

# پیش‌بینی تقاضای روزانه آب شهری با استفاده از شبکه‌های عصبی مصنوعی، مطالعه موردی: شهر تهران

مسعود تابش<sup>۱</sup>

مهدی دینی<sup>۲</sup>

(دریافت ۸۷/۳/۲۵ پذیرش ۸۸/۵/۲۶)

## چکیده

پیش‌بینی تقاضای آب در سیستم‌های آبرسانی و توزیع آب، با توجه به کمک شایانی که می‌تواند به مدیران این مجموعه‌ها برای مدیریت بحران (حداقل و حداکثر مصرف) داشته باشد، از اهمیت بالایی برخوردار است. پیچیدگی و تأثیر عوامل و پارامترهای مختلف بر میزان تقاضای آب در این سیستم‌ها، سبب گردیده است که روشهای تحلیلی و ریاضی کارایی لازم را در این زمینه نداشته باشند. در این مقاله روش شبکه‌های عصبی مصنوعی برای برآورد تقاضای روزانه آب شهری تهران به کار رفت. پارامترهای هواشناسی مربوط به سه ایستگاه هواشناسی تهران بزرگ به روش تیسسن وزن‌دهی شده و از میانگین وزنی آنها، داده‌های ورودی مدل به‌دست آمد. با ایجاد همبستگی بین میانگین وزنی پارامترهای هواشناسی و داده‌های مصرف، پارامترهای مؤثر مدل انتخاب شدند. پارامترهای مؤثر انتخاب شده شامل دمای متوسط روزانه، رطوبت نسبی، مصرف روزانه یک روز قبل تا مصرف روزانه یک هفته قبل (هفت روز) و مصرف روزانه یک سال قبل بودند. در این مقاله از شبکه‌های عصبی مصنوعی پرسپترون سه لایه با خروجی خطی و غیرخطی، مدل پرسپترون چهار لایه با خروجی غیرخطی و مدل RBF استفاده شد. مقایسه نتایج مدل‌ها با همدیگر و با نتایج مدل‌های نروفازی و روشهای سری زمانی ساخته شده در تحقیقات دیگر، نشان می‌دهد که مدل‌های شبکه عصبی از قابلیت بالایی برای مدل‌سازی تقاضای روزانه آب شهری برخوردارند. در این میان، مدل پرسپترون سه لایه با خروجی غیرخطی، دقت بالاتری دارد.

**واژه‌های کلیدی:** تقاضای آب شهری، پیش‌بینی، شبکه عصبی مصنوعی، درجه حرارت متوسط، درصد رطوبت نسبی

## Forecasting Daily Urban Water Demand Using Artificial Neural Networks, A Case Study of Tehran Urban Water

Masoud Tabesh<sup>1</sup>

M Dini<sup>2</sup>

(Received June 15, 2007 Accepted Aug. 17, 2009)

### Abstract

Water demand forecasting is one of the most important concerns for managers of water supply systems as the results can affect many decisions. Daily demand forecasting cannot be usually accomplished by mathematical functions because it is a complicated function of many variables. In this paper, neural networks are used to predict Tehran daily water demand. At first, weather data from three Tehran weather stations are weighted via the Thissen method and the effective input data parameters are selected using the regression of the weighted effective weather and consumption data. The effective parameters include daily average temperature, relative humidity, and last day to last week (7 days) as well as last year water consumptions. Three different ANN models are built in this stage: a three-layer model with one hidden layer including seven neurons, a four-layer model with two hidden layers including seven neurons in the first and four neurons in the second hidden layer, and a RBF three-layer model with twenty neurons in the middle layer. Comparison of the results of ANN with neuro-fuzzy and time series models shows that ANN models have a higher capability for predicting Tehran daily water consumption. Among these models, the ANN perceptron 3-layer model with a nonlinear output produced more accurate results.

**Keywords:** Urban Water Demand, Forecasting, Artificial Neural Networks, Average Temperature, Relative Humidity

1. Assoc. Prof. and Member of the Center of Excellence on Infrastructure Engineering and Management, Dept. of Civil Engineering, Faculty of Engineering, University of Tehran; mtabesh@ut.ac.ir
2. M.Sc. Graduate of Water Resources Engineering and Instructor of Azad University, Ahar Branch

- ۱- دانشیار و عضو قطب علمی مهندسی و مدیریت زیرساختها، دانشکده مهندسی عمران پردیس دانشکده‌های فنی، دانشگاه تهران، (نویسنده مسئول) ۶۱۱۱۲۲۵۸ (۲۱) mtabesh@ut.ac.ir
- ۲- عضو هیئت علمی دانشکده مهندسی عمران، دانشگاه آزاد اسلامی واحد اهر

به طور کلی پیش‌بینی تقاضای آب در سه دسته اصلی صورت می‌گیرد: پیش‌بینی درازمدت که معمولاً بازه‌ای از یک تا چند سال را در برمی‌گیرد و به منظور سرمایه‌گذاری‌های وسیع مورد نیاز در شبکه‌های آبرسانی برای سالهای آتی صورت می‌پذیرد؛ پیش‌بینی میان مدت که مربوط به نوسانات تقاضای آب در طول سال می‌باشد و می‌تواند به صورت تغییرات فصلی تقاضای آب ارزیابی شود؛ و پیش‌بینی کوتاه مدت که معمولاً بازه زمانی بین یک ساعت تا چند روز را پوشش می‌دهد. در مدیریت آب شهری دانستن تقاضای کوتاه مدت مهم است و در تعیین پارامترهای اقتصادی، قابلیت اطمینان و بهره‌برداری از شبکه نقش بسزایی دارد. این نوع پیش‌بینی به منظور بهره‌برداری از سیستم تله‌متری و کنترل از دور و سیستم ابزار دقیق در مراکز کنترل و تصمیم‌گیری، ضروری و از اهمیت و حساسیت خاصی برخوردار است.

تحقیقات انجام گرفته در زمینه پیش‌بینی تقاضای آب همواره مورد توجه بوده ولی روشهای پیش‌بینی و انگیزه آن در طول این دوران متفاوت بوده است. شروع تحقیقات در زمینه پیش‌بینی تقاضا بیشتر براساس مدل‌های آماری رگرسیون چندگانه و سری‌های زمانی بوده است [۱-۳]. به طور کلی به علت توان بالای سیستم‌های خبره برای مدل‌سازی سیستم‌های طبیعی، از آنها در زمینه‌های مختلف علوم پایه و مهندسی از جمله بخش آب استفاده شده است که نتایج خوبی در مدل‌سازی و انجام پیش‌بینی به دست آمده است [۴-۶]. استفاده از سیستم‌های خبره به خصوص شبکه‌های عصبی مصنوعی برای پیش‌بینی تقاضای کوتاه مدت آب در سالهای اخیر مورد توجه قرار گرفته است. استارک و همکاران<sup>۱</sup> شبکه عصبی مصنوعی را برای پیش‌بینی روزانه تقاضای آب برای یک مجموعه در شهر آلبرتا<sup>۲</sup> کانادا استفاده کردند. آنها نشان دادند که تغییرات در تقاضای آب تابعی از تغییرات در پارامترهای هواشناسی و الگوی رفتاری انسان‌ها می‌باشد [۷]. جین و همکاران<sup>۳</sup> شبکه عصبی مصنوعی را به عنوان یک روش جدید به همراه مدل‌های رگرسیون و سری زمانی برای پیش‌بینی تقاضای کوتاه مدت آب در مؤسسه کانپور<sup>۴</sup> هند به کار بردند. نتایج نشان داد که متوسط خطای مطلق برای داده‌های تست در بهترین مدل شبکه عصبی ۲/۴۱ درصد است و این مدل‌ها در مقایسه با مدل‌های رگرسیون و سری زمانی، عملکرد بهتری دارند [۸-۹]. لیو و همکاران<sup>۵</sup> شبکه عصبی مصنوعی را برای پیش‌بینی تقاضای آب خانگی شهر وینان<sup>۶</sup> چین به کار

بردند. نتایج داده‌های آموزش و تست نشان داد که بین مقادیر واقعی و مقادیر محاسباتی مدل ضریب همبستگی بیشتر از ۰/۹ وجود دارد [۱۰]. یو و همکاران<sup>۷</sup> مدل شبکه عصبی چند لایه را برای پیش‌بینی تقاضای آب شهر هانگزو<sup>۸</sup> چین بر اساس فاکتورهایی مانند نسبت به‌کارگیری آب در صنعت، جمعیت و رشد اقتصادی به کار بردند که نتایج، نشان دهنده دقت و صحت بسیار خوب این مدل‌ها بوده است [۱۱]. بوگادیس<sup>۹</sup> و آداموسکی<sup>۱۰</sup> مدل‌های رگرسیون، سری‌های زمانی و شبکه عصبی مصنوعی را برای پیش‌بینی کوتاه مدت حداکثر تقاضای آب در شهر اتاوا<sup>۱۱</sup> کانادا به کار بردند. در این تحقیق از متغیرهای هواشناسی مانند حداکثر درجه حرارت روزانه و بارندگی روزانه و حداکثر تقاضای دوره‌های قبل، برای ساخت مدل‌ها استفاده و مشاهده شد که نتایج مدل‌های شبکه عصبی در مقایسه با مدل رگرسیون و سری زمانی بهتر بوده است [۱۲-۱۳]. چانگ و همکاران<sup>۱۲</sup> مدل شبکه‌های عصبی را برای پیش‌بینی الگوی تقاضای آب شهری در آمریکا به کار بردند. آنها در این تحقیق رویکردهای متفاوت از هم، از نظر رشد و توسعه، شامل رشد سریع و رشد کند را در دو شهر امریکا مدل‌سازی کردند و الگوی تقاضای آب در آنها را به دست آوردند [۱۴]. مسیزا و همکاران<sup>۱۳</sup> شبکه‌های عصبی مصنوعی پرسپترون چندلایه<sup>۱۴</sup> و شبکه‌های عصبی پایه شعاعی<sup>۱۵</sup> را برای پیش‌بینی درازمدت و کوتاه‌مدت تقاضای آب شهری در افریقای جنوبی استفاده نمودند. مقایسه دو مدل نشان داد که مدل‌های تابع پایه شعاعی سریع‌تر به جواب‌ها همگرا شده و دقت نتایج آن بهتر از مدل پرسپترون چندلایه است [۱۵]. زانگ و همکاران<sup>۱۶</sup> شبکه عصبی مصنوعی را در لوئیزیانا<sup>۱۷</sup> آمریکا برای پیش‌بینی کوتاه‌مدت تقاضای آب شهری برای دو روز بعد استفاده کردند. نتایج مدل‌ها نشان داد که دقت پیش‌بینی‌ها در حدود ۹۵/۸۹ درصد است [۱۶]. گیائی و همکاران یک مدل شبکه عصبی مصنوعی دینامیکی را برای پیش‌بینی تقاضای آب شهری توسعه دادند و از نتایج به دست آمده از یک شبکه واقعی که اطلاعات را به صورت ماهانه، هفتگی، روزانه و ساعتی در اختیار قرار می‌داد برای تصدیق مدل استفاده کردند. مدل‌های ماهانه، هفتگی و روزانه دارای دقت بالای ۹۹ درصد و مدل‌های ساعتی دارای دقت بالای ۹۷ درصد بودند [۱۷].

<sup>7</sup> Yu et al.

<sup>8</sup> Hangzo

<sup>9</sup> Bougadis

<sup>10</sup> Adamowski

<sup>11</sup> Ottawa

<sup>12</sup> Change et al.

<sup>13</sup> Msiza et al.

<sup>14</sup> Multi Layer Perceptron (MLP)

<sup>15</sup> Radical Basis Function (RBF)

<sup>16</sup> Zhang et al.

<sup>17</sup> Louisville

<sup>1</sup> Stark et al.

<sup>2</sup> Alberta

<sup>3</sup> Jain et al.

<sup>4</sup> Kanpur

<sup>5</sup> Liu et al.

<sup>6</sup> Vinan

یورداسف و همکاران<sup>۱</sup>، مدل شبکه عصبی پرسپترون چند لایه و شبکه عصبی تابع پایه شعاعی را براساس فاکتورهای اجتماعی، اقتصادی و آب و هوایی برای پیش‌بینی ماهانه تقاضای آب شهری به کار گرفتند [۱۸].

در مورد کارهای انجام شده در ایران برای پیش‌بینی مصرف آب شهری، کریمی سیستم فازی را برای پیش‌بینی کوتاه‌مدت مصرف آب شهری تهران به‌کاربرد. وی داده‌های هواشناسی و مصرف روزانه سه سال مربوط به سالهای ۱۳۷۵ تا ۱۳۷۸ را برای ساخت و آزمایش مدل فوق به‌کار برد [۱۹]. تابش و همکاران در دو تحقیق مختلف، سری‌های زمانی و شبکه‌های عصبی را برای پیش‌بینی کوتاه مدت تقاضای آب شهری در تهران به‌کار بردند. آنها از داده‌های هواشناسی و داده‌های مصرف آب روزانه فروردین ۱۳۷۵ تا دی ۱۳۷۸ برای مدل‌سازی استفاده کردند که تعداد کم داده‌ها و محدود بودن تحقیق به یک نوع مدل شبکه عصبی از ضعفهای این کارها است [۲۰ و ۲۱]. تابش و دینی از مدل نروفازی برای پیش‌بینی مصرف آب شهری تهران استفاده کردند که در آن از داده‌های هواشناسی و مصرف آب تهران به‌مدت ۱۲ سال از سالهای ۱۳۷۰ تا ۱۳۸۲ استفاده شده است [۲۱].

میزان تقاضای آب، پدیده‌ای بسیار پیچیده و تابعی غیرخطی از عوامل متعددی است که این عوامل از ناحیه‌ای به ناحیه دیگر و در طی زمان تغییر می‌کنند. به همین دلیل تاکنون فرمول کامل و جامعی برای میزان تقاضای آب ارائه نشده است. روابط موجود یا دقیق نیستند و یا اینکه از جنبه خاصی، مثلاً از لحاظ اقتصادی میزان تقاضای آب را مورد بررسی قرار می‌دهند و از سایر عوامل موجود صرف‌نظر می‌شود [۲۲ و ۲۳]. همچنین روابط موجود، بیشتر میزان تقاضا را در اروپا و امریکا محاسبه می‌کنند و مطابق با شرایط منطقه‌ای و اجتماعی-اقتصادی آن کشورها کالیبره شده‌اند و با شرایط شهرهای ایران تطابق ندارند. برای استفاده و کالیبراسیون روشهای بالا، تهیه داده‌ها و اطلاعات مناسب و طولانی مدت و با دقت بالا نیاز است. در ایران به لحاظ برخی از مشکلات فنی و ضعف در جمع‌آوری داده‌ها و تهیه بانک‌های اطلاعاتی، چنین پایگاه کاملی از داده‌ها در دسترس نیست و یا پارامترهای اندازه‌گیری شده، قابل اطمینان نیستند.

با وجود اینکه پیش‌بینی تقاضای روزانه آب شهری در شهرهای بزرگی همچون تهران، گام مهمی در بهبود مدیریت این شبکه‌ها محسوب می‌شود ولی به‌علت کمبود و محدودیت داده‌ها، تاکنون اقدام مناسبی در این زمینه صورت نگرفته است. توجه به عوامل ذکر شده نشان می‌دهد که به‌ایزاری برای پیش‌بینی نیاز است که

توانایی یادگیری برداشت‌های میدانی ناقص موجود را داشته باشد و به‌علاوه بتواند در مقابل نوسان‌های ناشی از عدم دقت در داده‌ها مقاومت نماید. در این شرایط، شبکه‌های عصبی یکی از گزینه‌های مناسب به‌شمار می‌آیند، زیرا به‌دلیل هوشمند بودن، قابلیت یادگیری الگوی پیچیده مصرف آب را دارند و نیز با داده‌های محدود در حد چند سال، می‌توانند به جواب مطلوب برسند.

هدف از این مقاله بررسی پتانسیل مدل‌های مبتنی بر شبکه‌های عصبی مصنوعی برای پیش‌بینی تقاضای روزانه آب شهر تهران بود. در این مقاله با استفاده از شبکه‌های عصبی MLP و RBF نسبت به مدل‌سازی پیش‌بینی تقاضای روزانه آب شهر تهران اقدام شد. با تولید ساختارهای مختلف از این دو نوع مدل شبکه عصبی، در نهایت بهترین ساختار برای مدل پیش‌بینی تقاضا به‌دست آمد. استفاده از دو نوع ساختار شبکه‌های عصبی مصنوعی متفاوت و مقایسه نتایج آنها با همدیگر و همچنین به‌کارگیری دوازده سال داده هواشناسی و مصرف آب که حداکثر اطلاعات در دسترس تا زمان مدل‌سازی بوده است، از نقاط قوت این تحقیق به حساب می‌آید. همچنین نتایج مدل‌های عصبی با نتایج به‌دست آمده از مدل‌های نروفازی و روشهای سری زمانی مقایسه و عملکرد این سه نوع مدل‌سازی نیز بررسی شد.

## ۲- روش شناسی

### ۲-۱- انتخاب پارامتر

اطلاعات لازم برای بررسی و تحلیل آماری عوامل مؤثر بر تقاضای آب و تهیه مدل پیش‌بینی تقاضای آب، شامل داده‌های هواشناسی و مصرف آب است. داده‌های هواشناسی از سازمان هواشناسی کشور تهیه گردید که شامل پارامترهای هواشناسی روزانه از سال ۱۹۹۱ تا ۲۰۰۲ میلادی و برای سه ایستگاه هواشناسی مهرآباد تهران (غرب)، شمال تهران و دوشان تپه بود. داده‌های مربوط به تقاضا و تولید آب (آب تصفیه شده) از شرکت آب و فاضلاب تهران تهیه شد که شامل مصرف سالانه مناطق شش‌گانه تهران بزرگ و تولید روزانه آب از سال ۱۳۷۰ تا تابستان ۱۳۸۲ بود. داده‌های جمع‌آوری شده برای تقاضای آب تهران حداکثر داده‌هایی است که در زمان مطالعه موجود بود.

داده‌های مربوط به ایستگاههای هواشناسی تهران شامل دمای خشک، دمای تر، دمای کمینه، دمای بیشینه، دمای متوسط روزانه، بارش روزانه، تعداد ساعات آفتابی در روز، سرعت باد، رطوبت هوا و نقطه شبنم می‌باشد. با همپوشانی داده‌های هواشناسی و داده‌های مصرف آب، داده‌ها در ۱۲ سال از سالهای ۱۳۷۰ تا آخر ۱۳۸۱ برهم منطبق شدند. بعد از مرتب کردن داده‌های سه ایستگاه هواشناسی در کنار هم، با استفاده از روش چند ضلعی‌های تیسسن،

<sup>1</sup> Yurdusev et al.

وزن مربوط به پارامترهای هواشناسی ایستگاهها براساس مساحت تحت پوشش آنها و میانگین وزنی پارامترها محاسبه شد. مساحت منطقه شهری تحت پوشش ایستگاههای هواشناسی مهرآباد، شمال تهران و دوشان تپه به ترتیب برابر ۴۶/۷، ۳۳/۸ و ۱۹/۵ درصد است.

برای شناسایی عوامل مؤثر بر تقاضای آب شهر تهران، تحلیل همبستگی بر روی داده‌های موجود انجام گرفت و سپس با توجه به مقدار ضریب همبستگی عواملی که دارای بیشترین مقدار همبستگی با مصرف آب بودند، برای مدل‌سازی انتخاب گردیدند. نتایج حاصل از تحلیل مقادیر همبستگی، برای پارامترهای مختلف در جدول ۱ آورده شده است.

با توجه به نتایج به دست آمده، پارامترهای زیر برای مدل‌سازی انتخاب گردید:

۱- دمای متوسط روزانه به دلیل داشتن ضریب همبستگی زیاد با مصرف آب و امکان پیش‌بینی آن توسط سازمان هواشناسی با دقت بالا برای چند روز آینده؛

۲- رطوبت نسبی هوا به دلیل وجود همبستگی منفی و نسبتاً بالا؛

۳- مصرف روز قبل تا مصرف یک هفته قبل به دلیل وجود همبستگی نسبتاً بالا و وارد کردن اثر تغییرات هفتگی مصرف؛

۴- مصرف یک سال قبل به دلیل وجود همبستگی نسبتاً بالا و وارد کردن اثر تغییرات سالانه مصرف.

## ۲-۲- تشریح و ارزیابی مدل

در این مقاله از دو نوع شبکه عصبی MLP و شبکه عصبی RBF برای ساخت مدل‌های پیش‌بینی تقاضای روزانه آب استفاده شد. شبکه پرسپترون چند لایه شامل یک لایه ورودی و یک لایه خروجی است که می‌توان آنها را با یک یا چند لایه مخفی به کار برد.

در این مقاله از یک لایه مخفی برای مدل پرسپترون سه لایه و دو لایه مخفی برای مدل پرسپترون چهار لایه استفاده شد. توابع فعالیت نرون‌های تشکیل دهنده لایه‌های مخفی شبکه عصبی از دو نوع خطی و غیرخطی هستند که عمل پردازش بر روی اطلاعات ورودی را انجام می‌دهند. معادله توابع فعالیت غیرخطی شبکه‌های عصبی پرسپترون به صورت زیر است

$$y = f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (1)$$

برای پیدا کردن مدل مناسب پیش‌بینی تقاضا، ورودی‌های مدل به صورت یک مجموع وزن داده شده به همراه اریب ثابت به کلیه نرون‌های لایه مخفی وارد شد و مورد پردازش غیرخطی قرار گرفت. سپس به کلیه خروجی نرون‌های این لایه مخفی، وزن داده شد و خروجی‌ها وارد نرون‌های لایه مخفی بعدی شدند و این روند تا رسیدن به لایه خروجی تکرار شد. در ادامه مدل اولیه شبکه عصبی پرسپترون سه لایه و چهار لایه نشان داده شده است

$$\hat{y} = w_2 \cdot \tanh(W_1 \cdot \underline{X} + B_1) + B_2 \quad (2)$$


$$\hat{y} = \tanh(W_2 \cdot \tanh(W_1 \cdot \underline{X} + B_1) + B_2) \quad (3)$$

$$\hat{y} = \tanh(W_3 \cdot \tanh(W_2 \cdot \tanh(w_1 \cdot \underline{X} + B_1) + B_2) + B_3) \quad (4)$$

این روابط به ترتیب نشانگر مدل پرسپترون سه لایه با خروجی خطی (رابطه ۲)، سه لایه با خروجی غیرخطی (رابطه ۳) و چهار لایه با خروجی غیرخطی (رابطه ۴) است. برای مدل سه لایه با خروجی خطی،  $W_1$  ماتریس وزن متصل از لایه ورودی به لایه مخفی،  $B_1$  بردار بایاس متصل به نرون‌های لایه مخفی،  $W_2$  ماتریس وزن متصل از لایه مخفی به لایه خروجی،  $B_2$  بردار اریب متصل به

جدول ۱- ضرایب همبستگی بین انواع پارامترهای هواشناسی و مصرف روزهای قبل با تقاضای روزانه آب تهران در دوره دوازده ساله

پارامتر	مصرف روزانه آب	پارامتر	مصرف روزانه آب	پارامتر	مصرف روزانه آب
مصرف روزانه آب	۱/۰۰۰	مصرف یک روز قبل	۰/۹۵۵	مصرف سیزده روز قبل	۰/۸۹۱
دمای خشک	۰/۶۴۶	مصرف دو روز قبل	۰/۹۳۸	مصرف دو هفته قبل	۰/۹۰۰
دمای تر	۰/۶۲۸	مصرف سه روز قبل	۰/۹۳۵	مصرف پانزده روز قبل	۰/۸۸۶
دمای کمیته	۰/۶۴۰	مصرف چهار روز قبل	۰/۹۳۰	مصرف شانزده روز قبل	۰/۸۷۳
دمای بیشینه	۰/۶۳۸	مصرف پنج روز قبل	۰/۹۲۱	مصرف هفده روز قبل	۰/۸۷۰
درجه حرارت میانگین	۰/۶۴۲	مصرف شش روز قبل	۰/۹۲۶	مصرف هجده روز قبل	۰/۸۶۸
سرعت متوسط باد	۰/۱۱۸	مصرف یک هفته قبل	۰/۹۳۱	مصرف نوزده روز قبل	۰/۸۶۱
دمای نقطه شبنم	۰/۵۰۹	مصرف هشت روز قبل	۰/۹۱۶	مصرف بیست روز قبل	۰/۸۶۴
رطوبت نسبی	-۰/۴۴۵	مصرف نه روز قبل	۰/۹۰۳	مصرف سه هفته قبل	۰/۸۷۰
ساعات آفتابی	۰/۴۶۵	مصرف ده روز قبل	۰/۹۰۱	بیست و دو روز قبل	۰/۸۵۶
بارندگی روزانه	-۰/۱۴۶	مصرف یازده روز قبل	۰/۸۹۷	بیست و سه روز قبل	۰/۸۴۴
فشار هوا	-۰/۳۱۶	مصرف دوازده روز قبل	۰/۸۹۱	مصرف یک سال قبل	۰/۸۸۹



شکل ۱- ساختار کلی شبکه عصبی RBF

ماتریس نرم  $\Sigma_i$  با مقادیر ثابت  $[\sigma_{i1}, \sigma_{i2}, \dots, \sigma_{ip}]$  به عنوان پارامتر لایه مخفی  $i$  امین نرون شبکه RBF می باشد که در آن ثابتها به عنوان قطرهای ماتریس نرم می باشند. خروجی شبکه به صورت زیر محاسبه می شود

$$\hat{y} = \sum_{i=0}^m w_i \exp\left(-\frac{1}{2} u_i^2\right) \quad (7)$$

در نتیجه یک شبکه RBF دارای دسته پارامترهای زیر است  
 ۱- وزن های لایه خروجی  $w_i$  که دسته پارامترهای خطی هستند و میزان اریب و ارتفاع توابع پایه را مشخص می کنند.  
 ۲- بردار مراکز  $C_i$  که از دسته پارامترهای غیرخطی نرون های لایه مخفی بوده و مکان توابع پایه را مشخص می کنند.  
 ۳- انحراف معیارهای  $\sigma_{ij}$  که پهنا و میزان دوران توابع پایه گوسی را نشان می دهند.

در آموزش شبکه RBF ابتدا با استفاده از الگوریتم خوشه یابی K-means، پارامترهای لایه مخفی محاسبه و سپس با استفاده از کمترین مربعات، وزن های لایه خروجی که خطی می باشد، محاسبه می گردد [۲۵].

برای ارزیابی مدل، شاخصهای مختلفی در نظر گرفته شد که در ادامه به توضیح هر کدام پرداخته می شود:

MSE<sup>۳</sup>: میانگین مربع خطا که به صورت زیر تعریف می شود

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (8)$$

که در آن  $y_i$  مقادیر داده های واقعی مصرف،  $\hat{y}_i$  مقادیر داده های پیش بینی

نرون های لایه خروجی است. اگر تعداد نرون های لایه ورودی برابر  $n$ ، نرون های لایه مخفی برابر  $m$  و نرون های لایه خروجی برابر  $K$  باشد، آنگاه ابعاد ماتریس های  $W_1$  و  $W_2$  به ترتیب  $n.m$  و  $k.m$  و نیز ابعاد بردارهای اریب  $B_1$  و  $B_2$  به ترتیب برابر  $m.1$  و  $k.1$  ابعاد بردار  $X$  (بردار متغیرهای ورودی شبکه)،  $n.1$  خواهد بود.

با توجه به ساختار تعریف شده برای شبکه عصبی پرسپترون، پارامترهای مذکور باید به گونه ای حساب شود که خروجی شبکه عصبی فوق یعنی  $\hat{y}$  با بیشترین دقت ممکن به  $y$  نزدیک باشد و یا به عبارت دیگر تابع هزینه مورد نظر کمینه شود. در این مقاله از روشهای گرادیانی، تندترین شیب<sup>۱</sup>، نیوتن و لونیبرگ-مارکووارت<sup>۲</sup> استفاده شده است [۲۴]. مدل RBF نیز دارای سه لایه ورودی، لایه مخفی و لایه خروجی می باشد که ساختار کلی آن در شکل ۱ ارائه شده است.

در این مدل تابع فعال ساز، غیرخطی و گوسی شکل است که به صورت رابطه زیر تعریف می شود

$$g(u) = \exp\left(-\frac{1}{2} u_i^2\right) \quad (5)$$

که در آن:

$u_i$  فاصله بردار ورودی  $X_i = [x_1 \ x_2 \ \dots \ x_p]$  از بردار مرکز  $C_i = [c_{i1} \ c_{i2} \ \dots \ c_{ip}]$  با ماتریس نرم  $\Sigma_i$  می باشد و به صورت رابطه زیر تعریف می شود

$$u_i = \|X_j - C_i\|_{\Sigma_i} = \sqrt{\sum_{j=1}^p \left(\frac{x_j - c_{ij}}{\sigma_{ij}}\right)^2} \quad (6)$$

$$= \sqrt{\left(\frac{x_1 - c_{i1}}{\sigma_{i1}}\right)^2 + \dots + \left(\frac{x_p - c_{ip}}{\sigma_{ip}}\right)^2}$$

<sup>1</sup> Steepest Descent (SD)

<sup>2</sup> Levenberge-Marquart

<sup>3</sup> Mean Square Error

شده تقاضا و n تعداد داده‌ها است.

NMSE: میانگین مربع خطای نرمال شده<sup>۱</sup>

$$NMSE = \frac{MSE}{\text{var}(y)} \quad (9)$$

که در آن

var(y)، واریانس داده‌های واقعی است. به علت اینکه مقدار این شاخص به تعداد داده‌ها وابسته نیست، در این تحقیق از شاخص مزبور برای ارزیابی مدل‌ها استفاده شد. از این رو برای تعداد داده‌های مختلف می‌توان آن را به کار برد. هر چه مقدار شاخص به صفر نزدیک‌تر باشد، مدل بهتر است.

R: ضریب همان ضریب همبستگی است. برای حالتی که مقادیر داده‌های واقعی و داده‌های پیش‌بینی شده کاملاً به همدیگر انطباق داشته باشند، مقدار ضریب بسته به روند صعودی و نزولی داده‌ها ۱ یا -۱ خواهد بود. در صورتی که هیچ انطباقی بین داده‌های واقعی و پیش‌بینی وجود نداشته باشد، مقدار ضریب R صفر خواهد بود.

خطای مطلق: خطای مطلق به صورت تفاضل داده‌های واقعی از داده‌های پیش‌بینی، تقسیم بر داده‌های واقعی تعریف می‌شود. میانگین خطای مطلق یا درصد خطای میانگین مطلق<sup>۲</sup> از میانگین‌گیری تمامی خطاهای مطلق به دست می‌آید و به صورت زیر تعریف می‌شود

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad (10)$$

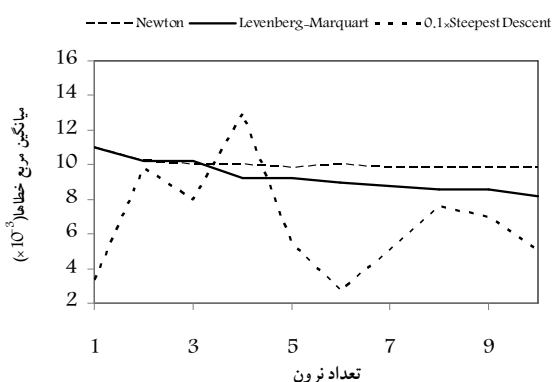
### ۳- ساخت مدل

برای ساخت و تعیین ساختار بهینه مدل‌های بالا، داده‌های ورودی به سه قسمت تقسیم شد: قسمت اول شامل ۶۰ درصد داده‌ها برای آموزش<sup>۳</sup>، قسمت دوم شامل ۱۵ درصد داده‌ها برای تصدیق<sup>۴</sup> و قسمت سوم شامل ۲۵ درصد داده‌ها برای آزمون<sup>۵</sup> بود. برای شبیه‌سازی مدل‌ها از محیط برنامه نویسی Matlab7 استفاده گردید و برای هر یک از مدل‌های عصبی به کار رفته، چندین فایل Matlab تهیه شد. در این فایل‌ها، در ابتدا ساختار مناسب از نظر تعداد نرون‌ها تعیین شد و پس از تعیین تعداد مناسب نرون‌ها، یک فایل برای تعیین تعداد مناسب آموزش ایجاد گردید. پس از تعیین تعداد مناسب آموزش و نرون‌ها، در یک فایل دیگر پارامترهای شبکه


عصبی بهینه تعیین و استخراج گردید و کلیه محاسبات بر حسب این شبکه بهینه انجام شد.

### ۳-۱- مدل پرسپترون سه لایه با خروجی خطی (3LPL)

برای پیدا کردن ساختار بهینه مدل پرسپترون سه لایه با خروجی خطی، ابتدا از یک ساختار ساده شروع کرده و با گام‌های آموزشی ثابت یک به یک، نرون‌های لایه مخفی افزایش یافتند. سپس نتایج مدل برای داده‌های آموزشی و تست بر اساس معیار میانگین مربع خطاها مورد مقایسه قرار گرفت. در این مقاله، مقایسه بر اساس روشهای آموزشی گرادیانی تندترین شیب، نیوتن و لونیبرگ مارکوارت صورت گرفت. در شکل‌های ۲ و ۳ نتایج برای داده‌های آموزش و آزمون آورده شده است.



شکل ۲- تغییرات خطای داده‌های آموزش با افزایش تعداد نرون‌های لایه مخفی



شکل ۳- تغییرات خطای داده‌های تست با افزایش تعداد نرون‌های لایه مخفی

بر اساس نمودارهای فوق روش گرادیانی لونیبرگ مارکوارت دارای بهترین نتایج برای تعیین ساختار بهینه شبکه‌های پرسپترون نسبت به دو روش دیگر می‌باشد. برای پیدا کردن ساختار بهینه در مدل‌های بعدی از این روش استفاده شد. در شکل ۴، نمودار

<sup>1</sup> Normalized Mean Square Error

<sup>2</sup> Mean Absolute Percentage Error (MAPE)

<sup>3</sup> Training

<sup>4</sup> Validation

<sup>5</sup> Testing


**۳-۲- مدل پرسپترون سه لایه با خروجی غیر خطی (3LPNL)**  
 برای پیدا کردن ساختار بهینه مدل پرسپترون سه لایه با خروجی غیر خطی، ابتدا از یک ساختار ساده شروع کرده و مشابه مدل قبلی مراحل یک به یک انجام شد. بر اساس تغییرات میانگین مربع خطاهای داده‌های آموزش، تصدیق و آزمون با افزایش تعداد نرون‌های لایه مخفی و تعداد گامهای آموزشی، ساختار مناسب مدل به دست می‌آید. در این مدل بهترین ساختار شامل ۷ نرون در لایه مخفی و ۱۴۰ گام آموزشی بود. در شکل ۶، تغییرات خطای داده‌ها با افزایش تعداد نرون‌های لایه مخفی نشان داده شده است که براساس نحوه تغییرات خطای آموزش و تصدیق تعداد ۷ نرون در لایه مخفی بهترین ساختار بود.



**شکل ۶- تغییرات خطای داده‌های آموزش، تست و تصدیق با افزایش تعداد نرون‌های لایه مخفی**

**۳-۳- مدل پرسپترون چهار لایه با خروجی غیر خطی (4LPNL)**  
 برای تعیین ساختار بهینه مدل پرسپترون چهار لایه با خروجی غیر خطی از همان روند تعیین ساختار که برای شبکه سه لایه به کار برده شد، استفاده گردید. ابتدا تعداد نرون‌های لایه مخفی اول این شبکه چهار لایه، برابر تعداد نرون‌های بهینه شبکه سه لایه غیرخطی در نظر گرفته شد و نمودار خطا بر حسب تعداد نرون‌های لایه مخفی دوم رسم و تعداد مناسب نرون‌های این لایه به دست آمد. در شکل‌های ۷ و ۸، تغییرات خطا برای مدل چهار لایه با افزایش تعداد نرون‌های لایه مخفی دوم و تعداد گامهای آموزشی نشان داده شده است. به این ترتیب بهترین ساختار مدل پرسپترون چهار لایه به صورت ۷ نرون در لایه مخفی اول و ۴ نرون در لایه مخفی دوم با تعداد گامهای آموزشی ۱۲۰ بود.

**۳-۴- مدل شبکه عصبی RBF**  
 برای تعیین ساختار مناسب شبکه RBF، نمودار معیار خطا برای دسته داده‌های آموزش، آزمون و تصدیق رسم شد و تعداد مناسب



**شکل ۴- تغییرات خطای داده‌های آموزش و تست و تصدیق با افزایش تعداد نرون‌های لایه مخفی**

تغییرات میانگین مربع خطاها نسبت به تعداد نرون‌های لایه مخفی برای مدل سه لایه با خروجی خطی نشان داده شده است. با توجه به تغییرات خطای داده‌های آموزش و تصدیق، تعداد مناسب نرون برای دستیابی به بیشترین عمومیت، مکانی از نمودار است که علاوه بر کاهش مطلوب خطای داده‌های آموزشی، خطای داده‌های تصدیق نیز کم شود و یا مکانی کمینه بر روی نمودار خطای تصدیق باشد که در این مدل ۸ نرون برای لایه مخفی این شرط را دارند. پس از تعیین تعداد مناسب نرون‌ها، تعداد گام آموزشی را با فواصل ۲۰ تا با افزایش داده و نمودار تغییرات خطا برای آن رسم شد. تعداد گام آموزشی بهینه مکانی از نمودار است که خطای داده‌های تصدیق شروع به افزایش می‌کند. در شکل ۵، تغییرات خطای مدل مذکور با ۸ نرون لایه مخفی و تعداد گامهای آموزشی مختلف نشان داده شده است. براساس این شکل، بهترین حالت ۱۴۰ گام آموزشی می‌باشد.



**شکل ۵- تغییرات خطای داده‌های آموزش، تست و تصدیق با افزایش تعداد گامهای آموزش**

همچنین به دلیل اینکه در این مدل عصبی با استفاده یکبار از کل داده‌ها از روش‌های خوشه‌یابی و کمترین مربعات با تخمین خطی استفاده می‌شود، دیگر تعداد گام‌های آموزشی هیچ مفهومی ندارد.

#### ۴- نتایج مدل‌ها

بعد از ساخت مدل‌های تشریح شده بالا و پیدا کردن بهترین ساختار برای آنها، نتایج مدل‌ها در حالت بهینه با هم مقایسه گردید. لازم به ذکر است که در این رابطه، مدل‌های متعددی ساخته شد که در جدول ۲، نتایج مدل پرسپترون غیرخطی (3MPNL) فقط برای دو حالت ورودی‌های گروه A و گروه B با هم مقایسه گردیده است: (A) داده‌های مصرف یک روز تا یک هفته قبل و نیز میانگین روزانه دما و رطوبت نسبی به‌عنوان پارامترهای ورودی مؤثر. (B) داده‌های مصرف یک روز و یک هفته و یک سال قبل و نیز میانگین روزانه دما و رطوبت نسبی به‌عنوان پارامترهای ورودی مؤثر.

نوع داده	MSE	NMSE	MAPE	R
A	۰/۰۰۶۰	۰/۰۵۶۹	۰/۰۲۶۹	۰/۹۷۱۱
B	۰/۰۰۶۵	۰/۰۷۱۹	۰/۰۲۷۹	۰/۹۶۳۳


نتایج جدول ۲ برای مدل پرسپترون سه لایه با خروجی غیرخطی (3MPNL) نشان می‌دهد که نتایج داده‌های گروه A نسبت به گروه B در تمامی شاخصها بهتر است. این موضوع برای تعداد نرون‌های مختلف در شکل ۱۰ نشان داده شده است. در مدل‌های بعدی داده‌های ورودی به‌صورت گروه A مورد استفاده قرار گرفت. البته باید توجه نمود که داده‌های گروه B به دلیل در نظر گرفتن مصرف سال قبل می‌تواند روند افزایش مصرف ناشی از افزایش جمعیت را در بر بگیرد. به‌طور کلی مقادیر خطای ناشی از گروه B کمی از گروه A بیشتر است ولی خطای زیادی محسوب نمی‌شود.

در جدول ۳ نتایج مدل پرسپترون سه لایه با خروجی خطی (3MPL) و غیرخطی (3MPNL) برای کل داده‌ها و داده‌های تست با هم مقایسه گردیده است. با توجه به نتایج جدول، مدل‌های با خروجی غیرخطی برای کلیه شاخصها نتایج بهتری نسبت به مدل‌های خطی به دست آوردند. از این رو در ساخت مدل‌های چهار لایه نیز از ورودی‌های غیرخطی استفاده شد.


در جدول ۴ نتایج کلیه مدل‌های بهینه به دست آمده برای کل داده‌ها و داده‌های آزمون با یکدیگر مقایسه شده‌اند. با توجه به این جدول‌ها و نتایج داده‌های آزمون، مشاهده می‌شود که شبکه



شکل ۷- تغییرات خطای داده‌های آموزش، تست و تصدیق با افزایش تعداد نرون‌های لایه مخفی



شکل ۸- تغییرات خطای داده‌های آموزش و تست و تصدیق با افزایش تعداد گام‌های آموزش



شکل ۹- تغییرات خطای داده‌های آموزش، تست و تصدیق با افزایش تعداد نرون‌های لایه مخفی شبکه RBF



نرون، همان تعدادی در نظر گرفته شد که به ازای آن، میزان هر سه خطا به طور متناسب با هم کم شده بود. در شکل ۹، این نمودار رسم شده است و تعداد مناسب نرون در شبکه RBF با توجه به نحوه تغییرات خطا نسبت به تعداد نرون‌ها، برابر ۲۰ انتخاب گردید.



غیرخطی (3MPNL) برای سالهای ۱۳۸۰ و ۱۳۸۱ در کنار مقادیر واقعی و همچنین نوسانات خطای داده‌ها نشان داده شده است که نشان دهنده دقت بالای مدل در شبیه‌سازی و پیش‌بینی مصرف روزانه آب شهری تهران می‌باشد. از این شکل نتیجه می‌شود که فقط برای چند روز محدود در طول این دو سال مقدار خطا بالای ۱۰ درصد است و در بقیه روزها مقدار خطا بسیار کم (کمتر از ۵ درصد) می‌باشد.

برای مقایسه نتایج مدل‌های عصبی ساخته شده با مدل‌های نروفازی و سری‌های زمانی، نتایج مدل‌های نروفازی برای داده‌های گروه A و B [۲۱ و ۲۶] و نتایج مدل‌های سری زمانی [۳] در جدول ۵ آورده شده است. مدل نروفازی گروه A دارای هفت ورودی شامل مصرف یک روز قبل تا یک هفته قبل بود. نتایج مدل‌های نروفازی نیز نشان داد که نتایج مدل برای داده‌های گروه A برای تمامی شاخصهای ارزیابی بهتر از نتایج گروه B بود. اما مقایسه نتایج نشان داد که شبکه‌های عصبی نسبت به مدل‌های نروفازی نتایج بهتری را تولید کرده‌اند هر چند در مجموع، هر دو نوع مدل‌های شبکه عصبی و نروفازی از قابلیت بالایی برای پیش‌بینی مصارف آب شهری برخوردارند. همچنین مشاهده شد که مدل‌های شبکه عصبی MLP بهتر از سری‌های زمانی سنتی بوده و جوابها به نتایج سری‌های زمانی پیشرفته بسیار نزدیک بود.

لازم به ذکر است که در روش سری‌های زمانی با تحلیل سنتی فرض بر این است که مؤلفه‌های مختلف یک سری زمانی از یکدیگر مستقل و قابل تفکیک‌اند، لذا با استفاده از روشهای مختلف همچون رگرسیون و میانگین متحرک، مؤلفه‌های مختلف را تعیین می‌کنند. مؤلفه‌های مختلف سری زمانی یعنی مؤلفه روند، مؤلفه تغییرات



شکل ۱۰- تغییرات خطای داده‌های آموزش و تست با افزایش تعداد نرون‌های لایه مخفی در دو حالت داده‌های گروه A و B


پرسپترون سه لایه نسبت به مدل‌های مشابه بهترین عملکرد برای پیش‌بینی را داراست، لکن به هر حال نتایج برای تمامی مدل‌ها بسیار خوب است. در شکل ۱۱، نتایج مدل پرسپترون سه لایه

جدول ۳- نتایج مدل پرسپترون سه لایه خطی و غیرخطی برای کل داده‌ها و داده‌های تست

مدل	نوع داده	MSE	NMSE	MAPE	R
3MPL	کل	۰/۰۰۶۵	۰/۰۶۱۱	۰/۰۲۸۰	۰/۹۶۸۹
3MPNL	داده‌ها	۰/۰۰۶۲	۰/۰۵۸۰	۰/۰۲۷۲	۰/۹۷۰۶
3MPL	داده‌های	۰/۰۰۶۷	۰/۰۶۳۴	۰/۰۲۸۵	۰/۹۶۷۸
3MPNL	تست	۰/۰۰۶۰	۰/۰۵۶۹	۰/۰۲۶۹	۰/۹۷۱۱

جدول ۴- نتایج انواع مدل‌های شبکه عصبی برای کل داده‌ها و داده‌های آزمون

مدل	نوع داده	MSE	NMSE	MAPE	R
3MPNL	کل	۰/۰۶۲/۰	۰/۰۵۸۰/۰	۰/۰۲۷۲/۰	۹۷۰۶/۰
4MPNL		۰/۰۶۰/۰	۰/۰۵۶۸/۰	۰/۰۲۷۱/۰	۹۷۱۲/۰
RBF	داده‌ها	۰/۰۷۴/۰	۰/۰۷۰۳/۰	۰/۰۲۹۸/۰	۹۶۴۲/۰
3MPNL		۰/۰۶۰/۰	۰/۰۵۶۹/۰	۰/۰۲۶۹/۰	۹۷۱۱/۰
4MPNL	داده‌های	۰/۰۶۲/۰	۰/۰۵۸۷/۰	۰/۰۲۷۴/۰	۹۷۰۲/۰
RBF		۰/۰۷۲/۰	۰/۰۶۷۸/۰	۰/۰۲۹۴/۰	۹۶۵۵/۰



شکل ۱۱- تغییرات خطای کل داده‌ها با نتایج مدل پرسپترون سه لایه غیرخطی

جدول ۵- نتایج مدل نروفازی [۲۱ و ۲۶] و سری زمانی [۳]

مدل	نوع داده	MSE	NMSE	MAPE	R
نروفازی	A	۰/۰۰۷	۰/۰۶۴	۰/۰۲۸۶	۰/۹۶۷
	B	۰/۰۰۷	۰/۰۷۲	۰/۰۲۸۲	۰/۹۶۳
سری زمانی (تحلیل سنتی)	-	-	-	۰/۰۳۳۳	-
سری زمانی (تحلیل پیشرفته)	-	-	-	۰/۰۲۲۸	-

یک روز قبل تا یک هفته قبل و میانگین دمای روزانه و رطوبت نسبی (A) در مقایسه گروه B بهتر بود و در مدل‌سازی‌ها از این دسته پارامترها استفاده شد.

مدل‌های ساخته شده شامل مدل شبکه عصبی پرسپترون سه لایه با خروجی خطی (3MPL)، مدل پرسپترون سه لایه با خروجی غیرخطی (3MPNL)، مدل پرسپترون چهار لایه با خروجی غیرخطی (3MPNL) و مدل RBF بهترین مدل‌های ممکن از نظر ساختاری بوده و با برنامه‌نویسی و ساخت مدل‌های متعدد و مقایسه آنها با یکدیگر به دست آمدند. به طور کلی مقایسه روشهای گرادینتی آموزش مدل‌های عصبی پرسپترون نشان می‌دهد که روش لونیگ مارکواریت نسبت به روشهای دیگر نتایج بهتری دارد و در این مقاله از این روش برای آموزش و بهینه‌سازی مدل‌ها استفاده شد.

مقایسه نتایج مدل‌های عصبی با همدیگر نشان می‌دهد که مدل‌های پرسپترون نسبت به مدل RBF نتایج مطلوب‌تری دارد. در

فصلی، مؤلفه دوره‌ای و مؤلفه تصادفی هر یک به صورت جداگانه تعیین می‌گردد و در نهایت مدل به صورت مجموعه‌ای از این مؤلفه‌ها مشخص می‌شود. مدل‌های سری‌های زمانی پیشرفته نیز شامل مدل‌های خودهمبسته (AR)، میانگین متحرک (MA)، خودهمبسته میانگین متحرک (ARMA) و خودهمبسته میانگین متحرک تفاضلی (ARIMA) می‌باشند که در آنها فرض بر این است که مؤلفه‌ها با یکدیگر همبستگی دارند، لذا برخلاف مدل سنتی تمامی مؤلفه‌ها به صورت یکجا در ارتباط با یکدیگر مشخص می‌شوند.

##### ۵- نتیجه‌گیری

با توجه به تعداد پارامترهای مؤثر تعریف شده شامل میانگین دمای روزانه، درصد رطوبت نسبی، مصرف یک روز قبل تا مصرف یک هفته قبل و مصرف یک سال، نتایج مدل‌ها برای داده‌های مصرف

که روشهای خبره با توجه به این که از طریق آموزش و یادگیری از داده‌های قبلی شکل می‌گیرند، برای استفاده آنها در کارهای عملی مرتباً نیاز به آموزش مجدد (به روز کردن) است تا تغییرات جدید را در بر بگیرند و مجدداً پیش‌بینی با دقت بالا صورت گیرد که این موضوع از محدودیتهای اساسی این روشها می‌باشد. همچنین این روشها در صورت استفاده از برون‌یابی دارای خطای بیشتری هستند به دلیل اینکه داده‌ها در محدوده‌ای خارج از محدوده داده‌های آموزش یافته قرار می‌گیرد. همین امر نیز ضرورت بهنگام کردن داده‌ها و مدل‌ها را دوچندان می‌سازد.

#### ۶- قدردانی

به این وسیله از معاونت پژوهشهای کاربردی شرکت مدیریت منابع آب وزارت نیرو که با پشتیبانی مالی خود از این پروژه تحقیقاتی حمایت نمودند، تشکر و قدردانی می‌شود.

بین مدل‌های عصبی پرسپترون نیز مدل‌های با خروجی غیرخطی نسبت به مدل‌های با خروجی خطی مناسب‌تر می‌باشد. همچنین بزرگ‌تر کردن ساختار شبکه تأثیر چندانی بر بهبود نتایج ندارد، به طوری که نتایج مدل پرسپترون چهار لایه در مقایسه با مدل پرسپترون سه لایه با خروجی غیرخطی با وجود نزدیک بودن نتایج بهتر نشد. در مجموع با توجه به داده‌های مورد استفاده، مدل پرسپترون سه لایه با خروجی غیرخطی (3MPNL) بهترین نتایج را برای پیش‌بینی مصرف روزانه آب شهری تهران ایجاد کرد. مقایسه نتایج مدل‌های شبکه عصبی با مدل‌های مشابه نروفازی و سری‌های زمانی نیز نشان داد که هر چند هر سه نوع مدل نتایج تقریباً نزدیکی به هم دارند، لکن مدل‌های شبکه عصبی مصنوعی سه لایه نتایج بهتری نسبت به مدل‌های نروفازی و نزدیکی بیشتری با سری‌های زمانی پیشرفته دارند. در رابطه با محدودیتهای روش شبکه عصبی نیز باید اشاره کرد

#### ۷- مراجع

- 1- Zhou, S.L., Mcmohon, T.A., Walton, A., and Lewis, J. (2000). "Forecasting daily urban water demand: A case study of Melbourne." *J. Hydrology*, 236, 153-164.
- 2- Zhou, S.L., Mcmohon, T.A., Walton, A., and Lewis, J. (2001). "Forecasting operation demand for an urban water supply zone." *J. Hydrology*, 259, 189-202.
- ۳- تابش، م.، دینی، م.، خوش خلق، ج.، و زهرایی، ب. (۱۳۸۷). "برآورد مصرف کوتاه مدت آب شهری تهران با استفاده از سری‌های زمانی." *م. تحقیقات منابع آب*، ۱۱ (۲)، ۵۷-۶۵.
- 4- Bowden, G.J., Maier, H.R., and Dandy, G.C. (2002). "Optimal division of data for neural network models in water resources applications." *Water Resources Research*, 38(2), 1-11.
- 5- Milot, J., Rodriguez, M.J., and Sérodes, J.B. (2002). "Contribution of neural networks for modeling trihalomethanes occurrence in drinking water." *J. of Water Resources Planning and Management*, 128(5), 370-376,
- 6- Michaelides, S.C., Pattichis, C.S., and Kleovoulou, G. (2001). "Classification of rainfall variability by using artificial neural networks." *International J. of Climatology*, 21, 1401-1414.
- 7- Stark, H.L., Stanley, S.J. and Buchanan, I.D. (2000). "The application of artificial neural networks to water demand modeling." *Annual Conference Abstracts of Canadian Society for Civil Engineering*, 139
- 8- Jain, A., Joshi, U.C., and Varshney, A.K. (2000). "Short-term water demand forecasting using artificial neural networks: IIT Kanpur experience." *In Proceedings of International Conference on Pattern Recognition*, 15(2), 459-462.
- 9- Jain, A., Varshney, A.K., and Joshi, U.C. (2001). "Short-term water demand forecast modeling at IIT Kanpur using artificial neural networks." *Water Resources Management*, 15(5), 299-321.
- 10- Liu, J., Savenije, H.G., and Xu, J. (2003). "Forecast of water demand in Weinan City in China using WDF-ANN model." *Physics and Chemistry of the Earth*, 28(4-5), 219-224
- 11- Yu, T-C, Zhang, T. Q., Mao, G. H., and Wu, X, G. (2004). "Study of artificial neural network model for forecasting urban water demand." *J. of Zhejiang University (Engineering Science)*, 38(9), 1156-1161.

- 12- Bougadis, J., Adamowski, K.B., and Diduch, R. (2005). "Short-term municipal water demand forecasting." *Hydrological Processes*, 19(1), 137-148.
- 13- Adamowski, J.F. (2008). "Peak daily water demand forecast modeling using artificial neural networks." *J. of Water Resources Planning and Management*, 134(2), 119-128.
- 14- Chang, N.B., and Makkeasorn, A. (2007). "Water demand analysis in urban region by neural network models." *In Proceedings of the 8th Annual Water Distribution Systems Analysis Symposium*, 48.
- 15- Msiza, I.S., Nelwamondo, F.V., and Marwala, T. (2007). "Water demand forecasting using multi-layer perceptron and radial basis functions." *In Proceedings of the IEEE International Conference on Neural Networks*, Article, 13-18.
- 16- Zhang, J., Song, R., Bhaskar, N. R., and French, M.N. (2007). "Short-term water demand forecasting: A case study." *In Proceedings of the 8th Annual Water Distribution Systems Analysis Symposium*, 49.
- 17- Ghiassi, G. A., Zimbra, D. K. B., and Saidane, H.C. (2008). "Urban water demand forecasting with a dynamic artificial neural network model." *J. of Water Resources Planning and Management*, 134(2), 138-146.
- 18- Yurdusev, M.A., Firat, M., Mermer, M., and Turan, M.E. (2009). "Water use prediction by radial and feed-forward neural nets." *In Proceedings of the Institution of Civil Engineers: Water Management*, 162(3), 179-188.
- ۱۹- کریمی، د. (۱۳۸۰). "کاربرد منطق فازی در پیش‌بینی کوتاه مدت مصرف آب تهران." پایان نامه کارشناسی ارشد، گروه مهندسی عمران محیط زیست، دانشگاه تربیت مدرس، تهران.
- ۲۰- تابش، م.، گوشه، س.، و یزدانپناه، م.ج. (۱۳۸۶). "کاربرد شبکه‌های عصبی مصنوعی در تخمین تقاضای کوتاه مدت آب شهری." *نشریه دانشکده فنی*، ۴۱(۱)، ۱۱-۲۴.
- 21- Tabesh, M., and Dini, M. (2008). "Fuzzy and neuro- fuzzy models for short-term water demand forecasting in tehran." *Iranian J. of Science and Technology*, Transaction B, 33 (1), 61-77.
- 22- Buchberger, G., and Wu, L. (1995). "Model for instantaneous residential water demand." *J. of Hydraulic Engineering*, 121(3), 232-246.
- 23- Buchberger, G., and Wells, G.J. (1996). "Intensity, duration and frequency of residential water demands." *J. of Water Resources Planning and Management*, 122(11), 11-18.
- 24- Haykin, S. (1999). *Neural networks: a comprehensive foundation*, Prentice Hall, New Jersey, USA.
- 25- Nelles, O. (2001). *Nonlinear system identification*, Springer Verlag, Berlin.
- ۲۶- تابش، م. (۱۳۸۵). *تخمین تقاضای کوتاه مدت آب شهری با استفاده از شبکه‌های عصبی و سیستم‌های فازی و ترکیبی*، گزارش نهایی طرح پژوهشی، مؤسسه آب دانشگاه تهران، انتشارات شرکت مدیریت منابع آب ایران، وزارت نیرو، تهران.