



فصلنامه علوم محیطی، دوره بیستم، شماره ۱، بهار ۱۴۰۱

۵۷-۷۶

مقاله پژوهشی

## بهره‌برداری از کانال‌های آبیاری با استفاده از روش‌های هوشمند

فاطمه بیات<sup>۱</sup>، حسام قدوسی<sup>۱\*</sup> و کاظم شاهوردی<sup>۲</sup>

<sup>۱</sup> گروه مهندسی آب، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران

<sup>۲</sup> گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران

تاریخ دریافت: ۱۴۰۰/۲/۳۰ تاریخ پذیرش: ۱۴۰۰/۰۶/۲۴

بیات، ف.، ح. قدوسی و ک. شاهوردی. ۱۴۰۱. بهره‌برداری از کانال‌های آبیاری با استفاده از روش‌های هوشمند. فصلنامه علوم محیطی. ۲۰(۱):۵۷-۷۶.

**سابقه و هدف:** رشد سریع جمعیت، کشاورزی، شهرنشینی و صنعت موجب افزایش تقاضای آب و رقابت برای مصرف‌های مختلف شده است. ترویج بهره‌وری آب در کشاورزی تأثیر قابل توجهی بر افزایش راندمان مصرف آب دارد. روش‌های توزیع و تحویل آب نیز نقش تعیین‌کننده‌ای در میزان انعطاف‌پذیری سامانه‌های آبیاری و بهبود بهره‌وری آب دارند. از میان روش‌های موجود، روش تحویل برحسب درخواست، انعطاف‌پذیری بیشتری نسبت به روش گردشی دارد و نسبت به روش برحسب تمایل (برحسب تقاضا) به زیرساخت‌های کمتری نیاز دارد. تنظیم مناسب سازه‌ها و دستورالعمل‌های بهره‌برداری بین درخواست‌های متوالی تابعی از تغییرات دبی، فاصله زمانی بین بهره‌برداری‌ها، همزمانی درخواست‌های مختلف، شرایط فیزیکی سازه‌های کانال و رفتار هیدرودینامیکی جریان می‌باشد که موجب پیچیدگی و لزوم استفاده از روش‌های ریاضی جهت مدل‌سازی و بهره‌برداری می‌گردد. در این تحقیق از روش جدید FSL و روش ANN استفاده گردید و به‌منظور تعیین عملکرد روش جدید بکار رفته عملکرد آن با روش ANN مقایسه گردید. داده‌های بکار رفته نیز مربوط به کانال عقیلی شرقی واقع در استان خوزستان می‌باشند.

**مواد و روش‌ها:** در این تحقیق، مقایسه کارائی دو روش یادگیری مدرن (یادگیری تقویتی سارسای فازی) و یادگیری سنتی (شبکه‌های عصبی مصنوعی) به‌منظور برنامه‌ریزی توزیع و تحویل آب در روش تحویل برحسب درخواست در کانال عقیلی شرقی استان خوزستان انجام شد. به‌منظور شبیه‌سازی از ۷۰٪، ۱۵٪ و ۱۵٪ داده‌ها به ترتیب برای آموزش، کالیبراسیون و اعتبار سنجی مدل‌ها استفاده شد. یادگیری و آموزش داده‌های دبی و بازشدگی آگیرها توسط شبکه‌های عصبی مصنوعی پرسپترون چند لایه و تابع پایه شعاعی انجام و بهترین حالت تنظیم سازه‌ها با استفاده از معیارهای ضریب همبستگی و ریشه میانگین مربعات خطا انتخاب شد. همچنین، بهترین تنظیم سازه‌ها با استفاده از روش یادگیری تقویتی نیز استخراج گردید. به‌منظور ارزیابی نتایج نیز از سنجه‌های راندمان، کفایت، پایداری و عدالت در تحویل آب و همچنین سنجه‌های میانگین و حداکثر نوسانات سطح آب نسبت به عمق هدف استفاده گردید.

**نتایج و بحث:** براساس نتایج به‌دست آمده مشاهده شد که سنجه MPA در روش شبکه عصبی مصنوعی برای بلوک‌های اول و دوم کانال

\* Corresponding Author: Email Address. ghodousi@znu.ac.ir

<http://dx.doi.org/10.52547/envs.2021.1045>

<http://dorl.net/dor/20.1001.1.17351324.1401.20.1.7.6>

به ترتیب برابرند با ۰/۹۵۲ و ۰/۹۱۹ و در حالت استفاده از روش سارسای فازی این مقادیر به ترتیب برابر ۰/۹۹۶ و ۱ می‌باشند. همچنین مقادیر سنجه MPF در هنگام شبیه‌سازی با استفاده از شبکه عصبی در هر دو بلوک برابر ۱ می‌باشد و در شبیه‌سازی با استفاده از FSL این مقادیر برابر ۰/۹۹۹ و ۰/۹۷۱ می‌باشند. در روش MLP خطای حداکثر نوسانات سطح آب در بلوک‌های اول و دوم به ترتیب برابرند با ۹/۲ و ۳/۸ درصد و در روش FSL این خطاها برابرند با ۵/۵ و ۷/۴ درصد. نتایج نشان داد که سنجه‌های میانگین و حداکثر نوسانات سطح آب برابر حداقل خود می‌باشند و سنجه‌های تحویل آب نیز به مقادیر مطلوبشان نزدیک می‌باشند. به‌طور کلی می‌توان نتیجه گرفت با توجه به سنجه‌های ارزیابی، روش FSL نتایج بهتری نسبت به روش MLP دارد. با این حال نتایج روش MLP نیز قابل قبول و معتبر می‌باشد.

**نتیجه‌گیری:** در این تحقیق از روش شبکه‌های عصبی پرسپترون چندلایه و تابع پایه شعاعی در برنامه متلب جهت تعیین دستورالعمل‌های بهره‌برداری کانال عقیلی شرقی در استان خوزستان استفاده شد و نتایج با روش سارسای فازی مورد مقایسه قرار گرفت. به‌منظور شبیه‌سازی هیدرودینامیکی کانال نیز، مدل ICSS مورد استفاده قرار گرفت. بررسی‌ها نشان داد که نتایج شبکه پرسپترون چندلایه از شبکه تابع پایه شعاعی بهتر است و نتایج مدل‌سازی با روش سارسای فازی نیز از روش پرسپترون چندلایه مناسب‌تر می‌باشد. اما به‌رحال هر دو روش می‌توانند در عمل مورد استفاده قرار گیرند.

**واژه‌های کلیدی:** روش برحسب درخواست، سنجه‌های ارزیابی، عملکرد بهره‌برداری، کانال عقیلی شرقی، یادگیری تقویتی، روش‌های محاسباتی نرم.

## مقدمه

روش میزان آب مورد نیاز توسط زارعان از قبل اعلام می‌شود و مدیریت شبکه باید با توجه به میزان آب موجود و درخواست‌های زارعان، برنامه‌ریزی تحویل آب و تنظیم سازه‌ها را به گونه‌ای انجام دهد که تا حد امکان نیاز آبیاریها به‌طور کامل تأمین گردد (Shahverdi, 2015). با توجه به اینکه بهره‌برداری از شبکه‌ها و بهینه‌سازی آن‌ها بویژه در شبکه‌های بزرگ به‌دلیل وجود جریان‌های غیرماندگار بسیار پیچیده می‌باشد باید از روش‌ها و مدل‌های ریاضی برای این منظور استفاده نمود. در سال‌های اخیر استفاده از الگوریتم‌های تکاملی در بهینه‌سازی توزیع و تحویل آب در شبکه‌های آبیاری مورد توجه محققان قرار گرفته است.

Haq and Anwar (2010) برنامه‌ریزی توزیع و تحویل آب در شبکه‌های آبیاری را با استفاده از الگوریتم ژنتیک انجام دادند. ایشان دو مدل مختلف برای برنامه‌ریزی توزیع و تحویل آب در یک کانال را بررسی نمودند. مدل اول که مدل بلوک زمانی نام داشت دور آبیاری را به قطعات زمانی مختلف تقسیم و هر قطعه را یک بلوک فرض می‌کرد. در مدل دوم که مدل لوله‌های جریان نام-گذاری شد فرض بر این بود که کانال توزیع از چندین

بروز خشکسالی‌های پی‌درپی، تأثیرهای ناشی از تغییر اقلیم و افزایش سریع و روزافزون جمعیت، بحران‌های ناشی از کمبود آب را افزایش داده و لزوم توجه جدی و همه‌جانبه، به بحث مدیریت منابع آب را بیش از پیش مطرح ساخته است. با توجه به آنکه شبکه‌های آبیاری ثقلی از عمده‌ترین سازه‌های انتقال و توزیع آب می‌باشند، مدیریت صحیح آن‌ها به‌منظور کاهش تلفات آب، ضروری می‌باشد. در روش بهره‌برداری دستی از شبکه‌های بهره‌برداری آبیاری و زهکشی بویژه در شبکه‌های قدیمی، مجموعه عملیات تنظیم ارتفاع و بازشدگی سازه‌های آب‌بند و آبیگر در کانال‌های آبیاری برای تحویل دقیق آب به آبیاریها را بهره‌برداری می‌نامند که توسط شخصی به نام میراب انجام می‌شود (Shahverdi et al., 2016). تعیین عامل‌های اصلی تحویل و توزیع آب یعنی مقادیر دبی (Q)، مدت زمان (T) و دوره یا فرکانس (F) تحویل آب به انشعابات مختلف موجود در یک کانال آبیاری را برنامه‌ریزی توزیع و تحویل آب در شبکه‌های می‌نامند (Shahdany et al., 2019). یکی از روش‌های تحویل و توزیع آب در شبکه‌های آبیاری روش برحسب درخواست می‌باشد. در این

شود، استفاده از ایستگاه‌های بیشتر، منجر به افزایش دقت می‌شود. در این تحقیق، بهترین نتیجه زمانی به- دست آمد که از هر دو سری داده هواشناسی ایستگاه هدف و ایستگاه مجاور استفاده گردید و مقایسه عملکرد دو شبکه عصبی مصنوعی MLP و RBF نشان داد که دقت شبکه عصبی مصنوعی MLP تا حدودی بیشتر از شبکه RBF می‌باشد.

یادگیری تقویتی یک روش قوی و جدید برای یادگیری استراتژی‌های کنترل در محیط‌های پیچیده از طریق تعامل با محیط می‌باشد. در تحقیق *Shahverdi et al.* (2015) سامانه برحسب درخواست بهره‌برداری در شبکه‌های آبیاری با استفاده از الگوریتم یادگیری تقویتی سارسای فازی توسعه یافت و در کانال E1R1 از شبکه آبیاری دز کنترل گردید. نتایج بیانگر توانایی الگوریتم در استخراج الگوهای مناسب بهره‌برداری بود. در تحقیق *Shahverdi and Monem* (2015) یک مدل ریاضی از الگوریتم یادگیری تقویتی برای کنترل جریان بالادست ارائه گردید. برای ارزیابی این الگوریتم از زمان پاسخگویی سیستم (SRT)، حداکثر خطای مطلق (MAE) و انتگرال مقدار خطا یا میانگین خطاها (IAE) استفاده شد. نتایج به دست آمده نشان داد که بیشترین مقادیر SRT، MAE و IAE به ترتیب ۲۵۲ ثانیه، ۳/۰۷ و ۰/۱۵۲ درصد می‌باشند که مقادیر قابل قبولی می‌باشد. در تحقیق *Shahverdi et al.* (2016) از داده‌های فیزیکی و هیدرولیکی کانال عقیلی شرقی برای ارزیابی روش FSL استفاده شد. مدت زمان عملیات از ۲۳:۱ ساعت به ۵:۷۶ ساعت در روش FSL کاهش یافت و سنج‌های کفایت و راندمان به دست آمده نزدیک به مقادیر مطلوب و انحراف سطح آب کمتر از ۱۰ درصد به دست آمد. در تحقیق *Savari et al.* (2016) روش یادگیری تقویتی با روش بهره‌برداری مرسوم دستی مقایسه شد. مدل یادگیری تقویتی که در تحقیق بیان شده استفاده شد، مدل توسعه یافته توسط *Shahverdi et al.* (2016) بود.

لوله جریان که دبی یکسانی دارند تشکیل شده است و هر لوله جریان می‌تواند چندین انشعاب را به طور همزمان تغذیه کند. نتایج این تحقیق نشان داد که مدل بلوک زمانی بهتر از مدل لوله‌های جریان در برنامه‌ریزی توزیع و تحویل آب در کانال عمل می‌نماید.

*Valipoor et al.* (2016) عملکرد شبکه از لحاظ توزیع آب را در قسمتی از شبکه آبیاری درودزن فارس بررسی نمودند. در این تحقیق، عملکرد در سطح کانال درجه ۳ با استفاده از سنج‌های کفایت، راندمان و عدالت بررسی شد. نتایج نشان داد کانال از لحاظ عدالت توزیع آب، عملکرد خوبی ندارد و کانال‌های بالادست بیشتر از کانال‌های پایین دست، آب برداشت می‌کنند. با محاسبه سنج‌های توزیع آب برای گزینه‌های بهره‌برداری مختلف، مشخص گردید که شرایط فعلی بهره‌برداری در محدوده عملکرد ضعیف قرار دارد. *Shahrokhnia and Ghiasi* (2018) نیز در پژوهشی با هدف ارزیابی تحویل آب در شبکه آبیاری و زهکشی درودزن، سنج‌های عملکرد شبکه شامل کفایت تحویل آب، بازده تحویل آب، عدالت توزیع آب، اعتمادپذیری تحویل آب و نسبت عملکرد تحویل آب را محاسبه کردند و به این نتیجه رسیدند که در شبکه بیان شده، هیدرومدول باید براساس روش پنمن مانیتیت محاسبه شده و در مدیریت آن استفاده شود.

تاکنون شبکه‌های عصبی مصنوعی در بسیاری از علوم مهندسی با موفقیت مورد استفاده قرار گرفته است. *Karbasi* (2017) در تحقیق خود با استفاده از دو نوع شبکه عصبی مصنوعی MLP و RBF و همچنین داده‌های هواشناسی ایستگاه هدف و ایستگاه‌های مجاور، اقدام به بازسازی داده‌های ماهیانه ساعات آفتابی نمود. نتایج این تحقیق نشان داد که می‌توان با استفاده از داده‌های هواشناسی ایستگاه هدف و ایستگاه‌های مجاور، ساعات آفتابی ماهانه را با دقت بالایی بازسازی نمود و در صورتیکه فقط از داده‌های ایستگاه‌های مجاور استفاده

متفاوت یادگیری (یادگیری تقویتی و شبکه‌های عصبی مصنوعی) در شبکه‌های آبیاری، نوآوری تحقیق حاضر است.

## مواد و روش‌ها

### مدل هیدرودینامیکی ICSS

هسته اصلی مدل ICSS، یک مدل هیدرودینامیک یک بعدی است که به منظور شبیه‌سازی هیدرولیکی، هیدرولوژیکی و بهره‌برداری از سیستم‌های انتقال و توزیع آب آبیاری طراحی شده است. مدل ICSS قادر است جریان ماندگار و غیرماندگار را برای شرایط مختلف بهره‌برداری از کانال‌های آبیاری با انواع شکل مقطع کانال همراه با طیف قابل توجهی از سازه‌ها همراه با جریان‌های گسترده ورودی و خروجی شبیه‌سازی کند. شبیه‌سازی جریان ماندگار در این مدل با استفاده از معادلات جریان متغیر تدریجی ارائه شده توسط هندرسون و شبیه‌سازی جریان غیرماندگار به وسیله معادلات سنت و نانت انجام می‌گردد. معادلات سنت و نانت در این مدل با استفاده از روش تفاضل‌های محدود براساس سیستم چهار نقطه‌ای وزنی پرایزمن که از دقت، همگرایی، پایداری و صحت بالایی برخوردار است، حل شده‌اند (Monem, 2006). در ارزیابی دقت مدل هیدرودینامیکی ICSS، اطلاعات خروجی مدل و روش به کار برده شده توسط کمیته کاری مدل‌های ریاضی جامعه مهندسان عمران کانادا به طور دقیق بررسی گردیده و نتایج آن موفق ارزیابی شده است (Manz and Schaalje, 1992).

در این تحقیق، مدل ICSS به عنوان شبیه‌ساز، جهت شبیه‌سازی کانال مورد مطالعه استفاده شد. پس از استخراج بازشدگی مناسب برای دریاچه‌های موجود در کانال توسط شبکه عصبی مصنوعی یا FSL، مقادیر بیان شده در مدل ICSS وارد گردید و مقادیر عمق آب و دبی در کانال شبیه‌سازی شد که با استفاده از آن‌ها سنج‌های ارزیابی محاسبه گردید.

بهره‌برداری دستی نیز با استفاده از مدل ICSS مدل‌سازی شد. نتایج نشان داد که در شرایط نرمال هر دو روش، نتایج کمابیش یکسانی را ارائه می‌دهند. اما در شرایط اضطرار و وجود کمبود آب در کانال، روش یادگیری تقویتی بهتر از روش مرسوم دستی می‌باشد. در تحقیق (Arauz *et al.*, 2020) با استفاده از کنترلگر تناسبی - انتگرالی میزان تنظیم سازه‌ها برای تحویل دبی با دقت مناسب بررسی شده است. برای این منظور، ضریب‌های انتگرالی و تناسبی مربوط به کنترلگر به گونه‌ای انتخاب شده است که عملکرد سیستم بهینه شود. (Hashemi *et al.*, 2019) از مدل کنترل پیش‌بین برای تنظیم سطح آب به منظور بالا بردن عملکرد کانال آبیاری در تحویل و توزیع بهینه آب، استفاده کردند. آن‌ها تقاضاهای قابل پیش‌بینی شده و پیش‌بینی نشده را به مدل اعمال کرده و عملیات کنترل را انجام دادند که نتایج حاصل، بیانگر توانایی مدل استفاده شده در کنترل سطح آب و عملکرد قابل قبول سیستم می‌باشد. (Hassani *et al.*, 2019) بررسی بهره‌برداری از کانال‌های آبیاری با دیدگاه اقتصادی بررسی کردند. آن‌ها مدل برنامه‌ریزی ریاضی مثبت را برای این منظور استفاده کردند و به این نتیجه رسیدند که استفاده از دیدگاه اقتصادی در بهره‌برداری از کانال‌های آبیاری بسیار سودمند خواهد بود.

با توجه به اینکه روش یادگیری تقویتی به عنوان یک روش پیچیده یادگیری در تحقیق‌های قبلی مورد استفاده قرار گرفته است، ضروری است تا کارایی آن در مقایسه با سایر روش‌های موجود در برنامه‌ریزی تحویل و توزیع آب مشخص شود. با توجه به اینکه شبکه‌های عصبی مصنوعی نیز جزء روش‌های یادگیری می‌باشند در این تحقیق، تحویل و توزیع آب به روش برحسب درخواست، با استفاده از روش‌های یادگیری تقویتی و شبکه عصبی مصنوعی و مقایسه نتایج آن‌ها به عنوان هدف تحقیق مد نظر قرار گرفت. مقایسه دو روش

## معرفی کانال مورد استفاده

داشتن مقدار دبی‌های درخواستی در طول کانال با موتورسیکلت حرکت می‌کند و عملیات تنظیم سازه‌ها را برای تحویل دبی درخواستی انجام می‌دهد. مشکلی که در این راستا وجود دارد این است که میراب فقط بر مبنای تجربه خود مقدار تنظیم سازه‌ها را انجام می‌دهد و هیچ‌گونه پشتوانه علمی ندارد. در نتیجه، راندمان آبیاری پایین می‌باشد.

کانال عقیلی شرقی به صورت بتنی با مقطع ذوزنقه‌ای با شیب جانبی ۱:۱ ساخته شده است. طول این کانال ۱۶/۲۱۵ کیلومتر بوده که از کیلومتر صفر تا ۹/۴۸۵ دارای عرض کف ۱/۵ متر و از کیلومتر ۹/۴۸۵ تا انتهای کانال دارای عرض کف ۱ متر می‌باشد. شیب طولی کانال بین ۰/۰۰۰۴ تا ۰/۰۰۱ در طول کانال متغیر می‌باشد. این کانال دارای ۲۰ سازه آبگیر، ۱۱ سازه تنظیم‌کننده و ۴ سیفون می‌باشد. نمای کلی شبکه عقیلی به همراه کانال عقیلی شرقی در شکل (۱) نشان داده شده است. لازم به بیان است که در این تحقیق، از داده‌های واقعی مربوط به سال‌های ۱۳۸۷ تا ۱۳۹۶ کانال عقیلی شرقی که از دفتر شبکه آبیاری عقیلی دریافت شد، استفاده گردید.

مطالعه تحقیق‌های مختلف در زمینه سیستم‌های توزیع و تحویل آب نشان می‌دهد که هدف‌های عمده آن‌ها، بهبود دقت دبی تحویلی به آبگیرها می‌باشد. با توجه به ماهیت روش برحسب درخواست، کانال مورد استفاده در این تحقیق باید به صورت دستی بهره‌برداری شود. همچنین به منظور مشاهده بهتر تأثیر جریان غیرماندگار و تداوم آن در کانال‌ها، کانال مورد استفاده باید طولانی باشد و همچنین تعداد سازه‌های آبگیر و آب‌بند، پیچیده‌تر می‌شود، به همین دلیل کانالی انتخاب شد که تعداد آب‌بندها و آبگیرهای آن زیاد باشد. بنابر بررسی‌های انجام شده، مشاهده شد که یکی از کانال‌هایی که شرایط بالا را دارا می‌باشد، کانال عقیلی شرقی در شبکه آبیاری عقیلی می‌باشد. در حال حاضر وضعیت بهره‌برداری و توزیع آب در این کانال به این صورت است که درخواست مصرف‌کنندگان زیردست هر دریچه که بایستی حداکثر تا ۲۴ ساعت قبل اعلام شده باشد. برای تحویل دبی و انجام عملیات بهره‌برداری، میراب کانال عقیلی شرقی ساعت ۸ صبح، در حضور مأمور اداره آب دبی ورودی از کانال اصلی عقیلی به کانال عقیلی شرقی را تنظیم می‌کند. سپس با در دست



شکل ۱- شماتیک کانال عقیلی شرقی و موقعیت آبگیرها روی آن (Savari *et al.*, 2016)


Fig. 1- Schematic of east Aghili canal and turnout positions (Savari *et al.*, 2016)

انجام می‌دهد تا خروجی به دست آید. اتصال‌های بین گره-ها، نحوه گذر اطلاعات بین گره‌ها (تک سوپه یا دوسوپه) را مشخص می‌نماید. تعامل بین گره‌ها از طریق این اتصال‌ها سبب بروز یک رفتار کلی از سوی شبکه می‌گردد که چنین رفتاری به تنهایی در هیچ یک از المان‌های

## شبکه‌های عصبی مصنوعی

شبکه‌های عصبی یکی از روش‌های کارآمد در حل مسئله-های پیچیده بوده که دارای دو مؤلفه شامل گره‌ها (نرون‌ها) و اتصال‌های بین آن‌ها می‌باشند. هر گره واحد محاسباتی شبکه است که ورودی‌ها را گرفته و پردازش

آمده با خروجی موردنظر مقایسه شده و خطای به‌دست آمده جهت اصلاح وزن‌های شبکه بکار می‌رود. این فرایند در اصطلاح آموزش شبکه عصبی نامیده می‌شود. در این تحقیق، از دو روش MLP و RBF در نرم‌افزار MATLAB 2014 استفاده گردید.



شکل ۲- مدل ریاضی یک شبکه عصبی مصنوعی (Arekhi and Fathizadehh, 2014)  
Fig. 2- Model of an artificial intelligence network (Arekhi and Fathizadehh, 2014)

می‌شود در فرم ماتریسی به صورت روابط (۱) و (۲) می‌باشد (Karimizad and Shahsavand, 2013).

$$d_i(P) = \sum_{j=1}^N \phi_j(P) \cdot w_{ij} \quad (1)$$

$$\phi_j = \exp\left(\frac{-1}{2\sigma_j^2} \|P - C_j\|^2\right) \quad (2)$$


که در آن  $d_i(P)$  خروجی نام شبکه و  $\phi_j$  خروجی گره زام به ازای بردار ورودی  $P$ ،  $w_{ij}$  اتصال سیناپسی میان دو گره،  $N$  تعداد کل نرون‌های لایه پنهان،  $C_j$  مرکز گوس و  $\sigma_j$  مشخص کننده میزان گسترده‌گی گوسی است.

### آموزش شبکه‌های MLP و RBF

همانطور که اشاره شد در این تحقیق، از داده‌های واقعی مربوط به سال‌های ۱۳۸۷ تا ۱۳۹۶ کانال عقیلی شرقی که از دفتر شبکه آبیاری عقیلی دریافت شد، استفاده گردید. برای این منظور، ۷۰ درصد داده‌ها برای آموزش، ۱۵ درصد برای واسنجی و ۱۵ درصد نیز برای اعتبار-سنجی استفاده شد. با توجه به تعداد زیاد متغیرها، حالت‌های مختلفی از ترکیب آن‌ها در نظر گرفته و آموزش شبکه انجام شد و در نهایت بهترین ترکیب متغیرها انتخاب شد. برای آموزش شبکه عصبی با استفاده از

شبکه دیده نمی‌شود (شکل ۲). در این شبکه، مقادیر ورودی پس از ضرب در وزن‌های موجود در گذرگاه‌های بین لایه‌ها، به نرون بعدی رسیده و در آنجا باهم جمع می‌شوند و پس از عبور از تابع شبکه مربوطه، خروجی نرون‌ها را تشکیل می‌دهند. در پایان خروجی به‌دست

شبکه‌های عصبی MLP یا پرسپترون چند لایه (شکل ۳)، شامل مجموعه‌ای از نرون‌های پایه می‌باشند که تشکیل دهنده لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی می‌باشند. سیگنال‌های ورودی در خلال شبکه و در مسیری رو به جلو به صورت لایه به لایه منتشر می‌شوند (Hykin, 1999).



شکل ۳- پرسپترون چند لایه

(Arekhi and Fathizadehh, 2014) MLP  
Fig. 3- Multilayer perceptron (Arekhi and Fathizadehh, 2014)

شبکه RBF برخلاف شبکه‌های MLP که دارای لایه‌های متوالی زیادی هستند، از سه لایه ثابت تشکیل شده است. لایه ورودی که محل تزریق سیگنال‌های ورودی به شبکه است، لایه میانی یا طبقه RBF که شامل توابع RBF می‌شود. لایه خروجی که ترکیبی خطی از کلیه خروجی‌های طبقه RBF را می‌سازد. عملیاتی که در این شبکه انجام

همین ترتیب برای آبگیرهای دیگر سایر شبکه‌ها تعیین شدند.

حالت سوم: در این حالت ۵ شبکه آموزش دیده وجود خواهد داشت. متغیرهای ورودی در شبکه اول، دبی‌های ورودی به پنج آبگیر اول کانال عقیلی (TO1-TO5) و عمق جریان بالادست آبگیرها (Y1-Y5) و متغیر خروجی آن، میزان بازشدگی دریچه آبگیر اول (GO1) بود. متغیرهای ورودی در شبکه دوم نیز، دبی‌های ورودی به پنج آبگیر اول و عمق جریان بالادست آبگیرها، و متغیر خروجی آن میزان بازشدگی دریچه دوم (GO2) بود و به همین ترتیب با در نظر گرفتن بازشدگی، سایر دریچه‌ها به‌عنوان خروجی شبکه‌های دیگر تعیین گردیدند. این حالت مانند حالت اول است با این تفاوت که در این حالت، عمق‌های بالادست آبگیرها نیز به‌عنوان متغیر ورودی در نظر گرفته شده است.

حالت چهارم: در این حالت نیز مانند حالت‌های قبل، پنج شبکه آموزش دیده وجود خواهد داشت. در شبکه اول، متغیرهای ورودی، دبی ورودی به آبگیر اول کانال عقیلی (TO1) و عمق جریان بالادست این آبگیر و متغیر خروجی میزان بازشدگی متناظر این دریچه (GO1) بود. در شبکه دوم، متغیرهای ورودی دبی ورودی به آبگیر دوم و عمق جریان بالادست این آبگیر و متغیر خروجی میزان بازشدگی دریچه دوم بود. دیگر شبکه‌ها نیز به همین ترتیب با تغییر متناظر ورودی‌ها و خروجی‌ها برای سایر آبگیرها تعیین شدند.

روش‌های MLP و RBF در این تحقیق، ۴ حالت (برای هر دو روش به‌صورت یکسان و جداگانه) به شرح جدول (۱) در نظر گرفته شد. با توجه به ترکیب استفاده شده مندرج در جدول (۱)، دبی یا دبی‌های آبگیر به‌عنوان ورودی و بازشدگی دریچه آبگیر به‌عنوان خروجی به شبکه عصبی معرفی گردید و سپس آموزش، واسنجی و اعتبارسنجی آن انجام شد. به‌عنوان نمونه، در حالت دوم و شماره شبکه ۱ مندرج در جدول (۱)، متغیر ورودی دبی آبگیر ۱ (TO1) و متغیر خروجی، بازشدگی آبگیر ۱ (GO1) است.

حالت اول: در این حالت، پنج شبکه آموزش در نظر گرفته شد. متغیرهای ورودی در شبکه اول، دبی‌های ورودی به پنج آبگیر اول کانال عقیلی (TO1-TO5) و متغیر خروجی، میزان بازشدگی دریچه اول (GO1) بود. متغیرهای ورودی در شبکه دوم نیز دبی‌های ورودی به پنج آبگیر اول و متغیر خروجی، میزان بازشدگی دریچه دوم (GO2) بود و به‌ترتیب با در نظر گرفتن متغیرهای ورودی مشابه، بازشدگی سایر آبگیرها به‌عنوان خروجی شبکه‌های دیگر نیز تعیین گردید.

حالت دوم: در این حالت نیز پنج شبکه آموزش دیده وجود خواهد داشت. در شبکه اول، متغیر ورودی، دبی ورودی به آبگیر اول کانال عقیلی (TO1) و متغیر خروجی آن، میزان بازشدگی دریچه متناظر آن (GO1) می‌باشد. در شبکه دوم، متغیر ورودی دبی ورودی به آبگیر دوم (TO2) و متغیر خروجی بازشدگی دریچه دوم (GO2) بود و به

جدول ۱- حالت‌های در نظر گرفته شده برای آموزش شبکه‌های MLP و RBF

Table 1. Considered states for training RBF and MLP networks

متغیر خروجی شبکه Output variable of network	متغیرهای ورودی Input variables	شماره شبکه Network number	
GO1	TO1, TO2, TO3, TO4, TO5	1	
GO2	TO1, TO2, TO3, TO4, TO5	2	
GO3	TO1, TO2, TO3, TO4, TO5	3	حالت اول
GO4	TO1, TO2, TO3, TO4, TO5	4	First state
GO5	TO1, TO2, TO3, TO4, TO5	5	
GO1	TO1	1	
GO2	TO2	2	

ادامه جدول ۱- حالت‌های در نظر گرفته شده برای آموزش شبکه‌های MLP و RBF  
Table 1. Cont. Considered states for training RBF and MLP networks

متغیر خروجی شبکه Output variable of network	متغیرهای ورودی Input variables	شماره شبکه Network number	حالت دوم Second state
GO3	TO3	3	
GO4	TO4	4	
GO5	TO5	5	
GO1	TO1, TO2, TO3, TO4, TO5, Y1, Y2, Y3, Y4, Y5	1	حالت سوم Third state
GO2	TO1, TO2, TO3, TO4, TO5, Y1, Y2, Y3, Y4, Y5	2	
GO3	TO1, TO2, TO3, TO4, TO5, Y1, Y2, Y3, Y4, Y5	3	
GO4	TO1, TO2, TO3, TO4, TO5, Y1, Y2, Y3, Y4, Y5	4	
GO5	TO1, TO2, TO3, TO4, TO5, Y1, Y2, Y3, Y4, Y5	5	
GO1	TO1, Y1	1	حالت چهارم Fourth state
GO2	TO2, Y2	2	
GO3	TO3, Y3	3	
GO4	TO4, Y4	4	
GO5	TO5, Y5	5	

خروجی خاص بازشدگی دریاچه‌های مختلف بررسی شد و از ریشه میانگین مربعات خطای مدل شبکه عصبی مصنوعی برای انتخاب ساختار بهینه استفاده شد. به منظور بررسی صحت نتایج خروجی شبکه عصبی، از دو سنجه آماری ضریب همبستگی پیرسون  $R$  و ریشه میانگین مربعات خطا  $RMSE$  (معادلات ۳ و ۴) استفاده گردید.

$$R = \frac{\sum_{i=1}^N (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2} \cdot \sqrt{\sum_{i=1}^N (P_i - \bar{P})^2}} \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (O_i - P_i)^2}{N}} \quad (4)$$

در روابط بالا، پارامتر  $Q_i$  مقادیر مشاهداتی و پارامتر  $P_i$  ، مقادیر برآوردی و  $O_i$  و  $P_i$  نیز به ترتیب میانگین مقادیر مشاهداتی و برآوردی و  $N$  نیز تعداد داده‌ها می‌باشد.

معیار ضریب همبستگی یک معیار بدون بعد و بهترین مقدار آن برابر با یک است. همچنین، ریشه میانگین مربعات خطا معیاری جهت سنجش میزان خطا با مقایسه اختلاف داده‌های واقعی و داده‌های محاسبه شده می‌باشد که هر چه میزان آن به صفر نزدیکتر باشد نشان‌دهنده خطای کمتر و مقبولیت بیشتر مدل می‌باشد.

بیان این نکته ضروری است که دلیل انتخاب مثلا دبی آبیگر ۴ جزء متغیرهای تأثیرگذار بر دریچه ۱، این است که مقدار دبی آبیگر ۴ روی دبی آبیگر ۱ و در نتیجه بازشدگی آن، تأثیر می‌گذارد. چنانچه دبی آبیگر ۴ (در نتیجه زیاد بودن بازشدگی آن) زیاد باشد، منجر به زیاد شدن برداشت آب از این آبیگر خواهد شد و اگر بازشدگی آبیگرهای بالادست کم باشد، عمده دبی کانال به این نقطه منتقل خواهد شد.

### تعیین ساختار بهینه و ارزیابی عملکرد مدل

همانطور که اشاره شد، شبکه‌های عصبی مصنوعی ساختار شبکه شامل نوع ورودی‌ها و خروجی‌ها، تعداد لایه‌های مخفی و تعداد نرون‌ها در هر لایه مخفی، نوع تابع فعالسازی و نوع الگوریتم آموزشی می‌باشد. تعیین تعداد لایه‌ها و تعداد نرون‌ها در هر لایه و همچنین نحوه ارتباط آن‌ها با یکدیگر در معماری شبکه اهمیت زیادی دارد. معیار خاصی برای تعیین تعداد لایه‌ها و تعداد نرون‌ها در لایه میانی بیان نشده است و به‌طور معمول از روش سعی و خطا استفاده می‌شود. لایه‌های میانی بسته به نوع داده‌ها و میزان خطای شبکه ممکن است یک یا چند عدد باشد. همچنین، تعداد نرون‌ها در لایه مخفی، نقش مهمی در کارایی مدل شبکه عصبی دارد. در این پژوهش ترکیب متفاوت پارامترهای ورودی و تعداد لایه‌های مخفی با یک



## یادگیری تقویتی

یک سیستم فازی TSK مرتبه صفر با  $n$  ورودی و یک خروجی و  $R$  قانون به فرم رابطه زیر می‌باشد. (Glorennec and Jouffe, 1997)

$$R_i : \text{If } x_1 \text{ is } L_{i1} \text{ and } \dots \text{ and } x_n \text{ is } L_{in}, \text{ then } (\alpha_{i1} \text{ with value } w_{i1}) \text{ or } \dots \text{ or } (\alpha_{im} \text{ with value } w_{im}) \quad (5)$$

که در آن بردار  $n$  بعدی متغیرهای وضعیت ورودی،  $L_i = L_{i1} \times \dots \times L_{in}$  شامل  $n$  مجموعه فازی با مرکزهای یکتا برای  $i$  امین قانون،  $m$  تعداد کنش‌های گسسته ممکن (بازشدگی درجه) برای هر قانون،  $\alpha_{ij}$  ز امین کنش کاندید در قانون  $i$  ام و  $w_{ij}$  مقدار ارزش تقریب زده شده برای کنش  $i$  ام در قانون  $i$  ام است.

در هر تکرار، یک کنش از میان  $m$  کنش کاندید شده بر مبنای مقدار وزن آن کنش انتخاب می‌شود و آنگاه کنش نهایی از ترکیب وزن دار این کنش‌ها حاصل می‌گردد. مقادیر اولیه  $w_{ij}$  برابر با صفر است. با توجه به پاداش دریافت شده، مقادیر  $w_{ij}$  در طول فرایند یادگیری به روز می‌شود. خروجی سیستم یعنی کنش  $a$  در وضعیت  $s$  (شرایط جریان در کانال) با  $a_t(s_t)$  نشان داده می‌شود ( $t$  شماره تکرار است) و با رابطه (۶) محاسبه می‌شود. ارزش کنش بیان شده نیز با رابطه (۷) محاسبه می‌شود:

$$a_t(s_t) = \sum_{i=1}^R \mu_i(s_t) a_{ii}^+ \quad (6)$$

$$\bar{Q}_t(s_t, a_t) = \sum_{i=1}^R \mu_i(s_t) w_t^{ii+} \quad (7)$$

که در آن،  $a_{ii}^+$  و  $w_t^{ii+}$  کنش انتخاب شده و وزن مرتبط با آن در قاعده  $i$  ام است. مقدار تعلق قانون  $i$  ام و  $i^+$  اندیس کنش انتخاب شده در قانون  $i$  ام است. انتخاب کنش در این روش با استفاده از رابطه (۸) انجام می‌شود.

$$p(u_{ij}) = \frac{e^{\frac{\mu_i w_{ij}}{\delta_t}}}{\sum_{j=1}^m e^{\frac{\mu_j w_{ij}}{\delta_t}}} \quad (8)$$

که در آن  $\delta$  ضریب دما است. ضریب دما بین تجربه‌های گذشته و اکتشاف‌های جدید تعادل ایجاد می‌کند و مقدار

آن در طول فرایند یادگیری به تدریج کاهش می‌یابد. مقادیر اولیه آن براساس تجربه و نوع مسئله توسط کاربر انتخاب می‌شود. به‌طور معمول در ابتدای آموزش مقدار ضریب دما بزرگ و در حین آموزش هر چه به سمت جلو می‌رویم مقدار آن با استفاده از رابطه (۹) کاهش می‌یابد تا از تجربه‌های قبلی بیشتر استفاده گردد:

$$\delta_{t+1} = \delta_0 - d\delta \cdot \delta_t \quad (9)$$

که در آن  $\delta_0$  مقدار اولیه دما و  $d\delta$  مقدار تغییر جزئی دما می‌باشد که مقادیر آن‌ها در این تحقیق به ترتیب ۳۰ و ۰/۰۰۸ در نظر گرفته شد. در صورتیکه نسبت ارزش یک کنش به مقدار دما خیلی بزرگ شود، فرایند یادگیری تمام شده و مدل همگرا می‌شود. پس از اعمال کنش روی محیط، مقدار پارامترهای وزن هر قانون با رابطه (۱۰) به روزرسانی می‌شوند:

$$\Delta w_{t+1}^{ij} = \begin{cases} \beta_t \times \Delta Q(s_t, a_t) \times \mu_i(s_t) \text{ if } j = i^+ \\ 0 \text{ otherwise} \end{cases} \quad (10)$$

که در آن  $\beta$  نرخ آموزش بوده و به روزرسانی مقادیر  $w$  را کنترل می‌کند. مقادیر آن براساس تجربه و نوع مسئله تعیین می‌شود. مقدار خطای ارزش-کنش با رابطه (۱۱) محاسبه می‌شود.

$$\Delta Q_t(s_t, a_t) = r_{t+1} + \gamma Q_t(s_{t+1}, a_{t+1}) - Q_t(s_t, a_t) \quad (11)$$

که در آن  $\gamma$  ضریب وزنی ارزش پاداش تکرار  $t+1$  را در تکرار  $t$  نشان می‌دهد. مقدار آن بین صفر و یک است و با آزمون و خطا تعیین می‌شود. مقدار پاداش ( $r$ ) با استفاده از رابطه (۱۲) محاسبه می‌شود:

$$\begin{cases} |y - y_{target}| > 0.2y_{target} \rightarrow r = 0 \\ |y - y_{target}| < 0.2y_{target} \\ \rightarrow r = \frac{100}{(dQ_c + dQt) + 0.01} \end{cases} \quad (12)$$

که در آن  $dQ_c$  و  $dQ_t$  به ترتیب مقدار انحراف دبی درخواستی از دبی تحویلی در آب‌بند و آبگیر،  $y$  و  $y_{target}$  عمق شبیه‌سازی شده با استفاده از ICSS و عمق هدف در محل آب‌بند است.

(1998, *al.*). سنجه خطای حداکثر مطلق برای اندازه‌گیری حداکثر انحراف سطح آب از عمق هدف ارائه شده است که به صورت رابطه (۱۷) تعریف می‌شود:

$$MAE = \frac{\max(|y_{target} - y|)}{y_{target}} \quad (17)$$

که در آن  $y$  سطح آب محاسبه شده توسط مدل در گام زمانی محاسباتی  $T$  و  $y_{target}$  عمق هدف می‌باشد. هرچه مقدار این سنجه کمتر باشد، نشان‌دهنده عملکرد مطمئن‌تر سیستم در کنترل سطح آب است. سنجه خطای مطلق تجمعی نشان‌دهنده میانگین انحرافات عمق آب از عمق هدف در طول دوره بهره‌برداری به صورت زیر می‌باشد.

$$IAE = \frac{T \sum_{T=0}^D (|y_{target} - y|)}{y_{target}} \quad (18)$$

که در آن  $D$  طول دوره بهره‌برداری می‌باشد. هرچه مقدار این سنجه کمتر باشد، نشان‌دهنده عملکرد مطمئن‌تر سیستم در کنترل سطح آب می‌باشد.

### نتایج و بحث

هدف اصلی این تحقیق، توسعه و آموزش شبکه عصبی مصنوعی در تهیه دستورالعمل‌های بهره‌برداری در شبکه‌های آبیاری با روش بهره‌برداری برحسب درخواست می‌باشد. بنابراین با استفاده از داده‌های دریافت شده (سال‌های ۱۳۸۷ تا ۱۳۹۶ اسفندماه) از دفتر شبکه آبیاری عقیلی، به آموزش شبکه عصبی مصنوعی پرداخته شد. در این تحقیق برای شبیه‌سازی پنج آبگیر اول کانال عقیلی شرقی مورد توجه قرار گرفت و میزان توانایی شبکه عصبی توسط سنجه‌های مختلف بررسی شد.

ساختار نهایی شبکه عصبی MLP استفاده شده با توجه به متغیر بودن تعداد ورودی‌ها در چهار حالت مختلف که برای حالت‌های ۱ تا ۴ به ترتیب برابر با ۵، ۱، ۱۰ و ۲ متغیر بود، متفاوت بود. اما در این شبکه‌ها یک متغیر خروجی وجود داشت که تابع مربوطه تابع سیگموئید

روش یادگیری تقویتی، براساس برهم‌کنش متقابل و جایزه‌ای که به عمل انجام شده می‌دهد، بهترین عمل ممکن را پیدا می‌کند و با توجه به ماهیت آن نیاز به هیچ‌گونه داده یا سری آماری جهت انجام یادگیری ندارد که این مهمترین مزیت‌های آن می‌باشد. با این حال فرمولاسیون پیچیده آن بویژه در شبکه‌های بزرگ آبیاری می‌تواند جزء محدودیت‌های آن باشد.

### سنجه‌های ارزیابی عملکرد

برای ارزیابی عملکرد توزیع و تحویل آب از سنجه‌های کفایت ( $MPA$ )، راندمان ( $MPF$ )، عدالت ( $MPE$ ) و پایداری ( $MPD$ ) استفاده شد که به ترتیب در روابط (۱۳) تا (۱۶) تعریف شده‌اند (Molden and Gates, 1990):

$$MPA = \frac{1}{N} \sum_N \frac{1}{M} \sum_M (PA), \begin{cases} PA = \frac{Q_D}{Q_R} IF Q_R > Q_D \\ PA = 1 IF 1 < \frac{Q_D}{Q_R} \end{cases} \quad (13)$$

$$MPF = \frac{1}{N} \sum_N \frac{1}{M} \sum_M (PE), \begin{cases} PE = \frac{Q_R}{Q_D} IF Q_R < Q_D \\ PE = 1 IF \frac{Q_R}{Q_D} > 1 \end{cases} \quad (14)$$

$$MPD = \frac{1}{R} \sum_R CV_T \left( \frac{Q_D}{Q_R} \right) \quad (15)$$

$$MPE = \frac{1}{T} \sum_T CV_R \left( \frac{Q_D}{Q_R} \right) \quad (16)$$

که در آن  $M$  تعداد آبگیرها،  $Q_R$  دبی مورد نیاز یا دبی درخواست شده در آبگیر  $M$ ،  $Q_D$  دبی واقعی تحویل شده به آبگیر  $M$  و  $N$  تعداد گام‌های زمانی مناسب در یک دوره تحویل،  $R$  تعداد آبگیرها،  $T$  تعداد گام‌های زمانی و  $CV$  ضریب تغییرات می‌باشد. بهترین مقدار برای سنجه‌های کفایت و راندمان برابر با ۱ و برای سنجه‌های عدالت و پایداری برابر با صفر است.

برای ارزیابی کنترل سطح آب از سنجه‌های خطای حداکثر مطلق ( $MAE$ ) و خطای مطلق تجمعی ( $IAE$ ) ارائه شده توسط ASCE استفاده شد (Clemmens *et*

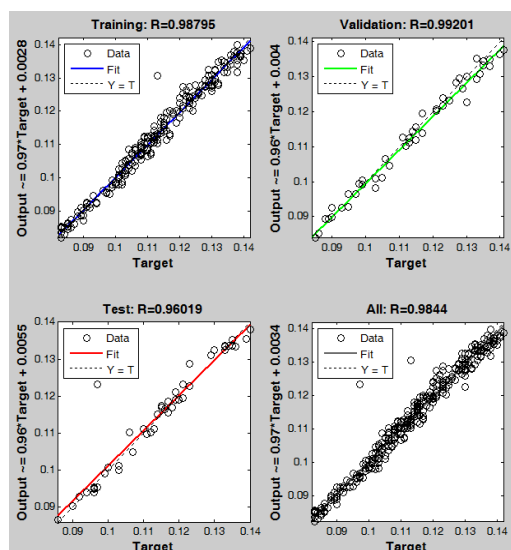
## نتایج آموزش داده‌ها با استفاده از روش‌های

### RBF و MLP

نتایج آموزش داده‌ها با استفاده از روش شبکه عصبی مصنوعی MLP در قالب سنجه‌های R و RMSE در جدول (۲) نشان داده شده است. همانطور که مشاهده می‌شود حالت سوم با داشتن ضریب همبستگی برابر با ۰/۹۹ در هر پنج آنگیر و RMSE کمتر نسبت به سایر حالت‌ها (کمابیش ۱۰ برابر کوچکتر)، بهترین حالت در روش MLP می‌باشد. این نتیجه نشان می‌دهد که آموزش پنج شبکه به صورت جداگانه که ورودی آن‌ها مقادیر دبی و عمق آب در هر پنج آنگیر بوده و خروجی آن‌ها مقادیر بازشدگی می‌باشد، نتایج بهتری به همراه دارد. این حالت به عنوان حالت منتخب در روش MLP در نظر گرفته شد.

نتایج آموزش داده‌ها با استفاده از روش شبکه عصبی مصنوعی RBF در قالب سنجه‌های R و RMSE نیز در جدول (۲) ارائه شده است. همانطور که مشاهده می‌شود، در این روش نیز، حالت سوم، نتایج بهتری داشته است، هر چند که نتایج حالت‌های سوم و چهارم با ضریب همبستگی مشابه، بسیار نزدیک به هم می‌باشند. با این حال حالت سوم نسبت به حالت چهارم برتری دارد و به عنوان روش منتخب انتخاب گردید.

انتخاب شد. همچنین تابع انتقال لایه میانی تانژانت هایپربولیک انتخاب شد. توابع انتخاب شده در شبکه RBF، برای لایه میانی تابع softmax و تابع انتقال لایه خروجی Identity انتخاب شد. با وارد کردن متغیرهای ورودی و خروجی، نتایج آموزش شبکه عصبی MLP برای شبکه ۴ حالت دوم (ورودی دبی آنگیر ۴ و خروجی بازشدگی آنگیر ۴) به عنوان نمونه در شکل (۴) نشان داده شده است.



شکل ۴- نتیجه شبیه‌سازی با استفاده از شبکه عصبی MLP برای شبکه ۴ در حالت دوم

Fig. 4- The result of MLP neural network for network 4 at state 2

جدول ۲- نتایج آموزش داده‌ها با استفاده از روش‌های MLP و RBF در حالت‌های مختلف

Table 2. Results of data training using the MLP and RBF methods in different states

RBF		MLP		خروجی output	
R	RMSE	R	RMSE		
0.40	0.0032	0.99	4.09e-6	GO1	حالت اول First state
0.83	2.37e-05	0.97	4.23e-6	GO2	
0.99	1.69e-6	0.99	1.7e-6	GO3	
0.98	9.39e-6	0.98	1.14e-5	GO4	
0.98	3.7e-6	0.99	3.51e-6	GO5	
0.36	0.0033	0.97	2.02e-6	GO1	حالت دوم Second state
0.76	3.19e-05	0.90	9.92e-6	GO2	
0.98	5.44e-06	0.98	3.71e-6	GO3	
0.95	2.16e-05	0.99	1.49e-5	GO4	
0.97	9.26e-6	0.96	8.72e-6	GO5	
0.37	0.0033	0.99	3.82e-7	GO1	حالت سوم* Third state
0.84	2.19e-05	0.99	1.21e-7	GO2	
0.99	4.22e-07	0.99	3.18e-7	GO3	
0.99	2.67e-05	0.99	3e-6	GO4	
0.99	5.93e-07	0.99	3.4e-7	GO5	

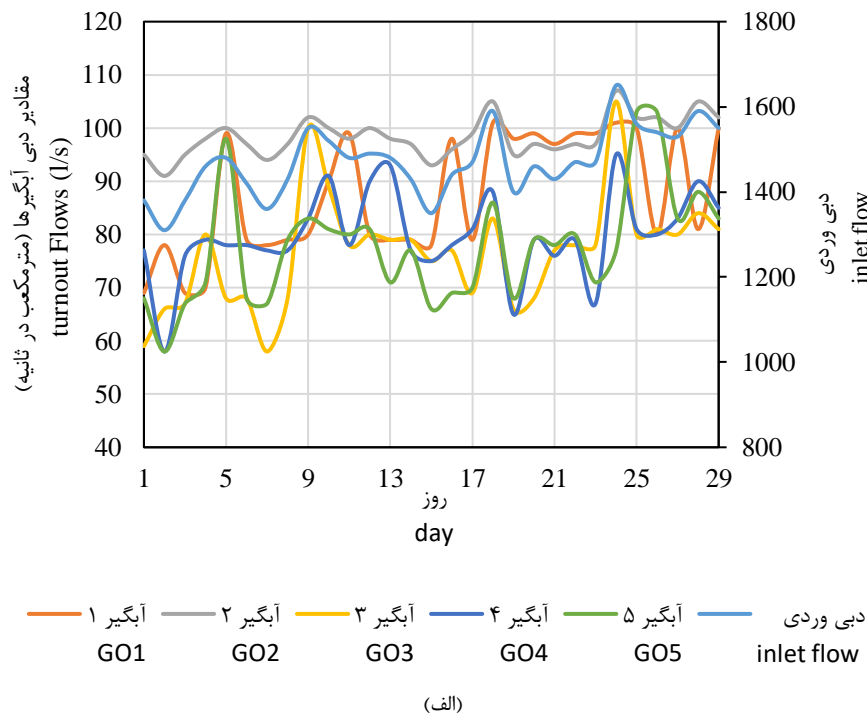
ادامه جدول ۲- نتایج آموزش داده‌ها با استفاده از روش‌های MLP و RBF در حالت‌های مختلف  
Table 2. Cont. Results of data training using the MLP and RBF methods in different states

RBF		MLP		خروجی output	
R	RMSE	R	RMSE		
0.37	0.0033	0.99	5.22e-6	GO1	
0.84	2.27e-05	0.94	1.01e-6	GO2	
0.99	8.61e-07	0.99	7.17e-7	GO3	حالت چهارم
0.99	5.29e-06	0.99	3.78e-6	GO4	Fourth state
0.99	1.2e-06	0.99	2.49e-6	GO5	


با استفاده از شبکه آموزش دیده برای حالت منتخب (حالت سوم MLP)، مقادیر بازشدگی آبیگرها برای اسفندماه سال ۱۳۹۶ محاسبه شد که نتایج آن در شکل ۵ الف نشان داده شده است. سپس این مقادیر در مدل هیدرودینامیک ICSS وارد و پس از شبیه‌سازی مقادیر دبی تحویلی در طول مدت آبیاری به دست آمد که مقادیر آن‌ها نیز در شکل (۵ ب) ارائه شده است. در ادامه سنجه‌های ارزیابی عملکرد کانال و سنجه‌های تغییرات سطح آب نیز محاسبه و مقادیر آن‌ها در شکل (۶) بیان شده است.

با مشاهده نتایج شبکه‌های عصبی MLP و RBF و مقایسه دو سنجه آماری ضریب همبستگی R و RMSE در حالت منتخب (حالت سوم در هر دو روش) مشخص شد که هر دو روش می‌توانند روش مناسبی برای آموزش داده‌ها باشند. با این حال نتایج نشان داد که روش MLP روش مناسب‌تری نسبت به روش RBF می‌باشد. بنابراین حالت سوم در روش MLP، به‌عنوان بهترین حالت از بین کل حالت‌های بررسی شده انتخاب گردید.

### مقادیر بازشدگی و سنجه‌های ارزیابی با روش منتخب (حالت سوم MLP)

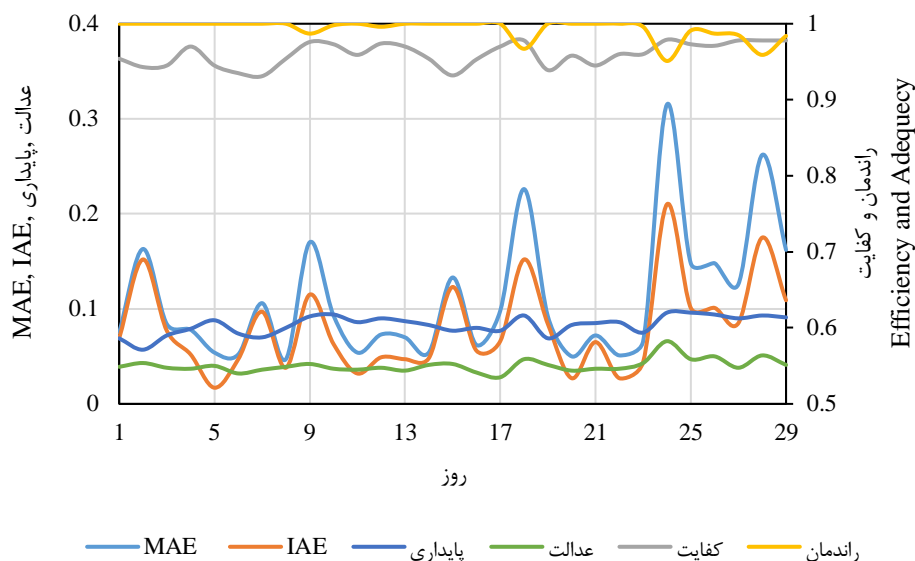


شکل ۵- نتایج شبیه‌سازی با استفاده از شبکه عصبی منتخب MLP در اسفندماه ۱۳۹۶  
Fig. 5- Values of delivered flow and corresponding gate opening of turnouts in March 2017



ب

ادامه شکل ۵- نتایج شبیه‌سازی با استفاده از شبکه عصبی منتخب MLP در اسفندماه ۱۳۹۶  
 Fig. 5- Cont. Values of delivered flow and corresponding gate opening of turnouts in March 2017



شکل ۶- مقادیر سنجه‌های محاسبه شده برای نتایج حاصل از شبکه عصبی منتخب در اسفندماه ۱۳۹۶  
 Fig. 6- Values of calculated indicators for selected artificial networks in March 2017

MPD و MPE، هر چقدر این مقادیر به صفر نزدیکتر باشد، نشانگر پایداری بهتر در سیستم و عدالت در تحویل آب می‌باشد. بیشترین مقدار این پارامترها برابر با ۰/۰۹۶ و ۰/۰۶۶ به دست آمده است. لازم به بیان است که  $dQ$  حجم آب مازاد یا کمبود تحویلی به آبیگرها در طول دوره شبیه‌سازی می‌باشد. علامت مثبت آن نشان‌دهنده مازاد تحویل و علامت منفی آن کمبود تحویل است.

همانطور که مشاهده می‌شود بیشترین مقدار MAE و IAE به ترتیب برابر با ۳۱ و ۲۱ درصد به دست آمده است. هر چه قدر مقادیر MPA و MPF به یک نزدیکتر باشد، نشان‌دهنده عملکرد بهتر سیستم در راندمان و کفایت تحویل آب می‌باشد. کمترین مقدار این پارامترها به ترتیب برابر با ۰/۹۳۱ و ۰/۹۵۱ به دست آمده است که نشانگر عملکرد مناسب سیستم می‌باشد. در مورد سنجه‌های

"خوب" می‌باشد. همچنین در مورد سنجه‌های MPD و MPE نیز چنین نتیجه‌ای را می‌توان گرفت. به‌طور کلی می‌توان نتیجه گرفت که شبکه عصبی MLP نتایج قابل قبولی در تهیه الگوهای بهره‌برداری داشته و عملکرد سیستم با توجه به سنجه‌های استاندارد "خوب" می‌باشد.

یکی از استانداردهای بیان شده جهت بررسی عملکرد سیستم با استفاده از سنجه‌های ارزیابی، استاندارد ارائه شده توسط Molden and Gates (1990) می‌باشد که در جدول (۳) خلاصه شده است. با توجه به مقادیر MPA و MPF بیان شده در شکل (۵) و مقایسه آن‌ها با جدول (۳) می‌توان نتیجه گرفت که عملکرد سیستم

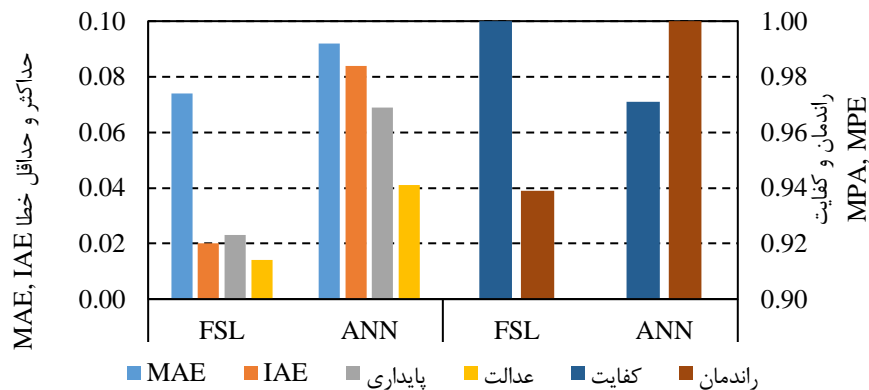
جدول ۳- استاندارد ارائه شده توسط Molden and Gates (1990) برای بررسی سنجه‌ها

Table 3. Molden and Gates (1990) criteria for investigating the indicators

نام شاخص Performance name	کیفیت عملکرد Performance quality		
	خوب Good	مناسب Appropriate	ضعیف Weak
MPA	0.9-1.0	0.8-0.89	< 0.8
MPF	0.85-1.0	0.7-0.84	< 0.7
MPE	0.0-0.1	0.11-0.25	> 0.25
MPD	0.0-0.1	0.11-0.20	> 0.20

تحقیق به همراه نتایج روش FSL تحقیق Shahverdi *et al.* (2016) نمایش داده شده است.

مقایسه عملکرد روش شبکه عصبی MLP و روش FSL در شکل ۷، نتایج روش شبکه عصبی MLP در این



شکل ۷- مقایسه عملکرد روش شبکه عصبی MLP و روش FSL  
Fig. 7- Comparing the performance of MLP and FSL methods

بیانگر سرعت به نسبت زیاد شبکه‌های عصبی مصنوعی در یادگیری و انجام محاسبات می‌باشد. این در حالی است که مدت زمان بیشتری جهت مدل FSL نیاز است. هر بار اجرای شبکه عصبی تنها چند ثانیه طول می‌کشد در حالیکه این مقدار برای مدل FSL حدود چند دقیقه است. بنابراین سرعت زیادتر شبکه عصبی مصنوعی نسبت به یادگیری تقویتی یک مزیت مهم می‌باشد. به‌طور کلی می‌توان نتیجه گرفت با توجه به سنجه‌های ارزیابی، روش FSL نتایج بهتری نسبت به روش MLP

با توجه به نتایج، مشاهده می‌شود که سنجه‌های انحراف عمق از عمق هدف یعنی MAE و IAE در روش FSL کمتر از مقادیر متناظر در روش MLP می‌باشد. کفایت تحویل در روش FSL برابر با ۱ و در روش MLP برابر با ۰/۹۳۹ و راندمان تحویل در روش MLP برابر با ۱ می‌باشد. همچنین پایداری و عدالت تحویل در روش FSL بهتر می‌باشد. افزون بر مقادیر سنجه‌ها، زمان انجام محاسبات مربوطه در دو مدل FSL و MLP نیز مقایسه شد که نتایج آن

سنجه‌های حداکثر خطای عمق، میانگین خطای عمق، راندمان و کفایت بوده و از نظر سنجه‌های عدالت و پایداری در طبقه‌بندی "خوب" با توجه به طبقه‌بندی Molden and Gates (1990) می‌باشد. مقایسه نتایج روش شبکه عصبی مصنوعی با روش FSL نیز نشان داد که در صورت داشتن سری‌های بلند مدت دقیق، می‌توان از شبکه عصبی مصنوعی جهت استخراج دستورالعمل‌های بهره‌برداری استفاده نمود. در غیر اینصورت، روش شبکه عصبی مصنوعی قابلیت کاربرد ندارد. اما روش FSL نیاز به داده آموزشی نداشته و به راحتی و فقط با تعامل با محیط، آموزش را انجام داده و نتایج مناسبی را ارائه می‌دهد. نتایج نشانگر سرعت بالاتر روش شبکه عصبی در آموزش نسبت به FSL است. با توجه به اینکه در اکثر شبکه‌های آبیاری (بویژه شبکه‌های قدیمی) داده‌های دقیق وجود ندارد، نمی‌توان از روش شبکه عصبی مصنوعی استفاده کرد؛ بنابراین، روش FSL جهت کاربرد در شبکه‌های آبیاری و استخراج دستورالعمل‌های بهره‌برداری پیشنهاد می‌شود.

### پی‌نوشت‌ها

- <sup>1</sup> Fuzzy Sarsa Learning
- <sup>2</sup> Artificial Neural Networks
- <sup>3</sup> Delivery Adequacy
- <sup>4</sup> Delivery Efficiency
- <sup>5</sup> time block model
- <sup>6</sup> stream tube model
- <sup>7</sup> Artificial Neural Network
- <sup>8</sup> Multilayer perceptron
- <sup>9</sup> Radial Basis Function
- <sup>10</sup> Reinforcement Learning Algorithm
- <sup>11</sup> System Response Time
- <sup>12</sup> Maximum Absolute Error
- <sup>13</sup> Integral of Absolute Magnitude of Error
- <sup>14</sup> Proprtional Integral
- <sup>15</sup> MPC
- <sup>16</sup> Train
- <sup>17</sup> test
- <sup>18</sup> Validation
- <sup>19</sup> Takagi-Sogeno and Kang

Arauz, T., Maestre, J.M., Tian, X. and Guan, G., 2020. Design of PI controllers for irrigation canals based on linear matrix inequalities. *Water*. 12(3), 855-860.

دارد. با این حال نتایج روش MLP نیز قابل قبول و معتبر می‌باشد. ولی برخلاف اینکه روش MLP با سهولت بیشتری نسبت به روش FSL قابل انجام است ولی نیاز به سری‌های طولانی داده‌ها دارد که در برخی از کانال‌ها چنین داده‌هایی به راحتی در دسترس نیستند. همچنین استفاده از شبکه‌های عصبی مصنوعی جهت تعیین بهترین عمل نیاز به مقادیر بهینه دارد که در بسیاری از کانال‌ها چنین داده‌هایی وجود ندارد. همه این موارد، برتری روش FSL را نسبت به شبکه عصبی مصنوعی نشان می‌دهد.

### نتیجه‌گیری

در این تحقیق، برای اولین بار روش شبکه عصبی مصنوعی به منظور استخراج دستورالعمل‌های بهره‌برداری در محیط نرم‌افزار MATAL 2014 توسعه داده شد و مدل مربوطه تهیه گردید. نتایج حاصل از آن با نتایج یادگیری تقویتی مقایسه شد. آموزش داده‌ها با استفاده از دو روش MLP و RBF در شبکه عصبی انجام شد. برای این منظور، داده‌های بین سال‌های ۱۳۸۷ تا ۱۳۹۶ کانال عقیلی شرقی استفاده شد و ۷۰ درصد آن‌ها برای آموزش شبکه، ۱۵ درصد برای تست و ۱۵ درصد نیز برای اعتبارسنجی و مدل ICSS به عنوان شبیه‌ساز جهت شبیه‌سازی کانال مورد مطالعه استفاده شد. مدل بیان شده توسط انجمن مهندسان عمران کانال، واسنجی و اعتبارسنجی شده است. نتایج نشان داد که روش MLP برای تهیه دستورالعمل‌های بهره‌برداری، روش بهتری می‌باشد و برای استفاده از آن باید مقادیر دبی و عمق آب در بالادست آب‌بندها به عنوان ورودی شبکه و بازشدگی دریچه‌ها به عنوان خروجی شبکه در نظر گرفته شود. نتایج سنجه‌های عملکرد نشان داد که روش MLP دارای دقت بالا از نظر

### منابع

Arekhi, S. and Fathizadehh, H., 2014. Efficiency evaluation of four methods of artificial neural network to provide land use cover using images of

- ETM satellite. *Geography and Development Iranian Journal*. 37, 133-146. (In Persian with English abstract).
- Clemmens, A.J., Kacerek, T.F., Grawitz, B. and Schuurmans, W., 1998. Test cases for canal control algorithms. *Journal of Irrigation and Drainage Engineering*. 124(1), 23-30.
- Glorennec, P.Y. and Jouffe, L., 1997. Fuzzy Q-learning fuzzy systems. In proceedings 4<sup>th</sup> IEEE International Conference, 17<sup>th</sup>-18<sup>th</sup> June, London, England. P.20.
- Haq, Z.U. and Anwar, A.A., 2010. Irrigation scheduling with genetic algorithms. *Journal of Irrigation and Drainage Engineering*. 136(10), 704-714.
- Hassani, Y. and Hashemy, S.M., 2019. Agricultural water distribution under drought conditions based on economic priorities: Case study of Qazvin Irrigation District. *Irrigation and Drainage*. 68(3), 443-451.
- Hykin, S., 1999. *Neural networks: A comprehensive foundation*. Printice-Hall, New Jersey.
- Karbasi, M., 2017. Reconstruction of missing data of monthly total sunshine hours using artificial neural networks. *Iranian Journal of Irrigation and Drainage*. 10(5), 570-580. (In Persian with English abstract).
- Karimizad, F. and Shahsavand, A., 2013. Comparing the results of MLP and RBF methods in predicting simultaneous phenomena of mass transfer and heat convection. *Journal of Modeling in Engineering*. 11(33), 27-43. (In Persian with English abstract).
- Manz, D.H. and Schaalje, M., 1992. Development and application of the irrigation conveyance system simulation model. In CEMAGREF-IIMI Int. Workshop on the application of mathematical modeling for improvement of irrigation canal operation, CEMAGREF, Montpellier, France. P.210.
- Molden, D.J. and Gates, T.K., 1990. Performance measures for evaluation of irrigation-water-delivery systems. *Journal of irrigation and drainage engineering*. 116(6), 804-823.
- Savari, H., Monem, M.J. and Shahverdi, K., 2016. Comparing the performance of FSL and traditional operation methods for on-request water delivery in the Aghili network, Iran. *Journal of Irrigation and Drainage Engineering*. 142(11), 1-8.
- Shahdany, S.H., Taghvaeian, S., Maestre, J. and Firoozfar, A., 2019. Developing a centralized automatic control system to increase flexibility of water delivery within predictable and unpredictable irrigation water demands. *Computers and Electronics in Agriculture*, 163, 1-13.
- Shahrokhnia, M.A. and Ghiasi, A.O., 2018. Evaluation of water delivery performance in doroodzan irrigation network under Two different water requirements. *Irrigation and Drainage Structures Engineering Research*. 19(70), 127-142. (In Persian with English abstract).
- Shahverdi, k., 2015. Development of on-request operation system for irrigation networks using reinforcement learning algorithm (Case Study: East Aghili Canal). Ph.D. Thesis, Tarbiat Modares University, Tehran. (In Persian with English abstract).
- Shahverdi, K. and Monem, M.J., 2015. Application of reinforcement learning algorithm for automation of canal structures, *Irrigation and Drainage*. 64, 77-84.
- Shahverdi, K., Monem, M.J. and Nili, M., 2016a. Application of reinforcement learning algorithm



for determining the operational instructions of the on-request method for optimal water distribution and delivery. *Journal of Water and Soil*. 46(2), 283-291. (In Persian with English abstract).

Shahverdi, K., Monem, M.J., and Nili, M., 2016b. Fuzzy SARSA learning of operational instructions to schedule water distribution and delivery. *Journal of Irrigation and Drainage*. 65, 276–284.

Valipoor, M., Heidarpour, M. and Afrasiabykia, P., 2016. Determination of optimal water distribution policy in an irrigation network (Case Study: Droodzan Network). *Applied Research of Water Sciences*. 2 (2), 11-24. (In Persian with English abstract).





Environmental Sciences Vol.20 / No.1 / Spring 2022

57-76

Original Article

## Operation of irrigation canals using intelligent methods

Fateme Bayat,<sup>1</sup> Hesam Ghodousi<sup>1\*</sup> and Kazem Shahverdi<sup>2</sup>

<sup>1</sup> Department of Water Engineering, Faculty of Agriculture, University of Zanjan, Zanjan, Iran

<sup>2</sup> Department of Water Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamadan, Iran

Received: 2019.08.19 Accepted: 2020.07.12

**Bayat, F., Ghodousi, H. and Shahverdi, K., 2022.** Operation of irrigation canals using intelligent methods. *Environmental Sciences*. 20(1): 57-76

**Introduction:** The rapid growth of population, agriculture, urban and industries has led to increasing water demand and competition for its consumptions. The promotion of agricultural water productivity has the main effect on improving water consumption. Water delivery and scheduling methods are important to increase the flexibility of irrigation systems. Among different available methods, the on-request water delivery has higher flexibility than the rotational one and doesn't need the high cost of automatic systems. The appropriate adjustment of the structures and their operational instructions between successive requests is a function of discharge variation, time interval between operations, coincidence of different request, physical condition of canal and structures and hydrodynamic behavior of the flow, which is a complex task. To obtain the performance of the recently utilized method, i.e., FSL (Fuzzy SARSA Learning), it is necessary to compare it to a traditional method like Artificial Neural Network (ANN). In this research, data from the east Aghili canal was trained for programming water delivery and distribution using MLP (Multi-Layer Perceptron) and RBF (Radial Basis Function) networks of ANN with the on-request method. Finally, the results of the FSL and ANN models were compared.

**Material and methods:** In this research, the MLP (Multi-Layer Perceptron) and RBF (Radial Basis Function) networks of ANN were used to determine the procedure for exploiting the operational instructions of the on-request method in the east Aghili canal, in Khuzestan Province, using its flow and gate opening data. In this research, 70%, 15%, and 15% of data were used to train, test, and validate the model, respectively. The correlation coefficient and root mean square error were used for determining the better method. Modeling of the canal was done using the Irrigation Canal Conveyance System (ICSS) hydrodynamic model. To evaluate

---

\* Corresponding Author: *Email Address.* ghodousi@znu.ac.ir  
<http://dx.doi.org/10.52547/envs.2021.1045>  
<http://dorl.net/dor/20.1001.1.17351324.1401.20.1.7.6>

the MLP, RBF, and FSL outputs, maximum and average errors of water depth, adequacy, efficiency, equity, and dependability were used.

**Results and discussion:** The operational instructions were determined using the MLP in March 2017 in the east Aghili canal, and were compared to the corresponding determined operational instructions using FSL. According to the obtained results, it was observed that the MPA index in the ANN method in the first and second block of this channel, respectively were 0.952 and 0.919 and in the case of using the FSL method, these values were equal to 0.996 and 1. Also, the MPF index in the simulation using the ANN in both blocks were equal to 1 and in the case of FSL, these values were equal to 0.999 and 0.971. The maximum error of MAE of water level in the first and second block of the study, respectively were equal to 9.2 and 3.8 % and in the case of using the FSL method, these were equal to 5.5 and 7.4 %. The results showed that the MLP was better than the RBF to determine the operational instructions. The MAE and IAE indicators were minimum, and the water delivery indicators were close to their desired values according to the Molden and Gates (1990) criteria. Also, it was revealed that the FSL was better than the MLP, however, the MLP results were valid and can be used in practice.

**Conclusion:** In this research, the ANN model was used for determining operational instructions using MATLAB. The training was done using the MLP and RBF using the east Aghili canal data. The ICSS was used for simulating the canal. The results showed that the MLP was better than RBF, and the FSL model was better than the MLP as well. However, both of them can be used in practice.

**Keywords:** East Aghili canal, Performance indicators, On-request method, Operation performance.

