

## ارزیابی مدل‌های رگرسیونی و نروفازی موجکی در برآورد مصرف آب شهری (مطالعه موردی: شهر کرمان)

مسعود رضا حسامی کرمانی<sup>۱\*</sup> و رضا ولی پرست فرخانی<sup>۲</sup>

### چکیده

پیش‌بینی میزان مصرف آب در مناطق شهری، اهمیت زیادی در مدیریت عرضه آب دارد. مدل پیش‌بینی مصرف آب، می‌تواند در برنامه‌ریزی منابع آب و گسترش زیر ساخت‌ها و همچنین بهبود کنترل و بهره‌برداری از سیستم‌های منابع آب استفاده شود. در این پژوهش، عملکرد مدل‌های رگرسیون خطی چند متغیره، سیستم استنتاج نروفازی تطبیقی، رگرسیون موجکی و نروفازی موجکی در پیش‌بینی تقاضای آب شهر کرمان ارزیابی شد. بدین‌منظور برای پیش‌بینی مصرف آب هفتگی شهر کرمان از داده‌های ۱۲ سال (۱۳۸۵-۱۳۹۶) مصرف آب هفتگی و پارامترهای هواشناسی (حداکثر دما و مجموع بارش هفتگی) استفاده شد. از داده‌های سال‌های ۱۳۸۵ تا ۱۳۹۳ (۴۶۹ هفته) برای آموزش و داده‌های سال‌های ۱۳۹۴ تا ۱۳۹۶ (۱۵۷ هفته) برای شبیه‌سازی استفاده شد. در مدل‌های رگرسیون موجکی و نروفازی موجکی سری‌های زمانی مصرف آب، حداکثر دما و بارش، توسط انتقال گسسته موجک به زیر سری‌های تقریب و جزئیات در سطوح مختلف تجزیه و به‌عنوان ورودی مدل‌های مبتنی بر موجک به کار گرفته شد. عملکرد مدل‌ها با شاخص‌های آماری ضریب همبستگی، ضریب تعیین، ریشه میانگین مربعات خطا و میانگین قدرمطلق خطا ارزیابی شد. نتایج به‌دست آمده، نشان داد که مدل رگرسیون موجکی ( $R^2 = 0/92$ ) و مدل نروفازی موجکی ( $R^2 = 0/94$ ) در مقایسه با سایر مدل‌ها از عملکرد بسیار بالاتری برخوردار بودند.

**واژه‌های کلیدی:** تبدیل موجک گسسته، تقاضای آب شهری، پیش‌بینی، رگرسیون خطی، نروفازی.

ارجاع: حسامی کرمانی م. ر. و ولی پرست فرخانی ر. ۱۳۹۹. ارزیابی مدل‌های رگرسیونی و نروفازی موجکی در برآورد مصرف آب شهری (مطالعه موردی: شهر کرمان). مجله پژوهش آب ایران. ۳۸: ۷۱-۸۴.

۱- استادیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه شهید باهنر کرمان.

۲- دانشجوی کارشناسی ارشد، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه شهید باهنر کرمان.

\*نویسنده مسئول: [hessami@uk.ac.ir](mailto:hessami@uk.ac.ir)

تاریخ پذیرش: ۱۳۹۸/۱۰/۰۲

تاریخ دریافت: ۱۳۹۸/۰۵/۲۳

## مقدمه

شبکه عصبی پایه شعاعی (RBNN)<sup>۲</sup> به پیش‌بینی تقاضای آب شهری در شهر از میر ترکیه پرداختند. مشخص شد که عملکرد مدل شبکه عصبی رگرسیون عمومی از سایر مدل‌ها بهتر است. آداموفسکی (۲۰۰۸) ۳۹ مدل رگرسیون خطی چندگانه (MLR)<sup>۴</sup>، نه مدل سری‌زمانی، و ۳۹ مدل شبکه عصبی مصنوعی را برای پیش‌بینی کوتاه مدت حداکثر تقاضای آب در شهر اتاواای کانادا بکار برد. مشاهده شد که نتایج مدل‌های شبکه عصبی در مقایسه با مدل‌های رگرسیون و سری زمانی بهتر بوده است. آداموفسکی و کاراپاتاکی (۲۰۱۰) مصرف هفتگی آب شهر نیکوزیا را در قبرس با استفاده از مدل‌های رگرسیون خطی چند متغیره و سه نوع مدل شبکه عصبی مصنوعی با الگوریتم‌های مختلف شامل شبکه عصبی لون برگ مارکوات (LM ANN)<sup>۵</sup>، شبکه عصبی انتشار بازگشتی ارتجاعی (RP ANN)<sup>۶</sup> و شبکه عصبی گرادیان مزدوج Powell-Beale (CGPB ANN)<sup>۷</sup> پیش‌بینی کردند. مشخص شد که مدل شبکه عصبی لون برگ مارکوات از سایر مدل‌های شبکه عصبی و رگرسیون خطی از دقت بالایی برخوردار است. همچنین مشخص شد که تقاضای آب هفتگی در نیکوزیا همبستگی بهتری با وقوع بارش نسبت به مقدار خود بارش دارد. آداموفسکی و همکاران (۲۰۱۲) با استفاده از روش‌های رگرسیون خطی چندگانه، رگرسیون غیرخطی چندگانه، مدل خود همبسته- میانگین متحرک تلفیق شده (ARIMA)<sup>۸</sup>، و شبکه عصبی پایه موجکی (WA-ANN) مصرف روزانه آب شهر مونترال کانادا را برآورد کردند. نتایج مدل‌سازی بیانگر توانایی خوب روش شبکه عصبی پایه موجکی در پیش‌بینی مصرف آب شهری است و این روش نتایج دقیق‌تری را نسبت به سایر مدل‌ها ارائه می‌دهد. محمد و ابراهیم (۲۰۱۲) با استفاده از مدل شبکه عصبی پایه موجکی به پیش‌بینی تقاضای آب شهری در شهر تامپا آمریکا در یک دوره زمانی چهارده ساله پرداختند. نتایج به دست آمده، نشان داد که مدل‌های با سطح و مرتبه بالاتر از موجک دوپچیز<sup>۹</sup> عملکرد بهتری نسبت به مدل‌های با سطح و

پیش‌بینی تقاضای آب شهری یک مسأله مهم در طراحی، نگهداری و بهره‌برداری از یک سیستم تأمین آب قابل اعتماد و کم مصرف است (قره‌باغی و همکاران، ۲۰۱۹). تقاضای آب تحت تأثیر عوامل بسیاری از جمله جمعیت، بارش، رطوبت، دما، شرایط صنعتی و تجاری است و یک پیش‌بینی قابل اعتماد باید به‌طور طبیعی آثار این عوامل اجتماعی-اقتصادی و اقلیمی تأثیرگذار بر مصرف آب را در نظر بگیرد. پیش‌بینی و مدل‌سازی تقاضای آب برای برنامه‌ریزی و مدیریت منابع آبی مهم و همچنین برای طراحی و بهره‌برداری از زیر ساخت‌های متعدد آب مانند تأسیسات ذخیره‌سازی و توزیع مخازن ضروری است (فیرات و همکاران، ۲۰۰۹). پژوهش‌های انجام گرفته در زمینه پیش‌بینی تقاضای آب همواره مورد توجه، ولی روش‌های پیش‌بینی و انگیزه آن در طول این دوران متفاوت بوده است. شروع پژوهش‌ها در این زمینه بیشتر بر اساس مدل‌های آماری و رگرسیون چندگانه و سری‌های زمانی بوده است. در سال‌های اخیر به موازات پیشرفت‌های قابل توجه در پردازش سریع اطلاعات بوسیله ماشین‌های الکترونیکی، بکارگیری مدل‌های غیرخطی برای به حداقل رساندن خطاهای احتمالی به‌طور چشم‌گیری افزایش یافته و استفاده از مدل‌های غیرخطی نظیر شبکه‌های عصبی مصنوعی و تبدیل موجک برای پیش‌بینی داده‌های سری‌زمانی در سال‌های اخیر مورد توجه قرار گرفته است (عاقلی کهنه شهری و آرام، ۱۳۹۰). یو و همکاران (۲۰۰۴) مدل شبکه عصبی چندلایه را برای پیش‌بینی تقاضای آب شهر هانگزو چین بر اساس فاکتورهایی مانند نسبت به‌کارگیری آب در صنعت، جمعیت و رشد اقتصادی به کار بردند که نتایج، نشان‌دهنده دقت و صحت بسیار خوب این مدل بوده است. بوگادیس و همکاران (۲۰۰۵) با استفاده از مدل‌های رگرسیون، سری زمانی و شبکه عصبی مصنوعی به پیش‌بینی کوتاه مدت حداکثر تقاضای آب در شهر اتاواای کانادا پرداختند. نتایج نشان داد که مدل‌های شبکه عصبی مصنوعی در مقایسه با مدل رگرسیون و سری زمانی از عملکرد بهتری برخوردار بوده است. فیرات و همکاران (۲۰۰۹) با استفاده از روش‌های مختلف شبکه عصبی مصنوعی مانند شبکه عصبی رگرسیون عمومی (GRNN)<sup>۱</sup>، شبکه عصبی پیشخور چندلایه (FFNN)<sup>۲</sup> و

2- Feed Forward Neural Networks

3- Radial Basis Neural Networks

4- Multiple Linear Regression

5- Levenberg-Marquardt Artificial Neural Network

6- Resilient Back-Propagation Artificial Neural Network

7- Conjugate Gradient Powell-Beale Artificial Neural Network

8- Auto Regressive Integrated Moving Average

9- Daubechies

1- Generalized Regression Neural Networks

صادقی و همکاران (۱۳۹۴) برای پیش‌بینی تقاضای آب شهر اصفهان از دو الگوی سری‌زمانی ساختاری<sup>۶</sup> STSM و سری‌زمانی<sup>۷</sup> ARMA استفاده کردند. داده‌های مورد استفاده در این پژوهش شامل داده‌های مصرف ماهانه، قیمت واقعی و هزینه‌های پرداختی مشترکین آب شهر اصفهان طی دوره ۱۳۹۰-۱۳۸۸ بود. در این پژوهش از شاخص‌های آماری ریشه میانگین مربعات خطا (RMSE)، میانگین خطای مطلق (MAE) و میانگین قدرمطلق درصد خطا (MAPE) برای ارزیابی و مقایسه مدل‌ها استفاده شده است. نتایج نشان داد که الگوی سری‌زمانی ساختاری عملکرد بهتری نسبت به مدل ARMA در پیش‌بینی تقاضای آب در شهر اصفهان دارد.

در سال‌های اخیر بررسی‌های گسترده‌ای درباره مسأله استفاده بهینه از منابع آب انجام شده است. اگرچه پیش‌بینی میزان مصرف آب به‌صورت تحلیلی بسیار مشکل است، امروزه سیستم‌های هوشمند، مانند آنالیز موجک، می‌تواند به‌عنوان یک گزینه راه‌گشا مطرح شود. در این پژوهش با استفاده از مدل‌های ترکیبی رگرسیون پایه موجکی و نروفازی پایه موجکی، میزان مصرف هفتگی آب شهر کرمان پیش‌بینی شده است. هدف اصلی از این پژوهش، ارائه یک سیستم مناسب برای پیش‌بینی مصرف آب شهر کرمان و همچنین کمک به مدیریت آب منطقه است.



شکل ۱- موقعیت شهر کرمان در تصویر ماهواره‌ای

#### مواد، روش‌ها و منطقه مورد مطالعه

منطقه مورد مطالعه، شهر کرمان با مساحت ۲۳۸/۸ کیلومتر مربع در استان کرمان واقع شده است. این منطقه

مرتبه کمتر دارند. کامپسی پینتو و آداموفسکی (۲۰۱۲) مدل ترکیبی شبکه عصبی پایه موجکی را برای پیش‌بینی تقاضای آب شهر سیراکوز در ایتالیا در بازه‌های زمانی مختلف اعمال کردند. نتایج نشان داد که تجزیه سری‌زمانی با استفاده از تبدیل موجک باعث بهتر شدن نتایج حاصل از شبکه عصبی مصنوعی می‌شود. آلتونکایناک و نیگوسی (۲۰۱۷) مصرف آب ۲۳ سال شهر استانبول در ترکیه را بصورت ماهانه پیش‌بینی کردند. در این پژوهش برای پیش‌پردازش داده‌ها از دو روش آگوریتیم فصلی چند ضلعی (MSA)<sup>۱</sup> و آنالیز تبدیل موجک گسسته استفاده شد. مدل‌های مورد استفاده شامل مدل‌های رگرسیون خطی چند متغیره، رگرسیون خطی پایه موجکی چند متغیره (DWT-MLP) و ترکیب رگرسیون خطی چند متغیره با آگوریتیم فصلی چند ضلعی (MSA-MLP) است. نتایج به دست آمده حاکی از آن بود که مدل (MSA-MLP) از سایر مدل‌ها عملکرد مطلوب‌تری داشت و مشخص شد MSA یک روش پیش‌پردازش بهتر نسبت به DWT است. گیو و لیو (۲۰۱۸) با استفاده از مدل‌های شبکه عصبی بازگشتی (GRUN)<sup>۲</sup> و شبکه عصبی مصنوعی (ANN)<sup>۳</sup> به پیش‌بینی تقاضای آب ۱۵ دقیقه و ۲۴ ساعت آینده در شهر چانگژوی چین پرداختند که نتایج حاکی از برتری مدل (GRUN) نسبت به مدل (ANN) بود.

تابش و دینی (۱۳۸۹) با استفاده از شبکه عصبی پرسپترون چندلایه (MLP)<sup>۴</sup> و شبکه عصبی تابع پایه شعاعی به پیش‌بینی تقاضای روزانه آب شهری تهران پرداختند. نتایج نشان داد که مدل‌های پرسپترون نسبت به مدل تابع پایه شعاعی نتایج مطلوب‌تری دارند. همچنین در بین مدل‌های شبکه عصبی پرسپترون مشخص شد که مدل‌های با خروجی غیرخطی نسبت به مدل‌های با خروجی خطی مناسب‌تر هستند. روشنگر و همکاران (۱۳۹۳) از ترکیب روش برنامه‌ریزی بیان ژن با آنالیز تبدیل موجک گسسته (DWT)<sup>۵</sup> برای پیش‌بینی تقاضای روزانه آب در شهر همدان استفاده کردند. نتایج نشان داد که ترکیب روش برنامه‌ریزی بیان ژن با آنالیز تبدیل موجک، نتایج پیش‌بینی را تا ۱۰ درصد بهبود می‌بخشد.

1- Multiplicative Season Algorithm Network

2- Gated Recurrent Unit Network

3- Artificial Neural Network


4- Multiple Layer Perceptron

5- Discrete Wavelet Transform

6- Structural Time Series Model

7- Auto Regressive Moving Average

شبهه‌سازی مدل استفاده شده است. در شکل ۲ سری‌زمانی مصرف آب شهر کرمان در طی این سال‌ها نشان داده شده است. در جدول ۱ تحلیل آماری هر سه پارامتر مصرف آب، دمای بیشینه و بارش کل برای مجموعه‌های شبهه‌سازی، آموزش و کل داده‌ها ارائه شده است.



شکل ۲- نمودار مصرف آب هفتگی شهر کرمان طی سال‌های ۱۳۸۵ تا ۱۳۹۶ بر حسب مترمکعب

در مختصات جغرافیایی ۵۷ درجه و ۷ دقیقه شرقی و ۳۰ درجه و ۱۸ دقیقه شمالی و در ارتفاع ۱۷۵۵ متر از سطح دریا قرار دارد. این شهر از شمال و شرق به کویر لوت، از جنوب به شهرستان‌های بم و جیرفت و از غرب به شهرستان‌های زرنند، راور، رفسنجان و بردسیر محدود می‌شود. شهر کرمان با جمعیتی بالغ بر ۷۳۵۷۲۴ نفر (۱۳۹۵) از کلان‌شهرهای ایران است. آب و هوای آن نیمه بیابانی و خشکی هوا و کمبود بارش از مشخصات این نوع آب و هواست. شکل ۱ موقعیت شهر کرمان در تصویر ماهواره‌ای را نشان می‌دهد. داده‌های مورد استفاده در این تحقیق شامل اطلاعات مربوط به پارامترهای هواشناسی و اطلاعات مربوط به مصرف آب در شهر کرمان است. داده‌های هواشناسی از سازمان هواشناسی کشور تهیه شد که شامل پارامترهای دمای بیشینه و مقدار کل بارش هفتگی است. همچنین داده‌های مربوط به مصرف آب از شرکت آب و فاضلاب شهر کرمان تهیه شد که شامل مصرف هفتگی بود. این اطلاعات مربوط به سال‌های ۱۳۸۵ تا ۱۳۹۶ که از داده‌ی سال‌های ۱۳۸۵ تا ۱۳۹۳ برای مدل‌سازی و از داده‌ی سال‌های ۱۳۹۴ تا ۱۳۹۶ برای

جدول ۱- توصیف آماری داده‌ها

پارامترهای آماری	مصرف آب (m <sup>3</sup> )	دمای حداکثر (°C)	بارش کل (mm)
میانگین	۶۹۵۷۷۶	۲۸/۴۸	۱/۸۹
بیشینه	۱۰۴۸۷۶۱	۴۱	۳۹/۴
کمینه	۳۲۹۱۵۴	۹	۰
انحراف معیار	۱۲۳۸۹۵	۷/۵۵	۵/۲۸
چولگی	-۰/۲۰	-۰/۲۳	۳/۸۱

### سیستم استنتاج نروفازی تطبیقی (ANFIS)


سیستم استنتاج نروفازی تطبیقی، را جانگ در سال ۱۹۹۳ معرفی کرد (جانگ، ۱۹۹۳). سیستم‌های استنتاج فازی، یک چارچوب محاسباتی پرترفدار بر مبنای مفهوم مجموعه‌های فازی، قواعد if-then و استدلال فازی هستند. ساختار پایه‌ای سیستم‌های استنتاج فازی از سه بخش مفهومی تشکیل می‌شود: بخش اول، قواعدی هستند که شامل گزینشی از قواعد فازی هستند. بخش دوم، پایگاه داده است که توابع عضویت مورد استفاده در قواعد فازی، در قالب آن تعریف می‌شود و در نهایت، بخش سوم، سازوکار استنتاج است که روال استنتاج توسط آن و به کمک قواعد و حقایق موجود، برای رسیدن به یک خروجی

معقول انجام می‌پذیرد؛ سه نوع از سیستم‌های استنتاج فازی که دارای کاربردهای گسترده‌ای هستند، عبارتند از: مدل‌های فازی ممدانی، مدل‌های فازی سوگنو<sup>۱</sup> و مدل‌های فازی تسوکاموتو<sup>۲</sup>. تفاوت بین این سیستم‌ها، در نتیجه قواعد فازی و روال محاسبه مجموع و غیرفازی‌سازی در آن‌ها است (کیا، ۱۳۹۰). سیستم استنتاج نروفازی تطبیقی، شبیه یک شبکه عصبی چند لایه است، با این تفاوت که علاوه بر الگوریتم‌های یادگیری شبکه عصبی از منطق فازی نیز بهره می‌گیرد و یک سیستم فازی سوگنو را در یک ساختار عصبی اجرا می‌کند. این سیستم برای فرآیند آموزش از ترکیبی از روش‌های آموزش پس انتشار

1- Sugeno Fuzzy Models

2- Tsukamoto Fuzzy Models

سایر مدل‌ها به نتایج بسیار خوبی رسید. آنالیز موجک می‌تواند یک ابزار امیدوارکننده در تجزیه سری زمانی باشد (شبری، ۲۰۱۵). شکل ۴ به صورت شماتیک تبدیل موجک را نشان می‌دهد.




شکل ۴- شماتیکی از تبدیل موجک

تبدیل موجک، تابعی است که نسخه بهبود یافته تبدیل فوریه را تداعی می‌کند. تحلیل فوریه، ابزاری ریاضی است که سیگنال را از حالت زمانی به حالت فرکانسی تبدیل می‌کند؛ درحالی که تبدیل‌های موجک یک بیان زمان-مقیاس از سری‌های زمانی (سیگنال) ارائه می‌دهند. روش متداول برای کاهش نویز و تجزیه سیگنال به فرکانس‌های آن، تبدیل فوریه است که در آنالیز و پردازش سیگنال‌ها کاربرد دارد؛ اما این تبدیل دارای محدودیت‌هایی است (هان و همکاران، ۲۰۰۵). نقص و مشکل جدی که تبدیل فوریه در انتقال به حوضه فرکانسی دارد، این است که اطلاعات زمانی سیگنال گم می‌شود. در صورتی که موجک‌ها، توابع ریاضی هستند که یک بیان زمان-مقیاس از سری‌های زمانی و نسبت‌های آن ارائه می‌دهند؛ این بیان برای تحلیل‌های سری زمانی ناپیوسته مفید است (آداموفسکی و چان، ۲۰۱۱). تبدیل موجک در دو نوع پیوسته و گسسته در زمان به کار می‌رود. موجک پیوسته (CWT)<sup>۱</sup> تبدیلی است که تابع پیوسته در بعد زمان را به فضای زمان-فرکانس می‌برد؛ یعنی تابع تک بعدی را به دو بعدی تبدیل می‌کند. برای یک سری زمانی با تابع  $f(t)$  تبدیل موجک پیوسته آن به صورت زیر است:

$$CWT(a,b) = |a|^{-1} \int_{-\infty}^{+\infty} f(t) \bar{\psi}\left(\frac{t-b}{a}\right) d_t \quad (2)$$

معادله بالا، تابعی از دو متغیر  $a$  و  $b$  که  $a$  نشان‌دهنده مقیاس (عکس فرکانس) و  $b$  نشان‌دهنده انتقال است.

خطا و کمینه مربعات خطا بهره می‌گیرد. یک مدل ANFIS از پنج لایه تشکیل شده است که عبارتند از: لایه ورودی اطلاعات؛ لایه محاسبه وزن قوانین فازی، لایه نرمال‌سازی وزن‌های قوانین به دست آمده، لایه محاسبه قوانین و لایه جمع‌بندی و خروجی شبکه. شکل ۳ شماتیکی از ANFIS نشان داده شده است.



شکل ۳- ساختار سیستم استنتاج نروفازی تطبیقی

### رگرسیون خطی چند متغیره (MLR)

تحلیل رگرسیون خطی چند متغیره، روشی در پیش‌بینی‌های سری‌زمانی، بری مدل کردن رابطه خطی بین یک متغیر وابسته و یک یا چند متغیر مستقل است. شکل معمول معادله به صورت زیر نشان داده می‌شود:


$$y = a_0 + \sum a_i x_i \quad (1)$$

که در آن  $y$  مقدار پیش‌بینی شده،  $a_0$  ثابت رگرسیون،  $a_i$  ضریب رگرسیون متغیرهای مستقل  $x_i$  است. هدف این روش، تعیین پارامترهای معادله رگرسیون است؛ به گونه‌ای که مقادیر تخمین زده شده کارا و سازگار باشند (رجایی، ۲۰۱۱).

### تبدیل موجک

واژه موجک را، برای اولین بار هار (۱۹۱۰) به کار برد، سپس (گراسمن و مورلت، ۱۹۸۴) به طور عام موجک‌ها را نام‌گذاری کردند. دوبچیز (۱۹۸۸) پایه‌های موجکی را معرفی کرد که خاصیت‌های متعامدی موضعی بودن را داشته و دقت لازم برای تولید توابع ساده را دارا بودند. ساده‌ترین موجک دوبچیز، موجک هار است و در بین موجک‌ها، دوبچیز تنها موجکی است که ناپیوسته است. عملیات انتقال موجک، تجزیه‌های سودمندی از داده‌های اصلی را به وجود می‌آورد که نتایج آن عملکرد پیش‌بینی مدل را بهتر می‌کند. می‌توان با هیبرید کردن موجک با

Db2 سری زمانی مصرف آب (S) را به یک تقریب (a3) و سه مؤلفه جزئیات (d1, d2, d3) تجزیه کرده است.



شکل ۶- عملیات فیلتر کردن یک سیگنال

نکته مهم در مورد انتخاب موجک مادر، طبیعت رخداد پدیده و نوع سری زمانی مشاهده شده است. سری زمانی مصرف آب هفتگی شهر کرمان ماهیت تک قله‌ای ندارد و دارای ویژگی نوسان پی‌درپی است. بنابراین الگوهایی از توابع موجک مادر که بتوانند از نظر شکل هندسی به خوبی بر منحنی سری زمانی منطبق شوند، بهتر می‌توانند عمل نگاشت را انجام دهند و نتایج بهتری دربر خواهند داشت. با توجه به شباهت نسبی که سری زمانی مصرف آب شهر کرمان به موجک مادر دوپچیز دارد، این نوع موجک انتخاب شد.

همچنین به کار بردن سطح تجزیه بالا مطلوب نیست؛ زیرا اگر چه سطح تجزیه بالا دقت آموزش شبکه را افزایش می‌دهد، نتیجه معکوس روی داده‌های شبیه‌سازی دارد.

### ارزیابی آماری مدل‌ها

برای ارزیابی عملکرد مدل‌ها در این پژوهش، از چهار شاخص آماری ضریب همبستگی (R)، ضریب تعیین ( $R^2$ )، ریشه میانگین مربعات خطا (RMSE) و میانگین قدرمطلق خطا (MAE) استفاده شد. معادلات مربوط به این شاخص‌ها به صورت زیر است:


$$R = \frac{\frac{1}{n} \sum_{i=1}^n (o_i - o_{ave})(p_i - p_{ave})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - o_{ave})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - p_{ave})^2}} \quad (۴)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (o_i - p_i)^2}{\sum_{i=1}^n (o_i - p_{ave})^2} \quad (۵)$$

$\Psi(t)$  تابع انتقال بوده و موج مادر نام دارد. تبدیل موجک گسسته (DWT) برای آنالیز داده‌ها مناسب‌تر از تبدیل پیوسته است؛ زیرا تبدیل معکوس را می‌توان برای هر دسته از داده‌های زمان - فرکانس به کار برد. همچنین برای یک سری زمانی با تابع  $f(t)$  تبدیل موجک گسسته آن به صورت زیر است:

$$DWT(t, s) = \frac{1}{\sqrt{2}} \sum_{t=0}^{n-1} x(t) * y\left(\frac{t}{2^s} - t\right) \quad (۳)$$

در این معادله،  $S, \tau$  و  $X(t)$  به ترتیب معرف پارامترهای انتقال، مقیاس و سیگنال (سری زمانی داده‌ها) هستند. در تبدیل موجک گسسته فرآیند تجزیه سیگنال شامل یک یا چند مرحله متوالی است که در اولین مرحله تجزیه، سیگنال به دو قسمت تقریب (cA) و جزئیات (cD) تجزیه می‌شود. در مرحله بعدی تجزیه، پس از اولین مرحله تفکیک با تجزیه مجدد، قسمت تقریب به دو قسمت تقریب و جزئیات ادامه پیدا می‌کند و با توجه به تعداد مراحل تجزیه مورد نظر این روند ادامه پیدا می‌کند. در شکل ۵ تجزیه سیگنال با استفاده از تبدیل موجک گسسته نشان داده شده است.



شکل ۵- تجزیه سیگنال با استفاده از موجک گسسته

در آنالیز تبدیل موجک، مؤلفه تقریب مربوط به مقیاس‌های بزرگ (فرکانس پایین) و جزئیات مربوط به مقیاس‌های کوچک (فرکانس بالا) است. عملیات فیلتر کردن به صورت ساده و کلی در شکل ۶ قابل نمایش است (روشنگر و همکاران، ۱۳۹۳).


در اکثر پژوهش‌ها از تبدیل موجک گسسته، به دلیل سادگی و سرعت بالای محاسبات استفاده می‌شود. در این پژوهش نیز تجزیه سری زمانی مصرف آب، حداکثر دما و بارش توسط موجک مادر دوپچیز (Db1, Db2, Db3) در سه سطح انجام شد، برای مثال در شکل ۷ موجک مادر

پیش‌بینی شده و  $P_{ave}$ : میانگین مقادیر پیش‌بینی شده است. هرچه میزان خطا (RMSE و MAE) کمتر و میزان همبستگی داده‌ها R و  $(R^2)$  بیشتر باشد، میزان عملکرد مدل مطلوب است.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - p_i)^2} \quad (6)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |o_i - p_i| \quad (7)$$

که در این معادلات، n تعداد مشاهدات،  $O_i$  مقادیر مشاهداتی،  $O_{ave}$  میانگین مقادیر مشاهداتی،  $P_i$  مقادیر



شکل ۷- سری زمانی اصلی مصرف آب هفتگی و مولفه‌های حاصل از تجزیه با تبدیل موجک گسسته

$$MAE = \frac{1}{n} \sum_{i=1}^n |o_i - p_i| \quad (7)$$

که در این معادلات، n تعداد مشاهدات،  $O_i$  مقادیر مشاهداتی،  $O_{ave}$  میانگین مقادیر مشاهداتی،  $P_i$  مقادیر پیش‌بینی شده و  $P_{ave}$ : میانگین مقادیر پیش‌بینی شده است. هرچه میزان خطا (RMSE و MAE) کمتر و میزان همبستگی داده‌ها R و  $(R^2)$  بیشتر باشد، میزان عملکرد مدل مطلوب است.

#### نتایج و بحث

در این پژوهش، برای پیش‌بینی مصرف آب هفتگی شهرکرمان از شش مدل رگرسیون خطی چند متغیره، شش مدل نروفازی، ۱۸ مدل رگرسیون خطی پایه موجکی و ۱۸ مدل نروفازی پایه موجکی استفاده شد. برای ساخت مدل‌های بالا، داده‌های ورودی به دو قسمت تقسیم شدند

#### ارزیابی آماری مدل‌ها

برای ارزیابی عملکرد مدل‌ها در این پژوهش، از چهار شاخص آماری ضریب همبستگی (R)، ضریب تعیین ( $R^2$ )، ریشه میانگین مربعات خطا (RMSE) و میانگین قدرمطلق خطا (MAE) استفاده شد. معادلات مربوط به این شاخص‌ها به صورت زیر است:

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (o_i - o_{ave})(p_i - p_{ave})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - o_{ave})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - p_{ave})^2}} \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (o_i - p_i)^2}{\sum_{i=1}^n (o_i - p_{ave})^2} \quad (5)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - p_i)^2} \quad (6)$$

مترمکعب در هفته و میانگین قدرمطلق خطای ۳۹۵۲۸ مترمکعب در هفته در مرحله آموزش بهترین عملکرد را داشته است. در این مدل از ترکیب شش استفاده شده است. همچنین ضعیف‌ترین مدل MLR1 با ضریب تعیین ۰/۶۵، ریشه میانگین مربعات خطای ۷۱۷۶۲ مترمکعب در هفته و میانگین قدرمطلق خطای ۴۰۱۳۲ مترمکعب در هفته در مرحله آموزش است. در این مدل از ترکیب یک استفاده شده است. نتایج حاصل از بررسی مدل ANFIS نشان داد که بهترین مدل مربوط به مدل ANFIS6 با ضریب تعیین ۰/۷۳، ریشه میانگین مربعات خطای آموزش ۶۲۷۷۱ مترمکعب در هفته و میانگین قدرمطلق خطای آموزش ۳۹۲۲۳ مترمکعب در هفته می‌باشد. در این مدل از ترکیب شش استفاده شده است. همچنین ضعیف‌ترین مدل ANFIS1 با ضریب تعیین ۰/۶۵، ریشه میانگین مربعات خطای ۷۱۷۶۲ مترمکعب در هفته و میانگین قدرمطلق خطای ۴۰۱۳۲ مترمکعب در هفته در مرحله آموزش است. در این مدل از ترکیب ۱ استفاده شده است. جدول ۳ وضعیت عملکرد آماری مربوط به مدل‌های MLR و ANFIS را نشان می‌دهد. همان‌گونه که مشاهده می‌شود، با افزودن پارامترهای هواشناسی به مدل عملکرد مدل بهتر می‌شود همچنین افزودن پارامترهای دو هفته قبل هم عملکرد مدل را بهبود می‌بخشد.

که قسمت اول شامل ۷۵ درصد داده‌ها (۱۳۸۵-۱۳۹۳) برای آموزش و قسمت دوم شامل ۲۵ درصد داده‌ها (۱۳۹۴-۱۳۹۶) برای شبیه‌سازی بود. برای شبیه‌سازی مدل‌ها از نرم‌افزار MATLAB استفاده شد. برای انجام مدل‌سازی با توجه به پارامترهای ورودی، شش نوع ترکیب مختلف مطابق جدول ۲ بررسی شد. ورودی‌های  $C_{t-1}$ ،  $C_{t-2}$  به ترتیب مصرف آب یک و دو هفته قبل، ورودی‌های  $T_{t-1}$ ،  $T_{t-2}$  به ترتیب حداکثر دمای یک و دو هفته قبل و ورودی‌های  $P_{t-1}$ ،  $P_{t-2}$  به ترتیب مقدار بارش کل یک و دو هفته قبل هستند. این ترکیب‌ها به‌عنوان ورودی در هر یک از مدل‌های ANFIS، MLR، WR و WANFIS بررسی شدند.

جدول ۲- ساختار مختلف مدل‌ها

ساختار	ورودی	خروجی
۱	$C_{t-1}$	$C_t$
۲	$C_{t-1}, T_{t-1}$	$C_t$
۳	$C_{t-1}, T_{t-1}, P_{t-1}$	$C_t$
۴	$C_{t-1}, C_{t-2}$	$C_t$
۵	$C_{t-1}, T_{t-1}, C_{t-2}, T_{t-2}$	$C_t$
۶	$C_{t-1}, T_{t-1}, P_{t-1}, C_{t-2}, T_{t-2}, P_{t-2}$	$C_t$

نتایج حاصل از بررسی مدل MLR نشان داد که بهترین مدل مربوط به مدل MLR6 است. این مدل با ضریب تعیین ۰/۷۲، ریشه میانگین مربعات خطای ۶۴۰۹۲

جدول ۳- مقادیر شاخص‌های آماری مدل‌های رگرسیون و نروفازی

شبیه‌سازی			آموزش			ورودی	مدل
MAE (m <sup>3</sup> )	RMSE (m <sup>3</sup> )	R <sup>2</sup>	MAE (m <sup>3</sup> )	RMSE (m <sup>3</sup> )	R <sup>2</sup>		
۳۳۶۶۲	۶۸۵۳۶	۰/۸۲	۴۰۱۳۲	۷۱۷۶۲	۰/۶۵	$C_{t-1}$	MLR1
۳۴۰۰۷	۶۶۷۷۸	۰/۸۳	۴۰۷۳۹	۷۱۳۵۴	۰/۶۵	$C_{t-1}, T_{t-1}$	MLR2
۳۴۰۵۸	۶۶۶۸۸	۰/۸۳	۴۰۸۳۱	۷۰۹۸۹	۰/۶۶	$C_{t-1}, T_{t-1}, P_{t-1}$	MLR3
۳۳۰۵۳	۶۴۹۳۶	۰/۸۳	۳۹۷۴۴	۶۵۹۱۸	۰/۷	$C_{t-1}, C_{t-2}$	MLR4
۳۳۱۶۳	۶۲۰۶۷	۰/۸۴	۳۹۵۷۳	۶۵۰۵۲	۰/۷۱	$C_{t-1}, T_{t-1}, C_{t-2}, T_{t-2}$	MLR5
۳۳۱۲۴	۶۱۷۷۲	۰/۸۴	۳۹۵۲۸	۶۴۰۹۲	۰/۷۲	$C_{t-1}, T_{t-1}, P_{t-1}, C_{t-2}, T_{t-2}, P_{t-2}$	MLR6
۳۶۷۹۴	۶۹۴۵۲	۰/۸۲	۴۰۱۳۲	۷۱۷۶۲	۰/۶۵	$C_{t-1}$	ANFIS1
۳۵۷۶۹	۶۷۴۴۹	۰/۸۳	۴۰۸۱۷	۷۱۰۴۱	۰/۶۶	$C_{t-1}, T_{t-1}$	ANFIS2
۳۶۶۱۵	۶۸۶۰۰	۰/۸۲	۴۱۰۲۸	۷۰۳۲۷	۰/۶۶	$C_{t-1}, T_{t-1}, P_{t-1}$	ANFIS3
۳۹۶۵۹	۶۷۷۲۴	۰/۸۱	۳۹۷۴۴	۶۵۹۱۸	۰/۷	$C_{t-1}, C_{t-2}$	ANFIS4
۳۳۱۶۳	۶۲۰۶۷	۰/۸۴	۳۹۵۷۳	۶۵۰۵۲	۰/۷۱	$C_{t-1}, T_{t-1}, C_{t-2}, T_{t-2}$	ANFIS5
۳۸۰۸۷	۶۶۶۶۶	۰/۸۲	۳۹۲۲۳	۶۲۷۷۱	۰/۷۳	$C_{t-1}, T_{t-1}, P_{t-1}, C_{t-2}, T_{t-2}, P_{t-2}$	ANFIS6

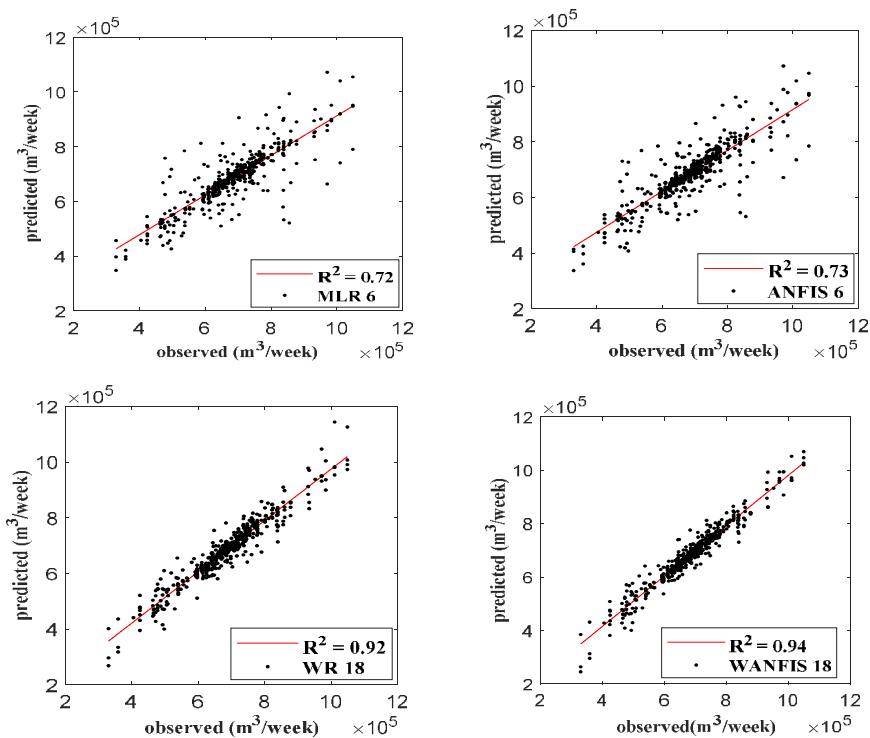


همچنین نتایج حاصل از بررسی مدل WANFIS نشان داد که بهترین مدل مربوط به مدل WANFIS18 با ضریب تعیین ۰/۹۴، ریشه میانگین مربعات خطای آموزش ۲۹۱۷۹ مترمکعب در هفته و میانگین قدرمطلق خطای آموزش ۲۰۶۷۵ مترمکعب در هفته است. در این مدل از ترکیب ۶ استفاده شد. این مدل با استفاده از موجک دوپچیز نوع سه و در سه سطح (Db3,3) میزان RMSE و MAE در مرحله آموزش را نسبت به مدل ANFIS6 به ترتیب به مقدار ۵۴٪ و ۴۷٪ بهبود بخشید. جدول ۵ مختص به وضعیت عملکرد آماری مربوط به مدل WANFIS است. شکل ۸ نمودار پراکنش بهترین مدل‌های ANFIS، MLR و WANFIS در طول دوره آموزش را نشان می‌دهد. همچنین در شکل‌های ۹ و ۱۰ به ترتیب نمودار مقایسه مقادیر مشاهداتی و پیش‌بینی شده مصرف آب شهری با مدل‌های مذکور در طول دوره آموزش و شبیه‌سازی نشان داده شد.

در مدل‌های ترکیبی WR و WANFIS ابتدا سیگنال‌های اصلی پارامترهای ورودی با استفاده از تبدیل موجک گسسته و با استفاده از موجک مادر دوپچیز نوع ۱، ۲ و ۳ و در سه سطح ((Db1,3), (Db2,3), (Db3,3)) به زیرسیگنال‌های تقریب ( $A_s$ ) و جزئیات ( $D_s$ ) تجزیه شدند و این زیرسیگنال‌ها به‌عنوان ورودی در مدل MLR و ANFIS قرار گرفتند تا مدل‌های WR و WANFIS ایجاد شوند. نتایج حاصل از بررسی مدل WR نشان داد که بهترین مدل، مربوط به مدل WR18 با ضریب تعیین ۰/۹۲، ریشه میانگین مربعات خطای آموزش ۳۴۱۵۱ مترمکعب در هفته و میانگین قدرمطلق خطای آموزش ۲۳۹۰۸ مترمکعب در هفته است. در این مدل از ساختار شش استفاده شده است. این مدل با استفاده از موجک دوپچیز نوع سه و در سه سطح (Db3,3) میزان RMSE و MAE در مرحله آموزش را نسبت به مدل MLR6 به ترتیب به مقدار ۴۷٪ و ۴۰٪ بهبود بخشید. در جدول ۴ وضعیت عملکرد آماری مربوط به مدل WR نشان داده شده است.

جدول ۴- مقادیر شاخص‌های آماری مدل‌های رگرسیون پایه موجکی

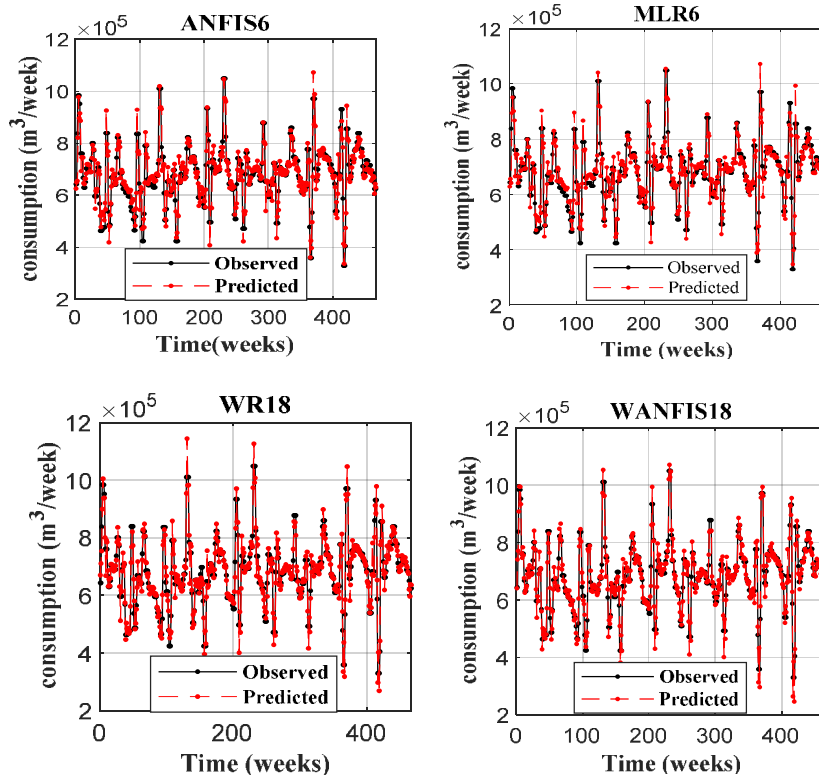
مدل	ورودی	نوع موجک	سطح تجزیه	آموزش			شبیه‌سازی		
				MAE (m <sup>3</sup> )	RMSE (m <sup>3</sup> )	R <sup>2</sup>	MAE (m <sup>3</sup> )	RMSE (m <sup>3</sup> )	R <sup>2</sup>
WR1	C <sub>t-1</sub>	Db1	۳	۳۶۶۶۶	۶۵۴۷۸	۰/۷۱	۳۱۷۵۴	۶۴۲۵۱	۰/۸۴
WR2	C <sub>t-1</sub> , T <sub>t-1</sub>	Db1	۳	۳۷۴۱۸	۶۴۹۷۶	۰/۷۱	۳۳۰۸۷	۶۳۱۴۸	۰/۸۴
WR3	C <sub>t-1</sub> , T <sub>t-1</sub> , P <sub>t-1</sub>	Db1	۳	۳۸۰۶۷	۶۴۴۷۹	۰/۷۲	۳۴۶۸۶	۶۱۷۶۶	۰/۸۶
WR4	C <sub>t-1</sub> , C <sub>t-2</sub>	Db1	۳	۲۹۹۳۳	۵۳۳۶۳	۰/۸	۲۷۷۷۱	۵۶۲۸۴	۰/۸۷
WR5	C <sub>t-1</sub> , T <sub>t-1</sub> , C <sub>t-2</sub> , T <sub>t-2</sub>	Db1	۳	۳۰۲۶۴	۵۲۶۴۳	۰/۸۱	۲۹۸۷۹	۵۴۸۰۸	۰/۸۸
WR6	C <sub>t-1</sub> , T <sub>t-1</sub> , P <sub>t-1</sub> , C <sub>t-2</sub> , T <sub>t-2</sub> , P <sub>t-2</sub>	Db1	۳	۳۰۴۳۸	۵۱۹۲۰	۰/۸۱	۳۰۷۶۲	۵۱۵۱۶	۰/۸۲
WR7	C <sub>t-1</sub>	Db2	۳	۳۶۹۰۶	۶۵۱۴۳	۰/۷۱	۳۴۰۴۹	۶۱۵۷۷	۰/۸۶
WR8	C <sub>t-1</sub> , T <sub>t-1</sub>	Db2	۳	۳۷۱۶۸	۶۴۷۹۱	۰/۷۱	۳۶۶۰۳	۵۹۹۶۷	۰/۸۶
WR9	C <sub>t-1</sub> , T <sub>t-1</sub> , P <sub>t-1</sub>	Db2	۳	۳۸۳۵۳	۶۴۰۸۶	۰/۷۲	۳۷۲۹۵	۵۸۰۱۸	۰/۸۷
WR10	C <sub>t-1</sub> , C <sub>t-2</sub>	Db2	۳	۲۵۶۷۴	۴۳۴۷۱	۰/۸۷	۲۷۹۶۰	۴۷۹۳۷	۰/۹۱
WR11	C <sub>t-1</sub> , T <sub>t-1</sub> , C <sub>t-2</sub> , T <sub>t-2</sub>	Db2	۳	۲۵۸۹۵	۴۲۳۰۶	۰/۸۷	۲۹۰۹۷	۴۶۵۶۷	۰/۹۱
WR12	C <sub>t-1</sub> , T <sub>t-1</sub> , P <sub>t-1</sub> , C <sub>t-2</sub> , T <sub>t-2</sub> , P <sub>t-2</sub>	Db2	۳	۲۶۱۶۴	۴۲۱۱۲	۰/۸۸	۲۸۳۹۶	۴۳۹۴۹	۰/۹۲
WR13	C <sub>t-1</sub>	Db3	۳	۳۵۸۱۹	۶۲۲۶۴	۰/۷۳	۳۳۵۳۵	۴۹۳۵۲	۰/۹۱
WR14	C <sub>t-1</sub> , T <sub>t-1</sub>	Db3	۳	۳۶۸۹۰	۶۱۰۲۳	۰/۷۴	۳۲۹۰۴	۴۷۸۹۰	۰/۹۱
WR15	C <sub>t-1</sub> , T <sub>t-1</sub> , P <sub>t-1</sub>	Db3	۳	۳۶۸۷۲	۵۹۷۵۴	۰/۷۵	۳۲۷۶۲	۴۶۶۱۹	۰/۹۲
WR16	C <sub>t-1</sub> , C <sub>t-2</sub>	Db3	۳	۲۴۵۱۹	۳۵۱۶۵	۰/۹۱	۱۷۳۹۷	۲۴۶۱۱	۰/۹۷
WR17	C <sub>t-1</sub> , T <sub>t-1</sub> , C <sub>t-2</sub> , T <sub>t-2</sub>	Db3	۳	۲۴۴۲۳	۳۴۵۸۲	۰/۹۱	۱۷۳۴۷	۲۴۲۵۴	۰/۹۷
WR18	C <sub>t-1</sub> , T <sub>t-1</sub> , P <sub>t-1</sub> , C <sub>t-2</sub> , T <sub>t-2</sub> , P <sub>t-2</sub>	Db3	۳	۲۳۹۰۸	۳۴۱۵۱	۰/۹۲	۱۶۷۸۸	۲۳۴۸۶	۰/۹۷



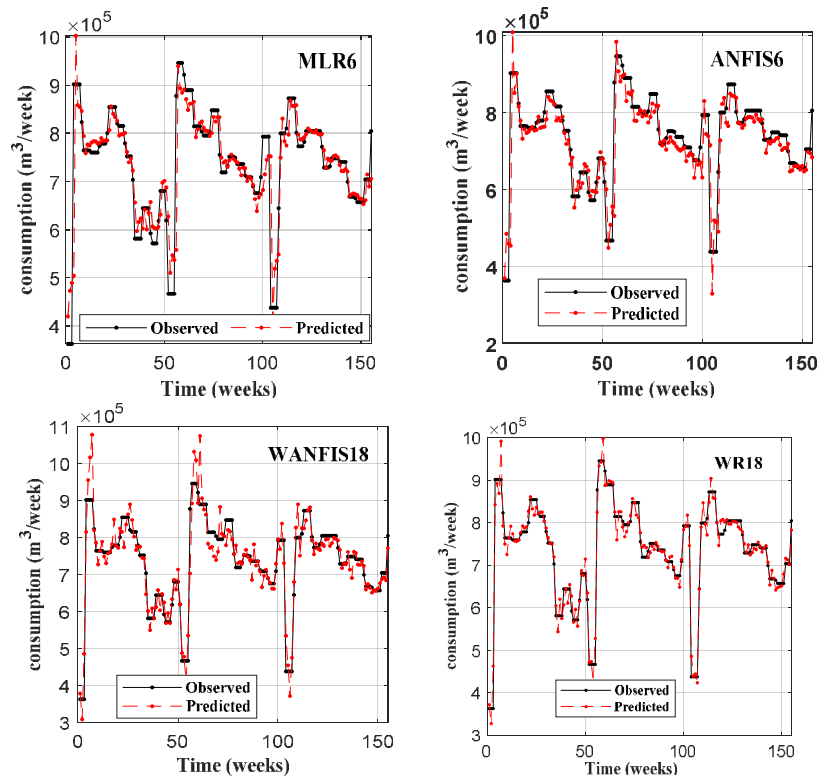
شکل ۸- نمودار پراکنش بهترین مدل‌ها در طول دوره آموزش

جدول ۵- مقادیر شاخص‌های آماری مدل نروفازی پایه موجکی

شبیه‌سازی			آموزش			سطح تجزیه	نوع موجک	ورودی	مدل
MAE (m³)	RMSE (m³)	R²	MAE (m³)	RMSE (m³)	R²				
۳۲۷۷۳	۶۴۴۸۲	۰/۸۴	۳۶۶۶۶	۶۵۴۷۸	۰/۸۴	۳	Db1	C <sub>t-1</sub>	WANFIS1
۳۷۰۹۰	۶۲۳۹۹	۰/۸۵	۳۶۸۸۱	۵۸۳۵۳	۰/۷۷	۳	Db1	C <sub>t-1</sub> , T <sub>t-1</sub>	WANFIS2
۴۴۳۳۸	۶۸۱۹۵	۰/۸۲	۳۵۶۴۰	۵۶۷۱۶	۰/۷۸	۳	Db1	C <sub>t-1</sub> , T <sub>t-1</sub> , P <sub>t-1</sub>	WANFIS3
۲۷۴۵۳	۵۶۱۲۲	۰/۸۷	۲۹۷۶۰	۵۲۴۰۱	۰/۸۱	۳	Db1	C <sub>t-1</sub> , C <sub>t-2</sub>	WANFIS4
۳۶۴۰۶	۵۸۷۴۱	۰/۸۶	۲۸۱۹۹	۴۴۴۳۵	۰/۸۶	۳	Db1	C <sub>t-1</sub> , T <sub>t-1</sub> , C <sub>t-2</sub> , T <sub>t-2</sub>	WANFIS5
۴۰۳۰۳	۶۳۸۱۸	۰/۸۳	۲۵۳۸۲	۴۱۶۸۶	۰/۸۸	۳	Db1	C <sub>t-1</sub> , T <sub>t-1</sub> , P <sub>t-1</sub> , C <sub>t-2</sub> , T <sub>t-2</sub> , P <sub>t-2</sub>	WANFIS6
۳۱۵۵۷	۶۸۵۲۰	۰/۸۲	۳۶۹۰۶	۶۵۱۴۳	۰/۷۱	۳	Db2	C <sub>t-1</sub>	WANFIS7
۳۸۵۸۸	۶۸۲۶۶	۰/۸۲	۳۷۱۸۹	۵۹۰۶۷	۰/۷۶	۳	Db2	C <sub>t-1</sub> , T <sub>t-1</sub>	WANFIS8
۴۵۲۷۸	۷۸۹۶۸	۰/۷۵	۳۶۲۰۸	۵۷۰۴۴	۰/۷۸	۳	Db2	C <sub>t-1</sub> , T <sub>t-1</sub> , P <sub>t-1</sub>	WANFIS9
۲۴۴۸۰	۵۳۳۷۶	۰/۸۸	۲۵۵۰۹	۴۲۶۷۶	۰/۸۷	۳	Db2	C <sub>t-1</sub> , C <sub>t-2</sub>	WANFIS10
۳۰۶۴۴	۵۶۹۲۹	۰/۸۷	۲۳۹۳۲	۳۸۷۴۴	۰/۸۹	۳	Db2	C <sub>t-1</sub> , T <sub>t-1</sub> , C <sub>t-2</sub> , T <sub>t-2</sub>	WANFIS11
۲۹۷۲۳	۵۷۵۸۰	۰/۸۷	۲۳۸۴۹	۳۵۱۵۰	۰/۹۱	۳	Db2	C <sub>t-1</sub> , T <sub>t-1</sub> , P <sub>t-1</sub> , C <sub>t-2</sub> , T <sub>t-2</sub> , P <sub>t-2</sub>	WANFIS12
۳۱۱۵۰	۶۴۴۴۰	۰/۸۴	۳۵۸۱۹	۶۲۲۶۴	۰/۷۳	۳	Db3	C <sub>t-1</sub>	WANFIS13
۳۶۹۲۹	۶۹۴۴۸	۰/۸۱	۳۶۴۰۲	۵۸۲۰۵	۰/۷۷	۳	Db3	C <sub>t-1</sub> , T <sub>t-1</sub>	WANFIS14
۳۹۷۰۶	۶۶۰۳۶	۰/۸۳	۳۳۷۶۲	۴۹۶۸۵	۰/۸۳	۳	Db3	C <sub>t-1</sub> , T <sub>t-1</sub> , P <sub>t-1</sub>	WANFIS15
۲۰۳۰۱	۳۲۵۹۸	۰/۹۵	۲۴۴۹۱	۳۴۷۴۳	۰/۹۱	۳	Db3	C <sub>t-1</sub> , C <sub>t-2</sub>	WANFIS16
۲۴۲۹۹	۳۷۸۲۵	۰/۹۴	۲۲۰۰۷	۳۰۶۳۱	۰/۹۴	۳	Db3	C <sub>t-1</sub> , T <sub>t-1</sub> , C <sub>t-2</sub> , T <sub>t-2</sub>	WANFIS17
۲۹۳۰۵	۴۳۶۹۸	۰/۹۲	۲۰۶۷۵	۲۹۱۷۹	۰/۹۴	۳	Db3	C <sub>t-1</sub> , T <sub>t-1</sub> , P <sub>t-1</sub> , C <sub>t-2</sub> , T <sub>t-2</sub> , P <sub>t-2</sub>	WANFIS18



شکل ۹- نمودار مقایسه مقادیر مشاهداتی و پیش‌بینی شده در طول دوره آموزش



شکل ۱۰- نمودار مقایسه مقادیر مشاهداتی و پیش‌بینی شده در طول دوره شبیه‌سازی

WANFIS18 برای پیش‌بینی تقاضای آب شهر کرمان در طول دوره آموزش و شبیه‌سازی نشان داده شده است. مدل WR18 میزان RMSE و MAE در دوره شبیه‌سازی را نسبت به مدل MLR6 به ترتیب به مقدار ۶۲٪ و ۴۹٪ بهبود بخشید. همچنین مدل WANFIS18 میزان RMSE و MAE در دوره شبیه‌سازی را نسبت به مدل ANFIS6 به ترتیب به مقدار ۳۴٪ و ۲۳٪ بهبود بخشید.

معادلات (۸) تا (۱۱)، معادلات مربوط به هر یک از مدل‌های برتر به ترتیب MLR6، WR18، ANFIS6 و WANFIS18 با استفاده از موجک دوبچیز نوع سوم، برای پیش‌بینی مصرف آب هفتگی شهر کرمان هستند. در معادله (۱۱)، بیانگر مؤلفه جزئیات و  $a_i$  بیانگر مولفه تقریب در سطح تجزیه  $i$  هستند. در جدول ۶ شاخص‌های آماری مدل‌های برتر MLR6، WR18، ANFIS6 و

$$P_{t-2} / 16.09 P_{t-1} + 1187.0 T_{t-2} - 67.2179 T_{t-1} + 67.807 C_{t-2} - 42.0 C_{t-1} - 12.1 + 168.26 C_t = \quad (8)$$

$$C_t = 288869 - 0.54 d1C_{t-1} - 0.74 d1C_{t-2} - 2.31/8 d1T_{t-1} + 213/34 d1T_{t-2} + 584/91 d1P_{t-1} + 487/87 d1P_{t-2} - 0.82 d2C_{t-2} - 0.61 d3C_{t-1} + 1621 d3T_{t-2} + 1/14 a1C_{t-1} - 2829/6 a1T_{t-1} - 8.0/69 a1T_{t-2} - 161.0/3 a1P_{t-1} - 547/44 a1P_{t-2} + 0.57 a2C_{t-1} - 0.86 a2C_{t-2} - 1192/1 a2T_{t-1} + 4431/8 a2P_{t-1} + 2567/5 a2P_{t-2} + 0.08 a3C_{t-2} + 56.06/8 a3T_{t-1} - 416/31 a3T_{t-2} - 3362/5 a3P_{t-1} - 4758/5 a3P_{t-2} \quad (9)$$

$$C_t = \text{ANFIS}(C_{t-1}, C_{t-2}, T_{t-1}, T_{t-2}, P_{t-1}, P_{t-2}) \quad (10)$$

$$C_t = \text{WANFIS}(d1C_{t-1}, d1C_{t-2}, d1T_{t-1}, d1T_{t-2}, d1P_{t-1}, d1P_{t-2}, a1C_{t-1}, a1C_{t-2}, a1T_{t-1}, a1T_{t-2}, a1P_{t-1}, a1P_{t-2}) \quad (11)$$

جدول ۶- مقایسه مدل‌های برتر برای پیش‌بینی تقاضای آب شهر کرمان در طول دوره آموزش و شبیه‌سازی

MLR6	ANFIS6	WR18	WANFIS18	شاخص عملکرد
دوره آموزش				
0/72	0/73	0/92	0/94	R <sup>2</sup>
64902	62771	34151	29179	RMSE(m <sup>3</sup> )
39528	39223	23908	20675	MAE(m <sup>3</sup> )
دوره شبیه‌سازی				
0/84	0/82	0/97	0/92	R
61772	66666	23486	43698	RMSE(m <sup>3</sup> )
33124	38087	16788	29305	MAE(m <sup>3</sup> )

### نتیجه‌گیری

و مرتبه کمتر دارند. با توجه به شاخص‌های آماری، می‌توان گفت مدل‌های مبتنی بر موجک، مقدار R<sup>2</sup>، RMSE و MAE را به میزان قابل ملاحظه‌ای بهبود می‌بخشند. در نهایت با توجه به نتایج به دست آمده می‌توان گفت که مدل‌های برتر برای پیش‌بینی مصرف آب هفتگی شهر کرمان مدل‌هایی با ورودی‌های مصرف آب، دمای حداکثر و بارش کل یک و دو هفته قبل و سطح تجزیه ۳ داده‌ها با استفاده از انتقال گسسته موجک هستند.

### سپاس‌گزاری

نویسندگان مقاله از شرکت سهامی آب منطقه‌ای کرمان و اداره کل هواشناسی استان کرمان که داده‌های این پژوهش را فراهم کردند، کمال تشکر را دارند.

در این پژوهش، پیش‌بینی مصرف آب هفتگی شهر کرمان توسط چهار مدل ANFIS، MLR، WR و WANFIS مطالعه و بررسی قرار شد. به همین منظور از داده‌های مصرف آب هفتگی، حداکثر دمای هفتگی و بارش کل هفتگی شهر کرمان در یک دوره ۱۲ ساله (۱۳۹۶-۱۳۸۵) و برای شبیه‌سازی نتایج مدل‌ها از داده‌های ۳ سال پایانی (۱۳۹۶-۱۳۹۴) استفاده شد. نتایج نشان داد که مدل‌هایی که در پیش‌پردازش پارامتر ورودی آن‌ها برای تجزیه داده‌ها از انتقال گسسته موجک استفاده شده است، نسبت به داده‌هایی که پارامترهای ورودی آن‌ها به صورت خام مورد استفاده قرار گرفته است، عملکرد بهتری دارند. همچنین مشخص شد که مدل‌های با سطح و مرتبه بالاتر موجک دوبچیز عملکرد بهتری نسبت به مدل‌های با سطح

- Resources Planning and Management. 15(2): 177-181.
11. Bougadis J. Adamowski K. and Diduch R. 2005. Short-term municipal water demand forecasting. Hydrological Processes: An International Journal. 19 (1): 137-148.
  12. 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. 26(12): 3539-3558.
  13. Daubechies I. 1988. Time-frequency localization operators: a geometric phase space approach. IEEE Transactions on Information Theory. 34(4): 605-612.
  14. Firat M. Yurdusev M. A. and Turan M. E. 2009. Evaluation of artificial neural network techniques for municipal water consumption modeling. Water resources management. 23(4): 617-632.
  15. Gharabaghi S. Stahl E. and Bonakdari H. 2019. Integrated nonlinear daily water demand forecast model (case study: City of Guelph, Canada). Journal of Hydrology. 579: 124182.
  16. Grossmann A. and Morlet J. 1984. Decomposition of Hardy functions into square integrable wavelets of constant shape. SIAM journal on mathematical analysis. 15(4): 723-736.
  17. Guo G. and Liu S. 2018. Short-term water demand forecast based on deep neural network. First International WDSA/CCWI Joint Conference Proceedings, Kingston, Ontario, Canada, July 23-25, Vol 1, 7 p.
  18. Haar A. 1910. Zur theorie der orthogonalen funktionensysteme. Mathematische Annalen. 69(3): 331-371.
  19. Han J. G. Ren W. X. and Sun Z. S. 2005. Wavelet packet based damage identification of beam structures. International Journal of Solids and Structures. 42(26): 6610-6627.
  20. Jang J. S. 1993. ANFIS: adaptive-network-based fuzzy inference system. IEEE transactions on systems, man, and cybernetics. 23(3): 665-685.
  21. Mohammed J. R. and Ibrahim H. M. 2012. Hybrid wavelet artificial neural network model for municipal water demand forecasting. ARPN Journal of Engineering and Applied Sciences. 7(8): 1047-1065.
  22. Rajae T. 2011. Wavelet and ANN combination model for prediction of daily suspended sediment load in rivers. Science of the total environment. 409(15): 2917-2927.
  23. Shabri A. 2015. A hybrid model for stream flow forecasting using wavelet and least Squares support vector machines. Journal Teknologi. 73(1): 89-96.
- منابع**
۱. عاقلی کهنه شهری ل. و آرام ع. ۱۳۹۰. ارائه یک مدل ترکیبی برای پیش‌بینی تقاضای روزانه آب شهری. مجله علمی پژوهشی اقتصاد مقداری. ۱۷-۱: (۱)۹.
  ۲. تابش م. و دینی م. ۱۳۸۹. پیش‌بینی تقاضای روزانه آب شهری با استفاده از شبکه عصبی مصنوعی، مطالعه موردی: شهر تهران. مجله آب و فاضلاب. ۹۵-۸۴: (۱)۲۱.
  ۳. روشنگر ک. ضرغامی م. و طرلانی آذر م. ۱۳۹۳. پیش‌بینی مصرف روانه آب شهری با استفاده از ترکیب الگوریتم‌های تکاملی و آنالیز تبدیل موجک، مطالعه موردی: شهر همدان. مجله آب و فاضلاب. ۱۲۰-۱۱۰: (۴)۲۶.
  ۴. کیا م. ۱۳۹۰. منطق فازی در MATLAB. انتشارات کیان رایانه سبز تهران. ۳۰۴ ص.
  ۵. صادقی ح. آخوند علی ع. م. حداد م. و گلابی م. ۱۳۹۴. الگوبندی و پیش‌بینی تقاضای آب شهر اصفهان با روند ضمنی و سری زمانی. فصلنامه آب و خاک. ۲۹: (۲)۲۶۲-۲۵۱.
  6. Adamowski J. and Chan H. F. 2011. A wavelet neural network conjunction model for groundwater level forecasting. Journal of Hydrology. 407(1-4): 28-40.
  7. Adamowski J. and Karapataki C. 2010. Comparison of multivariate regression and artificial neural networks for peak urban water-demand forecasting: evaluation of different ANN learning algorithms. Journal of Hydrologic Engineering. 15(10): 729-743.
  8. Adamowski J. Chan H. F. Prasher S. O. Ozga-Zielinski B. and Sliusarieva A. 2012. Comparison of multiple linear and nonlinear regression, autoregressive integrated moving average, artificial neural network, and wavelet artificial neural network methods for urban water demand forecasting in Montreal, Canada. Water Resources Research. 48(1): 1-14.
  9. Adamowski J. F. 2008. Peak daily water demand forecast modeling using artificial neural networks. Journal of Water Resources Planning and Management. 134 (2): 119-128.
  10. Altunkaynak A. and Nigussie T. A. 2017. Monthly water consumption prediction using season algorithm and wavelet transform-based models. Journal of Water

24. Yu T. C. Zhang T. Q. Mao G. H. and WU X. G. 2004. Study of artificial neural network model for forecasting urban water demand. Journal-Zhejiang University Engineering Science. 38(9): 1156-1161.