

## امکانسنجی امکان پیش بینی غلظت ذرات معلق با استفاده از شبکه عصبی (مطالعه موردی: شهر تبریز)

الهام اسراری<sup>۱\*</sup>، توحید ایرانی<sup>۲</sup>

۱- دانشیار گروه فنی و مهندسی، دانشگاه پیام نور

۲- کارشناسی ارشد عمران، محیط زیست دانشگاه پیام نور

(تاریخ دریافت: ۹۹/۰۱/۳۱ تاریخ پذیرش: ۱۴۰۰/۰۴/۰۷)

### چکیده

ذرات معلق یکی از آلاینده‌های مهم هوا است، که بر سلامتی انسان تأثیرات منفی دارد. بدیهی است تخمین و پیش‌بینی غلظت این ذرات مهم است. در این تحقیق با استفاده از مقایسه شبکه عصبی مصنوعی پیش‌خور پس‌انتشار و شبکه عصبی مصنوعی بازگشتی (NAR, NARX) و فازی تطبیقی (ANFIS) به تخمین ذرات معلق شهر تبریز پرداخته شده است. در این تحقیق داده‌های هواشناسی و داده‌های کیفیت هوا طی سال‌های ۱۳۹۲ تا ۱۳۹۶ مورد استفاده قرار گرفت. تخمین غلظت ذرات معلق با توجه به میزان بارش، سرعت باد، مقدار دما در هر مدل و نتایج مقایسه گردید. همچنین از داده‌های غلظت ذرات معلق ۲/۵ میکرومتر در ایستگاه سنجش کیفیت هوای باغشمال تبریز استفاده شد. ۵۰ درصد داده‌ها برای صحت‌سنجی و آزمون واز ۵۰ درصد داده‌ها در روند آموزش استفاده شد. با توجه به نتایج، در حالت ایستا و بدون تغییرات فصلی شبکه عصبی NARX با ضریب همبستگی (R) ۰/۹۹۹۵ و کمترین خطای میانگین مربعات (MSE) یعنی ۰/۰۰۵ بهینه‌ترین مدل این تحقیق شد. مقایسه نتایج مدل‌سازی با داده‌های واقعی نشان داد که بهترین پیش‌بینی متعلق به شبکه عصبی پیش‌خور پس‌انتشار است که با خطای ۰/۰۰۰۷ نسبت به داده نرمال شده، بهترین دقت را دارد و بعد از آن به ترتیب شبکه عصبی NARX و NAR و نهایتاً شبکه فازی تطبیقی قرار دارند.

**واژه‌های کلیدی:** ذرات معلق ۲/۵ میکرون، آلودگی هوا، شبکه‌های عصبی مصنوعی، سری‌های زمانی

### مقدمه

انتشار آلودگی هوا در کشورهای در حال توسعه در بیشتر موارد متأثر از عوامل توپوگرافیکی و اقلیمی مانند ارتفاع از سطح دریا، پستی، میزان بارش سالانه، نوع بادخیزی، سرعت و جهت باد، رطوبت هوا و دمای بیشینه و کمینه آن منطقه و عواملی نظیر رشد جمعیت، افزایش مصرف انرژی و افزایش وسایل نقلیه می‌باشد (اجتهادی، ۱۳۸۶). این عوامل ایجاد کننده آلاینده‌های اصلی نظیر ذرات معلق می‌باشد. تخمین غلظت ذرات معلق با مدل‌سازی خطی معمولاً با خطای زیاد همراه است در چنین مواردی از مدل‌های داده محوری همچون مدل‌های منطق فازی<sup>۱</sup> برای مدل‌سازی استفاده می‌شود، تا ارتباط بین عوامل مختلفی که ممکن است در روش‌های خطی نادیده گرفته، هم مد نظر گیرد (نایاک<sup>۲</sup>، ۲۰۰۵). بررسی توسعه روش‌های

شبکه عصبی مصنوعی (ANN<sup>۳</sup>) در پیش‌بینی آلودگی هوا نشان داد که چگونه مدل‌های عصبی مصنوعی در تعیین پارامترهای اصلی هواشناسی موثر در ارزیابی غلظت آلاینده‌ها کارا هستند (الانگاسینگ<sup>۴</sup> و همکاران ۲۰۱۴). همچنین برای مشخص کردن وضعیت هشدار کیفیت هوا برای زمان‌های اضطراری، استفاده از مدل شبکه‌های عصبی بازگشتی عمیق (RNN<sup>۵</sup>) می‌تواند موثر باشد (فن<sup>۶</sup>، ۲۰۱۷). پیش‌بینی اجزای کیفیت هوا با مجموع روش‌های شبکه‌های عصبی مصنوعی و مدل‌های رگرسیون بسیار کاربردی است. در مطالعه‌ای به پیش‌بینی اجزای کیفیت هوای شهر دهلی با شبکه‌های عصبی مصنوعی چندلایه پرسپترون، شبکه‌های عصبی شعاعی، شبکه‌های عصبی نارایکس (NARX<sup>۷</sup>) پرداختند. نتایج

3. Artificial Neural Network
4. Elangasinghe
5. Regressive Neural Network
6. Fan
7. Nonlinear Autoregressive with External Input

1. Fuzzy Logic
2. Nayak

یامیانگین مربعات خطا و ضریب همبستگی R و MAE که میانگین خطای مطلق می باشد، شبکه ها ارزیابی می شود. استفاده از نرم افزار، اعمال عملیات روی داده ها جهت نرمال سازی و نهایتاً آموزش، آزمون و صحت سنجی شبکه ها جزء روش تحقیق این پژوهش به شمار می رود.

مرحله نهایی کار باداده های حقیقی برای ایستگاه باغشمال تبریز انجام گردید داده ها مشتمل بر دو دسته داده های ورودی و خروجی می باشد که در سیستم های فازی اعمال می شود. براساس آنالیز حساسیت داده های هواشناسی (توکلی و اسماعیلی ساری، ۱۳۹۵) از بین متغیرهای مختلف سه متغیر اصلی سرعت باد، دما و بارش باران به عنوان عوامل اصلی موثر بر ذرات معلق هوا در نظر گرفته شد. داده های ورودی مستقل شامل سرعت متوسط باد، میزان بارش و دمای متوسط از اداره کل هواشناسی استان آذربایجان شرقی اخذ شد، که به عنوان ورودی های موثر از بین عوامل متعدد هواشناسی انتخاب گردیده اند (توکلی و اسماعیلی، ۱۳۹۳). داده خروجی که معیار اصلی این ارزیابی است شامل ذرات معلق با اندازه کمتر از ۲٫۵ میکرون است که مقادیر آن از سازمان محیط زیست استان آذربایجان شرقی به تعداد ۱۴۶۱ روز ثبت شده در ایستگاه باغشمال تبریز از مرداد سال ۱۳۹۲ تا مرداد ۱۳۹۶ دریافت گردید. لازم به ذکر است که منطقه مورد مطالعه شهر تبریز دارای میانگین دمای ۲۵٫۴ درجه سانتیگراد در تیرماه (گرمترین ماه سال) و ۲٫۵ - درجه سانتیگراد در دی ماه (سردترین ماه سال) است. میانگین سالانه دما ۱۱٫۹ درجه سانتیگراد و میانگین بارندگی سالانه در حدود ۳۳۰٫۱ میلی گرم در سال است. تبریز دارای صنایع مادر و صنایع کوچک می باشد و از این جهت شهری صنعتی و تجاری به حساب می آید.

نشان دادند که شبکه های عصبی شعاعی دارای نتایج دقیق تری بودند. (گانش<sup>۸</sup> و همکاران، ۲۰۱۷ و ۲۰۱۸) هدف این تحقیق ارزیابی روشهای استاتیک و دینامیک در امکانسنجی پیش بینی غلظت ذرات معلق می باشد. مدل های استاتیک از جمله مدل فازی تطبیقی و عصبی مصنوعی پیشخور بوده و مدل های دینامیک مدل های بازگشتی یا سری های زمانی با فیدبک و یا بدون فیدبک هستند. داده های ورودی شامل سرعت متوسط باد، میزان بارش و دمای متوسط است. داده خروجی ذرات معلق با اندازه ۲٫۵ میکرومتر می باشد که طی مدت چهار سال به صورت روزانه ثبت شده است. ۵۰ درصد داده ها برای آموزش و ۲۵ درصد برای صحت-سنجی و ۲۵ درصد برای آزمون به کار برده شد. در نهایت مقایسه خطا و نتایج با یافتن MSE یا میانگین مربعات خطا و ضریب همبستگی R و MAE که میانگین خطای مطلق است، انجام گردید.

## مواد و روش ها

### روش کار

در ابتدا مطالعه تحقیق های مشابه صورت گرفت. با توجه به اینکه هدف ایجاد ساختاری فازی برای تخمین دقیق تر غلظت ذرات است، به ایجاد ساختار شبکه مورد نظر در قالب شبکه فازی تطبیقی و عصبی مصنوعی پرداخته شد. در این تحقیق از مدل بازگشتی و پیشخور پسانتشار که از رایج ترین انواع شبکه های عصبی هستند، استفاده شد.

سیستم های فازی تطبیقی و عصبی مصنوعی در نرم افزار MATLAB پیکربندی گردید تا آماده اعمال داده های ورودی و خروجی گردد. ۵۰ درصد داده ها برای آموزش شبکه ها استفاده شد. خطاهای خروجی که به نوعی انحراف از مقادیر هدف هستند را به دست آورده و با اعمال فرآیندهای ریاضی و یافتن MSE

## استاندارد سازی داده‌ها

برای شروع کار نیاز به استاندارد سازی داده است. برای این کار، داده‌ها را به بازه دو عدد ۱ و -۱ منتقل می‌کند. اهمیت استاندارد سازی در یکسان سازی واحدهای داده‌های مورد استفاده در مدل شبکه عصبی و سیستم فازی تطبیقی می‌باشد. برای استاندارد سازی روشهای مختلفی وجود دارد از جمله استفاده از رابطه زیر:

$$Ni = (Xi - Xmin) / (Xmax - Xmin) * 0.8 \quad (1)$$

Ni داده نرمال سازی شده می‌باشد، داده اولیه  $Xi$  بزرگترین داده  $Xmax$  و کوچکترین داده  $Xmin$  می‌باشد. سپس داده‌ها را به سه قسمت تقسیم کرده به نحوی که ۵۰ درصد داده‌ها برای آموزش، ۲۵ درصد برای صحت سنجی و ۲۵ درصد برای آزمون استفاده گردید (چانگ و گولی، ۱۹۹۵). در نهایت خروجی که میزان غلظت ذرات معلق می‌باشد به دست می‌آید و با میزان آلاینده‌های مشاهده‌ای مقایسه می‌گردد (توکلی و اسماعیلی، ۱۳۹۳).

## مدل‌های استفاده شده

الف- سری زمانی: پشت سر هم قرار دادن رشته‌ای از مشاهدات در طول زمان را به اصطلاح سری زمانی می‌نامند که می‌تواند به صورت‌های برداری و یا عددی بیان شود. تجزیه و تحلیل سری‌های زمانی به داده‌هایی مربوط می‌شوند که مستقل نبوده و به طور متوالی به هم وابسته‌اند (چت فیلد، ۱۹۸۹). در حالت کلی می‌توان با کمک ورودی- خروجی (جعبه سیاه) چنین سیستم‌هایی را تحلیل و پیش‌بینی نمود که ورودی مدل گذشته و حال سیستم و خروجی آن نیز آینده سری زمانی هستند (نلز، ۲۰۰۱).

سری‌های زمانی آلودگی هوا دینامیک غیرخطی بالایی دارند. بنابراین، استفاده از مدل‌های غیرخطی سبب بهبود این پیش‌بینی خواهد شد از شبکه‌های عصبی در پیش‌بینی سری‌های زمانی، هنگامی که دینامیک سری‌های زمانی زیاد باشند، بسیار استفاده می‌شود (دورف نر<sup>۱۲</sup>، ۱۹۹۵).

ب- شبکه عصبی مصنوعی پیش‌خور: این شبکه برای تعیین الگوهای بین متغیرهای وابسته و مستقل می‌باشد که با توجه به الگوریتم مورد نظر شبکه، آموزش پیدا کند. بهترین الگوریتم آموزش الگوریتم لونیبرگ مارکواریت می‌باشد که در آن برای به هنگام سازی وزن های شبکه عصبی مصنوعی استفاده شد این الگوریتم پر کاربرد می‌باشد چون آموزش شبکه را بسیار سریع انجام و سطح خطای موجود را حداقل می‌سازد. در واقع این الگوریتم برای افزایش سرعت یادگیری شبکه طراحی و بر مبنای ماتریس هیس<sup>۱۳</sup> می‌باشد.

ج- شبکه عصبی مصنوعی NARX: شبکه بازگشتی نوعی شبکه عصبی مصنوعی با قابلیت آموزش برای پیش‌بینی سری‌های زمانی بر اساس ارزش همان سری‌ها در گذشته است. این مدل قابلیت پیش‌بینی فرآیند خود همبستگی را داراست (عباسپور، ۱۳۹۶). این نوع شبکه یک شبکه پویا بازگشتی است که دارای چندین لایه است. منظور از بازگشتی بودن این شبکه این است که با داشتن مقادیر سری زمانی قادر به پیش‌بینی مقادیر آینده است (زموری، ۲۰۱۰، ۱۴) و به صورت رابطه ریاضی (۲) قابل بیان است.

$$X(t) = f(x(t-d_i)) \quad (2)$$

که در آن  $X(t)$  مقدار تخمین شده از متغیر است که بر مبنای مقادیر گذشته آن متغیر بدست آمده است.

### الگوریتم شبکه عصبی

طرح‌های شبکه عصبی مصنوعی وجود دارند که با شکل‌بندی چند لایه پیش‌خور رو به جلو مشخص گردیده‌اند. ضریب سیناپتیک عصبی طوری تنظیم شده است که بتوان تخمینی بصورت ایده‌آل از پردازش به روش خطای پس انتشار بدست آورد.

این الگوریتم بر پایه روش حداقل مربعات خطا بدست می‌آید. برای لایه‌های خروجی تابع خطا  $e$  در  $n$  امین تکرار به صورت زیر است.

$$e(n) = 1/2 (T_i - O_i(n)) \quad (۳)$$

جایی که  $T$  و  $O$  به ترتیب مقدار هدف و مقدار الگو خروجی واقع است.

کاهش خطا با تنظیم هر وزنه مستقل  $W_{ij}(n+1)$  بدست می‌آید. جهت کاهش خطا از روش گرادینت نزولی در مراحل آموزش دادن همانند زیر بدست می‌آید.

$$W_{ij}(n+1) = W_{ij}(n) + \Delta W_{ij}(n) \quad (۴)$$

که در آن  $n$  تعداد تکرار است. در این تحقیق از تابع غیر خطی مشتق پذیر سیگموئید در لایه پنهان و تابع خطی در لایه خروجی استفاده می‌شود و از رابطه (۵) انتقال را انجام می‌دهد.

$$F(t) = 1/(1+e^{-t}) \quad (۵)$$


### داده‌های ایستا

سری‌های زمانی در دوره‌های بلند مدت دچار تغییرات فصلی می‌شوند. با استفاده از میانگین متحرک این تغییرات فصلی از بین رفته و سری زمانی به حالت ایستا درمی‌آید، از رابطه (۶) برای ایستایی داده‌ها استفاده شد.

$$(x_1 + x_2 + \dots + x_n) / n \quad (۶)$$

نمودارهای (۱) و (۲) به ترتیب پراکندگی داده‌ها را برای حالت غیرایستا با تغییرات فصلی و ایستا بدون تغییرات فصلی نمایش می‌دهد. روش‌های مختلفی برای اینکه داده‌ها به حالت ایستا درآورده شود وجود دارد که روش میانگین متحرک ساده‌ترین و سریع‌ترین آن می‌باشد. در دوره‌های کوتاه مدت هفتگی و روزانه و ساعتی تغییرات دوره‌ای وجود خواهد داشت و به ازای مقادیر کوتاه مدت دقت مدل‌ها برای سری‌های زمانی کاهش خواهد یافت و در واقع در این دوره‌های کوتاه مدت داده‌ها غیرایستا می‌شوند. در صورت وجود روند در داده‌ها حذف روند تغییرات الزامی است.


هرچه تعداد داده‌ها بیشتر باشد دقت محاسبات شبکه دقیق‌تر خواهد بود البته اگر تعداد داده فراتر از حد معینی باشد، ممکن است مدل و نتایج آن دچار بیش‌برازش<sup>۱۵</sup> و کم‌برازش<sup>۱۶</sup> گردند. در این تحقیق بین مدل‌های به کاررفته و تعداد داده‌ها مطابقت وجود دارد تا از بروز چنین خطاهایی اجتناب گردد.



نمودار ۱- پراکندگی داده‌ها برای حالت غیر ایستا با تغییرات فصلی بر حسب مقدار متوسط دما، بارش، سرعت باد و غلظت ذرات معلق (محور عمودی) در روز (محور افقی)

15. Overfit

16. Underfit



نمودار ۲- پراکندگی داده‌ها برای حالت ایستا بدون تغییرات فصلی بر حسب مقدار متوسط دما، بارش، سرعت باد و غلظت ذرات معلق (محور عمودی) در روز (محور افقی)

## نتایج

برای ارزیابی نتایج از ضریب همبستگی (R) و میانگین مربعات خطا (MSE) استفاده شد.

$$MSE = 1/n \times \sum |y_j - y_i|^2 \quad (7)$$

$$R = (\sum |x_i - x_i'| \times |y_i - y_i'|) / (\sum |x_i - x_i'|^2 \times \sum |y_i - y_i'|^2)^{1/2} \quad (8)$$

در شبکه‌های عصبی مصنوعی نتایج برای داده‌های نرمال شده با داشتن تغییرات فصلی به دست آمد. جداول (۱) و (۲) نتایج را نشان می‌دهند. در این حالت شبکه عصبی مصنوعی پیشخور دقت بالاتری نسبت به شبکه عصبی بازگشتی دارد. شبکه عصبی پیشخور به علت استاتیک بودن و عدم وابستگی به دوره‌های زمانی دقت بهتری دارد. در دوره‌های زمانی کوتاه هفتگی و روزانه یا ساعتی همواره حالت غیرایستا و با تغییرات دوره‌ای مواجه شده یعنی تغییرات روزانه، ساعتی و هفتگی سریع رخ می‌دهد.

بعد از حذف تغییرات فصلی از داده‌ها، نتایج نشان دادند که دقت شبکه عصبی بازگشتی بهتر از شبکه عصبی پیشخور است. در دوره‌های بلند مدت با حذف تغییرات فصلی، حالت ایستا به وجود می‌آید که سری زمانی را برای پیش‌بینی غلظت ذرات معلق دقیق‌تر می‌کند. در این حالت نتایج شبکه عصبی پیشخور نیز از حالت غیرایستا بهتر می‌شود. (جداول ۳ و ۴)

در داده‌های بدون هموارسازی، بهترین حالت در آموزش مدل عصبی مصنوعی پیشخور با ضریب همبستگی ۰/۸۵۱ و کمترین میانگین خطای مربعات نتایج یعنی ۰/۰۵۷ بهینه‌ترین مدل این مرحله شد اما مدل بازگشتی فیدبک دار NARX دارای نتایج نزدیک بوده و دارای مقادیر ۰/۸۱۰ برای ضریب همبستگی و میانگین خطای مربعات ۰/۰۷۹ است که در صورت ایجاد تغییرات موثر در ساختار شبکه آن امکان دستیابی به نقاط بهینه وجود خواهد داشت.

در حالتی که داده‌ها از تغییرات فصلی به حالت ایستا درآمد، نتایج در مقایسه دوشبکه عصبی بهینه دچار تغییر شد. در وضعیت جدید بیشترین ضریب همبستگی با مقدار ۰/۹۹۹ برای شبکه عصبی بازگشتی در حالت آموزش و ۰/۸۸۵ برای شبکه عصبی پیشخور در حالت آموزش می‌باشد. کمترین مقدار ۰/۰۰۵ برای شبکه عصبی بازگشتی در آموزش و ۰/۰۴۲ برای شبکه عصبی پیشخور در آموزش می‌باشد.

در دوره‌های کوتاه مدت هفتگی یا روزانه و ساعتی حالت غیرایستایی حاکم است و دقت شبکه عصبی بازگشتی کاهش می‌یابد. اما در دوره‌های بلند مدت با حذف اثر تغییرات فصلی نتایج شبکه عصبی بازگشتی دقیق‌تر از شبکه عصبی پیشخور است. با توجه به اولویت

و ۱- بیانگر بیشترین و کمترین مقدار هر داده است و همگرایی نتایج به ۱- بیانگر خطای کمتر است. در واقع ۱- بیانگر میزان خطای ۰ در نرمالسازی ۱، ۱- است. بهترین پیش‌بینی متعلق به شبکه عصبی پیش‌خورپس‌انتشار است که با خطای ۰,۰۰۰۷ بهترین دقت را داراست و بعد از آن به ترتیب شبکه‌های NAR، NARX و نهایتاً شبکه فازی تطبیقی قرار گرفتند.

### نتیجه‌گیری

در چهار سیستم فازی تطبیقی، عصبی مصنوعی پیش‌خور و عصبی مصنوعی بازگشتی بدون فیدبک و با فیدبک، امکان سنجی پیش‌بینی غلظت ذرات معلق بررسی گردید. روش‌های غیر کلاسیک در مدل‌سازی-های مسائل پیچیده مهندسی محیط زیست از جایگاه مهم برخوردار هستند و امکان بررسی مسائل پیچیده را به وجود می‌آورد. نتایج حاصله بهترین روش پیش‌بینی غلظت ذرات معلق رادر دودسته سیستم دینامیک و استاتیک معرفی می‌کند. با مقایسه ضریب همبستگی R و MSE و MAE به مقایسه مدل‌ها پرداخته شد.

با بررسی نتایج، برتری دو مدل بازگشتی با فیدبک و مصنوعی پیش‌خور که در واقع مدل دینامیکی و استاتیکی برتر هستند، مشخص می‌گردد. با توجه به نتایج سنجش تصادفی شبکه‌ها و نتایج ضرایب رگرسیون و خطا، مدل‌های عصبی مصنوعی پیش‌خور از کاراترین مدل‌ها برای پیش‌بینی فرآیندهای آلودگی هوا هستند. در این مدل جهت انتقال داده‌های یک سو به و بدون فیدبک است که برای مسائل ساده و پیچیده‌ای به راحتی قابل استفاده هستند. نتایج به دست آمده به معنی برتری کامل مدل‌های استاتیک بر مدل‌های دینامیک نیست. مدل‌های دینامیک که از سری‌های زمانی بهره می‌برند، از کاراترین مدل‌ها در تحلیل‌های بلندمدت به حساب می‌آیند. اما در بعضی از مسائل نسبت به مدل‌های استاتیک دارای برتری نیستند و این

حذف تغییرات فصلی از داده‌ها نتایج حالت دوم قابل قبول‌تر بوده و می‌توان شبکه عصبی NARX را برتر دانست.

نتایج تحقیق استفاده از شبکه بازگشتی NAR برای پیش‌بینی غلظت مونوکسید کربن (رفیع پور و همکاران، ۱۳۹۳) نشان می‌دهد که شبکه عصبی NAR قابلیت بسیار بالایی در پیش‌بینی سری زمانی غلظت مونوکسید کربن دارد که با نتایج این مطالعه مطابقت دارد. شبکه عصبی NAR مشابه شبکه عصبی NARX بوده اما به جهت ساختاری بدون حلقه بازگشتی مانند شبکه عصبی NARX است و در واقع مقدار خروجی قادر به ایجاد اثر در ورودی نخواهد بود.

### ارزیابی شبکه‌ها با داده‌های واقعی

برای بررسی نهایی نتایج بدست آمده نیاز به ارزیابی تمام مدل‌ها با داده‌های واقعی هست تا بدون در نظر گرفتن ضریب رگرسیون و خطا، کارایی شبکه مورد آزمون قرار گیرد. داده‌های سنجش به صورت تصادفی برای چندین روز مختلف در شبکه‌ها مورد ارزیابی قرار گرفت که نتایج حاکی از عملکرد بهینه شبکه‌ها در تخمین غلظت ذرات معلق هوا داشت که به عنوان نمونه یکی از این ارزیابی‌ها برای گزارش نتایج ارزیابی‌ها انتخاب شد. داده‌های روز ۲۶ دی‌ماه ۱۳۹۷ برای این منظور انتخاب شد که شامل سه متغیر متوسط بارش روزانه، دمای متوسط روزانه و متوسط سرعت باد و غلظت ذرات معلق متوسط بود. در ادامه با نرمالسازی این داده‌ها و اعمال آن به شبکه‌های ایجاد شده دقت پیش‌بینی مدل‌ها ملاحظه شد که در جدول ۵ نتایج آن مشاهده می‌گردد. مقدار هر کدام از نتایج به صورت حدی بدست آمدند که میزان همگرایی به داده واقعی را بیان می‌کند. با توجه به نتایج اعمال داده‌های واقعی به شبکه‌ها نتایج به صورت حدی حول مقدار ۱- به دست آمد و علت منفی بودن آن نرمال شدن داده‌ها در محدوده ۱ تا ۱- می‌باشد و در واقع مقادیر ۱

ممکن است به دلیل نامناسب بودن تاخیرها یا تعداد لایه‌ها و اندازه شبکه باشد. البته نتایج به دست آمده کارا توصیف می‌کند.

جدول ۱- نتایج مدل شبکه عصبی پیش‌خور

TOTAL	VALIDATION		TEST		TRAIN		ANN
	R	MSE	R	MSE	R	MSE	
0.840	0.847	0.075	0.816	0.074	0.851	0.057	

جدول ۲- نتایج مدل شبکه عصبی بازگشتی NARX

TOTAL	VALIDATION		TEST		TRAIN		NARX
	R	MSE	R	MSE	R	MSE	
0.782	0.733	0.103	0.771	0.095	0.813	0.079	

جدول ۳- نتایج مدل شبکه عصبی پیش‌خور (ایستا)

TOTAL	VALIDATION		TEST		TRAIN		ANN
	R	MSE	R	MSE	R	MSE	
0.879	0.884	0.042	0.885	0.073	0.874	0.044	

جدول ۴- نتایج مدل شبکه عصبی بازگشتی NARX (ایستا)

TOTAL	VALIDATION		TEST		TRAIN		NARX
	R	MSE	R	MSE	R	MSE	
0.999	0.999	0.006	0.998	0.007	0.999	0.005	

جدول ۵- نتایج ارزیابی شبکه عصبی با داده واقعی

آزمون	غلطت ذرات معلق بر حسب مقدار نرمال شده
Anfis	-0.9915
Ann	-1.0007
Narnet	-1.0041
Narxnet	-1.0016

## منابع

- ۱- اجتهادی، م.، ۱۳۸۶، بررسی آلودگی هوای شهری به دلیل فرایندهای انتقال در خشکی با تاکید بر ذرات معلق و ارزیابی راهکارهای مدیریتی (مطالعه موردی، تهران)، دهمین همایش بهداشت محیط.
- ۲- توکلی، م. و ع. اسماعیلی ساری، ۱۳۹۳، مقایسه عملکرد شبکه های عصبی مصنوعی و فازی تطبیقی در تخمین ذرات معلق تهران، فصل نامه علوم و محیط زیست ۷۵-۲.
- ۳- رفیع پور، م. ع. آل شیخ، و ع. محمدی، ع. و ع. صادقی نیارکی، ۱۳۹۵، استفاده از شبکه بازگشتی NARX برای پیش بینی غلظت ذرات مونوکسید کربن، علوم و تکنولوژی محیط زیست، ۱۸-۳.

- 10-Ganesh, S.S., P. Arulmozhiarman, and V.S.N.R. Tatavarti, 2018, Prediction of PM 2.5 using an ensemble of artificial neural networks and regression models, *Journal of Ambient Intelligence and Humanized Computing*,1-11.
- 11- Jang, J.S.R., N. Gulley, 1995, The fuzzy logic toolbox for use with MATLAB, The Mathworks Inc, Natick, MA.
- 12-Jiusheng, L., B. Zhenwu, 2003, Application of the neural network optical fiber temperature sensor probe design used in medical treatment, *International Conference on Neural Networks and Signal Processing*, Nanjing, pp. 389.
- 13-Nayak, P.C., K.P. Sudheer, D.M. Rangan and K.S. Ramasastri, 2005, Short term flood forecasting with a neuron fuzzy model , *Water Resources Research*,41(4),2517-2530.
- 14-Nelles, O., 2001, *Nonlinear system identification*, Springer, Berlin, Heidelberg.
- 15- Zemouri, R., R. Gouriveau and N. Zerhouni, 2010, Defining and applying prediction performance metrics on a recurrent NARX time series model, *Neurocomputing*, 73(13-15) ,2506-2521.
- ۴- عباس پور، ر.، ۱۳۹۶، پیش بینی غلظت آلاینده های مونوکسید کربن در کلان شهر تهران با استفاده از شبکه عصبی مصنوعی، ۱۹-۵.
- 5-Chatfield, C., 1989, *The analysis of time series: An Introduction*, 4<sup>th</sup> edition, Chapman and Hall, New York.
- 6-Dorffner, G., 1996, Neural networks for time series processing, *Neural Network World* 4(96), 447-68.
- 7- Elangasinghe, M., N. Singhal, K. Dirks and J. Salmond, 2014, Development of an ANN-based air pollution forecasting system with explicit knowledge through sensitivity analysis, *Atmospheric Pollution Research*, 5,696-708.
- 8-Fan, J.X., Q. Li and Y.J. Zhu, 2017, The space-time air pollution forecast model based on RNN study, *Journal of Surveying and Mapping Science*, 7, 80-87.
- 9-Ganesh S.S., S.H. Modali, S.R. Palreddy and P. Arulmozhiarman, 2017, Forecasting air quality index using regression models: A case study on Delhi and Houston, *International Conference on Trends in Electronics and Informatics* ,248-254.