

مقایسه نتایج شبکه‌های عصبی پرسپترون چند لایه با رگرسیون چندگانه در پیش‌بینی غلظت ازن در شهر تبریز

دکتر میرستار صدرموسوی* - دانشیار گروه جغرافیا و برنامه ریزی شهری، دانشگاه تبریز

اکبر رحیمی - دانشجوی دکتری جغرافیا و برنامه ریزی شهری

پذیرش مقاله: ۱۳۸۷/۱۰/۲۵ تأیید نهایی: ۱۳۸۸/۱۲/۱۰

چکیده

تبریز بعنوان یکی از پنج شهر بزرگ صنعتی و دومین شهر آلوده کشور به حساب می‌آید. مکانیابی مراکز صنعتی در غرب و جنوب غربی تبریز و وزش باد غالب در فصل‌های سرد از آن جهات، باعث آلودگی هوای شهر تبریز می‌شود. براساس اطلاعات اداره کل حفاظت محیط زیست استان آذربایجان شرقی در سال ۸۴، ۶۰ درصد آلودگی هوای تبریز مربوط به صنایع سنگینی است که در جنوب غربی و غرب آن مکانیابی شده‌اند. در این مقاله یک مدل بر مبنای رگرسیون چندگانه (روش خطی) و یک مدل دیگر بر اساس شبکه عصبی (روش غیرخطی) به منظور پیش‌بینی کوتاه مدت غلظت ازن برحسب شرایط آب و هوایی برای شهر تبریز ارائه شده و در ادامه به مقایسه نتایج به دست آمده از مدل خطی و غیر خطی پرداخته شده است. داده‌های هواشناسی این تحقیق شامل سرعت باد، رطوبت نسبی، جهت باد، درجه حرارت، بارندگی، فشار هوا، مقدار تابش و مقدار تبخیر از اداره هواشناسی تبریز (ایستگاه هواشناسی تبریز) و داده‌های آلودگی هوا (غلظت ازن) از اداره کل محیط زیست استان آذربایجان شرقی تهیه گردیده است. در این تحقیق داده‌های ماههای آذر و دی سال ۱۳۸۵ به صورت ساعتی مورد استفاده قرار گرفته است. داده‌های آلودگی هوا از میانگین چهار ایستگاه اندازه گیری موجود در تبریز، به دست آمده است. برای آموزش بهینه شبکه، پارامترهای هواشناسی در این پژوهش قبل از اینکه وارد شبکه شوند در محدوده + و ۱ و غلظت آلودگی در محدوده ۰/۹- و ۰/۹+ نرمالیزه شدند و از ۱۲۵۳ داده نرمالیزه شده ۶۵۰ داده برای آموزش شبکه، ۴۰۴ داده برای تأیید شبکه و ۱۹۹ داده برای تست شبکه انتخاب گردید. نتایج به دست آمده نشان می‌دهند که مدل شبکه‌های عصبی توانایی بیشتری نسبت به روشهای خطی (رگرسیون چندگانه) داشته است. بطوریکه ضریب همبستگی در مدل رگرسیون چندگانه ۰/۴۵ در حالی که ضریب همبستگی در شبکه‌های عصبی ۰/۹۱ بوده است.

کلیدواژه‌ها: پیش‌بینی آلودگی‌های هوایی، رگرسیون چندگانه، شبکه عصبی مصنوعی، پرسپترون چندلایه، ازن.

مقدمه

امروزه پیش‌بینی آلودگی‌های هوایی در نواحی شهری به دلیل تاثیر آن بر روی سلامتی انسان، یکی از موضوعات مهم در تحقیقات زیست محیطی می‌باشد. غلظت‌های با آلودگی بالا، تاثیرات سوء و مرگ زودرس گروه‌های حساس و آسیب پذیر جامعه از جمله افراد مسن و کسانی که به تنگی نفس دچار هستند را به دنبال دارد (Tiittanen et al., 1999). تحقیقات زیادی با استفاده از روشها و متدهای مختلف برای پیش‌بینی آلودگی این غلظت صورت گرفته است. یکی از دیدگاهها برای پیش‌بینی انتشار این غلظت‌ها استفاده از مدل انتشار اتمسفری می‌باشد. برای این منظور نیاز به معادلات فیزیکی و شیمیایی توصیف کننده تغییرات غلظت آلاینده‌ها، داده‌های انتشار جزئی تر و همچنین پارامترهای هواشناسی است. کولت و اودیومی (۱۹۹۷) در یک مقاله مروری به بررسی این مدلها پرداخته‌اند. دومین دیدگاه ارائه یک مدل آماری می‌باشد که هدفش مشخص کردن ارتباط بین داده‌های ورودی و خروجی می‌باشد. مدل رگرسیون یکی از

* E-mail: ssadr@tabrizu.ac.ir

این مدل‌های آماری می‌باشد که برای مدل‌سازی و پیش‌بینی غلظت‌های مختلف به کار برده می‌شود (Shi and Harrison, 1997, 4082; Ziomas, 1995, 3705). یکی از محدودیت‌های مهم برای این نوع مدل‌ها، یادگیری کم آنها در سیستم‌های غیرخطی می‌باشد (Gardner and Dorling, 1998, 2630). در حالیکه شبکه‌های عصبی مصنوعی^۱ (ANN) یکی از روش‌های مناسب برای مدل‌سازی سیستم‌های غیرخطی می‌باشد که در پژوهش‌های اولیه استفاده از این روش در پیش‌بینی غلظت دی اکسید سولفور در اسلوونی نتایج بهتر و مناسبتری به دست آمد (Agirre-Basurko et al., 2006, 441). در پیش‌بینی آلودگی هوا، انتخاب متغیرهای ورودی تاثیرگذار، یکی از مراحل مهم مدل‌سازی می‌باشد. به این دلیل که اندازه گیریها، از منابع آلاینده مختلف انجام شده و ارتباط این منابع آلوده کننده اغلب پیچیده و غیر خطی است (Jiang et al., 2004, 7059). کاربرد شبکه‌های عصبی در مدل‌سازی غلظت‌ها معمولاً نتایج بهتری را نسبت به روش‌های خطی در بردارد (رحیمی، ۱۳۸۵، ۱۶۸: 2629; Gardner and Dorling, 1998).

هویرگز و دیگران (۲۰۰۵)، غلظت PM_{10} را با استفاده از شبکه‌های عصبی در بلژیک پیش‌بینی کردند که پرسپترون چندلایه، با یک لایه مخفی و چهار نرون در آن مورد استفاده قرار گرفت. ریشه مجذور جذر خطا^۲ (RMSE) با استفاده از الگوریتم پس انتشار^۳ به حداقل رسید. برای جلوگیری از یادگیری بیش از حد، داده‌های تایید را به کار گرفتند. هدف اصلی از این تحقیق توسعه مدلی است که بتواند بین غلظت O_3 و پارامترهای هواشناسی (رطوبت نسبی، جهت باد، مقدار تشعشع، فشار هوا، فشار سطح ایستگاه، میزان بارش، سرعت باد و درجه حرارت) ارتباط برقرار کند. در این تحقیق از شبکه‌های عصبی پرسپترون چند لایه و رگرسیون چندگانه برای پیش‌بینی ساعتی غلظت O_3 با استفاده از داده‌های هواشناسی استفاده شده است.

مواد و روش‌ها

الف - رگرسیون چندگانه^۴ (MLR)

رگرسیون چندگانه روشی است که برای ارتباط خطی بین یک متغیر وابسته و یک یا چند متغیر مستقل مورد استفاده قرار می‌گیرد. شکل عمومی آن به شرح زیر می‌باشد:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip} + \epsilon_i$$

که برای یک سری از i مشاهده شده، Y متغیر پیش‌بینی شده است، β_0 یک ضریب می‌باشد، که در آن $1, 2, \dots, p$ ضرایب X_{i1}, \dots, X_{ip} متغیرهای مستقل را شامل می‌شوند و ϵ_i خطای بین متغیر اصلی و پیش‌بینی شده را نمایان می‌سازد. مدل MLR با این فرض در مدل استفاده می‌شود که شرایط زیر برقرار باشد:

- متغیرهای پیش‌بینی کننده باید مستقل باشد.
- مقدار خطای باقیمانده باید مستقل باشد. علاوه بر این دارای توزیع نرمال با میانگین صفر و واریانس ثابت α^2 باشد.

بردار مشاهدات $\{X_{i1}, X_{i2}, \dots, X_{ip}, Y_i\} i = 1, 2, \dots, n$ در تخمین پارامتر β مورد استفاده قرار می‌گیرد و سری درجه بندی را تشکیل می‌دهد. از روش حداقل مربعات، معمولاً برای تخمین پارامترهای مدل استفاده می‌شود. بنابراین معادله زیر برای مقدار پیش‌بینی به دست می‌آید:

$$\hat{Y}_i = b_0 + b_1 X_{i1} + b_2 X_{i2} + \dots + b_p X_{ip}$$

هدف از تحلیل رگرسیون مشخص کردن پارامترهای معادله رگرسیون و مقایسه کمی میزان جفت و جور شدن مدل با مقدار متغیر مستقل Y می‌باشد (Kuzmanovski and Aleksovska, 2003, 171).

1- Artificial Neural Network (ANN)

2- Root mean square error (RMSE)

3- Back-propagation

4- Multiple Linear Regression (MLR)

ب - شبکه‌های عصبی مصنوعی (ANN)


امروزه کاربردهای بسیاری برای شبکه‌های عصبی وجود آمده است و با توجه به نوع کاربرد ساختار و قوانین یادگیری در شبکه می‌تواند متفاوت باشد. بطور خلاصه مهمترین شبکه‌های عصبی را می‌توان بصورت زیر تقسیم‌بندی نمود:

پرسپترون چند لایه (MLP)، شبکه خود سازمانده (SOM)، LVQ، هاپفیلد، تاخیر زمانی (TDNN) و RBF.

از بین شبکه‌های عصبی مذکور شبکه پرسپترون چندلایه (MLP) بیشترین کاربرد را در پیش‌بینی آلودگی‌های هوایی دارد که در این تحقیق نیز از این شبکه استفاده شده است.

شبکه MLP از چند لایه تشکیل شده است، لایه ورودی، خروجی و لایه یا لایه‌های مخفی که خروجی لایه اول، بردار ورودی لایه دوم به حساب می‌آید. به همین ترتیب خروجی لایه دوم، بردار ورودی لایه سوم را تشکیل می‌دهد. خروجی‌های لایه دوم پاسخ واقعی شبکه را نشان می‌دهند (Chelani et al., 2002, 163).

نرونهای موجود در لایه بالادست به نرونهای موجود در لایه پائین دست ارتباط دارند. نقش هر نرون محاسبه مجموع وزن داده شده پترون ورودی (Net) و سپس گذراندن این مجموع از یک تابع به نام تابع انتقال^۱ می‌باشد. تابع انتقال می‌تواند یک تابع خطی یا غیر خطی باشد. دو نوع از توابع مرسوم در شبکه پرسپترون چند لایه تابع سیگموئید^۲ و تانژانت سیگموئید^۳ می‌باشد که در شکل‌های (۱) و (۲) این توابع نشان داده شده‌اند (Vakil-Baghmisheh, 2002, 121).



شکل ۲- تابع سیگموئید

(Vakil-Baghmisheh, 2002, 121)

شکل ۱- تابع تانژانت هایپربولیک

(Vakil-Baghmisheh, 2002, 121)

نحوه عمل پرسپترون چند لایه بدین صورت است که الگویی به شبکه عرضه می‌شود و خروجی آن محاسبه می‌گردد. مقایسه خروجی واقعی و خروجی مطلوب، باعث می‌شود که ضریب وزنی شبکه تغییر یابد به طوریکه در دفعات بعد خروجی درست‌تری حاصل می‌شود. قاعده فراگیری میزان کردن، ضرایب وزنی شبکه را بیان می‌کند. (رحیمی، ۱۳۸۵، ۱۲۴).

ج- داده‌ها

پارامترهای هواشناسی برای این تحقیق، شامل سرعت باد، رطوبت نسبی، جهت باد، درجه حرارت، بارندگی، فشار هوا، مقدار تشعشع و مقدار تبخیر از اداره هواشناسی تبریز (ایستگاه هواشناسی تبریز) و داده‌های آلودگی هوا (غلظت ازن) از اداره کل محیط زیست استان آذربایجان شرقی تهیه گردیده است. در این تحقیق داده‌های ماههای آذر و دی سال ۱۳۸۵ به صورت ساعتی مورد استفاده قرار گرفته است. داده‌های آلودگی هوا از میانگین چهار ایستگاه اندازه گیری موجود در تبریز، به دست آمده است. بدلیل آموزش بهینه شبکه، پارامترهای هواشناسی در این پژوهش قبل از اینکه وارد شبکه شوند در محدوده ۰ و ۱ و غلظت آلودگی در محدوده ۰/۹- و ۰/۹+ با استفاده از فرمول زیر نرمالیزه شدند (Gardner, Dorling, 1998, pp.709-719):

1- Transfer function

2- Sigmoid (Logsig)

3- Hyperbolic tangent (Tansig)

$$X_{\text{norm}} = \left(\frac{X - X_{\min}}{X_{\max} - X_{\min}} \right) * (r_{\max} - r_{\min}) + r_{\min} \quad (1)$$

که در این فرمول X داده اصلی، X_{\min} و X_{\max} میزان حداکثر و حداقل مقدار داده اصلی، r_{\max} و r_{\min} به ترتیب ۱ و ۰ برای پارامترهای هواشناسی و ۰/۹ و -۰/۹ برای غلظت ازن را شامل می‌شود. داده‌های نرمالیزه شده بعد از مدلسازی، با استفاده از فرمول زیر به داده اصلی برگردانده می‌شوند ((Gardner, Dorling, 1998, pp.709-719):

$$X = \left(\frac{X_{\text{norm}} - r_{\min}}{r_{\max}} \right) * (X_{\max} - X_{\min}) + X_{\min} \quad (2)$$

در تحقیق حاضر پارامترهای هواشناسی و غلظت آلودگی در محیط excel با استفاده از فرمولی که در بالا ذکر شد نرمالیزه گردید و از ۱۲۵۳ داده نرمالیزه شده ۶۵۰ داده برای آموزش شبکه، ۴۰۴ داده برای تایید شبکه و ۱۹۹ داده برای تست شبکه انتخاب گردید. برای مدلسازی از نرم افزارهای Neuralpower 2.5 و MATLAB 7 استفاده شده است.

یافته‌های تحقیق

توپولوژی ANN بوسیله تعداد لایه‌ها، تعداد نرونها در هر لایه، الگوریتم یادگیری و تابع انتقال در شبکه تعیین می‌گردد. در بیشتر پژوهشها در شبکه‌های عصبی سه لایه (لایه ورودی، خروجی و یک لایه مخفی) و لی در صورتی که داده‌های مورد استفاده در شبکه‌های عصبی حجم خیلی وسیعی داشته باشد، برای پردازش بهینه شبکه از شبکه‌های بیش از سه لایه استفاده می‌گردد. بدین صورت که لایه ورودی و خروجی بعنوان دو لایه ثابت بوده و فقط افزایش تعداد لایه‌های مخفی مد نظر می‌باشد که با لایه‌ها و نرونهای بیشتر بتوان حجم وسیع داده‌ها را در شبکه آموزش داد و عمدتاً میزان خطا افزایش می‌یابد. با توجه به اینکه حجم داده‌ها مورد استفاده در پژوهش حجم وسیعی نداشته و برای جلوگیری از افزایش خطا، شبکه سه لایه مورد استفاده قرار گرفت. در این پژوهش از الگوریتم‌های مختلفی برای آموزش شبکه استفاده شد که در نهایت الگوریتم LM برای یادگیری شبکه جواب بهینه ای داد. تابع انتقال تانژانت‌هایپر بولیک به دلیل تاثیر مثبتی که در آموزش شبکه داشته است، مورد استفاده قرار گرفت.

برای پیش بینی این غلظت از داده‌های هواشناسی به عنوان ورودی شبکه استفاده شد. شبکه را با نرون، توابع انتقال و دوره‌های یادگیری مختلف آموزش دادیم که در نهایت شبکه با ۳۵ نرون (در لایه مخفی)، تابع انتقال تانژانت‌هایپر بولیک با شیب یک و ۲۲۰۰ دور یادگیری جواب بهینه را به دست داد که نتایج تست شبکه در اشکال (۳ و ۴) نشان داده شده است. در تعیین تعداد نرون در لایه مخفی از تئوری کولموگوروف (Kolmogorov, 1957, 954) استفاده شده است. بر اساس این تئوری نرون‌ها در لایه مخفی از طریق فرمول $(2N+1)$ محاسبه می‌گردد. در این رابطه N تعداد پترنها را در لایه ورودی نشان می‌دهد. که تعداد نرونها در لایه مخفی بر اساس این فرمول شروع و کم کم افزایش داده شد. برای مشخص کردن میزان تاثیرگذاری هر یک از پارامترهای هواشناسی در غلظت O3 که نتایج آن در شکل ۵ نمایش داده شده است، از فرمول زیر استفاده شده است:

$$I_j = \frac{\sum_{m=1}^{N^h} \left(\frac{|W_{jm}^{ih}|}{\sum_{k=1}^{N^i} |W_{km}^{ih}|} * |W_{mn}| \right)}{\sum_{k=1}^{N^i} \left\{ \sum_{m=1}^{N^h} \left(\frac{|W_{jm}^{ih}|}{\sum_{k=1}^{N^i} |W_{km}^{ih}|} \right) * |W_{mn}| \right\}} \quad (3)$$

که N^h تعداد نرونها در لایه مخفی را نمایش می‌دهد، N^i نشانگر تعداد وزن‌ها در هر یک از نرونها در لایه مخفی می‌باشد، ih شماره لایه در لایه مخفی می‌باشد، و W_{mn} نشانگر وزن نرون N ام در لایه خروجی می‌باشد (Garson, 1991,49; Olden & Jackson, 2002, 142).

با کاهش میزان نرخ یادگیری و افزایش مقدار ثابت مومنتوم تا سقفی معین، تا حدودی می‌توان مقدار خطا را در شبکه کاهش داد. نرخ یادگیری و ثابت مومنتوم بهینه در این تحقیق، به ترتیب ۰/۶۰ و ۰/۹۰ انتخاب شدند، که در میزان یادگیری و کاهش خطای شبکه تاثیر مناسبی داشتند.

یکی از شاخص‌های مهم در شبکه‌های عصبی، محاسبه جذر میانگین مجذور خطا (RMSE) می‌باشد که با استفاده از فرمول زیر محاسبه شد:

$$RMSE = \left(\frac{1}{N} \sum_{i=1}^N (p_i - O_i)^2 \right)^{1/2} \quad (4)$$

که N تعداد داده‌ها، O_i داده‌های اصلی و P_i داده‌های پیش‌بینی را نشان می‌دهد. مقدار RMSE در داده‌های تست ۰/۲۸ بدست آمد.

ضریب همبستگی^۱ (R^2) که برای داده‌های تست ۰/۹۴ به دست آمد، با استفاده از فرمول زیر محاسبه گردید:

$$R^2 = \frac{\sum_{i=1}^n [p_i - \bar{p}]^2}{\sum_{i=1}^n [o_i - \bar{o}]^2} \quad (5)$$


در فرمول بالا \bar{O} میانگین داده‌های اصلی را نشان می‌دهد.

همانطور که در شکل ۵ مشخص شده است درجه حرارت با ۱۷/۵۳ درصد بیشترین تاثیر گذاری را در پیش‌بینی غلظت ازن داشته است. سرعت باد دومین عامل با ۱۵/۲۴ درصد تاثیر گذاری و رطوبت نسبی با ۱۳/۱۵ درصد تاثیر گذاری در رده سوم قرار می‌گیرد. جهت باد در پیش‌بینی غلظت ازن در رده چهارم با ۱۲/۷۲ درصد تاثیر گذاری قرار گرفته است. لازم به ذکر است که در فصل سرد سال بخصوص در ماههای آذر و دی باد غالب تبریز از غرب به شرق بوده و آلودگی‌های ناشی از صنایع و دیگر آلاینده‌های غربی شهر تبریز به طرف شهر سرازیر می‌گردد و عامل باد بعنوان عامل تشدید کننده آلودگی هوای شهر تبریز در این ماهها می‌گردد. برای مقایسه نتایج به دست آمده از شبکه عصبی و تایید کارایی بیشتر آن، از روشهای خطی نیز استفاده گردید. روشهای رگرسیون چند متغیره با تحلیل عاملی^۲، حداقل مربعات جزئی^۳ رگرسیون چندگانه از جمله روشهای خطی هستند که در تحقیق حاضر مورد استفاده قرار گرفتند. نتایج به دست آمده از رگرسیون چندگانه در مقایسه با دو روش دیگر قابل قبولتر بوده است. بنابراین در این پژوهش از نتایج رگرسیون چندگانه برای مقایسه نتایج پرسپترون چند لایه استفاده شد. نتایج مدل خطی MLR در مقایسه با نتایج پرسپترون چند لایه ضعیف بوده است و RMS و R^2 به ترتیب ۸/۵۴ و ۰/۵۱ بدست آمد (شکل‌های ۶ و ۷). بنابراین نتیجه می‌گیریم بین پارامترهای هواشناسی و غلظت‌های آلودگی هوایی، رابطه ای کاملا غیر خطی برقرار بوده است و در پیش‌بینی این غلظت‌ها نتایج شبکه‌های عصبی مناسبتر و قابل قبولتر می‌باشد. و نتایج پژوهشگران دیگر همچون گاردنر و دورلینق (2002) نیز موید این مطلب می‌باشد.


جدول شماره (۱) پارامترهای مختلف به کار برده شده در پیش‌بینی غلظت ازن در شهر تبریز، با مدل شبکه عصبی

نوع شبکه	MLP سه لایه
تعداد نرون در لایه مخفی	۳۵
تابع انتقال	تانژانت هایپر بولیک
دور یادگیری	۲۳۰۰
میزان نرخ یادگیری	۰/۶۰
مقدار ثابت مومنتوم	۰/۹۰
میزان ضریب همبستگی (R^2)	۰/۹۱
مقدار جذر میانگین مجذور خطا (RMSE)	۰/۲۶
الگو ریتم یادگیری	LM


1- Correlation coefficient (R^2)
 2- Principle Component Regression (PCR)
 3- Partial List Squire (PLS)




شکل ۳- همبستگی بین داده‌های اصلی و پیش‌بینی برای غلظت ازن به صورت ساعتی در شهر تبریز، برای داده‌های تست با مدل شبکه عصبی




شکل ۴- مقایسه بین مقادیر مشاهده شده و محاسبه شده برای غلظت ازن در شهر تبریز، برای داده‌های تست با مدل شبکه عصبی



شکل ۵- درصد تاثیر پارامترهای هواشناسی در غلظت ازن در شهر تبریز، برای داده‌های تست با مدل شبکه عصبی



شکل ۶- همبستگی بین داده‌های اصلی و پیش‌بینی برای غلظت ازن به صورت ساعتی در شهر تبریز، با مدل خطی (MLR)



شکل ۷- مقایسه بین مقادیر مشاهده شده و محاسبه شده برای غلظت ازن در شهر تبریز با مدل خطی (MLR).

نتیجه‌گیری

نتایج تحقیق نشان می‌دهد که شبکه‌های عصبی پرسپترون چند لایه، در مقایسه با رگرسیون چندگانه توانسته است بین پارامترهای هواشناسی و داده‌های غلظت ازن در شهر تبریز ارتباط برقرار کند که نتایج به دست آمده از تحقیق نشانگر آنست. در تحقیق حاضر از شبکه سه لایه (لایه ورودی، یک لایه پنهان و لایه خروجی) استفاده شد که با توجه به حجم داده‌ها این شبکه جواب بهینه‌ای داشته است. برای جلوگیری از یادگیری بیش از حد شبکه که باعث افزایش خطا در شبکه می‌گردد، داده‌های تایید در شبکه مورد استفاده قرار گرفت. بدین ترتیب داده‌ها به صورت داده‌های آموزش، تایید و تست شبکه تقسیم بندی گردید که شکل‌های ارائه شده در پژوهش نیز براساس نتایج داده‌های تست بوده است. شبکه سه لایه با ۳۵ نرون در لایه مخفی، تابع انتقال تانژانت‌هایپر بولیک با شیب یک و ۲۳۰۰ دور یادگیری شبکه بهینه انتخاب شد و ضریب همبستگی در داده‌های تست به ۰/۹۱ رسید. درجه حرارت با ۱۷/۵۳ درصد بیشترین تاثیر را در پیش‌بینی غلظت ازن داشته است و سرعت باد و رطوبت نسبی نیز در رده‌های بعدی تاثیرگذاری قرار داشتند. در فصل سرد سال با توجه به اینکه جهت غالب باد در شهر تبریز از غرب به شرق می‌باشد، آلودگی‌های ناشی از صنایع و دیگر آلاینده‌ها به طرف شهر منتقل می‌گردد و این عامل بعنوان یکی از عوامل اصلی در انتقال و عامل تشدید کننده در آلودگی هوای تبریز می‌باشد و در پیش‌بینی غلظت ازن نیز چهارمین عامل تاثیرگذار بوده است. برای مقایسه نتایج به دست آمده از شبکه‌های عصبی پرسپترون

چند لایه از روشهای خطی استفاده گردید که از بین روشهای خطی روش رگرسیون چندگانه نتیجه بهینه ای داشت ولی در مقایسه با پرسپترون چند لایه نتایج ضعیفی داشته است. بطوریکه ضریب همبستگی در این روش به ۰/۴۵ رسید. بدین ترتیب بین پارامترهای هواشناسی و داده‌های غلظت ازن در شهر تبریز رابطه غیر خطی برقرار بوده و شبکه‌های عصبی در مقایسه با روشهای خطی می‌تواند نتایج مناسب و بهینه‌ای داشته باشد.

منابع

- Agirre-Basurko, E., Ibarra-Berastegi, G., Madariaga, I., 2006. **Regression and multilayer perceptron-based models to forecast hourly O3 and NO2 levels in the Bilbao area**. Environmental Modelling & Software 21, 430–446.
- Chelani, A.B.; Chalapati R.C.V.; Phadke,K.M.; Hasan, M.Z., 2002. **Prediction of sulphur dioxide concentration using artificial neural networks**. Environmental Modelling & Software. 17, 161–168.
- Collet, R.S.; Oduyemi, K., 1997. **Air quality modelling: a technical review of mathematical approaches**. Meteorological Applications. 4, 235-246
- Gardner, M.W.; Dorling, S.R., 1998. **Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences**. Atmospheric Environment. 32 (14/15), 2627–2636.
- Garson, G.D. 1991. **Interpreting neural network connection weights**, Artif. Intell. Export 6, 47-51.
- Jiang, D.; Zhanga, Y.; Hua,Xiang.; Zenga,Yun.; Tanb,Jianguo.; Shao, Demin., 2004. **Progress in developing an ANN model for air Pollution index forecast**. Atmospheric Environment. 38, 7055–7064.
- Hooyberghs, J.; Mensink, C.; Dumont, G.; Fierens, F.; Brasseur, O., 2005. **A neural network forecast for daily average PM10 concentrations in Belgium**. Atmospheric Environment. 39, 3279–3289.
- Kolmogorov, A.N., 1957. **On the representation of continuous functions of many variables by superposition of continuous functions of one variable and addition**, Doklady Akademii Nauk SSR 114: 953-956.
- Kuzmanovski, I. Aleksovska. S., 2003. **Optimization of artificial neural networks for prediction of the unit cell parameters in orthorhombic perovskites**; Comparison with multiple linear regression. Chemometrics and Intelligent Laboratory Systems 67, 167– 174.
- Olden, J.D., & Jackson, D.A., 2002. **Illuminating the black box: a randomization approach for understanding variable contributions in artificial neural networks**, Ecol. Modell. 154, 135-150.
- Rahimi, Akbar, 2006, **Analysis of air pollution due to improper location of industrial centers in Tabriz**, using artificial neural networks, MS Thesis, Geography and Urban Planning, University of Tabriz.
- Shi, J.P.; Harrison, R.M. 1997. **Regression modelling of hourly NOx and NO2 concentrations in urban air in London**. Atmospheric Environment. 31 (24), 4081-4094
- Tiittanen, P.; Timonen, K.L.; Ruuskanen, J.; Mirme, A.; Pekkanen, J., 1999. **Fine particulate air pollution, resuspended road dust and respiratory health among symptomatic children**. European Respiratory Journal. 13, 266-273.
- Vakil-Baghmisheh, M.T. 2002. **Fari character recognition using artificial neural networks**, Ph.D. Thesis, Faculty of Electrical Engineering, University of Ljubljana, Slovenia.
- Ziomass, I.C.; Melas, D.; Zerefos, C.S.; Bais, A.F., 1995. **Forecasting peak pollutant levels from meteorological variables**, Atmospheric Environment. 29 (24), 3703-3711.