

یک مدل تلفیقی از شبکه‌های عصبی مصنوعی، تبدیل موجک و ARMA در پیش‌بینی تقاضای آب شهری

مهندی ذوالفاری*

دانشجوی دکترای اقتصاد دانشگاه تربیت مدرس

محمد رضامی ناصری

دانشیار- مدیرگروه مهندسی فناوری اطلاعات

دانشکده تربیت مدرس

فاطمه بشارت نیا

دانشجوکارشناسی ارشد مهندسی فناوری اطلاعات،

دانشگاه تربیت مدرس تهران

تاریخ دریافت: ۹۰/۸/۲۹

تاریخ پذیرش: ۹۰/۱۲/۲۰

چکیده

پیش‌بینی تقاضای آب شهری کمک موثری است به مدیران و بهره برداران سیستم‌های آب شهری می‌باشد تا بتوانند نسبت به مدیریت صحیح مصرف اقدام نمایند. در این راستا پیش‌بینی دقیق تقاضا از این نیاز حیاتی در دوره‌های زمانی مختلف حائز اهمیت می‌باشد. در این پژوهش با طراحی یک روش جدید که تلفیقی از مدل‌های خطی و غیرخطی است، به بررسی روند تقاضای روزانه آب شهر تهران و عوامل موثر بر تقاضای روزانه این حامل پرداخته شد. در این تحقیق، تقاضای روزانه آب شهری براساس مدل‌های ARMA، شبکه عصبی مصنوعی و مدل تلفیقی برای ۱۰ روز آینده به صورت "گام به گام" پیش‌بینی گردید. در طراحی شبکه عصبی مصنوعی و مدل تلفیقی، عوامل موثر بر تقاضای روزانه آب شهری، دمای هوا (حداقل، حداکثر و متوسط)، روزهای هفته، ایام تعطیلات و روزهای خاص در نظر گرفته شد. نتایج حاصل از به کارگیری معیارهای ارزیابی دقت پیش‌بینی نشان می‌دهد مدل تلفیقی نسبت به بقیه الگوها

دارای خطای کم و دقت بالایی در پیش‌بینی تقاضای روزانه آب شهری است. پس از مدل تلفیقی، شبکه عصبی مصنوعی و فرآیند ARMA به ترتیب در اولویت‌های بعدی قرار گرفتند.

طبقه‌بندی JEL: C53, C5

کلید واژه‌ها: تقاضای آب، پیش‌بینی، شبکه‌های عصبی مصنوعی، مدل تلفیقی، ARMA

A Combined Model from Artificial Neutral Network , Wavelet Converting , and ARMA in Predicting the Demand for Urban Water

Mehdi Zolfaghari

Ph.D Student in Economics, Tarbiyat Modares University

Mohammad Reaz Amin

Associate Professor, IT Engineering, Tarbiyat Modares University

Fateme Besharat Nia

M.Sc Student in IT Engineering, Tarbiyat Modares University

Abstract

Predicting the demand for urban water helps the managers and users of urban water systems to a great extent in order to manage properly in this regard . To do so , exact predicting of the demand for water is of great importance in different periods .

In this study , by using a method which is combination of linear and non-linear models , daily demand for water in Tehran and the effective factors on daily demand has been studied . Daily demand for urban water is predicted step by step based on ARMA models , Artificial Neutral Network , and the combined model for the next 10 days . To design Artificial Neutral Network and the combined model , the effective factors on daily demand for urban water , temperature (minimum , maximum , and average (medium)) , weekly days , holidays , and the special days are considered .

The results obtained from using criterion for accuracy evaluation show that the combined model has fewer error and high accuracy for this propose and Artificial Neutral Network and ARMA process are in next priorities .

Classifying JEL: C₅, C₅₃

Key words : Water Demand , Predict , Artificial Neutral Network , The Combined Model , ARMA

۱- مقدمه

تخمین تقاضای آب شهری نقشی کلیدی و انکارنایپذیر در مدیریت آب شهری دارد. اهمیت این موضوع، بخصوص برای کشوری نظری ایران با خشکسالی‌های پیاپی و منابع محدود آبی بسیار چشمگیرتر می‌باشد. پیش‌بینی بلند مدت و میان مدت معمولاً به منظور طراحی شبکه آبرسانی و توسعه شبکه استفاده می‌شود. پیش‌بینی کوتاه‌مدت معمولاً بازه‌ای از یک ساعت تا چند روز را شامل می‌شود که در مدیریت و بهره برداری بهینه از شبکه اهمیت به سزایی دارد و در اجرای سیاست‌های طرف تقاضا مانند جیره‌بندی، زمانبندی قطع و وصل پمپ‌ها و شیرآلات، زمانبندی تاسیسات آب و فاضلاب موثر است.

مدیران و بهره برداران سیستم‌های آب شهری برای تامین میزان تقاضا شده از آب، نیازمند کسب اطلاعات و آگاهی از رفتار مصرف کنندگان در این بخش هستند. با توجه به اهمیت راهبردی این مقوله، اطلاعات اکتسابی باید تا حدامکان دقیق و مطابق با واقعیت‌های آینده باشد. این اطلاعات می‌تواند بر اساس روند مشاهدات در دوره‌های زمانی گذشته به دست آید. یکی از مزایای این روش، آگاهی از رفتار و تغییرات رفتاری متقارضیان در دوره‌های زمانی خاص می‌باشد که احتساب این موارد در داده‌های پیش‌بینی شده آتی، مفید است. اما چگونگی لحاظ نمودن این داده‌ها، اهمیت الگوهای پیش‌بینی را نمایان می‌سازد. با توجه به اینکه اکثر مدل‌های پیش‌بینی سری زمانی معروفی شده در مطالعات اقتصادی مانند^۱ ARIMA و^۲ ARMA به صورت خطی هستند، در نظر گرفتن نوسانات سری زمانی در این مدل‌ها با محدودیت‌هایی مواجه است (Sadeghi and Zolfaghari, 2009). از طرف دیگر به موازات پیشرفت‌های قابل توجه در پردازش اطلاعات با روش‌های هوش مصنوعی، به کارگیری الگوهای غیر خطی در حوزه پیش‌بینی، محدودیت‌های مذکور را تا حد قابل توجهی کاسته است. اما الگوهای اخیر نیز در طول دوره زمانی، حالت تکاملی دارند و محدودیت‌های تحمیل شده بر آنها که منتج به خطای پیش‌بینی می‌شود، به تدریج در حال کاهش است. از این رو در راستای این حرکت تکاملی، ارائه روشی جدید، منطقی و با

1- Average Moving Integrated Regressive-Auto

2- Auto-Regressive Moving Average

کارایی بالاتر در پیش‌بینی، می‌تواند این حرکت را به جلو را به سمت حداقل نمودن خطاهای احتمالی در حوزه پیش‌بینی شتاب بخشد.

از این رو ارائه روشی کارآ جهت پیش‌بینی تقاضای آب شهری با توجه به شرایط خاص کشور از اهمیت ویژه‌ای برخوردار است. مهم ترین هدف این تحقیق، ارائه یک چنین الگوی سازگار با شرایط اقلیمی و محیطی کشور و از طرف دیگر، امکان استفاده از این روش در پیش‌بینی سایر متغیرهای سری زمانی است.

در این راستا روش‌های مختلفی جهت پیش‌بینی متغیرهای سری زمانی معرفی شده است. در حالت کلی روش‌های پیش‌بینی را می‌توان به دو دسته خطی و غیر خطی تقسیم بنده نمود. با این حال پرکاربردترین روش‌های پیش‌بینی خطی، روش‌های فرآیند خطی ARMA و ARIMA است (Ahmadi et al., 2009).

یکی از الگوهای غیر خطی که توانایی بالقوه خوبی برای پیش‌بینی سری‌های زمانی از خود نشان داده، شبکه‌های عصبی مصنوعی^۱ (ANN) می‌باشد. شبکه‌های عصبی تکنیک‌هایی هستند که به تقلید سیستم عصبی بیولوژیکی انسان می‌پردازنند.

از طرف دیگر، اخیراً علاقه مجددی به گسترش‌های خطی علامت‌ها به ویژه استفاده از موجک‌ها^۲ و تعمیمات آنها پدیدار گردیده است (Abbasinjad, et al., 2006). تئوری موجک یک ابزار ریاضی برای تجزیه علامت‌ها و نیز تکنیکی مفیدی را برای نمایش آنها در سطوح مختلف ارائه می‌دهد لیانق و پیک^۳ (۱۹۹۷) نشان داده‌اند که چند نمایشی علامت‌ها، قدرت تعمیم دهی و توانایی شبکه عصبی در پیش‌بینی را تقویت می‌کند.

در این مقاله در بخش دوم، پیشینه تحقیق ارائه می‌گردد. بخش سوم به معرفی مبانی نظری مدل‌های ARIMA، شبکه‌های عصبی، تبدیل موجک و مدل تلفیقی می‌پردازد. در بخش چهارم به مدل سازی و تخمین مدل‌های مذکور با استفاده از داده‌های روزانه تقاضای آب شهر تهران، برای دوره ۱۳۸۲/۳ تا ۱۳۸۹/۱/۳۱ پرداخته می‌شود و تقاضای روزانه آب شهر تهران توسط مدل‌های

1- Artificial Neural Networks

2- Wavelet

3- Liang and Peach

مذکور در بازه زمانی یک گام تا ده گام به جلو پیش‌بینی می‌گردد. در بخش پنجم با به کارگیری معیارهای سنجش به ارزیابی قدرت پیش‌بینی مدل‌های فوق پرداخته و در بخش ششم نتایج ارائه می‌گردد.

۲- پیشینه تحقیق

مطالعات صورت گرفته در زمینه پیش‌بینی آب بیشتر بر اساس مدل‌های آماری، رگرسیون چندگانه، سرهای زمانی است.

در سال ۱۹۸۴ مصرف ماهیانه (میان مدت) آب در تگزاس توسط میدمنت و پارزن^۱ (۱۹۸۴) با استفاده از سری زمانی تخمین زده شد. در این تحقیق آنها ابتدا مقادیر سری زمانی را به دو مؤلفه همیشگی و تصادفی تقسیم نمودند. مؤلفه همیشگی شامل مؤلفه روند و فصلی می‌شد که مؤلفه روند را به وسیله رگرسیون بین میانگین مصرف آب سالیانه و جمعیت شهر مدل کردند و مؤلفه فصلی را نیز با استفاده از سری‌های فوريه تخمین زدند. آنها برای مدل کردن مؤلفه تصادفی از دو معادله استفاده نمودند که این معادلات همبستگی مصرف آب با متغیرهای آب و هوایی، نظری حداقل درجه حرارت ماهانه، تبخیر و بارش را بررسی می‌کرد.

در سال ۱۹۸۵ میدمنت و همکارانش^۲ (۱۹۸۵) یکتابع انتقال برای پیش‌بینی مصرف روزانه آب برای شهر تگزاس به کار برdenد. همچنین آنها یک مدل مصرف کوتاه‌مدت توسط سری‌های زمانی طراحی نمودند که در آن از اطلاعات بلندمدت به صورت توام استفاده گردید.

استفاده از شبکه عصبی در سال ۲۰۰۰ توسط استارک و همکارانش^۳ (۲۰۰۰) برای شهر آلبراتا در کانادا به کار رفت. آنها به وسیله یک مدل عصبی سه لایه مصرف روزانه و مصرف ۱۰ روز آتی آب را با استفاده از پارامترهای هواشناسی پیش‌بینی کردند. پارامترهای به کار رفته در این تحقیق، شامل ماکزیمم و مینیمم درجه حرارت، بارش روز گذشته، مجموع بارش ۵ روز و ۳۰ روز گذشته، اندیس تعطیلی و غیر تعطیلی بود.

1- Parzen and Maidment

2- Maidment et al

3- Stark et al

جين و همکاران^۱ (۲۰۰۱) با استفاده از شبکه عصبی مصنوعی، به پیش‌بینی تقاضای کوتاه مدت آب شهر کانپور هند پرداختند. متغیرهای ورودی در مطالعه مذکور شامل تقاضای آب، میانگین دمای هوا و مقدار بارندگی در هفته بود. در مطالعه مذکور علاوه بر الگوی شبکه عصبی مصنوعی، سه الگوی رگرسیون خطی و دو الگوی سری زمانی به منظور مقایسه عملکرد الگوها در پیش‌بینی تقاضای آب، مورد بررسی قرار گرفت. نتایج مطالعه نشان داد که عملکرد شبکه عصبی مصنوعی از سایر الگوها بهتر بوده است.

یو و همکارانش^۲ (۲۰۰۲) از یک شبکه عصبی سه لایه پیشخور برای پیش‌بینی تقاضا آب در شهر سئول استفاده کردند. در تحقیق مذکور برای هر فصل از سال به طور جداگانه مدل سازی انجام گرفت و از مراکزیم درجه حرارت، تعطیلات، به عنوان پارامتر ورودی در تمام فصول سال و از سرعت باد در فصل بهار و رطوبت در فصل زمستان استفاده نمودند.

لیو و همکارانش^۳ (۲۰۰۲) شبکه‌های عصبی مصنوعی را برای پیش‌بینی مصرف ماهانه آب در شهر ویان^۴ کشور چین به کار برdenد. آنها از پارامترهای اقتصادی نرمالیزه نظیر درآمد سرانه، تعداد افراد خانوار، و قیمت آب برای این منظور استفاده کردند.

پیلای^۵ (۲۰۰۵) در مطالعه‌ای به پیش‌بینی کوتاه مدت تقاضای آب برای ۲۴ ساعت آینده شهر توومبا^۶ پرداخت. نتایج حاصل از مطالعه مذکور نشان داد که تقاضای شهر کاملاً تحت تأثیر حداکثر درجه حرارت هوا، بارندگی، روزهای بارانی، میانگین متحرک تقاضا، تقاضای میانگین وزنی ۴ روز و تراز محدودیت تحملی قرار گرفته است.

کستاس و چریس توموس^۷ (۲۰۰۶) پس از بررسی عوامل تعیین‌کننده بر تقاضای آب شهر آتن به پیش‌بینی تقاضای آب شهری پرداختند. در این مطالعه برای بخش‌های مرکزی آتن تأثیرات

- 1- Jain et al,
 2- Yu et al
 3- Liu and et al
 4- weiyang
 5- Pillay
 6- Toovoomba
 7- Kostas and Chrysostomos

متغیرهای درآمد و قیمت آب بر روی تقاضای آب مورد بررسی قرار گرفت. نتیجه آنکه هنگامی که دیگر عوامل اقتصادی تأثیر چندانی بر مصرف آب ندارند، انتظار افزایش درآمد در آینده موجب افزایش تقاضاً آب می‌شود.

وامورسی و خاطری^۸ (۲۰۰۹) در مطالعه خود با معرفی مدلی به بررسی ارتباط بین تقاضای آب شهر بیرونگام با شرایط آب و هوایی، آلودگی و رشد اقتصادی پرداختند. نتایج این تحقیق نشان داد تقاضای آب در آینده برای بیرونگام به وسیله عوامل اقتصادی اجتماعی متاثر خواهد شد و از تغییرات آب و هوا تأثیری نمی‌پذیرد.

از جمله مطالعات داخلی صورت گرفته می‌توان به مطالعه گوشه (۲۰۰۳) اشاره کرد، که پس از بررسی عوامل مؤثر بر تقاضای آب شهری، به پیش‌بینی تقاضای کوتاه مدت آب در شهر تهران با استفاده از شبکه‌های عصبی و الگوهای فازی بر اساس پارامترهای هواشناسی پرداخت. نتایج حاصل از مقایسه بین الگوی شبکه عصبی مصنوعی و فازی در مورد پیش‌بینی تقاضای کوتاه مدت آب شهری نشان داد الگوی شبکه عصبی مصنوعی عملکرد بهتری نسبت به الگوهای فازی در پیش‌بینی تقاضای آب در شهر تهران داشته است.

تابش و همکاران (۱۳۸۶) در مطالعه‌ای به پیش‌بینی تقاضای کوتاه مدت شهر تهران با استفاده از شبکه‌های عصبی پرسپترون چند لایه با الگوریتم آموزشی پس انتشار خطأ پرداختند. در مطالعه مذکور میزان مصرف یک روزه آب شهر تهران بر اساس پارامترهای هواشناسی و داده‌های تاریخی مصارف گذشته پیش‌بینی گردید.

همچنین آنها با استفاده از شبکه‌های عصبی مصنوعی، فرمول ساده‌ای برای پیش‌بینی میزان مصرف آب شهر تهران طراحی کردند که قادر است میزان تقاضای روزانه آب شهر تهران را تخمین بزند.

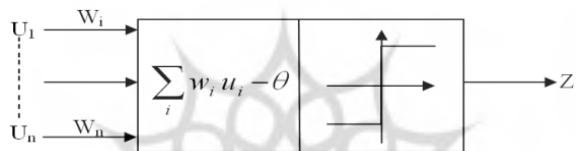
شرزه‌ای و همکاران (۱۳۸۷) با استفاده از الگوی ساختاری، سری‌های زمانی و شبکه عصبی از نوع GMDH به پیش‌بینی تقاضای سرانه آب در شهر تهران پرداخته‌اند. متغیرهای مورد استفاده در مقاله آنها مصرف سرانه آب، قیمت آب، متوسط درآمد خانوار و متوسط درجه حرارت سالانه

شهر تهران بود. نتایج به دست آمده نشان داد پیش‌بینی تقاضای آب با استفاده از روش شبکه‌های عصبی GMDH نسبت به روش‌های ساختاری و سری زمانی از درجه کارآیی بیشتری برخوردار است.

۳- روش‌های پیش‌بینی

۱-۳: مدل شبکه عصبی

شبکه‌های عصبی از دهه ۱۹۵۰ شناخته شده بودند، اما تنها در اواسط دهه ۱۹۸۰ بود که الگوریتم‌ها و روش‌های مربوط به شبکه‌های عصبی مصنوعی به درجه‌ای از پیشرفت رسید که در حل مسائل واقعی از آنها استفاده شد (Ahmadi et al., 2010). در واقع شبکه عصبی مصنوعی مجموعه‌ای از نرون‌های به هم متصل در لایه‌های مختلف هستند که اطلاعاتی را برای یکدیگر ارسال می‌کنند. نرون‌های مصنوعی واحدهای ساده پردازش اطلاعات هستند. بنابراین، تعداد زیادی از این نرون‌ها یک شبکه عصبی را می‌سازند. شکل (۱) تصویری از یک نرون مصنوعی را نشان می‌دهد.



شکل (۱): نرون مصنوعی با تابع آستانه

همان‌گونه که در شکل (۱) ملاحظه می‌شود، ارتباطها (سیناپس‌ها) W_i ، علامت‌ها (محرك‌ها) U_i را به نرون انتقال می‌دهند. W_i می‌تواند به عنوان یک وزن، که میزان اهمیت ورودی U_i را نمایش می‌دهد، تفسیر شود. در داخل نرون مجموعه ورودی‌های وزن دار $W_i U_i$ در نظر گرفته می‌شود. این مجموع $\Sigma_i w_i u_i$ بزرگ‌تر از حد آستانه خارجی θ در نظر گرفته شده و نرون خروجی Z را تولید می‌کند. Z یک مقدار باینری یا پیوسته است که وابسته به تابع فعالیت است. در اکثر موارد، انتخاب یک تابع فعالیت خروجی، نرون را به برد $[0, 1]$ یا $[-1, 1]$ محدود می‌سازد. (Basynzhad, Mohammadi, 2006)

از دید ریاضی تساوی زیر یک شرح جامع از نرون‌ها را ارائه می‌نماید:

$$y = \sum_{i=1}^n w_i u_i - \theta \quad z = \psi(y) \quad (1)$$

که در آن z ورودی خالص و $\psi(z)$ تابع فعالیت است.

به طور کلی نقش نرون‌ها در شبکه عصبی، پردازش اطلاعات است و این امر در شبکه عصبی مصنوعی به وسیله یک پردازشگر ریاضی، که همان تابع فعال‌سازی است، انجام می‌گیرد. تابع فعال‌سازی می‌تواند خطی و یا غیر خطی باشد که بر اساس نیاز خاص مسئله که قرار است به وسیله شبکه عصبی حل شود از سوی طراح انتخاب می‌گردد. برای بهره برداری واقعی از توانایی شبکه عصبی باید از توابع فعال‌سازی غیر خطی استفاده شود. این مسئله اجازه می‌دهد که شبکه، الگوهای غیر خطی مناسبی از مجموعه داده‌های پیچیده تولید نماید.

رایج‌ترین تابع فعال‌سازی مورد استفاده در ادبیات شبکه عصبی، تابع توزیع جمعی لجستیک یا

تابع سیگموئید است:

$$\varphi(x) = \frac{1}{1 + e^{-a(x)}} \quad (2)$$

این تابع پیوسته و مشتق پذیر است.

مقدار تابع لجستیک در محدوده $[0, 1]$ قرار دارد، به گونه‌ای که وقتی تابع نزدیک به یک می‌شود، نرون نسبت به علائم دریافتی بسیار فعال عمل می‌کند و وقتی تابع به صفر نزدیک می‌شود نرون به ندرت به علایم دریافتی واکنش نشان می‌دهد.

یک شبکه عصبی چند لایه، یک یا چند لایه پنهانی از نرون‌ها را نیز علاوه بر لایه ورودی و خروجی دارد.

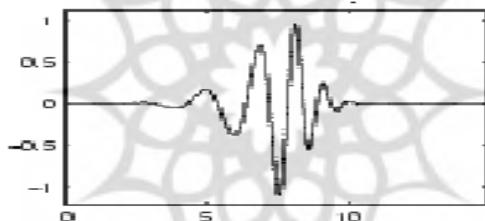
لایه‌های پنهان اضافی، توانایی شبکه را بالا می‌برند تا آمار بهتری از داده‌های ورودی استخراج کرد. این موضوع یک کیفیت مهم است، به ویژه آنکه یک لایه بزرگ ورودی وجود داشته باشد. اگر هر نرون در هر لایه شبکه به هر نرون دیگر در لایه همسایه جلویی متصل شده باشد، یک شبکه دارای اتصال کامل است.

در ادبیات شبکه عصبی به جای اصطلاح تخمین ضرایب از اصطلاح یادگیری یا آموزش برای پیدا کردن ارزش وزن‌های شبکه استفاده می‌شود. دو نوع یادگیری در این ادبیات، مورد بحث قرار

می‌گیرد: یادگیری تحت نظارت^۱ و یادگیری بدون نظارت^۲. در یادگیری با نظارت که به یادگیری با معلم نیز معروف است، ارزش‌های متغیر هدف که شبکه باید بر اساس ارزش‌های متغیرهای ورودی از طریق محاسباتش، آنها را دوباره تولید کند، مشخص می‌باشد، در نتیجه می‌توان خطای پیش‌بینی برای هر مشاهده را به وسیله محاسبه اختلاف خروجی شبکه با ارزش‌های متغیرهای هدف اندازه‌گیری کرد و سپس با استفاده از الگوریتم‌های مختلف تکرار، که مشهورترین آنها الگوریتم پس انتشار خطای^۳ است، وزن‌های شبکه تعديل می‌شود (اصطلاحاً شبکه آموزش داده می‌شود) به گونه‌ای که خطای پیش‌بینی داخل نمونه که به وسیله مجموع مربعات خطای مطلق میانگین خطای مطلق اندازه‌گیری می‌شود، حداقل شود. وقتی که وزن‌ها با هر تکرار تغییر می‌کند، اصطلاحاً^۴ گفته می‌شود که شبکه در حال یادگیری است (Tabesh et al., 2005).

۲-۳: تبدیل موجک

موجک در لغت به معنی یک موج کوچک است. موجک‌ها توابعی هستند که مقدار محدودی دارند و مقدار متوسط آنها برابر صفر می‌باشد. این موجک‌ها دارای انواع متعددی می‌باشند. در شکل (۲) یک موجک از خانواده دبوچی^۴ نشان داده شده است.



شکل (۲): یک موجک از خانواده دبوچی

تبدیل موجک پیوسته را می‌توان به صورت مجموع حاصل ضرب علامت اصلی در موجک

-
- 1- Supervised Learning
 2- Unsupervised Learning
 3- Error Back Propagation
 4- Dubochis

های تغییر مقیاس یافته و انتقال داده شده در زمان نمایش داد.

$$C(s, \tau) = \int_{-\infty}^{\infty} f(t) \cdot \psi_{s,\tau}(t) dt \quad (3)$$

در رابطه بالا (t) $\psi_{s,\tau}$ موجک مادر تغییر مقیاس یافته به اندازه S و انتقال یافته در زمان به اندازه τ می‌باشد. نتیجه تبدیل موجک پیوسته، ضرایب موجک C هستند که توابعی از مقیاس و ضرایب جا به جائی می‌باشند. با ضرب کردن هر کدام از این ضرایب در موجک‌های مادر تغییر مقیاس یافته و جایه جا شده در زمان، می‌توان موجک‌های تشکیل دهنده علامت اصلی را به دست آورد.

علامت اصلی در طول زمان توسط توابع موجک تغییر مقیاس یافته که در طول زمان جا به جا می‌شوند، ضرب و سپس از آنها انتگرال گیری می‌شود. بنابراین با استفاده از تبدیل موجک می‌توان یک علامت را با استفاده از مجموعه‌ای از توابع که از تغییر مقیاس و انتقال دادن یک تابع اصلی به نام موجک مادر به دست می‌آیند به زیر علامت‌هایی تجزیه نمود.

در صورت استفاده از تبدیل موجک پیوسته حجم اطلاعات بسیار زیاد می‌شود، چرا که بایستی برای مقیاس‌های مختلف (S مختلف) در طول زمان از علامت اصلی و تابع موجک، انتگرال گیری نمود. بنابراین، حجم اطلاعات و محاسبات بسیار زیاد می‌شود، چرا که S به صورت پیوسته تغییر می‌کند، ضمناً در برخی از موارد ممکن است به یک تابع غیر تحلیلی برخورد کرد که امکان انتگرال گیری از آن وجود نداشته باشد و یا اینکه انتگرال جواب خاصی نداشته باشد. از این رو بهتر است که از تبدیل موجک گستته استفاده گردد. این تبدیل، ویژگی‌های بسیار مناسبی را ارائه می‌دهد که از جمله آنها می‌توان به موارد زیر اشاره نمود:

- به اندازه کافی اطلاعات مورد نیاز را برای تحلیل و بررسی موج اصلی ارائه می‌دهد.

- مقدار محاسبات مورد نیاز را به مقدار بسیار مناسبی کاهش می‌دهد.

- می‌توان توسط آن علامت اصلی را در فرکانس‌های مختلف و با وضوح‌های کاملاً متفاوت بررسی و تحلیل نمود.

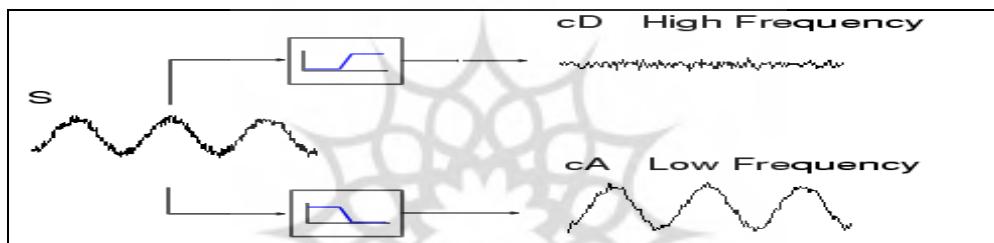
- می‌توان علامت اصلی را به علامت‌هایی با تقریب نه چندان خوب، ولی با اطلاعات بسیار

خوب و مفیدی از آن تجزیه نمود.

در تبدیل موجک گستته^۱ متغیرهای S و C که در حالت پیوسته، مقادیر پیوسته‌ای داشتند، در حالت گستته مقادیر گستته‌ای به خود می‌گیرند و پیاده‌سازی تبدیل به صورت ساده‌تری صورت می‌گیرد.

برای اکثر علامت‌ها، مؤلفه‌های فرکانس پایین اهمیت بسیار زیادی دارند. این مؤلفه‌ها، مشخصات کلی علامت را مشخص می‌کنند؛ از سوی دیگر، مؤلفه‌های فرکانس بالا، جزئیات ریز علامت را بیان می‌نمایند.

در تحلیل موجک، معمولاً از تقریب^۲ علامت و جزئیات^۳ آن بحث می‌شود. تقریب علامت معمولاً از مقیاس‌های بزرگ و یا از مؤلفه‌های فرکانس پایین تشکیل می‌شود، ولی جزئیات علامت از مقیاس‌های کوچک و یا مؤلفه‌های فرکانس بالا تشکیل می‌گردد. عملیات فیلتر نمودن به صورت کلی و ساده را می‌توان به صورت شکل(۳) نمایش داد.



شکل (۳) : عملیات فیلتر نمودن یک سیگنال

به همین ترتیب می‌توان عملیات فیلترسازی را طی مراحل مختلفی انجام داد. مطابق آنچه که در شکل (۳) نشان داده شده است، می‌توان مؤلفه‌های فرکانس پایین را دوباره از دو فیلتر پایین گذار و بالا گذار عبور داد و ضرایب دیگری از تبدیل موجک گستته در سطوح مختلف فرکانسی را به دست آورد (Zhang G Peter, 2003).

-
- 1- Distinct Wavelet Transform
2- Approx
3- Details

۳-۳: مدل تلفیقی

ترکیب مدل‌های شبکه‌عصبی مصنوعی به عنوان یک مدل غیرخطی با مدل ARIMA به عنوان یک مدل خطی در پیش‌بینی سری‌های زمانی، عملکرد بهتری نسبت به پیش‌بینی صورت گرفته با استفاده از هر یک از مدل‌ها به تنها بی دارد (Zhang G Peter, 2003). از طرفی تبدیل موجک، توانایی شبکه عصبی را در تجزیه و تحلیل و پیش‌بینی سری زمانی داده‌ها ارتقا می‌بخشد (ShangaKo and JiKongkou, 2005) از این رو با نگاهی به مطالعات صورت گرفته در به کارگیری روش‌های تلفیقی که بین روش‌های شبکه‌های عصبی و مدل ARIMA و شبکه عصبی و تبدیل موجک انجام گرفته است، این ایده به وجود آمد که روشی طراحی شود که تلفیقی از مدل‌های ARIMA، شبکه‌عصبی و تبدیل موجک باشد.

روش پیشنهادی، اطلاعات مفیدی را از تأثیرگذاری رویدادهای مختلف بر روى سرى زمانى ارائه مى‌دهد. اين روش، تلفیقی از مدل‌های ARIMA و تبدیل موجک به همراه شبکه‌های عصبی مصنوعی است.

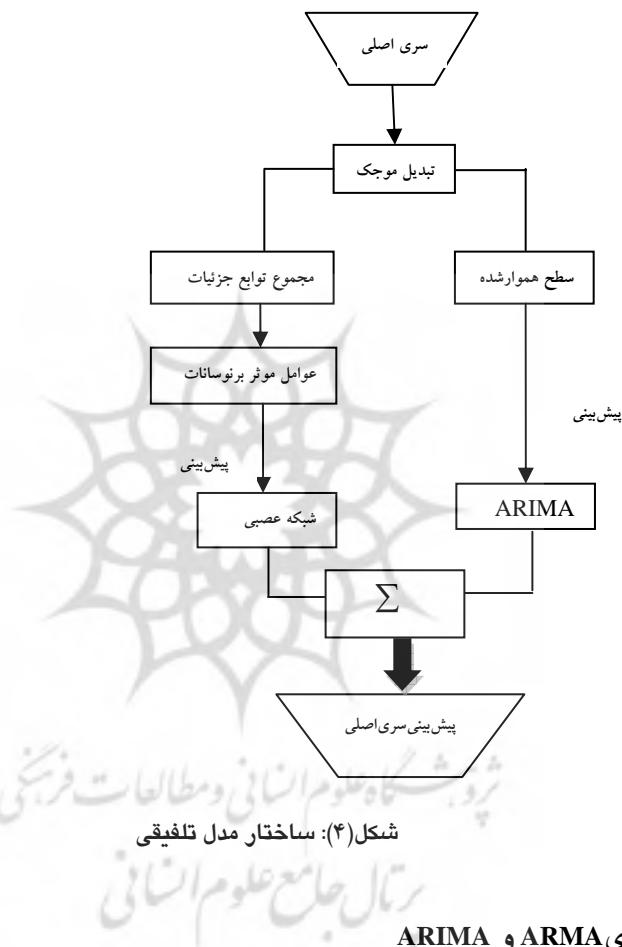
در اين روش در مرحله نخست با استفاده از موجک (از نوع دبوچی)، سرى زمانى تا سطحی تجزیه مى‌شود که سطح هموارشده (تقریبی) به صورت یک خط نسبتاً راست (یا یک روند) درآید و با در نظر گرفتن این نکته که ARIMA در پیش‌بینی سری‌های خطی قدرت بالایی دارد (Ahmadi,et al., 2010) این سرى را به وسیله آن پیش‌بینی مى‌شود. در مرحله بعد با جمع کردن توابع جزئیات (مؤلفه‌ها) یک سرى به دست مى‌آید که روند زدایی شده است و فقط شامل نوسانات در طول دوره است. از آنجایی که:

سری اصلی = سرى سطح هموار شده (تقریبی) + مجموع سری‌های توابع جزئیات (مؤلفه‌ها)

در مرحله بعد عوامل تأثیرگذار بر اين نوسانات تعیین مى‌گردد. با تعیین عوامل تأثیرگذار بر اين نوسانات، آنها را به عنوان متغیرهای توضیحی این نوسانات به عنوان ورودی به شبکه عصبی داده و مقدار مجموع توابع جزئیات به عنوان خروجی آن تعیین مى‌گردد و در شبکه عصبی به طراحی و تخمین مدل در اين زمینه بررسی مى‌شود.

در مرحله نهایی، این نوسانات را به وسیله شبکه عصبی، با در نظر گرفتن عوامل تأثیرگذار برای آينده، پیش‌بینی نموده و با مقادیر پیش‌بینی شده سرى هموار شده توسط ARIMA جمع بسته می‌شود.

این روش دارای دو مزیت قابل توجه است: اولاً سه الگوی خطی و غیرخطی ARIMA، شبکه عصبی و تبدیل موجک را با هم تلفیق می کند که در این زمینه نقاط ضعف هر یک از الگوها در پیش‌بینی با نقاط قوت الگوی دیگری حذف یا کم رنگ‌تر می شود؛ ثانیاً این روش با در نظر گرفتن سری زمانی، عوامل تأثیرگذار بر روی این سری را نیز در مدل دخیل می کند که قاعدتاً می بایستی قدرت پیش‌بینی سری زمانی را افزایش دهد. ساختار فرایند فوق را می توان به صورت شکل (۴) نمایش داد:



فرآیند ARIMA(p,d,q) برای متغیر x را می توان به صورت رابطه (۴) نشان داد:

که در آن:

$$y_t = \Delta^d x_t = (1-l)^d x_t \quad (4)$$

و $f(t)$ روند زمانی را (در صورت وجود) در y_t برآورد می‌کند. در اکثر متغیرهای اقتصادی، معمولاً $d=1$ بوده در نتیجه $f(t) = f_0 + \alpha t$ و یا $d=0$ می‌باشد^۱

$$f(t) = \alpha + \delta t \quad (5)$$

در فرآیند ARIMA(P, d, q) به ترتیب، بیانگر تعداد جملات خود توضیحی، مرتبه تفاضل گیری و تعداد جملات میانگین متحرک هستند. در صورتی که d برابر با صفر گردد، فرآیند ARIMA تبدیل به فرآیند ARMA می‌گردد. معمولاً برای تخمین الگوی ARIMA و ARMA از روش باکس-جنکینز استفاده می‌شود که دارای چهار مرحله شناسایی، تخمین، تشخیص دقت پردازش و پیش‌بینی است. تعداد جملات خود توضیحی و تعداد جملات میانگین متحرک معمولاً با استفاده از توابع خودهمبستگی^۲ (AC) و خود همبستگی جزئی^۳ (PAC) محاسبه می‌گردد.

در مرحله تشخیص دقت پردازش، تعداد صحیح جملات AR و MA پس از تعیین آنها توسط توابع خود همبستگی (AC) و خود همبستگی جزئی (PAC) براساس معیارهای مختلفی مورد بازبینی قرار می‌گیرد که از جمله آنها می‌توان به معیارهای آکائیک^۴ (AIC)، شوارتز - بیزین (SBIC)^۵ و حنان - کوئین^۶ (HQIC) اشاره نمود. این معیارها دو عامل را دربردارد: جمله‌ای که تابعی از مجموع مجذور باقیمانده‌ها (RSS) است و جمله‌ای که زیان ناشی از کاهش درجه آزادی، به خاطر وارد نمودن پارامترهای اضافی می‌باشد. بنابراین افزودن یک متغیر جدید یا دادن وقفه اضافی به مدل، دو اثر رقیب دارد که یکی موجب کاهش مجموع مجذورات باقیمانده‌ها می‌شود و دیگری درجه آزادی را کاهش می‌دهد.

1- Pesaran, & Pesaran (1997)

2- Auto Coptolation

3- Partial Auto Coptolation

4- Akaike Information Criterion

5- Schwarz Bayesian Information Criterion

6- Hannan–Quinn Information Criterion

هدف این است که مدل به گونه‌ای انتخاب شود که مقدار معیار حداقل گردد. بنابراین افزودن یک وقهه اضافی که همراه خود یک پارامتر را وارد می‌کند، مقدار معیار را در صورتی کاهش می‌دهد که مجموع مجذور باقیمانده را کاهش داده و بتواند زیان ناشی از کاهش درجه آزادی (که به صورت افزایش در معیار است) را جبران نماید.

لازم به ذکر است که SBIC در مقایسه با AIC وزن بیشتری به زیان حاصل از کاهش درجه آزادی می‌دهد در حالی که AIC در مقایسه با SBIC وزن بیشتری به مزیت حاصل از کاهش مجموع مجذور باقیمانده‌ها می‌دهد. HQIC نیز حالت بینابینی دارد. در مجموع استفاده از معیار حنان-کوئین در شرایطی لازم است که بین تعداد جملات AR و MA که مقادیر آکائیک و شوارتز - بیزین را حداقل می‌سازد، تفاوت وجود داشته باشد (PourKazemi et al., 2004).

۴- طراحی و تخمین مدل‌ها

داده‌های مورد استفاده در این پژوهش مصرف آب شهر تهران به صورت روزانه از ۱۳۸۲/۳/۱ تا ۱۳۸۹/۱/۳۱ بوده که در مجموع ۲۴۵۸ مشاهده را در بر می‌گیرد. داده‌ها از شرکت آب و فاضلاب استان تهران استحصال شده است. این داده‌ها از دو بخش تشکیل شده‌اند. نخست داده‌های مربوط به دوره ۱۳۸۲/۳/۱ تا ۱۳۸۹/۱/۲۱ برای آموزش و آزمایش و بخش دوم از ۱۳۸۹/۱/۳۱ تا ۱۳۸۹/۱/۲۲ برای اعتبار سنجی و مقایسه مدل‌های پیش‌بینی کننده مورد استفاده قرار می‌گیرد.

ARMA : ۱-۴

برای پیش‌بینی داده‌های سری زمانی ابتدا مانایی سری زمانی را بررسی کرده و مرتبه انباستگی (d) تعیین می‌شود. در مطالعه حاضر سری زمانی دارای روند فصلی می‌باشد؛ به گونه‌ای که در فصول گرم مصرف آب افزایش یافته و در فصول سرد مصرف کاهش می‌یابد. بنابراین در مرحله اول سری مورد نظر به صورت سالیانه روندزدایی شد. در ادامه سری زمانی در سطح ۹۵ درصد

براساس آزمون دیکی - فولر تعمیم یافته^۱، مانا شد (d) برابر با صفر گردد). سپس تعداد جملات خود توضیحی (p) و تعداد جملات میانگین متاخر (p)، با استفاده از توابع خود همبستگی (AC) و خود همبستگی جزئی (PAC) بر اساس مراحل باکس - جنکیتر محاسبه شد. از آنجایی که ممکن است مدل‌های دیگری باشند که مقدار آکائیک یا شوارتز کمتری داشته باشند و بر الگوی مذکور ترجیح داده شوند، مدل‌های دیگر نیز بررسی گردیدند. بر این اساس کمترین مقدار آکائیک و شوارتز - بیزین، مربوط به فرایند تعداد جملات خود توضیحی و میانگین متاخر کمی باشد، که نتایج تفصیلی حاصل از برآورد آن، در جدول (۱) آورده شده است.

جدول (۱): نتایج حاصل از برآورد دوره ۲۱/۱-۸۹/۱-۸۲/۳

نام متغیر	آماره t	ضریب	نام متغیر	آماره t	ضریب	نام متغیر	آماره t	ضریب
								C
۵/۱۸	-۰/۱۱		AR(۱۴)	۲۲۵/۵	۱۴/۹			
۱۳/۶۸	-۰/۱۹		AR(۳۶۵)	۱۵/۸۹	-۰/۸۲	AR(1)		
-۴.۴۵	-۰/۲۳		MA(1)	-۵/۷۳	-۰/۲۴	AR(2)		
۵/۹۲	-۰/۱۹		MA(2)	۲/۹۵	-۰/۰۷	AR(3)		
۲/۲۵	-۰/۰۷		MA(3)	۲/۲۳	-۰/۰۵	AR(4)		
۱/۴۸	-۰/۰۵		MA(4)	-۱/۹۶	-۰/۰۴۵	AR(5)		
۳/۲۲	-۰/۱۰		MA(5)	-۰/۰۸	-۰/۰۰۳	AR(6)		
۳/۶۳	-۰/۱۲		MA(6)	۱۶/۴۹	-۰/۵۵	AR(7)		
-۱۱/۶۲	-۰/۳۹		MA(7)	-۱۵/۴۱	-۰/۷۸	AR(8)		
۱۲/۴۷	-۰/۵۲		MA(8)	۸/۲۹	-۰/۳۰	AR(9)		
				-۲/۱۵	-۰/۰۵	AR(1۳)		
$\bar{R}^2 = +0.91$				F = ۹۴۳				

مأخذ: یافته‌های تحقیق

از آنجایی که مقادیر آکائیک و شوارتز - بیزین بر حسب مقادیر جدول بالا حداقل گردیدند، نیازی به استفاده از معیار حنان کوئین نیست.

1- Augmented Dickey-Fuller test statistic

در جدول (۱) جملات خود توضیحی مرتبه شش (AR(6) و میانگین متحرک مرتبه چهار (MA(4) بلحاظ آماری معنادار هستند. جمله خود توضیحی مرتبه پنج (AR(5) در سطح خطای ۰/۰۵ و بقیه جملات در سطح خطای ۰/۰۱ به لحاظ معنادار هستند

۴-۲: شبکه عصبی

انواع مختلفی از شبکه‌های عصبی مصنوعی با توجه به اهداف تحقیق می‌توان استفاده نمود. در این تحقیق از شبکه عصبی چند لایه پیشخور^۱ (MFNN) استفاده شده است. جدول (۲) چگونگی طراحی و مدل‌سازی تقاضای روزانه آب شهری را در شبکه عصبی نشان می‌دهد.

جدول(۲): طراحی و مدل‌سازی تقاضای روزانه آب شهری در شبکه عصبی

لوبنبرگ- مارکوات	الگوریتم آموزش شبکه‌های عصبی	پیشخور چند لایه‌ای	نوع شبکه عصبی
early stopping	روش توقف فرآیند آموزش	سیگموئید	تابع فعال‌سازی
۱۳۸۲/۳/۱-۱۳۸۹/۱/۲۱	دوره زمانی آموزش و آزمایش	۱۲	تعداد نرون ورودی
۰/۱۰ ۰/۹۰	نسبت تعداد داده‌های آموزش و آزمایش	۱	تعداد نرون خروجی
۰/۰۲	نرخ یادگیری	MSE	معیار تعیین تعداد نرون‌های مخفی
۱۳۸۹/۱/۲۲ - ۱۳۸۹/۱/۳۱	دوره زمانی پیش‌بینی	۱	تعداد لایه پنهان
		۲۰	تعداد نرون‌های پنهان

در طراحی شبکه‌های عصبی متغیرهای موثر (نرون‌های ورودی) عبارتند از: درجه دما هوا در غالب سه ورودی حداقل دما، حداقل دما و میانگین دمای روزانه و روزهای هفته (به طور معمول در روزهای پنجمشنبه به دلیل فعالیت پاره وقت و تعطیلی برخی موسسات مصرف آب تا حدودی کاهش می‌یابد. در اکثر روزهای جمیعه علی‌رغم افزایش مصرف خانوارها، به دلیل تعطیلی فعالیت‌های اقتصادی مصرف آب کاهش می‌یابد. همچنین در آغاز هفته مصرف آب نسبت به بقیه روزها به دلیل شروع فعالیت‌های اقتصادی افزایش می‌یابد و در بقیه روزهای هفته نوسان دارد. ایام

1- Multilayered Feedforward Neural Network

تعطیلات و روزهای خاص مانند ماه رمضان و ... نیز در نظر گرفته می‌شود. بنابراین ۱۲ نرون در لایه ورودی وجود دارد.

همان‌گونه که از جدول (۲) ملاحظه می‌گردد، در مطالعه حاضر از شبکه عصبی پیشخور چند لایه، دارای ۲۰ نرون در لایه مخفی و تابع فعال سازی سیگموئید و لایه خروجی آن به کار گرفته شده است. پس از تعیین تعداد وقفه‌های بهینه، برای انتخاب تعداد نرون‌های لایه مخفی شبکه، شبکه‌های مختلف با تعداد نرون‌های مخفی متفاوت طراحی و آموزش داده شد. از میان این شبکه‌ها با توجه به معیار MSE، شبکه بهینه انتخاب گردید؛ یعنی شبکه با کمترین MSE که دارای ۲۰ نرون مخفی بود به کار گرفته شد. لایه ورودی با توجه به داده‌های ورودی با ۱۲ نرون در نظر گرفته شده است. تابع فعال‌سازی استفاده شده برای شبکه مذکور از نوع سیگموئید است. خروجی‌های شبکه، دارای یک نرون و تابع فعال‌سازی خطی^۱ است.

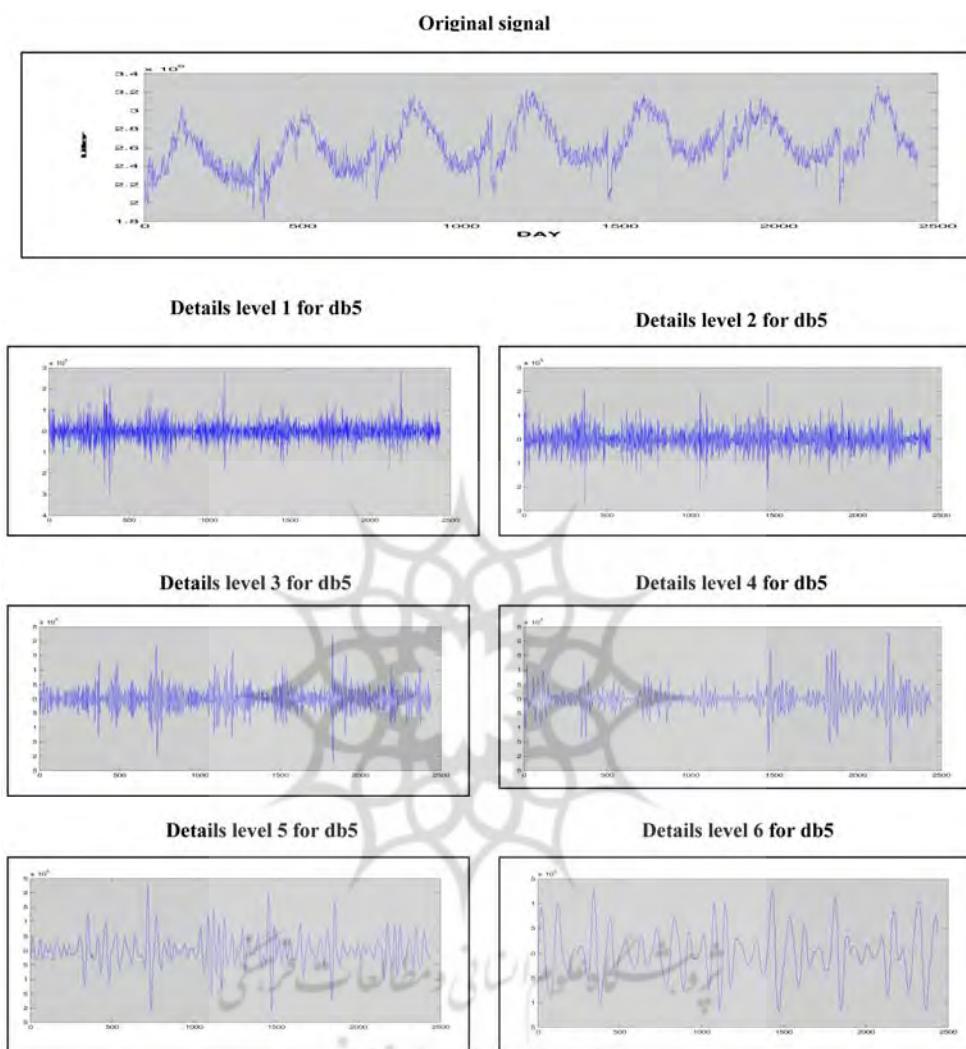
از میان الگوریتم‌های مختلفی که برای آموزش شبکه‌های عصبی مورد استفاده قرار می‌گیرد، الگوریتم لونبرگ-مارکوات انتخاب گردید. چرا که این الگوریتم در مقایسه با سایر الگوریتم‌های پس انتشار خطأ دارای سرعت بیشتری است (Ahmadi et al., 2010). دوره آموزش و آزمایش، شامل ۲۴۴۸ داده می‌باشد. تعداد داده‌های آموزش و آزمایش مدل به نسبت ۰/۹۰ به ۰/۱۰ تقسیم گردید و از نرخ یادگیری ۰/۰۲ استفاده شد. برای توقف فرآیند آموزش از روش early stopping بهره گرفته شد. در نهایت شبکه عصبی با استفاده از نرم‌افزار MATLAB(2008) طراحی و مدل‌سازی شد.

۳-۴- مدل تلفیقی

در این روش ابتدا سری زمانی تقاضای روزانه آب شهر تهران، به صورت ترکیبی از مؤلفه‌های مجزا در مقیاس و سطوح نوسان متفاوت در نظر گرفته شده است. با توجه به این مطلب، ابتدا تجزیه موجک به دست می‌آید. در این مرحله، نخست با استفاده از موجک (از نوع دبوچی)، سری زمانی تا سطحی تجزیه می‌شود که سطح هموارشده (تقریبی) به صورت یک روند هموار شده

۱- در ادبیات شبکه‌های عصبی، معمولاً منظور از یک تابع فعال‌سازی خطی استفاده از یک تابع خطی همانی است.

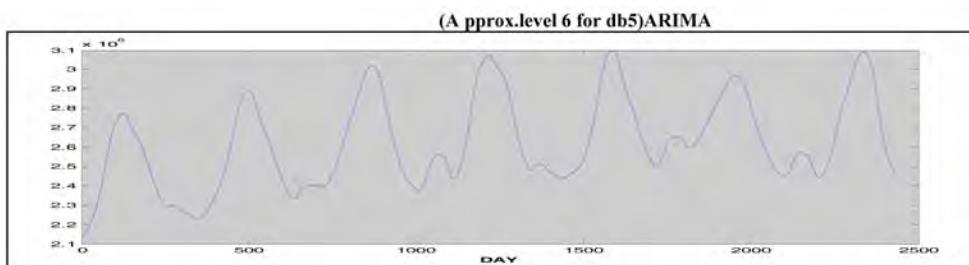
درآید. برای بررسی عملکرد سطح تجزیه، داده‌ها را با استفاده از موجک دبوچی ۵ تا ۶ سطح شکافته و سطح هموار شده با جزئیات سطوح یک تا شش به دست می‌آید. نتایج این کار در نمودارهای (۱) تا (۷) نشان داده شده است.



مأخذ : یافته‌های تحقیق

نمودارهای (۱) تا (۷) : مؤلفه‌های تجزیه شده سری زمانی تقاضای روزانه آب شهر تهران توسط موجک دبوچی ۵

حال با در نظر گرفتن این نکته که مدل ARIMA (یا ARMA) در پیش‌بینی سری‌های خطی قدرت بالایی دارد، سری هموار شده توسط مدل ARIMA برای ۱۰ روز بعدی پیش‌بینی می‌شود. نمودار (۸) سطح هموار شده (تقریبی) را برای تقاضای روزانه آب شهری نشان می‌دهد.



نمودار (۸): سری زمانی هموار شده (تقریبی) تقاضای روزانه آب شهری تهران برای پیش‌بینی
(A approx.level 6 for db5)ARIMA

ماخذ: یافته‌های تحقیق

در مطالعه حاضر سری زمانی هموار شده تقاضای روزانه آب شهری برای دوره (۱۳۸۲/۳/۱ تا ۱۳۸۹/۱/۲۱) پس از روند زدایی سالیانه، مانا گردید. سپس تعداد جملات خودتوضیحی (p) و تعداد جملات میانگین متغیر ک (p)، با توجه به توضیحاتی که در قسمت ۴-۱ بیان شد، به دست آمد. جدول (۳) نتایج حاصل از برآورد مدل ARMA را نشان می‌دهد.

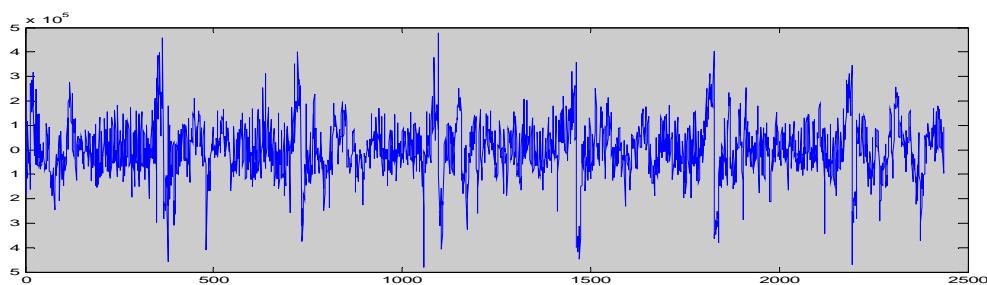
جدول(۳): نتایج حاصل از برآورد دوره ۱۳۸۲/۳/۱ - ۱۳۸۹/۱/۲۱

t	آماره	ضریب	نام متغیر	t	آماره	ضریب	نام متغیر
-۲۲/۳۳	-۰/۴۷	AR (4)	-۱/۰۸	-۰/۰۰۲	C		
۵/۷۱	۰/۰۴	AR (365)	۳۴/۹۸	۰/۷۱	AR(1)		
۴۱۳	۰/۹۸	MA (1)	۲۳/۳۹	۰/۶۶	AR(2)		
۲۰۶	۰/۷۱	MA (2)	۳/۶۷	۰/۰۹	AR (3)		
$\bar{R}^2 = ۹۸\%$				F= ۱۰۰۶۴			

ماخذ: یافته‌های تحقیق

در مرحله بعد با جمع کردن سایر توابع جزئیات (سطوح ۱ تا ۶) یک سری به دست می‌آید که

روند زدایی شده است و فقط شامل نوسانات در طول دوره است. نمودار (۹) این سری را نمایان می‌کند.



نمودار (۹): مجموع توابع جزئیات (مؤلفه‌ها) تقاضای روزانه آب شهری
ماخذ: یافته‌های تحقیق

در این بخش دمای هوا (حداقل، حداکثر و میانگین)، روزهای هفته، روزهای تعطیل و روزهای خاص به عنوان عوامل موثر بر نوسانات در ورودی شبکه عصبی در نظر گرفته می‌شود. همچنین از یک متغیر فصلی نیز برای تمیز فصول سرد و گرم در طراحی شبکه استفاده شد. بنابراین، شبکه عصبی دارای ۱۲ نرون در لایه ورودی و ۲۰ نرون در لایه پنهان است. بقیه مشخصه‌های ساختار شبکه همانند بخش ۴-۲ می‌باشد.

۵- ارزیابی مدل‌های پیش‌بینی

برای مقایسه قدرت پیش‌بینی مدل‌های پیش‌بینی کننده از معیارهای میانگین مربع خطای استاندارد (MSE)، مجدور میانگین مربع خطای استاندارد (RMSE)، میانگین قدر مطلق خطای (MAE) و میانگین درصد قدر مطلق خطای (MAPE) به صورت گام به گام (روز یکم تا روز دهم) استفاده شده که نتایج آن در جدول (۴) آورده شده است. این معیارها بر اساس مقیاس داده‌های واقعی ۸۹/۳/۲۲-۸۹/۱/۳۱ محاسبه شده‌اند.

با توجه به جدول (۴) بر اساس هر ۴ معیار ارزیابی، مدل تلفیقی در تمام گام‌ها دارای کمترین خطای پیش‌بینی بوده و نسبت به بقیه الگوها از دقت بالایی در پیش‌بینی برخوردار است. پس از مدل تلفیقی، شبکه عصبی پیشخور و مدل ARIMA به ترتیب در اولویت‌های بعدی از لحاظ دقت

پیش‌بینی قرار دارد. در مجموع، مدل تلفیقی با درنظر گرفتن عوامل موثر بر تقاضای روزانه آب شهری، به ویژه دمای هوا و پیاده سازی یک الگوی تلفیقی از الگوهای خطی و غیر خطی از قدرت بالایی در پیش‌بینی برخوردار است.

جدول(۴): مقایسه قدرت پیش‌بینی مدل‌های شبکه عصبی مصنوعی ARMA و مدل تلفیقی

مدل تلفیقی	ARMA	شبکه عصبی	گام	معیار	مدل تلفیقی	ARMA	شبکه عصبی	گام	معیار
۵۵	۳۲۰۸۳	۲۳۹۲	۱	MAE	۳۰۵۵	۱۰۲۹۳۶۹۷۸۳	۵۷۲۲۴۷	۱	MSE
۴۵۰۲	۳۰۹۳۷	۷۹۴۵	۲		۴۰۰۵۲۷۷۷	۹۵۸۴۴۲۱۰۹	۹۳۹۷۵۰۵۶	۲	
۳۴۲۸	۳۴۷۲۱	۵۸۳۰	۳		۲۷۲۴۷۵۵۳	۱۲۳۵۰۹۶۰۵۳	۶۳۵۰۳۱۲۸	۳	
۴۸۱۹	۲۶۲۰۸	۵۷۸۸	۴		۴۰۶۴۵۰۹۶	۹۲۶۴۳۳۴۶۹	۵۵۶۴۰۶۴۶	۴	
۶۶۶۱	۲۱۳۷۹	۱۰۵۰۹	۵		۷۱۸۹۶۳۷۹	۷۴۱۹۹۹۵۴۲	۲۱۷۳۱۵۷۷۳	۵	
۷۸۱۰	۳۱۴۶۳	۱۳۴۷۶	۶		۹۰۵۲۳۱۰۰	۱۷۳۵۷۸۶۰۷۴	۲۱۴۶۹۵۸۰۳	۶	
۸۷۳۹	۳۹۶۶۳	۱۳۷۰۸	۷		۱۰۶۸۷۳۵۸۴	۲۶۱۵۸۸۱۷۰	۳۰۲۳۲۲۳۳۱	۷	
۸۸۸۵	۴۲۹۳۱	۱۵۶۰۷	۸		۱۰۵۷۸۲۹۶۷	۲۸۳۰۲۲۶۹۷۴	۳۶۸۹۴۴۹۰۲	۸	
۹۴۱۵	۴۲۹۳۱	۱۳۹۷۵	۹		۱۱۴۷۵۹۱۳۸	۳۱۹۱۶۰۱۱۰۸	۳۲۸۰۴۵۰۶۷	۹	
۱۰۶۲۰	۴۹۲۱۹	۱۳۵۶۸	۱۰		۱۴۹۳۲۳۱۰۶	۳۳۷۳۰۷۴۴۲۸	۳۰۵۰۳۹۰۶۴	۱۰	
۰/۰۰۲۳	۱/۳۱	۰/۰۹	۱	MAPE	۵۵	۳۲۰۸۳	۲۳۹۲	۱	RMSE
۰/۱۷	۱/۲۵	۰/۳۱	۲		۶۳۲۸	۳۰۹۵۸	۹۶۹۴	۲	
۰/۱۳	۱/۴۱	۰/۲۳	۳		۵۲۱۹	۳۵۱۴۳	۷۹۶۸	۳	
۰/۱۹	۱/۰۷	۰/۲۳	۴		۶۳۷۵	۳۰۴۳۷	۷۴۵۹	۴	
۰/۲۶	۰/۸۷	۰/۴۲	۵		۸۴۷۹	۲۷۲۲۳۹	۱۴۷۴۱	۵	
۰/۳۱	۱/۲۷	۰/۰۴	۶		۹۵۱۴	۴۱۶۶۲	۱۷۷۳۹	۶	
۰/۳۵	۱/۶۲	۰/۰۵	۷		۱۰۳۳۷	۵۱۱۴۵	۱۷۳۸۷	۷	
۰/۳۶	۱/۷۶	۰/۰۳	۸		۱۰۲۵۸	۵۳۱۹۹	۱۹۲۰۷	۸	
۰/۳۸	۱/۹۲	۰/۰۵	۹		۱۰۷۱۲	۵۶۴۹۴	۱۸۱۱۲	۹	
۰/۴۳	۲/۰۲	۰/۰۵	۱۰		۱۲۲۱۹	۵۸۰۷۸	۱۷۴۶۵	۱۰	

ماخذ: یافته‌های تحقیق

۶ - نتیجه‌گیری

در این مطالعه یک مدل تلفیقی از شبکه‌های عصبی مصنوعی، تبدیل موجک و ARMA جهت

پیش‌بینی تقاضای روزانه آب شهری ارائه شده که متغیرهای موثر بر میزان مصرف روزانه آب شهری را در خود لحاظ کرده است. در ادامه براساس معیارهای ارزیابی MAE، RMSE، MSE، MAPE به مقایسه مدل تلفیقی با مدل‌های ARIMA و شبکه عصبی مصنوعی پیشخور پرداخته شد. نتایج حاصل از تحقیق نشان داد که بر اساس همه معیارهای ارزیابی و در تمام گام‌ها، مدل تلفیقی از دقت بالایی در پیش‌بینی روزانه تقاضای آب شهری نسبت به سایر الگوهای برخوردار است. پس از مدل تلفیقی، شبکه عصبی مصنوعی پیشخور و فرآیند ARIMA به ترتیب در رده‌های بعدی با خطای پیش‌بینی کمتر قرار گرفتند.

References

- 1- Abbasinjad, Hossein, Mohammadi, Ahmad, (2006), IR forecasting using wavelet transform and the artificial neural network, No. 11, pp 19-42. (in Persian)
- 2- Abrishami, Hamid, Mhrara, Mohsen(2003). Measurement of Applied Economics .Tehran University Press.(in Persian)
- 3- Ahmadi, Ali,Mohammad, Zulfiqar, Mehdi Ghfarnzhad and Aydin.(2010).
- 4- Comparative Study of Methods for ARIMA linear and Nonlinear Neural Networks in Predicting the Internal Needs of the Country's Electricity. Journal of Iranian Economic Research, No. 41,pp 39-61.(in Persian)
- 5- Basynzhad, Hussein and Mohammadi, Ahmad (2006). Forecasting Exchange Rates Using Neural Networks and Wavelet, EconomicLetters. vol 3, No. 1, pp 19-42. (In Persian)
- 6- Bithas , Kostas and Stofors , Chrysostomos.(2010) Estimating Urban Residential Water Demand Determinants and Forecasting Water Demand for Athens Metropolitan area. 2000-2010. South-Eastern Europe Journal of Economics. Vol1 ,pp 47-59.
- 7- Bhradmehr Nafiseh (2008), crude oil price forecasting using wavelets smoothing and the artificial neural network, Journal of Energy Economics, Fifth Year, No. 18, pp 81-98. (In Persian)
- 8- Goshe, Siamak .(2003). Short-Term Urban Water Demand Estimation Using Artificial Neural Networks. Master Thesis. Faculty of Engineering. Tehran University. (In Persian)
- 9- Jain, Ashu., et al.(2001).Short – term Water Demand Forecast Modelling at IIT Kanpur Using Artificial Neural Networks. Water Resources Management 15, 299-321.
- 10- K.B. Khatri and K. Vairavamoorthy. (2009).Water Demand Forecasting for the City of the Future against the Uncertainties and the Global Change Pressures: Case of Birmingham, EWRI/ASCE: 2009, Conference: Kansas,

- USA May 17-21.
- 11- Liu, J., Savenije, H.G. and Xu, J. (2002) .Forecast of Water Demand in Weinan City in China Using WDF-ANN Model. Physics and Chemistry of the Earth. Vol. 28, pp 219-224.
 - 12- Maidment, D. R. and Parzen, E. (1984). Cascade Model of Monthly Municipal Water use. J. of Water Resources Research, Vol. 20, No. 1, PP. 15-23.
 - 13- Maidment, D. R., Miaou, S. P. and Crawford, M. M. (1985).Transfer Function Models of Daily Urban Water Use, J. of Water Resources Research. Vol. 21, No. 4, PP. 425-432.
 - 14- Masoud Tabesh, Siamak Goshe, Yazdanpanah MJ.(2005). Short-Term Demand Forecast Using Artificial Neural Networks in Tehran.Faculty of Information Technology. Volume 41, Number 1, pp 24-11.(in Persian)
 - 15- Oskouie Asghari, MR.(2002) . Application of Neural Networks in Forecasting Time Series, Journal of Iranian Economic Research.No. 12, pp 95-69. (In Persian)
 - 16- PourKazemi, Mohammad Hussain, officer, Bijan and Amir, Nahavandi. (2004). Comparative Study of Linear ARIMA and Nonlinear Neural Networks to Predict The share of Gas Demand in Urban Areas, Journalof Economic Research. No. 71, pp 146-133.(In Persian)
 - 17- RavindraSenPillay. (2005).Short-Term Water Demand Forecasting for Production Optimisation. University of Southern Queensland Faculty of Engineering and Surveying.
 - 18- Sadeghi, Hussain and Zolfaghari, Mehdi .(2009).A New Model Designed to Predict Short-Term Natural Gas Demand. Energy EconomicsStudies. No. 23, pp 78-41. (In Persian)
 - 19- Sharzehiy Gholamali, Mehdi and Hassan Ahrar Fkhrayy. (2008). Tehran's Water Demand Prediction Using Structural Model, Time Series and Neural Network, Type GMDH. Journal of Economic Research.No. 84. pp175-151. (In Persian)
 - 20- Shuanghua Cao and Jiacong Cao. (2005). Forecast of Solar Irradiance Using Recurrent Neural Networks Combined With Wavelet Analysis.Applied Thermal Engineering. Volume 25, pages 161–172.
 - 21- Stark, H.L., Stanley, J.S. and Buchanan, I.D. (2000).Water Demand Forecasting Using Artificial Neural Networks .University of Alberta.
 - 22- Wang S, Yu L and Lai K.K. (2005). Crude Oil Price Forecasting with TEI@I Methodology. Journal of Systems Science and Complexity; 18.
 - 23- Yu, M.J., Joo, C.N.and Koo, J.Y. (2002). Application of Short-Term Water Demand Prediction Model to Seoul . Journal of Water Science & Technology. Vol. 46, No 6-7, pp 255–261.
 - 24- Zhang G Peter. (2003). Time Series Forecasting using a Hybrid ARIMA and Neural Network Model. Neurocomputing Volume 50, pages159-175.