



Studying the Effect of Wavelet Transform on the Uncertainty of Artificial Neural Network-Based Models and Extreme Learning Machines for the Prediction of Urban Water Demand

M. Rezaali¹, A. Karimi^{2*}, B. Mohammadnezhad³,
and A. Rasouli⁴

Abstract

Urban water demand prediction has been one of the contemporary concerns of modern urban societies. In this vein, many studies have been carried out comparing the performance of different models. By the introduction of artificial neural networks (ANNs), the discussion about the accuracy improvement of ANNs using wavelet transforms (WTs) was heated up. In many research, the effect of using WTs on the performance and the accuracy of ANNs drew many attentions. However, the effect of using WTs on the uncertainties associated with ANNs has not been investigated. In this study, the performance and the uncertainty of two ANN-based models, i.e., nonlinear autoregressive network with exogenous inputs (NARX) and extreme learning machines (ELM) were studied and the wavelet version of those, i.e., W_NARX and W_ELM were used for the prediction of urban water demand of Mahdie Residential Complex. The results indicated that NARX (regression coefficient (R) of 0.955) is more accurate than ELM (R of 0.787). On the other, the WT version of these models had the R of 0.960 and 0.847, respectively, indicating the outperformance of W_NARX model. The reason for the lower accuracy of ELM could be found in the complexity of the water consumer behavior and the simpler structure of ELM than NARX. Besides, the implementation of WTs had a positive effect on both models, but ELM more. The results of the uncertainty analysis of both models indicated a decrease in uncertainty. However, this was more considerable in W_NARX with the confidence interval of 98.75%.

Keywords: Artificial Neural Networks, Extreme Learning Machines, Wavelet Transform, Uncertainty.

Received: June 25, 2019

Accepted: September 29, 2019

بررسی اثر استفاده از تبدیلات موجک بر روی عدم قطعیت مدل‌های مبتنی بر شبکه عصبی مصنوعی و ماشین یادگیری افراطی در زمینه پیش‌بینی میزان تقاضای آب شرب شهری

مصطفی رضاعلی^۱، عبدالرضا کریمی^{۲*}، بایرامعلی محمدنژاد^۳
و عبدالرضا رسولی کناری^۴

چکیده

پیش‌بینی میزان مصرف آب شرب شهری یکی از دغدغه‌های نوین جوامع شهری معاصر بوده است. در این راستا، تحقیقات زیادی در زمینه مقایسه عملکرد مدل‌های مختلف انجام شده است. با معرفی شبکه عصبی مصنوعی، بحث پیرامون نحوه بهینه‌سازی آن‌ها با استفاده از روش‌های مختلف، بخصوص تبدیلات موجک داغ شد. در اغلب پژوهش‌ها اثر استفاده از تبدیلات موجک بر روی عملکرد و دقت مدل‌های عصبی مورد توجه قرار گرفت، اما تأثیر استفاده از تبدیلات موجک بر عدم قطعیت مدل‌های عصبی مورد بررسی قرار نگرفته است. در این پژوهش عملکرد و عدم قطعیت دو مدل مبتنی بر شبکه عصبی مصنوعی بازگشتی (NARX)، مدل یادگیری ماشینی افراطی (ELM) و نسخه موجکی آن‌ها (W_NARX) و (W_ELM) برای پیش‌بینی میزان مصرف آب شهرک مهدیه قم مورد بررسی قرار گرفت. نتایج نشان داد که مدل NARX (با ضریب رگرسیون ۰/۹۵۵) از دقت بالاتری در مقایسه با ELM (با ضریب رگرسیون ۰/۷۸۷) برخوردار است. از طرفی، نوع موجکی آن‌ها به ترتیب دارای ضریب رگرسیون ۰/۹۶۰ و ۰/۸۴۷ است که نشان‌دهنده برتری مدل W_NARX است. علت عملکرد ضعیف‌تر ELM را می‌توان در پیچیدگی زیاد رفتار مصرف‌کننده آب و ساختار ساده این مدل نسبت به NARX دانست. از طرفی، استفاده از تبدیلات موجک بر بهبود دقت هر دو مدل تأثیر مثبت داشت، اما این تأثیر در مدل ELM بیشتر بود. نتایج تحلیل عدم قطعیت بر روی این دو مدل حاکی از کاهش عدم قطعیت هر دو مدل بود. اما این مهم در مدل W_NARX با بازه اطمینان ۹۸/۷۵٪ بیشتر قابل توجه بود.

کلمات کلیدی: شبکه عصبی مصنوعی، ماشین یادگیری افراطی، تبدیلات موجک، عدم قطعیت.

تاریخ دریافت مقاله: ۹۸/۴/۴

تاریخ پذیرش مقاله: ۹۸/۷/۷

1- M.Sc. Graduate of Civil and Environmental Engineering, Department of Civil Engineering, Qom University of Technology (QUT), Qom, Iran.

2- Assistant Professor, Department of Civil Engineering, Qom University of Technology (QUT), Qom, Iran. Email: karimi@qut.ac.ir

3- Assistant Professor, Department of Civil Engineering, Qom University of Technology (QUT), Qom, Iran.

4- Assistant Professor, Department of Computer Engineering, Qom University of Technology (QUT), Qom, Iran.

*- Corresponding Author

۱- دانش‌آموخته کارشناسی ارشد مهندسی عمران- محیط زیست، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه صنعتی قم، قم، ایران.

۲- استادیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه صنعتی قم، قم، ایران.

۳- استادیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه صنعتی قم، قم، ایران.

۴- استادیار گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه صنعتی قم، قم، ایران.

*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان بهار ۱۳۹۹ امکانپذیر است.

در فلوریدا مورد مطالعه قرار گرفتند. نتایج نشان داد که مدل‌های سری‌زمانی، عملکرد بهتری نسبت به سایر مدل‌ها دارند (Duerr et al., 2018). در تحقیق (Adamowski et al., 2012)، استفاده از تبدیلات موجک به منظور بهبود عملکرد مدل مورد بررسی قرار گرفت و در نهایت به مقایسه آن با سایر مدل‌های مرسوم آماری و مدل‌های مبتنی بر یادگیری ماشینی پرداخته شد. تأخیر مورد استفاده در تمام مدل‌ها با استفاده از روش سعی و خطا، یک روز برآورد شد. داده‌های مورد استفاده به دست‌آمده از شهر مونترال کانادا شامل حداکثر دمای ماکزیمم روزانه، کل بارندگی روزانه و میزان تقاضای آب شرب شهر مونترال است. نتایج نشان داد که استفاده از تبدیلات موجک منجر به بهبود عملکرد مدل شبکه عصبی مصنوعی می‌شود. همچنین نشان داد مدل موجکی-عصبی دارای توانایی بهتری در زمینه پیش‌بینی عملکرد مدل است. (Tajbakhsh et al., 2019). طایفه پژوهشی به بررسی و مقایسه کارایی مدل M5 و ANN با نوع موجکی آن‌ها بمنظور پیش‌بینی میزان بارش- رواناب حوضه آبریز آجی‌چای پرداختند. نتایج نشان داد که برای حوضه نسبتاً آرام آجی‌چای عملکرد مدل ترکیبی پیشنهادی موجک-درخت تصمیم نسبت به مدل خام M5 درختی تا ۶۹ درصد بهبود می‌یابد.

با توجه به پژوهش‌های اشاره شده، هرچند پژوهش‌هایی در رابطه با عدم قطعیت مدل عصبی یادگیری افراطی در زمینه پیش‌بینی میزان تولید نیروی برق- بادی صورت گرفته است (Wan et al., 2014). اما اثر تبدیلات موجک بر روی عدم قطعیت مدل‌های عصبی در زمینه پیش‌بینی تقاضای آب شرب انجام نشده است. همچنین برخی متغیرهای پیشگوی میزان تقاضای آب نظیر ابرناکی، در کمتر پژوهشی مورد بررسی قرار گرفته‌اند (Praskiewicz and Chang, 2009). از طرفی، طبق پژوهش (Quilty and Adamowski, 2018)، نزدیک به ۹۰٪ (۱۹۱/۲۱۰) از مقالات ایندکس شده در اسکوپس در سال‌های ۲۰۰۳ تا ۲۰۱۸ از پژوهش‌های صورت گرفته در زمینه استفاده از تبدیلات موجک در شبکه عصبی مصنوعی، با روشی نادرست که منجر به نشت اطلاعات سری‌زمانی آینده و متعاقباً منجر به اغراق در نتایج واقعی مدل‌ها می‌شود انجام شده است. در این پژوهش دو مدل شبکه عصبی مصنوعی یادگیری افراطی و شبکه عصبی مصنوعی بازگشتی و نوع جفت شده آن‌ها با تبدیلات موجک بمنظور پیش‌بینی کوتاه‌مدت (ساعتی) مورد ارزیابی قرار گرفته تا تأثیر استفاده از تبدیلات موجک بر روی شاخص‌های عملکرد مدل‌ها و بر روی عدم قطعیت‌های آن‌ها بررسی شود.

استفاده از شبکه عصبی مصنوعی در کاربردهای مختلف نظیر پردازش تصویر، پردازش سیگنال، پزشکی، پیش‌بینی شاخص‌های اقتصادی و شناسایی الگو در دهه‌های اخیر مورد توجه بسیاری از پژوهشگران قرار گرفته است (Schalkoff, 1992; Vemuri and Rogers, 1994; Refenes et al., 1994; Gupta et al., 2000). از طرفی، اخیراً ارائه مدل‌های مبتنی بر شبکه عصبی مصنوعی در بین پژوهشگران حوزه‌های مختلف، از جمله منابع آب به دلیل توانایی این دسته از مدل‌ها در تقریب توابع و پیش‌بینی سری‌های زمانی رو به فزونی گذاشته است. با گسترش استفاده از این مدل‌ها، تلفیق مدل‌های عصبی با تبدیلات موجک به عنوان روشی برای بهبود متغیرهای ارزیابی عملکرد آن‌ها مورد استفاده بسیاری از پژوهشگران قرار گرفته است (Rezaali et al., 2018). اما در کمتر پژوهشی اثر استفاده از تبدیلات موجک بر عدم قطعیت مدل‌های مبتنی بر شبکه عصبی مصنوعی مورد مطالعه و بحث قرار گرفته است.

در زمینه پیش‌بینی تقاضای آب، با توجه به کاربرد گسترده آن در مدیریت منابع آب و غیره تحقیقات گسترده‌ای انجام گرفته است. (Adamowski and Karapataki, 2010) طی پژوهشی به مقایسه بین مدل‌های شبکه عصبی مصنوعی پرسپترون چند لایه^۱ و رگرسیون به‌منظور پیش‌بینی پیک مصرف آب شهری پرداختند. در پژوهش مذکور، داده‌های شش ساله پیک مصرف آب شهر نیکوزیا در قبرس مورد مطالعه قرار گرفت. بیست مدل رگرسیونی چندگانه و بیست مدل شبکه عصبی مصنوعی با استفاده از روش‌های یادگیری مختلف از جمله لوبنرگ-مارکوات مورد بررسی قرار گرفت. نتایج نشان داد که مدل شبکه عصبی مصنوعی آموزش دیده با استفاده از الگوریتم لوبنرگ-مارکوات عملکرد بهتری نسبت به سایر مدل‌ها داشته است. همچنین وقوع یا عدم وقوع بارش نسبت به میزان بارندگی برای افزایش دقت مدل‌ها مفیدتر واقع شده است. دامنه استفاده از مدل‌ها در بحث پیش‌بینی تقاضا، محدود به مدل‌های عصبی پرسپترون چندلایه و رگرسیونی نمی‌شود. در این راستا (Ghiassi et al., 2008) طی پژوهشی به مقایسه مدل شبکه عصبی مصنوعی دینامیکی^۲ با شبکه عصبی مصنوعی پیش‌خور^۳ پرداختند. در این پژوهش داده‌های مصرف آب شهر سن‌حوزه در اقیانوس غربی زمانی^۴ مختلف مورد مطالعه قرار گرفته است. نتایج این پژوهش نشان داد که شبکه عصبی مصنوعی دینامیکی از دقت بالاتری نسبت به سایر مدل‌ها برخوردار بود. تنوع استفاده از مدل‌ها در پژوهش ایزاک دوئر در سال ۲۰۱۸ بیشتر مورد توجه قرار گرفته است. در این پژوهش مدل‌های مبتنی بر رگرسیون^۵، مدل‌های گوسی^۶ و یادگیری ماشینی^۷ با داده‌های مصرف آب بندر تمپا

۲- مواد و روش‌ها

شهرک مهدیه قم با جمعیت بالغ بر سه هزار نفر، شهرکی غالباً روحانی‌نشین به حساب می‌آید. اطلاعات میزان تقاضای آب این شهرک که از تاریخ ۲۳ اردیبهشت ۱۳۹۶ لغایت ۳۰ بهمن ۱۳۹۶ به صورت ساعتی (شامل ۹ ماه و ۶ روز کامل یا ۶۷۶۹ ساعت) دریافت شده است، از این جهت مورد استفاده این پژوهش قرار گرفت که شهرک دارای شبکه توزیع آب جدا و زون‌بندی یکپارچه است. شکل ۱ تصویر محدوده تحت مطالعه را نشان می‌دهد.

با توجه به اینکه در اغلب نقاط شهر قم زون‌بندی شبکه احتیاج به اصلاح دارد و اطلاعات فلومترها کامل نیست و یا اصلاً تجهیزات اندازه‌گیری دبی میزان تقاضا موجود نیست، به همین دلیل در این پژوهش منطقه تحت مطالعه به این شهرک محدود شد.

۲-۲- تعیین متغیرهای مؤثر در مصرف آب و انتخاب تأخیرها

یکی از مهم‌ترین مراحل ایجاد مدل‌های عصبی، انتخاب تأخیرهای متغیرهایی است که می‌توانند به‌طور غیرمستقیم توصیف‌کننده رفتار مصرف‌کننده آب شرب شهری باشند.

بطور کلی در این پژوهش دو نوع از شبکه عصبی مصنوعی مورد استفاده قرار گرفته است که شامل شبکه عصبی مصنوعی بازگشتی^۱ و مدل ماشین یادگیری افراطی (ELM)^۲ که تمام آنالیزها روی این دو مدل و نوع موجکی آن‌ها به انجام رسیده است. در زیربخش‌های بعدی سعی شده تا نکات مرتبط با نحوه بکارگیری و جزئیات اجرایی این پژوهش شرح داده شود. لازم به ذکر است که تمام محاسبات این پژوهش در محیط (MATLAB 2018b) انجام شد.

۲-۱- محدوده تحت مطالعه

ایران هم‌اکنون در حال تجربه مشکلات جدی آب است. خشک‌سالی‌های مکرر توأم با برداشت بیش‌ازحد آب‌های سطحی و زیرزمینی از طریق شبکه بزرگی از زیرساخت‌های هیدرولیکی و چاه‌های عمیق، وضعیت آب کشور را به سطح بحرانی رسانده است. از نشانه‌های این وضعیت خشک شدن دریاچه‌ها، رودخانه‌ها و تالاب‌ها، کاهش سطح آب‌های زیرزمینی، فرونشست زمین، تخریب کیفیت آب، فرسایش خاک، بیابان‌زایی و طوفان‌های گردوغبار بیشتر است. یکی از استان‌هایی که در معرض بیشترین خطر خشک‌سالی است، استان قم است.




Fig. 1- Aerial photo of the study area

شکل ۱- تصویر هوایی از شهرک مهدیه قم

Table 1- The result of the performance assessment of the models for the optimization of transfer function

جدول ۱- نتایج ارزیابی عملکرد مدل‌ها بمنظور بهینه‌سازی تابع انتقال

Model	Transfer Function	R Coefficient
NARX	tansig	0.931
	logsig	0.921
W_NARX ¹	tansig	0.942
	logsig	0.937
ELM	tansig	0.722
	logsig	0.742
W_ELM ²	tansig	0.801
	logsig	0.815

1. Wavelet coupled NARX

2. Wavelet coupled ELM

۲-۴- شبکه عصبی مصنوعی سری‌زمانی بازگشتی و ماشین یادگیری افراطی

یکی از انواع شبکه عصبی مصنوعی سری‌زمانی، شبکه عصبی مصنوعی بازگشتی است. طبق مطالعات مختلف این نوع از مدل‌ها نسبت به شبکه عصبی مصنوعی ساده، بدلیل بازگرداندن خروجی تأخیریافته به ورودی مدل، توانایی بالاتری برای یادگیری دینامیک سری‌های زمانی دارند (Gençay and Liu, 1997; Maier and Dandy, 2000). شکل ۲ نمونه‌ای از شبکه عصبی مصنوعی بازگشتی را نشان می‌دهد.

ELM یکی از مشتقات شبکه عصبی مصنوعی پیش‌خور مرسوم^{۱۶} است که نسبت به آن سرعت یادگیری بسیار بیشتری دارد. اختلاف سرعت یادگیری در شبکه عصبی مصنوعی پیش‌خور با الگوریتم پس‌انتشار خطا در مقایسه با ELM بدلیل یادگیری برپایه ضرب ماتریسی شبه‌معکوس مور-پنروس تابع انتقال (به‌عنوان وزن لایه خروجی) در داده‌های آموزش است (Huang et al., 2006). یکی از تفاوت‌های عمده ELM با سایر انواع شبکه عصبی مصنوعی وجود تنها یک لایه پنهان است. به‌منظور تعیین توپولوژی مدل‌های عصبی بکاررفته از روش آزمون و خطا استفاده شد. بدین منظور تعداد نورون‌ها، تعداد لایه‌ها و نحوه اتصال لایه‌ها باتوجه به افزایش یا کاهش دقت مدل‌ها با استفاده از این روش مشخص شد. برای قضاوت بهتر در رابطه با شاخص‌های ارزیابی عملکرد مدل‌ها و در نتیجه کمک به یافتن بهتری توپولوژی مدل‌ها، در تمام مدل‌ها از Seedهای یکسان به‌منظور شروع تخصیص ضرایب تصادفی استفاده شد.

روش آزمون همبستگی متقابل^{۱۷} جزء یکی از متداول‌ترین روش‌های ارزیابی تأخیرها در متغیرهای پیشگو^{۱۱} است که در بسیاری از مطالعات مورد استفاده قرار گرفته است (Joo et al., 2002; Herrera et al., 2010; Adamowski and Karapataki, 2010; Babel and Shinde, 2011). لازم به ذکر است که متغیرهای هیدرولیکی نظیر فشار متوسط آب به‌صورت سری‌زمانی می‌توانند در بهبود نتایج عملکرد مدل‌ها مؤثر باشد، اما در این پژوهش بدلیل نقص قابل‌توجه داده‌ها و عدم وجود سنجش‌گر کافی به‌منظور کالیبره کردن مدل هیدرولیکی، از متغیرهای پیشگوی هیدرولیکی استفاده نشد. بطور کلی در این پژوهش دو نوع متغیر با روش همبستگی متقابل مورد بررسی قرار گرفت که شامل متغیرهای جوی و متغیر اجتماعی یا ایام تعطیل است. در این میان، متغیرهای جوی شامل دما، سرعت باد و ابرناکی است که براساس پژوهش‌های پیشین و آزمون آماری همبستگی انتخاب شدند. یکی از تفاوت‌های مهم مدل‌های سری‌زمانی با مدل‌های بکاررفته به‌منظور تقریب توابع، وجود تأخیرها در ورودی داده‌های مدل‌های سری‌زمانی است. دلیل استفاده از تأخیرها در مدل‌های سری‌زمانی ماهیت داده‌های ورودی است که در مورد پیش‌بینی تقاضای آب، ماهیت غالباً خودهمبسته^{۱۲} دارند. این تأخیرها در ورودی داده‌ها حالتی شبیه به حافظه را برای مدل ایجاد می‌کند تا با در نظر گرفتن مقادیر قبلی آن ورودی، تخمین بهتری از آینده کمیت هدف بزند. به‌منظور انتخاب تأخیرهای مناسب از همبستگی متقابل استفاده شد تا میزان تأخیر با توجه به میزان تقاضای ساعتی آب مشخص شود. لازم به ذکر است که این روش یکی از روش‌های مرسوم برای انتخاب تأخیرها در تحقیقات مختلف است (Campisi-Pinto et al., 2012; Duerr et al., 2018; Zhou et al., 2000). همچنین به‌منظور برآورد تأخیرهای میزان تقاضای آب، از تابع خودهمبستگی^{۱۳} استفاده شد.

۲-۳- پیش‌پردازش و پس‌پردازش داده‌های ورودی و خروجی مدل‌ها

داده‌های مورد استفاده در این پژوهش قبل از آموزش مدل‌ها، باتوجه به نوع تابع فعال‌ساز مورد استفاده، نرمال شد (Basheer and Hajmeer, 2000). بطوری که برای توابع فعال‌ساز tansig^{۱۴} از بازه ۱- تا ۱+ استفاده شده و برای تابع فعال‌ساز logsig^{۱۵} از بازه نرمال‌سازی ۰ تا ۱+ بوسیله سعی و خطا (با seedهای یکسان تولید اعداد تصادفی) و از بین این دو توابع انتقال بدلیل کاربرد متعدد در سایر پژوهش‌ها استفاده شد. در نهایت برای مدل NARX و ELM و نسخه موجکی آن‌ها به‌ترتیب از توابع انتقال tansig و logsig استفاده شد. همچنین به‌منظور تبدیل داده‌های خروجی مدل‌ها به حالت اصلی، تمام تنظیمات نرمال‌سازی برای خروجی مدل‌ها ذخیره شد.

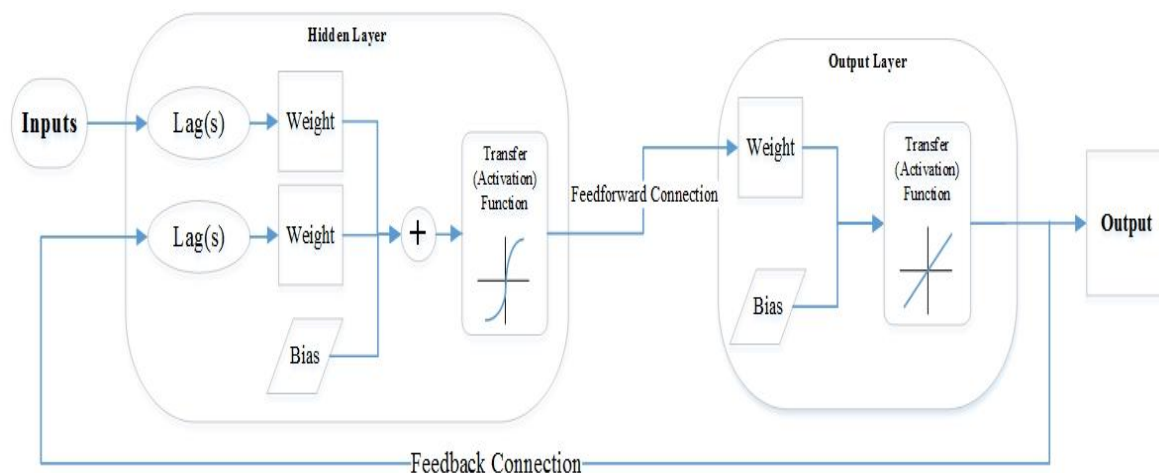


Fig. 2- Topology of a recurrent neural network
 شکل ۲- نحوه اتصال یک شبکه عصبی مصنوعی بازگشتی

۲-۶- تبدیلات موجک

بطور کلی، موجک‌ها دسته‌ای از توابع ریاضی هستند که داده‌های سری زمانی را به دو دسته کلی شامل جزئیات^{۱۷} و تخمینات^{۱۸} تقسیم می‌کنند (Alexandridis and Zapranis, 2013). این دسته از توابع کاربردهای مختلفی نظیر تحلیل سیگنال (Daubechies, 1990)، فشرده‌سازی داده‌ها (Santoso et al., 1997)، پردازش تصویر (Pittner and Kamarthi, 1992)، شناسایی الگو (Antonini et al., 1999) و ردیابی هواپیماها و زیردریایی‌ها (Sifuzzaman et al., 2009) را دارند. در این پژوهش هدف از بکارگیری تبدیلات موجک، افزایش دقت مدل‌های عصبی است. یکی از مهم‌ترین نکات استفاده از تبدیلات موجک، انتخاب نوع تابع تحلیل موجک با توجه به هدف مطالعه است. در زمینه پیش‌بینی سری‌های زمانی مانند پیش‌بینی میزان تقاضای آب این مهم حتماً باید مورد توجه قرار گیرد، چرا که برخی از توابع تحلیل موجک ردی از داده‌های آینده را در اختیار مدل‌های عصبی قرار می‌دهند که این امر موجب افزایش غیرواقعی دقت مدل می‌شود (Quilty and Adamowski, 2018). در این راستا، طبق پژوهش (Quilty and Adamowski, 2018)، توصیه شده که دو نوع مشخص از تبدیلات موجک مشکل افشای آینده را در سری‌های زمانی ندارند. این توابع شامل تبدیل موجک MODWT^{۱۹} و \hat{A} trous است. در این پژوهش باتوجه به کاربرد و هدف مطالعه، از تبدیلات موجک MODWT استفاده شده است.

تابع تبدیل MODWT بکاررفته در پژوهش کنونی، بصورت فرمول‌های ۳، ۴ و ۵ توصیف می‌شود که به ترتیب توصیف کننده

به روش مشابه، برای تعیین توابع فعال‌ساز در هر لایه و با توجه به نکات ذکر شده در قسمت ۲-۳، ترکیب انواع توابع فعال‌ساز در لایه خروجی و لایه پنهان مورد ارزیابی قرار گرفت. نتایج نشان داد که ترکیب توابع فعال‌ساز sigmoid و purelin بیشترین دقت را در بین سایر توابع برای مدل‌های عصبی دارند. همچنین برای تقسیم‌بندی داده‌های ورودی، ۷۰، ۱۵ و ۱۵ درصد داده‌های شبکه عصبی مصنوعی بازگشتی به ترتیب برای آموزش، اعتبارسنجی و تست تقسیم‌بندی شد. همچنین برای مدل ELM داده‌ها به دو بخش کلی بصورت ۸۰ و ۲۰ درصد برای آموزش و تست تقسیم‌بندی شد.

۲-۵- توابع خطای بکار رفته

یکی از مهم‌ترین قسمت‌های ارزیابی عملکرد مدل‌ها، انتخاب نوع توابع خطا است. در اکثر پژوهش‌ها، میانگین مربعات خطا (MSE) به عنوان شاخص ارزیابی عملکرد مدل‌ها انتخاب شده است (Adamowski and Karapataki, 2010; Adamowski et al., 2012; Adamowski, 2008; Duerr et al., 2018; Lin et al., 1996). در این پژوهش علاوه بر MSE (فرمول ۱)، ریشه میانگین مربعات خطا (فرمول ۲) و ضریب رگرسیون (R) به منظور ارزیابی عملکرد مدل‌ها انتخاب شد.

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

$$MSE = \frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2 \quad (2)$$

که در آن‌ها O_i مقدار مشاهداتی i ام، P_i خروجی i ام مدل و n تعداد داده‌ها است.

واشکافی و طول فیلتر بکاررفته L را نشان می‌دهد. با توجه به این فرمول و مطالب ذکر شده، در این تحقیق از موجک $db4$ در سطح واشکافی ۳ استفاده شد که با توجه به فرمول، این موجک ۵۰ رکورد از داده‌های ورودی را تحت تأثیر قرار می‌دهد. لازم به ذکر است که فیلتر $db4$ عضو (طول فیلتر) دارد که در سطح واشکافی ۳، $(1 + (7 \times 7))$ معادل ۵۰ عضو از داده‌های سری زمانی تحت مطالعه را تحت تأثیر قرار می‌دهد. شکل ۳ شمای کلی فرایند تجزیه داده‌های میزان تقاضای آب شهرک مهدیه را بوسیله تبدیلات موجک نشان می‌دهد.

۲-۷- روش مونت کارلو و آنالیز عدم قطعیت

در این پژوهش، به منظور بررسی اثر استفاده از تبدیلات موجک بر روی عدم قطعیت مدل‌های مبتنی بر شبکه عصبی مصنوعی، از آنالیز عدم قطعیت به روش مونت کارلو استفاده شد. بدین منظور، توزیع داده‌های توصیفی ابتدا با توجه به آزمون کلمگوروف-اسمیرنف^{۲۲} (K-S) مشخص شد. در این راستا انواع توابع توزیع احتمالات به داده‌های توصیفی فیت شد تا مشخص شود کدام توابع بهتر به توزیع داده‌ها فیت می‌شوند. در نهایت تمام توابع ذکر شده به صورت Object Workspace ذخیره شد تا برای مرحله بعد مورد استفاده قرار گیرند. سپس در بازه حداقل و حداکثر داده‌های توصیفی با استفاده از روش مونت کارلو ۵۰۰ بلوک ۶۷۶۹ عضوی معادل کل دوره مدل‌سازی از داده‌های ورودی با استفاده از توابع فیت شده ذخیره شده، داده‌های تصادفی ایجاد شد. لازم به ذکر است که الگوریتم بکاررفته برای ساخت داده‌های شبه تصادفی^{۲۳} Mersenne Twister بود.

ضرایب موجک، ضرایب مقیاس واشکافی و ضرایب بازسازنده موجک هستند (Quilty and Adamowski, 2018):

$$\tilde{W}_{j,t} = \sum_{l=0}^{L-1} \tilde{h}_l \tilde{V}_{j-1,t-2^{j-1} \bmod N} \quad (3)$$

$$\tilde{V}_{j,t} = \sum_{l=0}^{L-1} \tilde{g}_l \tilde{V}_{j-1,t-2^{j-1} \bmod N} \quad (4)$$

$$\tilde{V}_{j-1,t} = \sum_{l=0}^{L-1} \tilde{h}_l \tilde{V}_{j-1,t+2^{j-1} \bmod N} + \sum_{l=0}^{L-1} \tilde{g}_l \tilde{V}_{j-1,t+2^{j-1} \bmod N} \quad (5)$$

در فرمول‌های ۳، ۴ و ۵، $\tilde{W}_{j,t}(\tilde{V}_{j,t})$ ضرایب مقیاس واشکافی زام در زمان t ، $h(g)$ فیلتر بکاررفته، N تعداد نمونه‌ها، \bmod عملگر مدولی و L طول فیلتر موجک است. در تبدیلات موجک فیلتر نحوه واشکافی (decomposition) را توصیف می‌کند (مانند منقطع یا پیوسته) و سطح واشکافی، تجزیه یک سیگنال را به دو سیگنال تجزیه شده تخمینات و جزییات در سطوح مختلف تعیین می‌کند و مقیاس، میزان تورم یا فشردگی سیگنال تجزیه شده را نشان می‌دهد.

از طرفی سطح، مقیاس واشکافی و نوع فیلتر بکاررفته تبدیلات موجک هم باید با توجه به شرایط مرزی اصلاح شده^{۲۰} در نظر گرفته شود (Bašta, 2014; Maslova et al., 2016; Percival, 2008; Quilty and Adamowski, 2018). فرمول ۶ نحوه اصلاح شرایط مرزی را توضیح می‌دهد.

$$L_j = (2^j - 1) \times (L - 1) + 1 \quad (6)$$

در این فرمول، L_j تعداد داده‌های تحت اثر شرایط مرزی در سطح

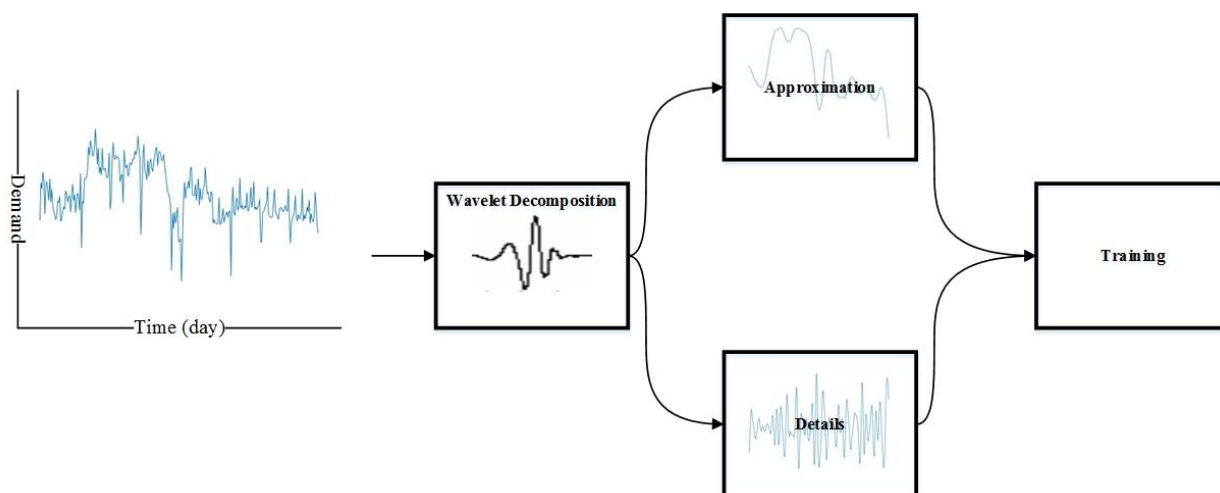


Fig. 3- Schematic of water demand signal decomposition of Mahdie Residential Complex using a db filter and MODWT wavelet transform function

شکل ۳- شمای کلی نحوه تجزیه سیگنال میزان تقاضای آب شهرک مهدیه با استفاده از فیلتر db و تابع تبدیل موجک MODWT

داده‌های ساخته شده توسط روش مونت کارلو به تمام مدل‌های آموزش دیده به عنوان ورودی مدل وارد شد تا برای هر ساعت از کل دوره مدل سازی ۵۰۰ خروجی بوجود آید. سپس به ازای هر ساعت، صدک‌های ۱۲/۵ام و ۹۷/۵ام (فاصله اطمینان ۲۴٪/۹۵) استخراج شد و با مقدار مشاهداتی میزان تقاضای آب مطابقت داده شد تا مشخص شود در هر گام زمانی مقدار تقاضای مشاهداتی کدام یک در بازه اطمینان ۹۵ درصدی قرار دارد.

۳- نتایج و بحث

۳-۱- پیش پردازش داده‌های توصیفی

مطالعات نشان داده، استفاده از داده‌های پیوسته‌ای که همبستگی آماری با میزان تقاضا ندارد، می‌تواند منجر به کاهش دقت مدل شود (Galelli and Castelletti, 2013). این دسته از داده‌های توصیفی اغلب برای مدل به عنوان نویز شناخته می‌شود، بطوری که در نهایت در فرآیند تعیین وزن لایه‌های شبکه عصبی مصنوعی اختلال ایجاد می‌کند. در این راستا، برای ارزیابی اثر استفاده از داده‌های توصیفی بر عملکرد مدل، از آزمون همبستگی اسپیرمن استفاده شد. شکل ۴ نقشه حرارتی میزان همبستگی و سطح معناداری آماری متغیرهای غیر باینری را نشان می‌دهد. باتوجه به این شکل، می‌توان گفت تمام متغیرهای توصیفی دارای همبستگی کافی به منظور استفاده به عنوان داده‌های ورودی به مدل هستند.

لازم به ذکر است که در این آزمون از داده‌های توصیفی ایام تعطیل یا غیر تعطیل بدلیل ماهیت دودویی یا باینری آن‌ها استفاده نشد. بمنظور ارزیابی این متغیر (ایام تعطیل)، از روش ذکر شده در بخش ۲-۲ استفاده شد. بطوری که دو شبکه عصبی با seedهای یکسان با یا بدون وجود این متغیر آموزش داده شد. سپس بهبود یا عدم بهبود دقت مدل‌ها در این فرآیند مورد بررسی قرار گرفت. نتایج نشان داد که استفاده از این متغیر منجر به کاهش خطای مدل عصبی در بخش آموزش و تست می‌شود.

برای تعیین میزان تأخیر، داده‌های توصیفی جوی شامل دما، ابرناکی و سرعت باد، همچنین ایام تعطیل در بازه زمانی مطالعه با محاسبه cross-correlation برای برآورد حد تأخیرهای مناسب ارزیابی شد. برای استفاده از این تأخیرها، حداکثر مقدار همبستگی به عنوان مقیاسی برای لحاظ یا عدم لحاظ تأخیرهای مربوطه در نظر گرفته شد. شکل ۵ خروجی این روش را تا تأخیر ۱۴ ساعت از داده‌های توصیفی جوی و غیرجوی نشان می‌دهد.

با توجه به این شکل، برای پارامترهای پوشش ابر و سرعت باد تأخیر صفر، برای ایام تعطیل تأخیر ۱ تا ۱۴ ساعت و برای دما تأخیر ۱ تا ۴ ساعته در نظر گرفته شد. همچنین با استفاده از نتایج تابع خودهمبستگی، حداکثر همبستگی بین تأخیرهای مختلف میزان تقاضای آب، به صورت ۲۴ ساعت برآورد شد که در مدل‌ها به صورت ۱ تا ۲۴ ساعت وارد شد.

۳-۲- ارزیابی عملکرد مدل‌ها

در مجموع چهار مدل شبکه عصبی مصنوعی بازگشتی- موجکی، ماشین یادگیری افراطی- موجکی و نسخه ساده آن‌ها برای ۳۰ مرتبه به اجرا گذاشته شد، تا باتوجه به خروجی توابع خطا و ضریب رگرسیون بهترین هر مدل از هر نوع انتخاب شود. جدول ۲ نتایج خروجی توابع مدل‌های منتخب را نشان می‌دهد. شکل ۶ نیز مقایسه عملکرد مدل ELM را با مدل W_ELM ارائه می‌دهد.

باتوجه به جدول ۲ می‌توان مدل شبکه عصبی مصنوعی بازگشتی- موجکی را به عنوان بهترین مدل در میان مدل‌های ذکر شده در این جدول دانست. از طرفی بنظر می‌رسد تبدیلات موجک در مدل ELM مفیدتر از NARX واقع شده است، هرچند که اختلاف دقت میان این دو مدل قابل توجه است. البته باید توجه داشت که مدت زمان فرآیند یادگیری در مدل ELM بسیار کمتر از مدل‌های پیچیده‌تر نظیر NARX است که این خود بسته به کاربرد می‌تواند یک مزیت محسوب شود. از طرفی، باید توجه داشت که مدل‌های ELM ساختار تک لایه و آموزش یک مرتبه‌ای دارند در حالی که مدل‌های NARX در هر دوره (Epoch) مقادیر وزن‌های لایه پنهان را بروزرسانی و اصلاح می‌کنند. در هر صورت می‌توان نتیجه گرفت که استفاده از تبدیلات موجک تأثیر قابل توجهی، مخصوصاً در مدل ELM، گذاشته است که توجیه کننده دلیل محبوبیت این روش در زمینه بهینه سازی شبکه عصبی مصنوعی است.

۳-۳- تحلیل عدم قطعیت

بمنظور تعیین نحوه توزیع احتمالاتی داده‌های روش مونت کارلو، با استفاده از آزمون کلموگروف- اسمیرنوف (K-S) داده‌های ورودی نظیر دما، سرعت باد و پوشش ابر به تمام توابع چگالی احتمالاتی (PDF^{۲۵}) Continuous فیت شد. همچنین برای داده‌های ایام تعطیل توابعی با توزیع Discrete در نظر گرفته شد. شکل ۷ مجموعه توابع فیت شده به PDF را برای داده‌های ورودی نشان می‌دهد.

صدک‌های ۱۲/۵ ام و ۹۷/۵ ام داده‌های خروجی از مدل‌ها محاسبه شد. سپس تعداد داده‌های مشاهداتی که در بازه صدک‌ها قرار داشتند محاسبه شد و درصد آن‌ها نسبت به کل داده‌های مشاهداتی بدست آمد. نتایج نشان داد که خروجی مدل‌های W_ELM، W_NARX و NARX به ترتیب در بازه ۹۵٪ عدم قطعیت ۹۸/۷۵٪، ۱/۸۳٪، ۷۹/۴۵٪ و ۲/۷۱٪ می‌باشند.

همانطور که در این شکل مشخص است، توابع فیت شده به PDF داده‌های سرعت باد، پوشش ابر و دما از نوع غیرپارامتریک^{۲۶} و به ترتیب با هسته نرمال، مثلثی و نرمال هستند. همچنین تابع فیت شده به PDF ایام تعطیل از نوع گسسته Binomial است.

به منظور انجام تحلیل عدم قطعیت برای بازه اطمینان ۹۵٪، ابتدا مقادیر

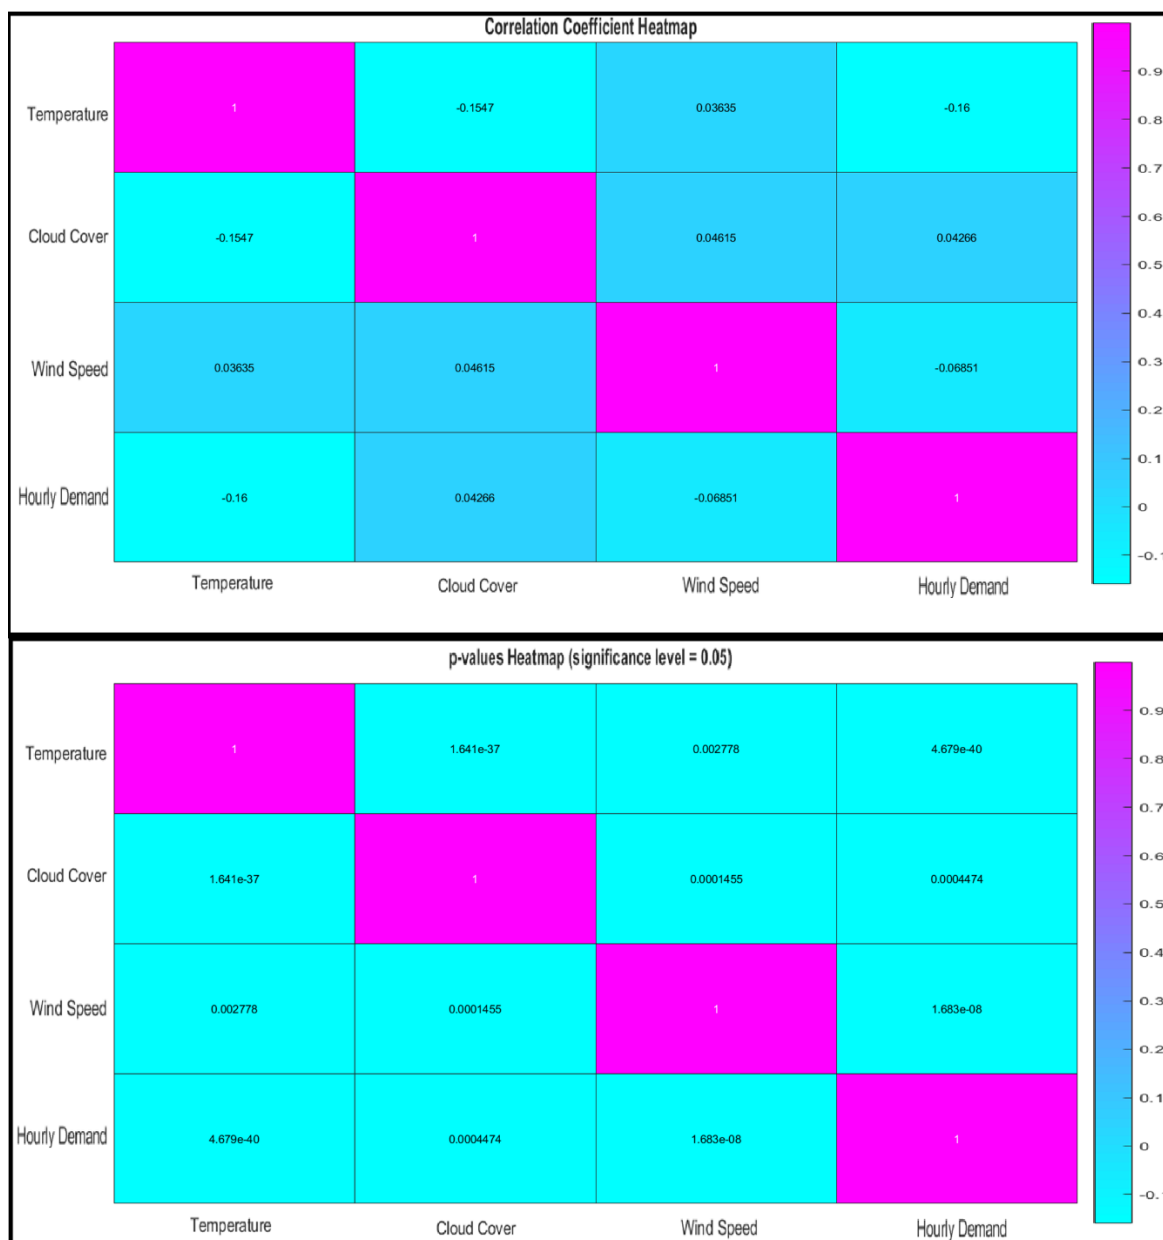


Fig. 4- Spearman's correlation heatmap and the statistical significance of the explanatory variables of hourly water demand of Mahdie Residential Complex

شکل ۴- نقشه حرارتی میزان همبستگی اسپیرمن و معناداری آماری داده‌های توصیفی میزان تقاضای آب ساعتی برای شهرک مهدیه قم

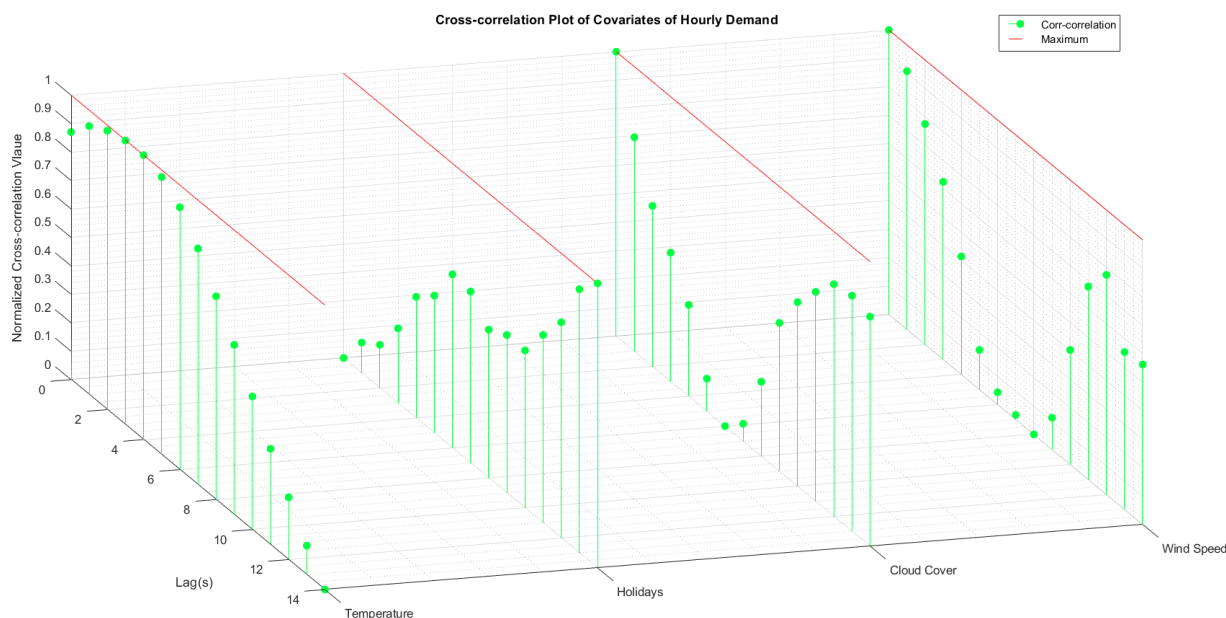


Fig. 5- 14-hour cross-correlation of the explanatory variables of Mahdie Residential Complex

شکل ۵- همبستگی متقابل ۱۴ ساعته از داده‌های توصیفی شهرک مهدیه قم

Table 2- The result of the performance assessment of the models for the prediction of urban water demand of Mahdie Residential Complex

جدول ۲- نتایج ارزیابی عملکرد مدل‌ها برای پیش‌بینی میزان تقاضای آب شهری شهرک مهدیه قم

Net Type	Train error (MSE)	Validation Error (MSE)	Test Error (MSE)	Coefficient of Determination
W_NARX ¹	18.50	20.00	19.30	0.960
W_ELM ²	26.31	No validation error	28.83	0.847
NARX	21.26	19.91	18.98	0.955
ELM	31.31	No validation error	36.06	0.787

1. Wavelet coupled NARX

2. Wavelet coupled ELM

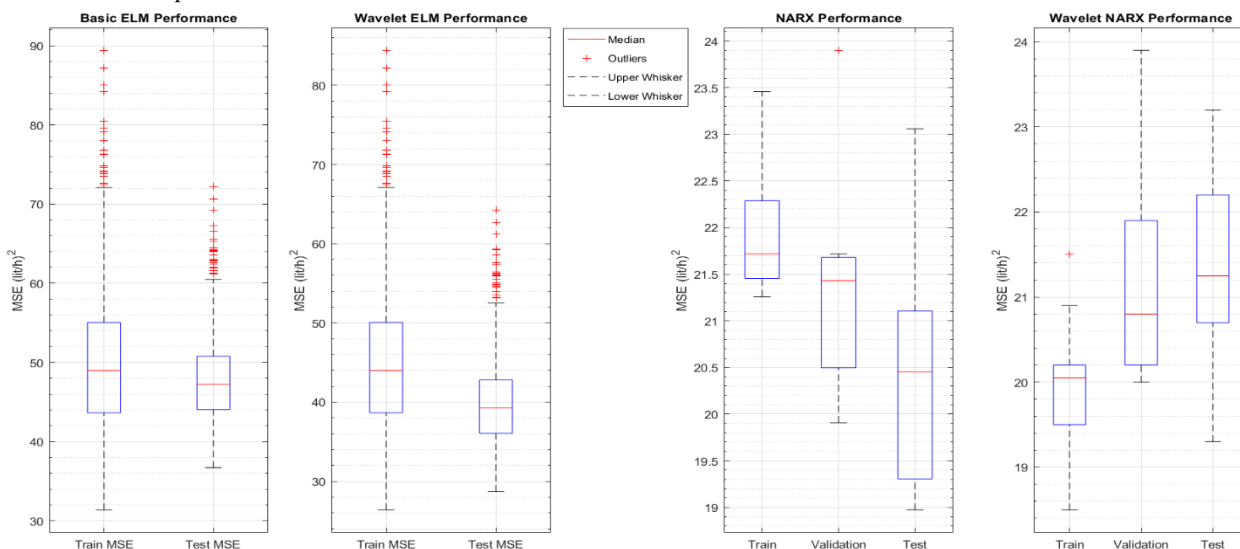


Fig. 6- Performance comparison of ELM, W_ELM, W_NARX and NARX models after 30 runs for finding the best model

شکل ۶- مقایسه عملکرد مدل‌های ELM, W_ELM, NARX و W_NARX بعد از ۳۰ بار اجرا بمنظور انتخاب بهترین مدل

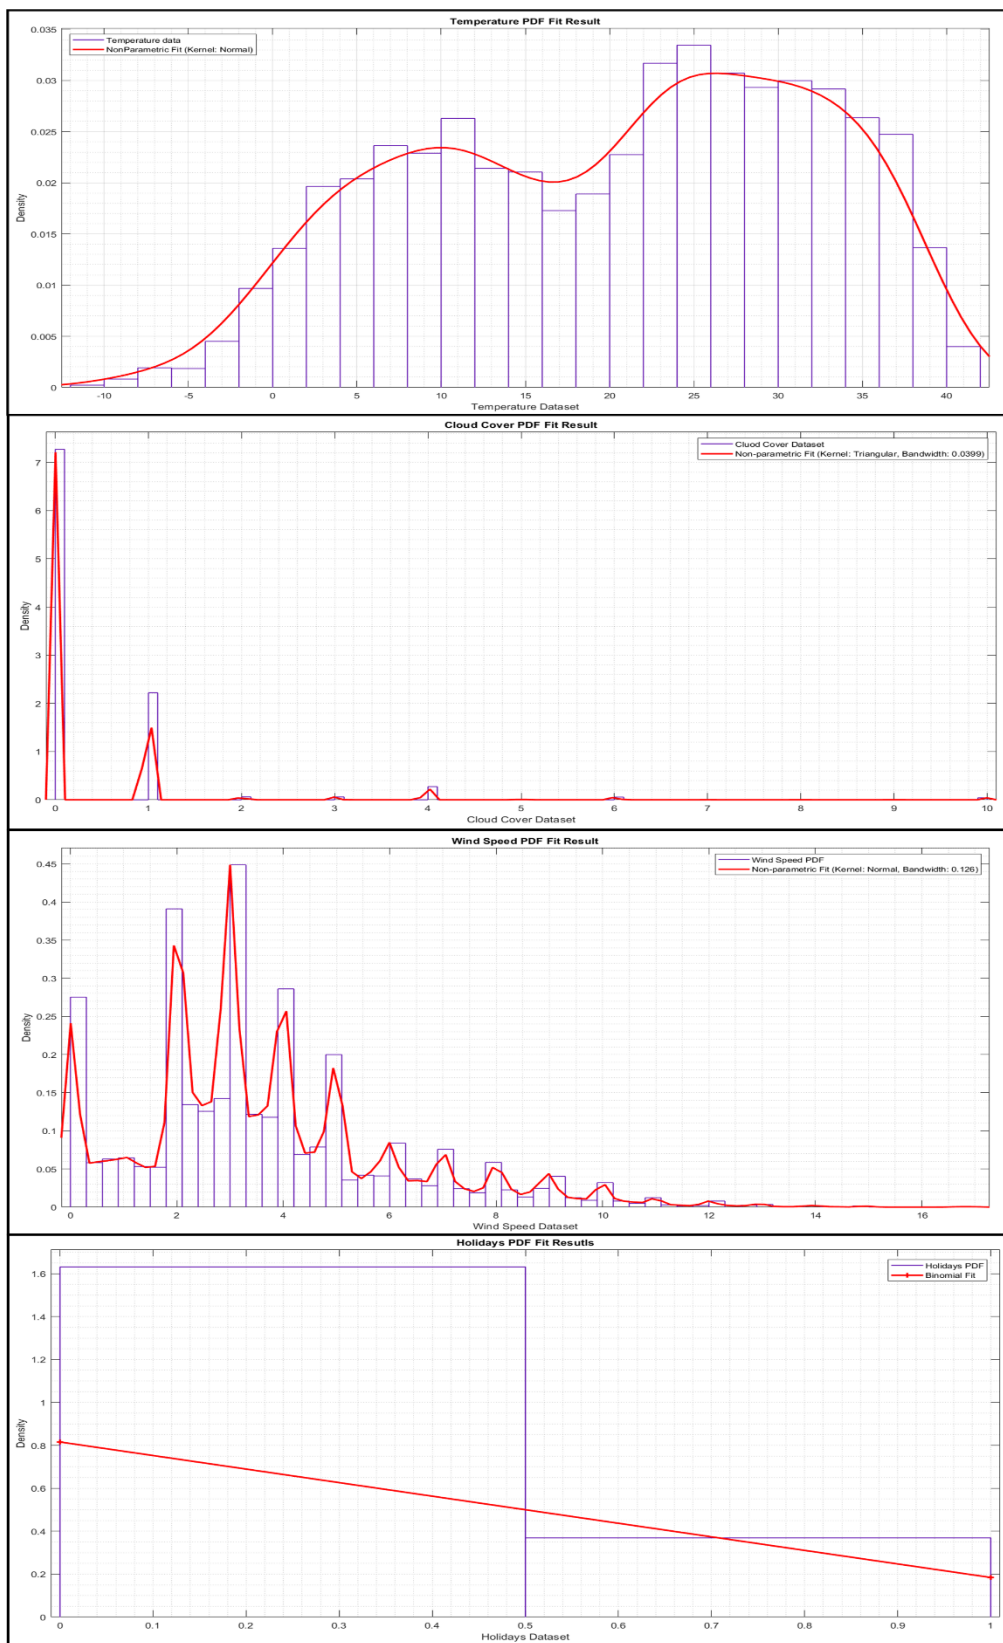


Fig. 7- The fitted probability density functions to the input variables
 شکل ۷- توابع چگالی احتمال فیت شده به داده‌های ورودی به مدل‌ها

باتوجه به این نتایج می‌توان نتیجه گرفت که استفاده از تبدیلات موجک در زمینه عدم قطعیت مدل NARX بیشتر از مدل ELM بوده است. هرچند که تأثیر آن‌ها در عملکرد مدل‌ها متفاوت بود. همچنین همانطور که انتظار می‌رفت مدل ELM که عملکرد بهتری نسبت به NARX در زمینه خطا نداشت، بیشتر دچار عدم قطعیت است، بطوری که حدود ۲۹٪ از داده‌های خروجی آن در صدک ۹۵٪ داده‌های مشاهده‌ای وجود ندارد. از این رو، عملکرد بسیار خوب مدل NARX در مقایسه با مدل ELM می‌تواند توجیه‌کننده پیچیدگی بیشتر این مدل نسبت به ELM باشد.

مدل‌های ELM و NARX نشان داد که استفاده از تبدیلات موجک باعث بهبود قابل توجه عدم قطعیت مدل NARX شد، اما باتوجه به عملکرد ضعیف‌تر مدل ELM، تأثیر آن بر روی مدل ELM به چشم‌گیری مدل NARX نبود.

برای مطالعات آتی پیشنهاد می‌شود از مدل‌های عصبی کوبل شده با روش‌های مرسوم بهینه‌سازی مانند الگوریتم‌های ژنتیک، الگوریتم مورچگان و غیره بمنظور تعیین برخی پارامترهای ورودی مدل استفاده شود و تأثیر آن بر روی عدم قطعیت مدل‌ها بررسی شود.

۴- نتیجه‌گیری

تاکنون بیشتر پژوهش‌ها اثر استفاده از تبدیلات موجک را بر روی عملکرد مدل‌های مبتنی بر شبکه عصبی مصنوعی بررسی کرده‌اند. باتوجه به خلاء پژوهشی نسبت به تأثیر استفاده از تبدیلات موجک بر میزان عدم قطعیت مدل‌های شبکه عصبی مصنوعی دو مدل ELM و NARX با استفاده از تبدیلات موجک آموزش داده شدند و عملکرد آن‌ها مورد ارزیابی قرار گرفت و سپس تأثیر استفاده از تبدیلات موجک بر روی عدم قطعیت آن‌ها بررسی شد. نتایج نشان داد که استفاده از تبدیلات موجک تأثیر قابل توجهی بر روی عملکرد مدل‌ها، مخصوصاً مدل ELM دارد. از طرفی مدل NARX دقت بهتری در مقایسه با ELM داشت که دلیل آن را غالباً می‌توان در پیچیدگی بیشتر و به‌روزرسانی وزن‌ها و بایاس‌ها در هر Epoch فرایند آموزش یافت. با توجه به این نتایج، هر دو مدل بسته به دقت مورد نیاز و کاربرد، می‌توانند به عنوان یک سیستم پشتیبان تصمیم‌گیری برای برآورد تقاضای آب عمل کنند. اما در مواردی که قدرت پردازش کامپیوتری محدود است، مدل ELM می‌تواند جایگزین قابل اتکایی در زمینه پیش‌بینی تقاضای آب باشد. از طرفی، در مواردی که دقت از اهمیت بیشتری برخوردار است و قدرت پردازش چندان محدود نیست، مدل NARX می‌تواند مورد توجه قرار گیرد. همچنین به این نکته نیز باید توجه کرد که استفاده از تبدیلات موجک تعداد داده‌های ورودی را بسته به سطح و مقیاس و اشکافی بیشتر می‌کند که در نهایت استفاده از این روش قدرت پردازش بیشتری را نسبت به حالت معمول می‌طلبد.

البته این نکته نیز حائز اهمیت است که رفتار مصرف‌کننده در هر کشور، شهر یا حتی محله متفاوت می‌باشد که این امر ممکن است عملکرد متفاوتی از مدل‌های مذکور به دنبال داشته باشد. لذا تحلیل عدم قطعیت هر مدل، فارغ از رفتار مصرف‌کننده در هر شهر و کشور می‌تواند جایگزین بهتری نسبت به روش‌های مرسوم ارزیابی عملکرد مدل‌ها باشد. در این راستا، نتایج استفاده از تبدیلات موجک بر عدم قطعیت

۵- تقدیر و تشکر

نویسندگان این تحقیق، سپاس و قدردانی خود را از شرکت آب و فاضلاب استان قم و همچنین سازمان هواشناسی کشوری بابت مساعدت در انجام این پژوهش ابراز می‌دارند.

پی‌نوشت‌ها

1. Multilayer Perceptron
2. Dynamic Artificial Neural Network
3. Feed-Forward Artificial Neural Network
4. Time Horizons
5. Regression-Based Models
6. Gaussian Models
7. Machine Learning
8. Recurrent Neural Networks
9. Extreme Learning Machines (ELM)
10. Cross-Correlation
11. Covariate
12. Autoregressive
13. Autocorrelation Function
14. Tangent-Sigmoidal
15. Logarithmic-Sigmoidal
16. Typical Feedforward Neural Network
17. Details
18. Approximations
19. Maximal Overlap Discrete Wavelet Transform
20. Boundary Corrected
21. Daubechies
22. Kolmogorov-Smirnov
23. Pseudo Random Number
24. Confidence Interval
25. Probability Density Function
26. Non-Parametric

۶- مراجع

Adamowski J, Fung Chan H, Prasher SO, Ozga-Zielinski B and Sliusarieva A (2012) Comparison of multiple linear and nonlinear regression,

- Ghiassi M, Zimbra DK, and Saidane H (2008) Urban water demand forecasting with a dynamic artificial neural network model. *Journal of Water Resources Planning and Management* 134(2):138–146
- Gupta H V, Hsu K, and Sorooshian S (2000) Effective and efficient modeling for streamflow forecasting. *Artificial neural networks in hydrology*. Springer, 7–22
- Herrera M, Torgo L, Izquierdo J, and Pérez-García R (2010) Predictive models for forecasting hourly urban water demand. *Journal of Hydrology* 387(1–2):141–150
- Huang G-B, Zhu Q-Y and Siew C-K (2006) Extreme learning machine: theory and applications. *Neurocomputing* 70(1–3):489–501
- Joo CN, Koo JY and Yu MJ (2002) Application of short-term water demand prediction model to Seoul. *Water Science and Technology* 46(6–7):255–261
- Lin T, Horne BG, Tino P, and Giles CL (1996) Learning long-term dependencies in NARX recurrent neural networks. *IEEE Transactions on Neural Networks* 7(6):1329–1338
- Maier HR and Dandy GC (2000) Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling & Software* 15(1):101–124
- Maslova I, Ticlavlilca AM, and McKee M (2016) Adjusting wavelet-based multiresolution analysis boundary conditions for long-term streamflow forecasting. *Hydrological Processes* 30(1):57–74
- Percival DB (2008) Analysis of geophysical time series using discrete wavelet transforms: an overview. *Nonlinear Time Series Analysis in the Geosciences*. Springer, 61–79
- Pittner S and Kamarthi S V (1999) Feature extraction from wavelet coefficients for pattern recognition tasks. *IEEE Transactions on Pattern Analysis urban water consumption and weather variables in Seoul, Korea*. *Physical Geography* 30(4) and *Machine Intelligence* 21(1):83–88
- Praskievicz S and Chang H (2009) Identifying the relationships between:324–337
- Quilty J and Adamowski J (2018) Addressing the incorrect usage of wavelet-based hydrological and water resources forecasting models for real-world applications with best practices and a new forecasting framework. *Journal of Hydrology* 563:336–353
- Refenes AN, Zapranis A, and Francis G (1994) Stock performance modeling using neural networks: a 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)
- 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
- Adamowski JF (2008) Peak daily water demand forecast modeling using artificial neural networks. *Journal of Water Resources Planning and Management* 134(2):119–128
- Alexandridis AK and Zapranis AD (2013) Wavelet neural networks: A practical guide. *Neural Networks* 42:1–27
- Antonini M, Barlaud M, Mathieu P and Daubechies I (1992) Image coding using wavelet transform. *IEEE Transactions on Image Processing* 1(2):205–220
- Babel MS and Shinde VR (2011) Identifying prominent explanatory variables for water demand prediction using artificial neural networks: a case study of Bangkok. *Water Resources Management* 25(6):1653–1676
- Basheer IA and Hajmeer M (2000) Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods* 43(1):3–31
- Bašta M (2014) Additive decomposition and boundary conditions in wavelet-based forecasting approaches. *Acta Oeconomica Pragensia* 22(2):48–70
- 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
- Daubechies I (1990) The wavelet transform, time-frequency localization and signal analysis. *IEEE Transactions on Information Theory* 36(5):961–1005
- Duerr I, Merrill HR, Wang C, Bai R, Boyer M, Dukes MD and Bliznyuk N (2018) Forecasting urban household water demand with statistical and machine learning methods using large space-time data: A Comparative study. *Environmental Modelling & Software* 102:29–38
- Galelli S and Castelletti A (2013) Tree-based iterative input variable selection for hydrological modeling. *Water Resources Research* 49(7):4295–4310
- Gençay R and Liu T (1997) Nonlinear modelling and prediction with feedforward and recurrent networks. *Physica D: Nonlinear Phenomena* 108(1–2):119–134

- compared to Fourier transform. *Journal of Physical Sciences* 13:121-134
- Tajbakhsh A, Nourani V, Molajou A (2019) Hybrid Wavelet-M5 modeling in rainfall-runoff process forecast. *Iran-Water Resources Research* 15(2):1735-2347 (In Persian)
- Vemuri R V and Rogers RD (1994) *Artificial neural networks: Forecasting time series*. Los Alamitos, Calif. : IEEE Computer Society Press, c1994
- Wan C, Xu Z, Pinson P, Dong ZY, and Wong KP (2014) Probabilistic forecasting of wind power generation using extreme learning machine. *IEEE Transactions on Power Systems* 29(3):1033-1044
- Zhou SL, McMahon TA, Walton A, and Lewis J (2000) Forecasting daily urban water demand: a case study of Melbourne. *Journal of Hydrology* 236(3-4):153-164
- comparative study with regression models. *Neural Networks* 7(2):375-388
- Rezaali M, Karimi A, Mohammadnezhad B, and Rasouli A (2018) Comparison of methods for urban water demand prediction, case study: Mahdie Residential Complex, Qom. Second Conference of Water and Wastewater Engineering. Isfahan University of Technology: Iran Water and Wastewater Organization. Available at: https://www.civilica.com/Paper-NWWCE02-NWWCE02_014.html (In Persian)
- Santoso S, Powers EJ, and Grady WM (1997) Power quality disturbance data compression using wavelet transform methods. *IEEE Transactions on Power Delivery* 12(3):1250-1257
- Schalkoff R (1992) *Pattern recognition: Statistical, structural and neural approaches*. John Wiley & Sons. Inc, New York
- Sifuzzaman M, Islam MR, and Ali MZ (2009) Application of wavelet transform and its advantages