

## پیش بینی میزان غلظت آلاینده های هوای تهران با استفاده از شبکه عصبی مصنوعی

سیامک بوداگپور<sup>\*۱</sup>

[Bodaghpour@kntu.ac.ir](mailto:Bodaghpour@kntu.ac.ir)

امیر چرخستانی<sup>۲</sup>

تاریخ پذیرش: ۸۷/۵/۱

تاریخ دریافت: ۸۷/۱/۲۰

در این تحقیق شبکه عصبی مصنوعی جهت برآورد و پیش بینی غلظت گازهای آلاینده هوا به کار رفته است. با توجه به خطر آلودگی هوا در شهر تهران و ایجاد مشکلات زیست محیطی و بیماری های 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 (سنسور) نصب شده در ایستگاه بازار در سال های ۱۳۸۱ تا ۱۳۸۶ استفاده شده است (گاز NOX). از مدل اتو رگرسیون و سری های زمانی جهت تعیین ورودی های شبکه عصبی استفاده شده و بر اساس این مدل غلظت گاز در زمان جاری به غلظت گازهای ۷ روز گذشته وابسته است. بنابراین ورودی های شبکه عصبی غلظت گاز در ۷ روز گذشته و خروجی آن که در واقع پیش بینی شبکه عصبی می باشد، غلظت گاز در زمان جاری می باشد. سپس با استفاده از نرم افزار مطلب ۷، مدل شبکه عصبی مصنوعی طراحی شده و این پیش بینی انجام گرفته است. همچنین این پیش بینی 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 می شود که خطای مدل شبکه عصبی کمتر از روش رگرسیون است. مدل های ارائه شده توانایی چشم گیری در پیش بینی میزان آلودگی هوای تهران را دارند.


واژه های کلیدی: آلودگی هوا، اکسیدهای نیتروژن، اکسیدهای کربن، شبکه عصبی، سری های زمانی.

۱- استادیار دانشکده عمران، دانشگاه صنعتی خواجه نصیرالدین طوسی تهران\* (مسئول مکاتبات).

۲- کارشناس ارشد مهندسی عمران- سازه های هیدرولیکی دانشگاه آزاد اسلامی واحد دزفول

## مقدمه

نارنگی که گذشته از توقف و کاهش رشد، موجب فساد سریع آن ها بعد از برداشت می شود (۲). 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 سال‌های اخیر هوش مصنوعی به جای روش‌های سنتی علمی قبلی جایگزین شده است. شبکه‌های عصبی مصنوعی یکی از محبوب‌ترین روش‌های هوش مصنوعی محسوب می‌شود که مدل‌های ریاضی مغز انسان را به صورت ساده به عنوان یک سیستم استفاده می‌کند. شبکه‌های عصبی عموماً با داده‌های آموزشی آموزش داده می‌شوند. آن‌ها قادرند ارتباطات جدید، توابع جدید و یا الگوهای جدید را کشف کنند و به دلیل ویژگی‌های 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 مدل‌های 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 منواکسید نیتروژن ( $NO$ ) گازی بی‌رنگ، غیر قابل اشتعال، بی‌بو و سمی است. همین‌طور دی‌اکسید نیتروژن ( $NO_2$ ) نیز گازی قهوه‌ای رنگ، غیر قابل اشتعال و با بوی شدیداً خفکان‌زا است.

$NO$  و  $NO_2$  هر دو برای سلامتی انسان مضرند و اثر  $NO_2$  چهار برابر بیشتر از  $NO$  است. دامنه آستانه تحریک  $NO_2$  در انسان ۱ تا ۳ ppm گزارش شده است (۱). غلظت‌های بالا تا حد ۱۳ ppm باعث ناراحتی‌های بینایی و تنفسی در بعضی افراد گردیده و غلظت‌های  $NO$  بیش از ۱۰۰ ppm در عرض ۱۰ تا ۱۲ روز باعث مرگ افراد می‌گردد.

اکسیدهای نیتروژن به گیاهان نیز آسیب می‌رسانند برای مثال  $NO$  در فتوسنتز گیاهان اختلال ایجاد می‌کند. هوای محتوی  $0.5 ppm$   $NO$  رشد گیاهان را بسیار کاهش می‌دهد. به‌خصوص در مورد گیاهانی نظیر گوجه‌فرنگی، لوبیا یا



شکل ۱- نواحی اصلی یک سلول عصبی بیولوژیک

#### کلیات

#### شناخت شهر تهران به عنوان حوضه مورد مطالعه

تهران، پایتخت کشور عزیزمان 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

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 هوا 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 باشد. 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<sup>۱</sup> استفاده می گردد (۴).

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 ضریب 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 (۸۱ تا ۸۶) 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	0.553925	0.562777	0.557089	0.572772	0.581295	0.597022	0.639203	0.819047	Pi1
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	0.096259	0.219497	0	Pi2
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	Pi3
0.000622	-0.001236	-0.002311	-0.003742	-0.003116	-0.000449	0.002089	0.002054	0.001932	0.00587	0.006592	0.016644	0.020662	0.081115	0	0	0	Pi4
0.040755	0.043888	0.044798	0.045388	0.047166	0.050366	0.051155	0.051125	0.052229	0.052677	0.066904	0.072477	0.108831	0	0	0	0	Pi5
-0.008386	-0.009004	-0.009307	-0.007528	-0.005425	-0.005448	-0.006136	-0.006942	-0.006583	0.002274	0.009826	0.0546	0	0	0	0	0	Pi6
0.004129	0.003899	0.002944	0.005103	0.005313	0.005462	0.008071	0.008073	0.010587	0.015443	0.078798	0	0	0	0	0	0	Pi7
0.070934	0.070509	0.06934	0.069548	0.069341	0.070992	0.071361	0.069898	0.071178	0.112542	0	0	0	0	0	0	0	Pi8
0.058668	0.058204	0.058093	0.05777	0.058302	0.058243	0.05925	0.059157	0.074615	0	0	0	0	0	0	0	0	Pi9
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	Pi10
-0.039369	-0.039741	-0.040651	-0.040742	-0.037226	-0.034166	-0.011509	0	0	0	0	0	0	0	0	0	0	Pi11
0.013648	0.01404	0.014024	0.01762	0.019418	0.041345	0	0	0	0	0	0	0	0	0	0	0	Pi12
0.023399	0.023562	0.021598	0.023468	0.040294	0	0	0	0	0	0	0	0	0	0	0	0	Pi13
0.014868	0.014323	0.013419	0.030761	0	0	0	0	0	0	0	0	0	0	0	0	0	Pi14
0.042368	0.041532	0.031862	0	0	0	0	0	0	0	0	0	0	0	0	0	0	Pi15
-0.016774	-0.0177	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	Pi16
-0.002068	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	Pi17
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	Pi18
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	Pi19
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	Pi20

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:

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

از آن‌جا که شبکه برای اعداد بین صفر و یک آموزش دیده است (به علت تسریع در امر شبیه‌سازی و ارایه جواب‌های مناسب‌تر) لذا بایستی اعداد ماتریس  $C$  را به صورت صفر و یک (اعداد استاندارد شده درآورد) 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  $\text{NO}_x$  ارایه می‌گردد.

همچنین نوع تابع محرک لایه اول از نوع  $\text{tansing}$  و لایه آخر از نوع  $\text{purelin}$  می‌باشد. لازم به ذکر است علت توقف آموزش شبکه در تعداد تکرارهای پایین، جلوگیری از آموزش زیاد شبکه<sup>۱</sup> می‌باشد. در این تحقیق آموزش شبکه زمانی متوقف شده است که میزان خطای داده‌های

در معادله بالا  $C$  یک ماتریس  $7 \times 1$  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 گذارده شده نشان‌دهنده ترانهاده آن ماتریس است و  $b_1$  و  $b_2$  بردارهای اساسی (ثابت‌های وزنی) لایه‌های اول و آخر می‌باشند. به عنوان نمونه ماتریس  $C$  برای پارامتر غلظت  $\text{No}_x$  در روزهای ۲۷-۲۱ ماه مارچ سال ۲۰۰۲ جهت پیش‌بینی غلظت در روز ۲۸ ماه مارچ همان سال به صورت زیر می‌باشد:

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

$$w'_1 = \begin{bmatrix} 0.4346 & -0.9992 & -0.8023 & 0.2263 & 0.6174 & -0.1938 & -1.1879 \\ 0.6573 & 2.8085 & 3.0188 & -0.5535 & 1.6468 & -2.8747 & -1.8094 \\ 2.3422 & -2.3645 & 0.3385 & -0.3887 & -0.4845 & 0.8682 & -1.4061 \\ -0.6509 & 0.0614 & 1.6586 & -0.0070 & 1.7790 & -0.0789 & 1.5787 \\ -1.5982 & 0.6534 & 0.1806 & -2.4236 & -1.7418 & -1.1175 & -1.3094 \\ 0.4301 & 0.0385 & 1.2282 & 0.3358 & -1.6272 & -1.8865 & 2.6763 \\ 1.4738 & -0.3454 & -0.9826 & 0.8442 & 3.3269 & -0.9287 & -3.7873 \\ -0.6918 & 1.2186 & 0.5833 & -0.4256 & 0.6483 & 1.5322 & -2.6997 \\ -1.4039 & -1.8348 & -0.9486 & -0.7713 & -3.3144 & -1.8556 & -2.7099 \\ 0.6865 & 1.3677 & 0.3983 & 1.6681 & -0.5584 & -0.7080 & 0.8259 \end{bmatrix}$$

$$w'_2 = \begin{bmatrix} -0.3204 & -0.0267 & 0.1279 & 0.0978 & -0.0820 & -0.4627 & 0.0135 & -0.1785 & -0.0764 & -0.3187 \end{bmatrix}$$

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

$$b_2 = 1.2272$$

### نتایج و بحث

داده های جدید داشته باشد. با توجه به این که توان شبکه عصبی با الگوریتم آموزش پس انتشار خطا (Back Propagation) در حل مسایل گوناگون به اثبات رسیده است، می توان با اطمینان از این روش در پیش بینی آلودگی هوای تهران استفاده نمود.

- میزان آلودگی انواع اکسیدهای نیتروژن نه تنها تابعی از سوخت خودروها و سایر عوامل آلوده کننده 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 فصل های بهار، زمستان و قسمتی از پاییز میزان حداکثر و مجموع انواع اکسیدهای نیتروژن جهش بیشتری را نشان می دهد.

- با توجه به نمودارهای نشان داده شده، روند تغییرات آلودگی اکسیدهای نیتروژن به طور مجموع و حداکثر سینوسی بوده و می توان آن ها را به روابط ریاضی تبدیل و برای پیش بینی شرایط آتی آلودگی استفاده کرد.

در این قسمت نتایج مربوط به ارایه داده ها (با توجه به نتایج سری های زمانی) به مدل شبکه عصبی برای گاز  $NO_x$  نشان داده شده است (نمودارهای ۴ تا ۷).

- امروزه توانایی بالا و قدرت شبکه های عصبی در یادگیری ارتباطات پیچیده سیستم های آلودگی هوا موجب شده تا کاربرد مدل شبکه عصبی در مسایل مختلف زیست-محیطی به طور روزافزونی گسترش یابد.

- آمارهای آلودگی هوا به کار گرفته شده در محاسبات ماهیت کاملاً غیرخطی دارند. تجربه حاصل از محاسبات نشان می دهد با کاهش ماهیت غیرخطی آمار، تعداد سلول های عصبی مورد نیاز برای شبکه و یا تعداد وزن های بین سلول های عصبی در شبکه کاهش می یابد. به عبارت دیگر، تعداد سلول های عصبی و یا وزن های ارتباطی مورد لزوم در یک شبکه، علاوه بر تعداد زوج های آموزشی به ماهیت غیرخطی اطلاعات نیز بستگی دارد و هر چه ماهیت غیرخطی بیشتر باشد تعداد مورد نیاز برای آن ها نیز بیشتر است.

- با کاهش ماهیت غیرخطی آمار موجود، شبکه بهتر آموزش می بیند و دقت آن نیز افزایش می یابد. از طرفی زمان مورد نیاز برای آموزش شبکه نیز کاهش می یابد.


- با توجه به رابطه مستقیم توان عصبی و آمارهای استفاده شده در آموزش آن، لازم است در تهیه داده های 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 داده‌های شبیه‌سازی شده و داده‌های واقعی برقرار است.

#### شبیه‌سازی روزانه غلظت پارامتر $NO_x$


تعداد نرون لایه اول و آخر به ترتیب عبارت است از: ۱۰ و ۱

همان طور که در نمودارهای یاد شده دیده می‌شود ابتدا خطای میانگین مربعات برای مدل و برای دسته‌های مختلف داده‌ها 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 داده‌های واقعی با داده‌های شبیه‌سازی شده برای هر سه دسته (داده‌های آموزشی، داده‌های کالیبراسیون و داده‌های صحت‌سنجی) داده‌ها، انجام یافته است. ملاحظه می‌شود که شبکه عصبی توانسته است به خوبی




نمودار ۴- میزان خطای آموزش، کالیبراسیون و صحت‌سنجی برای تکرارهای مختلف

#### جهت شبیه‌سازی غلظت $NO_x$



نمودار ۵- مقایسه غلظت  $NO_x$  مشاهده شده با مقادیر شبیه‌سازی شده با استفاده از داده‌های 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 صحت سنجی

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

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

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

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 مجذور میانگین مربعات خطا (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
غیر خطی	خطی		
۲۹/۷۱	۳۱/۲۴	۱۸/۹۲	NO <sub>x</sub>

- Rieddmailer, M. and Braun, H. (2001) "A direct Adaptive Method for faster backpropagation learning: The RPORP Algorithm" IEEE international conference on neural networks, pp. 586-591.
- Oavia, H.A.R. and Sies, C.P. (2002) "Pattern recognition with neural networks in C++". Florida, CRC and IEEE press
- Freeman, J.A. and Skapura, D.M. (1999) "Neural Networks Algorithms, Application and programming techniques" Addison-Wesley publishing company.
- Eberhart, R.C. and Bobins, R.W. (1998) "Neural net work PC tools". Academic press. San Diego, California
- Ellacott, S and Base, D. (1996) "Neural networks : deterministic method of analysis" Int. Thomason computer press.
- 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 غیر خطی قابل توجه بوده و بهتر می تواند شرایط آینده را شبیه سازی نماید.

#### منابع

- عباسپور، مجید، چاپ چهارم ۱۳۸۳، "مهندسی محیط زیست"، انتشارات دانشگاه آزاد اسلامی، جلد اول.
- فرشینه نژاد، محمدرضا، ۱۳۸۳، "آشنایی با مباحث آلودگی های محیط زیست"، انتشارات آدینه.
- منهاج، م. ب، ۱۳۸۴، "مبانی شبکه های عصبی مصنوعی"، انتشارات دانشگاه صنعتی امیر کبیر.
- کارآموز، محمد و عراقی نژاد، شهاب، ۱۳۸۴، "هیدرولوژی پیشرفته"، انتشارات دانشگاه صنعتی امیرکبیر (پلی تکنیک تهران).
- آمار آلودگی هوا، شرکت کنترل کیفیت هوا (وابسته به شهرداری تهران)

- Neural Networks Toolbox guider: for use with MATLAB (1996-2001), <http://www.matworks.com>

## بررسی غلظت نیکل در خاک و تعدادی از گونه های گیاهی طبیعی اطراف معدن سرب و روی آهنگران در استان همدان

فرخ لقا امینی<sup>۱</sup> \*

[amini\\_fl@yahoo.com](mailto:amini_fl@yahoo.com)

نورالله میرغفاری<sup>۲</sup>

بهروز عشقی ملایری<sup>۳</sup>

تاریخ پذیرش: ۸۷/۴/۱۰

تاریخ دریافت: ۸۶/۹/۲

فلزات سنگین از آلاینده های خطرناک زیست محیطی هستند که از طریق ورود به زنجیره غذایی موجب بروز خطرات بهداشتی برای انسان، گیاهان و سایر موجودات زنده می شوند. در خاک های آلوده به فلزات سنگین، استفاده از گیاهانی که توانایی رشد، سازگاری و جذب فلزات را دارند، به عنوان یکی از روش های پاک سازی این خاک ها مطرح است. این روش را گیاه پالایشی<sup>۴</sup> می نامند. در این تحقیق، غلظت نیکل در خاک و شش گونه گیاهی شامل *Centaurea virgata lam.* (گل گندم بوته ای)، *Euphorbia cheiradenia* (فرفیون خوشه ای)، *Scariorbis orientalis* (گاو چاق کن)، *Cardaria droba* (ازمک)، *Gundelia tourmefotii* (کنگر خوراکی)، *Euphorbia macroclada* (فرفیون شاخه ضخیم) در اطراف معدن سرب و روی آهنگران، واقع در جنوب شرقی استان همدان اندازه گیری گردید. تجزیه آماری داده ها در قالب طرح بلوک های کامل تصادفی نامتعادل انجام گرفت. نتایج نشان داد که تفاوت غلظت نیکل در ریشه و اندام هوایی گونه های گیاهی در سطح احتمال پنج درصد معنی دار است. بیشترین و کم ترین مقدار جذب نیکل در اندام هوایی به ترتیب در *Euphorbia macroclada* و *Centaurea virgata lam.* با مقادیر ۲۳ و ۶/۷ میلی گرم بر کیلوگرم ماده خشک بود. غلظت نیکل در اندام هوایی گیاهان با  $pH$  ( $r^2 = -0/331$ )، ظرفیت تبادل کاتیونی ( $r^2 = -0/83$ ) و درصد ماده آلی ( $r^2 = -0/46$ ) خاک همبستگی معکوس و با شوری ( $r^2 = 0/37$ )، غلظت کل ( $r^2 = 0/2$ ) و قابلیت جذب نیکل ( $r^2 = 0/7$ ) در خاک همبستگی مستقیم نشان می دهد.

واژه های کلیدی: آلودگی خاک، گیاه، معدن، نیکل، گیاه پالایشی، فلزات سنگین.

۱- کارشناس ارشد- پژوهشگاه علوم و فناوری رنگ- گروه رنگ و محیط زیست

۲- استادیار- دانشگاه صنعتی اصفهان- دانشکده منابع طبیعی- گروه مهندسی محیط زیست

۳- استادیار- دانشگاه بوعلی همدان- دانشکده علوم- گروه زیست شناسی