

ارائه‌ی یک مدل ترکیبی برای پیش بینی تقاضای روزانه آب شهری

عبدالرحمن آرام و دکتر لطفعلی عاقلی کهنه شهری*

تاریخ وصول: 1390/10/6 تاریخ پذیرش: 1391/3/30

چکیده:

آب به عنوان یکی از مهمترین نیازهای بشر، در زندگی روزمره دارای نقش حیاتی است. آگاهی از میزان تقاضای مورد نیاز آب برای سیاست‌گذاری مدیریت تقاضا، از اهمیت ویژه‌ای برخوردار است. در این مطالعه مدلی ترکیبی (تلفیقی از مدل‌های خطی و غیرخطی) منطبق با شرایط و ساختار اقلیمی شهر تهران و متغیرهای موثر بر مصرف آب برای پیش بینی تقاضای کوتاه‌مدت آب شهری طراحی شده است. با کمک این مدل، تقاضای روزانه آب شهری برای 10 روز بعد بر اساس مدل‌های ARIMA شبکه عصبی و مدل تلفیقی تبدیل موجک، پیش‌بینی شده است. سپس مقادیر پیش‌بینی شده هر یک از مدل‌ها، توسط معیار ارزیابی MAPE و R^2 در پیش‌بینی گام‌به‌گام و مجموع 10 روز مورد ارزیابی قرار گرفته است. در نهایت برای تقاضای روزانه آب شهر تهران، مدل تلفیقی تبدیل موجک با خطای کم (دقت پیش‌بینی بالا) به عنوان مدل بهینه انتخاب شده است.

طبقه بندی JEL: C45، C53، D12، Q25

واژه‌های کلیدی: پیش‌بینی، تقاضا، آب شهری، تبدیل موجک، شبکه‌های عصبی

* به ترتیب، کارشناس ارشد دانشگاه صنعت آب و برق شهید عباسپور و استادیار دانشگاه تربیت مدرس تهران
(aghelik@modares.ac.ir)

1- مقدمه

آب با توجه به اثر کلیدی در رفاه و سلامت جامعه و نقش تعیین‌کننده در رشد جوامع یکی از مهمترین منابع طبیعی است. در سال‌های اخیر مشکل کمیابی منابع آب در اثر افزایش روزافزون جمعیت در جهان و افزایش رقابت برای دستیابی به منابع آب که منجر به افزایش هزینه‌ی استفاده از آب می‌شود، تشدید شده است. برداشت بی‌رویه از منابع زیرزمینی، کاهش بارش و بروز خشکسالی در اکثر نقاط جهان و آلودگی آب‌های سطحی و زیرزمینی، بر شدت کمبود منابع آب افزوده است. بنابراین استفاده از این منبع حیاتی مستلزم مدیریت صحیح است.

پیش‌بینی دقیق تقاضای آب شهری به مدیران و بهره‌برداران شبکه‌های آب شهری در کمک به مدیریت صحیح مصرف در دوره‌های زمانی مختلف دارای اهمیت است. پیش‌بینی بلندمدت و میان مدت به منظور طراحی و توسعه‌ی شبکه‌ی آبرسانی است، اما پیش‌بینی کوتاه‌مدت در بازه‌های یک ساعته تا چند روزه در مدیریت و بهره‌برداری بهینه از شبکه دارای اهمیت است. این عامل در اجرای سیاست‌های طرف تقاضا مانند جیره‌بندی، زمانبندی قطع و وصل پمپ‌ها و شیرآلات، زمانبندی تأسیسات آب و فاضلاب موثر است. پیش‌بینی درست مصرف آب در توانمند سازی جامعه در مواجهه با مشکلات ناشی از کمبود آب موثر است (تابش و دیگران، 1387). کمبود آب و نقش آن در کشورهایی مانند ایران با سرانه آب تجدیدپذیر زیر 1000 متر مکعب، اهمیت پیش‌بینی کوتاه‌مدت مصرف آب را بیشتر کرده است.

روش‌های پیش‌بینی متغیرهای سری زمانی شامل دو دسته‌ی خطی و غیرخطی است. با این حال رایج‌ترین روش‌های پیش‌بینی خطی، روش‌های فرآیند خطی $ARIMA$ و $ARMA$ است. در سال‌های اخیر به موازات پیشرفت‌های قابل توجه در پردازش سریع اطلاعات با رایانه‌ها، کاربرد مدل‌های غیر خطی از جمله مدل شبکه‌ی عصبی مصنوعی به طور چشم‌گیری افزایش یافته است.

در این مقاله، با معرفی شبکه عصبی پیشخور، مدل‌های خطی $ARMA$ و $ARIMA$ و طراحی یک مدل ترکیبی با کمک تبدیل موجک، کارایی این مدل‌ها در پیش‌بینی تقاضای روزانه آب شهری تهران مقایسه شده است. برای این کار با کمک نرم‌افزار $MATLAB$ یک مدل شبکه‌ی عصبی پیشخور و با کمک نرم‌افزار $EvIEWS6$ یک مدل $ARMA$ برای دوره‌ی 1383/01/01 تا 1389/05/20 طراحی و

برآورد شده است. پس از برآورد مدل شبکه‌ی عصبی با متغیرهای موثر بر تقاضای روزانه آب شهر تهران (حداکثر، حداقل و میانگین دمای روزانه شهر تهران، روزهای هفته، روزهای خاص و ایام تعطیلات)، با ترکیب روش‌های $ARIMA$ شبکه‌ی عصبی مصنوعی و تبدیل موجک و با کمک معیارهای مرسوم، دقت سه مدل در پیش‌بینی تقاضای روزانه آب برای دوره‌ی 10 روزه ارزیابی و نتایج پایانی ارائه شده است.

2- پیشینه‌ی تحقیق

مطالعات پیش‌بینی آب بیشتر بر اساس مدل‌های آماری، رگرسیون چندگانه و سری‌های زمانی بوده و در سال‌های اخیر از شبکه‌ی عصبی برای پیش‌بینی استفاده شده است. در جدول (1) خلاصه‌ای از این مطالعات نشان داده شده است.

جدول 1: برخی مطالعات پیش‌بینی آب

سال	نویسنده	توضیحات
1985	میدمنت ¹ و دیگران	پیش‌بینی مصرف روزانه آب در شهر تگزاس با یک تابع انتقال
1999	استارک ² و دیگران	پیش‌بینی مصرف روزانه آب در شهر آلبرتای کانادا با شبکه‌ی عصبی
2002	یو ³ و دیگران	پیش‌بینی تقاضای آب در شهر سئول با یک شبکه‌ی عصبی سه لایه‌ی پیشخور
2005	بوگادیس ⁴	پیش‌بینی تقاضای آب در کانادا با سری زمانی و شبکه‌ی عصبی مصنوعی
2007	مسیزا ⁵ و دیگران	پیش‌بینی تقاضای آب شهری در آفریقای جنوبی با شبکه‌ی عصبی مصنوعی
2008	آداموسکی ⁶	پیش‌بینی تقاضای آب در کانادا با سری‌های زمانی و شبکه‌ی عصبی مصنوعی
1387	شرزهای و دیگران	پیش‌بینی تقاضای آب شهر تهران با الگوهای سری زمانی و شبکه‌ی عصبی
1389	تابش و دینی	برآورد تقاضای روزانه آب شهر تهران با شبکه‌ی عصبی مصنوعی
1386	عباسی نژاد و محمدی	پیش‌بینی نرخ های ارز

3- مبانی نظری تحقیق

3-1- مدل‌های $ARIMA$ و $ARMA$

الگوی $ARMA(p,q)$ مجموعی از ویژگی‌های دو الگوی خودرگرسیون و میانگین متحرک است. در این مدل p و q به ترتیب بیانگر تعداد جملات خودرگرسیون و تعداد جملات میانگین متحرک است. چنانچه سری زمانی مورد نظر با d بار

¹ Maidment

² Stark

³ Yu

⁴ Bougadis

⁵ Msiza

⁶ Adamowski

تفاضل‌گیری مانا گردد، سری زمانی اولیه‌ی یک فرآیند خود توضیح، جمعی میانگین متحرک از مرتبه‌ی p, d, q است که با $ARIMA(p, d, q)$ نشان داده می‌شود. فرآیند $ARIMA(p, d, q)$ برای متغیر y به صورت رابطه‌ی (1) است.

$$y_t = f(t) + \sum_{i=1}^p \hat{a}_i y_{t-i} + \sum_{j=1}^q \hat{a}_j e_{t-j} + e_t \quad (1)$$

در رابطه‌ی فوق $y_t = \Delta^d x_t = (1 - L)^d x_t$ و $f(t)$ برآورد کننده‌ی روند زمانی y_t (در صورت وجود) است. در اکثر متغیرهای اقتصادی، معمولاً $d=1$ بوده در نتیجه $f(t)=u$ و یا $d=0$ و $f(t) = a + dt$ است. برای تعیین d از آزمون مانایی استفاده می‌شود. تعداد جملات خودرگرسیو و میانگین متحرک با توابع خودهمبستگی⁷ (AC) و خودهمبستگی جزئی⁸ (PAC) و بر اساس مراحل باکس-جنکینز محاسبه می‌شود که دارای سه مرحله‌ی شناسایی، تخمین و تشخیص دقت پردازش است. مدل‌های مختلف مورد برآزش توسط ضابطه‌های آکائیک⁹ و یا شوارتز-بیزین¹⁰ بیزین می‌شود، به گونه‌ای که مدل مناسب باید کمترین آماره‌ی آکائیک و یا شوارتز-بیزین را داشته باشد.

3-2- مدل شبکه‌ی عصبی

در اواسط دهه‌ی 1980 میلادی الگوریتم‌های مربوط به شبکه‌های عصبی مصنوعی در حل مسائل واقعی به کار گرفته شدند. در واقع شبکه‌ی عصبی مصنوعی مجموعه‌ای از نرون‌های به هم متصل در لایه‌های مختلف است. این نرون‌ها اطلاعاتی را برای یکدیگر ارسال می‌کنند. نرون‌های مصنوعی واحدهای ساده‌ی پردازش اطلاعات هستند. تعداد زیادی از این نرون‌ها یک شبکه‌ی عصبی را می‌سازند. در نمودار (1) تصویری از یک نرون مصنوعی نشان داده شده است. مطابق این نمودار، ارتباطها (سیناپس‌ها) w_i ، منتقل کننده‌ی سیگنال‌ها (محرک‌ها) u_i به نرون هستند. وزن یا درجه‌ی اهمیت ورودی u_i است. در داخل نرون مجموع ورودی‌های موزون $w_i u_i$ لحاظ می‌شود. این مجموع، بزرگتر از حدآستانه‌ی خارجی q و تولید کننده‌ی نرون خروجی Z است.


⁷ Auto Correlation

⁸ Partial Auto Correlation

⁹ Akaike Information Criterion (AIC)

¹⁰ Schwartz Bayesian Criterion (SBC)

نمودار 1: نرون مصنوعی با تابع آستانه



مأخذ: بیل و جکسون (1383)

Z یک مقدار گسسته یا پیوسته و وابسته به تابع فعالیت است. در اکثر موارد، انتخاب یک تابع فعالیت خروجی، نرون را به برد $[0,1]$ یا $[-1,1]$ محدود می‌سازد. رابطه‌ی (2) شرح جامعی از نرون‌ها به صورت ریاضی است.

$$y = \sum_{i=1}^n w_i u_i - \theta \quad \& \quad z = y(y) \quad (2)$$

در رابطه‌ی فوق y ورودی خالص و $y(y)$ تابع فعالیت است.

به‌طور کلی پردازش اطلاعات توسط نرون‌ها و به وسیله‌ی یک پردازشگر ریاضی (تابع فعال‌سازی) انجام می‌گیرد. فرم خطی و یا غیر خطی تابع فعال‌سازی بر اساس نیاز خاص حل مسأله توسط طراح انتخاب می‌گردد. کاربرد توابع فعال‌سازی غیرخطی اجازه می‌دهد که شبکه، الگوهای غیرخطی مناسبی از مجموعه‌ی داده‌های پیچیده تولید نماید. رایج‌ترین تابع فعال‌سازی در شبکه‌های عصبی مصنوعی، تابع توزیع تجمعی لجستیک یا تابع سیگموئید به صورت رابطه‌ی (3) است.

$$j_x = \frac{1}{1 + e^{-a(x)}} \quad (3)$$


این تابع لجستیک، پیوسته و مشتق‌پذیر با بُرد $[0,1]$ است، به‌طوری که با نزدیکی تابع به یک، نرون نسبت به علائم دریافتی پاسخ سریع می‌دهد، اما با میل تابع به صفر، نرون به علائم دریافتی واکنش کُندی دارد.

در طراحی شبکه (تنظیم بین نرون‌ها و سیناپس‌ها)، یک ارتباط قوی بین الگوریتم یادگیری و ساختار شبکه وجود دارد که طراحی را در مرکزیت قرار می‌دهد.

در این تحقیق از شبکه‌ی عصبی پیشخور استفاده شده است. یک شبکه‌ی عصبی نوعی، متشکل از چندین لایه است. در یک شبکه‌ی دو لایه‌ای یک لایه‌ی

ورودی از منبع نرون‌ها و یک لایه‌ی خروجی از نرون‌ها وجود دارد. یک شبکه‌ی عصبی چند لایه، یک یا چند لایه‌ی پنهانی از نرون‌ها را در کنار لایه‌ی ورودی و خروجی دارد. نمایشی از شبکه‌ی عصبی سه لایه‌ای در نمودار (2) نشان داده شده است.

نمودار 2: نمایش شبکه‌ی عصبی با 3 لایه‌ی ورودی، پنهان و خروجی



مأخذ: بیل و جکسون (1383)

در ساختار شبکه‌ی عصبی نمودار (2) لایه‌هایی که مستقیماً به داده‌های ورودی و نتایج خروجی متصل نیستند را لایه‌های مخفی یا پنهان می‌نامند. این لایه‌ها، با افزایش توان شبکه، موجب اخذ نتایج بهتر از داده‌های ورودی می‌شوند. اگر هر نرون در هر لایه شبکه به نرون دیگری در لایه‌ی مجاور جلویی متصل باشد، آن شبکه‌ی دارای اتصال کامل است. شبکه‌ی عصبی پیشخور با یک لایه‌ی پنهان، تابع فعال‌ساز سیگموئید در لایه‌ی پنهان، تابع فعال‌ساز خطی در لایه‌ی خروجی و تعداد نرون‌های کافی در لایه‌ی پنهان، قادر است هر تابعی را با دقت دلخواه تقریب بزند. در این حالت، شبکه‌ی عصبی را تقریب‌زن جامع می‌گویند (اصغری اسکویی، 1381 و رحمانی و اسماعیلی، 1389).


3-3- مبانی نظری مدل ترکیبی

مدل ترکیبی در این مقاله، ترکیب مدل‌های *ARIMA* و تبدیل موجک با شبکه‌های عصبی مصنوعی است. در این روش، ابتدا با کمک موجک (از نوع دبوچی)، سری زمانی تا سطحی تجزیه می‌شود که سطح تقریباً هموار و به‌صورت یک خط نسبتاً راست درآید. چون مدل *ARIMA* در پیش‌بینی سری‌های خطی قدرت بالایی دارد، این سری به‌وسیله‌ی آن قابل پیش‌بینی است. سپس از حاصل جمع توابع مولفه‌ها یک سری بدون روند (فقط شامل نوسانات در طول دوره) به‌دست می‌آید (سری

اصلی = سری سطح هموار شده (تقریبی) + مجموع سری‌های توابع جزئیات (مولفه‌ها)).

در ادامه عوامل موثر بر این نوسانات، به‌عنوان ورودی به شبکه‌ی عصبی وارد می‌شود و نوسانات به‌عنوان خروجی آن تعیین می‌شود. در نهایت برای 10 روز بعدی، از حاصل جمع روند خطی پیش‌بینی شده توسط ARIMA با نوسانات پیش‌بینی شده توسط شبکه‌ی عصبی، پیش‌بینی سری اصلی قابل استخراج است. در این مدل سه مدل خطی و غیرخطی ARIMA، شبکه‌ی عصبی و تبدیل موجک قابل ترکیب است. بنابراین نقاط ضعف هر مدل پیش‌بینی با نقاط قوت مدل دیگر قابل حذف یا کم شدن است. همچنین این مدل با لحاظ سری‌زمانی افزایش دهنده‌ی قدرت پیش‌بینی سری زمانی است. در نمودار (3)، نمای کلی مدل پیشنهادی نشان داده شده است.

نمودار 3: ساختار مدل ترکیبی موجک



4- طراحی و تخمین مدل‌ها

در این بخش پس از طراحی و آماده‌سازی مدل‌ها، به تخمین مدل ARIMA آموزش و مدل‌سازی شبکه‌ی عصبی مصنوعی؛ و مدل‌سازی الگوی ترکیبی برای داده‌های سری زمانی مصرف آب شهری تهران طی دوره‌ی 1383/01/01 تا 1389/05/20 بر اساس هر روش به پیش‌بینی تقاضای آب شهری به دو صورت "مجموع 10 گام" و "یک گام به‌جلو تا ده گام به‌جلو" پرداخته شده است. دلیل استفاده از پیش‌بینی نوع گام‌به‌گام (روز یکم تا روز دهم) این است که هرچند یک مدل، می‌تواند در طول 10 گام پیش‌بینی، در چند گام اول نسبت به مدل دیگری

از قدرت پیش‌بینی بالاتری برخوردار باشد، اما در ارزیابی مجموع 10 گام این گونه نباشد، که توانایی پیش‌بینی این مدل در نوع دوم نادیده گرفته می‌شود (هر گام معرف یک روز است. به عنوان مثال در گام دوم مدل‌های مذکور برای دو روز آینده و در گام هفتم مدل‌ها برای 7 روز آینده پیش‌بینی می‌کنند).

4-1- ARIMA

برای پیش‌بینی داده‌های سری زمانی در فرآیند $ARMA(p,d,q)$ ابتدا مانایی سری زمانی بررسی شده و مرتبه‌ی انباشتگی (d) تعیین شده است. در تحقیق حاضر، برای تخمین مدل $ARIMA$ ، از نرم‌افزار *Eviews* استفاده شده است. نتایج آزمون مانایی سری زمانی تقاضای روزانه آب، بر اساس آزمون ریشه‌ی واحد دیکی فولر تعمیم یافته در جدول (2) نشان داده شده است. بر طبق نتایج، سری زمانی تقاضای روزانه آب شهری با یکبارتفاضل گیری، در سطح 5 درصد ایستا بوده است.

جدول 2: نتایج مربوط به آزمون ریشه‌ی واحد دیکی فولر پیشرفته

توضیحات	P value	آماره t	مرتبه تفاضل گیری
نا ایستایی	0/4610	-2/163882	(0)
ایستایی در سطح 5 درصد	0/0131	-4/926929	(1)

مأخذ: محاسبات تحقیق

پس از بررسی ایستایی تعداد جملات خودرگرسیو (p) و تعداد جملات میانگین متحرک (q)، با کمک توابع خودهمبستگی و خودهمبستگی جزئی مطابق روش باکس-جنکینز و با تصریح مدل‌های مختلف محاسبه و نتایج آن در جدول (3) ارائه شده است. مطابق نتایج، همه‌ی جملات خودرگرسیو و میانگین متحرک به‌جز جملات $AR(3)$ و $AR(4)$ در سطح خطای یک درصد به لحاظ آماری معنادار بوده است.

جمله $AR(4)$ در سطح خطای 5 درصد معنادار بوده است. بر اساس مقدار آماره‌ی F کل مدل از لحاظ آماری معنادار بوده است. بر اساس مقدار آماره R^2 ، تقاضای آب روزهای گذشته و جملات اخلاص مذکور در جدول (3)، بیش از 90

درصد تغییرات تقاضای روزانه آب شهری را با توجه به نوسانات نامنظم سری زمانی، توضیح داده است.

جدول 3: نتایج حاصل از برآورد مدل *ARIMA* برای دوره (1383/01/01 تا 1389/05/20)

نام متغیر	ضریب	خطای معیار	آماره t	P value
C	2950033/0	156821/9	18/81136	0/0000
$AR(1)$	0/990192	0/070078	14/12988	0/0000
$AR(2)$	-0/292199	0/055691	-5/246792	0/0000
$AR(3)$	0/031209	0/019554	1/596058	0/1106
$AR(4)$	-0/013698	0/016881	-0/811458	0/0172
$AR(6)$	-0/033633	0/016901	-1/989980	0/0067
$AR(7)$	0/811491	0/022323	36/35251	0/0000
$AR(8)$	-0/923791	0/068299	-13/52575	0/0000
$AR(9)$	0/290964	0/048900	5/950215	0/0000
$AR(364)$	0/120613	0/012425	9/707037	0/0000
$MA(1)$	-0/373294	0/067831	-5/503279	0/0000
$MA(2)$	0/132916	0/032622	4/074475	0/0000
$MA(3)$	0/089008	0/029838	2/982990	0/0029
$MA(4)$	0/118166	0/026908	4/391538	0/0000
$MA(5)$	0/070218	0/023999	2/925853	0/0035
$MA(6)$	0/103231	0/029623	3/484853	0/0005
$MA(7)$	-0/577573	0/033907	-17/03428	0/0000
$MA(8)$	0/446936	0/050425	8/863380	0/0000
	$F=1092/537$		$R^2=0/9043$	

مأخذ: محاسبات تحقیق

4-2- مدل شبکه‌ی عصبی مصنوعی

برای طراحی شبکه‌های عصبی در این تحقیق، نرون‌های ورودی (متغیرهای موثر) درجه‌ی دمای هوا در قالب سه ورودی حداقل دما، حداکثر دما و میانگین دمای روزانه و روزهای هفته در نظر گرفته شده است. به‌طور معمول در روزهای پنجشنبه به دلیل فعالیت پاره وقت و تعطیلی برخی موسسات مصرف آب تا حدودی کاهش داشته است. در اکثر روزهای جمعه علی‌رغم افزایش مصرف خانوارها، به دلیل تعطیلی فعالیت‌های اقتصادی، مصرف آب کاهش داشته است. همچنین در آغاز هفته مصرف آب نسبت به بقیه‌ی روزها به‌دلیل شروع فعالیت‌های اقتصادی افزایش داشته است. در بقیه‌ی روزهای هفته (ایام تعطیلات و روزهای خاص مانند ماه رمضان) نوسان در مصرف وجود داشته است. بنابراین 12 نرون در

لایه‌ی ورودی لحاظ شده است. جدول (4) نحوه‌ی مدل‌سازی تقاضای روزانه آب شهری را در شبکه‌ی عصبی چندلایه پیشخور (MFNN) نشان داده شده است. مطابق این نتایج، تعداد 18 نرون در لایه‌ی مخفی و یک نرون در لایه‌ی خروجی آن استفاده شده است. پس از تعیین تعداد وقفه‌های بهینه، برای انتخاب تعداد نرون‌های لایه‌ی مخفی، شبکه‌های مختلف با تعداد نرون‌های مخفی متفاوت طراحی و آموزش داده شده است. با توجه به معیار MSE ، شبکه‌ی بهینه با کمترین MSE حاوی 18 نرون مخفی انتخاب شده است. تعداد داده‌های ورودی، 12 نرون و تابع فعال‌سازی از نوع سیگموئید بوده است.

جدول 4: طراحی و مدل‌سازی تقاضای روزانه آب شهری در شبکه‌ی عصبی

نوع شبکه عصبی	پیشخور چندلایه‌ای	الگوریتم آموزش شبکه‌های عصبی	لونیبرگ - مارکوات
تابع فعال‌سازی	سیگموئید	روش توقف فرآیند آموزش	توقف سریع
تعداد نرون ورودی	12	دوره زمانی آموزش و آزمایش	1383/01/01 - 1389/05/20
تعداد نرون خروجی	1	نسبت تعداد داده‌های آموزش و آزمایش	0/05 به 0/95
معیار تعیین تعداد نرون‌های مخفی	MSE	نرخ یادگیری	0/01
تعداد لایه پنهان	1	دوره زمانی پیش‌بینی	1389/05/20 - 1389/05/30
تعداد نرون‌های پنهان	18		


مأخذ: محاسبات تحقیق

از میان الگوریتم‌های مختلف در آموزش شبکه‌های عصبی، الگوریتم لونیبرگ - مارکوات انتخاب شد. زیرا این الگوریتم در مقایسه با سایر الگوریتم‌های پس‌انتشار خطا، سرعت بیشتری دارد. دوره‌ی آموزش و آزمایش، شامل 2346 داده بوده است. تعداد داده‌های آموزش و آزمایش مدل به نسبت 0/95 به 0/05 تقسیم و از نرخ یادگیری 0/01 استفاده شده است. برای توقف فرآیند آموزش از روش توقف سریع بهره گرفته شده است. در نهایت شبکه‌ی عصبی با استفاده نرم‌افزار MATLAB طراحی شده است.


4-3- مدل ترکیبی با استفاده از تبدیل موجک

در این مطالعه روش‌های غیرخطی تبدیل موجک و شبکه‌ی عصبی با روش خطی ARIMA ترکیب شده است. استفاده از روش ARIMA در کنار روش‌های غیرخطی،

سبب می‌شود سری هموار شده با مدل تبدیل موجک دقیق‌تر از مدل‌های غیرخطی پیش‌بینی گردد. در این فرآیند، ابتدا با استفاده از موجک (از نوع دبوچی)، سری زمانی تا سطحی تجزیه می‌شود که سطح تقریباً هموار به صورت یک خط نسبتاً راست درآید. چون مدل $ARIMA$ در پیش‌بینی سری‌های خطی قدرت بالایی دارد، این سری به وسیله مدل $ARIMA$ برای 10 روز بعدی پیش‌بینی می‌شود. در نمودار (4) سطح تقریباً هموار برای تقاضای روزانه آب نشان داده شده است.



بر اساس آزمون ریشه‌ی واحد، سری زمانی هموار شده تقاضای روزانه آب در دوره‌ی 1383/01/01 تا 1389/05/20 با یکبار تفاضل‌گیری در سطح یک درصد مانا شده است. تعداد جملات خودرگرسیو (p) و میانگین متحرک (q), با کمک توابع خودهمبستگی و خودهمبستگی جزئی و روش باکس-جنکینز محاسبه شده است. کمترین مقدار آکائیک، مربوط به فرآیند $ARIMA(4,1,2)$ بوده است. نمودار (5) بر اساس مجموع سایر توابع جزئیات سری بدون روند استخراج شده است.




در این تحقیق عوامل موثر بر نوسانات تقاضای روزانه آب (روزهای هفته، حداقل و حداکثر درجه‌ی دما و ایام تعطیلات یا روزهای خاص) نیز تعیین شده است. در طراحی شبکه‌ی عصبی، کمینه و بیشینه‌ی دما در شهر تهران به‌صورت روزانه، روزهای هفته با 7 مشخصه و ایام تعطیلات و روزهای خاص با توجه به تقویم شمسی و قمری با عدد یک و بقیه‌ی روزها با عدد صفر به‌کار برده شده است. چون یکی از نرون‌های ورودی روند زمان است، شدت مصرف با توجه به زمان طراحی شده است. برای مثال به دلیل تفاوت شدت مصرف آب در 22 بهمن و 13 فروردین، نرون زمان (روند) اثر این اختلاف در طراحی شبکه دخالت داده شده است. در نهایت برای 10 روز آتی، از حاصل جمع روند خطی پیش‌بینی شده با $ARIMA$ و نوسانات پیش‌بینی شده با شبکه‌ی عصبی، پیش‌بینی سری اصلی استخراج شده است.

5- ارزیابی مدل‌ها

نمودار (6) مقادیر پیش‌بینی تقاضای روزانه آب برای 10 روز آتی نشان داده شده است. مطابق نتایج این نمودار اثر تعطیلات در پیش‌بینی با مدل $ARIMA$ کم‌رنگ‌تر بوده است. در حالی که پیش‌بینی‌های شبکه‌ی عصبی و مدل ترکیبی تبدیل موجه، وضعیت نسبتاً یکنواختی داشته و نسبت به روش $ARIMA$ اثر تعطیلات غالب‌تر بوده است.

نمودار 6: مقادیر پیش‌بینی شده تقاضای روزانه‌ی آب برای 10 روز آتی



مأخذ: محاسبات تحقیق

به منظور مقایسه‌ی قدرت پیش‌بینی مدل‌های *ARIMA*، شبکه‌ی عصبی مصنوعی و مدل ترکیبی موجد از معیار میانگین درصد قدرمطلق خطا (*MAPE*) به‌صورت گام به‌گام (روز یکم تا روز دهم) و مجموع 10 روز و از ضریب تعیین (R^2) فقط برای مجموع 10 روز استفاده شده است. این معیارها بر اساس داده‌های واقعی مصرف روزانه آب شهری تهران در دوره‌ی 1383/01/1 تا 1389/05/30 به کار رفته‌اند. دلیل استفاده از دو معیار در پیش‌بینی‌ها این است که یک مدل ممکن است در چند روز اول از دوره‌ی ده روزه، نسبت به بقیه‌ی مدل‌ها قدرت پیش‌بینی بالاتر اما در ارزیابی مجموع 10 روز توان پیش‌بینی کمتری داشته باشد. در جدول (5) قدرت پیش‌بینی مدل‌های سه‌گانه تحقیق با معیار *MAPE* و R^2 برای دوره‌ی 1389/05/20 تا 1389/05/30 نشان داده شده است. مطابق معیار *MAPE*، مدل‌های *ARIMA* و شبکه‌ی عصبی خطای پیش‌بینی بالایی داشته‌اند. در حالی که خطای مدل ترکیبی تبدیل موجد کمتر بوده است. براساس معیار R^2 نیز مدل‌های ترکیبی تبدیل موجد، شبکه‌ی عصبی و *ARIMA* به ترتیب دارای توضیح دهنده‌گی بیشتر به کمتر بوده است.

جدول 5: مقایسه‌ی مدل‌های پیش‌بینی برای مجموع 10 روز

مدل پیش‌بینی	<i>MAPE</i>	R^2
<i>ARIMA</i>	2/02	0/80
<i>ANN</i>	0/91	0/97
<i>Wavelet</i>	0/79	0/99

مأخذ: محاسبات تحقیق

در جدول (6) قدرت پیش‌بینی مدل‌ها بر اساس معیار *MAPE* برای دوره‌ی 10 روزه 1389/05/20 تا 1389/05/30 به‌صورت گام‌به‌گام نشان داده شده است.

جدول 6: قدرت پیش‌بینی مدل‌های پیش‌بینی براساس معیار ارزیابی *MAPE*

Wavelet	ANN	ARIMA	پیش‌بینی / مدل
0/00	0/01	0/13	یک گام به جلو
0/16	0/06	0/25	دو گام به جلو
0/17	0/07	0/42	سه گام به جلو
0/20	0/09	0/43	چهار گام به جلو
0/26	0/25	0/43	پنج گام به جلو
0/47	0/48	0/76	شش گام به جلو
0/59	0/71	1/13	هفت گام به جلو
0/69	0/83	1/41	هشت گام به جلو
0/71	0/87	1/73	نه گام به جلو
0/79	0/91	2/02	ده گام به جلو

مأخذ: محاسبات تحقیق

بر اساس نتایج جدول (6) برای گام سوم، قدرت پیش‌بینی مجموع سه روز اول و برای گام ششم، قدرت پیش‌بینی مجموع شش روز اول ارزیابی شده است. با توجه به نتایج، فرآیند *ARIMA* در همه‌ی گام‌ها، بیشترین خطای پیش‌بینی را با معیار *MAPE* داشته است. این خطا از گام اول تا گام پنجم تفاوت زیادی با سایر مدل‌ها نداشته است. در حالی که از گام پنجم به بعد خطای مدل نسبت به سایر مدل‌ها روند فزاینده داشته است. مدل شبکه‌ی عصبی پیشخور در گام‌های دوم، سوم، چهارم و پنجم خطای کمتری نسبت به مدل ترکیبی و در سایر گام‌ها خطای پیش‌بینی بیشتری نسبت به مدل ترکیبی داشته است. از این رو مدل ترکیبی تبدیل مویک با خطای پیش‌بینی کمتر در شش گام از ده گام، مدل بهینه است. با توجه به جدول (6)، مدل ترکیبی مطابق همه‌ی معیارهای ارزیابی، در شش گام اول پیش‌بینی بهتری داشته است. مدل شبکه‌ی عصبی مصنوعی با خطای پیش‌بینی کمتر در همه‌ی گام‌ها نسبت به مدل *ARIMA* برتری کامل داشته است.

7- نتیجه‌گیری

در مطالعه‌ی حاضر برای پیش‌بینی مصرف روزانه آب شهری تهران، عوامل موثر بر تقاضای روزانه آب شهری (حداکثر، حداقل و میانگین دمای روزانه در شهر تهران و همچنین روزهای تعطیلات و روزهای خاص) مورد بررسی قرار گرفته است. تقاضای روزانه‌ی آب شهری برای 10 روز آینده، به دو صورت مجموع 10 روز و گام‌به‌گام (روز یکم تا روز دهم) بر اساس مدل‌های *ARIMA*، شبکه‌ی عصبی

مصنوعی پیشخور و مدل ترکیبی تبدیل موجک پیش‌بینی شده است. در این تحقیق با ارزیابی مقادیر پیش‌بینی شده توسط معیار $MAPE$ در پیش‌بینی گام‌به‌گام و R^2 و $MAPE$ در پیش‌بینی مجموع 10 روزه، مدل ترکیبی تبدیل موجک، مدل بهینه شناخته شده است. همچنین مدل‌های شبکه عصبی و خطی $ARIMA$ به ترتیب در رتبه‌های بعدی قرار گرفته‌اند.

برقراری توازن بین عرضه و تقاضای آب با پیش‌بینی‌های دقیق طرف تقاضا امکان‌پذیر است. به دلیل دقت بالای پیش‌بینی تقاضای روزانه‌ی آب شهری در ترکیب مدل‌های خطی و غیرخطی، توجه به مدل ترکیبی تبدیل موجک به عنوان یک روش قوی پیش‌بینی در برنامه‌ریزی و مدیریت آبرسانی شهری دارای اهمیت است. این مدل در اجرای سیاست‌های مدیریت مصرف آب مثل جیره‌بندی، زمان‌بندی قطع و وصل شیرآلات و پمپ‌ها، زمان‌بندی تعمیرات در تأسیسات آب و فاضلاب قابل استفاده است. ماهیت نوسانی مصرف آب در مناسبت‌ها و ایام خاص مثل روزهای آخر هفته، اعیاد مذهبی و جشن‌ها به آسانی در قالب مدل ترکیبی تبدیل موجک قابل بررسی و ارزیابی است.

فهرست منابع:

- اصغری اسکویی، محمدرضا. (1381). کاربرد شبکه های عصبی در پیش بینی سری های زمانی. پژوهشهای اقتصادی ایران، 4(12): 69-96.
- بیل، راسل و تام جکسون. (1383). آشنایی با شبکه‌های عصبی. ترجمه محمود البرزی. چاپ اول، تهران: موسسه انتشارات علمی دانشگاه صنعتی شریف.
- پیکتن، فیلیپ. (1383). شبکه‌های عصبی (اصول و کاربردها). ترجمه مهدی غضنفری و جمال ارکات، چاپ اول، تهران: موسسه انتشارات دانشگاه علم و صنعت ایران.
- تابش، مسعود و مهدی دینی. (1389). پیش بینی تقاضای روزانه آب شهری با استفاده از شبکه عصبی مصنوعی، مطالعه موردی: شهر تهران. مجله آب و فاضلاب، 1: 84-95.
- تابش، مسعود، مهدی دینی، علی جعفر خوش خلق و بنفشه زهرایی. (1387). برآورد مصرف روزانه آب تهران با استفاده از سری‌های زمانی. تحقیقات منابع آب ایران، 4(2): 57-65.
- رحمانی، علی و غریبه اسماعیلی. (1389). کارایی شبکه‌های عصبی، رگرسیون لجستیک و تحلیل تمایزی در پیش بینی نکول. اقتصاد مقداری (بررسی‌های اقتصادی سابق)، 7 (4): 151-172.
- شرزه‌ای غلامعلی، مهدی احراری و حسن فخرائی. (1387). پیش بینی تقاضای آب شهر تهران با استفاده از الگوی ساختاری، سری‌های زمانی و شبکه عصبی نوع *GMDH*. مجله تحقیقات اقتصادی، 84: 151-175.
- عباسی‌نژاد، حسین و احمد محمدی. (1386). پیش‌بینی نرخ ارز با استفاده از شبکه‌های عصبی و تبدیل موجک. نامه اقتصادی، 3 (1): 19-42.
- گجراتی، دامودار. (1385). مبانی اقتصاد سنجی، جلد دوم. ترجمه حمید ابریشمی. تهران: موسسه انتشارات و چاپ دانشگاه تهران.

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.

Bougadis, J., K. Adamowski & R. Diduch. (2005). Short-Term Municipal Water Demand Forecasting. Hydrological Processes, 19(1): 137-148.

Maidment, D. R., S. P. Miaou & M. Crawford. (1985). Transfer Function Models of Daily Urban Water Use. Journal of Water Resources Research, 21(4): 425-432.

Msiza, I.S., F.V. Nelwamondo & T. Marwala. (2007). Water Demand Forecasting Using Multi-Layer Perceptron and Radial Basis Functions. Proceedings of International Joint Conference on Neural Networks, Orlando, Florida, USA, August 12-17.

- Stark H.L., S.J. Stanley & I.D. Buchanan. (1999). Water Demand Forecasting Using Artificial Neural Networks. OWWA Conference paper, Ottawa.
- Yu, M.J., C.N. Joo & J.Y. Koo. (2002). Application of Short-Term Water Demand Prediction Model to Seoul. Journal of Water Science & Technology, 46 (6-7): 255-261.