ارزيابی كاربرد شبكه‌هاي عصبي مصنوعي در پيش‌بيني منوكسيد كربن در هواي شهر تبريز

ميرستار صدرموسوي[*1]، اكبر رحيمي[2]
[1] دانشيار گروه جغرافيا و برنامه ريزي شهري، دانشگاه تبريز، ايران
[2] دانشجوي دكتري جغرافيا و برنامه ريزي شهري، دانشگاه تبريز، ايران
(تاريخ دريافت: ٨٥/٨/٩، تاريخ تصويب: ٨٧/٤/٣١)

چكيده

يكي از تنگناهاى بزرگ دركلان شهرها، آلودگي‌هاي هوا مي‌باشد. پيش‌بيني آلودگي هوا يكي از موضوع‌ها مهم در ناحيه‌هاى شهري به شمار مي‌رود. روش‌هاي زيادي براي پيش‌بيني غلظت آلاينده‌هاي هوا وجود دارد. در سال‌هاي اخير پيشرفت قابل توجهي در گسترش مدل‌هاي شبكه عصبي براي پيش‌بيني آلودگي هوا صورت گرفته است. در اين پژوهش، ضمن بهره‌گيرى از شبكه‌هاي عصبي مصنوعي براي پيش‌بيني غلظت منوكسيد كربن دركلان شهر تبريز، ارتباط غلظت اين آلاينده با مشخصه‌هاي آب و هوايي به صورت ساعتي، براي ماه‌هاي آذر و دي سال ١٣٨٢، با شبكه پرسپترون چندلايه مدلسازي شده است. كارايي شبكه پرسپترون چندلايه با مدل خطي ARIMA مقايسه شد. نتيجه نمايانگر آن بود كه بين غلظت منوكسيد كربن و مشخصه‌هاي آب و هوايي، از جمله سرعت و جهت باد و رطوبت نسبي، رابطه به طوركامل غير خطي برقرار است. استقرار مراكز بزرگ صنعتي در غرب و جنوب غرب شهر تبريز مهم‌ترين منبع آلودگي هوا مي‌باشد. وزش باد از طرف غرب و جنوب غربي در ماه‌هاي مورد بررسى، باعث انتقال آلودگي به طرف شهر مي‌شود. بنابراين، اين عامل يكي از عامل‌هاى مهم آلودگي هوا در شهر تبريز مي‌باشد.

لغات كليدي: شبكه‌هاي عصبي مصنوعي، پرسپترون چندلايه، روش ARIMA، آلودگي هوا، غلظت منوكسيد كربن

* نويسنده مسئول: تلفن: ٣٣٩٢٢٧٤-٠٤١١ فاكس: ٣٣٦٠٣٩٦-٠٤١١ E-mail: ssadr@tabrizu.ac.ir

مقدمه

آلـودگي هـوا يکـي از تنگناهـای شـهرهاي بـزرگ امـروز مي‌باشد و بيشتر شهرهاي بزرگ جهان بويژه در کـشورهاي جهان سوم از آن رنج مي‌برند. در ايران نيز شهرهاي بزرگـي همچون تهران، تبريز، مشهد، اصـفهان و ... بـا ايـن مـشکل مواجه مي‌باشند. گـزارش‌هـا در بـاره آلـودگي‌هـاي هـوا در شهرهايي همچون تهـران، مـشهد و سـنندج آن اسـت کـه آلودگي‌هاي حاصل از تردد وسايل نقليه موتـوري بنزينـي و ديزلـي، بيـشترين سـهم را بـه خـود اختـصاص داده اسـت (منتصري و همکاران، ۱۳۷۵). اما بررسی‌هاي به عمل آمده در شهر تبريز نمايانگر آن است که سـهم صـنايع بـزرگ در ايجاد آلودگي هوا بسيار بيشتر و چندين برابـر وسـيله‌هـای نقليه موتوري بوده است. از آنجا کهايـن صـنايع بـزرگ بـه طورعمده درغرب و جنوب غرب تبريـز اسـتقرار يافتـه‌انـد، نقش عامل آب و هوايي در ميزان آلودگي خيلي موثر بـوده است (زاهدي و همکاران، ۱۳۷۸).

مکان‌يـابي نـا مناسـب مراکـز صـنعتي از جملـه نيروگـاه حرارتي، پالايشگاه و پتروشيمي‌تبريز در غرب تبريـز باعـث انتشار آلودگيها به سوي شهر تبريز از آن جهت شده اسـت. بويژه در فصل سرد سال، جريان‌هـاي هـوايي کـه بـه طـور غالب از طـرف غـرب و جنـوب غربـي مـي‌وزد باعـث نفـوذ گسترده آلودگي‌هاي ناشي از فعاليت مراکز صنعتي به طرف شهر مي‌شود.

عامل‌های آب و هوايي، عوارض‌نگاری ويژه تبريـز – کـه از طرف شمال با کوه‌هاي عون بن علي و از طرف جنوب با تپه ماهورهاي سهند احاطه شده است- و استقرار مراکز صنعتي در غرب از عامل‌های اصلي آلودگي‌هاي هوا در شـهر تبريـز است.

در بسياري از بررسـی‌هـای تـاثير عامـل آب و هـوايي بـر آلودگي‌هاي هوا مورد بحث قـرار گرفتـه اسـت و در آنهـا از روش‌هاي مختلفي بـراي پـيش‌بينـي ميـزان غلظـت مـواد آلاينده با استفاده از مشخصه‌هاي آب و هوايي، بهره گيـری شده است. مدل گوسين[۱] و مدل‌هاي عددي از عمومي‌ترين اين روش‌ها مي‌باشند. بدين صورت که مشخصه‌هـاي آب و هـوايي بـه عنـوان ورودي[۲] و غلظـت آلـودگي بـه عنـوان خروجـي[۳] در نظـر گرفتـه مـي‌شـود (Collet & Oluyemi, ۱۹۹۷). اما در اين مدل‌ها توزيـع غلظـت آلاينـده در يک جهت و در يک مبا زماني، بايد به شـکل توزيـع نرمـال باشد. به خـاطر ايـن محـدوديت، ايـن مـدل‌هـا در بررسـي آلودگي‌هاي هوا مورد توجه اساسي قرار نگرفتند و درمقابـل مدل‌هاي آماري بيشتر نظرها را به خود جلب کرد (Finzi & Tebaldi,۱۹۸۲ Ziomass et al., ۱۹۹۵). از دشواری‌های مدل‌هاي آماري نيز مي‌تـوان بـه نبـود توزيـع آماري متغيرها اشاره کرد (Comrie,۱۹۹۷). در سال‌هـاي اخير، شبکه‌هاي عصبي مصنوعي[٤] (ANN) براي پيش‌بيني غلظت آلاينده‌هاي هوا مورد بهره‌گيری قـرار مـي‌گيـرد کـه کارايي بيشتري نسبت به روش‌هاي پيـشين دارد. در سـال ۱۹۹۳ بزنار[۵] و همکاران ازANN براي پيش‌بينـي SO_2 در منطقـه‌هـای صـنعتي اسـلووني بهـره‌گيـری کردنـد. ايـن پژوهشگران از داده‌هاي دوره‌اي SO_2 و مشخصه‌هـاي آب و هوايي همچون سرعت و جهت باد به عنـوان ورودي شـبکه پرسپترون چندلايه[٦] (MLP) بهره‌گيری کردند. نتايجي که آنـان از شـبکه MLP بـه دسـت آوردنـد، نـشانگر برتـري ANN نسبت به روش‌هاي ديگر بوده است. در سال ۱۹۹۸ گاردنر[۷] و دورلينگ[۸] در يک مقاله مروري، کاربرد ANN را در علوم هوايي مورد تجزيه و تحليل قرار دادنـد، کـه در آن کاربرد ANN بـويژه شـبکه MLP در پـيش‌بينـي ميـزان غلظت آلودگي به طور روشن تشريح شـده اسـت. مـوک[۹] و تام[۱۰] نيز در سال ۱۹۹۸، آلودگي هوا در شهـرهـاي بـزرگ، نـمـونـه موردي، شهر ماکائو را با بهره‌گيری از شبکـه‌هـاي

۱- Gaussian

۲-Input

۳- Output

۴- Artificial Neural Network (ANN)

۵- Boznar. M

۶- Multilayer Perceptron (MLP)

۷- Gardner. M.W

۸- Dorling. S.R

۹- Mok. K.M

۱۰- Tam. S.C

عصبي مورد تجزيه و تحليل قرار دادند. در اين بررسي آنان با به كارگيري شبكه سه لايه، دوره‌هاي زماني آلودگي را در شهر ماكائو با بهره‌گيری از MLP مدلسازي كردند.

در سال ١٩٩٩ گاردنر و دورلينگ شبكه MLP را براي پيش‌بيني غلظت NO_x و NO_2 در شهر لندن به كار بردند و از الگوريتم لونبرگ ماركوآرت[١] (LM) براي يادگيري شبكه بهره‌گيری كردند. آنان نتايج به دست آمده ازANN را با نتايجي كه شي[٢] و هاريسون[٣] از مدل‌هاي خطي همچون رگرسيون چندگانه[٤] (MLR) به دست آورده بودند، مقايسه كردند و برتري ANN را نسبت به روش‌هاي خطي نشان دادند. پستولاچ[٥] و همكارانش در سال ٢٠٠١ با بهره‌گيری از شبكه‌هاي پرسپترون چندلايه و تابع شعاعي[٦] (RBF) به پيش‌بيني غلظت CO پرداختند و نتايج بدست آمده نشانگر توانايي شبكه‌هاي عصبي در پيش‌بيني اين غلظت بوده است. هوبېرگز[٧] و ديگران در سال ٢٠٠٥ در بلژيك ازMLP با يك لايه مخفي بهره‌گيری كردند. ميزان خطا با بهره‌گيری از الگوريتم پس انتشار خطا[٨] كاهش يافت و براي پرهيز از افراط در آموزش[٩]، از داده‌هاي تاييد[١٠] و تست[١١] بهره‌گيری كردند. در آن بررسی از داده‌هاي ده مركز اندازه‌گيري آلودگي هوا، در سال‌هاي ١٩٩٧-٢٠٠١ بهره‌گيری شد. براي ورودي شبكه از داده‌هاي آب و هواشناسي بهره‌گيری شد و نتايج به دست آمده با نتايج مدل‌هاي خطي مورد مقايسه قرار گرفت. نتايج به دست آمد نشان داد كه شبكه سه لايه پرسپترون، براي پيش‌بيني غلظت آلودگي‌هاي هوا مناسب مي‌باشد (Hooyberghs et al.,٢٠٠٥). در سال ٢٠٠٧، شيوا نگندرا[١٢] و همكارانش با بهره‌گيری از شبكه‌هاي عصبي به پيش‌بيني غلظت CO در دهلي پرداختند كه نتايج آنها نشانگر آن بوده است كه شبكه‌هاي عصبي در پيش‌بيني كوتاه مدت آلودگي هوا كارايي بالايي دارد.

مواد و روش

داده‌ها

شهر تبريز به‌عنوان بزرگترين متروپل شمال غرب ايران با گستره‌اي حدود ١٣١ كيلومتر مربع در ٢٣َ، ٤٦°، ١١َ، ٤٦° طول شرقي و ٩َ، ٣٨°، ١َ، ٣٨° عرض شمالي با ارتفاع ميانگين حدود ١٣٤٠ متر در جلگه‌اي به نام جلگه تبريز واقع شده است. ميانگين بيشينه دما و كمينه دماي ساليانه شهر تبريز در يك دوره ٥٠ ساله (١٩٥١-٢٠٠٠) برابر ١٢/٣ درجه سلسيوس و ميانگين بيشينه دما و كمينه دما به ترتيب ٢٦/٢٣ و ١٨- است. ميانگين ساليانه بارش طي دوره ٤٥ ساله (١٩٥١-١٩٩٦) در شهر تبريز معادل ٣٠٠ ميليمتر است. فصل بهار با ٤١% از كل ميزان بارش ساليانه بيشترين ميزان را به خود اختصاص داده است. بيشترين مقدار رطوبت نسبي ٧٠/١ درصد در ديماه (ژانويه) و كمترين ميزان آن ٢٣/٧ درصد در تيرماه (ژوئيه) و شهريورماه (سپتامبر) مي‌باشد. ميانگين رطوبت نسبي در دوره ١٩٥١-٢٠٠٠ در شهر تبريز معادل ٥٢/٣ درصد است. باد غالب تبريز شرق به غرب بوده ولي در فصل سرد سال باد غربي باد غالب بوده و عامل اصلي در انتقال آلودگيهاي هوا در فصل سرد، باد غربي- شرقي به شمار مي‌آيد (رحيمي، ١٣٨٥).

مشخصه‌هاي آب و هوايي براي اين بررسی، شامل سرعت باد، رطوبت نسبي، جهت باد، دما، بارندگي، فشار هوا، ميزان تشعشع و ميزان تبخير از اداره هواشناسي تبريز (ايستگاه هواشناسي تبريز) و داده‌هاي آلودگي‌هاي هوا، از اداره كل محيط زيست استان آذربايجان شرقي تهيه گرديده است. در اين بررسی داده‌هاي ماه‌هاي آذر و دي سال١٣٨٢ به

١- Levenberg- Marquart (LM)
٢- Shi. J.P
٣-Harison. R.M
٤-Multiple Linear Regression (MLR)
٥-Postolache. O
٦-Radial Basic Function (RBF)
٧-Hooyberghs. J
٨-Back Propagation
٩-Overtraining
١٠-Validation
١١-Test
١٢-Shiva Nagendra, S. M.

صورت ساعتي مورد بهره‌گيری قرار گرفته است. داده‌هاي آلودگي هوا از ميانگين چهار ايستگاه اندازه‌گيري موجود در تبريز، به دست آمده است. به علت آموزش بهينه شبکه، مشخصه هاي آب و هوايي در اين پژوهش پيش از اينکه وارد شبکه شوند در محدوده ۱- و ۱ و غلظت آلودگي در محدوده ۰/۹- و ۰/۹ با بهره گيری از فرمول زير عادی سازی شدند:

$$X_{norm} = \left(\frac{(X - X_{min})}{(X_{max} - X_{min})}\right) * (r_{max} - r_{min}) + r_{min}$$

که در اين فرمول X داده اصلي، X_{max} و X_{min} ميزان بيشينه و کمينه مقدار داده اصلي، r_{max} و r_{min} به ترتيب ۱ و ۱- براي مشخصه‌هاي آب و هوايي و ۰/۹ و ۰/۹- براي داده‌هاي آلودگي را شامل مي‌شود. داده‌هاي عادی سازی شده پس از مدلسازي، با بهره‌گيری از فرمول زير به داده اصلي برگردانده مي‌شوند:

$$X = \left(\frac{(X_{norm} - r_{min}) * (X_{max} - X_{min})}{r_{max}}\right) + X_{min}$$

در اين بررسی حاضر مشخصه‌هاي آب و هوايي و غلظت آلودگي در محيط excel با بهره‌گيری از فرمولي که در بالا بيان شد عادی سازی شد، از ۱۰۴۳ داده عادی سازی شده ۴۸۴ داده براي آموزش شبکه، ۳۱۷ داده براي تاييد شبکه و ۲۴۲ داده براي آزمون شبکه گزينش شد. براي مدلسازي از نرم‌افزارهاي Neuralpower 2.5 و MATLAB 7 بهره گيری شده است.

شبکه‌هاي عصبي مصنوعي

شبکه‌هاي عصبي مدل‌هاي غير خطي هستند، که به طور گسترده‌ای براي الگو شناسي[1]، شناسايي سامانه[2] و پيش‌بيني دوره‌های زماني[3] کاربرد دارند. اين شبکه‌ها مي‌توانند ابزارهاي انعطاف پذيري از رگرسيون‌هاي غير خطي باشند که به طور اساسي از يک تا چندلايه با نرونهاي متفاوت تشکيل شده‌اند. (Pastor- Barsenas, ۲۰۰۵).

روند متداول براي طراحي شبکه شامل مرحله‌های زير مي‌باشد:

۱- تهيه و آماده سازي بردارهاي ورودي و خروجي
۲- گزينش تابع انتقال[4]
۳- گزينش ساختمان و ترکيب شبکه
۴- گزينش وزن‌هاي تصادفي
۵- گزينش روند يادگيري
۶- تهيه مجموعه آزمون و پيش‌بيني يا مجموعه تاييد از داده‌ها (Cheleni,۲۰۰۲).

عمومي‌ترين شبکه‌اي که براي پيش‌بيني آلودگي‌هاي هوا کاربرد دارد، شبکه MLP مي‌باشد (Kolehmanin, ۲۰۰۱ Pastor- barsenas, ۲۰۰۵& Gadner, ۱۹۹۹). شبکه MLP به طور کامل توسط هايکين[5] در سال ۱۹۹۹ تشريح شده است (Haykin,۱۹۹۹). بنا براين در اين بررسی تنها يک طرح کلي از آن توضيح داده مي‌شود. شبکه MLP از سه لايه با نرون‌هاي متفاوت ترکيب شده است: لايه ورودي، لايه مخفي و لايه خروجي. شکل ۱ شبکه MLP با N نرون در لايه ورودي، S نرون در لايه مخفي و L نرون در لايه خروجي را نشان مي‌دهد.

خروجي شبکه MLP از راه فرمول زير به دست مي‌آيد:

$$y_k^o = f_k^o\left(n_k^o\right)$$

$$for \qquad k = 1,....,l$$

$$Out = f_k^o\left(b_k^o + \sum_i^s w_{ik}^o f_i^h\left(n_i^h\right)\right)$$

۱- Pattern recognition
۲- System identification
۳- Time series prediction
٤-Transfer function
۵- Haykin. S

$$n_k^o = b_i^o + \sum_{i=1}^{s} w_{ik}^o y_i^h$$

$$n_i^h = b_i^h + \sum_{j=1}^{n} w_{ji}^h x_j$$

در فرمول بالا h نشان دهنده عنصرهای لايـه مخفـي و o مربوط به لايه خروجي مي‌باشد، w_{ji}^h نشانگر وزني است کـه نرون j در لايه ورودي را با نـرونi در لايـه مخفـي ارتبـاط مي‌دهد، w_{ik}^o نشانگر وزني است که نرون i در لايه مخفي را با نرون k در لايه خروجي ارتباط مي‌دهد، f_i^h تـابع انتقـال نرون k در لايه خروجي را شامل مي‌شود، b_i^h باياس نـرون i در لايه مخفي است، b_k^o باياس نـرون k در لايـه خروجـي است، n_i^h ميزان تحريک نرون i در لايه مخفـي اسـت، n_k^o ميـزان تحريـک نـرون k در لايـه خروجـي مـي‌باشـد، y_i^h خروجي نرون i را در لايه مخفي و x_j خروجـي نـرون j در لايه خروجي نشان مي‌دهد.

در بيشتر وقت‌هـا سـيگمويد[1] و تانژانـت‌هـايپر بوليـک[2] از جمله تابع‌های انتقال مي‌باشند، که بيشتر مورد بهره‌گيـری قرار مي‌گيرند و محدوه اولي بين ۰ و ۱ و دومي‌بين ۱- و ۱ مـي‌باشـد. کـه رابطـه آنهـا درزيـر آورده شـده اسـت (Agirre- basurko,۲۰۰۶).

$$\tan sig(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

$$\log sig(x) = \frac{1}{1 + e^{-x}}$$

E در فرمول زير ميزان تابع خطا را نـشان مـي‌دهـد، کـه هدف کمينه کردن ميزان خطا مي‌باشد.

$$E = \frac{1}{L} \sum_{k=1}^{L} \left(t_k - y_k^o\right)^2$$

t_k ميزان بهينه نرون k و y_k^o خروجـي نـرون k در لايـه خروجي مي‌باشد.

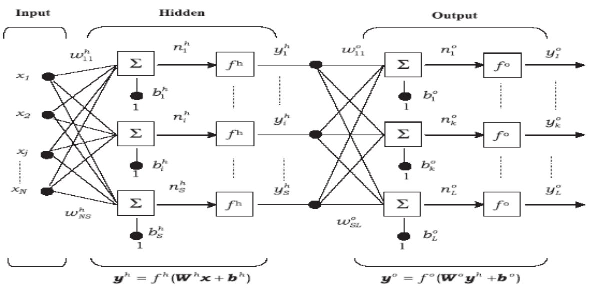

شکل ۱- ساختمان شبکه **MLP**

نتايج

توپولوژي ANN با شمار لايه‌ها، شـمار نـرون‌هـا در هـر لايه، الگـوريتم يـادگيري و تـابع انتقـال در شـبکه تعيـين مـي‌گـردد. بهينـه سازي توپولـوژي ANN گـام مهمـي‌در مدلـسازي شـبکه بـه شـمار مـي‌آيـد. در ايـن بررسـی از الگوريتم‌هاي مختلفي براي آموزش شبکه بهره‌گيری شد که در نهايت الگـوريتم Quick prop، بـراي يـادگيري شـبکه پاسخ بهتري داده است. با اين الگوريتم وزن‌هـا و لايـه‌هـاي مخفي مختلفي با نرون‌هاي متفاوت بهره‌گيری شد، و جواب بهينه شبکه با يک لايه مخفي – يعني MLP سه لايه - به دست آمـد کـه شـمار نـرون‌هـا در لايـه مخفـي ۲۵ نـرون مي‌باشد (شکل۲). يـک روش مناسـب بـراي گـزينش دور[3] آموزش - هنگامي‌که شبکه آمـوزش داده مـي‌شـود - بهـره گيری از داده‌هاي تاييد، براي محاسبه ميزان خطا مي‌باشد. کمينه خطاي تاييد، روش و شاخص مناسبي بـراي تعيـين شمار دور آموزش در شبکه مي‌باشد. هنگام يادگيري شبکه، وقتي ميزان دور از ۲۲۰۰ بيشتر گزينش مـي‌شـد، خطـاي تاييد، بيشتر مـي‌شـد و زيـاده‌روی در آمـوزش رخ مـی‌داد. بنابراين دور مناسـب بـراي شـبکه ۲۲۰۰ گـزينش شـد تـا ميزان خطا کاهش يابد.

۱- Sigmoid (Logsig)

۲- Hyperbolic tangent (Tansig)

۳- Epoch

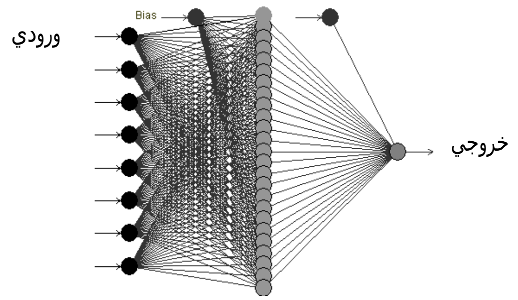

شکل ۲- شبکه بهينه شده با لايه‌هاي ورودي، مخفي و خروجي و شمار نرون‌هاي موجود در هرلايه

با کاهش ميـزان نـرخ يـادگيري[1] و افـزايش ميـزان ثابـت مومنتوم[2] تا سقفي معين، تا حدودي مي‌توان ميزان خطا را در شبکه کاهش داد. به همين خاطر نرخ يـادگيري و ثابـت مومنتوم در اين بررسی، به ترتيـب ۰/۶۵ و ۰/۹۵ گـزينش شدند، که در ميزان يادگيري تاثير مناسبي داشتند.

در شبکه‌هاي عصبي براي لايه مخفي و لايه خروجي تـابع انتقال به کار گرفته مي‌شود که در اين بررسی تـابع انتقـال تانژانت‌هايپربوليک با شيب يک براي شبکه بهينـه، هـم در لايه مخفي و هم در لايه خروجي، گزينش شد که محـدوده آن بـين ۱- و ۱ اسـت. يکـي از شـاخص‌هـاي مهـم در شبکه‌هاي عصبي، محاسـبه جـذر ميـانگين مجـذور خطـا[3] مي‌باشد که با بهره‌گيری از فرمول زير محاسبه مي‌شود:

$$RMSE=\left(\frac{1}{N}\sum_{i-1}^{N}(p_i-O_i)^2\right)^{1/2}$$

کـه N شـمار داده‌هـا، O_i داده‌هـاي اصـلي و p_i مقـادير پيش‌بيني را نشان مي‌دهد. RMSE در داده‌هـاي آمـوزش، آزمون و همانندسازي به ترتيب ۱/۶، ۱/۸ و ۲/۱ بـه دسـت آمد.

۱- Learning rate

۲- Momentum

۳- Root mean square error (RMSE)

ضريب همبستگي[4] (R^2) براي داده‌هاي آموزشي، تاييـد و تست به ترتيب ۰/۸۸، ۰/۸۲ و ۰/۷۸ به دست آمد، کـه بـا بهره‌گيری از فرمول زير محاسبه شده است:

$$R^2=\frac{\sum_{i-1}^{n}\left[p_i-\overline{O}\right]^2}{\sum_{i-1}^{n}\left[O_i-\overline{O}\right]^2}$$

در فرمول بالا $\overline{O}$ ميانگين داده‌هاي اصلي را نشان‌مي‌دهد.

شکل‌هاي شماره ۳ تا ۸، همبستگي بين داده‌هاي اصلي و داده‌هاي پيش‌بيني را در شبکه بهينه شده بـا ۲۵ نـرون در لايه مخفي براي غلظت CO نشان مي‌دهد. نتـايج نمايـانگر آن است که مدل‌هايANN در باز توليد داده‌هـاي CO بـر پايه داده‌هاي اصلي نتايج بهتري در بردارد.

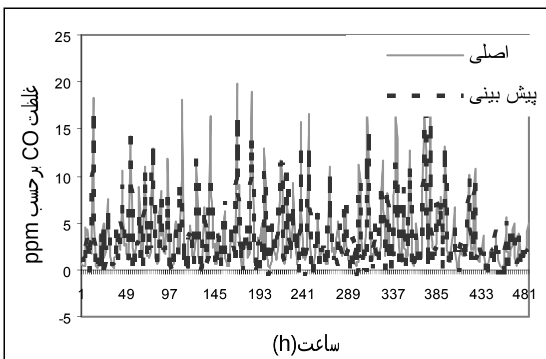

شکل ۳- ارتباط بين داده‌هاي اصلي و پيش‌بيني، براي داده‌هاي آموزش شبکه

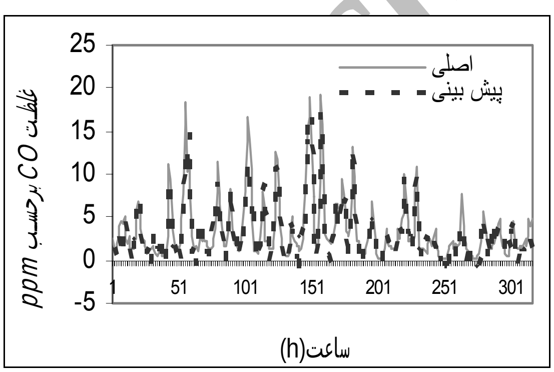

شکل ۴- ارتباط بين داده‌هاي اصلي و پيش‌بيني، براي داده‌هاي تاييد شبکه

۴- Correlation coefficient (R^2)

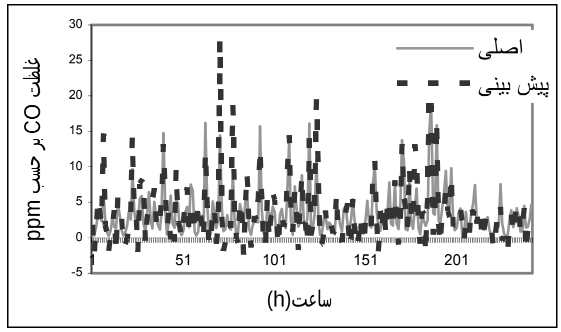

شکل ۵- ارتباط بین داده‌هاي اصلي و پیش‌بیني، براي داده‌هاي تست شبکه

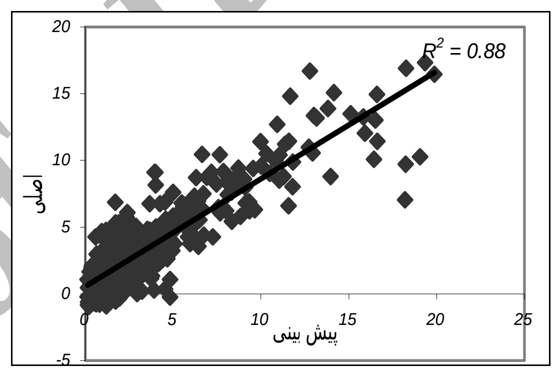

شکل ۶- مقایسه بین مقادیر مشاهده شده و محاسبه شده براي غلظت**CO** در داده‌هاي آموزش

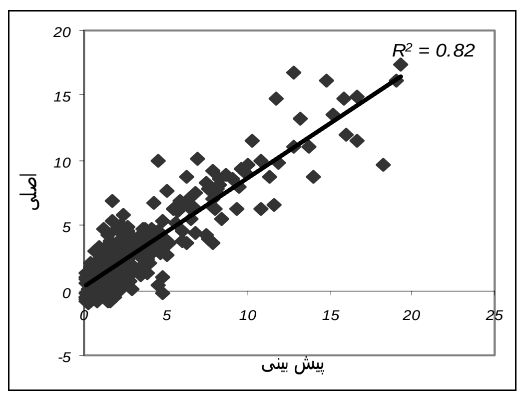

شکل ۷- مقایسه بین مقادیر مشاهده شده و محاسبه شده براي غلظت**CO** در داده‌هاي تایید.

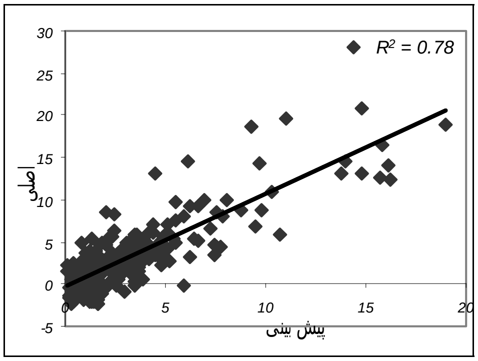

شکل ۸- مقایسه بین مقادیر مشاهده شده و محاسبه شده براي غلظت**CO** در داده‌هاي تست

براي مقایسه نتایج به دست آمده از ANN بـا روش‌هـاي خطي، روش ARIMA،[1] مورد بهره‌گیری قرار گرفـت. R^2 و RMSE در مدل ARIMA، بـه ترتیـب ۰/۱۰ و ۲۰/۴ بـه دست آمد که در شـکل‌هـاي ۹ و ۱۰ همبـستگي بـین داده‌هاي اصلي و میزان پیش‌بیني نشان داده شده است.

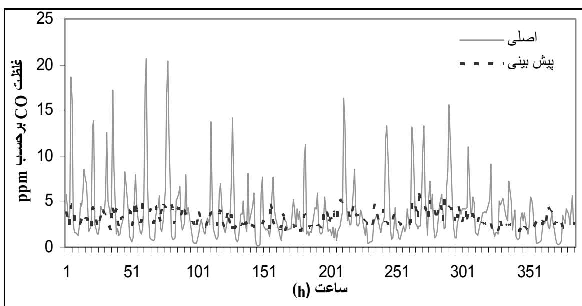

شکل ۹- ارتباط بین داده‌هاي اصلي و پیش‌بیني در مدل **ARIMA**

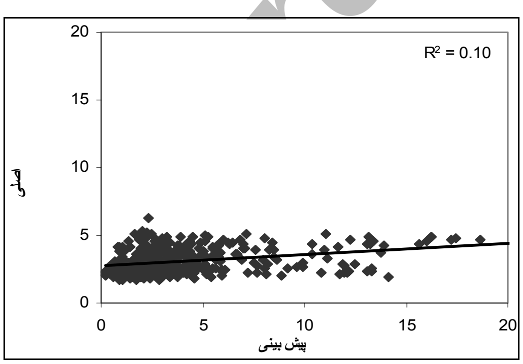

شکل ۱۰- مقایسه بین مقادیر مشاهده شده و محاسبه شده براي غلظت**CO** در مدل **ARIMA**.

۱- Auto-regressive integrated moving average (ARIMA)

همان‌طور که پیداست بین عامـل آب و هـوايي و میـزان غلظت CO رابطه به شدت غیر خطي برقرار است. بنـابراین ANN، در مقایسه بـا روش‌هـاي خطـي، کـارایي و نتیجـه بهتري در پیش‌بیني غلظت CO دارد.

نتیجه‌اي که از تاثیر مشخصه‌هاي آب و هوايي بـر غلظـت CO در شهرتبریز بـه دسـت آمـد، نمایـانگر آن اسـت کـه سرعت باد، رطوبت نسبي و جهت باد بـه ترتیـب بیـشترین تاثیر را در آن داشته‌اند و عامل‌هـای دیگـر در ردیـف‌هـاي بعدي قرار دارند. در جدول ۱ درصد تاثیرگذاري هر یـک از عامل‌ها نشان داده شده است که با بهره‌گیری از رابطه زیـر محاسبه شده است:

$$I_j = \frac{\sum_{m=1}^{N^h}\left(\frac{\left|W_{jm}^{ih}\right|}{\sum_{k=1}^{m=N^h}\left|W_{km}^{jh}\right|}*\left|W_{mn}^{ho}\right|\right)}{\sum_{k=1}^{k=N^i}\left\{\sum_{m=1}^{m=n^h}\left(\frac{\left|W_{jm}^{ih}\right|}{\sum_{k=1}^{m=N^h}\left|W_{km}^{jh}\right|}\right)*\left|W_{mn}^{ho}\right|\right\}}$$

N^h شمار نرون‌ها در لایه مخفي را نمایش مي‌دهـد، N^i نشانگر شمار وزن‌ها در هر یک از نـرون‌هـا در لایـه مخفـي اسـت، ih شـماره لایـه در لایـه مخفـي مـي‌باشـد، و W_{mn} نشانگر وزن نرون Nام در لایه خروجي اسـت (Olden & Jackson,۲۰۰۲Garson, ۱۹۹۱and).

در این ماه‌ها، به خاطر اینکه میزان بارش کمتر بوده است، این مشخصه تاثیر زیادي در غلظت CO نداشته و در ردیف پنجم از عامل‌های هشتگانه مشخصه‌هاي آب و هوايي -کـه دراین بررسی به کار گرفته شده است- قرار گرفته است.

جدول ۱- درصد تاثیر پارامترهاي آب وهوايي در غلظت **CO**

پارامترها	درجه حرارت	جهت باد	رطوبت نسبي	سرعت باد	جمع
درصد تاثیر	۱۲/۷	۱٤/۱	۱۵/۵	۱۹/٤	
پارامترها	مقدار تبخیر	مقدار تشعشع	فشار هوا	بارندگي	
درصد تاثیر	۷/۵	۹/۲	۱۰	۱۱/٦	۱۰۰

بحث

نتایج بررسی نشان مي‌دهد که شبکه‌هـاي عـصبيMLP، مي‌تواند بین مشخصه‌هاي آب و هوايي و داده‌هـاي غلظـت CO در محـیط‌هـاي شـهري ارتبـاط برقـرار کنـد. کـارایي ANN نسبت به روش‌هـاي خطـي از جملـه ARIMA بـا مقایسه نتایج آنها، که در بالا بیان شد، مـشخص مـي‌شـود. نتیجـه مقایـسه‌ایـن دو مـدل، نـشانگر آن اسـت کـه بـین مشخصه‌هاي آب و هوايي و غلظت CO ارتباط به طورکامل غیر خطي برقرار اسـت. بنـابراین شـبکه MLP نـسبت بـه روش ARIMA نتیجه بهتري در بردارد. گزینش شماري از داده‌ها براي آزمون کردن شـبکه، از زیـاده‌روی در آمـوزش جلوگیري مي‌کنـد و میـزان خطـا بـین داده‌هـاي اصـلي و پیش‌بیني را کاهش مي‌دهد. ANN براي پیش‌بینـي کوتـاه مدت غلظت آلودگي‌هاي هوا از جمله CO نتـایج بهتـري را مي‌دهد. به خاطر اینکه تغییرهای غلظت آلودگي‌ها در کوتاه مدت، بیشتر تحت تاثیر عامـل‌هـای آب و هـوايي از جملـه سرعت و جهت باد، رطوبت نسبي، دما و .... قرار مـي‌گیـرد. در تبریز، به علت اینکه صنایع بزرگ آلـوده سـاز، در غـرب وجنوب غرب آن مستقر شده است، و با توجـه بـه‌اینکـه در ماه‌هاي مورد بررسی، بادهاي غربي و جنوب غربـي، میـزان قابل توجهي از وزش را به خود اختصاص مـي‌دهنـد، نقـش عامل‌های آب و هوايي بویژه سرعت و جهت باد در آلـودگي هوا انکارناپذیر مي‌باشد. در نتیجه ANN با برقراري ارتبـاط بین پارامترهاي آب و هوايي و غلظت‌هاي آلودگي‌هاي هـوا، توانایي پیش‌بیني میزان آلودگي‌هاي هوا را دارا مي‌باشد.

منابع

۱- رحيمي، اكبر، ١٣٨٥. تحليل آلودگي‌هاي هوايي ناشي از مكان‌يابي نامناسب مراكز صنعتي در شهر تبريز با استفاده از شبكه‌هاي عصبي مصنوعي، پايان نامه كارشناسي ارشد، دانشگاه تبريز.

۲- زاهدي، مجيد، حسن ذولفقاري و سيما ترابي، ١٣٧٨. بررسي تاثيرات عوامل اقليمي‌در تشكيل هسته هواي آلوده شمال غرب تبريز، دومين كنفرانس منطقه‌اي تغيير اقليم. سازمان هواشناسي كشور. ١٣ و ١٤ آبانماه ١٣٧٨.

۳- منتصري، رقيه، جواد فكورمعنوي و حميده صالحي، ١٣٧٥. تحقيق و بررسي وضعيت آلودگي هوا، مشهد، مركز تحقيقات زيست محيطي خراسان.

4- Agirre-Basurko, E., G. Ibarra-Berastegi, & I. Madariaga, 2006. Regression and multilayer perceptron-based models to forecast hourly O_3 and NO_2 levels in the Bilbao area. Environmental Modelling & Software, 21: 430–446.

5- Boznar, M., M. Lesjak & P. Mlakar, 1993. A neural network-based method for short-term predictions of ambient SO_2 concentrations in highly polluted industrial areas of complex terrain. Atmospheric Environment, 27B (2): 221–230.

6- Chelani, Asha.B., C.V. Chalapati Rao, K.M. Phadke & M.Z. Hasan, 2002. Prediction of sulphur dioxide concentration using artificial neural networks. Environmental Modelling & Software, 17: 161–168.

7- Collet, R.S. & K. Oluyemi, 1997. Air quality modeling: a technical review of athematical approaches. Meteorological Applications, 4: 235–246.

8- Comrie, A.C., 1997. Comparing neural network and regression models for ozone forecasting. Journal of Air and Waste Management Association, 47: 653–663.

9- Finzi, G. & G. Tebaldi, 1982. A mathematical model for air pollution forecast and alarm in an urban area. Atmospheric Environment, 16 (9): 2055–2059.

10- Gardner, M.W. & S.R. Dorling, 1998. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. Atmospheric Environment, 32 (14/15): 2627–2636.

11- Gardner, M.W. & S.R. Dorling, 1999. Neural network modeling and prediction of hourly NO_x and NO_2 concentrations in urban air in London. Atmospheric Environment, 33: 709–719.

12- Haykin, S., 1999. Neural Networks: A comprehensive Foundation. Prentice Hall, New Jersey.

13- Garson, G.D. 1991. Interpreting neural network connection weights, Artif. Intell. Export 6, 47-51.

14- Hooyberghs, J., C. Mensink, G. Dumont, F. Fierens & O. Brasseur, 2005. A neural network forecast for daily average PM_{10} concentrations in Belgium. Atmospheric Environment, 39: 3279–3289

15- Kolehmainen, M., H. Martikainen & J. Ruuskanen, 2001. Neural networks and periodic components used in air quality forecasting. Atmospheric Environment, 35: 815–825.

16- Mok, K.M. & S.C. Tam, 1998. Short-term prediction of $S0_2$ concentration in Macau with artificial neural networks. Energy and Buildings, 28: 279-286.

17- Olden, J.D., & D.A. Jackson, 2002. Illuminating the black box: a randomization approach for understanding variable contributions in artificial neural networks, Ecol. Modell. 154, 135-150.

18- Pastor-Barcenas, B., E. Soria-Olivas & J.D. Martın-Guerrero, 2005. Unbiased sensitivity analysis and pruning techniques in neural networks for surface ozone modeling. Ecological Modelling, 182: 149–158.

19- Postolache, O. & P. Girao, M. Pereira, 2001. Neural network application in a carbon monoxide measurement system. International Joint Conference on neural network,Volume 3, Issue , 2001 Page(s):2076 – 2081.

20- Shi, J.P. & R.M. Harrison, 1997. Regression modelling of hourly NOx and NO2 concentrations in urban air in London. Atmospheric Environment 31 (24), 4081-4094.

21- Shiva Nagendra, S. M. & M. Khare, 2007. Artificial neural network based carbon monoxide persistence models for episodic urban air quality management. Environmental Monitoring and Assessment, Published online: 7 July 2007.

22- Ziomass, I.C., M. Dimitrios, S.Z. Christos & F.B. Alkiviadis, 1995. Forecasting peak pollutant levels from meteorological variables. Atmospheric Environment, 29 (24): 3703–3711.

The application of artificial neural networks in prediction of CO concentration: A case study of Tabriz

M. S. Sadr Mousavi [*1]**, A. Rahimi**[2]
[1] Associate prof, Tabriz University, I. R. Iran
[2] Ph. D. Student in Geography and Urban Planning, Tabriz University, I. R. Iran
(Received: 30 October2006, Accepted: 21 July 2008)

Abstract

Air pollution is one of the main problems in metropolitan areas. Therefore, the prediction of air pollution can be regarded as one of the important issues of air quality research in urban areas. There are many methods for the prediction of air pollutant concentration. In recent years, there has been considerable progress in the development of neural network models for air quality prediction. In this paper, artificial neural network has been used for the prediction of CO concentration in Tabriz. Hourly correlation between the concentration of CO and metrological variables was calculated by multilayer perceptron for the months of December and January 2003. Multilayer perceptron performance was compared with traditional methods such as auto-regressive integrated moving average (ARIMA). The results indicated that there was a high non-linear correlation between CO concentration and metrological variables such as: speed and direction of wind; and relative humidity. The location of large industries in the west and southwest of Tabriz were found to be the most effective elements in air pollution. Blowing of winds from west and southwest directions, on the months of December and January have caused pollution are transferred to the inner parts of Tabriz.

Keywords: Artificial Neural Networks, Multilayer perceptron, ARIMA, Air pollution, CO concentration.

* Corresponding author: Tel: +98 411 3392299 , Fax: +98 411 3356013 E-mail: ssadr@tabrizu.ac.ir