

## Application of NARX Neural Network as Surrogate Model to Long-term Simulation of the Outlet Salinity from Strong Stratified Reservoirs

MORAD ASADI<sup>1</sup>, JAMAL MOHAMMAD VALI SAMANI<sup>1\*</sup>, HOSEIN MOHAMMAD VALI SAMANI<sup>2</sup>

1. Water Structures Engineering Department, Tarbiat Modares University, Tehran, Iran.

2. Department of Civil Engineering, Shahr-e-Qods Branch, Islamic Azad University, Tehran, Iran.

(Receive: March. 14, 2020- Revise: June. 4, 2020- Accepted: June. 20, 2020)

### ABSTRACT

The CE-QUAL-W2 program as a physical model for quality and hydrodynamic simulation of water reservoirs has a high computational cost. Therefore, finding surrogate models to give optimal results in short term would have a great practical importance especially in simulation-optimization problems. In this study, the capability of the NARX model as a surrogate model was investigated to simulate the outlet salinity from strongly stratified reservoirs. For this purpose, the CE-QUAL-W2 model was used and calibrated to simulate the outlet salinity of the Upper Gotvand Reservoir over 10 years. Regarding the possibility of release from different reservoir intakes, by monthly change of release ratios, several problems were defined and a library of the physical model results was formed. Then different NARX architecture scenarios were introduced and trained using the library results. The results obtained from different scenarios indicate that the NARX neural network model has a high capability to simulate the CE-QUAL-W2 model results of outflow salinity, so that the correlation coefficient is always above 0.91. In the selected scenario, a very good agreement is observed between the results of the two models, with a correlation coefficient of 0.95, mean absolute percentage error of 8.7% and Nash-Sutcliffe coefficient of 0.79. The simulation time required for the NARX neural network model is less than 0.06% of the time required to run the physical model for the same problem. The results show that the NARX model can be used as a suitable surrogate model for CE-QUAL-W2 to predict the long-term reservoir outlet salinity and reduces the cost of computing while maintains accuracy.

**Keywords:** NARX Neural Network Model, CE-QUAL-W2 Physical Model, Surrogate Model, Long-Term Simulation, Reservoir Outlet Salinity.

## استفاده از شبکه عصبی NARX به عنوان مدل جایگزین برای شبیه‌سازی بلند مدت شوری خروجی از مخازن دارای لایه‌بندی کیفی

مراد اسدی<sup>۱</sup>، جمال محمدولی‌سامانی<sup>۱\*</sup>، حسین محمدولی‌سامانی<sup>۲</sup>

۱. گروه مهندسی سازه‌های آبی، دانشگاه تربیت مدرس، تهران، ایران.

۲. بخش مهندسی عمران، دانشگاه آزاد اسلامی واحد شهر قدس، تهران، ایران.

(تاریخ دریافت: ۱۳۹۸/۱۲/۲۴ - تاریخ بازنگری: ۱۳۹۹/۳/۱۵ - تاریخ تصویب: ۱۳۹۹/۳/۳۱)

### چکیده

برنامه CE-QUAL-W2 یک مدل فیزیکی با اطمینان‌پذیری بالا جهت شبیه‌سازی هیدرودینامیکی-کیفی مخازن بوده که هزینه محاسباتی زیادی دارد. بنابراین یافتن مدل‌های جایگزین که نتایج این مدل را با دقت مطلوب و در زمان اندکی برآورد کنند از اهمیت کاربردی بالایی برخوردار است. در این تحقیق قابلیت مدل شبکه عصبی NARX به عنوان مدل جایگزین CE-QUAL-W2 جهت پیش‌بینی نتایج بلند مدت شوری خروجی از مخزن بررسی شده است. برای این منظور مدل CE-QUAL-W2 مخزن سد گتوند علیا تهیه و پس از واسنجی، برای شبیه‌سازی شوری خروجی از مخزن در یک دوره زمانی ۱۰ ساله استفاده گردید. با توجه به امکان تخلیه از دریچه‌های مختلف مخزن، با تغییر ماهیانه نسبت تخلیه دریچه‌ها مسائل متعددی تعریف و کتابخانه‌ای از نتایج مدل فیزیکی تشکیل شد. سپس با معرفی سناریوهای مختلف معماری شبکه عصبی NARX، آموزش آن‌ها با استفاده از کتابخانه نتایج انجام شد. نتایج حاصل از سناریوهای مختلف بیانگر توانایی بالای شبکه عصبی NARX در برآورد روند شوری خروجی از مخزن بوده و ضریب تعیین همواره بیش از ۰/۹۱ است. در سناریوی منتخب ضریب تعیین ۰/۹۵، میانگین درصد خطای مطلق و ضریب نش-سانت‌کلیف به ترتیب ۸/۷ درصد و ۰/۷۹ بوده و انطباق خوبی بین نتایج دو مدل مشاهده می‌شود. مدت زمان شبیه‌سازی بلند مدت مخزن گتوند با استفاده از مدل شبکه عصبی کمتر از ۰/۰۶ درصد زمان لازم برای اجرای مدل فیزیکی است. نتایج این تحقیق نشان می‌دهد که مدل NARX را می‌توان جهت پیش‌بینی بلند مدت شوری خروجی از مخازن به عنوان مدل جایگزین برای CE-QUAL-W2 بکار برده و هم‌زمان هزینه‌ی محاسبات را به طور چشمگیری کاهش داد.

**واژه‌های کلیدی:** شبکه عصبی NARX، مدل CE-QUAL-W2، مدل جایگزین، شبیه‌سازی بلند مدت، شوری خروجی از مخزن.

### مقدمه

تماس با گستره‌ی وسیعی از سازنده‌های نمکی<sup>۱</sup> قرار گرفته است (Jalali *et al.*, 2019). تجمع تدریجی مواد آلاینده در مخزن، کیفیت آب و به تبع آن مصرف‌کنندگان پایین‌دست را تحت تأثیر قرار می‌دهد (Wei *et al.*, 2009). بنابراین پیش‌بینی شرایط کمی و کیفی مخازن و حفظ شرایط مطلوب در بلند مدت ضروری است. مدل‌های شبیه‌سازی مخزن به دلیل امکان برآورد شرایط کمی و کیفی مخازن در بلند مدت از اهمیت ویژه‌ای برخوردار هستند (Castelletti *et al.*, 2010) و می‌توانند جهت ارتقای بهره‌برداری از مخازن با هدف دستیابی به شرایط کیفی مطلوب مورد استفاده قرار گیرند. مدل‌های متعددی برای شبیه‌سازی پیکره‌های آبی بسط داده شده و مورد استفاده قرار گرفته‌اند (Wang *et al.*, 2014). برای شبیه‌سازی مخازن که غالباً پیکره‌های آبی طویل با عمق نسبتاً زیاد و دارای لایه‌بندی کیفی

مدل‌های شبیه‌سازی هیدرودینامیک و کیفیت آب ابزارهایی هستند که به کمک آن‌ها می‌توان وضعیت پیکره‌های آبی را تحت تأثیر عوامل آلاینده پیش‌بینی نموده و با مدیریت این عوامل کیفیت را ارتقا بخشید (Emamgholizadeh *et al.*, 2014; Jeznach *et al.*, 2016). کیفیت آب مخازن سدها در بلند مدت متأثر از نحوه بهره‌برداری (Yousefi *et al.*, 2019)، اندرکنش آب با محیط پیرامون و ورود آلاینده‌های ناشی از بارگذاری‌های موضعی یا گسترده در حوضه است (Sedlá and Nováková, 2017). علاوه بر این، محیط مخزن به دلیل تماس همیشگی آب، اثرات مهمی بر کیفیت مخزن داشته که با شروع آبیگری آغاز شده و می‌تواند در بلند مدت ادامه داشته باشد. یکی از نمونه‌های نادر از این نوع، سد گتوند بوده که با شروع آبیگری، محیط مخزن در

\* نویسنده مسئول: j\_samani@modares.ac.ir

مدل شبیه‌سازی اصلی به منظور کاستن از زمان محاسبات توسعه یافته و رواج پیدا کرده است (Razavi *et al.*, 2012). مدل‌های جایگزین با تقلید عملکرد مدل اصلی که مبتنی بر فیزیک مسئله است، در زمانی به مراتب کم‌تر، شرایط مخزن را شبیه‌سازی می‌کنند. دو هدف اصلی مدل‌های جایگزین را می‌توان حفظ دقت مطلوب مدل‌های فیزیکی و دیگری کاهش زمان محاسبات برشمرد.

شبکه‌های عصبی مصنوعی به عنوان ابزاری ریاضی که بر اساس عملکرد شبکه‌های عصبی زیستی مطرح شده‌اند، توانایی بالایی در حفظ، یادگیری و فراخوانی داده‌ها دارند (Boussaada *et al.*, 2018) و مدل جایگزین بسیار مناسبی برای CE-QUAL-W2 بوده و هزینه‌های محاسباتی را کاهش می‌دهند (Saadatpour *et al.*, 2017). یکی از روش‌های شبکه عصبی مورد استفاده برای پیش‌بینی فرآیندهای دینامیک روش NARX<sup>۳</sup> است. مهم‌ترین مزیت این مدل قابلیت آن در شبیه‌سازی مسائل نوسانی غیر خطی و متغیر با زمان بوده (Parlos *et al.*, 2000) و در رشته‌های مهندسی برق (Andalib and Atry, 2009)، فناوری اطلاعات (Amani *et al.*, 2011)، تجارت و بررسی بازار سهام (Ahmadi *et al.*, 2016) و... بکار رفته است. در مسائل مرتبط با آب و هیدرولوژی نیز استفاده از مدل NARX گزارش شده است. (Shaw *et al.*, 2017) از این مدل به عنوان مدل جایگزین CE-QUAL-W2 برای شبیه‌سازی غلظت اکسیژن محلول<sup>۴</sup> خروجی از مخزن در یک دوره زمانی ۱۰ روزه استفاده کرده‌اند. در تحقیق انجام شده توسط (Banihabib *et al.*, 2017) از این مدل به منظور پیش‌بینی جریان روزانه در حوضه دز استفاده شده است. همچنین (Guzman *et al.*, 2017) با بکارگیری این مدل و استفاده از داده‌های سطح ایستابی و میزان بارش در یک دوره هشت ساله توانستند تراز سطح آب در زمین‌های زراعی می‌سی‌سی‌پی را برای سه ماه بعد پیش‌بینی کنند. همچنین (Alarcon, 2019) با استفاده از مدل NARX و بهره‌گیری از داده‌های تاریخی، غلظت کل رسوبات معلق جریان را پیش‌بینی کرده است. تاکنون استفاده از این مدل به منظور شبیه‌سازی نتایج مدل‌های فیزیکی که شرایط کیفی خروجی از مخازن دارای لایه‌بندی شدید شوری را در بلند مدت مدل‌سازی می‌کنند، گزارش نشده است.

در این تحقیق تغییرات بلند مدت غلظت کل مواد جامد محلول<sup>۵</sup>، TDS، خروجی از مخزنی که امکان آبیگری هم‌زمان از ترازهای مختلف را دارد، با استفاده از مدل CE-QUAL-W2

هستند، مدل‌های دوبعدی که در آن‌ها فرض همگنی عرضی اعمال شده مناسب است (Kim and Kim, 2017). مدل CE-QUAL-W2 به عنوان یک مدل شبیه‌سازی دو بعدی هیدرودینامیکی و کیفی متوسط‌گیری شده در عرض (Park *et al.*, 2014) در بسیاری از تحقیقات، کاربردهای عملی و مسائل مرتبط با پیکره‌های آبی دارای لایه‌بندی کیفی مانند سدها، دریاچه‌ها و مخازن مورد استفاده قرار گرفته (Ma *et al.*, 2015) است. CE-QUAL-W2 به عنوان یک مدل با اطمینان‌پذیری بالا<sup>۱</sup> در مسائل بزرگ مقیاس و برای شبیه‌سازی دوره‌های زمانی بلند مدت بکار رفته (Afshar *et al.*, 2011) و می‌تواند تغییر شرایط کمی و کیفی را با توجه به الگوی بهره‌برداری از مخزن پیش‌بینی کند.

در بسیاری از کاربردهای عملی، در راستای بهینه کردن الگوی بهره‌برداری از مخازن لازم است تا مدل‌های شبیه‌سازی در قالب یک مدل بهینه‌سازی مورد استفاده قرار گرفته (Dhar and Datta, 2008) که اصطلاحاً به آن‌ها روش‌های شبیه‌سازی-بهینه‌سازی گفته می‌شود. با این شیوه می‌توان با استفاده از نتایج مدل شبیه‌سازی، تابع هدف مسئله بهینه‌سازی را برآورد نموده و بهره‌برداری بهینه را تعیین کرد. اهمیت ترکیب روش‌های شبیه‌سازی و بهینه‌سازی در تحقیقات مختلف نشان داده و اثبات شده که این شیوه به جواب‌های بهتری منجر می‌شود (Rani and Madalena, 2010). وابستگی شرایط کمی و کیفی مخازن سدها به پارامترهای متعدد و وجود ذی‌نفعان دارای اهداف و کاربری‌های متفاوت، مسئله بهره‌برداری از مخازن را به مسئله‌ای پیچیده با محدودیت‌های مختلف تبدیل می‌کند (Karamouz *et al.*, 2014). این پیچیدگی‌ها سبب شده تا در مسائل مدیریت منابع آب استفاده از روش‌های تکاملی به عنوان روش‌های بهینه‌سازی کارآمد، مورد استفاده قرار گیرد (Schardong and Simonovic, 2015) به طوری که در بسیاری از مسائل واقعی بهینه‌سازی استفاده از آن‌ها حیاتی است (Horne *et al.*, 2016).

صرف‌نظر از پیچیدگی‌های موجود در روش‌های بهینه‌سازی تکاملی، استفاده از مدل‌های شبیه‌سازی در قالب روش‌های بهینه‌سازی هزینه محاسبات را افزایش می‌دهد (Afshar and Masoumi, 2016). این مشکل در مسائل بزرگ مقیاس که تعداد پارامترهای زمانی یا مکانی بیش‌تر است، حادث‌تر بوده (Zhang *et al.*, 2017) و کاربرد روش‌های شبیه‌سازی-بهینه‌سازی را در اجرای مسائل واقعی با محدودیت روبرو می‌کند (Wu *et al.*, 2015). به همین دلیل استفاده از فرامدل‌ها یا مدل‌های جایگزین<sup>۲</sup>

4. Dissolved Oxygen (DO)  
۵ Total Dissolved Solids (TDS)

1. High Fidelity Model  
2. Surrogate or meta models  
3. Nonlinear AutoRegressive with eXogenous input (NARX)

بررسی شده است. روند اتخاذ روش‌های به کار رفته در این تحقیق در شکل (۱) ارائه و در ادامه این بخش توضیحات آن‌ها ارائه شده است.

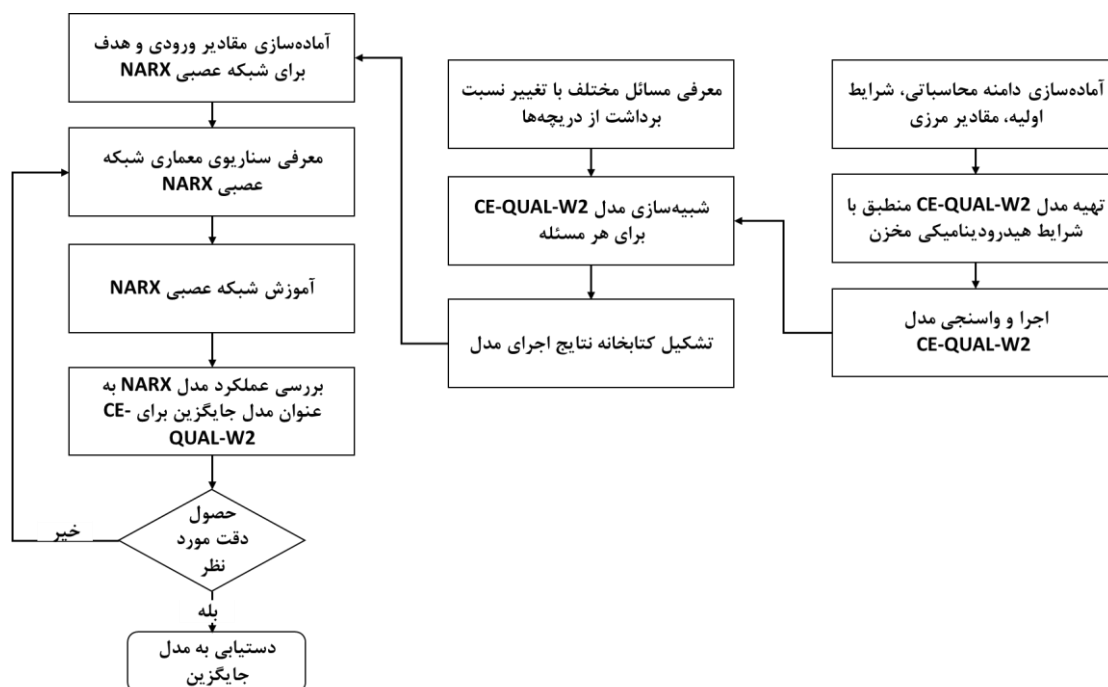
#### مدل CE-QUAL-W2

مدل CE-QUAL-W2 یک مدل شبیه‌سازی دو بعدی هیدرودینامیکی و کیفی متوسط‌گیری شده در عرض است که با همکاری مرکز تحقیقات آبراهه‌های رسته مهندسی ارتش آمریکا<sup>۱</sup> و دانشگاه ایالتی پرتلند تهیه شده است (Soleimani *et al.*, 2018). این مدل بر اساس فرض همگنی عرضی خصوصیات جریان بسط داده شده و برای شبیه‌سازی پیکره‌های آبی نسبتاً باریک و طولانی که دارای تغییرات (گرادیان) کیفیت در راستای ارتفاع و طول هستند مناسب است (Ma *et al.*, 2015). این مدل به فراوانی برای شبیه‌سازی شرایط کیفی رودخانه، دلتا، دریاچه، مخزن و سیستم‌های مخزن-رودخانه استفاده شده (Amirkhani *et al.*, 2016) و با توجه به قابلیت آن برای مدل‌سازی جریان‌های شور، برای شبیه‌سازی کیفی-هیدرودینامیکی تلاقی آب شور و شیرین در محل اتصال رودخانه به دریا نیز به کار رفته است (Haddout and Maslouhi, 2017).

مدل NARX به عنوان مدل جایگزین شبیه‌سازی شده است. با بکارگیری این دو مدل برای یک مسئله واقعی بهره‌برداری از مخزن در یک دوره زمانی ۱۰ ساله، قابلیت مدل جایگزین NARX برای شبیه‌سازی نتایج مدل فیزیکی CE-QUAL-W2 مورد بررسی قرار گرفته است. بررسی نتایج با استفاده از پارامترهای آماری و مقایسه مدت زمان اجرای هر دو مدل برای یک مسئله مشابه صورت گرفته است که نتایج آن در ادامه ارائه شده است.

#### مواد و روش‌ها

به منظور تهیه مدل شبیه‌سازی عددی مبتنی بر فیزیک مسئله، ابتدا با استفاده از شرایط مرزی و دامنه محاسباتی مخزن، ورودی‌های مدل CE-QUAL-W2 آماده و این مدل با توجه به داده‌های میدانی برداشت شده از مخزن واسنجی شده است. سپس با تعریف مسائل مختلف که نحوه بهره‌برداری ماهیانه از آن‌ها با هم تفاوت داشته، کتابخانه‌ای از مسائل و نتایج آن‌ها تهیه شده است. برای تعیین مدل جایگزین، معماری‌های متفاوتی برای شبکه عصبی NARX در نظر گرفته شده و با استفاده از کتابخانه نتایج، آموزش و اعتبارسنجی آن‌ها انجام و با شاخص‌های آماری، عملکرد هر سناریو در برآورد نتایج مدل شبیه‌سازی فیزیکی



شکل ۱- روند نمای تعیین بهترین معماری شبکه برای مدل NARX

پیش‌بینی سری‌های زمانی غیرخطی بسط یافته است. این مدل به صورت بازگشتی عمل نموده و از بازخورد پیش‌بینی‌های صورت گرفته توسط خودش حین آموزش استفاده می‌کند (Parlos *et*

#### شبکه عصبی NARX

مدل NARX یکی از نسخه‌های شبکه عصبی است که برای

شبکه عصبی NARX در گام زمانی  $i$  است.  $\bar{c}$  نیز میانگین داده‌های به دست آمده از مدل CE-QUAL-W2 است.

ضریب NSE به صورت تجربی به دست آمده و مقادیر نزدیک به ۱ بیانگر اطمینان‌پذیری بسیار بالای مدل بوده، اما به طور عمومی هر مقدار بین ۰.۵ تا ۱ به عنوان مقادیر قابل قبول برای عملکرد مدل پذیرفتنی است (Yazdi and Moridi, 2017). همچنین در مطالعات انجام گرفته که عملکرد مدل NARX راضی‌کننده بوده، مقدار شاخص MAPE نزدیک به ۱۰٪ گزارش شده است (Andalib and Atry, 2009).

#### مورد مطالعاتی

سد وزنی گتوند علیا از نوع سنگریزه‌ای با هسته رسی بوده که در شمال دشت خوزستان بر روی رودخانه کارون و در ۱۶ کیلومتری شمال شرق شهر گتوند احداث و در ۶ مرداد ماه ۱۳۹۰ آبیگری آن آغاز شد. در محور سد تراز نرمال و تراز کف رودخانه به ترتیب ۲۳۰ متر و ۸۰ متر از سطح دریا و حجم نرمال مخزن ۴,۶۷ کیلومتر مکعب است. مخزن سد گتوند علیا دارای سه تخلیه‌کننده اصلی شامل آبیگر نیروگاه، دریچه تحتانی و لوله GRP بوده که به ترتیب در ترازهای ۱۵۹، ۱۲۳ و ۹۰ متر از سطح دریا قرار داشته و سرریز سد نیز از نوع قطاعی است. متوسط دبی ورودی رودخانه کارون به مخزن از زمان احداث سد تا انتهای فروردین ماه ۹۸ معادل ۲۷۷ متر مکعب بر ثانیه بوده است. میانگین غلظت کل مواد جامد محلول رودخانه حدود ۶۰۰ میلی‌گرم بر لیتر است (Jalali et al., 2019). در شکل (۲) موقعیت جغرافیایی مخزن سد گتوند و مرز آن در تراز نرمال نشان داده شده است.

#### گنبد نمکی عنبر

در فاصله حدود پنج کیلومتری بالادست محور سد، گنبد نمکی عنبر واقع شده (Aghdam et al., 2012) که با شروع آبیگری سد در تماس با آب قرار گرفته و سبب شده حجم بالایی از شورابه با غلظت بالا به درون مخزن نفوذ کند. به دلیل تجمع شورابه در ترازهای کف مخزن، غلظت شوری در این ناحیه بیش از سه برابر دریای آزاد است. انحلال و ورود حجم بالایی از نمک به مخزن یک سد آب شیرین و وقوع لایه‌بندی شدید شوری یک نمونه نادر در جهان محسوب می‌شود.

به دلیل امکان آبیگری از ترازهای مختلف، در حال حاضر شوری خروجی از مخزن به میزان دبی تخلیه شده از هر آبیگر وابسته است. تغییرات آبی شورابه کف مخزن به میزان شوری ورودی از رودخانه، گنبد نمکی عنبر و میزان تخلیه آن از طریق

(al., 2000) علاوه بر این تأخیر زمانی متغیرهای ورودی و خروجی (یا هدف<sup>۱</sup>) و اثر آن‌ها بر روند‌های شبیه‌سازی را لحاظ می‌کند. اعمال تأخیر در داده‌های ورودی به مدل NARX اشاره به این دارد که متغیری که قرار است پیش‌بینی شود به چه تعداد از متغیر(های) قبل از خود وابسته است. چون این روش بازگشتی بوده و اثرات پیش‌بینی را هم در حین آموزش دخیل می‌کند، برای داده خروجی نیز تأخیر در نظر گرفته می‌شود. به بیان ریاضی، در این مدل مقادیر پیش‌بینی متغیر وابسته به  $n_x$  مقدار از متغیر مستقل و  $n_y$  مقدار از متغیر وابسته بستگی دارد (Xie et al., 2009).  $n_y$  و  $n_x$  به ترتیب بیانگر مرتبه‌ی حافظه‌ی ورودی‌ها و خروجی‌های شبکه عصبی NARX هستند:

(رابطه ۱)

$$y(t) = f(y(t-1), \dots, y(t-n_y), x(t-1), \dots, x(t-n_x))$$

در معادله ۱،  $x(t)$  و  $y(t)$  به ترتیب بیانگر متغیرهای وابسته

و مستقل و  $y(t)$  مقدار متغیر هدف در زمان حاضر است.

این شبکه سه لایه اصلی دارد که شامل لایه ورودی، لایه پنهان و لایه خروجی است. لایه ورودی شامل ورودی‌ها و خروجی‌های حاضر و گذشته است که به لایه‌ی پنهان خوراند می‌شود. لایه‌ی پنهان شامل یک یا چند نرون است که تعداد بهینه آن‌ها معمولاً از طریق سعی و خطا به دست می‌آید. لایه خروجی از ترکیب مقادیر واقع در لایه‌ی پنهان تشکیل شده که به خروجی مورد نظر منجر می‌شود (Amani et al., 2011). معماری شبکه عصبی NARX معرف میزان تأخیر در داده‌های ورودی و خروجی و تعداد نرون‌های لایه پنهان است. در پیشینه تحقیق روش خاصی برای اعمال میزان تأخیر در داده‌های ورودی و خروجی که دستیابی به بهترین معماری شبکه را تضمین کند بیان نشده است. اما با معرفی سناریوهای مختلف برای معماری شبکه و سعی و خطا می‌توان به معماری مطلوب دست یافت.

#### ارزیابی عملکرد مدل NARX

به منظور ارزیابی عملکرد مدل NARX جهت شبیه‌سازی نتایج بلند مدت مدل CE-QUAL-W2 از پارامترهای آماری شامل ضریب تعیین<sup>۲</sup>، میانگین درصدی خطای مطلق<sup>۳</sup>، MAPE، و ضریب بهره‌وری نش-ساتکلیف<sup>۴</sup>، NSE، استفاده شده است:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|c_{model}^i - c_{narx}^i|}{c_{model}^i} \quad (\text{رابطه ۲})$$

$$NSE = 1 - \frac{\sum_{i=1}^n (c_{model}^i - c_{narx}^i)^2}{\sum_{i=1}^n (c_{model}^i - \bar{c})^2} \quad (\text{رابطه ۳})$$

در این معادلات  $n$  تعداد کل داده‌ها،  $c_{model}^i$  مقدار به دست

آمده از مدل CE-QUAL-W2 و  $c_{narx}^i$  مقدار به دست آمده از

3. Mean Absolute Percentage Error (MAPE)

4. Nash-Sutcliffe Efficiency (NSE)

1. Target


2. Correlation Coefficient (R2)

بخش با طول متغیر از ۸۹۰۰ متر در ورودی مخزن تا ۷۰۰ متر در مجاورت بدنه سد تقسیم شده و ضخامت لایه‌ها در هر بخش نیز از ۲ متر در اعماق تا ۵ متر در نزدیکی سطح آب متغیر است. در این شبکه‌بندی از سلول‌های مستطیلی استفاده شده و نوع پیکره آبی به صورت آب شیرین در نظر گرفته شده است. در شکل (۳)، شبکه محاسباتی مخزن شامل بخش‌ها، لایه‌بندی عمقی مخزن و ضخامت لایه‌ها در بخش ۵ نشان داده شده است.

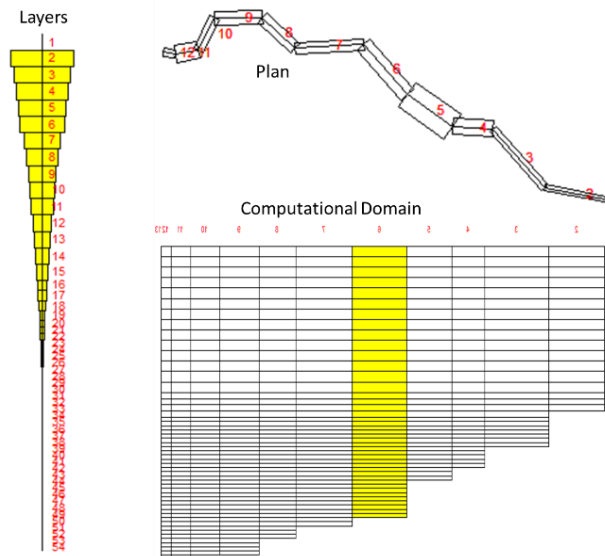
دریچه‌های سد بستگی دارد. اما آنچه مسلم است با انحلال نمک و ورود آن به مخزن، از حجم در معرض آب و دارای پتانسیل ورود به مخزن در آینده کاسته خواهد شد. بررسی وضعیت شوری خروجی از مخزن در بلند مدت، با شبیه‌سازی کیفی مخزن و در نظر گرفتن عوامل ورودی، خروجی، شرایط هندسی و هیدرولیکی مخزن و... امکان‌پذیر است.

### مدل شبیه‌سازی هیدرودینامیکی و کیفی مخزن

به منظور تهیه مدل CE-QUAL-W2، محدوده مخزن به ۱۱



شکل ۲- موقعیت جغرافیایی مخزن گتوند و ساحل آن در تراز نرمال



شکل ۳- شبکه محاسباتی مخزن سد گتوند علیا

شبیه‌سازی نمود. پارامترهای ورودی به مدل برای شبیه‌سازی شرایط کیفی مخزن طی یک دوره بلند مدت ۱۰ ساله در جدول (۱) آورده شده است. این ورودی‌ها از داده‌های بلند مدت ثبت شده هواشناسی، هیدرومتری و نحوه بهره‌برداری از آبگیرهای

### اجرای مدل

پس از تهیه دامنه محاسباتی می‌توان با معرفی ورودی‌های لازم برای اجرای مدل CE-QUAL-W2 شرایط هیدرودینامیکی و کیفی مخزن سد گتوند را تحت اعمال بهره‌برداری‌های مختلف

شبیه‌سازی بلند مدت مخزن برای یک دوره بلند مدت ۱۰ ساله از شروع آبیگری مخزن تا مرداد ۱۴۰۰ انجام می‌گیرد. البته برای اطمینان از نتایج به دست آمده از مدل CE-QUAL-W2 بایستی قبل از این کار واسنجی مدل انجام بگیرد.

### واسنجی مدل

به منظور واسنجی مدل از داده‌های پروفیل شوری و دمای مخزن که طی ماه‌های فروردین، تیر، مرداد، آبان و دی ماه سال‌های ۹۳-۱۳۹۲ برداشت شده استفاده گردید. طی این مدت علاوه بر داده‌های اشاره شده در جدول (۱)، نسبت برداشت از هر یک از دریچه‌های مخزن نیز مشخص بود. به همین دلیل با اعمال بهره‌برداری صورت گرفته، شبیه‌سازی مخزن با استفاده از مدل CE-QUAL-W2 انجام و لایه‌بندی کیفی مخزن به دست آمد. با مقایسه پروفیل‌های شوری و دمای به دست آمده از شبیه‌سازی مخزن و پروفیل‌های برداشت شده، واسنجی و تدقیق پارامترهای مدل انجام شد. پس از واسنجی مدل، مقادیر پارامترهای هیدرودینامیکی تدقیق گردید که نتایج آن در جدول (۲) ارائه شده است.

جدول ۲- پارامترهای واسنجی شده مدل CE-QUAL-W2 برای مخزن گتوند

ضریب	نماد ضریب در مدل	پیشنهاد مدل	پس از واسنجی
سپری باد	WSC	۰/۵-۱	۰/۷
ویسکوزیته گردابه‌ای افقی	AX	۱	۱/۱
پخشیدگی گردابه‌ای افقی	DX	۱	۰/۹۵
تبادل حرارتی رسوب	CBHE	۰/۳	۰/۳۵
دمای رسوب	TSED	۱۰	۱۴
a در فرمول سرعت باد	AFW	۹/۲	۹/۵۵
b در فرمول سرعت باد	BFW	۰/۴۶	۰/۶
c در فرمول سرعت باد	CFW	۲	۲/۵۴

است.

### تهیه مدل NARX

با تغییر نحوه بهره‌برداری از آبیگرها، نسبت برداشت ماهیانه از هر آبیگر و به تبع آن میزان شوری کل جریان خروجی از مخزن تغییر خواهد کرد. در این صورت با اعمال الگوهای مختلف بهره‌برداری می‌توان مسائل متعددی تعریف نمود که مقادیر دبی ورودی به مخزن، شرایط هواشناسی، دبی کل خروجی از مخزن و شرایط اولیه اعمال شده در آن‌ها یکسان است. در هر ماه مقدار کل جریان خروجی از مخزن که توسط سه آبیگر سد تخلیه می‌شود، مشخص است. اما برای تعریف مسائل متعدد با بهره‌برداری متفاوت، در هر ماه سهم هر آبیگر از کل جریان تخلیه شده از مخزن متفاوت بوده و نسبت برداشت ماهیانه هر آبیگر به صورت تصادفی تعیین شده است. پس از تعریف این مسائل و اجرای آن‌ها با مدل CE-

مخزن استخراج شده‌اند. البته به دلیل اینکه داده‌های بهره‌برداری از مخزن و میزان کل جریان خروجی کم‌تر از ۱۰ سال است، این پارامتر با توجه به روند بهره‌برداری از مخزن طی سال‌های گذشته، فرض شده است.

### جدول ۱- پارامترهای ورودی مدل CE-QUAL-W2 برای شبیه‌سازی بلند مدت مخزن گتوند

پارامتر ورودی	گام زمانی داده‌های ورودی به مدل
هواشناسی:	سه ساعته
سرعت و جهت باد، دمای هوا، نقطه شبنم، میزان ابرناکی	روزانه
دبی، دما و غلظت جریان‌های ورودی به مخزن	ماهانه
مجموع دبی برداشتی از مخزن	

شورابه ناشی از انحلال گنبد نمکی عنبر به صورت جریان جانبی در مدل اعمال شده است (Asadi et al., 2020). همچنین با در نظر گرفتن دریچه‌های مخزن در ترازهای مختلف، امکان برداشت انتخابی از سد فراهم شده است. با توجه به اینکه گام زمانی جریان برداشتی از مخزن ماهیانه بوده، کل دبی خروجی از آبیگرها و نسبت برداشت از هر آبیگر طی یک ماه ثابت است.

به دلیل تغییرات هیدرودینامیکی درون مخزن و اثر آن بر غلظت خروجی، میزان غلظت کل تخلیه شده از مخزن به صورت روزانه به دست آمده است. میزان غلظت کل جریان خروجی از مخزن تابع نحوه بهره‌برداری از آبیگرهای مخزن و میانگین وزنی غلظت تخلیه شده از آبیگرهای سد است:

(رابطه ۴)

$$C_{total} = \frac{C_{pwr} \times q_{pwr} + C_{btm} \times q_{btm} + C_{grp} \times q_{grp}}{q_{pwr} + q_{btm} + q_{grp}}$$

در معادله ۴،  $C_{total}$  غلظت کل جریان خروجی از مخزن بر حسب میلی‌گرم بر لیتر،  $C_{pwr}$  و  $q_{pwr}$ ،  $C_{btm}$ ،  $q_{btm}$  و  $C_{grp}$  و  $q_{grp}$  به ترتیب دبی و غلظت کل مواد جامد محلول خروجی از آبیگرهای نیروگاه، تحتانی و لوله GRP هستند. در این معادله منظور از غلظت همان TDS و واحد آن بر حسب میلی‌گرم بر لیتر

سناریو با استفاده از ۹۰٪ مسائل موجود در کتابخانه آموزش دیده است. سپس در هر سناریوی شبکه عصبی تمام مسائل قسمت آزمایش و آموزش اجرا و با استفاده از نتایج مدل CE-QUAL-W2 شاخص‌های آماری برای هر مسئله تعیین شده است. در ادامه جهت مقایسه عملکرد سناریوهای مختلف، میانگین شاخص‌های آماری ۹ مسئله‌ی قسمت آزمایش که هر بار با یک سناریو اجرا شده‌اند به دست آمده است. نتایج شاخص‌های آماری در جدول (۳) ارائه شده است.

اطلاعات اولیه ورودی شبکه عصبی شامل تعدادی از ورودی‌های مدل CE-QUAL-W2 از قبیل پارامترهای هواشناسی، دبی جریان خروجی از هر آبگیر و نتایج شوری کل جریان خروجی از مخزن است. پس از تکمیل فرآیند آموزش در هر سناریو، مدل شبکه عصبی به دست آمده تنها قسمتی از اطلاعات ورودی برای هر مسئله را دریافت کرده و مقادیر شوری خروجی از مخزن را به عنوان هدف شبکه عصبی محاسبه می‌کند.

QUAL-W2، کتابخانه‌ای از مسائل شبیه‌سازی شده و نتایج بلند مدت شوری خروجی از مخزن به دست خواهد آمد. از این کتابخانه یا اصطلاحاً بانک داده‌ای به منظور تهیه شبکه عصبی جایگزین برای مدل CE-QUAL-W2 استفاده می‌شود. در اینجا ۹۰ مسئله مختلف به منظور تهیه کتابخانه نتایج معرفی گردید. با شبیه‌سازی هر مسئله، نتایج روزانه غلظت کل خروجی از مخزن در یک دوره زمانی ۱۰ ساله به دست آمد. ۹۰٪ مسائل کتابخانه نتایج به منظور آموزش<sup>۱</sup> شبکه عصبی و ۱۰٪ باقیمانده که در فرآیند آموزش شرکت نکرده‌اند، به عنوان قسمت آزمایش، برای آزمون عملکرد<sup>۲</sup> شبکه به کار گرفته شد.

### نتایج و بحث

برای دستیابی به بهترین شبکه عصبی NARX حالت‌های مختلفی از تعداد نرون‌ها و میزان تأخیر در داده‌های ورودی و هدف که معماری شبکه را تشکیل می‌دهند، قابل اعمال است. در اینجا ۸ سناریو برای معماری شبکه عصبی معرفی شده و هر

جدول ۳- نتایج عملکرد مدل NARX در سناریوهای مختلف معماری شبکه عصبی

سناریو	تأخیر داده ورودی	تأخیر داده هدف	تعداد نرون لایه پنهان	MAPE		R <sup>2</sup>		NSE	
				آموزش	آزمایش	آموزش	آزمایش	آموزش	آزمایش
Sc1	۱	۱۰	۱۵	۴/۵	۱۰/۷	۰/۹۹	۰/۹۲	۰/۸۵	۰/۷۰
Sc2	۱	۱۰	۱۸	۴/۹	۱۰/۹	۰/۹۸	۰/۹۱	۰/۸۲	۰/۷۰
Sc3	۱	۲۰	۱۵	۴/۳	۹/۳	۰/۹۹	۰/۹۵	۰/۹۱	۰/۷۸
Sc4	۱	۲۰	۱۸	۳/۹	۸/۷	۰/۹۹	۰/۹۵	۰/۹۲	۰/۷۹
Sc5	۲	۱۰	۱۵	۵/۱	۱۰/۱	۰/۹۷	۰/۹۳	۰/۸۰	۰/۷۴
Sc6	۲	۱۰	۱۸	۴/۷	۱۱/۰	۰/۹۹	۰/۹۳	۰/۸۴	۰/۷۱
Sc7	۲	۲۰	۱۰	۴/۳	۱۰/۶	۰/۹۹	۰/۹۲	۰/۸۹	۰/۷۱
Sc8	۲	۲۰	۱۵	۴/۱	۹/۷	۰/۹۹	۰/۹۴	۰/۸۹	۰/۷۵

مقادیر میانگین ماهیانه دبی و غلظت کل مواد جامد محلول ورودی به مخزن سد برای دوره شبیه‌سازی از سال ۱۳۹۰ تا ۱۴۰۰ در شکل (۴) نشان داده شده است.

همچنین در شکل (۵) میزان تخلیه ماهیانه صورت گرفته از هر یک از آبگیرهای مخزن طی دوره ۱۰ ساله شبیه‌سازی نشان داده شده است.

میزان دبی تخلیه شده از هر آبگیر متناسب با بهره‌برداری صورت گرفته از مخزن و ظرفیت تخلیه آن آبگیر است. به همین دلیل میزان دبی تخلیه لوله GRP بسیار کم‌تر از دو آبگیر تحتانی و نیروگاه است. بیش‌تر حجم جریان توسط آبگیرهای تحتانی و نیروگاه از مخزن تخلیه شده و نسبت برداشت آن‌ها در هر ماه متفاوت است. همین امر بر پیچیدگی مسئله افزوده و نوسانات غیر

با توجه به نتایج به دست آمده از جدول (۳)، سناریوهای مختلف ارائه شده برای معماری شبکه عصبی، هم‌روندی خوبی بین مقادیر پیش‌بینی شده و به دست آمده از مدل CE-QUAL-W2 را نشان داده به طوری که ضریب تعیین همواره بیش از ۰/۹۱ است. در سناریوی چهارم ضریب تعیین به دست آمده بیش‌تر و میانگین درصدی خطای مطلق کم‌تر از سایر سناریوها بوده و به عنوان سناریوی منتخب به کار گرفته شده است.

### به کارگیری مدل NARX

به منظور بررسی عملکرد مدل شبکه عصبی NARX، نتایج شبیه‌سازی این مدل برای یک مسئله بلند مدت، با نتایج مدل CE-QUAL-W2 که برای همان مسئله اجرا شده، مقایسه شد.

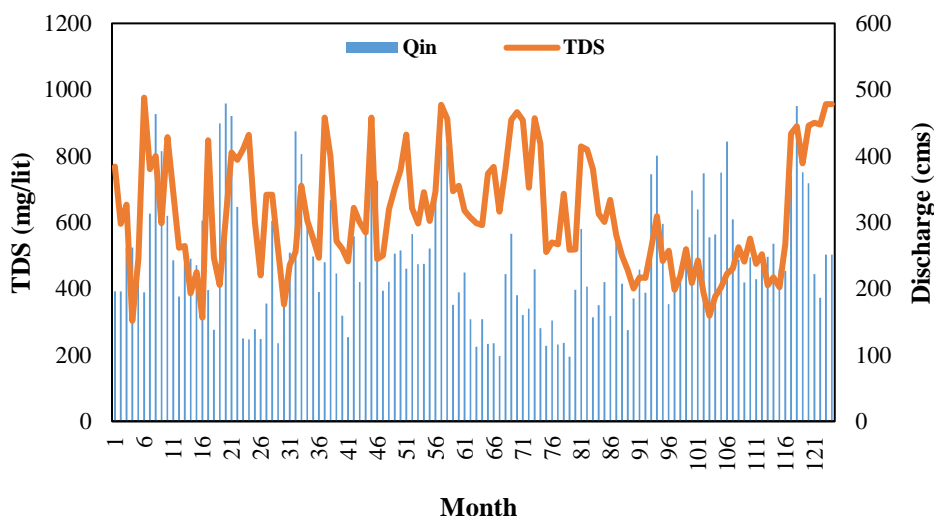


شده است. برای نشان دادن نحوه عملکرد شبکه عصبی NARX برای شبیه‌سازی بلند مدت شوری خروجی از مخازن، نتایج روزانه به دست آمده برای TDS کل جریان خروجی از مخزن با نتایج مدل CE-QUAL-W2 مقایسه شده که سری زمانی آن‌ها در شکل (۶) قابل مشاهده است.

خطی بیش‌تری در سری زمانی شوری تخلیه شده از مخزن ایجاد خواهد کرد. در این مسئله خاص، میانگین برداشت ماهیانه صورت گرفته از دریاچه تحتانی، دریاچه نیروگاه و لوله GRP به ترتیب ۱۳۵، ۱۰۹ و ۰/۱ متر مکعب بر ثانیه بوده است.

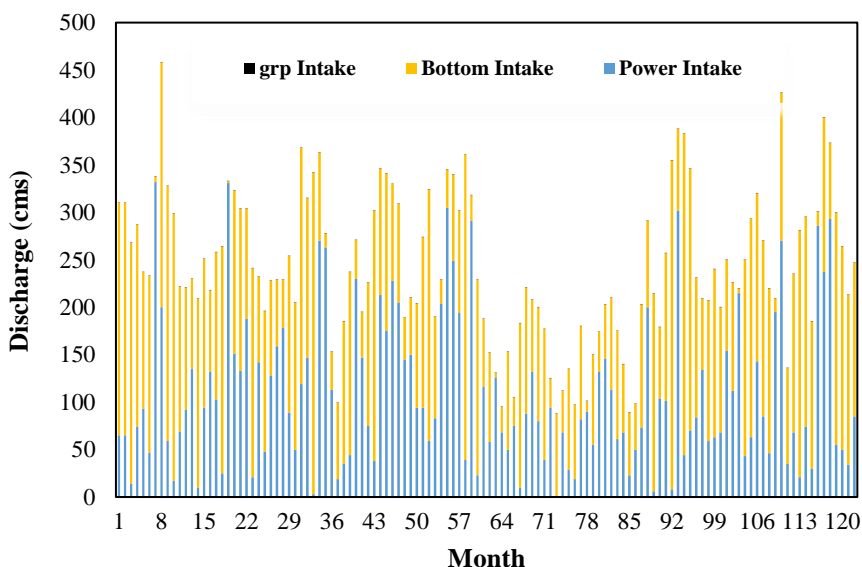
با توجه به اینکه میزان تغییرات شوری خروجی از مخزن به صورت روزانه توسط مدل CE-QUAL-W2 محاسبه می‌شود، شبکه عصبی نیز با همین گام زمانی آموزش دیده و اعتبارسنجی

میانگین ماهیانه دبی و غلظت جریان ورودی




شکل ۴- مقادیر دبی و غلظت کل مواد جامد محلول ورودی از رودخانه به مخزن در دوره بلند مدت شبیه‌سازی

دبی ماهیانه تخلیه‌شده از دریاچه‌های مخزن



شکل ۵- نمودار میزان دبی ماهیانه تخلیه شده از هر یک از آبگیرهای مخزن



شکل ۶- تغییرات روزانه TDS خروجی از مخزن در کل دوره شبیه‌سازی براساس نتایج مدل فیزیکی CE-QUAL-W2 و مدل شبکه عصبی NARX

مدل شبیه‌سازی CE-QUAL-W2 را در یک مسئله بهینه‌سازی با ۵۰ عضو و ۵۰۰ نسل مورد استفاده قرار دهیم، لازم است تا مدل ۲۵۰۰۰ بار اجرا شود. در این صورت حداقل به  $1/745 \times 10^4$  ثانیه معادل ۲۰۲ روز زمان نیاز است. این در حالی است که در تحقیق حاضر، برای تهیه کتابخانه نتایج تنها ۹۰ بار مدل CE-QUAL-W2 اجرا شده است. حال با بکارگیری شبکه عصبی NARX به عنوان مدل جایگزین که قابلیت آن با توجه به نتایج تأیید شده، مدت اجرای همان مسئله بهینه‌سازی، به ۲/۸ ساعت تقلیل می‌یابد.

### نتیجه‌گیری

در این تحقیق از شبکه عصبی NARX به عنوان مدل جایگزین برای CE-QUAL-W2 استفاده شده تا روند غیرخطی و کاملاً نوسانی غلظت مواد جامد محلول خروجی از مخزن را در بلند مدت پیش‌بینی کند. با مقایسه نتایج هر دو مدل در سناریوهای مختلف ارائه شده برای معماری شبکه، ضریب تعیین همواره بیش از ۰/۹۱ بوده و شبکه عصبی NARX روند شوری خروجی از مخزن را در بلند مدت به خوبی برآورد می‌کند. در ۸ سناریو بررسی شده برای معماری شبکه عصبی، به طور میانگین مقدار شاخص MAPE برابر با ۱۰/۱ درصد و ضریب نش-ساتنکلیف ۰/۷۳ به دست آمده است. از بین سناریوهای معرفی شده، سناریوی چهارم که در داده ورودی و خروجی به ترتیب ۱ و ۲۰ روز تأخیر ایجاد کرده و دارای

این مسئله خاص مربوط به مسئله شماره ۸۶ از مسائل مورد استفاده برای اعتبارسنجی بوده و در روند آموزش شبکه عصبی NARX شرکت نکرده است. به دلیل تأخیر اعمال شده برای مقادیر ورودی بر اساس معماری شبکه در سناریوی چهارم، شبکه عصبی ۲۰ روز اولیه شبیه‌سازی را به عنوان شرایط اولیه از نتایج مدل فیزیکی دریافت نموده اما مابقی مدت شبیه‌سازی یعنی بالغ بر ۳۶۳۰ روز آتی را پیش‌بینی کرده است. با مقایسه نتایج پیش‌بینی شده توسط مدل شبکه عصبی و مدل W2، در این مسئله میانگین درصدی خطای مطلق ۵ درصد، ضریب نش-ساتنکلیف ۰/۹۳ و ضریب تعیین ۰/۹۶ به دست آمد. این مقادیر بیانگر عملکرد مناسب مدل شبکه عصبی در برآورد نتایج مدل فیزیکی است. انطباق مناسب منحنی‌های شوری کل خروجی از مخزن که با استفاده از هر دو مدل دست آمده‌اند این نکته را تأیید می‌کند.

با اجرای مدل فیزیکی CE-QUAL-W2 با استفاده از یک رایانه رومیزی<sup>۱</sup> ۶۴ بیتی Intel Core i5-2450M @2.5GHz مدت زمان اجرای این مسئله ۶۹۸ ثانیه زمان می‌برد. اجرای همین مسئله با استفاده از مدل جایگزین، ۰/۴۰۴ ثانیه به طول می‌انجامد که هزینه محاسباتی به نسبت کم‌تری دارد. به عبارت دیگر با تهیه مدل جایگزین NARX، مدت زمان اجرای یک دوره ۱۰ ساله شبیه‌سازی مخزن کم‌تر از ۰/۰۶ درصد زمان لازم برای اجرای همان مسئله با استفاده از مدل فیزیکی است. بنابر این اگر

نتایج مدل فیزیکی را با دقت قابل قبولی پیش‌بینی نموده، در عین حال مدت زمان اجرای برنامه را به شدت کاهش داده است. لذا مدل NARX را می‌توان به عنوان یک مدل جایگزین مناسب برای CE-QUAL-W2 معرفی نموده که می‌تواند شوری خروجی از مخازن سدها را در بلند مدت با دقت مناسب پیش‌بینی و در عین حال هزینه محاسباتی را کاهش دهد.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

## REFERENCES

- Afshar, A., Kazemi, H., & Saadatpour, M. (2011). Particle Swarm Optimization for Automatic Calibration of Large Scale Water Quality Model (CE-QUAL-W2): Application to Karkheh Reservoir, Iran. *Water Resources Management*, 25(10), 2613–2632. <https://doi.org/10.1007/s11269-011-9829-7>.
- Afshar, A., & Masoumi, F. (2016). Waste load reallocation in river–reservoir systems: simulation–optimization approach. *Environmental Earth Sciences*, 75(1), 1–14. <https://doi.org/10.1007/s12665-015-4812-x>.
- Aghdam, J. A., Zare, M., Capaccioni, B., Raeisi, E., & Forti, P. (2012). The Karun River waters in the Ambal ridge region ( Zagros mountain Range , southwestern Iran ): mixing calculation and hydrogeological implications, 251–267. <https://doi.org/10.1007/s13146-012-0083-8>.
- Ahmadi, E., Abooi, M. H., Jasemi, M., & Mehrjardi, Y. Z. (2016). A Nonlinear Autoregressive Model with Exogenous Variables Neural Network for Stock Market Timing: The Candlestick Technical Analysis, 29(12), 1717–1725.
- Alarcon, V. J. (2019). Predicting Sediment Concentrations Using a Nonlinear Autoregressive Exogenous Neural Network. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics) (Vol. 11621 LNCS). Springer International Publishing. [https://doi.org/10.1007/978-3-030-24302-9\\_42](https://doi.org/10.1007/978-3-030-24302-9_42).
- Amani, P., Kihl, M., & Robertsson, A. (2011). NARX-based Multi-step Ahead Response Time Prediction for Database Servers. In [Host Publication Title Missing] (Pp. 813-818). *IEEE--Institute of Electrical and Electronics Engineers Inc.* <https://doi.org/10.1109/ISDA.2011.6121757>.
- Amirkhani, M., Haddad, O. B., Ashofteh, P.-S., & Lo?iciga, H. A. (2016). Determination of the optimal level of water releases from a reservoir to control water quality. *Journal of Hazardous, Toxic, and Radioactive Waste*, 20(2), 1–7. [https://doi.org/10.1061/\(ASCE\)HZ.2153-5515.0000295](https://doi.org/10.1061/(ASCE)HZ.2153-5515.0000295).
- Andalib, A., & Atry, F. (2009). Multi-step ahead forecasts for electricity prices using NARX : A new approach , a critical analysis of one-step ahead forecasts. *Energy Conversion and Management*, 50(3), 739–747. <https://doi.org/10.1016/j.enconman.2008.09.040>.
- Asadi, M., Samani, J.M. V., Samani, H.M.V., 2020. Investigation of Solutions for Introducing Concentrated Side-Inflows to Reservoirs in The 2D Hydrodynamic and Qualitative CE-QUAL-W2 Model, Case Study: Upper Gotvand Dam (In Farsi). In: Proceedings of 18th Iranian Hydraulic Association, 5-6 Feb, Tehran University, Tehran, Iran.
- Banihabib, M. E., Ahmadian, A., & Jamali, F. S. (2017). Hybrid DARIMA-NARX model for forecasting long-term daily inflow to Dez reservoir using the North Atlantic Oscillation (NAO) and rainfall data. *GeoResJ*, 13, 9–16. <https://doi.org/10.1016/j.grj.2016.12.002>.
- Boussaada, Z., Curea, O., Remaci, A., Camblong, H., & Bellaaj, N. M. (2018). Daily Direct Solar Radiation. *MDPI*, (energies). <https://doi.org/10.3390/en11030620>.
- Castelletti, A., Pianosi, F., Soncini-Sessa, R., & Antenucci, J. P. (2010). A multiobjective response surface approach for improved water quality planning in lakes and reservoirs. *Water Resources Research*, 46(6), 1–16. <https://doi.org/10.1029/2009WR008389>.
- Dhar, A., & Datta, B. (2008). Optimal operation of reservoirs for downstream water quality control using linked simulation optimization, 853(June 2007), 842–853. <https://doi.org/10.1002/hyp>.
- Emamgholizadeh, S., Kashi, H., Marofpoor, I., & Zalaghi, E. (2014). Prediction of water quality parameters of Karoon River ( Iran ) by artificial intelligence-based models, 645–656. <https://doi.org/10.1007/s13762-013-0378-x>.
- Guzman, S. M., Paz, J. O., & Tagert, M. L. M. (2017). The Use of NARX Neural Networks to Forecast Daily Groundwater Levels. *Water Resources Management*, 31(5), 1591–1603. <https://doi.org/10.1007/s11269-017-1598-5>.
- Haddout, S., & Maslouhi, A. (2017). Two-dimensional modeling of the vertical circulation of salt intrusion in the Sebou estuary under different hydrological conditions. *ISH Journal of Hydraulic Engineering*, 5010(October), 1–18. <https://doi.org/10.1080/09715010.2017.1391134>.
- Horne, A., Szemis, J. M., Kaur, S., Webb, J. A., Stewardson, M. J., Costa, A., & Boland, N. (2016). Environmental Modelling & Software Optimization tools for environmental water decisions : A review of strengths, weaknesses, and opportunities to improve adoption. *Environmental Modelling and Software*, 84, 326–338. <https://doi.org/10.1016/j.envsoft.2016.06.028>.
- Jalali, L., Zarei, M., & Guti, F. (2019). Salinization of reservoirs in regions with exposed evaporites . The

- unique case of Upper Gotvand Dam , Iran, 157. <https://doi.org/10.1016/j.watres.2019.04.015>.
- Jeznach, L. C., Jones, C., Matthews, T., Tobiasson, J. E., & Ahlfeld, D. P. (2016). A framework for modeling contaminant impacts on reservoir water quality. *JOURNAL OF HYDROLOGY*, 537, 322–333. <https://doi.org/10.1016/j.jhydrol.2016.03.041>.
- Karamouz, M., Nazif, S., Sherafat, M. A., & Zahmatkesh, Z. (2014). Development of an Optimal Reservoir Operation Scheme Using Extended Evolutionary Computing Algorithms Based on Conflict Resolution Approach: A Case Study. *Water Resources Management*, 28, 3539–3554. <https://doi.org/10.1007/s11269-014-0686-z>.
- Kim, Y., & Kim, B. (2017). Lake and Reservoir Management Application of a 2-Dimensional Water Quality Model ( CE-QUAL-W2 ) to the Turbidity Interflow in a Deep Reservoir ( Lake Soyang , Korea ) Application of a 2-Dimensional Water Quality Model ( CE-QUAL-W2) to the Turbidity Inter. *Lake and Reservoir Management*, 2381(March). <https://doi.org/10.1080/07438140609353898>.
- Ma, J., Liu, D., Wells, S. A., Tang, H., Ji, D., & Yang, Z. (2015). Modeling density currents in a typical tributary of the Three Gorges. *Ecological Modelling*, 296, 113–125. <https://doi.org/10.1016/j.ecolmodel.2014.10.030>.
- Park, Y., Hwa, K., Kang, J., Won, S., & Ha, J. (2014). Science of the Total Environment Developing a flow control strategy to reduce nutrient load in a reclaimed multi-reservoir system using a 2D hydrodynamic and water quality model. *Science of the Total Environment*, The, 466–467, 871–880. <https://doi.org/10.1016/j.scitotenv.2013.07.041>.
- Parlos, A. G., Rais, O. T., & Atiya, A. F. (2000). Multi-step-ahead prediction using dynamic recurrent neural networks. *Neural Networks*, (February 2015). <https://doi.org/10.1109/IJCNN.1999.831517>.
- Rani, D., & Madalena, M. (2010). Simulation – Optimization Modeling: A Survey and Potential Application in Reservoir Systems Operation, 1107–1138. <https://doi.org/10.1007/s11269-009-9488-0>.
- Razavi, S., Tolson, B. A., & Burn, D. H. (2012). Review of surrogate modeling in water resources, 48(October 2011). <https://doi.org/10.1029/2011WR011527>.
- Saadatpour, M., Afshar, A., & Edinger, J. E. (2017). Meta-Model Assisted 2D Hydrodynamic and Thermal Simulation Model ( CE-QUAL-W2 ) in Deriving Optimal Reservoir Operational Strategy in Selective Withdrawal Scheme. *Water Resources Management*, 2729–2744. <https://doi.org/10.1007/s11269-017-1658-x>.
- Schardong, A., & Simonovic, S. P. (2015). Coupled Self-Adaptive Multiobjective Differential Evolution and Network Flow Algorithm Approach for Optimal Reservoir Operation. *Journal of Water Resources Planning and Management*, 141(10), 04015015. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0000525](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000525).
- Sedlá, J., & Nováková, T. (2017). Science of the Total Environment Sedimentary record and anthropogenic pollution of a complex , multiple source fed dam reservoirs: An example from the Nové Mlýny reservoir , Czech Republic, 574, 1456–1471. <https://doi.org/10.1016/j.scitotenv.2016.08.127>.
- Shaw, A. R., Sawyer, H. S., LeBoeuf, E. J., McDonald, M. P., & Hadjerioua, B. (2017). Hydropower optimization using artificial neural network surrogate models of a high-fidelity hydrodynamics and water quality Model. *Water Resources Research*, 53, 1–18. <https://doi.org/10.1002/2017WR021039>.
- Soleimani, S., Bozorg-haddad, O., Saadatpour, M., & Loáiciga, H. A. (2018). Simulating thermal stratification and modeling outlet water temperature in reservoirs with a data mining method. *Journal of Water Supply: Research and Technology—AQUA*, 1–13. <https://doi.org/10.2166/aqua.2018.036>.
- Wang, Q., Li, S., Peng, J., Qi, C., & Ding, F. (2014). A review of hydrological/water-quality models. *Frontiers of Agricultural Science and Engineering*, 1(4), 267. <https://doi.org/10.15302/J-FASE-2014041>.
- Wei, G. L., Yang, Z. F., Cui, B. S., Li, B., Chen, H., Bai, J. H., & Dong, S. K. (2009). Impact of dam construction on water quality and water self-purification capacity of the Lancang River, China. *Water Resources Management*, 23(9), 1763–1780. <https://doi.org/10.1007/s11269-008-9351-8>.
- Wu, B., Yi, Z., Wu, X., Tian, Y., Han, F., Liu, J., & Zheng, C. (2015). Optimizing water resources management in large river basins with integrated surface groundwater modeling: A surrogate-based approach Bin. *Water Resources Research*, 51, 9127–9140. <https://doi.org/10.1002/2014WR016259>.
- Xie, H., Tang, H. A. O., & Liao, Y. (2009). TIME SERIES PREDICTION BASED ON NARX NEURAL NETWORKS: AN ADVANCED APPROACH, (July), 12–15.
- Yazdi, J., & Moridi, A. (2017). Interactive Reservoir-Watershed Modeling Framework for Integrated Water Quality Management, 2105–2125. <https://doi.org/10.1007/s11269-017-1627-4>.
- Yousefi, P., Saadatpour, M., & Afshar, A. (2019). Surrogate Based Simulation-Optimization Approach in Optimal Operation of Waterbody Considering Quality and Quantity Aspects. <https://doi.org/10.22093/wwj.2019.132788.2689>.
- Zhang, J., Wang, X., Liu, P., Lei, X., Li, Z., Gong, W., ... Wang, H. (2017). Assessing the weighted multi-objective adaptive surrogate model optimization to derive large-scale reservoir operating rules with sensitivity analysis. *Journal of Hydrology*, 544, 613–627. <https://doi.org/10.1016/j.jhydrol.2016.12.008>.