

پیش‌بینی میزان غلظت آلاینده‌های هوای تهران با استفاده از شبکه عصبی مصنوعی

*سیامک بوداچپور^۱

Bodaghpour@kntu.ac.ir

^۲امیر چرخستانی^۲

تاریخ پذیرش: ۸۷/۵/۱

تاریخ دریافت: ۸۷/۱/۲۰

در این تحقیق شبکه عصبی مصنوعی جهت برآورد و پیش‌بینی غلظت گازهای آلاینده هوای کار رفته است. با توجه به خطر آلودگی هوای در شهر تهران و ایجاد مشکلات زیست محیطی و بیماری‌های خطرناک تنفسی و پوستی به ویژه برای کودکان و سالمندان و نیاز شدید به کنترل آن، این تحقیق در جهت برنامه ریزی و کنترل این مشکل در تهران و همچنین شهرهای بزرگ دیگر انجام گرفته است. برای این منظور از آمار غلظت گازهای آلاینده هوای ثبت شده توسط حسگرهای (سنسر) نصب شده در ایستگاه بازار در سال‌های ۱۳۸۱ تا ۱۳۸۶ استفاده شده است (غاز NOX). از مدل اتو رگرسیو و سری‌های زمانی جهت تعیین ورودی‌های شبکه عصبی استفاده شده و بر اساس این مدل غلظت گاز در زمان حاری به غلظت گازهای ۷ روز گذشته وابسته است. بنابراین ورودی‌های شبکه عصبی غلظت گاز در ۷ روز گذشته و خروجی آن که در واقع پیش‌بینی شبکه عصبی می‌باشد، غلظت گاز در زمان حاری می‌باشد. سپس با استفاده از نرم افزار مطلب ۷، مدل شبکه عصبی مصنوعی طراحی شده و این پیش‌بینی انجام گرفته است. همچنین این پیش‌بینی با استفاده از رگرسیون غیر خطی نیز انجام گرفته و در پایان نتایج مدل ثبت گردیده و خطای جذر میانگین مربعات مدل شبکه عصبی با معادلات رگرسیون مقایسه شده است و مشاهده می‌شود که خطای مدل شبکه عصبی کمتر از روش رگرسیون است. مدل‌های ارایه شده توانایی چشم‌گیری در پیش‌بینی میزان آلودگی هوای تهران را دارند.

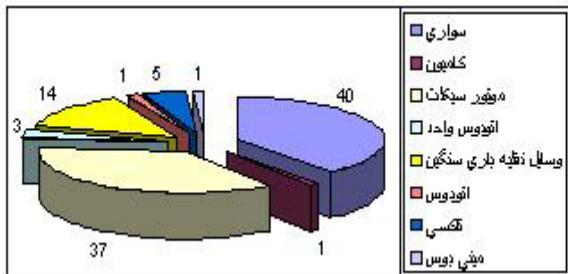
واژه‌های کلیدی: آلودگی هوای اکسیدهای نیتروژن، اکسیدهای کربن، شبکه عصبی، سری‌های زمانی.

۱- استادیار دانشکده عمران، دانشگاه صنعتی خواجه نصیر الدین طوسی تهران^{*} (مسئول مکاتبات).

۲- کارشناس ارشد مهندسی عمران- سازه‌های هیدرولیکی دانشگاه آزاد اسلامی واحد درفول

مقدمه

نارنگی که گذشته از توقف و کاهش رشد، موجب فساد سریع آن ها بعد از برداشت می شود(۳). نمودار ۱ توزیع سالیانه اکسید نیتروژن را توسط انواع خودروها در شهر تهران نشان می دهد.



نمودار ۱- نمودار توزیع سهم وسایل نقلیه در تولید اکسید نیتروژن

مقایسه شبکه عصبی مصنوعی و سیستم عصبی مغز ارتباطی که بین سیستم عصبی مغز و شبکه عصبی مصنوعی وجود دارد عبارتند از:

- بلوکهای ساختاری در هر دو شبکه مصنوعی و بیولوژیکی دستگاههای محاسباتی خیلی ساده‌ای هستند و علاوه بر این نرون‌های مصنوعی از سادگی بیشتری برخوردار می‌باشند.
- ارتباطات بین نرون‌ها عملکرد شبکه را تعیین می‌کند.

عملکرد مغز بسیار سریع تر از رایانه معمولی است. علت این امر به خاطر ساختار کاملاً موازی نرون‌ها می‌باشد و این به آن معنی است که همه نرون‌ها معمولاً به طور همزمان کار می‌کنند و پاسخ می‌دهند(۳).

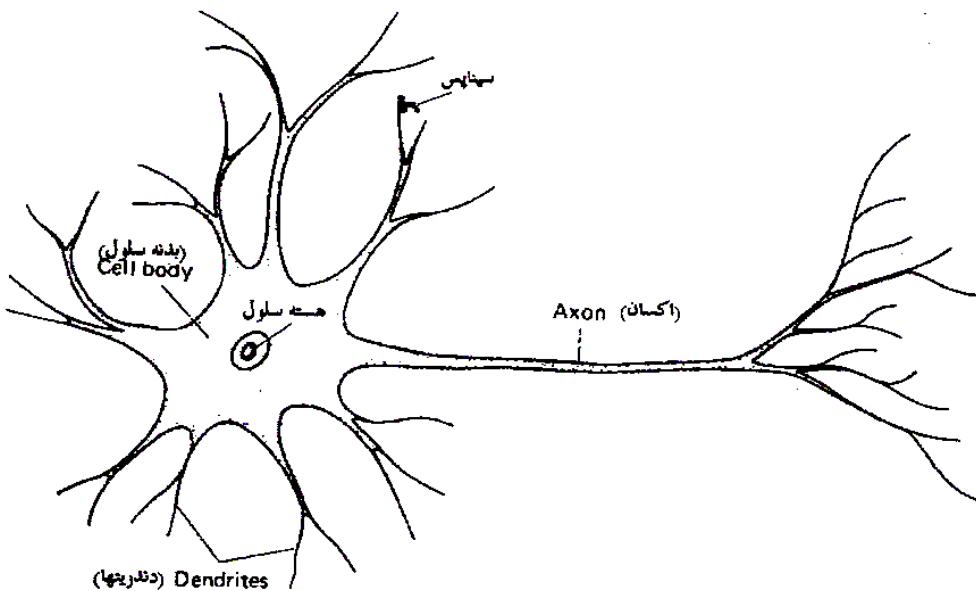
در سال های اخیر هوش مصنوعی به جای روش های سنتی علمی قبلی جایگزین شده است. شبکه های عصبی مصنوعی یکی از محبوب‌ترین روش های هوش مصنوعی محسوب می شود که مدل های ریاضی مغز انسان را به صورت ساده به عنوان یک سیستم استفاده می‌کند. شبکه های عصبی عموماً با داده های آموزشی آموزش داده می‌شوند. آن ها قادرند ارتباطات جدید، توابع جدید و یا الگوهای جدید را کشف کنند و به دلیل ویژگی های فوق کاربرد وسیعی پیدا کرده‌اند، به ویژه استفاده از شبکه پرسپترون چند لایه که برای پیش‌بینی در امر کیفیت هوا در دهه اخیر، مطالعات زیادی انجام یافته است. امروزه پیش‌بینی پارامترهای کیفیت هوا از موضوعات مهم و محبوب در علوم محیط زیست و اتمسفریک است زیرا رابطه مستقیم با سلامتی بشر دارد. بنابراین نیاز به مدل های دقیق برای پیش‌بینی آلودگی هوا احساس می‌شود.

اثرات اکسیدهای نیتروژن بر انسان، گیاهان و اجسام

نیتروس اکسید (N_2O) گازی بی‌رنگ، غیر قابل اشتعال، غیرسمی با مزه و بوی نسبتاً خوب است. نیتریک اکسید یا منواکسیدنیتروژن (NO) گازی بی‌رنگ، غیر قابل اشتعال، بی‌بو و سمی است. همین طور دی‌اکسید نیتروژن (NO_2) نیز گازی قهوه‌ای رنگ، غیر قابل اشتعال و با بوی شدیداً خفقلان زا است.

NO_2 و NO هر دو برای سلامتی انسان مضرند و اثر چهار برابر بیشتر از NO است. دامنه آستانه تحریک NO_2 در انسان ۱ تا $3 ppm$ گزارش شده است(۱). غلظت‌های بالا تا حد $13 ppm$ باعث ناراحتی‌های بینایی و تنفسی در بعضی افراد گردیده و غلظت‌های NO بیش از $100 ppm$ در عرض 10 تا 12 روز باعث مرگ افراد می‌گردد.

اکسیدهای نیتروژن به گیاهان نیز آسیب می‌رسانند برای مثال NO در فتوسنتر گیاهان اختلال ایجاد می‌کند. هوای محتوى NO $0.5 ppm$ رشد گیاهان را بسیار کاهش می‌دهد. بهخصوص در مورد گیاهانی نظری گوجه فرنگی، لوبیا یا



شکل ۱- نواحی اصلی یک سلول عصبی بیولوژیک

عصبی پرداخته شود تا در مراحل بعدی با استفاده از این داده ها به آموزش و آزمایش شبکه های عصبی گوناگون پرداخته و بهترین شبکه برگزیده شود.

در این بخش هدف تهیه داده های اولیه برای پیش بینی غلظت گازهای آلاینده ها با استفاده از شبکه عصبی مصنوعی می باشد.

مواد و روش ها

۱- تعیین میزان همبستگی غلظت پارامترهای آلودگی هوا با مقادیر گام های زمانی گذشته

جهت پیش بینی میزان غلظت پارامتر معرف آلودگی هوا که در این مطالعه NO_X می باشد، ابتدا باید متغیرهای مستقل این پارامتر تعیین گردد. در این تحقیق متغیرهای مستقل در واقع مقدار پارامتر ذکر شده فوق در گام های زمانی گذشته می باشند. بنابراین لازم است مشخص گردد پارامتر تا چند تأخیر زمانی با مقدار آن در زمان فعلی وابستگی دارد. جهت تعیین میزان این تأخیرها از مدل های خود همبسته استفاده می گردد(۴).

کلیات

شناخت شهر تهران به عنوان حوضه مورد مطالعه

تهران، پایتخت کشور عزیzman ایران بوده و در استان تهران در کوهپایه دامنه های جنوبی البرز قرار گرفته است. از نظر موقعیت کلی، تهران تقریباً در شمال استان تهران و بر روی سه مخروطه افکنه بزرگ جاجرود، کن و کرج قرار گرفته است. رشد و توسعه نا موزون و بدون برنامه شهری که عمدتاً در حاشیه شهرها به دلیل ارزان بودن زمین، کنترل کمتر متصدیان شهری بر این نقاط و عواملی از این دست در شهرهای بزرگ شکل می گیرد و با پدیده حاشیه نشینی نیز همراه می باشد، سبب گردیده که که مسئله حدود و حریم شهر تهران همواره مشکل ساز باشد.

داده های آلودگی هوا (ورودی شبکه عصبی)

با توجه به این که یکی از مسایل بسیار مهم در شبکه های عصبی مصنوعی تهیه داده های اولیه برای آموزش شبکه می باشد و توانایی شبکه عصبی در پاسخ به مسایل جدید تا حد زیادی به داده های اولیه بستگی دارد، لازم است به بررسی، جمع آوری، اندازه گیری و محاسبه ورودی های شبکه

میزان تغییرات غلظت پارامتر یاد شده بالا می‌باشد، لذا از متوسط غلظت ساعتی ثبت شده به عنوان غلظت روزانه استفاده شده است.

جداول و نمودارهای به دست آمده با استفاده از مدل خود همبسته برای گاز مورد مطالعه بیانگر چگونگی این همبستگی می‌باشند(جدول ۱ و نمودارهای ۲ و ۳).

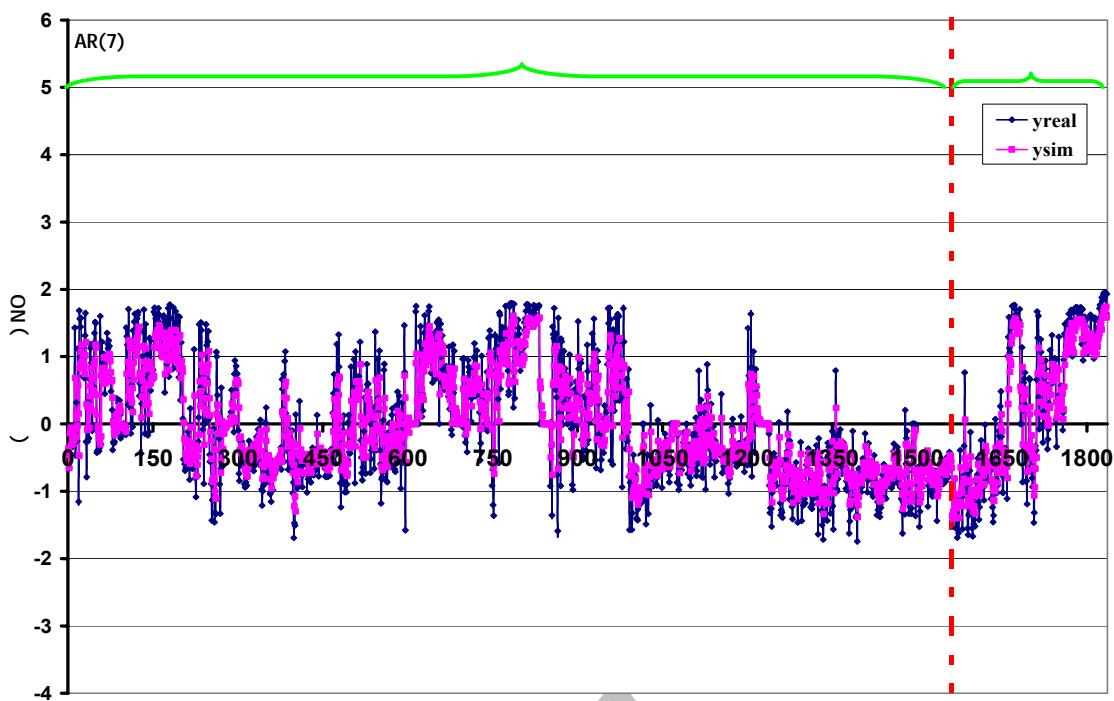
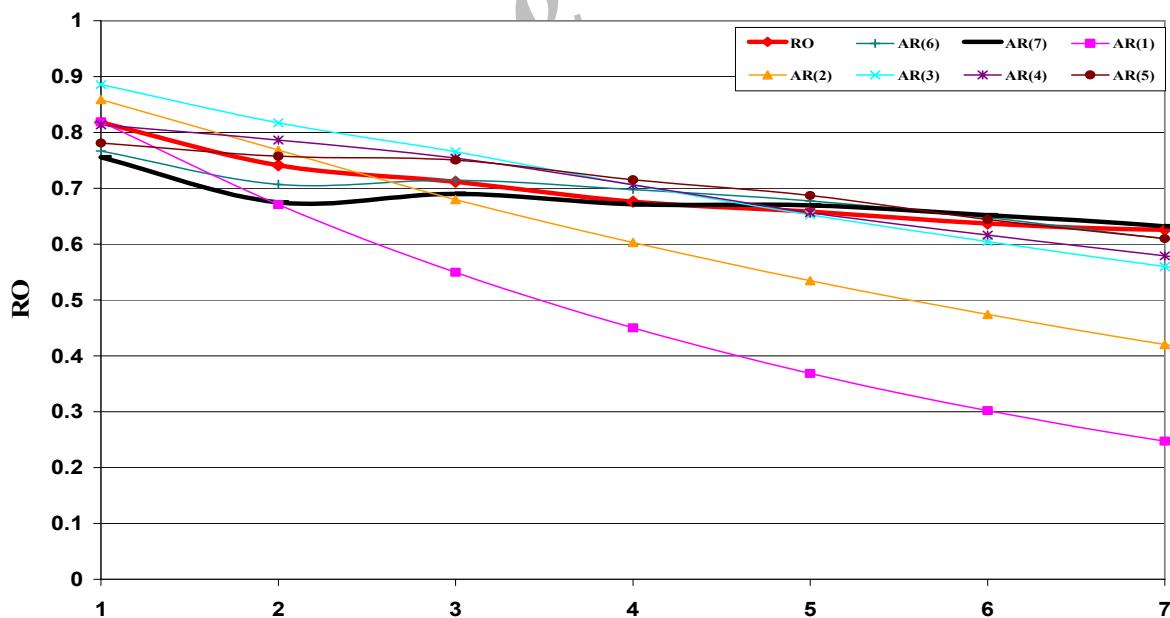
در واقع پردازش داده‌ها با استفاده از ضرایب خود- همبسته در جدول ۱ و رسم نمودارهای ۲ و ۳ انجام یافته است.

با توجه به رفتار و حافظه بلندمدت یا کوتاه مدت سری زمانی نوع مدل خود همبسته را می‌توان تعیین نمود. در این بخش با استفاده از مقایسه ضرایب خود همبسته (که از سری زمانی داده‌های غلظت به دست می‌آید) با مقدار این ضرایب برای مدل‌های مختلف و به ازای تأخیرهای متفاوت، تأخیری که بیشترین همبستگی را نشان می‌دهد انتخاب می‌گردد(۴).

در این تحقیق از داده‌های ساعتی ثبت شده ایستگاه بازار در طی یک دوره زمانی ۵ ساله (۸۶ تا ۸۱) استفاده شده است. با توجه به این که هدف در این مطالعه پیش‌بینی روزانه

AR17	AR16	AR15	AR14	AR13	AR12	AR11	AR10	AR9	AR8	AR7	AR6	AR5	AR4	AR3	AR2	AR1	
0.543719	0.54331	0.542654	0.543684	0.544678	0.544209	0.544232	0.543951	0.545524	0.553926	0.562777	0.567089	0.572772	0.581296	0.597022	0.639203	0.819047	Ph11
0.061646	0.062191	0.061936	0.062283	0.063362	0.062685	0.063601	0.062876	0.06437	0.06554	0.066707	0.072495	0.073628	0.08861	0.086259	0.219497	0	Ph12
0.114755	0.114808	0.114886	0.116125	0.114849	0.116242	0.118865	0.117987	0.118235	0.118412	0.125885	0.12725	0.134701	0.14376	0.192345	0	0	Ph13
0.000622	-0.001296	-0.002311	-0.003742	-0.003116	-0.004449	0.002089	0.002054	0.001932	0.00887	0.00692	0.016844	0.020662	0.081115	0	0	0	Ph14
0.040755	0.043888	0.044798	0.045388	0.047166	0.050366	0.051155	0.051125	0.052229	0.052677	0.066904	0.072477	0.103831	0	0	0	0	Ph15
-0.008386	-0.009004	-0.009807	-0.007528	-0.005425	-0.005448	-0.006136	-0.006642	-0.006583	0.002274	0.009826	0.0546	0	0	0	0	0	Ph16
0.004129	0.003899	0.002944	0.005103	0.005313	0.005462	0.008071	0.008073	0.010687	0.015443	0.078798	0	0	0	0	0	0	Ph17
0.070934	0.070509	0.065334	0.065648	0.065341	0.070992	0.071361	0.065888	0.071178	0.112542	0	0	0	0	0	0	0	Ph18
0.058568	0.058204	0.058093	0.05777	0.059302	0.059243	0.063925	0.063157	0.074615	0	0	0	0	0	0	0	0	Ph19
0.018302	0.018536	0.018791	0.020342	0.020276	0.025319	0.027203	0.020892	0	0	0	0	0	0	0	0	0	Ph10
-0.039369	-0.039741	-0.040651	-0.040742	-0.037226	-0.034166	-0.011509	0	0	0	0	0	0	0	0	0	0	Ph11
0.013648	0.01404	0.014024	0.01762	0.019418	0.041345	0	0	0	0	0	0	0	0	0	0	0	Ph12
0.023399	0.023562	0.021598	0.023468	0.040294	0	0	0	0	0	0	0	0	0	0	0	0	Ph13
0.014868	0.014323	0.013419	0.030761	0	0	0	0	0	0	0	0	0	0	0	0	0	Ph14
0.042368	0.041532	0.031862	0	0	0	0	0	0	0	0	0	0	0	0	0	0	Ph15
-0.016774	-0.0177	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	Ph16
-0.002068	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	Ph17
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	Ph18
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	Ph19
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	Ph20

جدول ۱- ضرایب خودهمبسته جزئی برای تأخیرهای مختلف مدل خودهمبسته (پارامتر NO_x)

نمودار ۲- نتایج مقادیر شبیه سازی و مشاهده شده با استفاده از مدل خود همبسته مرتبه ۷ (پارامتر NO_x)نمودار ۳- تعیین بهترین میزان تاخیر با استفاده از مقایسه ضریب همبستگی مقادیر مشاهده شده با توابع خود همبسته برای تاخیرهای مختلف (پارامتر NO_x)

صحت‌سنجی (داده‌هایی که در آموزش شبکه دخالت داده نشده‌اند) در تکرارهای بالا افزایش نیابد. با استفاده از وزن‌ها و بردارهای ثابت آموزش داده شده برای پارامترهای غلظت می‌توان معادله پیش‌بینی روزانه تغییرات غلظت را به صورت زیر ارایه نمود:

$$C_p = \text{purelin}(w'_2 \times \text{tansig}((w_1 \times c) + b_1) + b_2), \quad p = No, No_x, No_{x_2}, Co$$

از آن جا که شبکه برای اعداد بین صفر و یک آموزش دیده است (به علت تسریع در امر شبیه‌سازی و ارایه جواب‌های مناسب‌تر) لذا با استی اعداد ماتریس C را به صورت صفر و یک (اعداد استاندارد شده در آورده) تا شبکه جواب مناسب‌تری را حاصل نماید. به همین ترتیب معادلات تغییرات غلظت پارامتر یاد شده بالا برای کل روزهای سال پیش‌بینی می‌شود. با توجه به مناسب بودن آموزش شبکه، می‌توان پارامترهای وزنی نهائی شبکه را محاسبه نمود.

وزن و بردار اساسی پارامتر شبکه

در این بخش وزن‌ها و بردارهای بایس کالیبره شده پارامتر No_x ارایه می‌گردد.

همچنین نوع تابع محرک لایه اول از نوع tansing و لایه آخر از نوع purelin می‌باشد. لازم به ذکر است علت توقف آموزش شبکه در تعداد تکرارهای پایین، جلوگیری از آموزش زیاد شبکه^۱ می‌باشد. در این تحقیق آموزش شبکه زمانی متوقف شده است که میزان خطای داده‌های

در معادله بالا C یک ماتریس 7×1 می‌باشد که آرایه‌های آن میزان غلظت در ۷ روزه قبل می‌باشد. همچنین w'_2, w_1 به ترتیب پارامترهای وزنی شبکه برای لایه‌های اول و آخر (اندیس نشان‌دهنده شماره لایه می‌باشد)، اندیسی که در بالای پارامتر وزنی لایه آخر گذارد شده نشان‌دهنده ترانهاده آن ماتریس است و b_2 و b_1 بردارهای اساسی (ثابت‌های وزنی) لایه‌های اول و آخر می‌باشند. به عنوان نمونه ماتریس C برای پارامتر غلظت NoX در روزهای ۲۱-۲۷ ماه مارچ سال ۲۰۰۲ جهت پیش‌بینی غلظت در روز ۲۸ ماه مارچ همان سال به صورت زیر می‌باشد:

$$c = \begin{bmatrix} 19.179 \\ 12.733 \\ 15.583 \\ 33.017 \\ 45.283 \\ 23.733 \\ 32.746 \end{bmatrix}$$

$$w_1 = \begin{bmatrix} 0.4346 & -0.9992 & -0.8023 & 0.2263 & 0.6174 & -0.1938 & -1.1879 \\ 0.6573 & 2.8085 & 3.0188 & -0.5535 & 1.6468 & -2.8747 & -1.8094 \\ 2.3422 & -2.3645 & 0.3385 & -0.3887 & -0.4845 & 0.8682 & -1.4061 \\ -0.6509 & 0.0614 & 1.6586 & -0.0070 & 1.7790 & -0.0789 & 1.5787 \\ -1.5982 & 0.6534 & 0.1806 & -2.4236 & -1.7418 & -1.1175 & -1.3094 \\ 0.4301 & 0.0385 & 1.2282 & 0.3358 & -1.6272 & -1.8865 & 2.6763 \\ 1.4738 & -0.3454 & -0.9826 & 0.8442 & 3.3269 & -0.9287 & -3.7873 \\ -0.6918 & 1.2186 & 0.5833 & -0.4256 & 0.6483 & 1.5322 & -2.6997 \\ -1.4039 & -1.8348 & -0.9486 & -0.7713 & -3.3144 & -1.8556 & -2.7099 \\ 0.6865 & 1.3677 & 0.3983 & 1.6681 & -0.5584 & -0.7080 & 0.8259 \end{bmatrix}$$

$$w_2' = \begin{bmatrix} -0.3204 & -0.0267 & 0.1279 & 0.0978 & -0.0820 & -0.4627 & 0.0135 & -0.1785 & -0.0764 & -0.3187 \end{bmatrix}$$

$$b_1 = \begin{bmatrix} 0.7129 \\ -3.4378 \\ -2.1497 \\ -3.1590 \\ 3.3975 \\ 1.2897 \\ -0.6505 \\ -0.5467 \\ 2.6546 \\ 0.0303 \end{bmatrix}$$

$b_2 = 1.2272$

داده‌های جدید داشته باشد. با توجه به این که توان شبکه عصبی با الگوریتم آموزش پس انتشار خطا (Back Propagation) در حل مسائل گوناگون به اثبات رسیده است، می‌توان با اطمینان از این روش در پیش‌بینی آلودگی هوای تهران استفاده نمود.

میزان آلودگی انواع اکسیدهای نیتروژن نه تنها تابعی از سوخت خودروها و سایر عوامل آلوده‌کننده هوای شهر تهران است، بلکه شرایط جوی، دما و فصلی رابطه مستقیمی در میزان آلودگی هوای تهران دارد. همان گونه که در نمودارها مشهود است، در فصل‌های بهار، زمستان و قسمتی از پاییز میزان حداکثر و مجموع انواع اکسیدهای نیتروژن جهش بیشتری را نشان می‌دهد.

با توجه به نمودارهای نشان داده شده، روند تغییرات آلودگی اکسیدهای نیتروژن به طور مجموع و حداکثر سینوسی بوده و می‌توان آن‌ها را به روابط ریاضی تبدیل و برای پیش‌بینی شرایط آتی آلودگی استفاده کرد. در این قسمت نتایج مربوط به ارایه داده‌ها (با توجه به نتایج سری‌های زمانی) به مدل شبکه عصبی برای گاز NO_x نشان داده شده است (نمودارهای ۴ تا ۷).

نتایج و بحث

- امروزه توانایی بالا و قدرت شبکه‌های عصبی در یادگیری ارتباطات پیچیده سیستم‌های آلودگی هوای موجب شده تا کاربرد مدل شبکه عصبی در مسائل مختلف زیست محیطی به طور روزافزونی گسترش یابد.

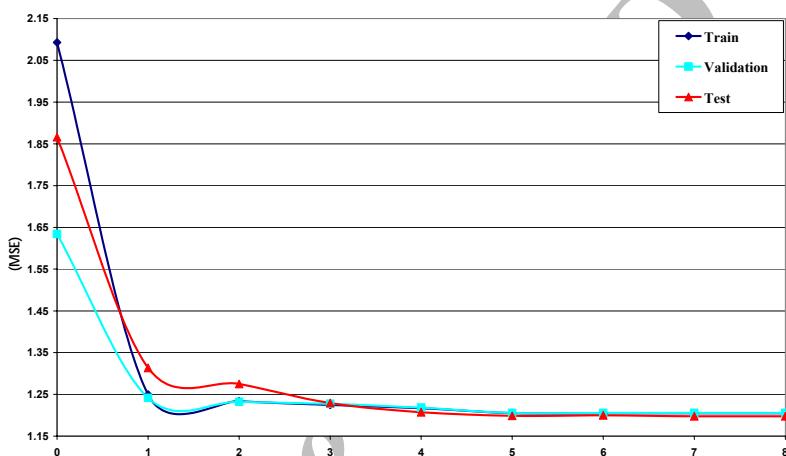
- آمارهای آلودگی هوای کار گرفته شده در محاسبات ماهیت کاملاً غیرخطی دارند. تجربه حاصل از محاسبات نشان می‌دهد با کاهش ماهیت غیرخطی آمار، تعداد سلول‌های عصبی مورد نیاز برای شبکه و یا تعداد وزن‌های بین سلول‌های عصبی در شبکه کاهش می‌یابد. به عبارت دیگر، تعداد سلول‌های عصبی و یا وزن‌های ارتباطی مورد لزوم در یک شبکه، علاوه بر تعداد زوج‌های آموزشی به ماهیت غیرخطی اطلاعات نیز بستگی دارد و هر چه ماهیت غیرخطی بیشتر باشد.

- تعداد مورد نیاز برای آن‌ها نیز بیشتر است. با کاهش ماهیت غیرخطی آمار موجود، شبکه بهتر آموزش می‌بیند و دقت آن نیز افزایش می‌یابد. از طرفی زمان مورد نیاز برای آموزش شبکه نیز کاهش می‌یابد.
- با توجه به رابطه مستقیم توان عصبی و آمارهای استفاده شده در آموزش آن، لازم است در تهیه داده‌های آموزش شبکه عصبی دقت لازم به عمل آید تا شبکه عصبی تعمیم پذیری مناسبی در مواجهه با

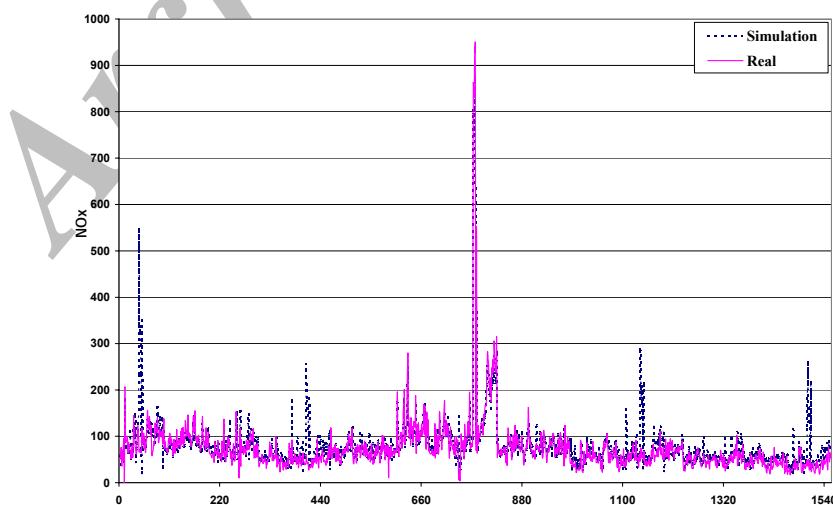
روند شبیه سازی را انجام دهد و انطباق خوبی بین داده های شبیه سازی شده و داده های واقعی برقرار است.

شبیه سازی روزانه غلظت پارامتر NO_X
تعداد نمونه لایه اول و آخر به ترتیب عبارت است از: ۱۰ و ۱

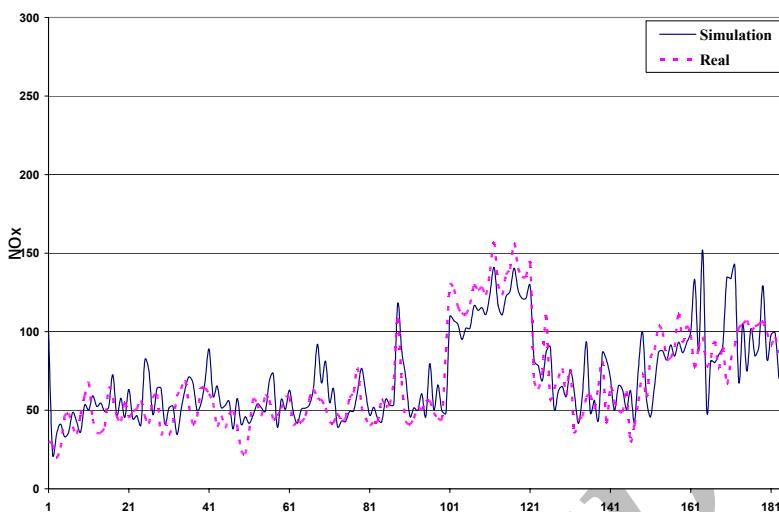
همان طور که در نمودارهای یاد شده دیده می شود ابتدا خطای میانگین مربعات برای مدل و برای دسته های مختلف داده ها محاسبه و ترسیم شده است، تا با استفاده از آن بتوان تعداد مناسب تکرار را به دست آورد. سپس در سه نمودار بعدی مقایسه غلظت داده های واقعی با داده های شبیه سازی شده برای هر سه دسته (داده های آموزشی، داده های کالیبراسیون و داده های صحت سنجی) داده ها، انجام یافته است. ملاحظه می شود که شبکه عصبی توانسته است به خوبی



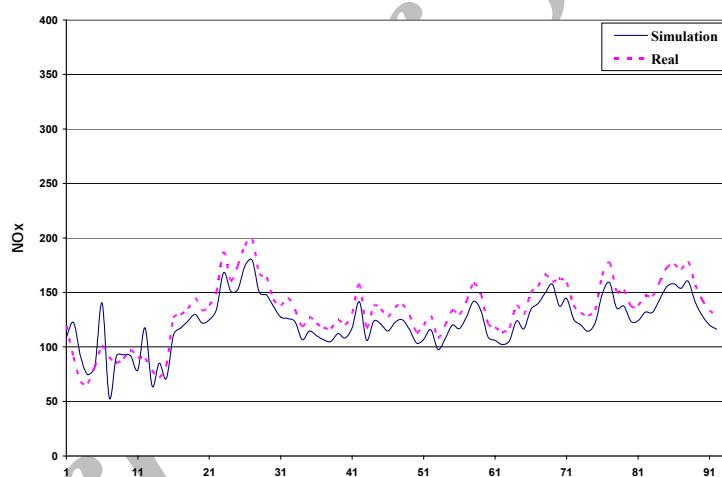
نمودار ۴- میزان خطای آموزش، کالیبراسیون و صحت سنجی برای تکرارهای مختلف جهت شبیه سازی غلظت NO_X



نمودار ۵- مقایسه غلظت NO_X مشاهده شده با مقادیر شبیه سازی شده با استفاده از داده های آموزشی



نمودار ۶- مقایسه غلظت NO_X مشاهده شده با مقادیر شبیه سازی شده با استفاده از داده های کالیبراسیون



نمودار ۷- مقایسه غلظت NO_X مشاهده شده با مقادیر شبیه سازی شده با استفاده از داده های صحتسنجی

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_{mi} - x_{ci})^2}{n}}$$

در معادله فوق متغیرها عبارتند از:

x_{mi} : مقدار اندازه گیری شده

x_{ci} : مقدار پیش بینی شده

n : تعداد کل داده های مشاهده شده

همان طور که در نمودارهای بالا مشاهده گردید انطباق خوبی بین داده های ورودی شبکه عصبی و نتایج مدل به دست آمده است.

مقایسه خطای نتایج مدل شبیه سازی شبکه عصبی مصنوعی با معادلات رگرسیونی

جهت ارایه برتری مدل شبیه سازی شبکه عصبی، نتایج شبیه سازی توسط این مدل با مدل رگرسیون خطی و غیرخطی با استفاده از معیار مجدد میانگین مربعات خطای (RMSE) مورد مقایسه قرار گرفته است.

مقایسه با رگرسیون های خطی و غیر خطی نشان می دهد.
معادله رگرسیونی غیر خطی پارامتر NOX

همان گونه که در جدول ۲ اشاره شده است برآورد پارامتر NOX توسط شبکه عصبی به مراتب خطای کمتری در

$$C_t^{NO_x} = 0.0068(C_{t-1}^{NO_x})^{1.56} - 10^{-7}(C_{t-2}^{NO_x})^{2.58} + 0.38(C_{t-3}^{NO_x})^{-5.2} - 10^{-4}(C_{t-4}^{NO_x})^{2.2} + 10^{-7}(C_{t-5}^{NO_x})^{3.64} + 3.12(C_{t-6}^{NO_x})^{0.45} + 0.49(C_{t-7}^{NO_x})^{1.01}$$

جدول ۲- میزان خطای RMSE در دو مدل شبکه عصبی و رگرسیون برای پارامتر NOX

رگرسیون		شبکه عصبی	پارامتر
غیرخطی	خطی		
۲۹/۷۱	۳۱/۲۴	۱۸/۹۲	NOx

7. Rieddmailer,M. and Braun, H.(2001) “A direct Adaptive Method for faster backpropagation learning: The RPOMP Algorithm” IEEE international conference on neural networks, pp. 586-591.
8. Oavia, H.A.R. and Sies, C.P. (2002) “Pattern recognition with neural networks in C++ ”. Florida, CRC and IEEE press
9. Freeman, J.A. and Skapura, D.M. (1999) “Neural Networks Algorithms, Application and programming technicques” Addison-Wesley publishing company.
10. Eberhart, R.C. and Bobins, R.W. (1998) “Neural net work PC tools ”. Academic press. San Diego, California
11. Ellacott, S and Base, D.(1996) “ Neural networks : deterministic method of analysis” Int. Thomason computer press.
12. Hericej, T. (1997). “Modular learning in neural network: the cerebral cortex”. Paris, Masson Prentice-Hall

با توجه به جدول ۲ می توان دریافت که میزان دقت مدل شبیه سازی شبکه عصبی در مقایسه با مدل های رگرسیون خطی و غیرخطی قابل توجه بوده و بهتر می تواند شرایط آینده را شبیه سازی نماید.

منابع

۱. عباسپور، مجید، چاپ چهارم ۱۳۸۳، "مهندسی محیط زیست" ، انتشارات دانشگاه آزاد اسلامی، جلد اول.
۲. فرشینه نژاد، محمدرضا، ۱۳۸۳، "آشنایی با مباحث آلودگی های محیط زیست" ، انتشارات آدینه.
۳. منهاج، م. ب، ۱۳۸۴، "مبانی شبکه های عصبی مصنوعی" ، انتشارات دانشگاه صنعتی امیر کبیر.
۴. کارآموز، محمد و عراقی نژاد، شهاب، ۱۳۸۴، "هیدرولوژی پیشرفته" ، انتشارات دانشگاه صنعتی امیر کبیر(پلی تکنیک تهران).
۵. آمار آلودگی هوا، شرکت کنترل کیفیت هوا(وابسته به شهرداری تهران)
6. Neural Networks Toolbox guider: for use with MATLAB (1996-2001), <http://www.matworks.com>