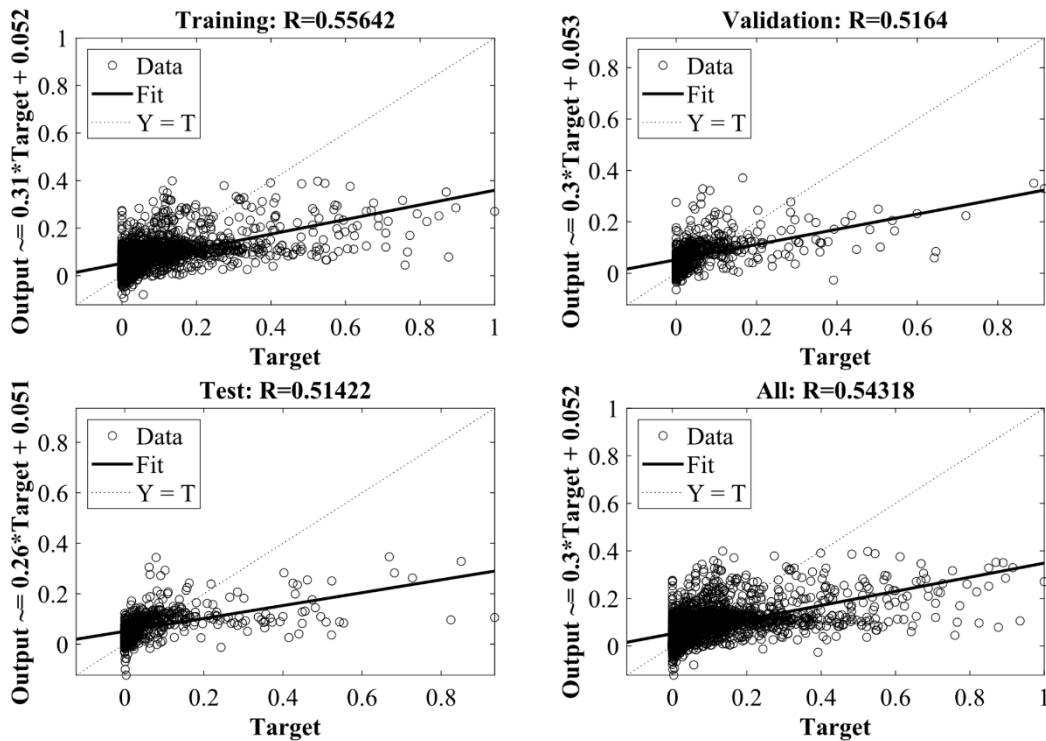


Fig. 19- A- Regression of ANN-PSO model with two lag times for Samian Basin
شکل ۱۹-۱۹- A- رگرسیون مدل ANN-PSO با دو گام زمانی تأخیر حوضه ایستگاه سامیان




Fig. 19- B- Regression of ANN-PSO model with two lag times for Amoghein Basin
شکل ۱۹-۱۹- B- رگرسیون مدل ANN-PSO با دو گام زمانی تأخیر حوضه ایستگاه عموقین

خلاصه نتایج ارزیابی و سنجش شبیه‌سازی انجام‌یافته توسط تمامی مدل‌های استفاده شده برای داده‌های ایستگاه عموقین، که با تأخیر دو گام زمانی (روز) بین داده‌های ورودی و خروجی ساخته شده بودند، در جدول ۳ درج شده است.

با مقایسه دقت مدل‌های ساخته شده با الگوریتم‌های فراابتکاری مورد استفاده در این تحقیق، با سایر تحقیقات مشابه، مشخص می‌شود که دقت مدل‌های ANN-ACO، ANN-GA و ANN-PSO در مقایسه با تحقیقات مشابه، از دقت کم‌تری برخوردار بوده و ضریب همبستگی نتایج شبیه‌سازی شده با اطلاعات مشاهداتی پایین است. علت این موضوع این است که در این تحقیق، برخلاف اغلب تحقیقاتی که به برخی از آن‌ها اشاره شده است، از اطلاعات مشاهداتی هدف (که در این تحقیق دبی رواناب بود) به‌عنوان یکی از پارامترهای ورودی آموزش استفاده نشد تا وابستگی مدل به آن، به حداقل برسد.

طبق نتایج جدول ۳ مدل NARX در مقایسه با سایر مدل‌ها و نتایج تحقیق سایر محققین عملکرد قابل قبولی داشت که نشان‌دهنده توانایی آن در پیش‌بینی دبی رواناب در محل انجام تحقیق است. همچنین دقت پایین الگوریتم‌های فراابتکاری در این تحقیق را می‌توان به عدم حذف مولفه‌های سری‌زمانی از داده‌ها نسبت داد. با استفاده از مدل‌های مورد استفاده در این تحقیق، دبی رواناب در ایستگاه هیدرومتری عموقین اردبیل شبیه‌سازی شد که خروجی مدل‌های مورد استفاده در برازش با داده‌های مشاهداتی در قالب شکل‌های ۲۰ الی ۲۳ ارائه شده است. همانگونه که مشاهده می‌شود و مطابق شکل ۲۰، مدل NARX نزدیک‌ترین برازش را نسبت به داده‌های مشاهداتی دارد.

Dehghani et al. (2021) برای شبیه‌سازی جریان رودخانه‌ای از شبکه‌های عصبی مصنوعی ترکیبی برای مدل‌سازی حوضه آبریز رودخانه کرخه استفاده کردند؛ آن‌ها در بخشی از تحقیق خود از مدل‌های ACO، GA و PSO جهت بهینه‌سازی شبکه عصبی مصنوعی استفاده کردند. داده‌های ورودی شامل بارش و جریان رودخانه در گذشته بود. دقت نتایج این تحقیق توسط آماره‌های R^2 ، RMSE، MAE و NSE بررسی شد که مقادیر آن در یکی از ایستگاه‌های منتخب برای مدل GA به ترتیب برابر بود با ۰/۹۲۱، ۰/۰۹۸، ۰/۰۶۸ و ۰/۹۳۲؛ برای مدل PSO به ترتیب برابر با ۰/۹۶۳، ۰/۰۶۲، ۰/۰۳۷ و ۰/۹۸۵ بود. Azad et al. (2018) نیز در تحقیقی مشابه، برای پیش‌بینی جریان رودخانه از مدل‌های ترکیبی عصبی فازی استفاده کردند؛ مدل‌ها با استفاده از ACO، GA و PSO بهینه شدند. نتایج تحقیق آن‌ها نشان داد که بهینه‌سازی با استفاده از مدل PSO نسبت به سایر مدل‌ها بهترین نتیجه را در پی داشته است. همچنین در تحقیق مذکور، بهترین نتیجه برای تخمین جریان پایین دست با یک روز تأخیر مابین داده‌های ورودی و خروجی به دست آمده است. Chen et al. (2015) در مطالعه‌ای کارایی الگوریتم‌های بهینه‌سازی مبتنی بر جمعیت را برای پیش‌بینی جریان رودخانه بر روی حوضه آبریز رودخانه آلتاهاما در پایین دست در ترکیب با مدل شبکه عصبی بررسی کردند، که جریان پایین دست رودخانه با پارامتر ایستگاه‌های بالادست و بارش حوضه مدل شد. دقت مدل‌ها با استفاده از آماره‌های NSE و RMSE بررسی شدند که مقادیر بدست آمده برای مدل ACO به ترتیب برابر بود با ۰/۷۹۸ و ۸/۸۵۷ و برای PSO به ترتیب برابر با ۰/۸۲۹ و ۸/۱۵ بود و به مانند نتایج مطالعه حاضر دقت تقریباً مشابهی بدست آمد که می‌توان دریافت رویکرد استفاده شده در این تحقیق با استناد به این نتایج مورد تأیید است.

Table 3- Accuracy of selected models for two lag times for Amoghein basin data

جدول ۳- مقایسه دقت مدل‌های منتخب برای تأخیر با دو گام زمانی برای داده‌های حوضه ایستگاه عموقین

Amoghein Basin	Time Lag	MSE	R^2	RMSE	NSE	MAE
NARX	2 Days	0.001	0.86	0.039	0.855	0.015
ANN-ACO		0.012	0.12	0.110	-0.177	0.066
ANN-GA		0.012	0.11	0.108	0.012	0.065
ANN-PSO		0.013	0.11	0.114	-0.257	0.069




Fig. 20- Simulation of the flow rate at Amoghein gauge using the NARX model
 شکل ۲۰- شبیه‌سازی دبی جریان در محل ایستگاه هیدرومتری عموقین با استفاده از مدل NARX




Fig. 21- Simulation of the flow rate at Amoghein gauge using the ANN-ACO model
 شکل ۲۱- شبیه‌سازی دبی جریان در محل ایستگاه هیدرومتری عموقین با استفاده از مدل ANN-ACO




Fig. 22- Simulation of the flow rate at Amoghein gauge using the ANN-GA model
 شکل ۲۲- شبیه‌سازی دبی جریان در محل ایستگاه هیدرومتری عموقین با استفاده از مدل ANN-ACO




Fig. 23- Simulation of the flow rate at Amoghein gauge using the ANN-PSO model
 شکل ۲۳- شبیه‌سازی دبی جریان در محل ایستگاه هیدرومتری عموقین با استفاده از مدل ANN-PSO

پی‌نوشت‌ها

- 1- Normalized Difference Vegetation Index
- 2- Nonlinear Autoregressive Network with Exogenous Inputs
- 3- Nonlinear Autoregressive Model with Exogenous Geomorphometrically Processed Inputs
- 4- Long Short-Term Memory
- 5- Feedforward Neural Networks
- 6- Geographic Information Systems
- 7- Numerical Weather Prediction
- 8- Application Programming Interface
- 9- Google Earth Engine
- 10- Genetic Algorithm
- 11- Particle Swarm Optimization
- 12- Ant Colony Optimization Algorithm
- 13- Levenberg–Marquardt Algorithm
- 14- Artificial Neural Network-Genetic Algorithm
- 15- Artificial Neural Network- Particle Swarm Optimization
- 16- Artificial Neural Network- Ant Colony Optimization Algorithm
- 17- Ant Colony Optimization for Continuous Domain
- 18- Mean Squared Error
- 19- Nash–Sutcliffe Model Efficiency Coefficient
- 20- Root Mean Squared Error
- 21- Mean Absolute Error

۴- نتیجه‌گیری

در این مطالعه سعی شد تا طریق داده‌های سنجش از دور و با کمک شبکه‌های عصبی مصنوعی برای محاسبه رواناب در حوضه‌های فاقد آمار مدل قابل قبولی پیشنهاد شود. به همین منظور، با کمک داده‌های سنجش از دور و با استفاده از رابط GEE از طریق سنجنده ERA5_Land داده‌های ورودی جمع‌آوری شد. داده‌های استخراج شده به عنوان ورودی شامل ۹ سری زمانی، متشکل از پارامترهای فشار هوا، شاخص پوشش گیاهی، دمای خاک، دمای سطح زمین، حجم آب خاک، رواناب، پتانسیل تبخیر و بارش بود که در مقابل داده‌های مشاهداتی دو ایستگاه هیدرومتری و به صورت روزانه وارد مدل‌های منتخب شدند. در این مطالعه از چهار مدل شامل ANN-، NARX، ANN-GA، و ANN-PSO استفاده گردید. مقایسه نتایج به دست آمده به وضوح نشان می‌دهد که مدل NARX در ترکیب با داده‌های سنجش از دور برای پیش‌بینی رواناب در حوضه‌های فاقد آمار از قابلیت بسیار خوبی نسبت به سایر مدل‌های بررسی شده برخوردار است. با توجه به نتایج به‌دست آمده به طور کلی پیشنهاد می‌شود کارایی این روش در یک حوضه آبریز با وجود عوامل انسانی زیاد (مانند حوضه کرخه) مورد ارزیابی قرار گیرد تا کارایی آن از نظر کاربردی قابل ارزیابی باشد.

۵- مراجع

- Adamowski J, Karapataki C (2010) Comparison of multivariate regression and artificial neural networks for peak urban water-demand forecasting: Evaluation of different ANN learning algorithms. *Journal of Hydrologic Engineering* 15(10):729-743
- Affandia A K, Watanabe K, Tirtomihardjo H (2007) Application of an artificial neural network to estimate groundwater level fluctuation. *Journal of Spatial Hydrology* 7(2)
- Akhtar M, Ahmad N, Booij M J (2008) The impact of climate change on the water resources of Hindukush–Karakorum–Himalaya region under different glacier coverage scenarios. *Journal of Hydrology* 355(1-4):148-163
- Alsumaiei A A (2020) A nonlinear autoregressive modeling approach for forecasting groundwater level fluctuation in urban aquifers. *Water* 12(3):820
- Amirahmadi A, Maali Ahari N, Ahmadi T (2014) The determination of probable subsidence areas of Ardebil Plain by the use of GIS. *Journal of Geography and Planning* 17(46):1-23
- Amisigo B A, van de Giesen N, Rogers C, Andah W E I, Friesen J (2008) Monthly streamflow prediction in the Volta Basin of West Africa: A SISO NARMAX polynomial modelling. *Physics and Chemistry of the Earth, Parts A/B/C* 33(1):141-150
- Azad A, Farzin S, Kashi H, Sanikhani H, Karami H, Kisi O (2018) Prediction of river flow using hybrid neuro-fuzzy models. *Arabian Journal of Geosciences* 11(22):718
- Balamurugan R, Natarajan A M, Premalatha K (2015) Stellar-mass black hole optimization for Biclustering Microarray Gene Expression Data. *Applied Artificial Intelligence* 29(4):353-381
- Basheer I A, Hajmeer M (2000) Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods* 43(1):3-31
- Bastola S, François D (2012) Temporal extension of meteorological records for hydrological modelling of Lake Chad Basin (Africa) using satellite rainfall data and reanalysis datasets. *Meteorological Applications* 19(1):54-70
- Bastola S, Misra V (2014) Evaluation of dynamically downscaled reanalysis precipitation data for hydrological application. *Hydrological Processes* 28(4):1989-2002
- Bianchi L, Dorigo M, Gambardella L M, Gutjahr W J (2009) A survey on metaheuristics for stochastic combinatorial optimization. *Natural Computing* 8:239-287
- Bingeman A K, Kouwen N, Soulis E D (2006) Validation of the hydrological processes in a hydrological model. *Journal of Hydrologic Engineering* 11(5):451-463
- Casella G (2002) *Statistical inference*. Second ed., Duxbury/Thomson Learning, Pacific Grove, CA, 556 p
- Chen X Y, Chau K W, Busari A O (2015) A comparative study of population-based optimization algorithms for downstream river flow forecasting by a hybrid neural network model. *Engineering Applications of Artificial Intelligence* 46:258-268
- Dehghani R, Poudeh H T (2021) Applying hybrid artificial algorithms to the estimation of river flow: A case study of Karkheh catchment area. *Arabian Journal of Geosciences* 14(9):768 (In Persian)
- Deneubourg J-L, Aron S, Goss S, Pasteels J M (1987) Error, communication and learning in ant societies. *European Journal of Operational Research* 30(2):168-172
- Draper N R, Smith H (1998) *Applied regression analysis* (Vol. 326). John Wiley & Sons,
- Fabio D N, Abba S, Pham B Q, Towfiqul Islam A R M, Talukdar S, Francesco G (2022) Groundwater level forecasting in Northern Bangladesh using nonlinear autoregressive exogenous (NARX) and extreme learning machine (ELM) neural networks. *Arabian Journal of Geosciences* 15(7):647
- Fraser A (1957a) Simulation of genetic systems by automatic digital computers I. Introduction. *Australian Journal of Biological Sciences* 10(4):484-491
- Fraser A (1957b) Simulation of genetic systems by automatic digital computers I, Effects of Linkage on Rates of Advance Under Selection. *Australian Journal of Biological Sciences* 10(4):492-500
- Gaur S, Ch S, Graillot D, Chahar B R, Kumar D N (2013) Application of artificial neural networks and particle swarm optimization for the management of groundwater resources. *Water Resources Management* 27(3):927-941
- Glantz S A, Slinker B K, Neilands T B (1990) *Primer of applied regression and analysis of variance*. M*c Graw Hill. Inc., New York

- Gorelick N, Hancher M, Dixon M, Ilyushchenko S, Thau D, Moore R (2017) Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment* 202:18-27
- Goswami M, O'connor K, Bhattarai K (2007) Development of regionalisation procedures using a multi-model approach for flow simulation in an ungauged catchment. *Journal of Hydrology* 333(2-4):517-531
- Guan X, Zhang J, Yang Q, Tang X, Liu C, Jin J, Wang G (2020) Evaluation of precipitation products by using multiple hydrological models over the upper Yellow River Basin, China. *Remote Sensing* 12(24):4023
- Guang-Bin H (2003) Learning capability and storage capacity of two-hidden-layer feedforward networks. *IEEE Transactions on Neural Networks* 14(2):274-281
- He S, Gu L, Tian J, Deng L, Yin J, Liao Z, Hui Y (2021) Machine learning improvement of streamflow simulation by utilizing remote sensing data and potential application in guiding reservoir operation. *Sustainability* 13(7):3645
- Hernández-Bedolla J, García-Romero L, Franco-Navarro C D, Sánchez-Quispe S T, Domínguez-Sánchez C (2023) Extreme runoff estimation for ungauged watersheds using a new multisite multivariate stochastic model MASVC. *Water* 15(16):2994
- Holland J H (1992) Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence. MIT press, p
- Huang Q, Qin G, Zhang Y, Tang Q, Liu C, Xia J, Post D (2020) Using remote sensing data-based hydrological model calibrations for predicting runoff in ungauged or poorly gauged catchments. *Water Resources Research* 56(8)
- Hydrogeol J (2010) The relation between karst spring discharge and rainfall by cross-correlation analysis (Campania, southern Italy). *Hydrogeology Journal* 18:1881-1895
- Hydrology A N N (2000) Artificial neural networks in hydrology. I: Preliminary concepts. *Journal of Hydrologic Engineering* 5(2):115-123
- Hyndman R J, Koehler A B (2006) Another look at measures of forecast accuracy. *International Journal of Forecasting* 22(4):679-688
- Jemcov I, Petric M (2009) Measured precipitation vs. effective infiltration and their influence on the assessment of karst systems based on results of the time series analysis. *Journal of Hydrology* 379(3):304-314
- Joo C, Koo J, Yu M (2002) Application of short-term water demand prediction model to Seoul. *Water Science and Technology* 46(6-7):255-261
- Kalra A, Aryal A, Bhusal A, Gupta R (2023) Floodplain mapping of ungauged watershed using HEC models and PERSIANN precipitation. Paper Presented at the World Environmental and Water Resources Congress
- Kanishka G, Eldho T (2020) Streamflow estimation in ungauged basins using watershed classification and regionalization techniques. *Journal of Earth System Science* 129:1-18
- Khaki M, Yusoff I, Islami N (2015) Simulation of groundwater level through artificial intelligence system. *Environmental Earth Sciences* 73:8357-8367
- Khalili K, Abbaszade afshar m, Nazeri Z (2014) Compared to the normal mechanism becomes the normal monthly rainfall data from different regions of Iran. *Water and Soil* 28(2):365-372 (In Persian)
- Kisi O, Alizamir M, Zounemat-Kermani M (2017) Modeling groundwater fluctuations by three different evolutionary neural network techniques using hydroclimatic data. *Natural Hazards* 87(1):367-381
- Levenberg K (1944) A method for the solution of certain non-linear problems in least squares. *Quarterly of Applied Mathematics* 2(2):164-168
- Li H, Lu Y, Zheng C, Yang M, Li S (2019) Groundwater level prediction for the arid oasis of Northwest China based on the artificial bee colony algorithm and a back-propagation neural network with double hidden layers. *Water* 11(4):860
- Li K, Coe M, Ramankutty N, De Jong R (2007) Modeling the hydrological impact of land-use change in West Africa. *Journal of Hydrology* 337(3-4):258-268
- Lin T-N, Giles C L, Horne B G, Kung S-Y (1997) A delay damage model selection algorithm for NARX neural networks. *IEEE Transactions on Signal Processing* 45(11):2719-2730
- Maswood M, Hossain F (2016) Advancing river modelling in ungauged basins using satellite remote sensing: The case of the Ganges–Brahmaputra–Meghna basin. *International Journal of River Basin Management* 14(1):103-117

- MATLAB V (2013) 8.2. 0.701. The MathWorks Inc 2013
- Meresa H (2019) Modelling of river flow in ungauged catchment using remote sensing data: Application of the empirical (SCS-CN), artificial neural network (ANN) and hydrological model (HEC-HMS). *Modeling Earth Systems and Environment* 5:257-273
- Merz R, Blöschl G (2004) Regionalisation of catchment model parameters. *Journal of Hydrology* 287(1-4):95-123
- Mirarabi A, Nassery H, Nakhaei M, Adamowski J, Akbarzadeh A, Alijani F (2019) Evaluation of data-driven models (SVR and ANN) for groundwater-level prediction in confined and unconfined systems. *Environmental Earth Sciences* 78(15):1-15
- Mishra P, Babu R R (2022) Remote Sensing and Geographic Information System (GIS) based runoff estimation from an agricultural watershed. *Journal of Soil and Water Conservation* 21(2):167-175
- Muñoz-Sabater J, Dutra E, Agustí-Panareda A, Albergel C, Arduini G, Balsamo G, Thépaut J N (2021) ERA5-Land: a state-of-the-art global reanalysis dataset for land applications. *Earth System Science Data* 13(9):4349-4383
- Muñoz Sabater J (2019) ERA5-land monthly averaged data from 1981 to present, Copernicus Climate Change Service (C3S) Climate Data Store (CDS). *Earth System Science Data* 55:5679-5695
- Nash J E, Sutcliffe J V (1970) River flow forecasting through conceptual models part I—A discussion of principles. *Journal of Hydrology* 10(3):282-290
- Nogueira Filho F J M, Souza Filho F d A, Porto V C, Vieira Rocha R, Sousa Estácio Á B, Martins E S P R (2022) Deep learning for streamflow regionalization for ungauged basins: Application of long-short-term-memory cells in semiarid regions. *Water* 14(9):1318
- Noor H M, Ndzi D, Yang G, Safar N Z M (2017). Rainfall-based river flow prediction using NARX in Malaysia. Paper presented at the 2017 IEEE 13th International Colloquium on Signal Processing & its Applications (CSPA)
- Oudin L, Andréassian V, Perrin C, Michel C, Le Moine N (2008) Spatial proximity, physical similarity, regression and ungauged catchments: A comparison of regionalization approaches based on 913 French catchments. *Water Resources Research* 44(3)
- Padilla A, Pulido-Bosch A (1995) Study of hydrographs of karstic aquifers by means of correlation and cross-spectral analysis. *Journal of Hydrology* 168(1):73-89
- Panagopoulos G, Lambrakis N (2006) The contribution of time series analysis to the study of the hydrodynamic characteristics of the karst systems: Application on two typical karst aquifers of Greece (Trifilia, Almyros Crete). *Journal of Hydrology* 329(3):368-376
- Pasteels J M, Deneubourg J-L, Goss S (1987) Self-organization mechanisms in ant societies. I: Trail recruitment to newly discovered food sources. *Experientia: Supplementum* (54):155-175
- Post D A (2009) Regionalizing rainfall-runoff model parameters to predict the daily streamflow of ungauged catchments in the dry tropics. *Hydrology Research* 40(5):433-444
- Rezaei M J, Rezaei M R (2020) The estimation of groundwater level changes using four different techniques of evolutionary neural network, case study of Dasht-e-Abbas plain, Ilam province. *Watershed Engineering and Management* 12(3):737-755 (In Persian)
- Rostamzadeh H, Asadi E, Jarazadeh J (2015) Evaluation of the groundwater table using multi-criteria decision making and spatial analysis, case study: Ardebil Plain. *Journal of Spatial Analysis Environmental Hazards* 2(1):31-42 (In Persian)
- Shao Y, Zhao J, Xu J, Fu A, Li M (2022) Application of rainfall-runoff simulation based on the NARX Dynamic neural network model. *Water* 14(13):2082
- Shen Y, Liu D, Jiang L, Yin J, Nielsen K, Bauer-Gottwein P, Wang J (2020) On the contribution of satellite altimetry-derived water surface elevation to hydrodynamic model calibration in the han river. *Remote Sensing* 12(24):4087
- Sobhani B, Nasiri f (2022) Agro-ecological zonation of canola cultivation in Ardebil Plain. *Journal of Applied Researches in Geographical Sciences* 22(65):61-78 (In Persian)
- Tarpanelli A, Santi E, Tourian M J, Filippucci P, Amarnath G, Brocca L (2018) Daily river discharge estimates by merging satellite optical sensors and radar altimetry through artificial neural network. *IEEE Transactions on Geoscience and Remote Sensing* 57(1):329-341
- Thapa S, Zhao Z, Li B, Lu L, Fu D, Shi X, Qi H (2020) Snowmelt-driven streamflow prediction using machine learning techniques (LSTM, NARX, GPR, and SVR). *Water* 12(6):1734
- Tiwari D K, Tiwari H, Nateriya R (2022) Geomorphology-wavelet based approach to rainfall runoff modeling for data scarce semi-arid regions,

- Kolar river catchment, India. *Journal of Engineering Research* 10(1B):29-40
- Toksarı M D (2007) Ant colony optimization approach to estimate energy demand of Turkey. *Energy Policy* 35(8):3984-3990
- Trenberth K E, Smith L, Qian T, Dai A, Fasullo J (2007) Estimates of the global water budget and its annual cycle using observational and model data. *Journal of Hydrometeorology* 8(4):758-769
- Trichakis I C, Nikolos I K, Karatzas G P (2011) Artificial Neural Network (ANN) based modeling for karstic groundwater level simulation. *Water Resources Management* 25(4):1143-1152
- Wagener T, Wheeler H, Gupta H V (2004) Rainfall-runoff modelling in gauged and ungauged catchments. *World Scientific*, 4-8 p
- Xu C-Y (1999) Estimation of parameters of a conceptual water balance model for ungauged catchments. *Water Resources Management* 13:353-368
- Xue H, Liu J, Dong G, Zhang C, Jia D (2022) Runoff estimation in the upper reaches of the heihe river using an LSTM model with remote sensing data. *Remote Sensing* 14(10):2488
- Young A R (2006) Stream flow simulation within UK ungauged catchments using a daily rainfall-runoff model. *Journal of Hydrology* 320(1-2):155-172
- Yu H, Wilamowski B M (2011) Levenberg-marquardt training. *Industrial Electronics Handbook* 5(12):1
- Yu L, Liu K, Li K (2007) Ant Colony Optimization in continuous problem. *Frontiers of Mechanical Engineering in China* 2(4):459-462