پيش بيني تقاضاي كوتاه مدت آب شهر تهران با استفاده از شبكه هاي عصبي مصنوعي

مسعود تابش[*۱] ، سيامك گوشه[۲] و محمدجواد يزدان پناه[۳]

[۱] دانشيار و عضو قطب علمي مديريت و مهندسي زيرساختها - دانشكده مهندسي عمران پرديس دانشكده هاي فني - دانشگاه تهران

[۲] دانش آموخته كارشناسي ارشد مهندسي عمران - پرديس دانشكده هاي فني - دانشگاه تهران

[۳] دانشيار و عضو قطب علمي كنترل و پردازش هوشمند - دانشكده مهندسي برق و كامپيوتر پرديس دانشكده هاي فني - دانشگاه تهران

(تاريخ دريافت ۸۳/۵/۲۱ ، تاريخ دريافت روايت اصلاح شده ۸۵/۳/۳۰ ، تاريخ تصويب۸۵/۱۰/۲)

چكيده

پيش بيني تقاضاي كوتاه مدت آب شهري كمک موثري به مديران و بهره برداران سيستمهاي آب شهري مي باشد تا بتوانند نسبت به مديريت صحيح مصرف، مخازن، پمپها، شيرآلات و تصفيه خانه ها اقدام نمايند. مصرف كوتاه مدت آب تابعي از پارامترهاي مختلف و متنوع مانند شرائط اقليمي و هواشناسي، مناسبتهاي فرهنگي، اقتصادي، اجتماعي و مصارف گذشته مي باشد. بدليل همين تنوع، پيش بيني مصرف كوتاه مدت بصورت تحليلي بسيار مشكل و يا ناممكن مي باشد. در اين شرايط استفاده از سيستمهاي هوشمند مانند شبكه هاي عصبي مصنوعي مي تواند بعنوان يک گزينه راه گشا مطرح گردد. در اين تحقيق با استفاده از شبكه هاي عصبي پرسپترون چند لايه و با الگوريتم آموزشي پس انتشار خطا، ميزان مصرف يک روزه آب شهر تهران بر اساس پارامترهاي هواشناسي و داده هاي تاريخي مصارف گذشته پيش بيني مي شود. نتايج اين تحقيق نشان ميدهد كه با اطلاعات محدود قابل دسترس، شبكه عصبي با دو لايه نهان كه به ترتيب داراي يک و هفت نرون مي باشند توانسته است ميزان تقاضاي روزانه آب شهر تهران را با ضريب همبستگي بيش از ۸۰ درصد و خطاي متوسط حدود دو درصد تخمين بزند. بديهي است با افزايش تعداد داده ها در يک دوره زماني گسترده تر، ميزان دقت مدل قابل بهبود مي باشد. در اين مقاله همچنين با استفاده از شبكه هاي عصبي مصنوعي، يک فرمول ساده براي پيش بيني ميزان مصرف روزانه آب شهر تهران توليد شده است و با ورود داده هاي درجه حرارت هوا و مصرف آب روز قبل، ميزان مصرف روز بعد بدست مياييد. نتايج اين تحقيق نشان ميدهد كه اين فرمول قادر است ميزان تقاضاي روزانه آب شهر تهران را با ميانگين خطاي مطلق حدود ۳ درصد، تخمين بزند.

واژه هاي كليدي : شبكه هاي عصبي مصنوعي - تقاضاي كوتاه مدت آب - پارامترهاي هواشناسي - مصرف آب

مقدمه

براي مديريت سيستمهاي آب شهري و تصميم گيري در خصوص تامين آب و بهره برداري بهينه از شبكه هاي توزيع، نياز به اطلاعات و ابزارهايي است كه يكي از مهمترين و اصلي ترين آنها، پيش بيني نياز آبي - تقاضا - به عنوان بار وارد بر شبكه ميباشد. پيش بيني مصرف آب را در دوره هاي كوتاه مدت، ميان مدت و بلند مدت [۲،۱] مي توان مطرح نمود. پيش بيني بلند مدت معمولاً بازه اي از يك تا چند سال را در بر مي گيرد و از اطلاعات بدست آمده به منظور طراحي شبكه، تأمين منابع آبي جديد و توسعه شبكه استفاده مي شود. پيش بيني ميان مدت براي بازه هاي ماهانه و فصلي صورت مي گيرد. پيش بيني كوتاه مدت معمولاً بازه اي از يك ساعت تا چند روز را شامل مي گردد. در مديريت آب شهري دانستن تقاضاي كوتاه مدت بسيار مهم و حياتي است و از آن ميتوان در موارد زير بهره برد: مديريت منابع آب، مديريت بهره برداري مخازن و تصفيه خانه هاي آب، برنامه ريزي و مديريت پمپها و شير آلات شبكه، تعيين قابليت اطمينان شبكه، كنترل كيفيت آب، مديريت بهره برداري در تصفيه خانه، تعيين بهترين زمان جهت تعميرات و بازسازي شبكه،

* نويسنده مسئول : تلفن : ۶۱۱۱۲۲۵۸ – ۰۲۱ , فاكس : ۶۶۴۰۳۸۰۸ – ۰۲۱ , Email: mtabesh@ut.ac.ir

کاهش آب به حساب نیامده، پیش بیني مقدار فروش آب، هزینه هاي دریافتي و مقایسه عرضه و تقاضا.

بیشتر مقالاتي که به بحث در مورد پیش بیني مصرف آب شهري مي پردازند، مصرف ماهانه یا سالانه و بعبارتي میان مدت و بلند مدت را در نظر گرفته اند و تنها تعداد اندکي از آنها مصرف کوتاه مدت را بررسي کرده اند. این تحقیقات بیشتر بر اساس مدلهاي آماري، رگرسیون چندگانه و سریهاي زماني به پیش بیني مصرف پرداخته اند [٤،٣]. بحث پیش بیني بلند مدت مصرف ابتدا توسط Wong در سال ١٩٧٢ [٥]، Young در سال ١٩٧٣ [٦] و Willlsie در سال ١٩٧٤ [٧] مطرح شد. آنها با استفاده از سریهاي زماني، مصرف سالانه آب را بر اساس جمعیت، درآمد سرانه، قیمت آب، بارندگي، درجه حرارت و تبخیر مدل نمودند. در سال ١٩٨٤ Maidment و Parzen [٨] مصرف ماهیانه (میان مدت) آب در تگزاس را توسط سري زماني تخمین زدند. در این تحقیق آنها ابتدا مقادیر سري زماني را به دو مولفه همیشگي و تصادفي تقسیم نمودند. مولفه‌هاي همیشگي، شامل مولفه‌هاي روند و فصلي مي شد که مولفه روند را به وسیله رگرسیون بین میانگین مصرف آب سالیانه و جمعیت شهر مدل کردند و مولفه فصلي را نیز با استفاده از سري‌هاي فوریه تخمین زدند. آنها براي مدل کردن مولفه تصادفي از دو معادله استفاده نمودند. یکي از این معادلات، همبستگي مصرف آب با مقادیر مصرف شده در روزهاي قبل و معادله دیگر، همبستگي مصرف آب با متغیرهاي آب و هوایي، نظیر حداکثر درجه حرارت ماهانه، تبخیر و بارش را بررسي مي‌کرد. در سال ١٩٨٥ Maidment و همکارانش [٩] یک تابع انتقال[1] براي پیش بیني مصرف روزانه آب براي شهر تگزاس بکار بردند. همچنین آنها یک مدل مصرف کوتاه مدت توسط سریهاي زماني Box-Jenkins ساختند که در آن از اطلاعات بلند مدت و کوتاه مدت بصورت توام استفاده گردید. استفاده از شبکه هاي عصبي براي پیش بیني مصرف کوتاه مدت ابتدا در سال ٢٠٠٠ توسط Stark و همکارانش براي شهر آلبراتا در کانادا بکار رفت [١٠]. آنها مصرف روزانه آب و همچنین مصرف روزانه ده روز آتي را با استفاده از پارامترهاي ماکزیمم و مینیمم درجه حرارت، بارش روز گذشته، مجموع بارش ٥ روز گذشته، مجموع بارش ٣٠ روز گذشته، اندیس تعطیلي و غیر تعطیلي و اندیس فصل پیش بیني نمودند. این روش در سال ٢٠٠٢ توسط Yu و همکارانش [١١] براي سئول در کره جنوبي بکار رفت. آنها از یک شبکه عصبي سه لایه استفاده نمودند. در این تحقیق از ماکزیمم درجه حرارت، تعطیلات و مصرف روز گذشته بعنوان پارامتر ورودي در تمام فصول سال استفاده گردید. علاوه بر پارامترهاي فوق، سرعت باد در فصل بهار و رطوبت در فصل زمستان نیز به ورودیهاي مدل اضافه گردیدند. Liu و همکارانش در سال ٢٠٠٢ [١٢] شبکه هاي عصبي مصنوعي را براي پیش بیني مصرف ماهانه آب در شهر Weinan در کشور چین بکار بردند. آنها از پارامترهاي اقتصادي نرمالیزه نظیر درآمد سرانه، تعداد افراد خانواده و قیمت آب براي این منظور استفاده نمودند.

میزان مصرف آب، پدیده اي بسیار پیچیده است که تابعي غیرخطي از عوامل بسیاري مي باشد که این عوامل از ناحیه اي به ناحیه دیگر و در طي زمان تغییر مي نمایند. به همین دلیل تاکنون فرمول کامل و جامعي براي میزان مصرف آب ارائه نشده است. فرمولهاي موجود یا دقیق نیستند و یا اینکه از زاویه اي خاص، مثلا از لحاظ اقتصادي [١٤،١٣] میزان مصرف آب را مورد بررسي 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 منطقه اي و اجتماعي - اقتصادي آنجا کالیبره شده اند و با شرایط شهرهاي ایران تطابق ندارند. براي استفاده و کالیبراسیون روشهاي فوق، تهیه اطلاعات و آمار مناسب و طولاني مدت و با دقت بالا نیاز میباشد. حال آنکه در کشور ما به لحاظ برخي از مشکلات تکنولوژیک و ضعف درجمع آوري آمار و تهیه بانکهاي اطلاعاتي، چنین پایگاه کاملي از داده ها در دسترس نمیباشد، یا اینکه پارامترهاي اندازه گیري شده قابل اطمینان نیستند. با توجه به اینکه پیش بیني تقاضاي روزانه آب شهري در شهرهاي مهمي همچون تهران گام مهمي در بهبود مدیریت این شبکه ها مي باشد ولي بعلت محدودیت فراوان اطلاعات، تاکنون اقدام مناسبي در این زمینه صورت نگرفته است، هدف این مقاله ارائه یک روش مناسب و قابل اطمینان براي

بدست آوردن ميزان تقاضاي روزانه آب شهر تهران مي باشد. با توجه به عوامل ذكر شده مشخص ميگردد كه به ابزاري جهت پيش بيني نياز است كه توانايي يادگيري برداشت هاي ميداني ناقص موجود را داشته باشد و به علاوه بتواند در مقابل نوسانهاي ناشي از عدم دقت در داده ها مقاومت نمايد. در اين شرايط، شبكه هاي عصبي يكي از گزينه هاي مناسب بشمار مي آيند. زيرا بدليل هوشمند بودن، قابليت يادگيري الگوي مصرف پيچيده آب را دارند و هم با اطلاعات آماري محدود - در حد چند سال - ميتوانند به جواب مطلوب برسند. در اين تحقيق با استفاده از پارامترهاي هواشناسي و داده هاي تاريخي مصرف روزانه آب در گذشته، مصرف روزانه آب تهران بوسيله شبكه هاي عصبي مصنوعي مدل مي شود. بنابراين مزيت اين تحقيق نسبت به كارهاي قبلي تنوع بيشتر و تفاوت ساختارها و تفاوت پارامترهاي مدل و كاربرد مدل براي اولين بار در مورد داده هاي آب شهر تهران مي باشد. علاوه بر اين در اين مقاله جهت ساده سازي و استفاده راحت كاربران، با استفاده از شبكه هاي عصبي مصنوعي، يک فرمول ساده براي پيش بيني ميزان تقاضاي روزانه آب شهر تهران توليد شده است.

بررسي و انتخاب پارامترهاي ورودي به مدل (آناليز حساسيت)

براي آنكه بتوان ميزان مصرف آب را پيش بيني نمود، بايد در مورد نوع مصرف كنندگان هم شناخت كافي داشت. مصرف آب شهري را مي توان در چهار شاخه طبقه بندي كرد: مصرف خانگي، صنعتي، تجاري و عمومي. البته به موارد فوق مصرف آتش نشاني و ميزان آب به حساب نيامده را هم مي توان اضافه نمود. عوامل بسياري در ميزان مصرف آب شهري تأثير مي گذارند كه از جمله مي توان به عوامل اقليمي (هواشناسي) شامل دما، نزولات جوي، فشار هوا، باد، ساعات آفتابي و اثر رطوبت هوا، عوامل اجتماعي و اقتصادي شامل سطح زندگي مردم، ميزان درآمد سرانه، تعداد افراد در هر خانه، اندازه زمين خانه، فرهنگ زندگي و قيمت آب، جمعيت و بافت شهري، كيفيت شبكه توزيع آب شامل نحوه اجراي شبكه و كيفيت آن، عمر شبكه، مديريت شبكه و مديريت مصرف و عوامل متفرقه مانند پريود صدور قبض آب و سن افراد اشاره نمود. از بين اين عوامل تنها پارامترهاي هواشناسي و اقليمي بر مصرف كوتاه مدت آب موثر مي باشند. علاوه بر موارد فوق كه ميزان مصرف پايه را مشخص مي كند تغيير فصول سال، روزهاي هفته و تعطيلات نيز موجب نوسان مصرف آب مي شوند [۱۷،۱۵،۱۶،۲].

در انتخاب پارامترهاي ورودي به مدل، دو اصل مد نظر قرار ميگيرند. اول آنكه متغيرهايي انتخاب گردند كه با توجه به شرايط اقليمي و اقتصادي - اجتماعي شهر مورد نظر يعني تهران، بر مصرف آب كوتاه مدت تأثير محسوس داشته باشند. ديگر اينكه اطلاعات آماري اين پارامترها بعنوان ورودي به مدل عصبي در دسترس باشد. اطلاعات مربوط به هواشناسي، از طريق سازمان هواشناسي كل كشور تهيه شده است كه مربوط به ده سال مي باشد. ميزان مصرف آب روزانه از سازمان آب و فاضلاب كشور تهيه شد كه مصرف روزانه پنج سال را شامل مي گردد. در نهايت از آنجا كه محدوده زماني اين داده ها در يک دوره حدود چهارسال - فروردين ۱۳۷۵ تا دي ۱۳۷۸- با يكديگر انطباق داشتند، اطلاعات مصرف آب و پارامترهاي هواشناسي اين دوره زماني براي مدلسازي انتخاب شدند.

براي بررسي تاثير پارامترها بر مصرف آب از آناليز حساسيت استفاده مي گردد. در اين مقاله از ضريب حساسيت نرمال استفاده مي شود كه از رابطه زير بدست مي آيد:

$$S_{ij} = \frac{\partial y_i}{y_i} \div \frac{\partial x_j}{x_j} = \frac{\partial y_i}{\partial x_j} \cdot \frac{x_j}{y_i} \qquad (۱)$$

كه S_{ij} : حساسيت متغير وابسته (i) نسبت به متغير مستقل (j) ، y : متغير وابسته و x : متغير مستقل ميباشند.

براي محاسبه ضريب حساسيت داده ها از بسته نرم افزاري SPSS (نگارش۱۱.۰) استفاده و نتايج در جدول (۱) نشان داده شده است.

با بررسي نتايج حاصل از نرم افزار SPSS مشاهده مي شود كه در فصول مختلف، تأثير پارامترهاي مختلف بر مصرف آب متغير مي باشد. لذا در اين تحقيق هر سال به دو دوره زماني تقسيم مي شود و براي هر دوره، يک مدل عصبي توليد مي گردد تا عملكرد شبكه هاي عصبي در مدلسازي شرايط واقعي بهبود يابد. اين دو

دوره زماني بعنوان ماههاي گرم و ماههاي سرد نامگذاري شدند. ماههاي گرم از ١٥ فروردين الي ٣٠ مهر و ماههاي سرد از اول آبان الي ١٥ اسفند ماه انتخاب گرديد. همچنين اطلاعات مربوط به يكماه از سال، ١٦ اسفند تا ١٥ فروردين، بدليل شرايط خاص عيد نوروز كه متاثر از پارامترهاي هواشناسي نبوده ولي در عين حال باعث نوسانات مصرف مي شود (افزايش مصرف در دوران خانه تكاني و كاهش مصرف بدليل مسافرتهاي گسترده در تعطيلات نوروز) لحاظ نگرديد.

در اين مقاله از اطلاعات نرماليزه شده استفاده گرديده است. در نرمال سازي، پراكندگي و فاصله ها به يك ناحيه اشباع - بين صفر و يك - تبديل ميشود. روشهاي متعددي براي نرمال سازي وجود دارد.

جدول ١: نتايج آناليز حساسيت.

No.	Parameter	Correlation Coefficient		Model Input Parameters	
		Cold Months	Hot Months	First Step	Second Step
1	Year	0.431	0.254	✓	×
2	Month	-0.216	0.424	✓	×
3	Week Days	0.440	0.066	✓	×
4	Weekend	0.379	0.016	✓	×
5	Yesterday Water Consumption	0.577	0.921	✓	✓
6	Water Consumption of 2 Days Ago	0.390	0.886	✓	×
7	Water Consumption of 3 Days Ago	0.435	0.883	✓	×
8	Water Consumption of 7 Days Ago	0.704	0.858	✓	✓
9	Dry Temperature	0.454	0.850	✓	✓
10	Yesterday Dry Temperature	0.396	0.851	✓	✓
11	Dry Temperature of 2 Days Ago	0.368	0.835	✓	×
12	Dry Temperature of 3 Days Ago	0.342	0.816	✓	×
13	Wet Temperature	0.434	0.793	✓	✓
14	Yesterday Wet Temperature	0.407	0.794	✓	✓
15	Wet Temperature of 2 Days Ago	0.375	0.784	✓	×
16	Minimum Temperature	0.360	0.820	✓	×
17	Yesterday Minimum Temperature	0.358	0.815	✓	×
18	Minimum Temperature of 2 Days Ago	0.339	0.795	✓	×
19	Maximum Temperature	0.489	0.852	✓	✓
20	Yesterday Maximum Temperature	0.408	0.848	✓	✓
21	Maximum Temperature of 2 Days Ago	0.371	0.830	✓	×
22	Average Temperature	0.442	0.850	✓	✓
23	Yesterday Average Temperature	0.396	0.845	✓	✓
24	Average Temperature of 2 Days Ago	0.365	0.826	✓	×
25	Average Temperature of 3 Days Ago	0.338	0.808	✓	×
26	Absolute Humidity	0.241	0.428	✓	×
27	Relative Humidity	-0.200	-0.541	✓	×
28	Surface Temperature	0.312	0.827	✓	×
29	Sunshine Hours	0.286	0.448	✓	×
30	Precipitation	-0.184	-0.246	✓	×
31	Wind	0.017	-0.088	✓	×
32	Pressure at Station	0.112	-0.445	✓	×
33	Pressure at Sea Surface	-0.041	-0.690	✓	×

در اين تحقيق از فرمول زير استفاده شده است [۱۲]:

$$x_{nor} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (۲)$$

كه در آن x مقدار غير نرماليزه، x_{nor} مقدار نرماليزه و x_{max} و x_{min} به ترتيب بيشترين و كمترين مقدار مربوط به يك پارامتر ميباشد.

شاخصهاي ارزيابي مدل

با توجه به اينكه در اين تحقيق مدلهاي زيادي توليد خواهند شد بايد مشخص شود كه كدام مدل بهترين تطابق را با واقعيت دارد و مي تواند ميزان مصرف را با بهترين تقريب و كمترين خطا محاسبه نمايد و نهايتاً با توجه به اهداف مورد نظر، كدام مدل، توليد كننده بهترين جواب مي باشد. براي اين منظور بايد به ارزيابي مدل و نتايج خروجي آن پرداخت. منظور از ارزيابي مدل اين است كه مدل تا چه حد قادر است با توجه به آموزشي كه ديده است نسبت به ورودیهاي جديد جواب قابل قبولي ارائه دهد. روشهاي متعددي در ارزيابي يك مدل وجود دارد. در اين تحقيق دو شاخص زير بعنوان معيار براي ارزيابي انتخاب شده اند:

ميانگين درصد خطاي مطلق[۲] (MAPE): اين معيار كه به وسيله تعداد زيادي محقق براي ارزيابي پيش بيني انتخاب شده است بصورت رابطه زير تعريف مي شود [۱۸]:

$$MAPE = \frac{1}{n}\sum_{i=1}^{n}\frac{|Actual_i - Forecast_i|}{Actual_i} \times 100 \quad (۳)$$

كه n تعداد داده ها، $Actual_i$ داده هاي واقعي و $Forecast_i$ داده هاي پيش بيني شده مي باشند. هر چقدر اين شاخص به صفر نزديكتر باشد بيانگر كارآيي بهتر مدل است. در اين تحقيق با توجه به ساير تحقيقات انجام گرفته [۱۸]، ميانگين درصد خطاي مطلق ۵ درصد بعنوان يک حد مطلوب در نظر گرفته شده است. لازم به ذكر است كه علاوه بر ميانگين درصد خطاي مطلق، از مقادير خطاي ماكزيمم و مينيمم نيز بعنوان شاخصهايي براي مقايسه استفاده شده است كه در آنها براي تعيين درصد خطا از فرم رابطه (۳) بدون قدر مطلق و ميانگين گيري استفاده مي شود.

ضريب همبستگي[۳] (R): ضريب همبستگي بعنوان يك معيار براي ارتباط بين داده ها بكار مي رود و بيانگر شدت وابستگي ميان x و y در يك فضاي نمونه مي باشد. ضريب همبستگي از رابطه زير بدست مي آيد:

$$R = R(x,y) = \frac{cov(x,y)}{\sigma_x \sigma_y} = \frac{\frac{1}{n}\sum_{i=1}^{n}(x_i - \mu_x)(y_i - \mu_y)}{\sqrt{\frac{1}{n}\sum(x_i - \mu_x)^2} \cdot \sqrt{\frac{1}{n}\sum(y_i - \mu_y)^2}} \quad (۴)$$

كه x و y به ترتيب مقدار مصرف روزانه واقعي و مقدار مصرف روزانه پيش بيني شده توسط مدل، cov(x,y): كوواريانس x و y، μ_x و μ_y : مقادير ميانگين مصارف روزانه واقعي و پيش بيني شده، σ_x^2: واريانس داده‌هاي x و σ_y^2: واريانس داده‌هاي y ميباشند. مقدار R همواره بين منهاي يک و بعلاوه يک قرار دارد و هر چقدر R به يك نزديكتر باشد بيانگر عملكرد بهتر مدل است [۱۹]. در اين تحقيق ضريب همبستگي بالاي ۰/۸ بعنوان يک حد مطلوب در نظر گرفته شده است.

تهيه مدل شبكه عصبي

همانگونه كه قبلا ذكر شد در اين تحقيق از روش شبكه هاي عصبي مصنوعي براي مدلسازي استفاده مي شود. شبكه هاي عصبي داراي ويژگيهايي به شرح زير هستند [۲۰]: قابليت تقريب زني عمومي دارند و تقريباً مي توانند هر تابعي را تقريب بزنند. اين مدلها بصورت خودكار قابليت تطبيق[۴] دارند و هنگامي كه رابطه موجود در اطلاعات آماري تغيير ميكند خود را به روز مينمايند. شبكه هاي عصبي در مقايسه با ساير روشهاي پيش بيني بسيار پايدارتر مي باشند. براي استفاده از شبكه هاي عصبي، احتياج به يادگيري روشهاي پيچيده نبوده و فقط به اطلاعات اوليه آماري احتياج است. براي كار با شبكه هاي عصبي به شناخت عميق از ارتباط و واكنش بين متغيرهاي موجود در مساله و نيز رابطه متغيرها و يا تابع موجود نيازي نمي باشد. همچنين بدليل خاصيت پردازش متني در شبكه هاي عصبي، متغيرهاي آماري نادرست و خطا دار تأثير بسيار كمي بر نتايج مي گذارند.

تـاكنون روشـها و الگوريتمهـاي مختلفـي بـراي آموزش شبكه هـاي عصـبي ارائـه شـده اسـت. يكـي از مهمترين اين الگوريتمهـا، الگـوريتم پـس انتشـار خطـا مي باشد كه در اين تحقيق مـورد اسـتفاده قـرار گرفتـه است. اين الگوريتم مكمل توپولوژي شبكه هـاي عصـبي چند لايه پيشرو است [١٥]. همچنين بهمـراه الگـوريتم پس انتشار خطا از شبكه هاي پرسپترون چند لايـه كـه در شناخت الگو و تابع حاكم بر يک مساله خاص بسـيار متبحر هستند استفاده شده است.

در ايــن تحقيــق از بســته نــرم افــزاري Matlab (ويرايش ٦.١) كه حاوي ماژول شبكه هاي عصـبي مـي باشد استفاده شده است. ماژول شبكه عصبي نـرم افـزار Matlab داراي يك رابط گرافيكي[5] مي باشـد كـه كـاربر دوسـت بـوده و امكـان سـاخت شـبكه هـاي عصـبي بـا ساختار هاي مختلف را در حداقل زمان فـراهم ميسـازد. با در نظر گرفتن ماهيت اين تحقيق كه نيازمند سـاخت و آموزش تعداد زيـادي مـدل عصـبي اسـت، نـرم افـزار Matlab بسيار مناسب مـي باشـد. در مدلسـازي شـبكه هاي عصبي توصيه شده است قبـل از آمـوزش، وزنهـاي شبكه عصبي با مقادير كوچـك و تصـادفي مقـدار دهـي شود[6]. اين امر به آموزش بهتر شبكه كمك مي كنـد. در نرم افزار Matlab اين مطلب را مي تـوان بـا اسـتفاده از يك گزينـه، بصـورت خودكـار و سـريع انجـام داد. بايـد توجه داشت كه يك مـدل شـبكه عصـبي بـا سـاختار و بردارهاي آموزشي يكسان كه وزنها با مقدار دهـي اوليـه مختلف آموزش يابد، نتايج يكسـان ارائـه نميكننـد، هـر چند كه غالباً نتايج آنها نسبتاً نزديك به هم مـي باشـد. در اين تحقيق هر مدل عصبي حداقل پنج بار بـا مقـدار دهي اوليه متفاوت آمـوزش داده شـده و بهتـرين نتـايج خروجي انتخاب مي گردد.

همانطور كه ذكر شد، در اين پژوهش اطلاعات چهارسال - فروردين ١٣٧٥ الي بهمن ١٣٧٨ – كه طي آن داده هاي هواشناسي و مصرف آب تقريبا بر يكديگر منطبق مي باشند موجود بوده است. براي آنكه ورودي كافي براي آموزش شبكه هاي عصبي در دسترس باشد، از اطلاعات دو سال متوالي بطور توأمان براي هر مدل استفاده مي شود. مشخصات مدلها در جدول (٢) خلاصه شده است.

براي مدلسازي دو مجهول اساسي وجود دارد. اولين مجهول، ساختار شبكه عصبي است كه شامل تعداد لايه ها، نرونهاي هر لايه و توابع فعاليت مي باشد. دومين مجهول، تركيب پارامترهاي ورودي در مدل است. در انتخاب پارامترها بهتر است كاربردي بودن مدل هم مد نظر قرار گيرد. بديهي است اگر مدل تعداد زيادي پارامتر ورودي داشته باشد، استفاده از آن با دشواري همراه خواهد بود. براي يافتن بهترين ساختار در شبكه هاي عصبي چاره اي جز بررسي ساختارهاي مختلف به روش سعي و خطا نمي باشد. در اين تحقيق مدلهاي زيادي ساخته شده و آزمايش گرديده است.

مدلسازي از ساده ترين ساختار آغاز و بتدريج تعداد نرونها و لايه ها افزايش مي يابد. بدليل آنكه خروجي مدل فقط ميزان مصرف آب روزانه است، لذا لايه خروجي تنها يك نرون خواهد داشت. در اين مقاله، توابع فعاليت تمام نرونهاي يك لايه، يكسان انتخاب مي شوند. توابع فعاليت لايه خروجي مي تواند غيرخطي و يا خطي باشد. در اين تحقيق توابع فعاليت لايه هاي مياني از نوع غيرخطي LogSig انتخاب گرديده اند.

جدول ٢: معرفي مدلهاي عصبي.

Model No.	Explanation	Training Time	Testing Time
1	Hot Months (1375-1376)	15.1.1375 to 30.7.1375 15.1.1376 to 31.6.1376	1.7.1376 to 30.7.1376
2	Hot Months (1377-1378)	15.1.1377 to 30.7.1377 15.1.1378 to 31.6.1378	1.7.1378 to 30.7.1378
3	Cold Months (1375-1376)	1.8.1375 to 15.12.1375 1.8.1376 to 15.11.1376	15.11.1376 to 15.12.1376
4	Cold Months (1377-1378)	1.8.1377 to 15.12.1377 1.8.1378 to 10.9.1378	11.9.1378 to 10.10.1378*

*داده هاي مصرف آب تا پايان دي ماه ١٣٧٨ موجود مي باشد.

اين انتخاب بر پايه دو عامل بود. اول آنكه اين تابع غيرخطي بوده و در نتيجه عملكرد غيرخطي مصرف آب را بهتر مدل مي نمايد. ثانياً بازه اي از صفر تا يك دارد كه براي اطلاعات نرماليزه شده ايده ال است. در لايه خروجي هم از تابع خطي PureLine و هم تابع غيرخطي LogSig استفاده شده است.

در مرحله اول از همه پارامترهاي جدول (۱) بعنوان ورودي استفاده گرديد و فقط ساختار مدل تغيير يافت. نتايج حاصل در جدول (۳) آورده شده است. در گام بعد با توجه به آزمون حساسيت ارائه شده، تعداد پارامترهاي ورودي در ماههاي گرم و ماههاي سرد كاهش مي يابند (جدول ۱).

در اين انتخاب دو عامل در نظر گرفته شده است. اول اينكه پارامترهايي انتخاب شوند كه بيشترين تأثير را بر ميزان مصرف آب داشته باشند و دوم آنكه براي كاربردي شدن مدل پارامترهاي اضافي حذف گردند. همچنين با توجه به نتايج مرحله اول، فقط از ساختار شماره دو و سه استفاده شده است. نتايج مدلسازي در اين مرحله و مقايسه ساختارهاي مرحله دوم در جداول (٤) و (٥) ارائه شده است. با بررسي نتايج ساختارهاي مختلف (جدول ٥)، ساختار نهايي مدل عصبي با دو لايه نهان كه لايه اول يک نرون و لايه دوم آن داراي هفت نرون مي باشد، انتخاب مي شود.

نحوه تعيين ساختار مدل شبكه عصبي در شكل (۱) آورده شده است.

بررسي نتايج مدلسازي

اكنون نتايج پيش بيني اين مدل در تمام ماههاي سال بررسي مي گردد. براي اين منظور از اطلاعات دي ۱۳۷۷ الي دي ۱۳۷۸، كه آخرين سال بوده و جديدترين آمار را دارد، استفاده مي شود. در جدول (٦) نتايج مربوط به آموزش و در جدول (۷) نتايج مربوط به آزمايش ارائه شده است. بعنوان نمونه در شكلهاي (۲) و (۳) دو نمونه از نتايج خروجي اين مدلها بصورت نمودارهاي ٤٥ روزه ارائه گرديده است.

جدول ۳ : نتايج بدست آمده از مدلسازي – مرحله اول (ساخت مدل با تمام پارامترها در دوره آموزش).

Parameter	1st Structure	2nd Structure	3rd Structure	4th Structure
No. of Layers	1	2	2	2
No. of Neurons in the 1st Hidden Layer	0-50	1	2	3
No. of Neurons in the 2nd Hidden Layer	-	0-50	0-50	0-50
Average Error	2% - 8%	2% - 4%	1.5% - 5%	2% - 9%
Activation Function in the Output Layer	No difference between linear and nonlinear functions	Nonlinear functions produce better results	Linear functions produce better results	No difference between linear and nonlinear functions

جدول ٤: نتايج بدست آمده از مدلسازي – مرحله دوم (ساخت مدل با ۱۰ پارامتر در دوره آموزش).

Parameter	2nd Structure	3rd Structure
No. of Layers	2	2
No. of Neurons in the 1st Hidden Layer	1	2
No. of Neurons in the 2nd Hidden Layer	0-50	0-50
Average Error	1% - 1.5%	1%- 2%
Activation Function in the Output Layer	Nonlinear functions produce better results	Nonlinear functions produce better results

جدول ٥ : مقايسه نتايج ساختارهاي مختلف مدل عصبي.

No.	Structure No.	Time of Modeling	MAPE (%)	Max. Error (%)	Min. Error (%)	R
1	2	Hot Months (1375-1376)	1.753	4.10	-6.07	0.433
2	3	Hot Months (1375-1376)	1.643	4.04	-5.54	0.429
3	2	Cold Months (1375-1376)	1.594	7.06	-3.30	0.721
4	3	Cold Months (1375-1376)	1.717	5.67	-4.03	0816
5	2	Hot Months (1377-1378)	1.633	4.50	-1.66	0529
6	3	Hot Months (1377-1378)	1.647	4.63	-2.15	0.552
7	2	Cold Months (1377-1378)	0.886	3.62	-1.17	0.416
8	3	Cold Months (1377-1378)	0.930	4.21	-1.04	0376

جدول ٦ : نتايج خروجي مدل عصبي نهايي – دوره آموزش.

No.	Time of Modeling	MAPE (%)	Max. Error (%)	Min. Error (%)	R
1	15.9.1377 to 30.10.1377	2.207	14.70	-20.11	0.890
2	1.11.1377 to 15.12.1377	2.950	15.54	-21.88	0.751
3	16.1.1378 to 31.2.1378	2.558	15.08	-20.06	0.948
4	1.3.1378 to 15.4.1378	2.669	14.22	-20.02	0.945
5	16.4.1378 to 31.5.1378	2.716	14.85	-20.41	0.942
6	1.6.1378 to 15.7.1378	2.658	14.75	-20.59	0.945
7	16.7.1378 to 30.8.1378	2.115	7.56	-7.64	0.766
8	1.9.1378 to 15.10.1378	1.996	5.59	-7.40	0.799

جدول ٧ : نتايج خروجي مدل عصبي نهايي – دوره آزمايش.

No.	Time of Modeling	MAPE (%)	Max. Error (%)	Min. Error (%)	R
1	15.9.1377 to 30.10.1377	2.426	4.95	-2.30	0.829
2	1.11.1377 to 15.12.1377	4.478	13.41	-19.95	0.755
3	16.1.1378 to 31.2.1378	2.830	13.06	-11.99	0.693
4	1.3.1378 to 15.4.1378	1.986	4.73	-5.91	0.858
5	16.4.1378 to 31.5.1378	1.715	5.47	-4.91	0.808
6	1.6.1378 to 15.7.1378	1.914	5.62	-4.29	0.880
7	16.7.1378 to 30.8.1378	2.201	5.35	-5.40	0.680
8	1.9.1378 to 15.10.1378	2.019	6.74	-2.77	0.505

جداول (٦) و (٧) و نمودارهاي نمونه ارائه شده در شكلهاي (٢) و (٣) نمايانگر قابليت شبكه هاي عصبي مصنوعي در پيش بيني مصرف روزانه آب شهر تهران ميباشند. همچنين با بررسي نتايج، مشاهده مي شود كه نتايج حاصل از مدل عصبي در فصول گرم سال بسيار بهتر است. اين امر بدليل اين اصل است كه در ماههاي گرم سال، پارامترهاي هواشناسي تاثير بيشتري بر مصرف آب دارند.

در ادامه نتايج حاصله از اين تحقيق با يک روش ديگر كه پيش بيني مصرف روزانه آب تهران با استفاده از سيستمهاي فازي انجام شده است، مقايسه ميگردد. براي معيار مقايسه از ميانگين درصد خطاي مطلق و ضريب همبستگي استفاده مي شود. در جدول (٨) نتايج مربوط به مدلهاي عصبي در اين تحقيق و همچنين نتايج مربوط به يكي از تحقيقات انجام شده با مدلهاي فازي [١٨] ارائه گرديده است. البته شايان ذكر است كه روش بكار رفته براي مدلسازي، پردازش اطلاعات و ... در اين تحقيق، با روش منطق فازي يكسان نميباشد. براي مثال در اين تحقيق سال به دو قسمت - ماههاي گرم و سرد - تقسيم شده و براي هر قسمت بطور جداگانه مدلسازي انجام گرفته است.

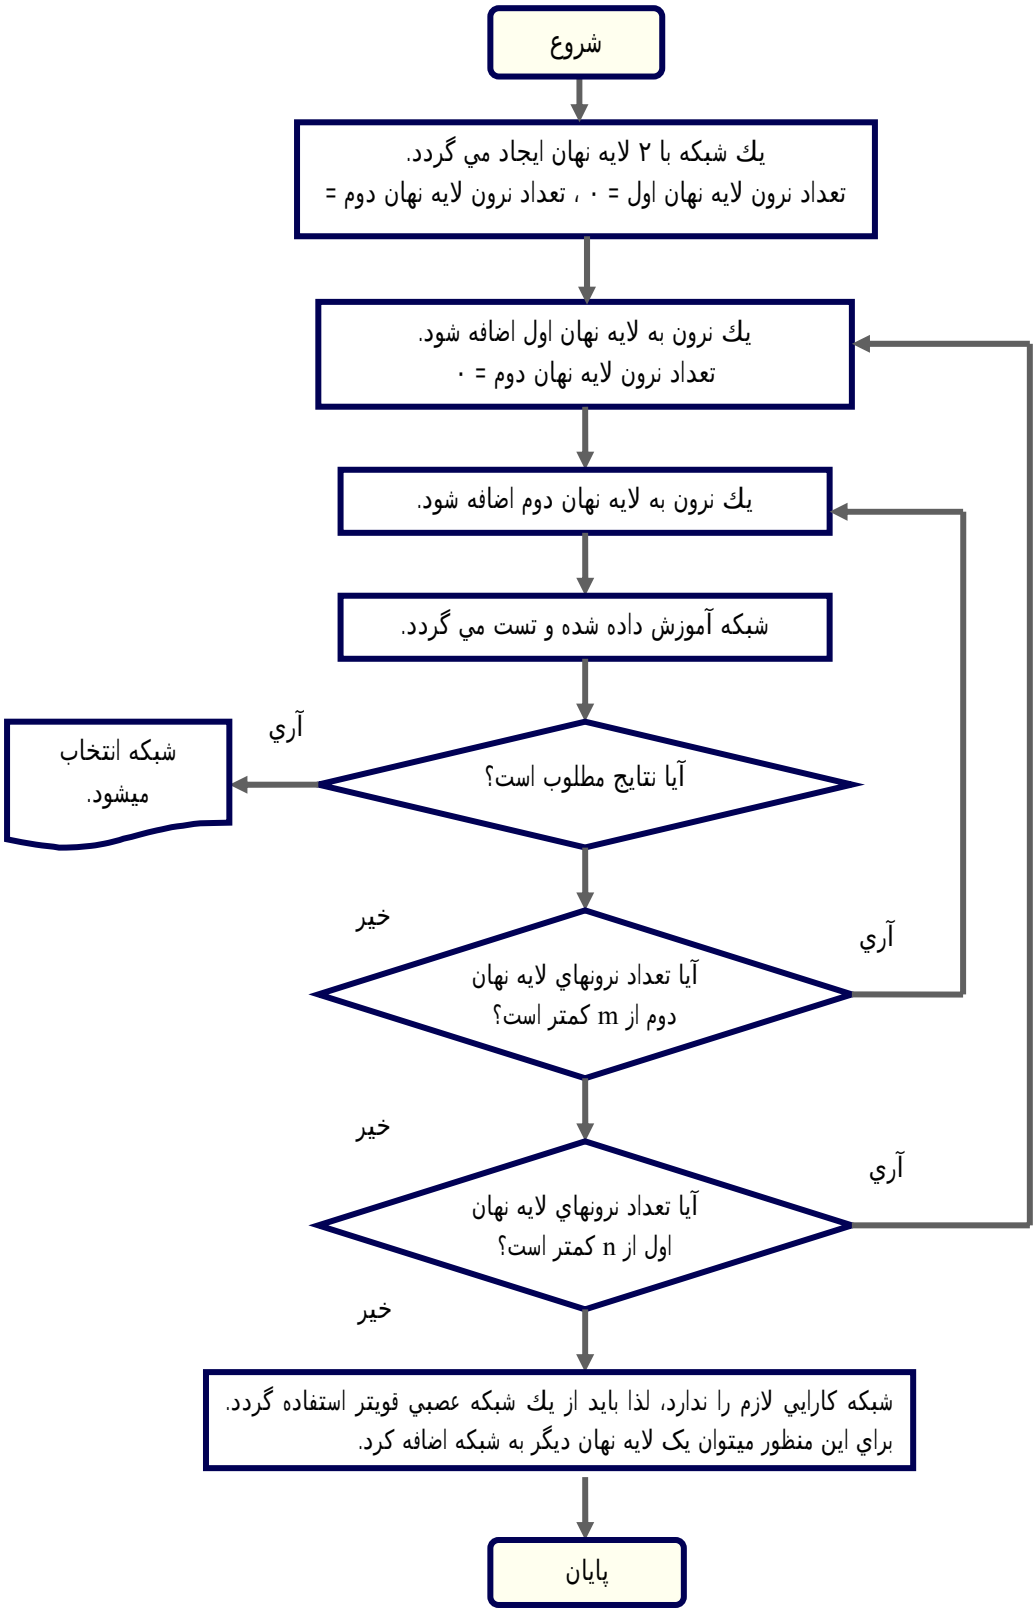

شكل ۱: الگوريتم مدل شبكه عصبي با دو لايه نهان.

m و n بر اساس نوع مسأله، تعداد داده ها و شرايط مدل انتخاب مي شوند.

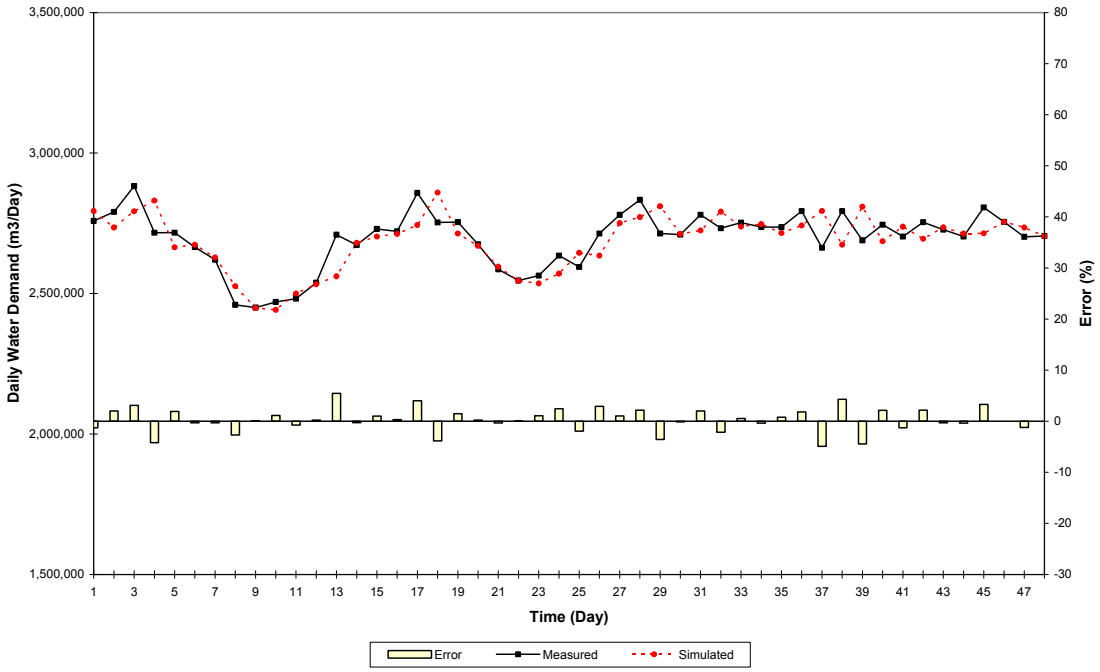

شكل ٢ : نتايج خروجي مدل عصبي (تير و مرداد ١٣٧٨).

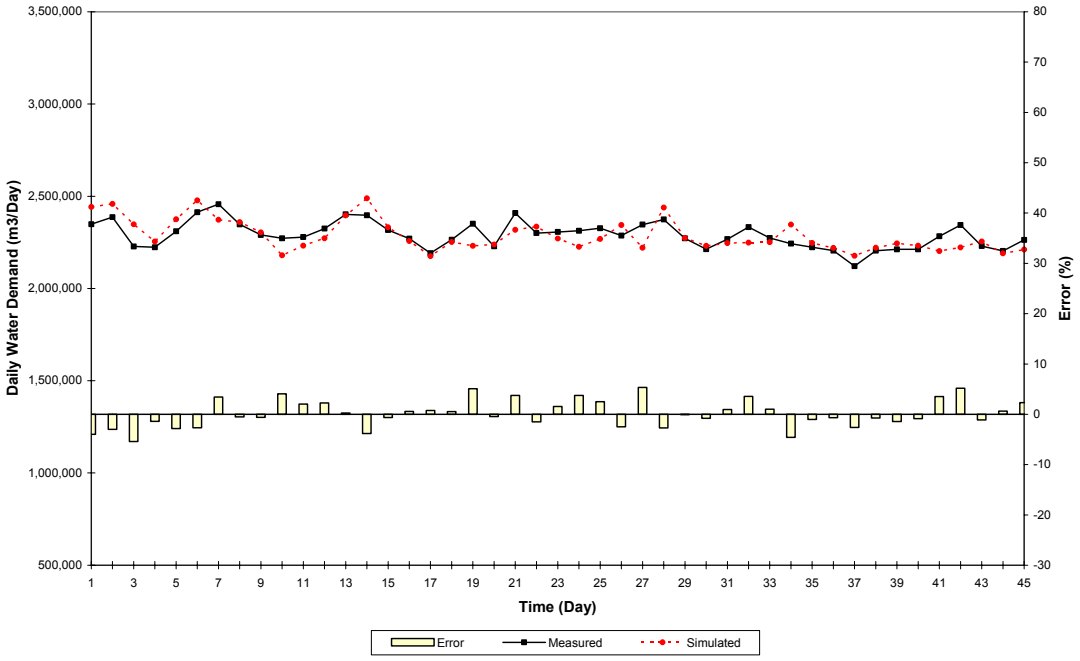

شكل ٣ : نتايج خروجي مدل عصبي (آبان و آذر ١٣٧٨).

جدول ٨ : مقايسه نتايج حاصل از مدلهاى عصبي و فازي [١٨].

Type of Model	Index	Case 1	Case 2	Case 3	Case 4
ANN	MAPE (%)	1.986	1.715	1.919	2.201
	R	0.857	0.808	0.880	0.680
Fuzzy [18]	MAPE (%)	6.740	5.682	6.357	6.410
	R	0.878	0.874	0.859	0.837

حالتهاي ١ تا ٤ مربوط به مدلهاي با ساختارهاي متفاوت از نظر تعداد توابع عضويت و تعداد قواعد فازي ساخته شده و پارامترهاي ورودي در مرجع [١٨] مي باشد.

از مقايسه نتايج دو روش مشاهده مي شود شبكه هاي عصبي خطاي كمتري نسبت به مدلهاي فازي دارند كه خود بيانگر عملكرد بهتر شبكه هاي عصبي در پيش بيني مصرف ميباشد. ضريب همبستگي در دو روش تقريبا نزديک به يكديگر مي باشد. يک مزيت ديگر شبكه هاي عصبي نسبت به منطق فازي اينست كه با حذف پارامترهايي كه تاثير كمتر بر ميزان مصرف دارند - مانند بارندگي - عملكرد مدل بهبود مي يابد ولي در مدلهاي فازي اين امر موجب كاهش عملكرد مدل ميگردد [۱۸]. همچنين براي آموزش شبكه هاي عصبي زمان بسيار كمتري بايد صرف كرد. شبكه هاي عصبي معمولا در چند دقيقه آموزش مي بينند ولي مدلهاي فازي بر اساس ساختار و روش استنتاج از چند دقيقه تا چند ساعت زمان نياز دارند تا آموزش ببينند. البته شايان ذكر است كه يک مزيت روش فازي نسبت به شبكه هاي عصبي قابليت استفاده همزمان از تجربيات كارشناسان مي باشد ولي اين امر در ساير روشها تقريبا محال است.

رابطه پيش بيني تقاضاي روزانه آب شهري

با توجه به پيچيدگي روند ساخت، آموزش و اجراي مدل شبكه عصبي و به منظور كاربردي كردن و ساده سازي آن، در ادامه اين تحقيق سعي شده است كه با استفاده از نتايج مدل شبكه عصبي رابطه ساده اي ارائه شود كه كاربران بدون نياز به شناخت و اجراي يک مدل پيچيده بتوانند براحتي و با تعداد ورودي اندک، با دقت مناسبي تقاضاي آب روز بعد را پيش بيني نمايند. براي بدست آوردن فرمول حاكم بر تقاضاي آب شهر تهران يک مدل شبكه عصبي پرسپترون يك لايه و با يك نرون مطابق شكل (٤) در نظر گرفته مي شود. اين فرض بدليل سادگي ساختار مدل ميباشد تا امكان استخراج فرمول حاكم بر مدل عصبي فراهم آيد. بدليل آنكه ميزان مصرف آب، يك تابع غيرخطي است لذا تابع فعاليت نرون، LogSig فرض ميشود. همچنين با توجه به آنكه درجه حرارت خشك و ميزان مصرف روز قبل بيشترين تاثير را در مصرف آب دارند، صرفا اين دو پارامتر بعنوان ورودیهاي مدل در نظر گرفته ميشوند.

با توجه به ساختار ارائه شده در شكل (٤)، فرمول حاكم بر اين شبكه را ميتوان بصورت رابطه زير نمايش داد.

$$LogSig(W_1.T + W_2.W + 1.b) = D \qquad (۵)$$

متغيرهاي فوق در جدول۹ معرفي گرديده اند. مقادير b، W_1 و W_2 از آموزش شبكه عصبي حاصل مي گردد.

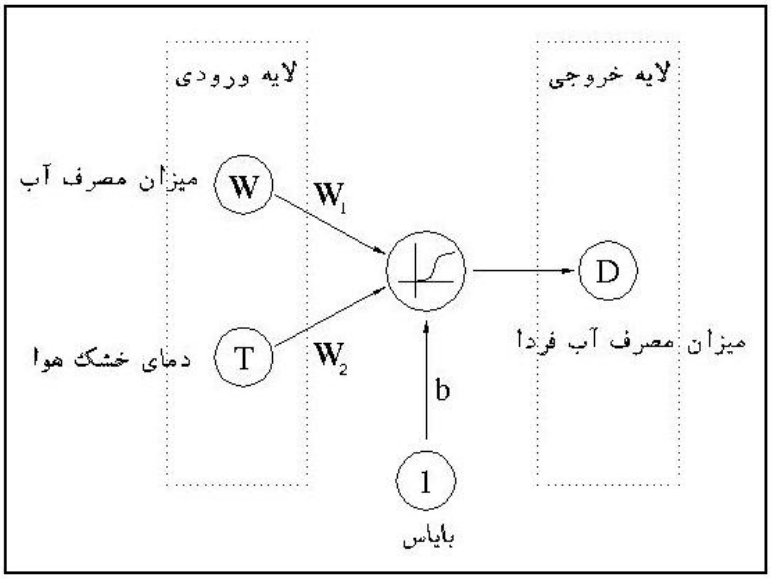

شكل ٤ : ساختار شبكه عصبي تک نرون.

جدول ۹: تعريف متغيرهاي بكار رفته در فرمول تقاضاي آب شهر تهران.

Symbol	Definition	Parameter Type	Unit
W	Today Water Consumption	Input	Million Cubic Meter / day
T	Today Dry Temperature	Input	Degree (Centigrade)
W_1	-	Weight	-
W_2	-	Weight	-
D	Tomorrow Water Demand	Output	Million Cubic Meter / day

پارامتر η که بعنوان فاکتور مصرف نامگذاري ميگردد و تابع فعاليت LogSig به صورت روابط زير تعريف ميشوند:

$$\eta = W_1.T + W_2.W + 1.b \quad (۶)$$

$$LogSig(x) = \frac{1}{1+e^{-x}} \quad (۷)$$

خروجي تابع LogSig همواره بين صفر و يك ميباشد. براي اينكه خروجي مدل برحسب متر مكعب در روز باشد از تكنيك زير استفاده ميشود. هنگام آموزش مدل، ميزان مصرف بر حسب ميليون متر مكعب در روز و ميزان دماي حرارت هوا بر حسب درجه سانتيگراد ميباشد ولي ميزان مصرف روز بعد -خروجي مدل- بر عدد ده تقسيم ميگردد تا درمحدوده صفر و يك قرار بگيرد يعني واحد خروجي مدل يک دهم ميليون متر مكعب در روز خواهد بود. براي آنكه خروجي فرمول برحسب ميليون متر مكعب در روز بدست آيد، يك ضريب ۱۰ در فرمول وارد ميشود. با جايگذاري رابطه (٦) در رابطه (۵) ميتوان فرمول ميزان تقاضاي آب را بدست آورد.

$$D = \frac{10}{1+e^{-\eta}} \quad (۸)$$

نتايج بدست آمده از مدلسازي كه در آن فصول ۳ سال اول بعنوان دوره آموزش و سال آخر (۱۳۷۸) بعنوان دوره آزمايش بوده اند در جداول (۱۰) و (۱۱) ارائه گرديده است. در جدول (۱۰) ضرايب رابطه (٦) كه از آموزش شبكه عصبي بدست آمده اند و در جدول (۱۱) نتايج مربوط به آزمايش مدل عصبي كه همان پيش بيني محسوب ميشود، ارائه شده اند. همچنين در شكل (۵) نتايج خروجي شبكه هاي عصبي همراه با خطاي مدل براي فصل تابستان بعنوان نمونه ارائه گرديده است كه اين نتايج بيانگر تطبيق خوب مدل با واقعيت است.

جدول ۱۰ : نتايج بدست آمده از مدل شبكه عصبي يك لايه - دوره آموزش.

Season	W_1	$W_2 * 10^{-3}$	b
Spring	0.3165	8.7048	-2.1206
Summer	0.3707	4.3589	-2.1303
Autumn	0.2936	4.6433	-1.9631
Winter	0.3587	1.4202	-2.0701

مقايسه نتايج شبكه عصبي اصلي با دو لايه نهان و فرمول (۸) نشان مي دهد كه براي داده هاي آزمايش در سال ۱۳۷۸، دقت نتايج ناشي از فرمول، حدود يک درصد از نتايج مدل اصلي كمتر مي باشد. استفاده از فرمول (۸) باعث سهولت در پيش بيني مي شود، هر چند كه بدليل استفاده از تنها دو پارامتر ورودي در مدل عصبي، بهتر است در فواصل زماني كوتاهتري پارامترهاي b ، W_1 و W_2 كاليبره گردند تا صحت و دقت نتايج در محدوده قابل قبول تضمين گردد.

جدول ۱۱ : نتايج بدست آمده از مدل شبكه عصبي يك لايه - دوره آزمايش.

Season	MAPE (%)	Max. Error (%)	Min. Error (%)
Spring	1.866	7.90	-3.31
Summer	2.075	7.04	-3.13
Autumn	2.517	8.99	-4.69
Winter	2.925	10.38	-8.43

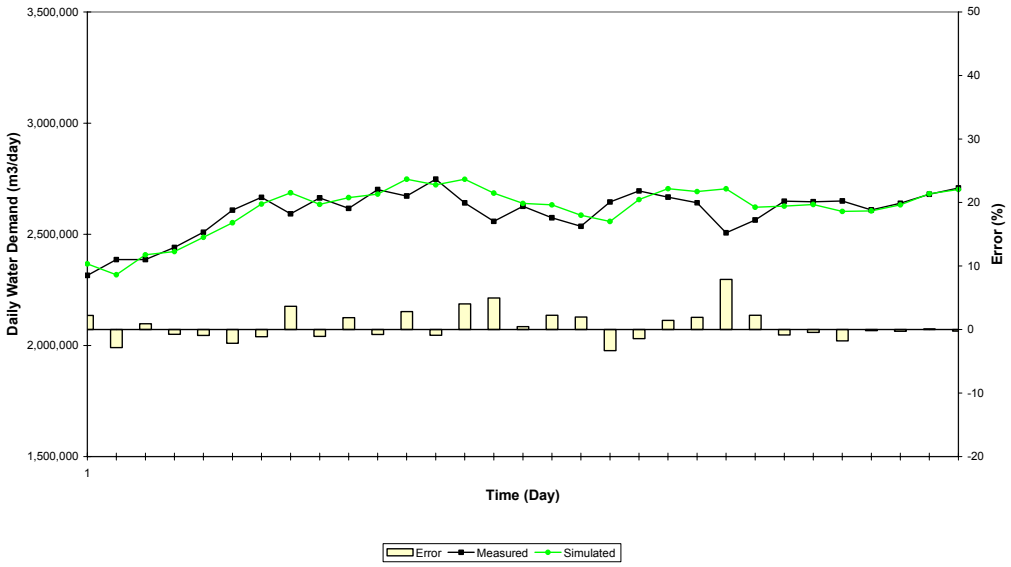

شكل ۵ : نتايج خروجي مدل براي فصل بهار.

جمع بندي و نتيجه گيري

در اين تحقيق با استفاده از شبكه هاي عصبي مصنوعي ميزان مصرف روزانه آب شهر تهران پيش بيني شده است. نتايج نشان مي دهد كه شبكه هاي عصبي از قابليت بالايي براي درک الگوي مصرف آب برخوردارند و بعنوان ابزاري قدرتمند براي تخمين ميزان مصرف كوتاه مدت آب به شمار مي آيند. با توجه به بررسي چهار ساختار مختلف با تعداد متفاوت نرون و لايه هاي نهان، شبكه عصبي مصنوعي با دو لايه نهان كه داراي يک نرون در لايه نهان اول و هفت نرون در لايه نهان دوم مي باشد، بهترين نتيجه را براي تخمين تقاضاي كوتاه مدت آب شهر تهران نشان داد. با مقايسه توابع فعاليت خطي و غير خطي مشخص شد كه در لايه خروجي مدل عصبي، توابع فعاليت غيرخطي عملكرد بهتري نسبت به توابع خطي از خود نشان ميدهند. همچنين نتايج حاصل نشان ميدهد كه پارامترهاي هواشناسي تاثير قابل ملاحظه اي بر ميزان مصرف آب دارند. تاثير پارامترهاي هواشناسي بر ميزان مصرف آب در ماههاي گرم سال بسيار بيشتر از ماههاي سرد سال ميباشد. در ميان پارامترهاي هواشناسي، دما بيشترين تاثير را بر مصرف آب شهري دارد. ميزان تاثير پارامترهاي هواشناسي بر ميزان مصرف آب شهري در زمانهاي مختلف متفاوت است و گاهي تاثير معكوس دارد. براي مثال باد درماههاي گرم موجب كاهش مصرف ميگردد ولي در ماههاي سرد موجب افزايش آن ميشود. در نهايت مشخص گرديد در ميان سيستمهاي خبره، شبكه هاي عصبي مصنوعي در كنار سيستمهاي فازي قادر به پيش بيني تقاضاي كوتاه مدت آب شهري با دقت مناسب مي باشند.

در ادامه اين تحقيق، با استفاده از يک مدل عصبي تک نرون، يک رابطه ساده براي تخمين ميزان مصرف آب روزانه شهر تهران بدست آمد. نتايج اين تحقيق بيانگر توانايي خوب اين رابطه در پيش بيني تقاضاي كوتاه مدت آب است. نتايج نشان ميدهد كه دقت اين فرمول از دقت يک مدل عصبي چند لايه حدود يک درصد كمتر است ولي استفاده از اين فرمول به زمان كمتري نياز دارد و كاربرد آن بسيار ساده تر است. لذا مي تواند براحتي بوسيله كاربران مورد استفاده قرار گيرد. با توجه به اينكه متغيرهاي موثر در مصرف آب، ماهيتا داراي طبيعتي تصادفي هستند، براي ارتقاي اعتمادپذيري مدل مي توان از شبكه هاي تصادفي استفاده نمود كه اين ايده هم اينک توسط مولفين تحت بررسي است.

تقدير و تشكر

بدينوسيله از معاونت پژوهشي دانشگاه تهران به جهت تامين مالي اين تحقيق تحت عنوان پروژه تحقيقاتي شماره ٦١٤/٢/٩٧٥ تقدير و تشكر مي گردد.

مراجع

1 - Monzavi, M. T. (1999). *Water supply, University of Tehran Press*, !0th Edition, 379 p. (in Farsi).

2 - Taebi, A. and Chamani, M. R. (2000). *Urban water distribution networks*, Isfahan University of Technology Press, 628 P. (in Farsi).

3 - Zhou, S.L., McMahon, T. A., Walton, A. and Lewis, J. (2000). "Forecasting daily urban water demand: a case study of Melbourne." *J. of Hydrology,* Vol. 236, PP. 153-164.

4 - Zhou, S. L., McMahon, T. A., Walton, A. and Lewis, J. (2001). "Forecasting operational demand for an urban water supply zone." *J. of Hydrology*, Vol. 259, PP. 189-202.

5 - Wong, S. T. (1972). "A model on municipal water demand: a case study of northeastern Illinois." *Land Econ.*, Vol. 48, No.1, PP. 34-44.

6 - 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, PP. 1068-1072.

7 - Willsie, R. H. and Pratt, H. L. (1974). "Water use relationships and projection corresponding with regional growth." *Water Resources Bulletin,* Vol.10, No. 2, PP. 360-371.

8 - 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.

9 - 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.

10 - Stark, H. L., Stanley, J. S. and Buchanan, I. D. (2000). *Water demand forecasting using artificial neural networks*, University of Alberta.

11- Yu, M. J., Joo, C. N. and Koo, J. Y. (2002). "Application of short-term water demand prediction model to Seoul." *J. of Water Science & Technology,* Vol. 46, No. 6-7, PP. 255–261.

12 - 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.

13 - Buchberger, G. and Wells, G. J. (1996). "Intensity, duration and frequency of residential water demands." *Journal of Water Resources Planning and Management, ASCE*, Vol. 122, No. 11, PP. 11-18.

14 - Buchberger, G. and Wu, L. (1995). "Model for instantaneous residential water demand." *J. of Hydraulic Engineering,* Vol. 121, No. 3, PP. 232-246.

15 - Chatterjee, A. K. (2001). *Water supply, waste disposal and environmental engineering,* Seventh Edition, KHANA Publishers, 900 P.

16 - Management and Budget Organization and Ministry of Energy, (1992). *Urban water supply design codes,* Report No. 117-3, Technical Standards, (in Farsi).

17 - Merritt, F. S. (1983). *Standard Handbook for Civil Engineers*, Third Eedition, McGraw-Hill, 1492 P.

18 - Karimi, D. (2001). *Application of Fuzzy systems on Tehran short term water consumption*, MSc Thesis, Tarbiat Modares University, Tehran, Iran, (in Farsi).

19 - Devore, J. L. (2000). *Probability and statistics*, Fifth Edition, California Polytechnic State University, 755 P.

20 - Fausett, L. (1994). *Fundamental of neural networks*, Florida Institute of Technology, 461 P.

واژه هاي انگليسي به ترتيب استفاده در متن

1 - Transfer Function
2 - The Mean Average Percentage Error
3 - Correlation Coefficient
4 - Self-Adaptive
5 - Graphical User Interface
6 - Initialize