

پیش‌بینی تقاضای آب شهر همدان با استفاده از شبکه‌های عصبی مصنوعی

بابک بلالی‌مقدم*، محمدهادی دارابی**

تاریخ دریافت مقاله: ۹۴/۹/۹

تاریخ پذیرش مقاله: ۹۴/۱۱/۱۱

چکیده

پیش‌بینی تقاضای آب شهری کمک مؤثری به مدیران و بهره‌برداران سیستم‌های آب شهری می‌باشد تا بتوانند نسبت به مدیریت صحیح مصرف، مخازن، پمپ‌ها، شیرآلات و تصفیه‌خانه‌ها اقدام نمایند. مصرف کوتاه‌مدت آب تابعی از پارامترهای مختلف و متنوع مانند شرایط اقلیمی و هواشناسی، مناسبت‌های فرهنگی، اقتصادی، اجتماعی و مصارف گذشته می‌باشد. به دلیل همین تنوع، پیش‌بینی مصرف کوتاه‌مدت به صورت تحلیلی بسیار مشکل و یا ناممکن می‌باشد. در این شرایط استفاده از سیستم‌های هوشمند مانند شبکه‌های عصبی مصنوعی می‌تواند به عنوان یک گزینه راهگشا مطرح گردد. در این تحقیق با استفاده از شبکه‌های عصبی پرسپترون چندلایه و با الگوریتم آموزشی پس انتشار خطا، میزان مصرف یک‌روزه آب شهر همدان بر اساس پارامترهای هواشناسی و داده‌های تاریخی مصارف گذشته پیش‌بینی می‌شود. نتایج این تحقیق نشان می‌دهد که با اطلاعات محدود قابل‌دسترس، شبکه عصبی با دولایه نهان که به ترتیب دارای یک و هفت نرون می‌باشند توانسته است میزان تقاضای روزانه آب شهر همدان را با ضریب همبستگی بیش از ۸۵ درصد و خطای متوسط حدود دو درصد تخمین بزند. بدیهی است با افزایش تعداد داده‌ها در یک دوره زمانی گسترده‌تر، میزان دقت مدل قابل‌بهبود می‌باشد. در این مقاله همچنین با استفاده از شبکه‌های عصبی مصنوعی، یک فرمول ساده برای پیش‌بینی میزان مصرف روزانه آب شهر همدان تولید شده است و با ورود داده‌های درجه حرارت هوا و مصرف آب روز قبل، میزان مصرف روز بعد به دست می‌آید. نتایج این تحقیق نشان می‌دهد که این فرمول قادر است میزان تقاضای روزانه آب شهر همدان را با میانگین خطای مطلق حدود ۲/۷۵ درصد، تخمین بزند.

واژگان کلیدی

شبکه‌های عصبی مصنوعی، تقاضای کوتاه‌مدت آب، پارامترهای هواشناسی، مصرف آب

E-Mail: b.balali91@gmail.com

* کارشناسی ارشد برنامه‌ریزی شهری، دانشگاه آزاد اسلامی، همدان

** کارشناس ارشد کامپیوتر، دانشگاه ارومیه، ارومیه، ایران

مقدمه

برای مدیریت سیستم‌های آب شهری و تصمیم‌گیری در خصوص تأمین آب و بهره‌برداری بهینه از شبکه‌های توزیع، نیاز به اطلاعات و ابزارهایی است که یکی از مهم‌ترین و اصلی‌ترین آن‌ها، پیش‌بینی نیاز آبی تقاضا به‌عنوان بار وارد بر شبکه می‌باشد. پیش‌بینی مصرف آب در دوره‌های کوتاه‌مدت، میان‌مدت و بلندمدت می‌توان مطرح نمود (Monzavi, 1999; Taebi & Chamni, 2000). پیش‌بینی بلندمدت معمولاً بازه‌ای از یکتا چند سال را در برمی‌گیرد و از اطلاعات به‌دست‌آمده به‌منظور طراحی شبکه، تأمین منابع آبی جدید و توسعه شبکه استفاده می‌شود. پیش‌بینی میان‌مدت برای بازه‌های ماهانه و فصلی صورت می‌گیرد. پیش‌بینی کوتاه‌مدت معمولاً بازه‌ای از یک ساعت تا چند روز را شامل می‌گردد. در مدیریت آب شهری دانستن تقاضای کوتاه‌مدت بسیار مهم و حیاتی است و از آن می‌توان در موارد زیر بهره برد: مدیریت منابع آب، مدیریت بهره‌برداری مخازن و تصفیه‌خانه‌های آب، برنامه‌ریزی و مدیریت پمپ‌ها و شیرآلات شبکه، تعیین قابلیت اطمینان شبکه، کنترل کیفیت آب، مدیریت بهره‌برداری در تصفیه‌خانه، تعیین بهترین زمان جهت تعمیرات و بازسازی شبکه، کاهش آب به‌حساب نیامده، پیش‌بینی مقدار فروش آب، هزینه‌های دریافتی و مقایسه عرضه و تقاضا. بیشتر مقالاتی که به بحث در مورد پیش‌بینی مصرف آب شهری می‌پردازند، مصرف ماهانه یا سالانه و به عبارتی میان‌مدت و بلندمدت را در نظر گرفته‌اند و تنها تعداد اندکی از آن‌ها مصرف کوتاه‌مدت را بررسی کرده‌اند. این تحقیقات بیشتر بر اساس مدل‌های آماری، رگرسیون چندگانه و سری‌های زمانی به پیش‌بینی مصرف پرداخته‌اند (Zhou et al, 2000; Zhou et al, 2001). بحث پیش‌بینی بلندمدت مصرف ابتدا توسط Wong در سال ۱۹۷۲، Young در سال ۱۹۷۳ و Willisie در سال ۱۹۷۴ مطرح شد. آن‌ها با استفاده از سری‌های زمانی، مصرف سالانه آب را بر اساس جمعیت، درآمد سرانه، قیمت آب، بارندگی، درجه حرارت و تبخیر مدل نمودند. در سال ۱۹۸۴ Parzen و Maidment مصرف ماهیانه (میان‌مدت) آب در تگزاس را توسط سری زمانی تخمین زدند. در این تحقیق آن‌ها ابتدا مقادیر سری زمانی را به دو مؤلفه همیشگی و تصادفی تقسیم نمودند. مؤلفه‌های همیشگی، شامل مؤلفه‌های روند و فصلی می‌شد که مؤلفه روند را به‌وسیله 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. یکی از این معادلات، همبستگی مصرف آب با مقادیر مصرف‌شده در روزهای قبل و معادله دیگر، همبستگی مصرف آب با متغیرهای آب و هوایی، نظیر حداکثر درجه حرارت ماهانه، تبخیر و بارش را بررسی می‌کرد. در سال ۱۹۸۵ Maidment و همکارانش یک تابع انتقال^۱ برای پیش‌بینی مصرف روزانه آب برای شهر تگزاس بکار بردند. همچنین آن‌ها یک مدل مصرف کوتاه‌مدت توسط سری‌های زمانی Box-Jenkins ساختند که در آن از اطلاعات بلندمدت و کوتاه‌مدت به‌صورت توأم استفاده گردید. استفاده از شبکه‌های عصبی برای پیش‌بینی مصرف کوتاه‌مدت ابتدا در سال ۲۰۰۰ توسط Stark و همکارانش برای شهر آلبرتا در کانادا بکار رفت. آن‌ها مصرف روزانه آب و همچنین مصرف روزانه ده روز آتی را با استفاده از پارامترهای ماکزیمم و مینیمم درجه حرارت، بارش روز گذشته، مجموع بارش ۵ روز گذشته، مجموع بارش ۳۰ روز گذشته، اندیس تعطیلی و غیر تعطیلی و اندیس فصل پیش‌بینی نمودند. این روش در سال ۲۰۰۲ توسط Yu و همکارانش برای سئول در کره جنوبی بکار رفت. آن‌ها از یک شبکه عصبی سه لایه استفاده نمودند. در این تحقیق از ماکزیمم درجه حرارت، تعطیلات و مصرف روز گذشته به‌عنوان پارامتر ورودی در تمام فصول سال استفاده گردید. علاوه بر پارامترهای فوق، سرعت باد در فصل بهار و رطوبت در فصل زمستان نیز به ورودی‌های مدل اضافه گردیدند.

Liu و همکارانش در سال ۲۰۰۲ شبکه‌های عصبی مصنوعی را برای پیش‌بینی مصرف ماهانه آب در شهر Weinan در کشور چین بکار بردند. آن‌ها از پارامترهای اقتصادی نرمالیزه نظیر درآمد سرانه، تعداد افراد خانواده و قیمت آب برای این منظور استفاده نمودند. میزان مصرف آب، پدیده‌ای بسیار پیچیده است که تابعی غیرخطی از عوامل بسیاری است که این عوامل از ناحیه‌ای به ناحیه دیگر و در طی زمان تغییر می‌نمایند. به همین دلیل تاکنون فرمول کامل و جامعی برای میزان مصرف آب ارائه نشده است. فرمول‌های موجود یا دقیق نیستند و یا اینکه از زاویه‌ای خاص، مثلاً از لحاظ اقتصادی (Buchberger & Wells, 1996; Buchberger & Wu, 1995)، میزان مصرف آب را مورد بررسی قرار می‌دهند و از سایر عوامل موجود صرف‌نظر می‌شود. همچنین فرمول‌ها و روابط موجود، بیشتر میزان مصرف را در اروپا و آمریکا محاسبه می‌کنند و مطابق با شرایط منطقه‌ای، اجتماعی و اقتصادی آنجا کالیبره شده‌اند و با شرایط شهرهای ایران تطابق ندارند. برای استفاده و کالیبراسیون روش‌های فوق، تهیه اطلاعات و آمار مناسب و طولانی‌مدت و با دقت بالا نیاز می‌باشد. حال آنکه در کشور ما به لحاظ برخی از مشکلات تکنولوژیک و ضعف در جمع‌آوری آمار و تهیه بانک‌های اطلاعاتی، چنین پایگاه کاملی از داده‌ها در دسترس نمی‌باشد، یا اینکه پارامترهای اندازه‌گیری شده قابل اطمینان

نیستند. با توجه به اینکه پیش‌بینی تقاضای روزانه آب شهری در شهرهای مهمی همچون همدان گام مهمی در بهبود مدیریت این شبکه‌ها می‌باشد؛ ولی به علت محدودیت فراوان اطلاعات، تاکنون اقدام مناسبی در این زمینه صورت نگرفته است، هدف این مقاله ارائه یک روش مناسب و قابل اطمینان برای به دست آوردن میزان تقاضای روزانه آب شهر همدان می‌باشد. با توجه به عوامل ذکر شده مشخص می‌گردد که به ابزاری جهت پیش‌بینی نیاز است که توانایی یادگیری برداشت‌های میدانی ناقص موجود را داشته باشد و به علاوه بتواند در مقابل نوسان‌های ناشی از عدم دقت در داده‌ها مقاومت نماید. در این شرایط، شبکه‌های عصبی یکی از گزینه‌های مناسب بشمار می‌آیند؛ زیرا به دلیل هوشمند بودن، قابلیت یادگیری الگوی مصرف پیچیده آب را دارند و هم با اطلاعات آماری محدود در حد چند سال - می‌توانند به جواب مطلوب برسند. در این تحقیق با استفاده از پارامترهای هواشناسی و داده‌های تاریخی مصرف روزانه آب در گذشته، مصرف روزانه آب همدان به وسیله شبکه‌های عصبی مصنوعی مدل می‌شود؛ بنابراین مزیت این تحقیق نسبت به کارهای قبلی تنوع بیشتر و تفاوت ساختارها و تفاوت پارامترهای مدل و کاربرد مدل برای اولین بار در مورد داده‌های آب شهر همدان می‌باشد. علاوه بر این در این مقاله جهت ساده‌سازی و استفاده راحت کاربران، با استفاده از شبکه‌های عصبی مصنوعی، یک فرمول ساده برای پیش‌بینی میزان تقاضای روزانه آب شهر همدان تولید شده است.

بررسی و انتخاب پارامترهای ورودی به مدل (آنالیز حساسیت)

برای آنکه بتوان میزان مصرف آب را پیش‌بینی نمود، باید در مورد نوع مصرف‌کنندگان هم شناخت کافی داشت. مصرف آب شهری را می‌توان در چهار شاخه طبقه‌بندی کرد: مصرف خانگی، صنعتی، تجاری و عمومی. البته به موارد فوق مصرف آتش‌نشانی و میزان آب به حساب نیامده را هم می‌توان اضافه نمود. عوامل بسیاری در میزان مصرف آب شهری تأثیر می‌گذارند که از جمله می‌توان به عوامل اقلیمی (هواشناسی) شامل دما، نزولات جوی، فشار هوا، باد، ساعات آفتابی و اثر رطوبت هوا، عوامل اجتماعی و اقتصادی شامل سطح زندگی مردم، میزان درآمد سرانه، تعداد افراد در هر خانه، اندازه زمین خانه، فرهنگ زندگی و قیمت آب، جمعیت و بافت شهری، کیفیت شبکه توزیع آب شامل نحوه اجرای شبکه و کیفیت آن، عمر شبکه، مدیریت شبکه و مدیریت مصرف و عوامل متفرقه مانند پیروید صدور قبض آب و سن افراد اشاره نمود. از بین این عوامل تنها پارامترهای هواشناسی و اقلیمی بر مصرف کوتاه‌مدت آب مؤثر می‌باشند. علاوه بر موارد فوق که میزان مصرف پایه را مشخص می‌کند تغییر فصول سال، روزهای هفته و تعطیلات نیز موجب نوسان مصرف آب می‌شوند (Taebi & Chamni, 2000; Chattejee, 2001; Management and Budget (Organization and Ministry of Energy, 1994; Merritt, 1983).

در انتخاب پارامترهای ورودی به مدل، دو اصل مدنظر قرار می‌گیرند. اول آنکه متغیرهایی انتخاب گردند که با توجه به شرایط اقلیمی و اقتصادی - اجتماعی شهر موردنظر یعنی همدان، بر مصرف آب کوتاه‌مدت تأثیر محسوس داشته باشند. دیگر اینکه اطلاعات آماری این پارامترها به عنوان ورودی به مدل عصبی در دسترس باشد. اطلاعات مربوط به هواشناسی، از طریق سازمان هواشناسی کل کشور تهیه شده است که مربوط به ده سال می‌باشد. میزان مصرف آب روزانه از سازمان آب و فاضلاب کشور تهیه شد که مصرف روزانه پنج سال را شامل می‌گردد. در نهایت از آنجاکه محدوده زمانی این داده‌ها در یک دوره حدود چهار سال (فروردین ۱۳۸۵ تا دی ۱۳۸۸) با یکدیگر انطباق داشتند، اطلاعات مصرف آب و پارامترهای هواشناسی این دوره زمانی برای مدل‌سازی انتخاب شدند. برای بررسی تأثیر پارامترها بر مصرف آب از آنالیز حساسیت استفاده می‌گردد. در این مقاله از ضریب حساسیت نرمال استفاده می‌شود که از رابطه زیر به دست می‌آید:

$$S_{ij} = \frac{\partial y_i}{\partial x_j} \div \frac{\partial x_j}{x_j} = \frac{\partial y_i}{\partial x_j} \cdot \frac{x_j}{y_i} \quad (1)$$

که S_i حساسیت متغیر وابسته i نسبت به متغیر مستقل j ، y متغیر وابسته و x مستقل می‌باشند. برای محاسبه ضریب حساسیت داده‌ها از بسته نرم‌افزاری SPSS (نگارش ۱۹) استفاده و نتایج در جدول (۱) نشان داده شده است. با بررسی نتایج حاصل از نرم‌افزار SPSS مشاهده می‌شود که در فصول مختلف، تأثیر پارامترهای مختلف بر مصرف آب متغیر می‌باشد؛ لذا در این تحقیق هر سال به دو دوره زمانی تقسیم می‌شود و برای هر دوره، یک مدل عصبی تولید می‌گردد تا عملکرد شبکه‌های عصبی در مدل‌سازی شرایط واقعی بهبود یابد. این دو دوره زمانی به عنوان ماه‌های گرم و ماه‌های سرد نام‌گذاری شدند. ماه‌های گرم از ۱۵ فروردین الی ۳۰ مهر و ماه‌های سرد از اول آبان الی ۱۵ اسفندماه انتخاب گردید. همچنین اطلاعات مربوط به یک ماه از سال،

۱۶ اسفند تا ۱۵ فروردین، به دلیل شرایط خاص عید نوروز که متأثر از پارامترهای هواشناسی نبوده؛ ولی درعین حال باعث نوسانات مصرف می‌شود. افزایش مصرف در دوران خانه‌تکانی و کاهش مصرف به دلیل مسافرت‌های گسترده در تعطیلات نوروز لحاظ نگردد. در این مقاله از اطلاعات نرمالیزه شده استفاده گردیده است. در نرمال‌سازی، پراکندگی و فاصله‌ها به یک ناحیه اشباع (بین صفر و یک) تبدیل می‌شود. روش‌های متعددی برای نرمال‌سازی وجود دارد.

جدول ۱- نتایج آنالیز حساسیت

شماره	پارامتر	ضریب همبستگی		پارامترهای ورودی مدل	
		ماه‌های گرم	ماه‌های سرد	مرحله اول	مرحله دوم
۱	سال	0.254	0.431	+	+
۲	ماه	0.424	-0.216	+	+
۳	هفته روز	0.066	0.440	+	+
۴	آخر هفته	0.016	0.379	+	+
۵	دیروز مصرف آب	0.921	0.577	+	-
۶	مصرف آب ۲ روز پیش	0.886	0.390	+	+
۷	مصرف آب از ۳ روز پیش	0.883	0.435	+	+
۸	مصرف آب از ۷ روز پیش	0.858	0.704	+	-
۹	دمای خشک	0.850	0.454	+	-
۱۰	دیروز دما خشک	0.851	0.396	+	-
۱۱	دمای خشک از ۲ روز پیش	0.835	0.368	+	+
۱۲	دمای خشک از ۳ روز پیش	0.816	0.342	+	+
۱۳	درجه حرارت مرطوب	0.793	0.434	+	-
۱۴	دیروز دما مرطوب	0.794	0.407	+	-
۱۵	درجه حرارت مرطوب از ۲ روز پیش	0.784	0.375	+	+
۱۶	حداقل دما	0.820	0.360	+	+
۱۷	دیروز حداقل دما	0.815	0.358	+	+
۱۸	حداقل درجه حرارت ۲ روز پیش	0.795	0.339	+	+
۱۹	حداکثر درجه حرارت	0.852	0.489	+	-
۲۰	دیروز حداکثر دما	0.848	0.408	+	-
۲۱	حداکثر درجه حرارت ۲ روز پیش	0.830	0.371	+	+
۲۲	دمای میانگین	0.850	0.442	+	-
۲۳	دیروز میانگین دما	0.845	0.396	+	-
۲۴	میانگین دمای ۲ روز پیش	0.826	0.365	+	+
۲۵	میانگین دمای ۳ روز پیش	0.808	0.338	+	+

در این تحقیق از فرمول زیر استفاده شده است:

$$x_{nor} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2)$$

که در آن x مقدار غیر نرمالیزه، x_{nor} مقدار نرمالیزه و x_{min} و x_{max} به ترتیب بیشترین و کمترین مقدار مربوط به یک پارامتر می‌باشد.

شاخص‌های ارزیابی مدل

با توجه به اینکه در این تحقیق مدل‌های زیادی تولید خواهند شد باید مشخص شود که کدام مدل بهترین تطابق را با واقعیت دارد و می‌تواند میزان مصرف را با بهترین تقریب و کمترین خطا محاسبه نماید و نهایتاً با توجه به اهداف موردنظر، کدام مدل، تولیدکننده بهترین جواب می‌باشد. برای این منظور باید به ارزیابی مدل و نتایج خروجی آن پرداخت. منظور از ارزیابی مدل این است که مدل تا چه حد قادر است با توجه به آموزشی که دیده است نسبت به ورودی‌های جدید جواب قابل قبولی ارائه دهد. روش‌های متعددی در ارزیابی یک مدل وجود دارد. در این تحقیق دو شاخص زیر به‌عنوان معیار برای ارزیابی انتخاب‌شده‌اند:

میانگین درصد خطای مطلق (MAPE): این معیار که به‌وسیله تعداد زیادی محقق برای ارزیابی پیش‌بینی انتخاب‌شده است به‌صورت رابطه زیر تعریف می‌شود:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|Actual_i - Forecast_i|}{Actual_i} \times 100 \quad (3)$$

که n تعداد داده‌ها، $Actual_i$ داده‌های واقعی و $Forecast_i$ داده‌های پیش‌بینی شده می‌باشند. هرچقدر این شاخص به صفر نزدیک‌تر باشد بیانگر کارایی بهتر مدل است. در این تحقیق با توجه به سایر تحقیقات انجام‌گرفته، میانگین درصد خطای مطلق ۵ درصد به‌عنوان یک حد مطلوب در نظر گرفته شده است. لازم به ذکر است که علاوه بر میانگین درصد خطای مطلق، از مقادیر خطای ماکزیمم و مینیمم نیز به‌عنوان شاخص‌هایی برای مقایسه استفاده شده است که در آن‌ها برای تعیین درصد خطا از فرم رابطه (۳) بدون قدر مطلق و میانگین‌گیری استفاده می‌شود.

ضریب همبستگی (R): ضریب همبستگی به‌عنوان یک معیار برای ارتباط بین داده‌ها بکار می‌رود و بیانگر شدت وابستگی میان X و Y در یک فضای نمونه می‌باشد. ضریب همبستگی از رابطه زیر به دست می‌آید:

$$R = R(x, y) = \frac{cov(x, y)}{\sigma_x \sigma_y} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \mu_x)(y_i - \mu_y)}{\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu_x)^2} \cdot \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \mu_y)^2}} \quad (4)$$

که X و Y به ترتیب مقدار مصرف روزانه واقعی و مقدار مصرف روزانه پیش‌بینی شده توسط مدل $cov(x, y)$ کوواریانس X و Y ، μ_x و μ_y مقادیر میانگین مصارف روزانه واقعی و پیش‌بینی شده، σ_x^2 و σ_y^2 واریانس داده‌های X و Y می‌باشند. مقدار R همواره بین منهای یک و بعلاوه یک قرار دارد و هرچقدر R به یک نزدیک‌تر باشد بیانگر عملکرد بهتر مدل است. در این تحقیق ضریب همبستگی بالای ۰.۸۵، به‌عنوان یک حد مطلوب در نظر گرفته شده است.

تهیه مدل شبکه عصبی: همان‌گونه که قبلاً ذکر شد در این تحقیق از روش شبکه‌های عصبی مصنوعی برای مدل‌سازی استفاده می‌شود. شبکه‌های عصبی دارای ویژگی‌هایی به شرح زیر هستند:

قابلیت تقریب زنی عمومی دارند و تقریباً می‌توانند هر تابعی را تقریب بزنند. این مدل‌ها به‌صورت خودکار قابلیت تطبیق دارند و هنگامی که رابطه موجود در اطلاعات آماری تغییر می‌کند خود را به‌روز می‌نمایند. شبکه‌های عصبی در مقایسه با سایر روش‌های پیش‌بینی بسیار پایدارتر می‌باشند. برای استفاده از شبکه‌های عصبی، احتیاج به یادگیری روش‌های پیچیده نبوده و فقط به اطلاعات اولیه آماری احتیاج است. برای کار با شبکه‌های عصبی به شناخت عمیق از ارتباط و واکنش بین متغیرهای موجود در مسئله و نیز رابطه متغیرها و یا تابع موجود نیازی نمی‌باشد. همچنین به دلیل خاصیت پردازش متنی در شبکه‌های عصبی، متغیرهای آماری نادرست و خطادار تأثیر بسیار کمی بر نتایج می‌گذارند.

تاکنون روش‌ها و الگوریتم‌های مختلفی برای آموزش شبکه‌های عصبی ارائه شده است. یکی از مهم‌ترین این الگوریتم‌ها، الگوریتم پس انتشار خطا می‌باشد که در این تحقیق مورد استفاده قرار گرفته است. این الگوریتم مکمل توپولوژی شبکه‌های عصبی چندلایه پیشرو است (Chattejee, 2001)؛ همچنین به همراه الگوریتم پس انتشار خطا از شبکه‌های پرسپترون چندلایه که در شناخت الگو و تابع حاکم بر یک مسئله خاص بسیار متبحر هستند استفاده شده است. Matlab در این تحقیق از بسته نرم‌افزاری (ویرایش ۱۲) که

حاوی ماژول شبکه‌های عصبی می‌باشد، استفاده شده است. ماژول شبکه عصبی نرم‌افزار دارای یک رابط گرافیکی ۵ می‌باشد که کاربر Matlab دوست بوده و امکان ساخت شبکه‌های عصبی با ساختارهای مختلف را در حداقل زمان فراهم می‌سازد. با در نظر گرفتن ماهیت این تحقیق که نیازمند ساخت و آموزش تعداد زیادی مدل عصبی است، نرم‌افزار بسیار مناسب می‌باشد. در مدل‌سازی شبکه Matlab های عصبی توصیه شده است، قبل از آموزش، وزن‌های شبکه عصبی با مقادیر کوچک و تصادفی مقداردهی شود. این امر به آموزش بهتر شبکه کمک می‌کند. در این مطلب را می‌توان با استفاده از Matlab نرم‌افزار یک گزینه، به صورت خودکار و سریع انجام داد. باید توجه داشت که یک مدل شبکه عصبی با ساختار و بردارهای آموزشی یکسان که وزن‌ها با مقداردهی اولیه مختلف آموزش یابد، نتایج یکسان ارائه نمی‌کنند، هرچند که غالباً نتایج آن‌ها نسبتاً نزدیک به هم می‌باشد. در این تحقیق هر مدل عصبی حداقل پنج بار با مقداردهی اولیه متفاوت آموزش داده شده و بهترین نتایج خروجی انتخاب می‌گردد. همان‌طور که ذکر شد، در این پژوهش اطلاعات چهار سال (فروردین ۱۳۸۵ الی بهمن ۱۳۸۸) که طی آن داده‌های هواشناسی و مصرف آب تقریباً بر یکدیگر منطبق می‌باشند موجود بوده است. برای آنکه ورودی کافی برای آموزش شبکه‌های عصبی در دسترس باشد، از اطلاعات دو سال متوالی به‌طور توأمان برای هر مدل استفاده می‌شود. مشخصات مدل‌ها در جدول (۲) خلاصه شده است.

برای مدل‌سازی دو مجهول اساسی وجود دارد. اولین مجهول، ساختار شبکه عصبی است که شامل تعداد لایه‌ها، نرون‌های هر لایه و توابع فعالیت می‌باشد. دومین مجهول، ترکیب پارامترهای ورودی در مدل است. در انتخاب پارامترها بهتر است کاربردی بودن مدل هم مدنظر قرار گیرد. بدیهی است اگر مدل تعداد زیادی پارامتر ورودی داشته باشد، استفاده از آن با دشواری همراه بود. برای یافتن بهترین ساختار در شبکه‌های عصبی چاره‌ای جز بررسی ساختارهای مختلف به روش سعی و خطا نمی‌باشد. در این تحقیق مدل‌های زیادی ساخته شده و آزمایش گردیده است.

مدل‌سازی از ساده‌ترین ساختار آغاز و به تدریج تعداد نرون‌ها و لایه‌ها افزایش می‌یابد. به دلیل آنکه خروجی مدل فقط میزان مصرف آب روزانه است، لذا لایه خروجی تنها یک نرون خواهد داشت. در این مقاله، توابع فعالیت تمام نرون‌های یک لایه، یکسان انتخاب می‌شوند. توابع فعالیت لایه خروجی می‌تواند غیرخطی و یا خطی باشد. در این تحقیق توابع فعالیت لایه‌های میانی از نوع غیرخطی LogSig انتخاب گردیده‌اند.

جدول ۲- معرفی مدل‌های عصبی

شماره مدل	دوره موردنظر	زمان یادگیری (آموزش)	زمان تست
۱	ماه‌های گرم (۱۳۸۵-۱۳۸۷)	۱۳۸۵/۱/۱۵ تا ۱۳۸۵/۷/۳۰ ۱۳۸۶/۱/۱۵ تا ۱۳۸۶/۷/۳۰	۱۳۸۶/۷/۳۰ تا ۱۳۸۶/۷/۱
۲	ماه‌های گرم (۱۳۸۵-۱۳۸۷)	۱۳۸۷/۱/۱۵ تا ۱۳۸۷/۷/۳۰ ۱۳۸۸/۱/۱۵ تا ۱۳۸۸/۷/۳۰	۱۳۸۸/۷/۳۰ تا ۱۳۸۸/۷/۱
۳	ماه‌های گرم (۱۳۸۵-۱۳۸۷)	۱۳۸۵/۸/۱ تا ۱۳۸۵/۱۲/۱۵ ۱۳۸۶/۸/۱ تا ۱۳۸۶/۱۲/۱۵	۱۳۸۶/۱۲/۱۵ تا ۱۳۸۶/۱۱/۱۵
۴	ماه‌های گرم (۱۳۸۵-۱۳۸۷)	۱۳۸۷/۸/۱ تا ۱۳۸۷/۱۲/۱۵ ۱۳۸۸/۸/۱ تا ۱۳۸۸/۱۲/۱۵	۱۳۸۸/۱۲/۱۵ تا ۱۳۸۸/۱۱/۱۵

این انتخاب بر پایه دو عامل بود. اول آنکه این تابع غیرخطی بوده و در نتیجه عملکرد غیرخطی مصرف آب را بهتر مدل می‌نماید. ثانیاً بازه‌ای از صفر تا یک دارد که برای اطلاعات نرمالیزه شده ایده آل است. در لایه خروجی هم از تابع خطی PureLine و هم تابع غیرخطی LogSig استفاده شده است. در مرحله اول از همه پارامترهای جدول (۱) به‌عنوان ورودی استفاده گردید و فقط ساختار مدل تغییر یافت. نتایج حاصل در جدول (۳) آورده شده است. در گام بعد با توجه به آزمون حساسیت ارائه شده، تعداد پارامترهای ورودی در ماه‌های گرم و ماه‌های سرد کاهش می‌یابند (جدول ۱). در این انتخاب دو عامل در نظر گرفته شده است. اول اینکه پارامترهایی انتخاب شوند که بیشترین تأثیر را بر میزان مصرف آب داشته باشند و دوم آنکه برای کاربردی شدن مدل پارامترهای اضافی حذف گردند. همچنین با توجه به نتایج مرحله اول، فقط از ساختار شماره دو و سه استفاده شده است. نتایج مدل‌سازی در این مرحله و مقایسه ساختارهای مرحله دوم در جداول (۴) و (۵) ارائه شده است. با بررسی نتایج ساختارهای مختلف جدول (۵)، ساختار نهایی مدل

عصبی با دولایه نهان که لایه اول یک نرون و لایه دوم آن دارای هفت نرون می‌باشد، انتخاب می‌شود. نحوه تعیین ساختار مدل شبکه عصبی در تصویر (۱) آورده شده است.

بررسی نتایج مدل‌سازی

اکنون نتایج پیش‌بینی این مدل در تمام ماه‌های سال بررسی می‌گردد. برای این منظور از اطلاعات دی ۱۳۸۷ الی دی ۱۳۸۸ که آخرین سال بوده و جدیدترین آمار را دارد، استفاده می‌شود. در جدول (۶) نتایج مربوط به آموزش و در جدول (۷) نتایج مربوط به آزمایش ارائه شده است.

جدول ۳- نتایج به‌دست‌آمده از مدل‌سازی، مرحله اول (ساخت مدل با تمام پارامترها در دوره آموزش)

پارامتر	ساختار شماره یک	ساختار شماره دو	ساختار شماره سه	ساختار شماره چهار
تعداد لایه‌ها	۱	۲	۲	۲
تعداد نورون‌ها در لایه پنهان ۱	۵۰-۰	۱	۲	۳
تعداد نرون در لایه پنهان ۲	-	۵۰-۰	۵۰-۰	۵۰-۰
میانگین خطا	۳ تا ۷ درصد	۳ تا ۵/۵ درصد	۱ تا ۴ درصد	۳ تا ۸ درصد
تابع فعال در لایه خارجی	هیچ تفاوتی بین توابع خطی و غیرخطی ندارد.	با توابع غیرخطی نتایج بهتر تولید می‌کند	با توابع خطی نتایج بهتر تولید می‌کند	هیچ تفاوتی بین توابع خطی و غیرخطی ندارد

جدول ۴- نتایج به‌دست‌آمده از مدل‌سازی، مرحله دوم (ساخت مدل با تمام پارامترها در دوره آموزش)

پارامتر	ساختار شماره دو	ساختار شماره سه
تعداد لایه‌ها	۲	۲
تعداد نرون در لایه پنهان اول	۱	۲
تعداد نرون در لایه پنهان دوم	۵۰-۰	۵۰-۰
میانگین خطا	۱ تا ۱/۵ درصد	۱ تا ۲ درصد
تابع فعال در لایه خروجی	با توابع غیرخطی نتایج بهتر تولید می‌کند	با توابع غیرخطی نتایج بهتر تولید می‌کند

جدول ۵- مقایسه نتایج ساختارهای مختلف مدل عصبی

شماره	شماره ساختار	زمان مدل‌سازی	MAPE	حداکثر خطا	حداقل خطا	R
۱	۲	ماه‌های گرم (۱۳۸۵-۱۳۸۶)	1.830	4.10	-6.07	0.405
۲	۳	ماه‌های گرم (۱۳۸۵-۱۳۸۶)	1.743	5.25	-5.54	0.419
۳	۲	ماه‌های سرد (۱۳۸۵-۱۳۸۶)	1.579	6.38	-3.30	0.727
۴	۳	ماه‌های سرد (۱۳۸۵-۱۳۸۶)	1.699	5.90	-4.03	0.831
۵	۲	ماه‌های گرم (۱۳۸۷-۱۳۸۸)	1.685	4.30	-1.66	0.621

شماره	شماره ساختار	زمان مدل سازی	MAPE	حداکثر خطا	حداقل خطا	R
۶	۳	ماه‌های گرم (۱۳۸۷-۱۳۸۸)	1.715	4.19	-2.15	0.549
۷	۲	ماه‌های سرد (۱۳۸۷-۱۳۸۸)	0.891	4.10	-1.17	0.461
۸	۳	ماه‌های سرد (۱۳۸۷-۱۳۸۸)	0.920	4.33	-1.04	0.358

جدول ۶- نتایج خروجی مدل عصبی نهایی، دوره آموزش

شماره	زمان مدل سازی	MAPE	حداکثر خطا	حداقل خطا	R
1	30.10.1387 تا 15.9.1387	1.830	4.10	-6.07	0.405
2	15.12.1387 تا 1.11.1387	1.743	5.25	-5.54	0.419
3	31.2.1378 تا 16.1.1388	1.579	6.38	-3.30	0.727
4	15.4.1388 تا 1.3.1388	1.699	5.90	-4.03	0.831
5	31.5.1388 تا 16.4.1388	1.685	4.30	-1.66	0.621
6	15.7.1388 تا 1.6.1388	1.715	4.19	-2.15	0.549
7	30.8.1388 تا 16.7.1388	0.891	4.10	-1.17	0.461
8	15.10.1388 تا 1.9.1388	0.920	4.33	-1.04	0.358

جدول ۷- نتایج خروجی مدل عصبی نهایی، دوره آزمایش

شماره	زمان مدل سازی	MAPE	حداکثر خطا	حداقل خطا	R
1	30.10.1387 تا 15.9.1387	1.830	4.10	-6.07	0.405
2	15.12.1387 تا 1.11.1387	1.743	5.25	-5.54	0.419
3	31.2.1378 تا 16.1.1388	1.579	6.38	-3.30	0.727
4	1.3.1388 تا 15.4.1388	1.699	5.90	-4.03	0.831
5	31.5.1388 تا 16.4.1388	1.685	4.30	-1.66	0.621
6	1.6.1388 تا 15.7.1388	1.715	4.19	-2.15	0.549
7	16.7.1388 تا 30.8.1388	0.891	4.10	-1.17	0.461
8	1.9.1388 تا 15.10.1388	0.920	4.33	-1.04	0.358


جداول (۶) و (۷) و نمودارهای نمونه ارائه‌شده در تصویرهای (۲) و (۳) نمایانگر قابلیت شبکه‌های عصبی مصنوعی در پیش‌بینی مصرف روزانه آب شهر همدان می‌باشند. همچنین با بررسی نتایج، مشاهده می‌شود که نتایج حاصل از مدل عصبی در فصول گرم سال بسیار بهتر است. این امر به دلیل این اصل است که در ماه‌های گرم سال، پارامترهای هواشناسی تأثیر بیشتری بر مصرف آب دارند.

رابطه پیش‌بینی تقاضای روزانه آب شهری

با توجه به پیچیدگی روند ساخت، آموزش و اجرای مدل شبکه عصبی و به‌منظور کاربردی کردن و ساده‌سازی آن، در ادامه این تحقیق سعی شده است که با استفاده از نتایج مدل شبکه عصبی رابطه ساده‌ای ارائه شود که کاربران بدون نیاز به شناخت و اجرای یک مدل پیچیده بتوانند به راحتی و با تعداد ورودی اندک، با دقت مناسبی تقاضای آب روز بعد را پیش‌بینی نمایند. برای به دست آوردن فرمول حاکم بر تقاضای آب شهر همدان یک مدل شبکه عصبی پرسپترون یک‌لایه و با یک نرون مطابق تصویر (۴) در نظر گرفته می‌شود. این فرض به دلیل سادگی ساختار مدل می‌باشد تا امکان استخراج فرمول حاکم بر مدل عصبی فراهم آید. به دلیل آنکه میزان مصرف آب، یک تابع غیرخطی است؛ لذا تابع فعالیت نرون، LogSig فرض می‌شود. همچنین با توجه به آنکه درجه حرارت خشک و میزان مصرف روز قبل بیشترین تأثیر را در مصرف آب دارند، صرفاً این دو پارامتر به‌عنوان ورودی‌های مدل در نظر گرفته می‌شوند. با توجه به ساختار ارائه‌شده در تصویر (۴)، فرمول حاکم بر این شبکه را می‌توان به صورت رابطه زیر نمایش داد.

$$\text{LogSig}(W.T + W.W + 1.b) = D \quad (5)$$

متغیرهای فوق در جدول (۹) معرفی گردیده‌اند. مقادیر b ، W_1 و W_2 از آموزش شبکه عصبی حاصل می‌گردد.



تصویر ۴- ساختار شبکه عصبی تک نرون

جدول ۸- تعریف متغیرهای به‌کاررفته در فرمول تقاضای آب شهر همدان

نماد	تعریف نماد	نوع پارامتر	واحد
w	مصرف آب روزانه	ورودی	میلیون مترمکعب/روز
T	دمای خشک روزانه	ورودی	درجه سانتی‌گراد
W_1	-	وزن	-
W_2	-	وزن	-
D	پیش‌بینی آب فردا	خروجی	میلیون مترمکعب/روز

پارامتر η که به‌عنوان فاکتور مصرف نام‌گذاری می‌گردد و تابع فعالیت LogSig به‌صورت روابط زیر تعریف می‌شوند:

$$\eta = W_1.T + W_2.W + 1.b$$

$$\text{LogSig}(x) = 1 / (1 + e^{-x})$$

خروجی تابع LogSig همواره بین صفر و یک می‌باشد. برای اینکه خروجی مدل برحسب مترمکعب در روز باشد از تکنیک زیر استفاده می‌شود. هنگام آموزش مدل، میزان مصرف برحسب میلیون مترمکعب در روز و میزان دمای حرارت هوا برحسب درجه سانتی‌گراد است ولی میزان مصرف روز بعد (خروجی مدل) بر عدد ده تقسیم می‌گردد تا در محدوده صفر و یک قرار بگیرد؛ یعنی واحد خروجی مدل یک‌دهم میلیون مترمکعب در روز خواهد بود. برای آنکه خروجی فرمول برحسب میلیون مترمکعب در روز به دست آید، یک ضریب ۱۰ در فرمول وارد می‌شود. با جایگذاری رابطه (۶) در رابطه (۵) می‌توان فرمول میزان تقاضای آب را به دست آورد.

$$D=10(I+e^{-n}) \quad (8)$$

نتایج به‌دست‌آمده از مدل‌سازی که در آن فصول ۳ سال اول به‌عنوان دوره آموزش و سال آخر (۱۳۸۸) به‌عنوان دوره آزمایش بوده‌اند در جداول (۱۰) و (۱۱) ارائه گردیده است. در جدول (۱۰) ضرایب رابط (۶) که از آموزش شبکه عصبی به‌دست‌آمده‌اند و در جدول (۱۱) نتایج مربوط به آزمایش مدل عصبی که همان پیش‌بینی محسوب می‌شود، ارائه شده‌اند. همچنین در تصویر (۵) نتایج خروجی شبکه‌های عصبی همراه با خطای مدل برای فصل تابستان به‌عنوان نمونه ارائه گردیده است که این نتایج بیانگر تطبیق خوب مدل با واقعیت است.


جدول ۹- نتایج به‌دست‌آمده از مدل شبکه عصبی یک‌لایه - دوره آموزش

فصل	W_1	W_2	B
بهار	۰/۲۹۱۴	۰/۰۰۸۵	-۲/۱۲۰۶
تابستان	۰/۳۲۸۷	۰/۰۰۴۳	-۲/۱۳۱۸
پاییز	۰/۲۷۶۳	۰/۰۰۴۶	-۱/۹۲۰۶
زمستان	۰/۳۱۹۰	۰/۰۰۱۲	-۲/۰۵۰۷

مقایسه نتایج شبکه عصبی اصلی با دولایه نهان و فرمول (۸) نشان می‌دهد که برای داده‌های آزمایش در سال ۱۳۸۸، دقت نتایج ناشی از فرمول، حدود یک درصد از نتایج مدل اصلی کمتر می‌باشد. استفاده از فرمول (۸) باعث سهولت در پیش‌بینی می‌شود، هرچند که به دلیل استفاده از تنها دو پارامتر ورودی در مدل عصبی، بهتر است در فواصل زمانی کوتاه‌تری کالیبره گردند تا صحت و W_1 و W_2 پارامترهای دقت نتایج در محدوده قابل قبول تضمین گردد.

جدول ۱۰- نتایج به‌دست‌آمده از مدل شبکه عصبی یک‌لایه - دوره آموزش

فصل	خطای مطلق (%)	ماکزیمم خطا (%)	مینیمم خطا (%)
بهار	۱.۷۹۵	۶.۷۵	-۲/۱۲۰۶
تابستان	۲.۰۲۳	۵.۹۴	-۲/۱۳۱۸
پاییز	۲.۴۹۹	۷.۷۸	-۳/۹۲۰۶
زمستان	۲.۹۰۱	۹.۹۸	-۷/۰۵۰۷



تصویر ۵- نتایج خروجی مدل برای فصل تابستان

جمع‌بندی و نتیجه‌گیری

در این تحقیق با استفاده از شبکه‌های عصبی مصنوعی میزان مصرف روزانه آب شهر همدان پیش‌بینی شده است. نتایج نشان می‌دهد که شبکه‌های عصبی از قابلیت بالایی برای درک الگوی مصرف آب برخوردارند و به‌عنوان ابزاری قدرتمند برای تخمین میزان مصرف کوتاه‌مدت آب به شمار می‌آیند. با توجه به بررسی چهار ساختار مختلف با تعداد متفاوت نرون و لایه‌های نهان، شبکه عصبی مصنوعی با دو لایه نهان که دارای یک نرون در لایه نهان اول و هفت نرون در لایه نهان دوم می‌باشد، بهترین نتیجه را برای تخمین تقاضای کوتاه‌مدت آب شهر همدان نشان داد. با مقایسه توابع فعالیت خطی و غیرخطی مشخص شد که در لایه خروجی مدل عصبی، توابع فعالیت غیرخطی عملکرد بهتری نسبت به توابع خطی از خود نشان می‌دهند. همچنین نتایج حاصل نشان می‌دهد که پارامترهای هواشناسی تأثیر قابل‌ملاحظه‌ای بر میزان مصرف آب دارند. تأثیر پارامترهای هواشناسی بر میزان مصرف آب در ماه‌های گرم سال بسیار بیشتر از ماه‌های سرد سال می‌باشد. در میان پارامترهای هواشناسی، دما بیشترین تأثیر را بر مصرف آب شهری دارد. میزان تأثیر پارامترهای هواشناسی بر میزان مصرف آب شهری در زمان‌های مختلف متفاوت است و گاهی تأثیر معکوس دارد. برای مثال باد در ماه‌های گرم موجب کاهش مصرف می‌گردد ولی در ماه‌های سرد موجب افزایش آن می‌شود.

در ادامه این تحقیق، با استفاده از یک مدل عصبی تک نرون، یک رابطه ساده برای تخمین میزان مصرف آب روزانه شهر همدان به دست آمد. نتایج این تحقیق بیانگر توانایی خوب این رابطه در پیش‌بینی تقاضای کوتاه‌مدت آب است. نتایج نشان می‌دهد که دقت این فرمول از دقت یک مدل عصبی چندلایه حدود یک درصد کمتر است؛ ولی استفاده از این فرمول به زمان کمتری نیاز دارد و کاربرد آن بسیار ساده‌تر است؛ لذا می‌تواند به‌راحتی به‌وسیله کاربران مورد استفاده قرار گیرد. با توجه به اینکه متغیرهای مؤثر در مصرف آب، ماهیتاً دارای طبیعتی تصادفی هستند، برای ارتقا اعتمادپذیری مدل می‌توان از شبکه‌های تصادفی استفاده نمود که این ایده هم‌اینک توسط مؤلفین تحت بررسی است.

منابع

- Buchberger, G., & Wu, L. (1995). Model for instantaneous residential water demand. *J. of Hydraulic Engineering*, Vol. 121, No. 3, 232-246.
- Buchberger, G., & Wells, G. J. (1996). Intensity, duration and frequency of residential water demands. *Journal of Water Resources Planning and Management*, ASCE, Vol. 122, No. 11, 11-18.
- Devore, J. L. (2000). Probability and statistics, Fifth Edition, California Polytechnic State University, 755.
- Liu, J., Savenije, H. G., & Xu, J. (2002). Forecast of water demand in Weinan city in China using WDF-ANN model. *Physics and Chemistry of the Earth*, Vol. 28, 219-224.
- Maidment, D. R., Miaou, S. P., & Crawford, M. M. (1985). Transfer function models of daily urban water use. *J. of Water Resources Research*, Vol. 21, No. 4, 425-432.
- Management & Budget Organization and Ministry of Energy. (1992). Urban water supply design codes, Report No. 117-3, Technical Standards, (in Farsi).
- Maidment, D. R., & Parzen, E. (1984). Cascade model of monthly municipal water use. *J. of Water Resources Research*, Vol. 20, No. 1, 15-23.
- Merritt, F. S. (1983). *Standard Handbook for Civil Engineers*, Third Edition, McGraw-Hill, 1492.
- Monzavi, M. T. (1999). *Water supply*, University of Tehran Press, 0th Edition, 379. (In Farsi).
- Stark, H. L., Stanley, J. S. and Buchanan, I. D. (2000). Water demand forecasting using artificial neural networks, University of Alberta.
- Taebi, A., & Chamani, M. R. (2000). Urban water distribution networks, Isfahan University of Technology Press, 628. (In Farsi).
- Wong, S. T. (1972). A model on municipal water demand: a case study of northeastern Illinois. *Land Econ.*, Vol. 48, No.1, 34-44.
- Young, R. A. (1973). Price elasticity of demand for municipal water: a case study of Tucson and Arizona. *J. of Water Resources Research*, Vol. 9, No. 4, 1068-1072.
- Yu, M. J., Joo, C. N. & Koo, J. Y. (2002). Application of short-term water demand prediction model to Seoul. *J. of Water Science & Technology*, Vol. 46, No. 6-7, 255-261.