

# پیش‌بینی مصرف روزانه آب شهری با استفاده از ترکیب الگوریتم‌های تکاملی و آنالیز تبدیل موجک (مطالعه موردی: شهر همدان)

کیومرث روشنگر<sup>۱</sup>، مهدی زرغامی<sup>۲</sup>، مهدی طرلانی‌آذر<sup>۳</sup>

(دریافت ۹۲/۱۰/۶ پذیرش ۹۳/۸/۲۵)

## چکیده

پیش‌بینی تقاضای آب شهری ابزاری مهم برای طراحی، بهره‌برداری و مدیریت سیستم‌های تأمین آب شهرها به‌شمار می‌رود. تعدد عوامل اثرگذار بر تقاضای آب شهری و تغییر اثر آنها با تغییر شرایط، باعث ضعف روش‌های تحلیلی ریاضی سنتی در این زمینه شده است. تاکنون روش‌های متعددی برای پیش‌بینی تقاضای آب شهری مورد استفاده قرار گرفته است که الگوریتم‌های تکاملی از پرکاربردترین آنها است. در این تحقیق از ترکیب روش برنامه‌ریزی بیان ژن که سرعت همگرایی و دقت بالایی در محاسبات و شبیه‌سازی دارد، با آنالیز تبدیل موجک برای پیش‌بینی تقاضای روزانه آب در شهر همدان استفاده شد. مصرف آب روزهای قبل و پارامترهای اقلیمی به‌عنوان عوامل مؤثر بر تقاضای آب در نظر گرفته شد. در بخش اول این مطالعه، کارایی روش برنامه‌ریزی بیان ژن در پیش‌بینی تقاضای روزانه آب شهری مورد بررسی قرار گرفت و بهترین مدل برای پیش‌بینی تعیین شد و در بخش دوم، تأثیر آنالیز تبدیل موجک بر نتایج، ارزیابی شد. بر اساس نتایج حاصل، مدلی با ورودی‌هایی شامل مصرف آب یک، دو، سه و هفت روز قبل بهترین مدل برای پیش‌بینی تقاضای روزانه آب، در مطالعه موردی حاضر است. ترکیب روش برنامه‌ریزی بیان ژن با آنالیز تبدیل موجک نتایج پیش‌بینی را تا ۱۰ درصد بهبود می‌بخشد.

**واژه‌های کلیدی:** تقاضای آب شهری، الگوریتم‌های تکاملی، برنامه‌ریزی بیان ژن، آنالیز تبدیل موجک

## Forecasting Daily Urban Water Consumption using Conjunctive Evolutionary Algorithm and Wavelet Transform Analysis, A Case Study of Hamedan City, Iran

K. Roushangar<sup>1</sup>, M. Zarghaami<sup>2</sup>, M. Tarlaniazar-Azar<sup>3</sup>

(Received Dec. 27, 2013 Accepted Nov. 16, 2014)

### Abstract

Water demand forecasting is an important tool in the design, operation, and management of urban water supply systems. The wide variety of factors affecting urban water demand and the variations in the impact levels of these factors due to changes in environmental conditions have undermined the efficiency of conventional mathematical forecasting models in forecasting water demand. Different methods have been so far employed for urban water demand forecasting, among which evolutionary algorithms are the most widely used. In this study, the gene expression programming model, which has a high convergence speed with high precision in calculation and simulation, is combined with the wavelet transform analysis to derive a hybrid model for forecasting daily water demand (consumption) in the city of Hamedan. Water consumption of previous days and climatic parameters constitute the factors affecting water demand in this model. In the first part of the present study, the efficiency of gene expression programming models in forecasting urban daily water demand is investigated to

1. Assoc. Prof., Dept. of Civil Engineering, University of Tabriz  
(Corresponding Author) (+98 41) 33392416  
roshangari@tabrizu.ac.ir  
2. Assoc. Prof., Dept. of Civil Engineering, University of Tabriz  
3. Former Graduate Student of Hydraulic Structures, University of Tabriz

۱- دانشیار، دانشکده مهندسی عمران، دانشگاه تبریز (نویسنده مسئول) ۳۳۳۹۲۴۱۶ (۰۴۱) roshangari@tabrizu.ac.ir

۲- دانشیار، دانشکده مهندسی عمران، دانشگاه تبریز

۳- دانش‌آموخته کارشناسی ارشد سازه‌های هیدرولیکی، دانشگاه تبریز

identify the best model (i.e., the best combination of inputs). The second part is dedicated to the evaluation of the effect of wavelet analysis on the results obtained. The results indicate that the best model for forecasting daily water demand is the one with water consumptions of 1, 2, and 3 previous days as well as those of the preceding week as its input. It is also found that the combined gene expression programming and wavelet transform analysis leads to a 10% improvement in forecasting results.

**Keywords:** Urban Water Consumption, Evolutionary Algorithms, Gene Expression Programming, Wavelet Transform Analysis.

## ۱- مقدمه

زمان از فواید روش‌های مختلف شود نیز در پیش‌بینی تقاضای آب شهری افزایش داشته است [۱].

در این تحقیق از روش برنامه‌ریزی بیان ژن<sup>۳</sup> استفاده شد و نتایج با حالتی که این روش با روش آنالیز تبدیل موجک<sup>۴</sup> ترکیب شد، مقایسه شدند. هر چند در مطالعات قبلی، برای پیش‌بینی تقاضای آب شهری، از سایر روش‌های هوش محاسباتی، به ویژه شبکه‌های عصبی مصنوعی بسیار استفاده شده است، اما از روش برنامه‌ریزی بیان ژن و ترکیب آن با آنالیز تبدیل موجک که ابزاری مهم در تحلیل تغییرات، پیش‌بینی و روند در سری‌های زمانی است، برای پیش‌بینی تقاضای آب شهری استفاده نشده است. برخی مطالعات که از روش‌های مختلف هوش محاسباتی در پیش‌بینی تقاضای آب شهری و یا سایر زمینه‌های مهندسی آب استفاده کرده‌اند در ادامه معرفی شده است.

ژو و همکاران در سال ۲۰۰۰ با روش تحلیل سری زمانی، تقاضای روزانه آب در شهر ملبورن<sup>۵</sup> استرالیا را پیش‌بینی کردند. در این پژوهش یک سری زمانی به شکل چند معادله که نشان دهنده اثر پارامترهای روند، فصل، رابطه آب و هوا و همبستگی می‌باشد، فرموله شده است. مصرف آب به دو بخش مصرف پایه (عدم حساسیت به آب و هوا) و مصرف فصلی (حساسیت به آب و هوا) تقسیم شده است که مصرف پایه، کمترین میزان مصرف در بین ماه‌های سال در نظر گرفته شده. در نتیجه‌گیری از این مطالعه، روند بلند مدت و سال به سال مصرف پایه به صورت یک معادله چند جمله‌ای و تابعی از زمان بیان شده است [۲]. استارک و همکاران در سال ۲۰۰۰ برای یک مجموعه در شهر آلبرتا<sup>۶</sup> در کانادا اقدام به پیش‌بینی تقاضای آب روزانه با استفاده از شبکه عصبی مصنوعی<sup>۷</sup> پرداختند. نتایج به دست آمده نشان می‌داد که تغییرات در میزان تقاضای آب، تابع تغییرات آب و هوا و الگوی رفتاری مصرف‌کنندگان است [۳]. کیم و همکاران در سال ۲۰۰۱ با استفاده از روش نرو-ژنتیک<sup>۸</sup> اقدام به پیش‌بینی تقاضای روزانه آب در

افزایش روز افزون جمعیت شهرها، توسعه امکانات و بالا رفتن سطح رفاه، افزایش تقاضای آب را در پی داشته است. این افزایش، تأمین آب شرب با کیفیت و تحویل آن به مصرف‌کنندگان را به یکی از چالش‌های پیش روی مدیران و برنامه‌ریزان، تبدیل کرده است. شرایط اقلیمی کشور امکان حل این چالش را از طریق گسترش منابع آب غیرمکن می‌سازد لذا باید در پی راه‌حلهایی بود که به واسطه آن میزان مصرف کاهش یابد. مدیریت منابع آب از راهکارهای کاهش مصرف است و پیش‌بینی تقاضای آب از ابزارهای مورد نیاز این مدیریت است.

پیش‌بینی تقاضای آب شهری با توجه به دوره زمانی آن به سه دسته تقسیم می‌شود: پیش‌بینی بلند مدت که معمولاً بازه‌ای از یک تا چند سال را در بر می‌گیرد، پیش‌بینی میان مدت که معمولاً بازه‌ای از یک ماه تا یک سال را شامل می‌شود و پیش‌بینی کوتاه مدت که معمولاً بازه زمانی یک ساعت تا چند روز را شامل می‌شود. در مدیریت آب شهری اطلاع از تقاضای کوتاه مدت آب به دلیل کاربرد و تأثیر آن در بهبود عملکرد پمپ‌ها، کاهش نگهداشت آب در مخزن که باعث بهبود کیفیت آب و تحویل آن با فشار مناسب به مصرف‌کنندگان می‌شود، مهم است و در تعیین پارامترهای اقتصادی، قابلیت اطمینان و بهره‌برداری از شبکه اهمیت بسزایی دارد. پیش‌بینی تقاضای آب شهری از دهه ۱۹۵۰ میلادی مورد توجه بوده است و طی این مدت، مطالعات زیادی با انگیزه و روش‌های متعدد در این زمینه انجام شده است. در سال‌های اخیر استفاده از الگوریتم‌های تکاملی<sup>۱</sup> که از زیرمجموعه‌های روش‌های هوش محاسباتی<sup>۲</sup> بوده و توانایی یادگیری دانش نهفته در مسائل طبیعی، سرعت همگرایی بالا و دقت زیاد در محاسبات را دارد و برای شبیه‌سازی سیستم‌های پیچیده مناسب است، در پیش‌بینی تقاضای آب شهری مورد توجه قرار گرفته است. همچنین ترکیب روش‌های مختلف هوش محاسباتی که می‌تواند باعث استفاده هم

<sup>3</sup> Gene Expression Programming (GEP)

<sup>4</sup> Wavelet Transform Analysis

<sup>5</sup> Melbourne

<sup>6</sup> Alberta

<sup>7</sup> Artificial Neural Network

<sup>8</sup> Neuro-Genetic

<sup>1</sup> Evolutionary Algorithms

<sup>2</sup> Computational Intelligence Methods

شهر سئول<sup>۱</sup> کره جنوبی نمودند، بر اساس نتایج حاصل اگر در پیش‌بینی تقاضای روزانه آب از مدل شبکه عصبی مصنوعی همراه با الگوریتم ژنتیک<sup>۲</sup> استفاده شود، نتایج به‌دست آمده بهتر خواهد بود. در این مطالعه دمای هوا، مقادیر مصرف آب در روزهای قبل، ساعات آفتابی و نوع روز در میزان تقاضای آب تأثیر بیشتری داشتند و در صورت انتخاب یک پارامتر به‌عنوان ورودی مدل‌ها، مقدار مصرف آب در روز قبل بهترین پارامتر است. در این مطالعه بهترین مدل برای پیش‌بینی تقاضای روزانه آب، مدلی با ورودی‌های شامل مصرف آب یک و دو روز قبل و میانگین دمای امروز و روز قبل است [۴]. آلتون کایناک و همکاران در سال ۲۰۰۵ با استفاده از روش منطق فازی مقادیر تقاضای ماهانه آب در شهر استانبول را پیش‌بینی کردند. روش منطق فازی مورد استفاده در این مطالعه از نوع تاکاگی سوگنو<sup>۳</sup> بوده و از مقادیر قبلی مصرف آب برای پیش‌بینی استفاده شده است. در این مطالعه اقدام به پیش‌بینی مصرف ۱۸ ماه از داده‌های آزمون شده است که خطای نسبی به دست آمده در این پیش‌بینی کمتر از ۱۰ درصد است و عملاً یک مقدار قابل قبول می‌باشد [۵]. تابش و همکاران در سال ۲۰۰۶ با استفاده از روش شبکه عصبی مصنوعی، مصرف یک‌روزه آب در شهر تهران را بر اساس پارامترهای اقلیمی و داده‌های تاریخی مصرف آب، پیش‌بینی کردند. علیرغم محدودیت داده‌های در دسترس، میزان تقاضای روزانه آب در شهر تهران با ضریب همبستگی حدود ۸۰ درصد و خطای متوسط حدود ۲ درصد پیش‌بینی شد. انتظار می‌رود در صورت وجود بانک اطلاعاتی کامل‌تر، نتایج دقیق‌تری به‌دست آید. همچنین در این مطالعه فرمولی برای پیش‌بینی تقاضای روزانه آب در شهر تهران تعریف شد که قادر است با خطای مطلق ۳ درصد، تقاضای روزانه آب در شهر تهران را پیش‌بینی کند [۶]. مسیزا و همکاران در سال ۲۰۰۷ با استفاده از شبکه‌های عصبی مصنوعی پرسپترون چند لایه<sup>۴</sup> و شبکه‌های عصبی شعاعی<sup>۵</sup> اقدام به پیش‌بینی بلند مدت و کوتاه مدت تقاضای آب شهری در شهری واقع در آفریقای جنوبی کردند که بر اساس نتایج حاصله، مدل‌های تابع پایه شعاعی سریع‌تر به جواب‌ها همگرا شده و همچنین دقت آن از شبکه عصبی مصنوعی پرسپترون چند لایه بیشتر بوده است [۷].

تابش و همکاران در سال ۲۰۰۹ مدل‌های مختلف فازی<sup>۶</sup> و نروفازی<sup>۷</sup> را برای پیش‌بینی کوتاه مدت تقاضای آب در شهر تهران

تعریف کردند. مقایسه نتایج حاصل از این مدل‌ها نشان می‌دهد مدل‌های نروفازی که ورودی‌های آن از داده‌های تصادفی انتخاب شده‌اند، نتایج دقیق‌تری ارائه کرده‌اند. همچنین مقایسه نتایج روش نروفازی با روش شبکه عصبی مصنوعی بیانگر دقت یکسان این دو روش بود [۸]. بابل و همکاران در سال ۲۰۱۱ طی یک مطالعه موردی در شهر بانکوک<sup>۸</sup> تایلد اقدام به تعیین پارامترهای مؤثر بر پیش‌بینی تقاضای آب با استفاده از شبکه‌های عصبی مصنوعی کردند. نتایج نشان می‌دهد که مصرف آب در کوتاه مدت از مصرف آب روزهای قبل، دمای میانگین و بارندگی تأثیرپذیر است. در بازه زمانی میان مدت، سطح سواد و تعداد انشعابات عواملی هستند که بیشترین تأثیر بر مصرف آب دارند [۹]. هررا و همکاران در سال ۲۰۱۰ در یک بخش هیدرولیکی، در شهر کوچکی در جنوب شرقی اسپانیا اقدام به تعریف مدل‌های مختلف پیش‌بینی تقاضای ساعتی آب نمودند. در این مطالعه از چندین روش برای پیش‌بینی تقاضای ساعتی آب استفاده شد و نتایج حاصل با یکدیگر مقایسه شدند. بررسی و مقایسه نتایج نشان داد که کارآمدترین روش برای پیش‌بینی تقاضای ساعتی آب، رگرسیون بردار پشتیبان<sup>۹</sup> است. همچنین این مطالعه دلالت بر ناکارآمدی انواع مختلف شبکه عصبی مصنوعی در پیش‌بینی تقاضای ساعتی آب دارد [۱۰]. کامپسی پینتو و آداموفسکی در سال ۲۰۱۲ در یک مطالعه موردی در شهر سیراکوز<sup>۱۰</sup> در ایتالیا با استفاده از ترکیب روش‌های شبکه عصبی مصنوعی و آنالیز تبدیل موجک اقدام به برآورد تقاضای آب در بازه‌های زمانی مختلف کردند. در این مطالعه سری زمانی اولیه با استفاده از آنالیز تبدیل موجک در سطوح مختلف تجزیه و رفع نویز<sup>۱۱</sup> شده است. نتایج نشان می‌دهد که تجزیه سری زمانی اولیه تا یک سطح می‌تواند باعث بهتر شدن نتایج حاصل از شبکه عصبی مصنوعی شود. این بهبود نتایج زمانی که موجک مورد استفاده از نوع Haar، db2 و یا db3 باشد مشهودتر است [۱۱]. ناصری و همکاران در سال ۲۰۱۱ با استفاده از ترکیب روش‌های برنامه‌نویسی ژنتیک (GP) و فیلتر توسعه یافته کالمن<sup>۱۲</sup> تقاضای ماهانه آب در شهر تهران را مورد بررسی قرار دادند. هدف اصلی این مطالعه به‌دست آوردن یک فرمول برای مصرف ماهانه آب در شهر تهران بود. در این مطالعه، فیلتر توسعه یافته کالمن برای پی بردن به متغیرهای نهفته، به‌منظور ایجاد یک پیش‌بینی دقیق از تقاضای آب بر اساس نتایج GP استفاده شده است. مقایسه نتایج حاصل از GP و GP-EKF نشان از برتری روش ترکیبی دارد و

<sup>8</sup> Bangkok  
<sup>9</sup> Support Vector Regression (SVR)  
<sup>10</sup> Syracuse  
<sup>11</sup> Denoising  
<sup>12</sup> Extended Kalman Filter (EKF)

<sup>1</sup> Seoul  
<sup>2</sup> Genetic Algorithm (GA)  
<sup>3</sup> Takagi-Sugeno  
<sup>4</sup> Multi-Layer Perceptron (MLP)  
<sup>5</sup> Radial Basis Function (RBF)  
<sup>6</sup> Fuzzy  
<sup>7</sup> Neuro-Fuzzy

پیش‌بینی با خطای کمتری انجام شده است [۱۲]. کیشی و شیری در سال ۲۰۱۱ از روش برنامه‌ریزی بیان ژن و ترکیب آن با آنالیز تبدیل موجک برای پیش‌بینی بارندگی استفاده کردند که ترکیب دو روش باعث بهبود نتایج شده است [۱۳]. اکلا و همکاران در سال ۲۰۱۲ کاربرد روش برنامه‌ریزی بیان ژن را برای مدل‌های پیش‌بینی یک روزه جریان، در حوضه‌هایی با شرایط بسیار متفاوت مورد بررسی قرار دادند. این روش با سایر روش‌های داده‌گرای مرسوم که تاکنون استفاده شده‌اند، متفاوت است. این روش یک مدل شفاف با بیان ریاضی برای پیش‌بینی جریان از داده‌های ورودی نظیر سابقه بارندگی، تولید می‌کند. در این مطالعه چهار مدل برنامه‌ریزی بیان ژن با استفاده از نرم‌افزار GeneXproTools برای چهار حوضه تولید شد. نتایج به‌دست آمده نشان می‌دهد که این مدل‌های شفاف می‌توانند یک پیش‌بینی دقیق مطابق با اهداف، انجام دهند [۱۴]. کیشی و همکاران در سال ۲۰۱۱ با استفاده ترکیب برنامه‌ریزی ژنتیک (برنامه‌ریزی بیان ژن) و آنالیز تبدیل موجک، دمای هوا را در بازه‌های زمانی بلند مدت و کوتاه مدت پیش‌بینی کردند. در این مطالعه دقت مدل‌های برنامه‌ریزی بیان ژن تنها و مدل‌های ترکیب شده با آنالیز تبدیل موجک با یکدیگر مقایسه شدند. بر اساس نتایج، استفاده از آنالیز تبدیل موجک باعث افزایش دقت مدل به‌خصوص در بازه زمانی بلند مدت شده است [۱۵].

در پیش‌بینی تقاضای آب در مناطق شهری، تهیه داده‌های مصرف آب در طولانی مدت با صحت و دقت قابل قبول از ملزومات اولیه کار است. در اکثر شهرهای ایران به دلیل مشکلات فنی و ابزاری موجود در ثبت داده‌های مصرف آب، معمولاً یا پایگاه داده‌ای برای مصرف آب موجود نیست و یا اینکه پارامترهای اندازه‌گیری شده قابل اطمینان نیستند. به همین دلیل تا به حال در اکثر شهرهای کشور، تقاضای روزانه آب که از عوامل مهم در بهبود مدیریت شبکه‌های آبرسانی شهری است، اندازه‌گیری نشده است. بنابراین به‌منظور پیش‌بینی، روش‌هایی که قابلیت یادگیری داده‌های ناقص میدانی را داشته باشند و در برابر نوسانات ناشی از خطای اندازه‌گیری مقاوم باشند، مورد نیاز است [۱۶]. برای این شرایط روش برنامه‌ریزی بیان ژن که به‌عنوان جدیدترین روش شاخه الگوریتم‌های تکاملی مطرح است و در مقایسه با روش‌های مشابه قبلی قدرتمندتر است، توانایی رسیدن به جواب مطلوب را دارد و ترکیب آن با آنالیز تبدیل موجک که توانایی تحلیل روند و تغییرات سری‌های زمانی را داراست، می‌تواند به بهبود دقت پیش‌بینی منجر شود. هدف از انجام این تحقیق در مرتبه اول ارائه یک رابطه ریاضی ساده برای محاسبه میزان تقاضای روزانه آب در شهر همدان است. چنین رابطه‌ای باید در موارد عملی و محاسبات واقعی

تقاضای آب قابل استفاده باشد و از دقت کافی برخوردار باشد، لذا برای این منظور از روش برنامه‌ریزی بیان ژن که برای محاسبه تابع هدف، قادر به تولید رابطه صریح ریاضی است، استفاده شده است. لازم به ذکر است که برخی از روش‌های هوشمند دیگر، نظیر شبکه‌های عصبی مصنوعی نیز قادرند برای هر تابع غیرخطی ریاضی، یک رابطه تولید کنند ولی الگوریتم‌های تکاملی اقدام به تعریف تابع هدف در قالب معیارهای کیفی می‌کنند و برای مقایسه روش‌های مختلف حل و تعیین بهترین روش، تابع یاد شده را در یک فرایند گام به گام تصحیح داده‌ها، به‌کار می‌گیرند که در نتیجه آن، بهترین روش تعیین می‌شود [۱۷]. تعیین تاثیر آنالیز تبدیل موجک بر نتایج حاصل از روش برنامه‌ریزی بیان ژن نیز هدف دیگر پژوهش حاضر است.

## ۲- مواد و روش‌ها

### ۲-۱- انتخاب پارامتر

پارامترهای مورد نیاز در پیش‌بینی تقاضای روزانه آب شهری، مقادیر قبلی مصرف آب و اطلاعات هواشناسی است. در این مطالعه اطلاعات مصرف آب از شرکت آب و فاضلاب استان همدان تهیه شد. این اطلاعات مربوط به مصرف روزانه آب در یک دوره زمانی چهار ساله، از اول مهر ۱۳۸۶ تا ۳۱ شهریور ۱۳۹۰ یعنی حداکثر دوره زمانی برای پایگاه داده قابل اطمینان برای مصرف روزانه آب شهر همدان است که تا زمان انجام این مطالعه در دسترس بوده است. داده‌های پارامترهای اقلیمی مربوط به دوره زمانی طولانی‌تری است که قسمتی از آن که منطبق بر دوره زمانی مصرف آب می‌باشد، مورد استفاده قرار گرفت. این آمار مربوط به ایستگاه فرودگاه همدان بوده و شامل پارامترهای میانگین دمای روزانه، حداکثر دمای روزانه، حداقل دمای روزانه، متوسط نم نسبی روزانه، بارندگی روزانه و طول ساعات آفتابی روزانه است.

در جدول ۱ مقادیر همبستگی مصرف آب روزهای قبل و پارامترهای اقلیمی با مصرف روزانه آب ارائه شده است. همانطور که مشاهده می‌شود با زیاد شدن تأخیرات زمانی، میزان همبستگی مصرف آب در روزهای قبل با مصرف روزانه آب کمتر می‌شود و نیز اینکه بر خلاف دمای هوا که رابطه مستقیم با مصرف آب دارد، رطوبت نسبی یک رابطه معکوس با مصرف آب داشته و با افزایش رطوبت، از میزان تقاضا برای آب کاسته می‌شود. در نهایت با استفاده از نه پارامتر منتخب شامل مصرف آب یک تا هفت روز قبل، حداکثر دمای روزانه و مقدار نم نسبی اقدام به تعریف ده مدل برای پیش‌بینی تقاضای روزانه آب شد. دلیل انتخاب حداکثر دمای روزانه و نم نسبی از بین پارامترهای اقلیمی به ترتیب همبستگی زیادتر در مقایسه با سایر پارامترها و همبستگی منفی بالا است.

جدول ۲ نشان دهنده پارامترهای ورودی هر یک از مدل‌های تعریف شده است که  $q_i$  مصرف در روز  $i$  ام،  $RH$  نم نسبی و  $T_{max}$  حداکثر دمای روزانه را نشان می‌دهد.

جدول ۱- مقادیر همبستگی پارامترهای مختلف با مصرف روزانه آب در طول دوره آماری چهار ساله

پارامتر	همبستگی با مصرف روزانه	پارامتر	همبستگی با مصرف روزانه
مصرف یک روز قبل	۰/۸۹	مصرف روزانه	۱/۰۰
مصرف دو روز قبل	۰/۸۷	میانگین دمای روزانه	۰/۶۵
مصرف سه روز قبل	۰/۸۶	حداکثر دمای روزانه	۰/۶۷
مصرف چهار روز قبل	۰/۸۴	حداقل دمای روزانه	۰/۵۸
مصرف پنج روز قبل	۰/۸۳	رطوبت نسبی	-۰/۶۲
مصرف شش روز قبل	۰/۸۲	بارندگی	-۰/۱۸
مصرف هفت روز قبل	۰/۸۱	ساعات آفتابی	۰/۴۹

جدول ۲- پارامترهای ورودی مدل‌های تعریف شده

مدل	پارامترهای مورد استفاده
M1	$q(t-1)$
M2	$q(t-2), q(t-1)$
M3	$q(t-3), q(t-2), q(t-1)$
M4	$q(t-4), q(t-3), q(t-2), q(t-1)$
M5	$q(t-5), q(t-4), q(t-3), q(t-2), q(t-1)$
M6	$q(t-6), q(t-5), q(t-4), q(t-3), q(t-2), q(t-1)$
M7	$q(t-7), q(t-6), q(t-5), q(t-4), q(t-3), q(t-2), q(t-1)$
M8	$q(t-7), q(t-3), q(t-2), q(t-1)$
M9	$q(t-3), q(t-2), q(t-1), T_{max}, RH$
M10	$q(t-7), q(t-3), q(t-2), q(t-1), T_{max}, RH$

## ۲-۲- برنامه‌ریزی بیان ژن

برنامه‌ریزی بیان ژن (GEP) در سال ۱۹۹۹ توسط فریرا<sup>۱</sup> ابداع شد و تا به حال برنامه‌های کامپیوتری زیادی برای آن ارائه شد که روز به روز در حال تکمیل می‌باشند. این روش همانند الگوریتم ژنتیک (GA) و برنامه‌ریزی ژنتیک (GP)، جزو الگوریتم‌های تکاملی است که از جمعیتی از افراد استفاده کرده و آنها را مطابق برازندگی انتخاب می‌کند و تغییرات ژنتیکی را با استفاده از یک یا چند عملگر ژنتیکی اعمال می‌نماید. تفاوت اساسی بین این سه الگوریتم، مربوط به ماهیت افراد آنهاست، به طوری که در GA، افراد رشته‌های خطی با طول ثابت (کروموزوم) و در GP نهادهای غیرخطی با اندازه‌ها و

<sup>۱</sup> Ferreira

اشکال متفاوت (درختان تجزیه) می‌باشند، در حالی که در GEP افراد به صورت رشته‌های خطی با طول ثابت (ژنوم یا کروموزوم) کدگذاری شده (مشابه با آنچه که در الگوریتم ژنتیک استفاده می‌شود) و سپس به شکل نهادهای غیرخطی با اندازه‌ها و اشکال متفاوت (یعنی نمایش دیاگرام ساده یا بیان درختی مشابه با درختان تجزیه در برنامه‌ریزی ژنتیک) اظهار می‌شوند [۱۸]. در این روش، کروموزوم‌ها از چندین ژن تشکیل شده‌اند که هر ژن نیز از یک زیربرنامه کوچک به دست آمده است. به علاوه ساختار کروموزوم‌های خطی باعث عملکرد آزادانه عملگرهای ژنتیکی نظیر جهش، انتقال و ترکیب می‌شود. از توانایی‌های روش برنامه‌ریزی بیان ژن، ساده بودن ایجاد تنوع ژنتیکی و ماهیت چندژنی آن است که اجازه تکامل به برنامه‌های پیچیده متشکل از چندین زیربرنامه را می‌دهد که باعث شده برنامه‌ریزی بیان ژن از روش قدیمی برنامه‌ریزی ژنتیک ۱۰۰ تا ۱۰۰۰۰ بار قدرتمندتر شود [۱۳]. الهام از طبیعت از امتیازات برنامه‌ریزی بیان ژن است ولی امتیاز مهم‌تر آن این است که اولاً کروموزوم‌ها نهادهای خطی، فشرده، نسبتاً کوچک و راحت برای تغییرات ژنتیکی هستند و ثانیاً این که هر بیان درختی منحصراً تصویری از کروموزوم مربوط به خودش می‌باشد.

روش و مراحل کار برای پیش‌بینی تقاضای روزانه آب شهری به ترتیب زیر است:

مرحله اول: انتخاب تابع برازش.

مرحله دوم: انتخاب ترمینال‌ها (ورودی مدل‌ها) و توابع برای ایجاد کروموزوم‌ها. انتخاب توابع بستگی به نقطه نظر کاربر دارد که در این تحقیق، چهار عمل اصلی به عنوان عملگرهای اصلی و چندین عملگر معروف دیگر به عنوان عملگرهای فرعی انتخاب شده‌اند. بنابراین دو مجموعه مختلف از عملگرها به شرح زیر مورد ارزیابی قرار گرفت:

مجموعه اول:  $\{+, -, \times, /\}$  و مجموعه دوم:  $\{+, -, \times, /\}$ ،  $\{Ln, sin, exp, x^2, sqrt\}$ .

مرحله سوم: انتخاب ساختار و معماری کروموزوم‌ها که طول سر برابر ۸ و تعداد ۳ و ۴ ژن انتخاب شده است.

مرحله چهارم: انتخاب تابع پیوند ژن‌ها، که در این مطالعه از تابع جمع (+) به عنوان تابع پیوند استفاده شده است.

مرحله پنجم: انتخاب عملگرهای ژنتیکی و نرخ آنها.

جدول ۳ به صورت خلاصه پارامترهای مورد استفاده در مراحل مختلف مدل‌سازی برای پیش‌بینی تقاضای روزانه آب شهری با استفاده از نرم افزار GeneXproTools 4.0<sup>۲</sup> را نشان می‌دهد.

<sup>۲</sup> (<http://www.gene-expression-programming.com>)

جدول ۳- مقادیر پارامترهای مورد استفاده برای پیش‌بینی تقاضای روزانه آب شهری با استفاده از روش GEP

پارامتر	مقدار
اندازه سر	۸
تعداد کروموزوم‌ها	۳۰
تعداد ژن‌ها در هر کروموزوم‌ها	۴ و ۳
نرخ جهش	۰/۰۴۴
نرخ وارون‌سازی	۰/۱
نرخ ترکیب تک-نقطه‌ای	۰/۳
نرخ ترکیب دو-نقطه‌ای	۰/۳
نرخ ترکیب ژن	۰/۱
نرخ ترانهش درج متوالی	۰/۱
نرخ ترانهش ریشه درج	۰/۱
نرخ ترانهش ژن	۰/۱
معیار خطای تابع	RMSE
تابع پیوند	جمع (+)

### ۲-۳- آنالیز تبدیل موجک

برای آنالیز سیگنال‌ها و استخراج اطلاعاتی که دستیابی به آنها از طریق سیگنال‌های خام به راحتی امکان پذیر نیست از تبدیل‌های ریاضی استفاده می‌شود. تبدیل موجک از تبدیل‌های کارآمد ریاضی در زمینه پردازش سیگنال است. موجک‌ها توابع ریاضی‌اند که شکل مقیاس-زمان از سری‌های زمانی و روابط آنها برای آنالیز سری‌های زمانی که شامل متغیرها و غیرثابت‌ها می‌باشند را ارائه می‌دهد. یک موجک که به معنای موج کوچک است و قسمتی از یک موج است که طول مؤثر محدودی دارد و در آن طول، دارای مقدار متوسط صفر است. یعنی

$$\int \psi(t) dt = 0 \quad (1)$$

دو نوع تبدیل موجکی وجود دارد: تبدیل موجکی پیوسته<sup>۱</sup> (CWT) و تبدیل موجکی گسسته<sup>۲</sup> (DWT) تبدیل موجکی پیوسته با رابطه زیر بیان می‌شود

$$CWT_s^w(a, b) = \frac{1}{\sqrt{|a|}} \int s(t) \psi_{a,b}^* t(dt) \quad (2)$$

رابطه بالا تابعی از دو متغیر  $a$  و  $b$  است که  $a$  نشان دهنده مقیاس<sup>۳</sup> (عکس فرکانس) و  $b$  نشان دهنده انتقال<sup>۴</sup> است. همچنین

علامت \* نشان دهنده مزدوج مختلط<sup>۵</sup> است، پارامترهای  $a$  و  $b$  اعداد حقیقی هستند که  $a$  همیشه مثبت است،  $a$  و  $b$  در تبدیل موجکی پیوسته و گسسته به ترتیب دارای مقادیر پیوسته و گسسته هستند.  $\psi(t)$  تابع انتقال بوده و موج مادر نام دارد و به این دلیل موج مادر نام دارد که توابع (موجک‌های) مختلف به وجود آمده بر اساس پارامترهای انتقال و مقیاس همگی از تابع پایه (موج مادر) ناشی می‌شوند. موج مادر، موج اصلی برای تولید توابع پنجره دیگر است. این توابع پنجره، تابع موجکی<sup>۶</sup> نامیده می‌شوند و از رابطه زیر به دست می‌آیند [۱۹ و ۲۰]


$$\psi_{a,b}(t) = \psi\left(\frac{t-b}{a}\right) \quad (3)$$

در صورت استفاده از تبدیل موجک پیوسته به دلیل تغییر پارامترهای انتقال و مقیاس در طول زمان، حجم اطلاعات زیاد می‌شود و چون در محاسبات کامپیوتری میزان تغییرات در هر مرحله بسیار کوچک است، حجم محاسبات کامپیوتری بالا می‌رود. برای انجام محاسبات تبدیل موجک با استفاده از کامپیوترهای دیجیتال از تبدیل موجک گسسته استفاده می‌شود که ویژگی‌های بسیار مناسبی دارد مانند ارائه اطلاعات کافی و مورد نیاز برای تحلیل و بررسی موج و ساده‌تر شدن پیاده‌سازی تبدیل به واسطه تخصیص مقادیر گسسته به پارامترهای  $a$  و  $b$ . در آنالیز تبدیل موجک و تجزیه سیگنال توسط آن معمولاً تقریب<sup>۷</sup> علامت و جزئیات<sup>۸</sup> آن بحث می‌شود. تقریب مربوط به مقیاس‌های بزرگ (فرکانس پایین) و جزئیات مربوط به مقیاس‌های کوچک (فرکانس بالا) است. عملیات فیلتر نمودن به صورت ساده و کلی در شکل ۱ قابل نمایش است.

فرکانس بالا cD



فرکانس پایین cA



شکل ۱- عملیات فیلتر نمودن یک سیگنال [۱۸]

<sup>5</sup> Complex Conjugate

<sup>6</sup> Mother Wavelet

<sup>7</sup> Wavelet Function

<sup>8</sup> Approximation

<sup>9</sup> Details

<sup>1</sup> Continues Wavelet Transform (CWT)

<sup>2</sup> Discrete Wavelet Transform (DWT)

<sup>3</sup> Scale

<sup>4</sup> Transition

مربعات خطا و میانگین خطای نرمال شده آن نسبت به سایر مدل‌ها دارای کمترین مقدار باشد و ضریب تبیین آن نزدیک‌ترین مقدار به ۱ را داشته باشد. معیارهای ارزیابی محاسبه شده برای مدل‌های مختلف در جدول ۴ آورده شده است.

جدول ۴ - معیارهای ارزیابی، برای مدل‌های مختلف در روش GEP

مدل	داده‌های آموزش			داده‌های آزمون		
	RMSE	MNE	R <sup>2</sup>	RMSE	MNE	R <sup>2</sup>
M1	۰/۶۹۱	۳/۷۱	۰/۷۰۳	۰/۷۰۳	۳/۲۵	۵۴۴۵/۴
M2	۰/۷۵۶	۳/۱۸	۰/۷۵۸	۰/۷۵۸	۲/۸۴	۴۷۴۷/۶
M3	۰/۷۷۴	۳/۰۳	۰/۷۸۳	۰/۷۸۳	۲/۶۴	۴۴۲۳/۹
M4	۰/۷۳۷	۳/۳۳	۰/۷۳۵	۰/۷۳۵	۳/۰۱	۵۰۳۲/۹
M5	۰/۷۴۴	۳/۲۷	۰/۷۴۴	۰/۷۴۴	۲/۹۴	۴۹۱۷/۶
M6	۰/۷۲۴	۳/۴۴	۰/۷۲۲	۰/۷۲۲	۳/۱۱	۵۲۰۵/۷
M7	۰/۸۱۷	۲/۶۴	۰/۸۲۴	۰/۸۲۴	۲/۲۹	۳۸۳۶/۱
M8	۰/۸۱۹	۲/۶۴	۰/۸۳۰	۰/۸۳۰	۲/۲۸	۳۸۱۲/۲
M9	۰/۷۸۳	۲/۹۵	۰/۷۹۱	۰/۷۹۱	۲/۵۸	۴۳۱۸/۲
M10	۰/۸۰۱	۲/۸۱	۰/۸۱۰	۰/۸۱۰	۲/۴۳	۴۰۶۹/۵

با توجه به نتایج، مدل‌های M7 و M8 که به ترتیب شامل ۷ و ۴ متغیر ورودی، مطابق جدول ۲ می‌باشند از سایر مدل‌ها بهتراند. نتایج این دو مدل بسیار نزدیک به یکدیگر است، ولی مدل M8 به دلیل تعداد ورودی کمتر که باعث سادگی مدل می‌شود از مدل M7 بهتر بوده و به عنوان بهترین مدل انتخاب شده است. همچنین مدل M8 برای بررسی تأثیر ترکیب آنالیز تبدیل موجک با برنامه‌ریزی بیان ژن مورد استفاده قرار خواهد گرفت. معیارهای ارزیابی محاسبه شده برای مدل M8 در مراحل آموزش و آزمون عبارت‌اند از:  $R^2=0.819$  و  $RMSE=4413.1$  و  $MNE=2.64$  برای مرحله آموزش و  $R^2=0.830$  و  $RMSE=3812.2$  و  $MNE=2.28$  برای مرحله آزمون. در این مدل ۷۵ درصد داده‌ها برای آموزش و ۲۵ درصد داده‌ها برای آزمون استفاده شده و استفاده از سه ژن با ترکیب عملگرهایی مطابق با مجموعه دوم منجر به بهترین نتیجه شده است. فرمول ریاضی برای پیش‌بینی تقاضای روزانه آب که از نمودار درختی استخراج و ساده‌سازی شده است به صورت رابطه ۷ ارائه شد. ارائه رابطه صریح ریاضی متشکل از متغیرهای ورودی، برای محاسبه تابع هدف (میزان تقاضای روزانه آب) از مزیت‌های روش برنامه‌ریزی بیان ژن در مقایسه با سایر روش‌های هوشمند به حساب می‌آید.

عملیات فیلترسازی طی چند مرحله قابل اجرا است به طوری که می‌توان مؤلفه‌های فرکانس پایین را مجدداً از دو فیلتر پایین گذر و بالاگذر عبور داد و ضرایب دیگری از تبدیل موجک گسسته در سطوح مختلف به دست آورد. در انجام این تحقیق اقدام به تجزیه سری زمانی اصلی مصرف آب تا سه سطح با استفاده از موجک‌های مادر db2, haar, db3, db4, db5 شد و از جنبه رفع نویز آنالیز تبدیل موجک استفاده شد. برای این منظور با انجام عملیات فیلترسازی و تجزیه سیگنال در هر مرحله، فقط از قسمت تقریب و فرکانس پایین حاصل از تجزیه موج، برای مدل‌سازی استفاده شد و بخش فرکانس بالا و جزئیات آن کنار گذاشته شد. در این مطالعه به منظور انجام این مراحل از نرم‌افزار MATLAB R2010-b استفاده شد.

### ۲-۴- معیارهای ارزیابی

به منظور ارزیابی و بررسی کارایی روش استفاده شده برای پیش‌بینی روزانه تقاضای آب شهری در مطالعه موردی حاضر و نیز تعیین بهترین مدل برای انجام این پیش‌بینی، در این تحقیق از معیارهای جذر میانگین مربعات خطا<sup>۱</sup>، ضریب تبیین<sup>۲</sup> و میانگین خطای نرمال شده<sup>۳</sup> استفاده شد

(۴)

$$R^2 = \left[ \frac{\sum_{i=1}^n (Q_0 - \bar{Q}_0) * (Q_p - \bar{Q}_p)}{\sqrt{\sum_{i=1}^n (Q_0 - \bar{Q}_0)^2 \sum_{i=1}^n (Q_p - \bar{Q}_p)^2}} \right]^2$$

$$RMSE = \sqrt{\left[ \frac{\sum_{i=1}^n (Q_0 - Q_p)^2}{n} \right]} \quad (۵)$$

$$MNE = \frac{1}{n} \sum_{i=1}^n \frac{|Q_0 - Q_p|}{Q_0} * 100 \quad (۶)$$

که در این روابط

$Q_0$  مقدار واقعی مصرف روزانه آب،  $\bar{Q}_0$  متوسط مقدار واقعی مصرف روزانه آب،  $Q_p$  مقدار پیش‌بینی شده مصرف روزانه آب و  $\bar{Q}_p$  متوسط مقدار پیش‌بینی شده مصرف روزانه آب است.

### ۳- نتایج و بحث

#### ۳-۱- نتایج روش برنامه‌ریزی بیان ژن (GEP)


با استفاده از نتایج به دست آمده، معیارهای ارزیابی در مرحله آموزش و آزمون برای تمامی مدل‌ها محاسبه شد. از بین مدل‌ها، مدلی به عنوان مدل برتر انتخاب شد که معیارهای جذر میانگین

<sup>۱</sup> Root Mean Square Error (RMSE)


<sup>۲</sup> Correlation Coefficient (R<sup>2</sup>)

<sup>۳</sup> Mean Normalized Error (MNE)

نویز از سری زمانی مصرف روزانه آب شد و بخش فرکانس پایین برای تعیین متغیرهای ورودی استفاده شد.



شکل ۲- پراکندگی داده‌های مصرف روزانه واقعی و پیش‌بینی شده و میزان همبستگی آنها (روش GEP)



شکل ۳- مقایسه مصرف روزانه واقعی و پیش‌بینی شده (روش GEP)

موجک‌های مادر مورد استفاده در تجزیه سیگنال شامل db5 و db4، db3، db2، Haar می‌باشد که هر کدام از آنها بسته به ویژگی‌هایی که دارند، در هر سطح از تجزیه، تغییراتی را در روند و وضعیت آماری سری زمانی اصلی مصرف آب ایجاد کرده‌اند. در جدول ۵ خلاصه وضعیت آماری سری زمانی اصلی مصرف آب و سری زمانی رفع نویز شده در سطح سوم با انواع موجک مورد استفاده در این تحقیق آورده شده است. می‌توان گفت میانگین سری زمانی مصرف آب در حالت خام و رفع نویز شده ثابت مانده است، ضریب تغییرات کاهش یافته است و تغییرات مقادیر حداکثر و حداقل از روند ثابتی برخوردار نیست. در شکل‌های ۴ و ۵ به ترتیب سری زمانی اصلی مصرف آب و سری زمانی رفع نویز شده در سطح سوم با استفاده از موجک db5 نمایش داده شده است. پس از رفع نویز از سری زمانی مصرف آب و تعریف متغیرهای ورودی برای مدل M8 با استفاده از سری زمانی رفع نویز شده، معیارهای ارزیابی برای این مدل طبق جدول ۶ به دست آمد. در جدول ۷ سطح تجزیه، در کنار نام موجک مادر نوشته شده است.

جدول ۵- معیارهای ارزیابی، برای مدل برتر مختلف در روش GEP

داده‌های صحت سنجی			داده‌های آزمون			داده‌های آموزش			مدل
RMSE	MNE	R <sup>2</sup>	RMSE	MNE	R <sup>2</sup>	RMSE	MNE	R <sup>2</sup>	

$$Q(t) = \left\{ \left( \ln(q_{(t-3)}) \right)^2 \right\} + \left\{ \left[ \left( \frac{q_{(t-2)} - q_{(t-1)}}{5.5} \right) - 6.96 \right] \right\} + \quad (7)$$

از موارد بسیار مهم در پیش‌بینی پارامترهایی نظیر تقاضای آب شهری توسط روش‌های هوش مصنوعی، اطمینان از عدم آموزش اضافی<sup>۱</sup> در مرحله آموزش است. در این مطالعه برای اطمینان از این موضوع برای مدل برتر (M8) مقادیر پارامترهای ارزیابی، علاوه بر مراحل آموزش و آزمون برای مرحله اعتبارسنجی<sup>۲</sup> نیز محاسبه شده‌اند، برای این منظور داده‌ها با نسبت ۲۰، ۲۰ و ۶۰ درصد به ترتیب به مراحل اعتبارسنجی، آزمون و آموزش اختصاص داده شده است و معیارهای ارزیابی محاسبه شده‌اند که مقادیر آن برای هر سه مرحله در جدول ۵ آورده شده است. با بررسی نتایج حاصل می‌توان گفت فرایند آموزش اضافی در حین مرحله آموزش اتفاق نیفتاده است.

در شکل ۲ نمودار پراکندگی داده‌های مصرف روزانه واقعی و پیش‌بینی شده در مقابل یکدیگر و میزان همبستگی آنها برای روش GEP نمایش داده شده است و در شکل ۳ مصرف واقعی و پیش‌بینی شده برای این روش در دوره زمانی یک‌ساله نمایش داده شده است. با بررسی دقیق این نمودار می‌توان گفت هرچند مصرف پیش‌بینی شده از نظر روند کلی از سری زمانی مصرف واقعی تبعیت می‌کند ولی دارای تأخیر زمانی نسبت به آن است و در پیش‌بینی نقاط پیک مصرف و روزهایی که حداقل مصرف را داشته‌اند، عملکرد خوبی نداشته و پیش‌بینی از دقت زیادی برخوردار نیست.


### ۳-۲- نتایج روش برنامه‌ریزی بیان ژن ترکیب شده با آنالیز تبدیل موجک (WGEP)

همانطور که ذکر شد با توجه به نتایج به دست آمده مدل M8 بهترین مدل برای پیش‌بینی تقاضای روزانه آب در مطالعه موردی حاضر است، از این مدل برای بررسی تأثیر آنالیز تبدیل موجک بر نتایج استفاده شد. برای انجام این مهم، اقدام به تجزیه سری زمانی اصلی مصرف روزانه آب با استفاده از آنالیز تبدیل موجک تا سه سطح شد. پس از تجزیه سیگنال در سطح مورد نظر، بخش فرکانس بالای حاصل از تجزیه سیگنال کنار گذاشته شد یا به اصطلاح اقدام به رفع


<sup>1</sup> Over train

<sup>2</sup> Validation





شکل ۵- سری زمانی مصرف آب رفع نویز شده با موجک db5 در سطح سوم



شکل ۴- مصرف روزانه آب و روند کلی آن

جدول ۶- خلاصه وضعیت آماری سری زمانی اصلی و سری زمانی رفع نویز شده در سطح سوم

سری زمانی رفع نویز شده					سری زمانی اصلی	پارامتر
db5	db4	db3	db2	Haar		
۱۳۱۵۱۲/۷	۱۳۱۵۳۲/۶	۱۳۱۵۰۶/۷	۱۳۱۵۳۶/۲	۱۳۱۴۹۵/۶	۱۳۱۵۴۳/۸	میانگین (m³/day)
۱۵۷۶۸۳/۱	۱۵۶۲۱۸/۲	۱۵۸۵۵۴/۵	۱۵۷۰۶۴/۰	۱۵۶۱۳۵/۸	۱۵۷۸۰۸/۰	حداکثر (m³/day)
۱۰۴۳۳۰/۰	۱۰۲۴۷۶/۴	۱۰۳۷۶۴/۳	۹۹۳۷۷/۴	۱۰۷۳۷۴/۶	۱۰۱۰۶۸/۰	حداقل (m³/day)
۹۸۷۵/۸	۹۹۱۳/۷	۹۸۶۱/۲	۹۹۰۹/۹	۹۸۰۲/۳	۱۰۴۹۲/۱	انحراف معیار (Sx)
۷/۵	۷/۵	۷/۵	۷/۵	۷/۵	۸/۰	ضریب تغییرات (%) (CV)
۰/۹۳۸	۰/۹۴۴	۰/۹۳۶	۰/۹۴۴	۰/۹۳۱	۱/۰۰	همبستگی با سری زمانی اصلی

۳۱۷۶/۸    ۱/۸۵    ۰/۸۸۱    ۳۷۲۴/۰    ۲/۲۶    ۰/۸۶۵    db5-3

در این حالت معیارهای ارزیابی برای مدل M8 در مراحل آموزش و آزمون عبارت‌اند از:  $R^2=0.918$ ,  $RMSE=2619.1$  و  $MNE=1.57$  برای مرحله آموزش و  $R^2=0.919$ ,  $RMSE=2615.6$  و  $MNE=1.56$  برای مرحله آزمون و تعداد سه ژن با ترکیب عملگرهایی مطابق با مجموعه دوم منجر به بهترین نتیجه شده است. فرمول ریاضی برای پیش‌بینی تقاضای روزانه آب، به صورت رابطه ۸ ارائه شده است.

(۸)

$$Q_{(t)} = \left\{ q_{(t-1)} - \sqrt{(3q_{(t-2)} - 2q_{(t-7)})} \right\} + \left[ \left[ \left( \frac{8.02 + q_{(t-3)} + q_{(t-7)}}{(q_{(t-7)} + q_{(t-1)})} \right) * q_{(t-1)} \right] - q_{(t-2)} \right]$$

در شکل ۶ نمودار پراکندگی داده‌های مصرف روزانه واقعی و پیش‌بینی شده در مقابل یکدیگر و میزان همبستگی آنها برای روش WGEP نمایش داده شده است و در شکل ۷ مصرف واقعی و پیش‌بینی شده برای دوره زمانی یک‌ساله آورده شده است. با بررسی دقیق این نمودار و مقایسه با نمودار روش GEP (شکل ۳) می‌توان

رفع نویز سری زمانی مصرف آب در سطح اول با موجک مادر db5 منجر به بهترین نتایج شده و نتایج را تا ده درصد بهبود بخشیده است.


جدول ۷- معیارهای ارزیابی، برای مدل برتر در روش WGEP

موجک مادر	داده‌های آموزش			داده‌های آزمون		
	RMSE	MNE	R <sup>2</sup>	RMSE	MNE	R <sup>2</sup>
haar-1	۳۰۲۶/۱	۱/۷۵	۰/۸۹۲	۳۶۷۳/۸	۲/۱۰	۰/۸۷۴
haar-2	۳۰۵۰/۷	۱/۷۶	۰/۸۹۰	۳۶۵۵/۸	۲/۱۸	۰/۸۷۵
haar-3	۳۳۶۷/۱	۲/۰۱	۰/۸۶۶	۴۰۲۸/۳	۲/۳۶	۰/۸۴۸
db2-1	۲۸۴۶/۶	۱/۶۴	۰/۹۰۵	۳۳۳۵/۳	۱/۹۲	۰/۸۹۶
db2-2	۲۷۹۹/۸	۱/۶۵	۰/۹۰۸	۳۴۱۷/۸	۲/۰۲	۰/۸۹۱
db2-3	۳۲۶۶/۱	۱/۸۸	۰/۸۷۴	۳۶۲۰/۵	۲/۱۶	۰/۸۷۷
db3-1	۲۷۶۹/۳	۱/۶۳	۰/۹۱۰	۳۰۸۵/۷	۱/۸۵	۰/۹۱۱
db3-2	۲۸۴۶/۸	۱/۶۸	۰/۹۰۵	۳۲۷۶/۳	۱/۹۴	۰/۹۰۷
db3-3	۳۲۴۸/۲	۱/۸۹	۰/۸۷۶	۳۸۵۸/۳	۲/۱۹	۰/۸۸۰
db4-1	۲۶۹۸/۲	۱/۶۳	۰/۹۱۴	۳۰۵۹/۴	۱/۸۴	۰/۹۱۴
db4-2	۲۷۶۴/۴	۱/۶۰	۰/۹۱۰	۳۲۳۱/۶	۱/۹۴	۰/۹۰۲
db4-3	۳۱۸۰/۵	۱/۸۱	۰/۸۸۱	۳۵۶۳/۳	۲/۱۲	۰/۸۸۱
db5-1	۲۶۱۵/۶	۱/۵۶	۰/۹۱۹	۲۶۱۹/۱	۱/۵۷	۰/۹۱۸
db5-2	۲۶۵۸/۸	۱/۵۵	۰/۹۱۷	۳۰۶۳/۴	۱/۸۳	۰/۹۱۱


در این تحقیق اقدام به پیش‌بینی تقاضای روزانه آب شهری با استفاده از روش برنامه‌ریزی بیان ژن شد و قابلیت و کارایی این

روش برای این منظور، مورد بررسی قرار گرفت و نتایج به‌دست آمده با حالتی که این روش با آنالیز تبدیل موجک ترکیب می‌شود، مقایسه شد. با توجه به نتایج به‌دست آمده می‌توان گفت که بهترین مدل برای پیش‌بینی تقاضای روزانه آب، مدلی با ورودی‌هایی شامل مصرف آب یک، دو و سه روز قبل و یک هفته قبل است، بنابراین در مطالعه موردی حاضر، برای پیش‌بینی تقاضای روزانه مصرف آب، مقادیر مصرف آب در روزهای قبل نسبت به پارامترهای اقلیمی، پارامتر مهم‌تری است. مصرف روزانه پیش‌بینی شده آب، توسط روش GEP به رغم تبعیت از روند کلی سری زمانی مصرف واقعی و همبستگی مناسب با آن، دارای تأخیر زمانی نسبت به آن است و در بیشتر نقاط حداکثر و حداقل مصرف، اختلاف زیادی با آن دارد و این در حالی است که مصرف روزانه پیش‌بینی شده، با روش WGEF از نظر روند کلی، مطابق با مصرف واقعی است و همبستگی مناسبی با آن دارد و در نقاط حداکثر و حداقل مصرف، تقریباً منطبق بر مقادیر مصرف واقعی است یا بسیار نزدیک به آن است و نتایج حاصل از این روش تا ۱۰ درصد بهتر از حالت قبلی هستند. برای مطالعات آتی برای پیش‌بینی دقیق‌تر پیشنهاد می‌شود در استفاده از آنالیز تبدیل موجک تمام اطلاعات فرکانس پایین و فرکانس بالای به‌دست آمده از تجزیه سری زمانی مصرف آب به‌عنوان ورودی مدل‌ها استفاده شود و نتایج با حالت رفع نویز مقایسه شود. همچنین در راستای تکمیل مطالعات پیشنهاد می‌شود با استفاده از سایر روش‌های هوشمند مصرف روزانه آب برای مطالعه موردی حاضر محاسبه شده و نتایج آنها با روش برنامه‌ریزی بیان ژن مقایسه شود.

گفت که مصرف پیش‌بینی شده علاوه بر تبعیت از روند کلی از سری زمانی مصرف واقعی روزانه از نظر زمانی نیز منطبق بر سری زمانی مصرف واقعی است و نسبت به آن تأخیر ندارد و نقاط حداقل و حداکثر مصرف با دقت خوبی پیش‌بینی شده‌اند و تا حد زیادی با نقاط حداکثر و حداقل مصرف در سری زمانی مصرف واقعی مطابقت دارند.



شکل ۶- پراکندگی داده‌های مصرف روزانه واقعی و پیش‌بینی شده و میزان همبستگی آنها (روش WGEF)



شکل ۷- مقایسه مصرف روزانه واقعی و پیش‌بینی شده (روش WGEF)

۴- نتیجه‌گیری

۵- مراجع

1. Qi, C., and Chang, N. (2011). "System dynamics modeling for municipal water demand estimation in an urban region under uncertain economic impacts." *J. of Environmental Management*, 92, 1628-164.
2. Zhou, S.L., McMahon, T.A., Walton, A., and Lewis, L. (2000). "Forecasting daily urban water demand: A case study of Melbourne." *J. Hydrology*, 236, 153-164.
3. Stark, H.L., Stanley, S.J., and Buchana, I.D. (2000). "The application of artificial neural networks to water demand modeling." *Annual Conference Abstracts of Canadian Society for Civil Engineering*, Montreal, Canada, 139.
4. Kim, J.H., Hwang, S.H., and Shin, H.S. (2001). "A neuro-genetic approach for daily water demand." *J. Civil Engineering*, 5(3), 281-288.
5. Altunkaynak, A., Özger, M., and Cakmakci, M. (2005). "Water consumption prediction of Istanbul city by using fuzzy logic approach." *Water Resources Management*, 19, 641-654.
6. Tabesh, M., Goosheh, S., and Yazdanpanah, M. J. (2006). "Short term water demand forecasting of tehran city by artificial neural network." *J. Tehran University Engineering Faculty*, 41(2), 11-24.

7. Msiza, I.S., Nelwamondo, F.V., and Marwala, T. (2007). "Water demand forecasting using multi-layer perceptron and radial basis functions." *In Proceedings of the IEEE International Conference on Neural Networks*, IEEE, Orlando, FL.
8. Tabesh, M., and Dini, M. (2009). "Fuzzy and neuro-fuzzy models for short-term water demand forecasting in Tehran." *Iranian Journal of Science and Technology*, Transaction B, Engineering, 33(B1), 61-77.
9. Babel, M.S., and Shinde, R. V. (2011). "Identifying prominent explanatory variables for Water demand prediction using artificial neural networks: a case study of bangkok." *Water Resources Management*, 25, 1653-1676.
10. Herrera, M., Torgo, L., Izquierdo, J., and Perez-Garcia, P. (2010). "Predictive models for forecasting hourly urban water demand." *J. Hydrology*, 387, 141-150.
11. Campisi-Pinto, S., Adamowski, J., and Oron, G. (2012). "Forecasting urban water demand via wavelet-denoising and neural network models. Case study: City of Syracuse, Italy." *Water Resources Management*, DOI: 10.1007/s11269-012-0089-y.
12. Nasserri, M., Moeini, A., and Tabesh, M. (2011). "Forecasting monthly urban water demand using extended Kalman filter and genetic programming." *J. Expert Systems with Applications*, 38, 7387-7395.
13. Kisi, O., and Shiri, J. (2011). "Precipitation forecasting Using wavelet-genetic Programming and wavelet-neuro-fuzzy conjunction models." *Water Resources Management*, 25, 3135-3152.
14. Fernando, A.K., Shamseldin, A.Y., and Abrahart, B.J. (2012). "River flow forecasting using gene expression programming models." *In Proceedings of the 10th International Conference on Hydroinformatics*, HIC 2012, Hamburg, Germany.
15. Kisi, O., Shiri, J., and Nazemi, A.H. (2011). "A Wavelet-genetic programming model for predicting short-term and long-term air temperatures." *J. Civil Engineering and Urbanism*, 1, 25-37.
16. Tabesh, M., and Dini, M. (2009). "Forecasting urban water demand using artificial neural network, a case study of tehran urban water." *J. Water and Wastewater*, 21-1 (73), 84-95. (In Persian)
17. Kavehkar, S.H., Ghorbani, M.A., Ashrafzadeh, A., and Darbandi, S. (2013). "Simulation of water level fluctuations using gene expression programming." *J. Civil Engineering and Environment*, 43(3), 69-75.
18. Ferreira, C. (2001). "Gene expression programming: A new adaptive algorithm for solving problems." *Complex Systems*, 13(2), 87-129.
19. Toofani, P., Mosaedi, A., and Fakheri Fard, A. (2011). "Prediction of precipitation applying wavelet network model (case study: Zarringol station, Golestan province, Iran)." *J. Water and Soil*, 25(5), 1217-1226.
20. Zolfaghari, M., Aminnaaseri, M.R., and Beshatnia, F. (2011). "A combined model from artificial neural network, wavelet converting, and arma in predicting the demand for urban water." *J. Knowledge and Technology*, 5, 95-119.