

مدل سازی و پیش بینی کوتاه مدت تقاضای آب شهری

تاریخ دریافت: ۸۹/۰۱/۱۵

تاریخ تأیید: ۸۹/۰۷/۱۲

حسین صادقی^۱

استادیار اقتصاد دانشگاه تربیت مدرس

مهدی ذوالفقاری^۲

دانشجوی دکتری اقتصاد نظری دانشگاه تربیت مدرس

رحمان آرام^۳

کارشناس ارشد اقتصاد انرژی دانشگاه صنعت آب و برق

چکیده

آب به عنوان یکی از مهم ترین منابع تأمین نیاز بشر در زندگی روزمره نقش حیاتی ایفا می کند. لذا آگاهی از میزان تقاضای مورد نیاز آب جهت اعمال سیاست گذاری های لازم در راستای مدیریت تقاضا، از اهمیت ویژه ای برخوردار می باشد. در این مقاله، تقاضای روزانه آب شهر تهران برای یک دوره هفت ساله با استفاده از روش های غیر خطی شبکه عصبی مصنوعی و فرایند خطی ARMA مدل سازی گردید و در ادامه تقاضای روزانه آب شهری برای ده روز آینده پیش بینی گردید. در طراحی شبکه عصبی مصنوعی، عوامل مؤثر 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 بکارگیری معیارهای ارزیابی دقت پیش بینی، نشان می دهد که شبکه عصبی مصنوعی در پیش بینی تقاضای روزانه آب شهر تهران نسبت به مدل ARMA از قدرت بالاتری برخوردار می باشد.

واژگان کلیدی: تقاضای آب، پیش بینی، شبکه های عصبی مصنوعی، ARMA

طبقه بندی موضوعی: C5, C53

مقدمه

آب با توجه به اثر کلیدی در رفاه و سلامت جامعه و نقش تعیین کننده ای که در فعالیت ها و رشد جوامع داشته است، به عنوان یکی از مهم ترین منابع طبیعی شناخته می شود. در سال های اخیر مشکل کمیابی منابع آب به صورت افزایش رقابت برای دستیابی به منابع آب که منجر به افزایش هزینه استفاده از آب می شود، وجود داشته است. با افزایش روزافزون جمعیت در جهان، کمبود آب بیش از پیش خودنمایی می کند. برداشت بی رویه از منابع زیرزمینی، کاهش بارش و بروز خشکسالی در اکثر نقاط جهان و آلودگی آب های سطحی و زیرزمینی، بر شدت کمبود منابع

1. Email: sadeghih@modares.ac.ir

2. Email: zolfaghari_mahdi@yahoo.com

3. Email: a.rahman@yahoo.com

آب افزوده‌اند. بنابراین استفاده از این منبع حیاتی مستلزم اعمال مدیریت صحیح می‌باشد. سیاست‌های مدیریت تقاضای آب اساساً شامل، حداقل کردن تلفات در سیستم‌های نگهداری و انتقال، استفاده دوباره از آب، کاهش مصرف آب از طریق اجتناب کردن از اسراف آب، استفاده صحیح و کارا از منابع آب می‌باشد.

پیش‌بینی تقاضای آب شهری کمک مؤثری به مدیران و بهره‌برداران 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. پیش‌بینی بلندمدت و میان‌مدت 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 بهره‌برداری بهینه از شبکه اهمیت بسزایی دارد و در اجرای سیاست‌های طرف تقاضا مانند جیره‌بندی، زمانبندی قطع وصل پمپ‌ها و شیرآلات، زمانبندی تأسیسات آب و فاضلاب مؤثر می‌باشد.

ضرورت پیش‌بینی مصرف آب به این دلیل است که پیش‌بینی میزان مصرف آب می‌تواند تا حدودی دولت را از مواجه شدن با مشکلات ناشی از کمبود آب مصون نگه دارد. همچنین در مدیریت آب شهری دانستن تقاضای کوتاه‌مدت بسیار مهم و حیاتی است (تابش، ۱۳۸۶). به عبارتی برخی از خصوصیات بررسی سیاست‌های مدیریت تقاضا و مدیریت عملیاتی سیستم توزیع آب به این پیش‌بینی وابسته‌اند. از طرفی کمبود آب و نقش آن در کشورهایی مانند ایران که سرانه آب تجدیدپذیر کمتر از هزار متر مکعب را پیش رو دارند، اهمیت پیش‌بینی کوتاه‌مدت مصرف آب را بیشتر می‌کند.

روش‌های مختلفی برای پیش‌بینی متغیرهای سری زمانی وجود دارد. اقتصاددانان برای برآورد تابع تقاضا غالباً از روش‌های اقتصادسنجی استفاده می‌کنند. در حالت کلی روش‌های پیش‌بینی را می‌توان به دو دسته خطی و غیرخطی تقسیم‌بندی نمود. با این حال پرکاربردترین روش‌های پیش‌بینی خطی، روش‌های فرایند خطی $ARMA^1$ و $ARIMA^2$ می‌باشد. در سال‌های اخیر به موازات پیشرفت‌های قابل توجه در پردازش سریع اطلاعات به وسیله ماشین‌های الکترونیکی، بکارگیری مدل‌ها غیرخطی در میان اقتصاددانان به طور چشمگیری افزایش یافته است. مدل شبکه‌های عصبی از معروف‌ترین این مدل‌های می‌باشد که استفاده از آن در اقتصاد کلان در دهه ۹۰ مورد

1. AutoRegressive Moving Average
2. Regressive Integrated Moving Average-Auto

توجه پژوهشگران قرار گرفت. امروزه از بین روش‌های پیش‌بینی، شبکه‌های عصبی مصنوعی یکی از ابزار قدرتمند برای تجزیه و تحلیل و مدل‌سازی روابط غیرخطی به حساب می‌آید.

در بخش دوم این مقاله پیشینه تحقیق ارائه می‌گردد. بخش سوم به معرفی مبانی نظری شبکه‌های عصبی و مدل‌های ARMA و ARIMA می‌پردازد. در بخش چهارم به مدل‌سازی و تخمین مدل‌های مذکور با استفاده از داده‌های روزانه تقاضای آب شهر تهران، برای دوره ۱۳۸۲/۱/۱ تا ۱۳۸۸/۸/۳۰ پرداخته می‌شود و تقاضای روزانه آب شهری توسط مدل‌های مذکور در بازه زمانی یک گام تا ده گام به جلو پیش‌بینی می‌گردد. در بخش پنجم با بکارگیری معیارهای سنجش به ارزیابی قدرت پیش‌بینی مدل‌های فوق پرداخته و در بخش ششم نتایج ارائه می‌گردد. در طراحی شبکه عصبی عوامل مؤثر بر تقاضای روزانه آب شهری؛ دما هوا در قالب ۳ ورودی حداقل، حداکثر و میانگین دما، روزهای هفته، ایام تعطیلات و روزهای خاص در نظر گرفته شده است.

۱- پیشینه تحقیق

مطالعات صورت گرفته در زمینه پیش‌بینی آب بیشتر بر اساس مدل‌های آماری، رگرسیون چندگانه، سرهای زمانی می‌باشد. در سال ۱۹۸۴ مصرف ماهیانه (میان‌مدت) 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 فوریه تخمین زدند. آن‌ها برای مدل کردن مؤلفه تصادفی از دو معادله استفاده نمودند که این معادلات همبستگی مصرف آب با متغیرهای آب و هوایی، نظیر حداکثر درجه حرارت ماهانه، تبخیر و بارش را بررسی می‌کرد. میدمنت و همکارانش در سال ۱۹۸۵ یک تابع انتقال برای پیش‌بینی مصرف روزانه آب برای شهر تگزاس به کار بردند. همچنین آن‌ها یک مدل مصرف کوتاه‌مدت توسط سری‌های زمانی طراحی نمودند که در آن از اطلاعات بلندمدت به صورت توأم استفاده گردید.

استفاده از شبکه عصبی در سال ۲۰۰۰ توسط استارک و همکارانش^۲ (۲۰۰۲) برای شهر آلبرتا در کانادا به کار رفت. آن‌ها به وسیله یک مدل عصبی سه لایه مصرف روزانه و مصرف ده

1. Maidment&parzen
2. Stark & et al

روز آتی آب را با استفاده از پارامترهای هواشناسی پیش‌بینی نمودند. پارامترهای به کار رفته در این تحقیق شامل ماکزیمم و مینیومم درجه حرارت، بارش روز گذشته، مجموع بارش پنج روز و سی روز گذشته، اندیس تعطیلی و غیر تعطیلی بود.

جین و همکاران^۱ (۲۰۰۱) با استفاده از شبکه عصبی مصنوعی، به پیش‌بینی تقاضای کوتاه‌مدت آب شهر کانپور (هند) پرداختند. متغیرهای ورودی در این مطالعه شامل تقاضای آب، میانگین دمای هوا و مقدار بارندگی در هفته بود. در این مطالعه 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 تقاضای آب در شهر سئول استفاده کردند. در این تحقیق برای هر فصل از سال به طور جداگانه مدل‌سازی انجام گرفت و از ماکزیمم 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 بردند. آن‌ها از پارامترهای اقتصادی نرمالیزه نظیر درآمد سرانه، تعداد افراد خانوار، و قیمت آب برای این منظور استفاده کردند.

پیلای^۵ (۲۰۰۵) در پایان‌نامه خود تحت عنوان «پیش‌بینی کوتاه‌مدت تقاضای آب برای بهینه‌سازی تولید» به پیش‌بینی تقاضای آب برای ۲۴ ساعت آینده شهر توومبا^۶ پرداخت. نتایج حاصل از این مطالعه جامع بود و 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 تحمیلی قرار گرفته است.

کستاس و چریس توموس^۷ (۲۰۰۶) در مقاله خود تحت عنوان «تخمین تعیین‌کننده‌های تقاضای آب مسکونی شهر و پیش‌بینی تقاضای آب» برای بخش‌های مرکزی آتن تأثیرات متغیرهای درآمد و قیمت آب را روی تقاضای آب مورد بررسی قرار دادند. نتیجه آنکه هنگامی که دیگر عوامل اقتصادی تأثیر چندانی بر مصرف آب ندارند، انتظار افزایش درآمد در آینده موجب افزایش تقاضای آب می‌شود.

1. Jain and et al
2. Yu and et al
3. Liu and et al
4. weiyao
5. Pillay
6. Toovoomba
7. Kostas & Chrysostomos

وامورسی و خاطری^۱ (۲۰۰۹) در مطالعه خود با معرفی مدلی به بررسی ارتباط بین تقاضای آب شهر بیرمنگام با شرایط آب و هوایی، آلودگی و رشد اقتصادی پرداختند. نتایج این تحقیق نشان داد که تقاضای آب در آینده برای بیرمنگام به وسیله فاکتورهای اقتصادی - اجتماعی متأثر خواهد شد و متأثر از تغییرات آب و هوا نیست.

از جمله مطالعات داخلی صورت گرفته می‌توان به مطالعه گوشه (۱۳۸۲) اشاره کرد، که پس از بررسی عوامل مؤثر بر تقاضای آب شهری، به پیش‌بینی تقاضای کوتاه‌مدت 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 کوتاه‌مدت آب شهری نشان داد که الگوی شبکه عصبی مصنوعی عملکرد بهتری نسبت به الگوهای فازی در پیش‌بینی تقاضای آب در شهر تهران داشته است.

تابش و همکاران (۱۳۸۶) در مقاله خود تحت عنوان «پیش‌بینی تقاضای کوتاه‌مدت شهر تهران با استفاده از شبکه‌های عصبی مصنوعی» با استفاده از شبکه‌های عصبی پرسپترون چند لایه و با الگوریتم آموزشی پس انتشار خطا، میزان مصرف یک روزه آب شهر تهران را بر اساس پارامترهای هواشناسی و داده‌های تاریخی مصارف گذشته پیش‌بینی نمودند. در این مقاله همچنین با استفاده از شبکه‌های عصبی مصنوعی، یک فرمول ساده برای پیش‌بینی میزان مصرف آب شهر تهران طراحی شده که قادر است میزان تقاضای روزانه آب شهر تهران را تخمین بزند.

شرزهای، احراری و فخرایی (۱۳۸۷) در مقاله خود تحت عنوان «پیش‌بینی تقاضای آب شهر تهران با استفاده از الگوی ساختاری، سری‌های زمانی و شبکه عصبی نوع GMDH» به مقایسه روش‌های پیش‌بینی تقاضای سرانه آب در شهر تهران پرداخته‌اند. متغیرهای مورد استفاده در این مقاله مصرف سرانه آب، قیمت آب، متوسط درآمد خانوار و متوسط درجه حرارت سالانه شهر تهران بود. نتایج به دست آمده نشان داد که پیش‌بینی تقاضای آب با استفاده از روش شبکه‌های عصبی GMDH نسبت به روش‌های ساختاری و سری زمانی از درجه کارایی بیشتری برخوردار است.

۲- مبانی نظری

۲-۱- مدل شبکه عصبی

در سال‌های اخیر روش‌های قابل توجهی در آزمایش و مدلسازی سری‌های زمانی رشد پیدا کرده است. در این سال‌ها بیشترین نظرات، در مدل‌های شبکه عصبی

متمرکز شده است (پسور کاسظمی، افسسر، نهاوندی، ۱۳۸۴: ۱۴۷). 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. 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 غیرخطی باشد که بر اساس نیاز خاص مسئله که قرار است به وسیله شبکه عصبی حل شود از سوی طراح انتخاب می‌گردد. برای بهره‌برداری واقعی از توانایی شبکه عصبی باید از توابع فعال‌سازی غیرخطی استفاده شود. این مسئله اجازه می‌دهد که شبکه، الگوهای غیرخطی مناسبی از مجموعه داده‌های پیچیده تولید نماید.

رایج‌ترین تابع فعال‌سازی مورد استفاده در ادبیات شبکه عصبی، تابع توزیع تجمعی لجستیک یا تابع سیگموئید است:

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

این تابع پیوسته و مشتق پذیر است.

مقدار تابع لجستیک در محدوده [۰, ۱] 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 علائم دریافتی واکنش نشان می‌دهد.

انواع مختلفی از شبکه‌های عصبی مصنوعی با توجه به اهداف تحقیق می‌توان استفاده شود. در این تحقیق شبکه عصبی چند لایه پیشخور (MFNN)^۱ به کار گرفته شده 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^۲ و یادگیری بدون نظارت^۳، در یادگیری با نظارت که به یادگیری با معلم نیز معروف است، ارزش‌های متغیر هدف که

1. Multilayered Feedforward Neural Network
2. Supervised Learning
3. Unsupervised Learning

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 پس‌انتشار خطا^۱ می‌باشد، وزن‌های شبکه تعدیل می‌شود (اصطلاحاً شبکه آموزش داده می‌شود) به گونه‌ای که خطای پیش‌بینی داخل نمونه که به وسیله مجموع مربعات خطا یا میانگین خطای مطلق اندازه‌گیری می‌شود حداقل شود. وقتی که وزن‌ها با هر تکرار تغییر می‌کند، اصطلاحاً گفته می‌شود که شبکه در حال یادگیری است.

۲-۲- مدل‌های ARMA و ARIMA

مشخصه‌های دو الگوی خودرگرسیو و میانگین متحرک با هم جمع می‌شوند و الگویی تحت عنوان $ARMA(P, q)$ به وجود می‌آید که در آن P ، q به ترتیب بیانگر تعداد جملات خود رگرسیو و تعداد جملات میانگین متحرک می‌باشد. در صورتی که لازم باشد از سری زمانی مورد نظر d بار تفاضل‌گیری شود تا مانا گردد و بتوان آن را در قالب الگوی $ARMA(P, q)$ آورد، گفته می‌شود سری زمانی اولیه یک فرایند خود توضیح جمعی میانگین متحرک از مرتبه P, d, q است که به صورت $ARIMA(P, d, q)$ نشان داده می‌شود.

فرایند $ARIMA(P, d, q)$ برای متغیر x را می‌توان به صورت رابطه (۲) نشان داد:

$$y_t = f(x) + \sum_{i=1}^P \varphi_i y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (2)$$

که در آن:

$$y_t = \Delta^d x_t = (1 - l)^d x_t \quad (3)$$

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

$$f(t) = \alpha + \delta t \quad (4)$$

1. Error Back Propagation
2. Pesaran, H. M. & B. Pesaran (1997).

برای تعیین d از آزمون مانایی بهره گرفته می‌شود. همچنین تعداد جملات خود رگرسیو و تعداد جملات میانگین متحرک معمولاً با استفاده از توابع خودهمبستگی^۱ (AC) خودهمبستگی جزئی^۲ (PAC) بر اساس مراحل باکس - جنکینز محاسبه می‌شود که دارای سه مرحله شناسایی، تخمین و تشخیص دقت پردازش می‌باشد. اما از آنجایی که ممکن است مدل‌های بهینه دیگری وجود داشته باشند که بر الگوی مذکور ترجیح داده شوند، این مدل‌ها توسط ضابطه‌های آکائیک^۳ و یا شوارتز - بیزین^۴ بازبینی می‌شود، به گونه‌ای که مدلی مناسب می‌باشد که کمترین مقدار آماره آکائیک و یا شوارتز - بیزین را داشته باشد.

۳- طراحی و تخمین مدل‌ها

داده‌های مورد استفاده در این پژوهش مصرف آب شهر تهران به صورت روزانه از ۱۳۸۲/۱/۱ تا ۱۳۸۸/۹/۱۰ بوده که در مجموع ۲۴۵۰ مشاهده را در بر می‌گیرد. داده‌ها از شرکت آب و فاضلاب شهر تهران استحصال شده است. این داده‌ها از دو بخش تشکیل شده‌اند. نخست داده‌های مربوط به دوره ۱۳۸۲/۱/۱ تا ۱۳۸۸/۸/۳۰ برای آموزش و آزمایش شبکه عصبی و تخمین مدل ARMA و بخش دوم از ۱۳۸۸/۹/۱ تا ۱۳۸۸/۹/۱۰ برای اعتبارسنجی و مقایسه مدل‌های مذکور مورد استفاده قرار می‌گیرد.

۳-۱- ARMA

برای پیش‌بینی داده‌های سری زمانی ابتدا مانایی سری زمانی را بررسی کرده و مرتبه انباشتگی (d) تعیین می‌شود. در مطالعه حاضر سری زمانی در سطح ۹۵ درصد بر اساس آزمون دیکی - فولر تعمیم یافته^۵، مانا شد (d برابر با صفر گردد). سپس تعداد جملات خودرگرسیو (p) و تعداد جملات میانگین متحرک (p)، با استفاده از توابع خودهمبستگی (AC) خودهمبستگی جزئی (PAC) بر اساس مراحل باکس - جنکینز محاسبه شد. اما از آنجایی که ممکن است مدل‌های دیگری وجود داشته باشند که مقدار آکائیک یا شوارتز کمتری داشته باشند و بر الگوی مذکور ترجیح داده شوند، مدل‌های دیگر را نیز بررسی می‌کنیم. بر این اساس کمترین مقدار آکائیک، مربوط به فرایند تعداد جملات خودرگرسیو و میانگین متحرک می‌باشد، که نتایج تفصیلی حاصل از برآورد آن، در جدول (۱) آورده شده است.

-
1. Auto Coloration
 2. Partial Auto Correlation
 3. Akaike Information Criterion (AIC)
 4. Schwarz Baisian criterion
 5. Augmented Dickey-Fuller test statistic

جدول (۱): نتایج حاصل از برآورد دوره ۸۸/۸/۳۰ - ۸۲/۱/۱

نام متغیر	ضریب	آزمون T	نام متغیر	ضریب	آزمون T
C	۱۴.۹	۲۲۵.۵	AR(14)	۰.۱۱	۵.۱۸
AR(1)	۰.۸۲	۱۵.۸۹	AR(364)	۰.۱۹	۱۳.۶۸
AR(2)	-۰.۲۴	-۵.۷۳	MA(1)	-۰.۲۳	-۴.۴۵
AR(3)	۰.۰۷	۲.۹۵	MA(2)	۰.۱۹	۵.۹۲
AR(4)	۰.۰۵	۲.۲۳	MA(3)	۰.۰۷	۲.۲۵
AR(5)	-۰.۰۴۵	-۱.۹۶	MA(4)	۰.۰۵	۱.۴۸
AR(6)	-۰.۰۰۳	-۰.۰۸	MA(5)	۰.۱۰	۳.۲۲
AR(7)	۰.۵۵	۱۶.۴۹	MA(6)	۰.۱۲	۳.۶۳
AR(8)	-۰.۷۸	-۱۵.۴۱	MA(7)	-۰.۳۹	-۱۱.۶۲
AR(9)	۰.۳۰	۸.۲۹	MA(8)	۰.۵۲	۱۲.۴۷
AR(13)	-۰.۰۵	-۲.۱۵			

$$\bar{R}^2 = ۰/۹۱$$

$$F = ۹۴۳$$

مأخذ: یافته‌های تحقیق

در جدول (۱) جملات خودرگرسیو مرتبه شش (AR(6)) و میانگین متحرک مرتبه چهار (MA(4)) به لحاظ آماری معنادار نمی‌باشند. جمله خودرگرسیو مرتبه پنج (AR(5)) در سطح خطای ۰.۰۵ و بقیه جملات در سطح خطای ۰.۰۱ به لحاظ آماری معنادار می‌باشند.

۳-۲- شبکه عصبی

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

1. Multilayered Feedforward Neural Network.

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

لونیگ-مارکوات	الگوریتم آموزش شبکه‌های عصبی	پیشخور چندلایه‌ای	نوع شبکه عصبی
early stopping	متد توقف فرایند آموزش	سیگموئید	تابع فعال‌سازی
۱۳۸۸/۸/۳۰ - ۱۳۸۲/۱/۱	دوره زمانی آموزش و آزمایش	۱۲	تعداد نرون ورودی
۰/۰۵ به ۰/۹۵	نسبت تعداد داده‌های آموزش و آزمایش	۱	تعداد نرون خروجی
۰/۰۱	نرخ یادگیری	MSE	معیار تعیین تعداد نرون‌های مخفی
۱۳۸۸/۹/۱۰ - ۱۳۸۸/۹/۱	دوره زمانی پیش‌بینی	۱	تعداد لایه پنهان
		۱۸	تعداد نرون‌های پنهان

در طراحی شبکه‌های عصبی متغیرهای مؤثر (نرون‌های ورودی) عبارتند از درجه دما هوا در قالب سه ورودی حداقل دما، حداکثر دما و میانگین دما روزانه، روزهای هفته (به طور معمول در روزهای پنجشنبه به دلیل فعالیت پاره وقت و تعطیلی برخی مؤسسات مصرف آب تا حدودی کاهش می‌یابد. در اکثر روزهای جمعه به‌رغم 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 تعطیلات و روزهای خاص (مانند ماه رمضان و ...): بنابراین دوازده نرون در لایه ورودی داریم.

با توجه به جدول (۲) در مطالعه حاضر از شبکه عصبی پیشخور چند لایه، دارای ۲۰ نرون در لایه مخفی و تابع فعال‌سازی 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 شده 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 دوازده 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 می‌باشد.

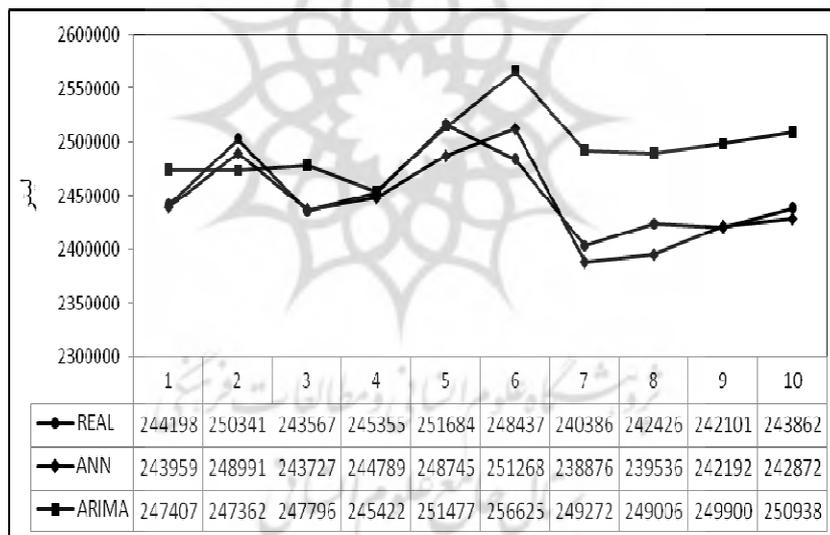
۱. در ادبیات شبکه‌های عصبی معمولاً منظور از یک تابع فعال‌سازی خطی استفاده از یک تابع خطی همانی است.

از میان الگوریتم‌های مختلفی که برای آموزش شبکه‌های عصبی مورد استفاده قرار می‌گیرد، الگوریتم لونیگ - مارکوات انتخاب گردید. چرا که این الگوریتم در مقایسه با سایر الگوریتم‌های پس‌انتشار خطا دارای سرعت بیشتری است. دوره آموزش و آزمایش، شامل ۲۰۰۰ داده می‌باشد. تعداد داده‌های آموزش و آزمایش مدل به نسبت ۰/۹۵ به ۰/۰۵ تقسیم گردید و از نرخ یادگیری ۰/۰۱ استفاده شد. برای توقف فرایند آموزش از متد early stopping بهره گرفته شد. در نهایت شبکه عصبی با استفاده نرم‌افزار MATLAB(2008) طراحی و مدل‌بندی شد.

۴- ارزیابی مدل‌های پیش‌بینی

نمودار (۱) نتایج حاصل از پیش‌بینی تقاضای روزانه آب شهری را به وسیله شبکه عصبی پیش‌خور و فرایند ARIMA به همراه مقادیر واقعی برای ده روز آینده (۸۸/۹/۱۰ - ۸۸/۹/۱) نشان می‌دهد.

نمودار (۱) - مقادیر پیش‌بینی شده تقاضای آب شهری توسط مدل‌های پیش‌بینی



مأخذ: یافته‌های تحقیق

به منظور مقایسه قدرت پیش‌بینی فرایند ARIMA و شبکه عصبی مصنوعی از معیارهای میانگین مربع خطای استاندارد (MSE)، مجذور میانگین مربع خطای استاندارد (RMSE)، میانگین قدر مطلق خطا (MAE) و میانگین درصد قدر مطلق خطا (MAPE) به صورت گام به گام (روز یکم تا روز دهم) استفاده شده که نتایج آن در جدول (۳) آورده شده است. این معیارها بر اساس مقیاس داده‌های واقعی ۸۸/۹/۱۰ - ۸۸/۹/۱ محاسبه شده‌اند.

جدول (۳): مقایسه قدرت پیش‌بینی مدل‌های شبکه عصبی پیش‌خور و ARMA

ARMA	شبکه عصبی	گام	معیار	ARMA	شبکه عصبی	گام	معیار
32083	2392	1	MAE	1029369783	5722547	1	MSE
30937	7945	2		958442109	93975056	2	
34721	5830	3		1235096053	63503128	3	
26208	5788	4		926433469	55640646	4	
21379	10509	5		741999542	217315773	5	
31463	13476	6		1735786074	314695803	6	
39663	13708	7		2615888170	302322331	7	
42931	15607	8		2830226974	368944902	8	
42931	13975	9		3191601108	328045067	9	
49219	13568	10		3373074438	305039064	10	
1.31	0.09	1	MAPE	32083	2392	1	RMSE
1.25	0.31	2		30958	9694	2	
1.41	0.23	3		35143	7968	3	
1.07	0.23	4		30437	7459	4	
0.87	0.42	5		27239	14741	5	
1.27	0.54	6		41662	17739	6	
1.62	0.55	7		51145	17387	7	
1.76	0.63	8		53199	19207	8	
1.92	0.56	9		56494	18112	9	
2.02	0.55	10		58078	17465	10	

مأخذ: یافته‌های تحقیق

دلیل استفاده از پیش‌بینی نوع گام به گام (روز یکم تا روز دهم) بیان این نکته است که برای مثال یک مدل، در طول ده روز پیش‌بینی، ممکن است در چند روز اول نسبت به مدل دیگری از قدرت پیش‌بینی بالاتری برخوردار باشد اما در ارزیابی مجموع ده روز این گونه نباشد، که توانایی پیش‌بینی این مدل در نوع دوم نادیده گرفته می‌شود. هر گام معرف یک روز می‌باشد به عنوان مثال در گام دوم مدل‌های مذکور برای دو روز آینده پیش‌بینی می‌کنند و در گام هفتم مدل‌ها برای هفت روز آینده پیش‌بینی می‌کنند.

با توجه به نتایج جدول (۲) کلیه معیارها نشان‌دهنده برتری شبکه عصبی پیش‌خور نسبت به مدل ARMA می‌باشد. براساس نتایج به دست آمده مدل شبکه عصبی پیش‌خور در تمام گام‌ها، دارای خطای کمتر و در نتیجه کارایی بیشتری در پیش‌بینی تقاضای روزانه آب شهری است.

نتیجه‌گیری

با توجه به نقش حیاتی آب در زندگی روزمره، آگاهی از میزان تقاضای آن در جهت برنامه‌ریزی، طراحی و اجرا و مدیریت بهتر منابع آب از اهمیت ویژه‌ای برخوردار است. هدف از این تحقیق، برآورد و ارائه مدل مناسب برای پیش‌بینی تقاضای کوتاه‌مدت آب شهر تهران می‌باشد. در این تحقیق به مطالعه تطبیقی روش‌های خطی ARMA و غیرخطی شبکه عصبی پیشخور چند لایه برای پیش‌بینی تقاضای روزانه آب شهری پرداخته شد. با توجه به نتایج جدول (۳) شبکه عصبی پیشخور از نظر تمامی معیارهای عملکرد، بر روش ARMA برتری دارد. نتایج مطالعه نشان داد که شبکه عصبی مصنوعی توانایی بالایی در پیش‌بینی تقاضای روزانه آب دارد و قادر است میزان تقاضای آب را دقیق‌تر از روش ARMA پیش‌بینی نماید. بر این اساس با توجه به اهمیت آگاهی از تقاضای کوتاه‌مدت آب شهری، به مدیران و بهره‌برداران سیستم‌های آب شهری پیشنهاد می‌گردد که از شبکه‌های عصبی مصنوعی به عنوان یک ابزاری قدرتمند در تجزیه و تحلیل و پیش‌بینی داده‌ها، می‌توان در مواردی همچون مدیریت منابع آب، مدیریت بهره‌برداری مخازن و تصفیه خانه‌های آب، برنامه‌ریزی و مدیریت پمپ‌ها و شیرآلات شبکه، تعیین قابلیت اطمینان شبکه، کنترل کیفیت آب، مدیریت بهره‌برداری در تصفیه خانه، تعیین بهترین زمان جهت تعمیرات و بازسازی شبکه، کاهش آب به حساب نیامده، پیش‌بینی مقدار فروش آب، هزینه‌های دریافتی و مقایسه عرضه و تقاضا بهره برد.

منابع

الف - فارسی

۱. ابریشمی، حمید؛ مهرآرا، محسن؛ *اقتصادسنجی کاربردی*، انتشارات دانشگاه تهران، ۱۳۸۱.
۲. اصغری اسکویی، محمدرضا؛ «کاربرد شبکه‌های عصبی در پیش‌بینی سری‌های زمانی»، فصل‌نامه پژوهش‌های اقتصادی ایران، ۱۳۸۱، شماره ۱۲.
۳. پورکاظمی، محمدحسین؛ نهاوندی، افسر، امیر و بیژن؛ «مطالعه تطبیقی روش‌های خطی ARIMA و غیرخطی شبکه‌های عصبی در پیش‌بینی تقاضای اشتراک گاز شهری»، مجله تحقیقات اقتصادی، ۱۳۸۴، شماره ۷۱.
۴. تابش، مسعود؛ گوشه، سیامک؛ یزدان‌پناه، محمد جواد؛ «پیش‌بینی تقاضای کوتاه‌مدت شهر تهران با استفاده از شبکه‌های عصبی مصنوعی»، نشریه دانشکده فنی، جلد ۴۱، ۱۳۸۵، شماره ۱.
۵. شرزهای، غلامعلی؛ احراری، مهدی؛ فخرانی، حسن؛ «پیش‌بینی تقاضای آب شهر تهران با استفاده از الگوی ساختاری، سری‌های زمانی و شبکه عصبی نوع GMDH»، مجله تحقیقات اقتصادی، ۱۳۸۷، شماره ۸۴.
۶. گوشه، سیامک؛ تخمین تقاضای کوتاه‌مدت آب شهری با استفاده از شبکه‌های عصبی مصنوعی، پایان‌نامه کارشناسی ارشد، دانشکده فنی، دانشگاه تهران، ۱۳۸۲.

ب- لاتین

7. Bithas Kostas, "Stoforos Chrysostomos, Estimating urban Residential water Demand Determinants and Forecasting Water Demand For Athens Metropolitan Area", 2000-2010, South-Eastern Europe Journal of Economics, Vol. 1, 2006.
8. Jain, Ashu et al; "Short-term Water demand Forecast Modelling at IIT Kanpur Using Artificial Neural Networks", Water Resources Management, 2001, No. 15.
9. K.B. Khatri; K. Vairavamoorthy; "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, 2009.
10. Liu, J; Savenije, H.G & Xu, J; "Forecast of Water Demand in Weinan City in China Using WDF-ANN Model", Physics and Chemistry of the Earth, Vol. 28, 2002.
11. Maidment, D. R. & Parzen, E; "Cascade model of monthly municipal water use" J. of Water Resources Research, Vol. 20, 1984, No. 1.
12. Maidment, D. R; Miaou, S. P & Crawford, M. M; "Transfer function models of daily urban water use", J. of Water Resources Research, Vol. 21, 1985, No. 4.
13. Ravindra Sen Pillay; *Short-Term Water Demand Forecasting for Production Optimisation*, University of Southern Queensland Faculty of Engineering and Surveying, 2005.
14. Stark, H.L; Stanley, J.S; Buchanan, I.D; *Water Demand Forecasting Using Artificial Neural Networks*, University of Alberta, 2000.
15. Yu, M.J; Joo, C.N; Koo, J.Y; "Application of Short-Term Water Demand Prediction Model to Seoul", Journal of Water Science & Technology, Vol. 46, 2002, No. 6-7.