



## مدلسازی و مقایسه شبکه‌های عصبی مصنوعی GMDH و RBF در پیش‌بینی تقاضای کوتاه‌مدت آب شرب شهر زاهدان

مجتبی عباسیان<sup>۱</sup>، علی سردار شهرکی<sup>۲</sup>

تاریخ ارسال: ۱۳۹۷/۰۵/۱۶

تاریخ پذیرش: ۱۳۹۷/۰۷/۰۷

مقاله علمی پژوهشی

### چکیده

آب بخش شهری زاهدان از طریق انتقال آب از مخازن چاه نیمه سیستان تأمین شده که خود دچار بحران شدید آبی است. از اینرو پیش‌بینی تقاضای آب شرب این شهر، کمک مؤثری به مدیران و بهره‌برداران سیستم آب شهری خواهد نمود، تا بتوانند نسبت به مدیریت صحیح مصرف اقدام نمایند. لذا در این مقاله از شبکه‌های عصبی مصنوعی GMDH و RBF که از ابزارهای قدرتمند برای تجزیه و تحلیل و مدل‌سازی روابط غیرخطی به حساب می‌آیند، برای برآورد تقاضای ماهانه آب شهری زاهدان در سال ۱۳۹۶ استفاده شد. پارامترهای موثر انتخاب شده، شامل میانگین دمای ماهانه، درصد رطوبت نسبی، متوسط میزان بارندگی، ساعات آفتابی و مصرف ماه قبل می‌باشند. نتایج بدست آمده و مقایسه شاخص‌های MSE و MAE نشان می‌دهد با توجه به بررسی هفت ساختار مختلف با تعداد متفاوت نرون و لایه‌های نهان، شبکه عصبی GMDH با سه لایه نهان که دارای یک نرون در لایه اول، سه نرون در لایه نهان دوم و سه نرون در لایه نهان سوم می‌باشد، بهترین نتیجه را برای پیش‌بینی تقاضای کوتاه مدت آب شرب نشان داد. با مقایسه توابع فعالیت خطی و غیر خطی مشخص شد که در لایه خروجی مدل‌های عصبی GMDH و RBF، توابع غیر خطی عملکرد بهتری نسبت به توابع خطی از خود نشان می‌دهند. همچنین در بین مدل‌های GMDH نیز مدل‌های با خروجی غیرخطی نسبت به مدل‌های با خروجی خطی مناسب‌تر می‌باشند. همچنین نتایج حاکی از آن بود که بزرگتر کردن ساختار شبکه، تاثیر چندانی بر بهبود نتایج ندارد.

**واژه‌های کلیدی:** پیش‌بینی کوتاه مدت، تقاضای آب، شبکه عصبی مصنوعی، RBF، GMDH

۱ - استادیار گروه اقتصاد، دانشگاه دریانوردی و علوم دریایی چابهار، abbasian@cmu.ac.ir

۲ - نویسنده مسئول: استادیار گروه اقتصاد کشاورزی، دانشگاه سیستان و بلوچستان، a.s.shahraki@eco.usb.ac.ir



## مقدمه

ضرورت پیش بینی مصرف آب به این دلیل است که پیش-بینی میزان مصرف آب می‌تواند تا حدودی دولت را از مواجه شدن با مشکلات ناشی از کمبود آب مصون نگه دارد. همچنین در مدیریت آب شهری دانستن تقاضای کوتاه مدت بسیار مهم و حیاتی است (Tabesh et al., 2008)، به عبارتی برخی از خصوصیات بررسی سیاست های مدیریت تقاضا و مدیریت عملیاتی سیستم توزیع آب به این پیش بینی وابسته اند. از طرفی کمبود آب و نقش آن در کشورهایی مانند ایران که سرانه آب تجدید پذیر کمتر از هزار متر مکعب را پیش رو دارند، اهمیت پیش بینی کوتاه مدت مصرف آب را بیشتر می کند (Sadeghi et al., 2012).

روشهای مختلفی برای پیش بینی متغیرهای سری زمانی وجود دارد، اقتصاد دانان برای برآورد تابع تقاضا غالباً از روشهای اقتصاد سنجی استفاده می کنند. در حالت کلی روش های پیش بینی را می توان به دو دسته خطی و غیرخطی تقسیم بندی نمود. در سالهای اخیر به موازات پیشرفت های قابل توجه در پردازش سریع اطلاعات بوسیله ماشین های الکترونیکی، بکارگیری مدل ها غیرخطی در میان اقتصاددانان بطور چشمگیری افزایش یافته است. مدل شبکه های عصبی از معروف ترین این مدلها می باشد که استفاده از آن در اقتصاد کلان در دهه ۹۰ مورد توجه پژوهشگران قرار گرفت. امروزه از بین روش های پیش بینی، شبکه های عصبی مصنوعی یکی از ابزارهای قدرتمند برای تجزیه و تحلیل مدل سازی روابط غیرخطی به حساب می-آید. لذا در این مطالعه با استفاده از شبکه های عصبی مصنوعی GMDH1 و RBF نسبت به مدل سازی و پیش بینی تقاضای کوتاه مدت آب شرب شهر زاهدان اقدام شد. از نقاط قوت این تحقیق می توان استفاده از دو نوع ساختار شبکه عصبی مصنوعی متفاوت و مقایسه نتایج آنها با همدیگر، تنوع بیشتر، تفاوت ساختارها و تفاوت پارامترهای مدل را برشمرد.

افزایش جمعیت طی سالهای اخیر عرضه سرانه منابع طبیعی را محدود و تحت فشار قرار داده و لذا طراحی ساز و کارهایی برای تخصیص بهینه عرضه این منابع بین تقاضاهای رقابتی مورد نیاز است (یحیوی و همکاران، ۱۳۸۷). برداشت بی رویه از منابع زیر زمینی، کاهش بارش و بروز خشکسالی در اکثر نقاط جهان و آلودگی آب سطحی و زیرزمینی، بر شدت کمبود منابع آب افزوده اند، بنابراین استفاده از این منبع حیاتی مستلزم اعمال مدیریت صحیح می باشد. سیاست های مدیریت تقاضای آب اساساً شامل حداقل کردن تلفات در سیستم های نگهداری و انتقال، استفاده دوباره از آب، کاهش مصرف آب از طریق اجتناب کردن از اسراف آب، استفاده صحیح و کارا از منابع آب می-باشد (Sardar Shahraki, 2017).

پیش بینی تقاضای آب شهری کمک مؤثری به مدیران و بهره برداران سیستم های آب شهری می باشد تا بتوانند نسبت به مدیریت صحیح مصرف اقدام نمایند. در این راستا پیش بینی دقیق تقاضا از این نیاز حیاتی در دوره های زمانی مختلف حائز اهمیت می باشد (Sadeghi et al., 2012). بطور کلی پیش بینی تقاضای آب در سه دسته اصلی صورت می گیرد: پیش بینی دراز مدت که معمولاً بازه ای از یک تا چند سال را در بر می گیرد و بمنظور سرمایه گذاری های وسیع مورد نیاز در شبکه های آبرسانی برای سالهای آتی صورت می پذیرد، پیش بینی میان مدت که مربوط به نوسانات تقاضای آب در طول سال می باشد و می تواند بصورت تغییرات فصلی تقاضای آب ارزیابی شود و پیش بینی کوتاه مدت که معمولاً بازه ای از یک ساعت تا چند روز را شامل می شود که در مدیریت و بهره برداری بهینه از شبکه اهمیت بسزایی دارد و در اجرای سیاست های طرف تقاضا مانند جیره بندی، زمان بندی قطع وصل پمپ ها و شیر آلات، زمان بندی تأسیسات آب و فاضلاب مؤثر می باشد (Tabesh et al., 2009).



## ادبیات و پیشینه تحقیق

تحقیقات انجام گرفته در زمینه پیش بینی تقاضای آب همواره مورد توجه بوده، ولی روشهای پیش بینی و انگیزه آن در طول این دوران متفاوت بوده است. شروع تحقیقات در زمینه پیش بینی تقاضا بیشتر بر اساس مدل های آماری رگرسیون چندگانه و سری های زمانی بوده است. بطور کلی بعلت توان بالای سیستم های خبره برای مدل سازی سیستم های طبیعی از آنها در زمینه های مختلف علوم پایه و مهندسی از جمله بخش آب استفاده شده است که نتایج خوبی در مدل سازی و انجام پیش بینی بدست آمده است. استفاده از سیستم های خبره بخصوص شبکه های عصبی مصنوعی برای پیش بینی تقاضای کوتاه مدت آب در سالهای اخیر مورد توجه قرار گرفته است، که در ادامه مختصراً به آنها اشاره می گردد:

Kostas and Chrysostomos (2006) در مطالعه خود تحت عنوان تخمین تعیین کننده های تقاضای آب مسکونی شهر و پیش بینی تقاضای آب برای بخش های مرکزی آتن تأثیرات متغیر های درآمد و قیمت آب را روی تقاضای آب مورد بررسی قرار دادند. نتیجه پژوهش آنها مؤید آن بود که عوامل اقتصادی تأثیر چندانی بر مصرف آب ندارند و انتظار افزایش درآمد در آینده موجب افزایش تقاضای آب می شود. Vairavamoorthy & Khatri (2009) در پژوهش خود با معرفی مدلی به بررسی ارتباط بین تقاضای آب شهر بیرمنگام با شرایط آب و هوایی، آلودگی و رشد اقتصادی پرداختند. نتایج این تحقیق نشان داد که تقاضای آب در آینده برای بیرمنگام بوسیله فاکتورهای اقتصادی- اجتماعی متأثر خواهد شد و متأثر از تغییرات آب و هوا نیست. Sharzei et al. (2009) در پژوهشی تحت عنوان پیش بینی تقاضای آب شهر تهران با استفاده از الگوی ساختاری، سری های زمانی و شبکه عصبی نوعی GMDH به مقایسه روش های پیش بینی تقاضای سرانه آب در شهر تهران پرداخته اند. متغیرهای مورد

استفاده در این پژوهش مصرف سرانه آب قیمت آب، متوسط در آمد خانوار و متوسط درجه حرارت سالانه شهر تهران بود. نتایج بدست آمده نشان داد که پیش بینی تقاضای آب با استفاده از روش شبکه های عصبی GMDH نسبت به روش های ساختاری و سری زمانی از درجه کارایی بیشتری برخوردار است.

Liu and Chang (2010) در تحقیق خود از تئوری خاکستری و شبکه عصبی مصنوعی جهت پیش بینی تقاضای آب شهر یانگ کوان در سال ۱۹۹۸، ۱۹۹۹ و ۲۰۰۰ استفاده نمودند. نتیجه نشان داد که دقت پیش بینی در مدل شبکه عصبی RBF بهتر از مدل تئوری خاکستری (GM) بوده و دوره پیش بینی نیز طولانی تر از مدل خاکستری می باشد.

Tabesh et al (2010) در مطالعه خود تحت عنوان پیش بینی تقاضای کوتاه مدت شهر تهران با استفاده از شبکه های عصبی مصنوعی با استفاده از شبکه های عصبی پرسپترون چند لایه و با الگوریتم آموزشی پس انتشار خطا میزان مصرف یک روزه آب شهر تهران را بر اساس پارامترهای هواشناسی و داده های تاریخی مصارف گذشته پیش بینی نمودند. در مطالعه مذکور همچنین با استفاده از شبکه های عصبی مصنوعی، یک فرمول ساده برای پیش بینی میزان مصرف آب شهر تهران طراحی شده که قادر است میزان تقاضای روزانه آب شهر تهران را تخمین بزند. Sadeghi et al (2012) در مدل سازی و پیش بینی کوتاه مدت تقاضای آب شهری و در طراحی شبکه عصبی مصنوعی، عوامل موثر بر تقاضای روزانه آب شهری، دمای هوا (حداقل، حداکثر و متوسط)، روزهای هفته، ایام تعطیلات و روزهای خاص در نظر گرفتند، نتایج حاصل از بکارگیری معیارهای ارزیابی دقت پیش بینی، نشان داد که شبکه عصبی مصنوعی در پیش بینی تقاضای روزانه آب شهر تهران نسبت به مدل 1ARMA از قدرت بالاتری برخوردار می باشد. Al-Zahrani & Abo-Monasar



(RBF) و خطی<sup>۷</sup> را به منظور پیش بینی تراز سطح آب زیرزمینی دشت شهرکرد بررسی نمودند. نتایج نشان داد که با توجه به معیارهای خطای ضریب راندمان و ریشه میانگین مربعات خطا (RMSE<sup>۸</sup>)، مدل (MLP) در ۵۶ درصد و مدل SVR نیز در ۴۴ درصد موارد عملکرد بهتری نسبت به نتایج کل سایر مدل ها داشته اند

Perea et al (2018) برای ارائه پیش بینی کوتاه مدت تقاضای آب آبیاری روزانه از شبکه های عصبی مصنوعی (ANN)، چارچوب بیزی و الگوریتم های ژنتیک در منطقه آبیاری جنوب اسپانیا استفاده نمودند. بهترین مدل ANN دارای پیش بینی استاندارد خطا (SEP) و ضریب تعیین  $R^2$  به ترتیب ۸/۷٪ و ۹۶٪ بود.

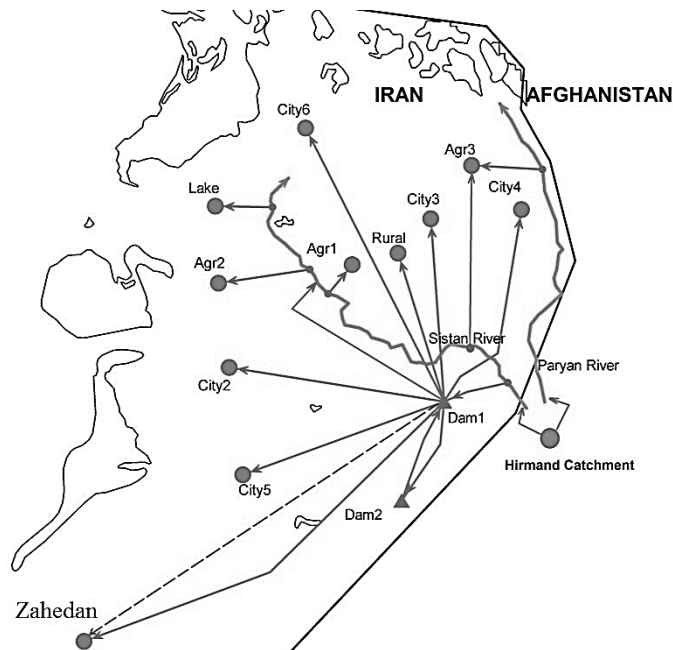
بررسی مطالعات پیشین نشان می دهد که پیش بینی تقاضای آب شهری بسیار مورد توجه بوده است. در این زمینه، کاربرد تکنیک های شبکه عصبی مصنوعی از جایگاه خاصی برخوردار بوده است. استان سیستان و بلوچستان به دلیل شرایط جوی و خشکسالی های مکرر در وضعیت بحران آبی قرار گرفته است. از طرفی آب شرب شهر زاهدان از طریق مخازن چاه نیمه سیستان با انتقال آب ۲۰۰ کیلومتری (شکل ۱) تأمین شده می شود. تأمین آب شهرستان زاهدان از طریق انتقال آب از مخازن چاه نیمه سیستان با خط هاشور نشان داده شده است. انتقال خط لوله آب شرب شهرستان زاهدان با حجم ۲۶ متر مکعب بر ثانیه در حال اجرا می باشد. با توجه به پیش گفته ها و وضعیت موجود، ضرورت تخمین تقاضای آب شهر زاهدان بیش از پیش نمایان است. از اینرو در پژوهش حاضر کاربرد تکنیک های شبکه عصبی مصنوعی برای تخمین و پیش بینی برای اولین بار کاربردی شده است.

(2015) پیش بینی تقاضای آب روزانه شهر الخبار در پادشاه عربستان سعودی مورد بررسی قرار دادند. برای این منظور، از روش ترکیبی شبکه های عصبی مصنوعی (ANN) و سری زمانی بصورت شبکه عصبی رگرسیون عمومی<sup>۱</sup> (GRNN) استفاده شد. نتایج نشان داد که مدل ترکیبی GRNN در مقایسه با استفاده از مدل های ANN و یا سری سری زمانی نتایج بهتری همراه خواهد داشت. Mousavi and Kavousi (2016) با بهره گیری از سه رهیافت خود توضیح جمعی میانگین متحرک فصلی، شبکه عصبی مصنوعی و الگوی هیبرید خود توضیح جمعی میانگین متحرک فصلی در ترکیب با الگوریتم پس انتشار خطا به الگوسازی و پیش بینی مقدار مصرف آب شرب شهر رشت پرداختند. پیش بینی مقدار مصرف آب شهر رشت برای ماه های سال ۱۳۸۸ با استفاده از سه الگوی یادشده گویای برتری و قدرت پیش بینی بالای الگوی هیبرید SARIMABP<sup>۲</sup> بود. از سوی دیگر، دو الگوی SARIMA<sup>۲</sup> و ANN<sup>۳</sup> نیز با خطای پیش بینی کمتر از یک درصد نتایج مطلوبی را برای استفاده مدیران شهری فراهم نموده است. Gagliardi et al (2017) در تحقیقشان روش پیش بینی تقاضای آب در کوتاه مدت مبتنی بر استفاده از زنجیره مارکوف را که مبتنی بر محاسبه احتمالاتی ارزش تقاضای آب در آینده می باشد را بصورت دو حالت زنجیره مارکوف همگن و غیر همگن پیشنهاد نمودند. نتایج بدست آمده نشان می دهد که مدل مبتنی بر یک زنجیره همگن مارکوف، پیش بینی های دقیق تری نسبت به یک زنجیره مارکوف غیر همگن ارائه می دهد.

Ramezani and Zounemat Kermani (2017) کارایی روش های گرسون خطی چند متغیره (MLR<sup>۴</sup>)، شبکه عصبی پرسپترون چند لایه (MLP<sup>۵</sup>) و دو مدل رگرسیونی ماشین بردار پشتیبان (SVR<sup>۶</sup>) با توابع کرنل پایه شعاعی

5- Multi layer perceptron  
6- Support Vector Regression  
7- Linear  
8- Root-Mean-Square Error

1- General Regression Neural Network (GRNN) model  
2- Seasonal autoregressive integrated moving average  
3- Artificial Neural Network  
4- Multiple Linear Regression



شکل (۱): تأمین آب شهرستان زاهدان از طریق انتقال آب از مخازن چاه‌نیمه‌ی سیستان

## روش پژوهش

در این پژوهش از دو نوع شبکه عصبی GMDH و شبکه عصبی RBF برای ساخت مدل‌های پیش‌بینی تقاضای روزانه آب استفاده شد.

در اینجا مدل بدنبال شبکه‌ای که بتواند مقدار خروجی  $\hat{y}$  را برای هر بردار ورودی  $X$  بر اساس رابطه (۲) پیش‌بینی کند، می‌باشد:

$$\hat{y}_i = f(x_{1i}, x_{2i}, x_{3i}, \dots, x_{ni}) ; \quad i = 1, 2, \dots, M \quad (2)$$

بطوری که میانگین مربعات خطا بین مقادیر حقیقی و پیش‌بینی کمینه شود، به بیان دیگر:

$$MSE = \frac{\sum_{i=1}^M (\hat{y}_i - y_i)^2}{M} \rightarrow Min \quad (3)$$

شکل عمومی اتصال بین متغیرهای ورودی و خروجی را می‌توان با استفاده از تابع چند جمله‌ای به شکل رابطه (۴)، بیان کرد:

$$y = \alpha_0 + \sum_{i=1}^n \alpha_i x_i + \sum_{i=1}^n \sum_{j=1}^n \alpha_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n \alpha_{ijk} x_i x_j x_k + \dots \quad (4)$$

## الف) شبکه عصبی GMDH

شبکه عصبی GMDH دربرگیرنده مجموعه‌ای از نرون‌ها است که از پیوند جفت‌های مختلف از طریق یک چند جمله‌ای درجه دوم بوجود می‌آیند، شبکه با ترکیب چند جمله‌ای‌های درجه دوم حاصل از تمامی نرون‌ها، تابع تقریبی  $\hat{f}$  را با خروجی  $\hat{y}$  برای یک مجموعه از ورودی‌های  $X = (x_1, x_2, x_3, \dots, x_n)$  با کمترین خطا در مقایسه با خروجی واقعی  $y$ ، توصیف می‌کند. بنابراین برای  $M$  داده آزمایشگاهی شامل  $n$  ورودی و یک خروجی، نتایج واقعی به شکل رابطه (۱) نمایش داده می‌شوند (Sharzei et al., 2009):

$$y_i = f(x_{1i}, x_{2i}, x_{3i}, \dots, x_{ni}) \quad \forall i = 1, 2, \dots, M \quad (1)$$



از شکل درجه دوم تابع بیان شده در رابطه (۵) برای هر  $M$  ردیف سه تایی استفاده می‌شود، این معادلات را می‌توان به شکل ماتریسی رابطه (۸) بیان کرد:

$$A\alpha = Y \quad (8)$$

که در آن  $A$  بردار ضرایب مجهول معادله درجه دو نشان داده شده در رابطه (۵) است:

$$\alpha = \{\alpha_0, \alpha_1, \dots, \alpha_5\} \quad (9)$$

$$Y = \{y_1, y_2, y_3, \dots, y_M\}^T \quad (10)$$

از مقادیر بردارهای ورودی و شکل تابع به راحتی قابل مشاهده است که:

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}^2 & x_{1q}^2 & x_{1p}x_{1q} \\ 1 & x_{2p} & x_{2q} & x_{2p}^2 & x_{2q}^2 & x_{2p}x_{2q} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{Mp} & x_{Mq} & x_{Mp}^2 & x_{Mq}^2 & x_{Mp}x_{Mq} \end{bmatrix} \quad (11)$$

روش حداقل مربعات از آنالیز *Multiple-Regression* حل معادلات را به شکل رابطه (۱۲) بدست می‌دهد:

$$\alpha = (A^T A)^{-1} A^T Y \quad (12)$$

این معادله بردار ضرایب رابطه (۵) را برای تمام  $M$  مجموعه سه تایی ایجاد می‌کند. ضرایب نرون ها در لایه های پنهان و خروجی در مرحله مدل سازی (آموزش) بر اساس تعریف اولیه برنامه از سطح معناداری و فاصله اطمینان مورد نظر پژوهشگر، تعیین و فرآیند بهینه یابی ضرایب و معادلات نرون ها و سازوکار غربال سازی داده ها، یعنی حذف متغیرهایی که همبستگی پائینی را در این

که چند جمله ای ایواخنکو<sup>۱</sup> نامیده می‌شود. در بسیاری از موارد کاربردی از شکل درجه دوم و دو متغیره این چند جمله ای بصورت رابطه (۵) استفاده می‌شود:

$$\hat{y} = G(x_i, x_j) = \alpha_0 + \alpha_1 x_i + \alpha_2 x_j + \alpha_3 x_i^2 + \alpha_4 x_j^2 + \alpha_5 x_i x_j \quad (5)$$

ضرایب مجهول  $\alpha_i$  در رابطه (۵) با تکنیک‌های رگرسیونی چنان بدست می‌آیند که اختلاف بین خروجی واقعی  $y$  و مقادیر محاسبه شده  $\hat{y}$  برای هر جفت متغیر ورودی  $x_i, x_j$  کمینه شود (Sharzei et al., 2009). مجموعه ای از چند جمله ای ها با استفاده از رابطه (۵) ساخته می‌شوند که ضرایب مجهول تمام آنها با استفاده از روش حداقل مربعات ( $LS$ ) بدست می‌آیند. برای هر تابع  $G_i$  (هر نرون ساخته شده)، ضرایب معادلات هر نرون برای حداقل کردن خطای کل آن بمنظور انطباق بهینه ورودی ها بر تمام جفت مجموعه های ورودی- خروجی بدست می‌آیند:

$$E = \frac{\sum_{i=1}^M (y_i - G_i)^2}{M} \rightarrow Min \quad (6)$$


در روش های پایه ای الگوریتم  $GMDH$ ، تمامی ترکیبات دوتایی (نرون ها) از  $n$  متغیر ورودی ساخته شده و ضرایب نامعلوم تمام نرون ها با استفاده از روش حداقل مربعات

بدست می‌آیند. بنابراین  $\binom{n}{2} = \frac{n(n-1)}{2}$  نرون در لایه دوم ساخته می‌شوند که آن را می‌توان به شکل مجموعه (۷) نمایش داد:

$$\{(y_i, x_{ip}, x_{iq}) | (i=1,2,3,\dots,M) \ \& \ p,q \in (1,2,\dots,M)\} \quad (7)$$

**(ب) شبکه تابع پایه شعاعی (RBF)**

شبکه تابع پایه شعاعی از جمله شبکه های پیشرو با سه لایه می باشند. مدل RBF دارای سه لایه ورودی، لایه مخفی و لایه خروجی می باشد که ساختار کلی آن در شکل (۲) ارائه شده است.



شکل (۲): ساختار کلی شبکه عصبی RBF

مرحله نشان می دهند توسط الگوریتم ژنتیک صورت می گیرد، بنابراین محاسبات در حجم بالا در عمل قابل حل بوده و کمک می کند تا سیستم معادلات نرمال در شرایط مناسب و قابل حل قرار گیرد.

که در آن ثابت ها به عنوان قطر های ماتریس نرم می باشند، خروجی شبکه بصورت زیر محاسبه می شود:

$$y = \sum_{i=0}^m W_i \exp\left(-\frac{1}{2}u_i^2\right) \quad (15)$$

در نتیجه یک شبکه RBF دارای دسته پارامترهای زیر است: ۱- وزن های لایه خروجی  $W_i$  که دسته پارامترهای خطی هستند و میزان اریب و ارتفاع توابع پایه را مشخص می کنند.

۲- پرداز مراکز  $C_i$  که از دسته پارامترهای غیرخطی نرون های لایه مخفی بوده و مکان توابع پایه را مشخص می کنند.

۳- انحراف معیارهای  $\sigma_{ij}$  که پهنا و میزان دوران توابع پایه گوسی را نشان می دهند.

در آموزش شبکه RBF ابتدا با استفاده از الگوریتم خوشه یابی k-means پارامترهای لایه مخفی محاسبه و سپس با استفاده از کمترین مربعات، وزن های لایه خروجی که خطی می باشد محاسبه می گردد (Tabesh and Dini, 2011).

در این مدل تابع فعال ساز، غیر خطی و گوسی شکل است که به صورت رابطه زیر تعریف می شود (Tabesh and Dini, 2011):

$$g(u) = \text{Exp}\left(-\frac{1}{2}u_i^2\right) \quad (13)$$

که در آن  $u_i$  فاصله بردار ورودی  $x_j = [x_1, x_2, \dots, x_p]$  از بردار مرکز  $C_i = [c_{i1}, c_{i2}, \dots, c_{ip}]$  با ماتریس نرم می باشد و بصورت رابطه زیر تعریف می شود:

$$u_i = \|X_j - C_i\|_{\sum_j} = \sqrt{\sum_{j=1}^p \left(\frac{X_j - C_{ij}}{\sigma_{ij}}\right)^2} = \sqrt{\left(\frac{X_1 - C_{i1}}{\sigma_{i1}}\right)^2 + \dots + \left(\frac{X_p - C_{ip}}{\sigma_{ip}}\right)^2} \quad (14)$$

ماتریس نرم  $\sum_j$  با مقادیر ثابت  $[\sigma_{i1}, \sigma_{i2}, \dots, \sigma_{ip}]$  به عنوان پارامتر لایه مخفی نرون شبکه RBF می باشد



برای مقایسه قابلیت پیش بینی RBF و GMDH با شبکه های عصبی مصنوعی از ۲ معیار ارزیابی مدل های رقیب که در جدول (۱) ارائه شده اند، استفاده گردید.

جدول (۱): مدل های ارزیابی مدل های رقیب

فرمول	معیار
$MSE = \frac{\sum(\hat{y} - y)^2}{n}$	میانگین مربعات خطا
$MSE = \frac{\sum \hat{y} - y }{n}$	میانگین قدرمطلق انحراف

بیشترین مقدار همبستگی با مصرف آب بودند، برای مدل سازی انتخاب گردیدند. نتایج حاصل از تحلیل مقادیر همبستگی، برای پارامترهای مختلف در جدول (۲) آورده شده است.

با توجه به نتایج بدست آمده پارامترهای زیر برای مدل سازی انتخاب گردید:

۱. دمای متوسط روزانه بدلیل داشتن ضریب همبستگی زیاد با مصرف آب و امکان پیش بینی آن توسط سازمان هواشناسی با دقت بالا برای چند روز آینده.
۲. رطوبت نسبی هوا بدلیل وجود همبستگی منفی و نسبتاً بالا.
۳. مصرف ماه قبل بدلیل وجود همبستگی نسبتاً بالا و وارد کردن اثرات تغییرات هفتگی مصرف.
۴. میزان بارندگی بدلیل وجود همبستگی مثبت و نسبتاً بالا.

اطلاعات لازم برای بررسی و تحلیل آماری عوامل موثر بر تقاضای آب و تهیه مدل پیش بینی تقاضای آب شامل داده های هواشناسی و مصرف آب است. داده های هواشناسی از اداره کل هواشناسی سیستان و بلوچستان که شامل پارامترهای هواشناسی ماهانه (حداکثر دما، حداقل دما، میانگین دما، حداکثر رطوبت، میانگین رطوبت، میزان بارندگی، سمت باد حداکثر، سرعت باد حداکثر، ساعت آفتابی) تهیه شد و داده های مربوط به تقاضا و تولید آب (آب تصفیه شده) از شرکت آب و فاضلاب شهرستان زاهدان که شامل مصرف ماهانه آب بود، از فروردین ۸۱ تا مهر ۹۶ تهیه گردید.

## نتایج و بحث

برای شناسایی عوامل مؤثر بر تقاضای آب شهر زاهدان تحلیل همبستگی بر روی داده های موجود انجام گرفت و سپس با توجه به مقدار ضریب همبستگی عواملی که دارای





جدول (۲). ضرایب همبستگی بین انواع پارامترهای هواشناسی با تقاضای ماهانه آب زاهدان در دوره پانزده ساله

پارامتر	مقدار
مصرف ماهانه آب	۱/۰۰۰
حداکثر دما	۰/۸۰۶
حداقل دما	۰/۶۱۶
میانگین دما	۰/۷۰۳
حداکثر رطوبت	-۰/۴۶۳
حداقل رطوبت	-۰/۴۶۶
میانگین رطوبت (%)	-۰/۴۷۲
میزان بارندگی	۰/۷۲۴
سمت باد حداکثر	۰/۳۲۶
سرعت باد حداقل	۰/۳۱۶
ساعت آفتابی	۰/۳۷۴

ماخذ: یافته های تحقیق

تعداد مناسب نرون ها دیگر پارامترهای شبکه عصبی بهینه تعیین و استخراج گردید و کلیه محاسبات برحسب این شبکه بهینه انجام شد.

پس از تعیین تعداد نرون های ورودی بهینه، برای انتخاب تعداد نرونهای لایه مخفی شبکه، شبکه های مختلف با تعداد نرونهای متفاوت طراحی و آموزش داده شد. برای پیدا کردن ساختار بهینه مدل GMDH با خروجی خطی و غیرخطی، ابتدا از یک ساختار ساده شروع کرده و با گامهای آموزشی ثابت یک به یک، نرون های لایه مخفی افزایش یافتند.

برای ساخت و تعیین ساختار بهینه مدل های شبکه عصبی مصنوعی داده های ورودی به سه قسمت تقسیم شد، قسمت اول شامل ۷۰ درصد داده ها برای آموزش، قسمت دوم شامل ۱۵ درصد داده ها برای تصدیق و قسمت سوم شامل ۱۵ درصد داده ها برای آزمون بود. برای شبیه سازی مدل ها از محیط برنامه نویسی نرم افزار MATLAB استفاده گردید و برای هر یک از مدل های عصبی بکار رفته، چندین فایل MATLAB تهیه شد. در این فایل ها در ابتدا ساختار مناسب از نظر تعداد نرون ها تعیین شد و پس از تعیین

جدول (۳): مقایسه نتایج مدل های مختلف شبکه عصبی GMDH


MAE	MSE	آرایش نرونی	شبکه GMDH
۵/۹۶	۵/۶۳	Nonlinear ۱-۵-۴	Model 1
۶/۸۹	۶/۴۴	Linear ۱-۴-۳	Model 2
۳/۰۱	۲/۶۳	Nonlinear ۱-۴-۳	Model 3
۶/۴۱	۶/۲۹	Linear ۱-۸-۲	Model 4
۴/۵۶	۴/۰۹	Nonlinear ۱-۸-۲	Model 5
۲/۷۲	۲/۰۷	Linear ۱-۱۱-۳	Model 6
۱/۵۳	۱/۰۲	Nonlinear ۱-۱۱-۳	Model 7

ماخذ: یافته های تحقیق



غیرخطی مشخص شد که در لایه خروجی مدل عصبی GMDH، توابع فعالیت غیرخطی عملکرد بهتری نسبت به توابع خطی از خود نشان می دهند. نمودار (۱) تقاضای پیش بینی شده و واقعی آب تحت مدل GMDH را نشان می دهد.

با توجه به نتایج جدول (۳) و بررسی ساختارهای مختلف با تعداد متفاوت نرون و لایه های مخفی با توجه به معیار MSE، شبکه بهینه انتخاب گردید، یعنی شبکه با کمترین میانگین مربعات خطا که دارای ۳ نرون ورودی و ۱۱ نرون لایه مخفی می باشد، بهترین نتیجه را برای تخمین تقاضای ماهانه آب شهر زاهدان نشان داد. با مقایسه توابع خطی و



نمودار (۱): تقاضای پیش بینی شده و واقعی آب تحت مدل GMDH

در جدول (۴) مقایسه نتایج مدل های مختلف شبکه عصبی RBF ارائه گردیده است.

همانگونه که در نمودار (۱) مشاهده می شود، تقاضای آب برآورد شده بوسیله مدل به حدی به تقاضای واقعی نزدیک است که تقاضای آب واقعی و پیش بینی شده در بیشتر موارد بر هم منطبق اند.


جدول (۴): مقایسه نتایج مدل های مختلف شبکه عصبی RBF

MAE	MSE	آرایش نرونی	شبکه RBF
۳/۲۹	۳/۱	۱-۱-۱۱-۲	Model 1
۵/۹۶	۵/۲۲	۱-۱-۱۰-۵	Model 2
۴/۸۹	۳/۴۱	۱-۱-۵-۳	Model 3
۴/۰۱	۳/۲۰	۱-۱-۴-۳	Model 4
۶/۴۱	۳/۸۱	۱-۱-۴-۴	Model 5
۴/۵۶	۳/۰۵	۱-۱-۲-۲	Model 6
۳/۷۲	۲/۹۸	۱-۱-۴-۲	Model 7

ماخذ: یافته های تحقیق

همچنین به دلیل اینکه در این مدل عصبی با استفاده یکباره از کل داده ها از روش خوشه یابی و کمترین مربعات با تخمین خطی استفاده می شود، دیگر تعداد گامهای آموزشی هیچ مفهومی ندارند. نمودار (۲) نتایج تقاضای آب پیش بینی شده و تقاضای واقعی آب را تحت مدل RBF نشان می دهد.

برای تعیین ساختار مناسب شبکه RBF، نمودار معیار خطا برای دسته داده های آموزش، آزمون و تصدیق رسم شد و تعداد مناسب نرون، همان تعدادی در نظر گرفته شد که به ازای آن، میزان هر سه خطا بطور متناسب با هم کم شده باشد. تعداد مناسب نرون در شبکه RBF با توجه به نحوه تغییرات خطا نسبت به تعداد نرون ها، برابر ۴ انتخاب گردید.



نمودار (۲): نتایج تقاضای آب پیش بینی شده و تقاضای واقعی آب را بوسیله مدل RBF

جدول (۵) عملکرد مدل های بهینه GMDH و RBF در پیش بینی تقاضای آب شهر زاهدان بر حسب معیارهای MSE و MAE نشان می دهد.

جدول (۵): مقایسه و ارزیابی قدرت پیش بینی مدل های بهینه RBF و GMDH

MAE	MSE	مدل بهینه	مدل
۱/۵۳	۱/۰۲	Nonlinear ۱-۱۱-۳	GMDH Neural Network
۳/۷۲	۲/۹۸	۱-۱-۴-۲	RBF Neural Network

ماخذ: یافته های تحقیق

براساس همه معیارهای مورد بررسی (MSE, MAE) در این مطالعه، عملکرد بهتری نسبت به مدل رقیب در پیش بینی تقاضای آب در شهر زاهدان داشته است. از سویی دیگر، اگر

مقایسه نتایج بدست آمده نشان می دهد که هر چند در مجموع، هر دو نوع از مدل های شبکه عصبی از قابلیت بالایی برای پیش بینی تقاضا برخوردارند، اما مدل GMDH



های ارزیابی، مدل‌های ساخته شده، شبکه عصبی مصنوعی GMDH نسبت به شبکه عصبی RBF کارایی بهتر داشته است. با توجه به بررسی هفت ساختار مختلف با تعداد متفاوت نرون و لایه های نهان، شبکه عصبی GMDH با سه لایه نهان که دارای یک نرون در لایه اول، سه نرون در لایه نهان دوم و سه نرون در لایه نهان سوم می باشد، بهترین نتیجه را برای پیش بینی تقاضای کوتاه مدت آب شرب نشان داد. با مقایسه توابع فعالیت خطی و غیر خطی مشخص شد که در لایه خروجی مدل های عصبی GMDH و RBF، توابع غیر خطی عملکرد بهتری نسبت به توابع خطی از خود نشان می دهند. همچنین در بین مدل‌های GMDH نیز مدل‌های با خروجی غیرخطی نسبت به مدل های با خروجی خطی مناسب تر می باشند. بزرگتر کردن ساختار شبکه نیز نشان داد که تاثیرچندانی بر بهبود نتایج ندارند.

با توجه به این موضوع که پیش بینی‌های دقیق به منظور برنامه‌ریزی صحیح برای استفاده از منابع در آینده، می‌توانند کمک قابل ملاحظه‌ای را ارائه کنند و با توجه به اهمیت آگاهی از تقاضای کوتاه مدت آب شهری زاهدان، به مدیران و بهره برداران سیستم های آب شهری پیشنهاد می گردد که از شبکه های عصبی مصنوعی به عنوان یک ابزار قدرتمند در تجزیه و تحلیل و پیش بینی داده ها، می توان در مواردی همچون مدیریت منابع آب، مدیریت بهره برداری مخازن و تصفیه خانه های آب، برنامه ریزی و مدیریت پمپ ها و شیرآلات شبکه، پیش بینی مقدار فروش و ..... در بخش مدیریت آب بهره برد.

چه شبکه های عصبی در مقایسه با رگرسیون های معمولی، توانایی مدل سازی روابط غیرخطی را دارند، ولی کاربرد این شبکه ها بمنظور تفسیر و توضیح روابط بین متغیرها مناسب نیست. همچنین به شبکه های عصبی به دلیل اینکه روابط بین متغیرها را ارائه نمی کنند، جعبه های سیاه نیز گفته می - شود. اگر چه در شبکه عصبی GMDH، روابط بین نهاده ها و ستاده بوسیله معادلات نرون ها قابل بیان است، ولی این روابط هیچ گونه تعبیر و تفسیری نخواهد داشت.

### نتیجه گیری و پیشنهادها

با توجه به نقش حیاتی آب در زندگی روزمره، آگاهی از میزان تقاضای آن در جهت برنامه ریزی، طراحی و اجرا و مدیریت بهتر منابع آب از اهمیت ویژه ای برخوردار است. بر این اساس با توجه به این موضوع که پیش بینی دقیق به منظور برنامه ریزی صحیح برای استفاده از منابع در آینده، می‌توانند کمک قابل ملاحظه‌ای را ارائه کنند، لذا در این تحقیق بر اساس مطالعات مرور شده مبنی بر دقت بیشتر مدل های شبکه عصبی مصنوعی بر مدل های ساختاری و رگرسیونی، با استفاده از شبکه های عصبی مصنوعی RBF و GMDH میزان تقاضای کوتاه مدت آب شرب شهر زاهدان پیش بینی شده است. از داده های مصرف ماهانه آب شرب شهرستان زاهدان به عنوان متغیر خروجی مدل های پیش بینی و از داده های ماهانه میانگین دمای ماهانه، درصد رطوبت نسبی، متوسط میزان بارندگی، ساعات آفتابی و مصرف ماه قبل به عنوان متغیرهای ورودی مدل های پیش بینی استفاده شد. نتایج نشان داد که در تمام شاخص

### منابع

- Al-Zahrani, M., Abo- Monasar, A., 2015, "Urban Residential Water Demand Prediction Based on Artificial Neural Networks and Time Series Models", *Water Resources Management*, 29(10): 3651-3662.
- Gagliardi, F., Alvisi, S., Kapelan, Z., Franchini, M., 2017, "A Probabilistic Short-Term Water Demand Forecasting Model Based on the Markov Chain", *Water*, 9(7): 1-15.
- Khatri, K.B., Vairavamoorthy, K., 2009, "Water Demand Forecasting for the City of the Future against the Uncertainties and the Global Change Pressures: Case of Birmingham", *EWRI/ASCE: 2009, Conference: Kansas, USA May*.



- Kostas, B., Chrysostomos, S., 2006, "Estimating urban Residential Water Demand Determinants and Forecasting Water Demand for Athens Metropolitan Area, 2000-2010", *South-Eastern Europe Journal of Economics*, 4(1): 47-51.
- Liu, J., Mingqi, C., 2010, "Application of the Grey Theory and the Neural Network in Water Demand Forecast", *Sixth International Conference on Natural Computation (ICNC)*.
- Mousavi, S.N., Kavousi, M., 2016, "Application of neural network methods and time series models in predicting drinking water consumption, Case study of Rasht city", *Journal of Water and Sewage*, 27(4): 84-89. (In Persian)
- Perea, R.G., E.M., Montesinos, P., Díaz, J.A.R., 2018, "Optimisation of water demand forecasting by artificial intelligence with short data sets", *Biosystems Engineering*, April, 168: 141-152.
- Ramezani Chermahineh, A., Zounemat Kermani, M., 2017, "Investigating the Efficiency of Support Vector Regression Methods, Multilevel Perceptron Neural Network and Multivariate Linear Regression in Determining Groundwater Levels (Case Study: Shahrekord Plain)", *Watershed Management Research*, 8(15): 1-12. (In Persian)
- Sadeghi, H., Zolfaghri, M., Aram, R., 2012, Modeling and Urgent Forecasting Urban Water demand, *Economic Policies (Neme Mofid)*, 7: 159-172. (In Persian)
- Sardar Shahraki, A., 2017, "Optimal allocation of water sources in the Hirmand watershed using game theory and evaluation of management scenarios", Ph.D. in Agricultural Economics, Sistan and Baluchestan University, Zahedan, Iran. (In Persian)
- Sharzei, G.A., Ahrari, M., Fakhrai, H., 2008, "Prediction of water demand in Tehran using structural models, time series and GMDH neural network", *Economic research*, 43: 151-175.
- Tabesh, M., Dini, M., 2011, "Prediction of daily urban water demand using artificial neural networks, Case study: Tehran", *Journal of Water and Sewage*, 21(1), 84-95.
- Tabesh, M., Dini, M., Khoshakhlagh, A.J., Zahraie, B., 2009, "Estimation of daily water consumption in Tehran using time series", *Iranian Water Resources Researches Journal*, 4: 57-65. (In Persian)
- Tabesh, M., Ghosheh, S., Yazdan Panah, M.J., 2008, "The short-term demand for water in Tehran using artificial neural networks", *Journal of Faculty of Engineering*, 41(1): 11-24. (In Persian).



## Modeling and Comparing GMDH and RBF Artificial Neural Networks in Forecasting Short-Term Demand for Drinking Water in Zahedan

Mojtaba Abbasian<sup>1</sup>, Ali Sardar Shahraki<sup>2</sup>

### Abstract

The water requirement of the urban district of Zahedan City in Iran is met by the transfer of water from Sistan Chah-Nimeh reservoirs that are themselves suffering from severe water crisis. So, the prediction of the urban demand for drinking water can greatly help managers and users of urban water systems to use sound management practices. The present paper uses the artificial neural networks of GMDH and RBF, as two vigorous tools for the analysis and modeling of nonlinear relationship, to estimate monthly demand for drinking water in Zahedan in 2017. The selected parameters include mean monthly temperature, relative humidity percentage, mean precipitation, sunny hours, and previous-month consumption rate. The results of comparing MSE and MAE indicators show that after studying different structures with various number of neurons and hidden layers, the GMDH neural network with three hidden layers that has one neuron in layer 1, three neurons in hidden layer 2, and three neurons in hidden layer 3 yields the best results for the predication of short-term demand for drinking water. The comparison of linear and nonlinear activity functions reveals that in output layer of GMDH and RBF neural models, the nonlinear functions outperform linear functions. As well, among the GMDH model, the models with nonlinear output show better performance than those with linear output. Also, it is shown that the expansion of the network structure cannot improve the results considerably.

**Keywords:** Short-Term Forecast, Water Demand, Artificial Neural Network, RBF, GMDH.

---

1- Assistant Professor of Economics, Maritime and Marine Science University of Chabahar, abbasian@cmu.ac.ir

2- Corresponding Author: Assistant Professor of Agricultural Economics, University of Sistan and Baluchestan, a.s.shahraki@eco.usb.ac.ir