

پیش‌بینی آلاینده‌های دی‌اکسیدنیترژن در شهر تهران با استفاده از سیستم استنتاج فازی - عصبی تطبیقی با نظارت الگوریتم یادگیری کلاغ

سمیرا شهرکی^{۱*}، مهدی خزاعی پور^۲، شراره ملبوسی^۳

۱- دانشجوی دکتری، دانشگاه آزاد اسلامی واحد بیرجند، بیرجند، ایران.

۲- استادیار، دانشگاه آزاد اسلامی واحد بیرجند، گروه کامپیوتر، بیرجند، ایران

۳- دانشجوی دکتری، دانشگاه آزاد اسلامی واحد فردوس، فردوس، ایران

چکیده

دی‌اکسیدنیترژن یکی از آلاینده‌هایی است که بیشترین اثرات را بر سلامتی دارد. اطلاعات پیشرفته در مورد غلظت آن در هوا می‌تواند به نظارت و کنترل بیشتر عواقب بیشتر کمک کند و در عین حال اعمال اقدامات پیشگیرانه و کاهش‌دهنده را آسان‌تر می‌کند. فناوری‌های یادگیری ماشینی با روش‌ها و قابلیت‌های موجود می‌توانند تحلیل‌های پیش‌بینی‌کننده را با دقت بالاتری انجام دهند و در نتیجه می‌توانند به عنوان یک ابزار حمایتی برای مدیریت مولد عمل کنند. یکی از پیشرفته‌ترین الگوریتم‌های یادگیری ماشین، سیستم استنتاج فازی-عصبی تطبیقی است که در این مقاله برای پیش‌بینی غلظت دی‌اکسیدنیترژن استفاده می‌شود. برای افزایش دقت در پیش‌بینی آلاینده‌های دی‌اکسیدنیترژن از الگوریتم یادگیری کلاغ در آموزش سیستم استنتاج فازی-عصبی تطبیقی استفاده شده است و نتایج با شبکه عصبی پایه‌ای-شعاعی مقایسه شده است. نتایج حاکی از عملکرد بهتر سیستم استنتاج فازی-عصبی تطبیقی در مقایسه با شبکه عصبی پایه‌ای-شعاعی در پیش‌بینی آلاینده‌های دی‌اکسیدنیترژن دارد.

کلید واژه‌ها: پیش‌بینی آلاینده‌ها، دی‌اکسیدنیترژن، سیستم استنتاج فازی-عصبی تطبیقی، الگوریتم یادگیری کلاغ.

مقدمه

امروزه آلودگی هوا به دلیل شهرنشینی مداوم، به یک موضوع جهانی در دو حوزه اجتماعی و زیست محیطی تبدیل شده است، به ویژه که ارتباط تنگاتنگی با کیفیت زندگی دارد. بسیاری از مطالعات ارتباط بین افزایش میزان آلودگی هوا و شیوع بیماری‌های مرتبط با آلودگی هوا را گزارش کرده‌اند [۱]. علاوه بر این، گزارش «به‌روزرسانی سالانه» سال ۲۰۲۰ توسط شاخص زندگی کیفیت هوا (AQLI) نشان می‌دهد که طی دو دهه گذشته کاهش جهانی کمی در آلودگی هوا صورت گرفته است که منجر به کاهش دو ساله امید به زندگی برای هر فرد در سطح جهان شده است [۲]. پیش‌بینی بلندمدت دی-اکسیدنیترژن سطح زمین در سطح جهانی برای حمایت از تحقیقات محیطی و بهداشت عمومی و ارائه اطلاعات به دولت‌ها و جامعه برای سیاست‌های کنترل آلودگی هوا مهم است [۳]. دی اکسیدنیترژن یکی از خطرناک‌ترین آلاینده‌هایی است که توسط سازمان بهداشت جهانی شناسایی شده است. پیش‌بینی و کاهش آلاینده‌ها در حال تبدیل شدن به یک کار بسیار فوری است و روش‌های زیادی مانند مدل‌های فیزیکی یا یادگیری ماشین برای پیش‌بینی غلظت آنها استفاده شده است [۴]. بنابراین در این مقاله از سیستم استنتاج فازی-عصبی تطبیقی آموزش‌یافته با الگوریتم یادگیری کلاخ در پیش‌بینی آلاینده‌گی دی‌اکسیدنیترژن استفاده می‌شود. ادامه ساختار این مقاله به این صورت است که در بخش دوم مروری بر پیشینه تحقیقات انجام‌شده خواهیم داشت و در بخش سوم الگوریتم‌های سیستم استنتاج فازی-عصبی تطبیقی، شبکه عصبی پایه‌ای- شعاعی، یادگیری کلاخ و تحلیل مؤلفه‌های اصلی بیان می‌شوند. در بخش چهارم مدل پیشنهادی به صورت پیش‌بینی آلاینده‌گی دی‌اکسیدنیترژن به صورت گام‌به‌گام مطرح می‌شود و در بخش پنجم نتایج استفاده از سیستم استنتاج فازی عصبی تطبیقی آموزش‌یافته با الگوریتم‌های یادگیری کلاخ به عنوان روش پیشنهادی و شبکه عصبی پایه ای- شعاعی در پیش‌بینی آلاینده‌گی دی‌اکسیدنیترژن بیان می‌شود و در نهایت در بخش آخر نتیجه‌گیری انجام می‌شود.

۲- مروری بر پیشینه تحقیق

لیم و همکاران در سال ۲۰۲۲، به فضا سازی و پیش‌بینی آلودگی فصلی NO₂ ناشی از تغییر اقلیم در منطقه پایتخت کره از

طریق مدل‌سازی رگرسیون پرداختند. شهرنشینی باعث افزایش آلودگی هوا می‌شود که منجر به مشکلات جدی سلامتی می‌شود. با این حال، حتی اگر ضرورت تنظیم آن اذعان شود، مکان‌های نظارتی نسبتاً کمی در کلان‌شهر پایتخت جمهوری کره وجود دارد. علاوه بر این، انتظار می‌رود که بین آلودگی هوا و متغیرهای آب و هوا رابطه معناداری وجود داشته باشد، بنابراین پیش‌بینی آلودگی هوا تحت تغییر اقلیم باید به دقت مورد توجه قرار گیرد. هدف این مقاله پیش‌بینی و فضا سازی توزیع NO₂ در حال و آینده با استفاده از سایت‌های نظارتی موجود برای غلبه بر کمبود در نظارت است. پیش‌بینی از طریق مدل‌سازی رگرسیون کاربری فصلی با استفاده از متغیرهای مرتبط با غلظت NO₂ انجام شد. متغیرها از طریق دو تحلیل همبستگی انتخاب شدند و آلودگی آینده تحت سناریوهای مختلف پیش‌بینی شد. نتایج حاکی از غلظت نسبتاً بالای NO₂ در زمستان در پیش‌بینی‌های حال و آینده دارد که ناشی از استفاده زیاد از سوخت‌های فسیلی در دیگ‌های بخار است و همچنین افزایش آلودگی NO₂ به دلیل تغییرات آب و هوایی را نشان داد. نتایج این مطالعه می‌تواند استراتژی‌های موجود مدیریت آلودگی هوا و اقدامات کاهش را برای برنامه‌ریزی در مورد تغییرات اقلیمی آینده، حمایت از مدیریت صحیح و کنترل آلودگی هوا تقویت کند [۵]. شمس و همکاران در سال ۲۰۲۱، به ارزیابی دقت هوش مصنوعی در پیش‌بینی غلظت NO₂ هوای کلانشهرها پرداختند. کیفیت هوا نگرانی اصلی در سراسر جهان بوده است و اکسیدنیترژن (NO₂) یکی از آلاینده‌هایی است که بر سلامت انسان و محیط زیست تأثیر بسزایی دارد. این مطالعه با هدف مقایسه تحلیل رگرسیون و مدل شبکه عصبی برای پیش‌بینی آلاینده‌گی NO₂ در هوای کلان‌شهر تهران انجام شده است. داده‌ها طی یک سال در محدوده شهری تهران جمع‌آوری و با استفاده از شبکه‌های عصبی رگرسیون چندخطی و پرسپترون چندلایه مورد تجزیه و تحلیل قرار گرفته است. پارامترهای هواشناسی، داده‌های ترافیک شهری، اطلاعات فضای سبز شهری و پارامترهای زمانی به عنوان ورودی برای پیش‌بینی غلظت روزانه NO₂ در هوا اعمال شدند. نتایج نشان می‌دهد که مدل‌سازی شبکه عصبی پرسپترون چندلایه با جذرمیانگین مربعات خطای ۰.۳۲ منجر به پیش‌بینی‌های دقیق‌تری نسبت به رگرسیون چندخطی با جذرمیانگین مربعات خطای ۱۳.۱۵۱ شده است. با توجه به

ثبت‌شده در لهستان در سال‌های ۲۰۱۵-۲۰۱۷، یک روش تکراری برای تعیین غلظت مرزی که میانگین خطای انحراف مطلق برای مدل پارتیشن به کمترین مقدار خود رسیده است، استفاده شد. مدل حاصل دارای مقدار R2 برابر ۰.۸۲ در مقایسه با ۰.۶۰ برای مدل کلاسیک جنگل تصادفی است. اهمیت متغیرها در مدل، به طور مشابه در مورد کلاسیک، نشان می‌دهد که بیشترین تأثیر بر غلظت NO2 از جریان ترافیک و به دنبال آن عوامل هواشناسی، به ویژه جهت و سرعت باد می‌آید. در مدل، اهمیت متغیرها به طور قابل توجهی متفاوت است در حالی که جریان ترافیک همچنان بیشترین تأثیر را دارد، تأثیرات دما و رطوبت نسبی تقریباً به همان اندازه است. این امر توجه‌پذیری ساخت مدل‌های جداگانه برای غلظت-های کم و زیاد آلودگی را تایید می‌کند [۸]. مسعودی و همکاران در سال ۲۰۱۸، به وضعیت و پیش‌بینی NO2 به عنوان یک آلاینده هوا در اصفهان، ایران پرداختند. در این مقاله، تجزیه و تحلیل کیفیت هوا برای دی‌اکسیدنیترژن (NO2) در اصفهان، ایران انجام شد. اندازه‌گیری‌ها در سه مکان مختلف برای تهیه میانگین داده‌ها در شهر انجام شد. میانگین غلظت برای هر ۲۴ ساعت، هر ماه و هر فصل محاسبه شد. نتایج نشان داد که بیشترین غلظت دی‌اکسیدنیترژن به طور کلی در صبح و شب و کمترین غلظت در بعدازظهر و نیمه شب رخ می‌دهد. غلظت ماهانه دی‌اکسیدنیترژن در ماه مارس بیشترین مقدار را نشان داد. غلظت فصلی در فصل بهار کم‌ترین و در زمستان بیش‌ترین مقدار را نشان داد. سپس رابطه بین آلاینده هوا و برخی پارامترهای هواشناسی با استفاده از میانگین روزانه داده‌ها به صورت آماری محاسبه شد. دما (حداکثر، حداقل)، بارش، جهت باد (حداکثر)، سرعت باد (حداکثر) و تبخیر به عنوان متغیرهای مستقل در نظر گرفته شدند. روابط سطح بین غلظت آلاینده و پارامترهای هواشناسی با استفاده از معادلات خطی چندگانه برای شرایط سالانه و فصلی با استفاده از نرم افزار SPSS بیان شد. آزمون RMSE نشان داد که در بین مدل‌های مختلف پیش‌بینی، مدل گام‌به‌گام بهترین گزینه است. نتایج نشان داد که مقادیر NO2 در فصول مختلف و کل سال را می‌توان با پارامترهای اقلیمی تخمین زد. نتایج همچنین نشان داد که روابط بین NO2 و پارامترهای هواشناسی قوی‌تر از کل سال در طول فصول است [۹]. کابانروس و همکاران در سال ۲۰۱۷، به مدل‌های شبکه عصبی مصنوعی ترکیبی برای

نتایج تحلیل حساسیت مدل، مقدار مساحت پارک، میانگین مساحت فضای سبز و تأخیر زمانی یک روزه پارامترهای بسیار مهم تأثیرگذار بر غلظت NO2 هوا هستند. مدل‌های شبکه عصبی مصنوعی می‌توانند ابزاری قدرتمند، مؤثر و مناسب برای تحلیل و مدل‌سازی روابط پیچیده و غیرخطی متغیرهای محیطی مانند توانایی در پیش‌بینی آلودگی هوا باشند. ایجاد فضای سبز حتی بیش از حجم ترافیک در کاهش NO2 نقش بسزایی دارد [۶]. پروسی و همکاران در سال ۲۰۲۰، به توسعه مدلی برای پیش‌بینی پایدار دی‌اکسیدنیترژن با استفاده از شبکه‌های عصبی پرداختند. آلودگی هوا امروزه یک تهدید جدی برای زندگی است. از نظر کیفیت هوای جهانی، دی-اکسیدنیترژن یکی از آلاینده‌های برجسته بر اساس گزارش‌های سازمان بهداشت جهانی است. دی‌اکسیدنیترژن عامل حدود ۹۲ درصد از موارد آسم است. مطالعات اپیدمیولوژیک سهم دی‌اکسیدنیترژن در مرگ‌ومیر را آشکار کرده است. جدا از اثرات قابل توجه سلامتی، در تشکیل سایر آلاینده‌های اصلی ازن و ذرات معلق نیز نقش دارد. پایش و ارزیابی آلاینده‌ها فرآیندی پیچیده و پرهزینه است که به طور همزمان برای ثروت و سلامت کشور بسیار مهم است. این مشکل قبل از استفاده از مدل‌های آماری و قطعی مختلف با در نظر گرفتن وابستگی دی‌اکسیدنیترژن به آلاینده‌های مختلف و پارامترهای هواشناسی بررسی می‌شود. مطالعه حاضر به پیش-بینی دی‌اکسیدنیترژن برای سیاست‌گذاری خوب کمک می‌کند. مدل پیشنهادی در مقایسه با مدل‌های موجود، منابع فشرده‌تر و مؤثرتر است [۷]. کامینسکا و همکاران در سال ۲۰۱۹، به یک مدل بخش‌بندی جنگل تصادفی برای پیش‌بینی غلظت NO2 از جریان ترافیک و شرایط هواشناسی پرداختند. غلظت بالای دی‌اکسیدنیترژن در هوا، به ویژه در مناطق شهری شدید، تأثیر نامطلوبی بر بسیاری از جنبه‌های سلامت ساکنان (آسیب‌های کوتاه‌مدت و بلندمدت، بوی نامطبوع و غیره) دارد. روشی برای مدل‌سازی غلظت‌های NO2 اتمسفر در یک شهرک، با استفاده از یک مدل پارتیشن متشکل از دو مدل جداگانه برای مقادیر غلظت پایین‌تر و برای مقادیر بالاتر پیشنهاد شده است. یک تکنیک پیشرفته داده‌کاوی، که از جنگل‌های تصادفی، استفاده می‌کند. این روشی مبتنی بر یادگیری ماشینی است که شامل جمع‌آوری همزمان اطلاعات از چندین درخت تصادفی است. با استفاده از مثال داده‌های

آلاینده‌ها در مناطق مختلف شهر دارند. این مقاله بر تغییرات هواشناسی و تأثیر آنها بر غلظت NO₂ پس‌زمینه شهری در شهر بریلا برای سال‌های ۲۰۰۹-۲۰۱۳ تمرکز دارد. وابستگی بین داده‌های اندازه‌گیری شده NO₂ و پارامترهای هواشناسی با استفاده از دو روش رگرسیون خطی چندگانه و شبکه‌های عصبی مصنوعی مدل‌سازی تجزیه و تحلیل می‌شود. مجموعه داده محاسبه شده با استفاده از مدل‌های پیشنهادی نشان می‌دهد که شبکه‌های عصبی مصنوعی را می‌توان در تحلیل و پیش‌بینی کیفیت هوا به کار برد [۱۲].

مروری بر الگوریتم‌ها

در این بخش الگوریتم‌های یادگیری کلاغ، سیستم استنتاج فازی-عصبی تطبیقی و شبکه عصبی پایه‌ای-شعاعی بررسی می‌شوند.

الگوریتم یادگیری کلاغ

الگوریتم یادگیری کلاغ در سال ۲۰۲۰ معرفی شده است و از مکانیزم یادگیری بین کلاغ‌ها الگوبرداری شده است. در الگوریتم یادگیری کلاغ هر راه‌حل مسأله یک کلاغ است و کلاغ‌ها برای یافتن جواب بهینه از مکانیزم یادگیری استفاده می‌کنند. در الگوریتم کلاغ دو راه‌حل بهینه‌تر به عنوان پدر و مادر بوده و کلاغ‌ها بر اساس این دو راه‌حل آموزش داده می‌شوند. یک نمونه یادگیری در الگوریتم کلاغ، یادگیری هر کلاغ از خواهر و برادران خود است و از آنها نیز یادگیری دارد. در این الگوریتم جالب و ساده از رفتار کلاغ‌ها برای شکار کرم‌هایی که درون تنه درخت قرار دارند برای مدل‌سازی استفاده می‌شود. در الگوریتم کلاغ هر عضو جمعیت به مرور زمان یاد می‌گیرند که موقعیت بهینه غذا را یاد بگیرند و به سمت آن پرواز کنند. در این الگوریتم هر کلاغ با یادگیری در نهایت جواب بهینه یا کرم را پیدا و آن را شکار می‌کند.

یادگیری در الگوریتم کلاغ: در مرحله یادگیری، هر فرد یا کلاغ در خانواده با استفاده از مکانیسم‌های یادگیری مختلف، رفتار خود را بهبود می‌بخشد، از جمله یادگیری‌ها می‌توان به یادگیری اجتماعی اشاره نمود. در مرحله یادگیری، هر یک از نوجوانان خانواده با تجربه اندک سعی می‌کنند ویژگی‌های رفتاری خود را به صورت اجتماعی یا فردی به روز کنند. هر

پیش‌بینی مؤثر و کاهش آلودگی NO₂ کنار جاده‌های شهری پرداختند. آلودگی هوای ناشی از ترافیک به دلیل تأثیرات فیزیولوژیکی و زیست محیطی، نگرانی جدی در میان سیاست‌گذاران و مردم بوده است. بنابراین یک سیستم هشدار اولیه مبتنی بر ابزارهای پیش‌بینی دقیق باید برای دورزدن اثرات نامطلوب قرارگرفتن در معرض آلاینده‌های عمده هوا اجرا شود. یک شبکه عصبی پرسپترون چندلایه با استفاده از داده‌های آلودگی هوا و هواشناسی در یک دوره دو ساله از یک سایت نظارتی در خیابان مریل‌بون، مرکز لندن برای پیش‌بینی مقادیر غلظت NO₂ در کنار جاده در ۲۴ ساعت آینده آموزش و توسعه داده شد. چندین مدل ترکیبی نیز با استفاده از تکنیک‌های انتخاب ویژگی مانند رگرسیون گام‌به‌گام، تجزیه و تحلیل مؤلفه‌های اصلی و درختان طبقه‌بندی و رگرسیون برای مدل شبکه عصبی توسعه یافتند. اکثر متغیرهای آلاینده کنار جاده، به عنوان مثال، اکسیدهای نیترژن، در پیش‌بینی NO₂ مهم هستند. نتایج آماری برتری پیش‌بینی کلی مدل‌های ترکیبی را نسبت به مدل شبکه عصبی مستقل نشان می‌دهد [۱۰].

میکانویز و همکاران در سال ۲۰۱۶، به یک مدل پراکندگی رگرسیون/خط منبع کاربری ترکیبی برای پیش‌بینی NO₂ درون شهری پرداختند. مدل رگرسیون به عنوان یک ابزار استاندارد برای تخمین تغییرات درون شهری در قرار گرفتن در معرض آلودگی هوا در طولانی مدت تکامل یافته است. با این حال، مدل رگرسیون به طور کلی بر روابط فضایی مشاهده شده بین منابع توزیع شده و اقدامات آلودگی اطلاعات هواشناسی یا فیزیکی و شیمیایی متکی است. گنجاندن اطلاعات تعامل هواشناسی و ترافیک در رگرورها از طریق مدل‌های پراکندگی ممکن است دقت و قابلیت تفسیر فیزیکی را بهبود بخشد. بهبودهای مدل در سایت‌هایی با غلظت NO₂ نسبتاً بالاتر مشاهده شد که حجم ترافیک بالاتری را نشان می‌دادند که ممکن است نقش مهمی در شناسایی بهتر نوردهی‌ها در محیط‌های نزدیک جاده و محیط‌های پرتراфик داشته باشد [۱۱].

دراگومیر و همکاران در سال ۲۰۱۵، به پیش‌بینی داده‌های غلظت NO₂ در یک منطقه شهری با استفاده از رگرسیون چندگانه و شبکه‌های عصبی پرداختند. احتمال فراتر رفتن از مقادیر حد اتحادیه اروپا برای غلظت NO₂ در بسیاری از شهرهای اروپایی افزایش یافته است. پارامترهای هواشناسی نقش بسیار مهمی در ارزیابی پراکندگی

$$F = \begin{cases} (X_{11}, X_{12}, X_{13}, \dots, X_{1d}) \Rightarrow X_1 \\ (X_{21}, X_{22}, X_{23}, \dots, X_{2d}) \Rightarrow X_2 \\ (X_{31}, X_{32}, X_{33}, \dots, X_{3d}) \Rightarrow X_3 \\ \vdots \\ (X_{n1}, X_{n2}, X_{n3}, \dots, X_{nd}) \Rightarrow X_n \end{cases} \quad (1)$$

که X_{ij} بردار راه‌حل i ام و بعد j ام آن است. در تکرار اول جمعیت تصادفی از راه‌حل‌ها مانند رابطه (۲)، ایجاد می‌شود.

$$X_{ij} = L + (U - L) \times U(0,1) \quad (2)$$

که $U(0,1)$ بردار تصادفی بین صفر و یک با توزیع یکنواخت است. L و U به ترتیب محدوده پایین و بالایی هر راه‌حل است. در مرحله بعدی، شایستگی هر کلاغ با توجه به ویژگی‌های رفتاری مانند متغیرهای تصمیم‌گیری محاسبه می‌شود و در اینجا برای ارزیابی هر بردار راه‌حل می‌توان از تابع هدف استفاده نمود. می‌تواند شایستگی کلاغ‌ها بر اساس تجربه و یادگیری را در یک ماتریس مانند رابطه (۳)، ایجاد نمود.

$$Cost = \begin{cases} Cost(X_{11}, X_{12}, X_{13}, \dots, X_{1d}) \\ Cost(X_{21}, X_{22}, X_{23}, \dots, X_{2d}) \\ Cost(X_{31}, X_{32}, X_{33}, \dots, X_{3d}) \\ \vdots \\ Cost(X_{n1}, X_{n2}, X_{n3}, \dots, X_{nd}) \end{cases} \quad (3)$$

می‌توان اعضای جمعیت را براساس شایستگی آنها مرتب نمود و دو عضو شایسته X_1 و X_2 را به عنوان موقعیت دو راه‌حل والد در نظر گرفت و $n-2$ کلاغ دیگر را به عنوان کلاغ‌های جوان و جویای تجربه و یادگیری در نظر گرفت. مدل‌سازی رفتار یادگیری از والدین یا خواهر و برادر در رابطه (۴)، نمایش داده شده است.

$$\begin{aligned} X_{ij}(t) &= X_{kj}(t-1) \\ \text{for Vertical - Learning: } k &= 1 \text{ or } 2 \\ \text{for Horizontal - Learning: } 3 &\leq k \leq i - 1 \end{aligned} \quad (4)$$

که t شمارنده تکرار جدید و $t-1$ تکرار فعلی الگوریتم کلاغ است و k شماره یک کلاغ از جمعیت است که اگر یادگیری براساس پدر و مادر باشد آنگاه k برابر ۱ یا ۲ است. در یادگیری مبتنی بر خواهر یا برادر که یادگیری افقی نیز می‌گویند می‌توان هر یک از مؤلفه‌های بکار رفته در خواهر یا برادر را استفاده نمود. در الگوریتم کلاغ یکی از کلاغ‌های خواهر و برادر که شماره آن برابر $k=3$ تا $i=1$ است انتخاب شده و برای انتخاب می‌توان تصادفی و به مانند رابطه (۵) استفاده نمود.

$$k = 3 + [\text{rand} \times (i - 3)] \ \& \ i \geq 3 \quad (5)$$

نوجوان برای بروزرسانی ویژگی‌های رفتاری خود به لحاظ اجتماعی از رفتار سایر کلاغ‌ها استفاده نماید.

یادگیری افقی و عمودی الگوریتم کلاغ: در الگوریتم کلاغ، وقتی یک کلاغ نوجوان تصمیم می‌گیرد از نظر اجتماعی طبق احتمال $SLprop$ یاد بگیرد، می‌تواند تصمیم بگیرد که از والدین خود یا از خواهر و برادر بزرگ‌تر و با تجربه‌اش یاد بگیرد. در الگوریتم کلاغ، احتمال یادگیری از پدر و مادر برابر

$VSLprob$ و احتمال یادگیری از برادر و خواهر برابر با $1-VSLprob$ خواهد بود. مقدار بزرگ‌تر $VSLprob$ باعث می‌شود که کلاغ‌ها بیشتر از پدر و مادر خود یادگیری انجام داشته باشند تا از برادر و خواهر خود یادگیری داشته باشند. افزایش مقدار $1-VSLprob$ باعث می‌شود که کلاغ‌ها بیشتر از خواهر و برادران خود یادگیری داشته باشند.

یادگیری فردی در الگوریتم کلاغ: در الگوریتم کلاغ، وقتی کلاغ نوجوان یا بدون تجربه تصمیم می‌گیرد به صورت جداگانه یاد بگیرد، می‌تواند ویژگی‌های رفتاری خود را به صورت تصادفی به روز کند. با توجه به این رابطه، به یک احتمال از پیش تعیین شده عدم شرکت در یادگیری اجتماعی $1-VSLprob$ و یک احتمال یادگیری فردی $TaEprob$ می‌تواند یادگیری فردی کلاغ‌ها را با احتمال کلی و برابر مقدار $1-VSLprob$ انجام دهد. مقادیر بالای $TaEprob$ به عوامل جستجو سراسری به الگوریتم این اجازه می‌دهد تا بیشتر به طور تصادفی در اطراف فضای جستجو مسأله و جستجوی از نوع سراسری را انجام دهد.

تقویت یادگیری کلاغ‌های نوجوان: در الگوریتم کلاغ، پس از اتمام مرحله یادگیری، برخی از ویژگی‌ها و رفتارهای یاد گرفته شده نوجوانان از والدین ممکن است شامل پاداش شود.

تقویت یادگیری کلاغ‌های والدین: در الگوریتم کلاغ، پس از تقویت یادگیری نوجوانان، والدین X_1 ، X_2 به رفتارهای خود پاداش می‌دهند زیرا دانش و تجربه آنها با توجه به تجربیات گذشته خود افزایش می‌یابد. در الگوریتم کلاغ و در خانواده F تعدادی کلاغ وجود دارد که نمایانگر جمعیت است و موقعیت هر کلاغ یا راه‌حل مسأله با X_i نمایش داده می‌شود. اعضای جمعیت کلاغ‌ها و خانواده آنها در یک ماتریس مانند رابطه (۱)، نگهداری می‌شوند.

$$lf = lfmin + ((lfmax - lfmin) / Max_t) \times t \quad (9)$$

که $lfmin$ کم‌ترین ضریب یادگیری و $lfmax$ بیش‌ترین ضریب یادگیری است و Max_t بیشترین شماره تکرار است و t هم شماره تکرار فعلی الگوریتم کلاغ است. با استفاده از این فاکتور یادگیری در الگوریتم کلاغ مرتباً تقویت شده و مقدار آن از $lfmin$ در تکرار اول به مقدار $lfmax$ در تکرار آخر می‌رسد. با توجه به روابط فوق، می‌توان ضریب پاداش را طبق رابطه (۱۰) محاسبه نمود.

$$RW = \begin{cases} \beta - \alpha & \text{if } i < n/2 \\ r_1 \times ((r_2 \times \beta) - \alpha) & \text{otherwise} \end{cases} \quad (10)$$

در الگوریتم کلاغ، پس از تقویت یادگیری نوجوانان، والدین $X1, X2$ به رفتارهای خود پاداش می‌دهند زیرا دانش و تجربه آنها با توجه به تجربیات گذشته خود افزایش می‌یابد. از طریق مرحله تقویت یادگیری، است که $X1, X2$ برخی از ویژگی‌های رفتاری خود را مانند رابطه (۱۱) به روز می‌کنند.

در این حالت یک کلاغ یا یک بردار ویژگی تصادفی می‌تواند مقادیر ویژگی‌های خود را یک بازه مشخص و به صورت تصادفی به روزرسانی نماید. در الگوریتم کلاغ، پس از اتمام مرحله یادگیری، برخی از ویژگی‌های و رفتارهای یادگیری گرفته شده نوجوانان از والدین ممکن است شامل پاداش شود. احتمال دریافت پاداش برابر $Rpprob$ است و طبق رابطه (۶)، یک فرد پاداش دریافت می‌نماید.

$$X_{ij}(t+1) = X_{ij}(t) \pm RW \quad (6)$$

که RW پاداش محاسبه شده است و با استفاده از رابطه‌های (۷) و (۸)، که در آن هر ویژگی j رفتار نوجوانان Xi در تکرار t می‌توان با RW افزایش یا کاهش داد.

$$RW = |X_{ij}(t) - X_{ij}(t-1)| \alpha \quad (7)$$

$$RW = X_{ij}(t-1) \times \exp(-lf \times r \times t \times \text{mean}(j)) \beta \quad (8)$$


که برای محاسبه β می‌توان از میانگین یک ویژگی نظیر J مانند $\text{mean}(j)$ استفاده نمود و r یک عدد تصادفی بین صفر و یک است و lf مقدار فاکتور یادگیری است که طبق رابطه (۹) محاسبه می‌شود.

$$X_{ij}(t) = \begin{cases} X_{ij}(t-1) - [X_{1j}(t-1) + \exp(r_1 \times \text{mean}(j)) - X_{ij}(t-1)] & i = 1 \\ X_{ij}(t-1) - [r_2 \times X_{1j}(t-1) + \exp(r_1 \times \text{mean}(j)) - X_{ij}(t-1)] & i = 2 \end{cases} \quad (11)$$

این روش برای اولین بار در سال ۱۹۹۳ توسط جانگ مطرح شد. الگوریتم ساده‌ای از عملکرد و ارتباط بین لایه‌های آن در شکل (۱) آورده شده است.

در این رابطه، کلاغ والد شماره یک یا $i=1$ از رابطه استفاده نموده و کلاغ والد دوم از رابطه دوم استفاده می‌کند و در اینجا $X1j=(t-1)$ بهترین راه حل است. $r1$ و $r2$ به ترتیب دو عدد تصادفی یکنواخت بین صفر و یک است [۱۳].

۲-۳- سیستم استنتاج فازی- عصبی تطبیقی



شکل ۱- شمای ساده ای از ANFIS [۳]

دقت می‌باشند. نکته بسیار جالب آن است که این شبکه‌ها تنها با داشتن یک لایه مخفی، دارای چنین خاصیتی هستند. شبکه‌های پایه‌ای شعاعی بیش‌ترین الهام را از تکنیک‌های آماری طبقه‌بندی الگوها گرفته‌اند که اساساً به‌عنوان گونه‌ای از شبکه‌های عصبی، حیاتی‌نو یافته‌اند و مزیت عمده آنها طبقه‌بندی الگوهایی که دارای فضای غیرخطی هستند می‌باشد. با قراردادن این شبکه برای طبقه‌بندی اصلی شبکه‌های عصبی، این تکنیک‌ها، گرچه تعدادشان اندک است، به فراوانی به‌کار گرفته شده‌اند. در شبکه عصبی پایه‌ای-شعاعی، لایه ورودی فقط یک لایه ورودی است و در آن هیچ پردازشی صورت نمی‌گیرد. لایه دوم یا لایه پنهان، یک انطباق غیرخطی مابین فضای ورودی و یک فضای معمولاً با بُعد بزرگ‌تر برقرار می‌کند و نقش مهمی در تبدیل الگوهای غیرخطی به الگوهای تفکیک‌پذیر خطی دارد. سرانجام لایه سوم، جمع وزنی را به همراه یک خروجی خطی تولید می‌کند. در صورتی که از این شبکه عصبی برای تقریب تابع استفاده شود، چنین خروجی‌ای مفید خواهد بود ولی در صورتی که نیاز باشد طبقه‌بندی الگوها انجام شود، آن‌گاه یک محدودکننده سخت یا یک تابع سیگموئید را می‌توان بر روی عصب‌های خروجی قرار داد تا مقادیر خروجی ۰ یا ۱ تولید شوند. همان‌طور که از توضیحات بالا مشخص می‌شود خصوصیات منحصربرفرد این شبکه، پردازشی است که در لایه پنهان انجام می‌گیرد. تابع لایه پنهان دارای رابطه‌ای مطابق با رابطه (۱۲) است:

$$f(x) = \sum_{i=1}^p w_i \varphi(Xc_i - x) \quad (12)$$

که در آن p تعداد توابع شعاعی، w_i وزن نورون i ام، Xc_i مرکز ثقل نورون i ام، x بردار ورودی و φ تابع شعاعی است. رابطه (۱۲) نشان می‌دهد که برای تقریب تابع f از p تابع شعاعی که دارای مراکز ثقل Xc_i هستند استفاده می‌شود. نماد $\| \cdot \|$ تابع فاصله در فضای R^n است که معمولاً فاصله اقلیدسی انتخاب می‌شود. از آنجایی که منحنی نمایش تابع‌های پایه‌ای شعاعی به‌صورت شعاعی متقارن است، نورون‌های لایه مخفی به نورون‌های تابع شعاعی معروفند. تابع معروف در شبکه‌های شعاعی همان تابع گوسی یا نمایی است که در رابطه (۱۳) مشخص شده است.

ساختار ANFIS شامل پنج لایه است که به ترتیب شامل گره‌های ورودی، گره‌های قاعده، گره‌های متوسط، گره‌های نتیجه و گره‌های خروجی می‌باشند و به‌طور مستقیم با هم ارتباط دارند. هر گره دارای تابعی با پارامترهای قابل تنظیم یا ثابت است. ساختار مناسب تکنیک ANFIS متناسب با داده‌های ورودی، درجه عضویت، قوانین و توابع عضویت مناسب ورودی و خروجی انتخاب می‌گردد. در مرحله آموزش با اصلاح پارامترهای درجه عضویت بر اساس میزان خطای قابل قبول، مقادیر ورودی به مقادیر واقعی نزدیک‌تر می‌شوند. تکنیک ANFIS از الگوریتم‌های یادگیری شبکه عصبی و منطق فازی به منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کند و قابلیت خوبی در آموزش، ساخت و طبقه‌بندی دارد. همچنین دارای این مزیت است که اجازه استخراج قوانین فازی را از اطلاعات عددی یا دانش متخصص می‌دهد و به‌طور تطبیقی یک قاعده بنیاد می‌سازد. علاوه بر این، می‌تواند تبدیل پیچیده هوش بشری به سیستم‌های فازی را تنظیم کند. قانون یادگیری آن بر پایه الگوریتم پس‌انتشار خطا با نگرش بر حداقل کردن میانگین مربعات خطا بین خروجی شبکه و خروجی واقعی می‌باشد. اکثر سیستم‌های استنتاج فازی شامل سه نوع سیستم، سیستم ممدانی، سیستم سوگنو و سیستم سوکاموتو می‌باشند که در بیشتر موارد از سیستم‌های ممدانی استفاده می‌شود، اما سیستم سوگنو در محاسبات عملکرد بهتری دارد و از خروجی قطعی برخوردار می‌باشد [۱۴].

شبکه عصبی پایه‌ای-شعاعی

شبکه‌های عصبی به‌عنوان یک تکنولوژی کاربردی ظاهر شده‌اند که به‌صورت موفقیت‌آمیزی در زمینه‌های متفاوت به‌کار برده می‌شوند. مهم‌ترین مزیت شبکه عصبی قابلیت خود تطبیقی، خودسازمان‌دهی و عملیات بلادرنگ و غیره است. شبکه عصبی پایه‌ای-شعاعی به‌طور گسترده‌ای برای تخمین غیرپارامتریک توابع چندبُعدی از طریق مجموعه‌ای محدود از اطلاعات آموزشی به‌کار می‌رود. شبکه‌های عصبی پایه‌ای-شعاعی به‌واسطه آموزش سریع و فراگیر، بسیار جالب و مفید هستند و مورد توجه خاصی قرار گرفته‌اند. شبکه‌های عصبی پایه‌ای شعاعی تقریب‌سازی هر تابع پیوسته و با هر درجه

انتخاب ویژگی

در این مقاله در جهت انتخاب ویژگی و کاهش فضای ورودی از الگوریتم تحلیل مؤلفه‌های اصلی استفاده شده است. الگوریتم تحلیل مؤلفه‌های اصلی داده‌ها را از فضای ورودی به صورت خطی به فضای جدید نگاشت می‌کند و همبستگی بین ویژگی‌ها را از بین می‌برد و ویژگی‌های با واریانس بالا انتخاب می‌شوند [۱۶]. در این پژوهش از مجموعه داده‌ای ۷ ویژگی از ۲۳ ویژگی انتخاب شدند.

مراحل روش پیشنهادی

پس از آماده‌سازی داده‌ها در مرحله پس‌پردازش از سیستم استنتاج فازی-عصبی تطبیقی در جهت پیش‌بینی میزان آلاینده‌گی دی‌اکسیدنیترژن استفاده می‌شود. برای آموزش سیستم استنتاج فازی-عصبی تطبیقی از الگوریتم یادگیری کلاخ استفاده می‌شود. تعیین مقادیر بهینه مراکز در توابع عضویت و وزن‌ها در سیستم ANFIS باعث افزایش دقت آن و کاهش میزان خطا در پیش‌بینی میزان آلاینده‌گی دی‌اکسیدنیترژن می‌شود. برای این منظور از ایده استفاده از الگوریتم یادگیری کلاخ به منظور تعیین مقادیر بهینه مراکز توابع عضویت و وزن‌ها در مدل ANFIS استفاده می‌شود تا مقادیر بهینه مراکز توابع عضویت و وزن‌ها تعیین شود تا با دقت بالایی پیش‌بینی میزان آلاینده‌گی دی‌اکسیدنیترژن انجام شود. تابع هدف در الگوریتم یادگیری کلاخ میانگین مربعات خطا در نظر گرفته شده است. در ادامه قصد داریم نحوه ترکیب سیستم استنتاج فازی-عصبی تطبیقی ANFIS با الگوریتم یادگیری کلاخ به عنوان مدل پیشنهادی به صورت گام‌به‌گام بیان شود.

مرحله آماده‌سازی اولیه: در این حالت موقعیت کلاخ شامل مراکز توابع عضویت و وزن‌های سیستم استنتاج فازی-عصبی ANFIS خواهد بود. شکل (۲) موقعیت کلاخ و شکل (۳) ساختار سیستم استنتاج فازی-عصبی ANFIS را در حالتی که شامل ۲ ورودی در لایه ورودی، ۲ نورون در لایه میانی و یک نورون خروجی است، را نشان می‌دهد. در مرحله آماده‌سازی مقادیر مراکز و وزن‌ها به صورت تصادفی مقداردهی می‌شوند و تابع هدف فراخوانی شده و موقعیت کلاخ در توابع عضویت ورودی و وزن‌ها در سیستم استنتاج فازی-عصبی تطبیقی قرار می‌گیرد سپس ورودی‌های

$$\phi(r) = e^{-\frac{r^2}{2\sigma^2}} \quad c > 0 \quad r \in \mathbb{R} \quad (13)$$

که در آن $r = \|x - xc\|$ است و σ فاکتور عرض هسته است. دلیل انتخاب تابع نمایی گوسی به‌عنوان تابع پاسخ نورون‌ها در شبکه عصبی این است که تابع نمایی جزء گروهی از توابعی است که دارای بهترین خواص در تقریب‌سازی هستند [۱۵].

روش پیشنهادی

در این بخش کلیه مراحل روش پیشنهادی شامل پیش-پردازش (پاک‌سازی، نرمال‌سازی و انتخاب ویژگی) و پس-پردازش (آموزش سیستم استنتاج فازی-عصبی تطبیقی با استفاده از الگوریتم یادگیری کلاخ) بیان می‌شود.

جمع‌آوری داده‌ها

در این مقاله از داده‌های ایستگاه هواشناسی مهرآباد تهران استفاده شده است که شامل ۱۰۰۰ نمونه داده با ۲۳ ویژگی است که از ۸۰ درصد داده‌ها (۸۰۰ نمونه) در آموزش و از ۲۰ درصد داده‌ها (۲۰۰ نمونه) در آزمایش استفاده می‌شود.

پاک‌سازی داده‌ها

پایگاه داده شامل ۱۰۰۰ نمونه با ۲۶ ویژگی است که برخی از ویژگی‌ها در بعضی از نمونه‌ها فاقد مقدار هستند بنابراین از آماره مرکزی میانگین برای پاک‌سازی داده‌ها استفاده می‌شود به این ترتیب که برای هر ویژگی در مجموعه داده‌ای، از نمونه‌هایی که دارای مقدار هستند میانگین‌گیری نموده و در نمونه‌های فاقد مقدار استفاده می‌شود.

نرمال‌سازی داده‌ها


در جهت یکسان‌سازی تأثیر ورودی‌ها بایستی داده‌ها نرمال‌سازی شده و در بازه یکسانی قرار گیرند در این مقاله با استفاده از نرمال‌سازی خطی داده‌ها به بازه $[0, 1]$ نرمال می‌شوند. رابطه (۱۴) نحوه نرمال‌سازی را نشان می‌دهد.

$$\frac{x - \min(x)}{\max(x) - \min(x)} \quad (14)$$

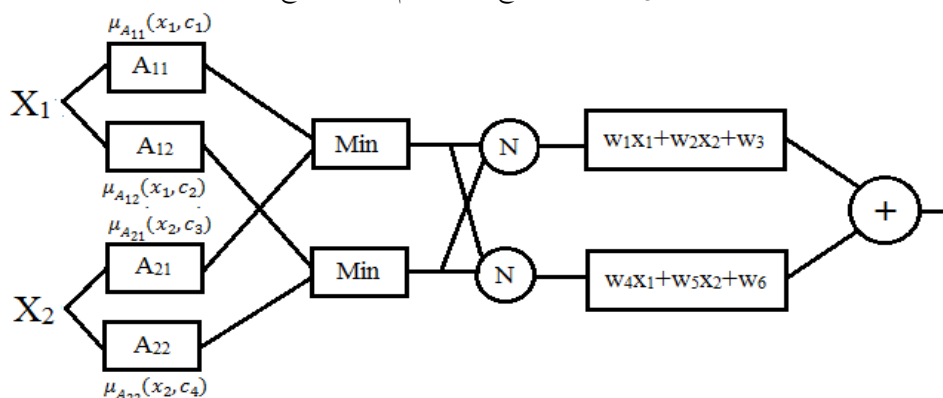
که x داده، $\min(x)$ کم‌ترین مقدار و $\max(x)$ بیش‌ترین مقدار است.

به عنوان پدر و مادر در نظر گرفته می‌شوند و بقیه کلاغ‌ها به عنوان کلاغ‌های نوجوان در نظر گرفته می‌شوند. یادگیری کلاغ: در این گام موقعیت جدید کلاغ بر اساس یادگیری عمودی یا افقی تعیین می‌شود. شکل (۴) موقعیت کلاغ قبل و بعد از یادگیری را نشان می‌دهد.

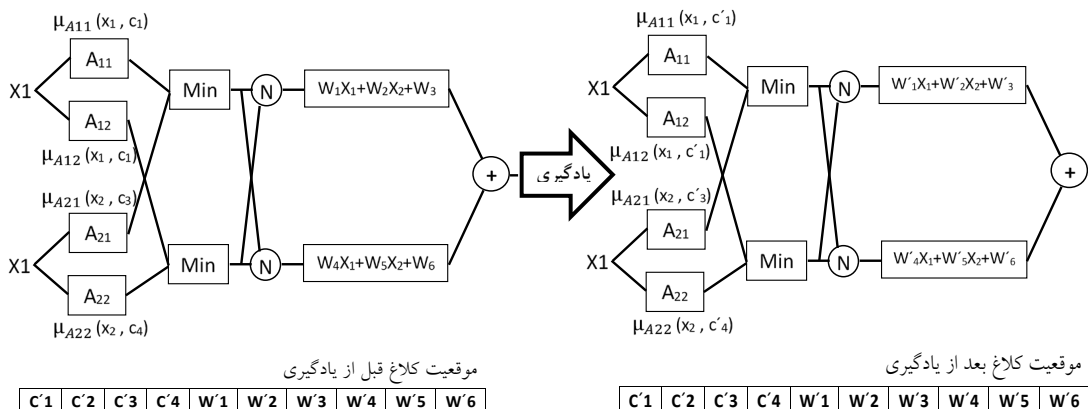
آموزشی به آن اعمال می‌شود و خروجی آموزشی ایجاد می‌شود و میانگین مربعات خطا محاسبه می‌شود و به عنوان میزان شایستگی کلاغ ذخیره می‌شود. مرحله تکرار: انتخاب والدین: در این گام بر اساس شایستگی اعضای جمعیت، دو کلاغی که بیش‌ترین شایستگی را دارند



شکل ۲- موقعیت کلاغ در الگوریتم یادگیری کلاغ



شکل ۳- ساختار سیستم استنتاج فازی - عصبی ANFIS



شکل ۴- فاز یادگیری و موقعیت جدید کلاغ پس از فاز یادگیری

است که میانگین مربعات خطای آن کمتر از بقیه اعضای جمعیت کلاغها است بنابراین شامل بهترین مقادیر مراکز توابع عضویت و وزنهای سیستم استنتاج فازی- عصبی تطبیقی است در این وضعیت آموزش سیستم استنتاج فازی- عصبی تطبیقی برای پیشبینی میزان آلاینده‌گی دی-اکسیدنیترژن به پایان رسیده است.

ارزیابی موقعیت کلاغ: تابع هدف فراخوانی شده و موقعیت کلاغ در توابع عضویت ورودی و وزنها در سیستم استنتاج فازی- عصبی تطبیقی قرار می‌گیرد سپس ورودیهای آموزشی به آن اعمال می‌شود و خروجی آموزشی ایجاد می‌شود و میانگین مربعات خطا محاسبه می‌شود و به عنوان میزان شایستگی کلاغ ذخیره می‌شود.

بررسی شرایط خاتمه: در این مرحله شرایط خاتمه تکرار بررسی می‌شود. خروجی الگوریتم عضوی از جمعیت کلاغها

نتایج شبیه‌سازی

در این بخش، کل کارهای پیاده‌سازی که در این تحقیق به‌دست آمده است از جمله نتایج پیاده‌سازی سیستم استنتاج فازی- عصبی تطبیقی آموزش‌یافته با الگوریتم یادگیری کلاغ به عنوان روش پیشنهادی و شبکه عصبی پایهای- شعاعی در پیش‌بینی غلظت آلاینده‌گی دی‌اکسیدنیترژن مورد بررسی قرار می‌گیرد .


نتایج پیش بینی غلظت آلاینده‌گی دی اکسید نیترژن با روش پیشنهادی

در استفاده از سیستم استنتاج فازی- عصبی تطبیقی آموزش‌یافته با الگوریتم یادگیری کلاغ در پیش‌بینی غلظت

آلاینده‌گی دی‌اکسیدنیترژن، پارامترهای اندازه جمعیت کلاغها برابر ۵۰ و حداکثر تعداد دفعات تکرار برابر ۵۰۰، نوع سیستم استنتاج فازی از نوع سوگنو و توابع عضویت ورودی گاوسی در نظر گرفته شده است و نتایج بر اساس انواع خطا مطابق جدول (۱) است. در شکل (۵) هیستوگرام خطا به ازای داده‌های آموزشی با رنگ قرمز و به ازای داده‌های آزمایشی با رنگ آبی نمایش داده شده است محور افقی مقدار خطا و محور عمودی فراوانی خطا در سیستم استنتاج فازی- عصبی تطبیقی آموزش یافته با الگوریتم یادگیری کلاغ را نشان می‌دهد.

جدول ۱- انواع خطا در روش پیشنهادی در پیش‌بینی NO2

	MSE	RMSE	MAE	SSE
Train Data	۰.۰۰۷۹	۰.۰۸۹	۰.۰۶۵	۶.۳۴۶
Test Data	۰.۰۰۸۹	۰.۰۹۴	۰.۰۷	۱.۷۹۲
All Data	۰.۰۰۸۱	۰.۰۹	۰.۰۶۶	۸.۱۳۸



آموزش‌یافته با الگوریتم یادگیری کلاغ ANFIS شکل ۵- هیستوگرام خطا به ازای داده‌های آموزشی و آزمایشی در

آموزشی نمایش داده شده است. محور افقی اندیس داده-ها و محور عمودی مقادیر دی‌اکسیدنیترژن هدف و پیش‌بینی شده نمایش داده شده است. در شکل (۶-ب) خروجیهای هدف با دایره‌های قرمز و خروجیهای سیستم


در شکل (۶-الف) خروجی‌های هدف با دایره‌های قرمز و خروجی‌های سیستم استنتاج فازی- عصبی تطبیقی آموزش‌یافته با الگوریتم یادگیری کلاغ در پیش‌بینی دی-اکسیدنیترژن با مربع‌های آبی رنگ به ازای داده‌های

نتایج پیش‌بینی غلظت آلاینده‌گی دی‌اکسیدنیترژن با

شبکه عصبی پایه‌ای- شعاعی

در استفاده از شبکه عصبی پایه‌ای- شعاعی در پیش‌بینی غلظت آلاینده‌گی دی‌اکسیدنیترژن، حداکثر تعداد نورون‌ها برابر ۲۰، نوع توابع شعاعی از نوع گاوسی و مقدار پارامتر پراکنده‌گی برابر ۱.۳ در نظر گرفته شده است و نتایج بر اساس انواع خطا مطابق جدول (۲) است. در شکل (۷) هیستوگرام خطا به ازای داده‌های آموزشی با رنگ قرمز و به ازای داده‌های آزمایشی با رنگ آبی نمایش داده شده است محور افقی مقدار خطا و محور عمودی فراوانی خطا در شبکه عصبی پایه‌ای- شعاعی را نشان می‌دهد.


استنتاج فازی- عصبی تطبیقی آموزش‌یافته با الگوریتم یادگیری کلاخ در پیش‌بینی دی‌اکسیدنیترژن با مربعهای آبی رنگ به ازای داده‌های آزمایشی نمایش داده شده است. محور افقی اندیس داده‌ها و محور عمودی مقادیر دی‌اکسیدنیترژن هدف و پیش‌بینی شده نمایش داده شده است. در شکل (۶-ج) خروجیهای هدف با دایره‌های قرمز و خروجیهای سیستم استنتاج فازی- عصبی تطبیقی آموزش‌یافته با الگوریتم یادگیری کلاخ در پیش‌بینی دی‌اکسیدنیترژن با مربعهای آبی رنگ به ازای کل داده‌ها نمایش داده شده است. محور افقی اندیس داده‌ها و محور عمودی مقادیر دی‌اکسیدنیترژن هدف و پیش‌بینی شده نمایش داده شده است.



آموزش‌یافته با الگوریتم یادگیری کلاخ به ازای داده‌های آموزشی (الف) و ANFIS شکل ۶- خروجیهای هدف و خروجیهای آزمایشی (ب) و کل داده‌ها (ج)

جدول ۲- انواع خطا در شبکه عصبی پایه‌ای- شعاعی در پیش‌بینی NO₂


	MSE	RMSE	MAE	SSE
Train Data	۰.۰۰۹۷	۰.۰۹۸	۰.۰۷۲	۷.۸۳۴
Test Data	۰.۰۱۱۶	۰.۱۰۸	۰.۰۸۲	۲.۳۳۴
All Data	۰.۰۱۰۱	۰.۱	۰.۰۷۴	۱۰.۱۶۹



شکل ۷- هیستوگرام خطا به ازای داده‌های آموزشی و آزمایشی در شبکه عصبی پایه‌ای- شعاعی

شده است. محور افقی اندیس داده‌ها و محور عمودی مقادیر دی‌اکسید نیتروژن هدف و پیش‌بینی شده نمایش داده شده است. در شکل (۱۲) خروجی‌های هدف با دایره‌های قرمز و خروجی‌های شبکه عصبی پایه‌ای- شعاعی در پیش‌بینی دی‌اکسید نیتروژن با مربع‌های آبی رنگ به ازای کل داده‌ها نمایش داده شده است. محور افقی اندیس داده‌ها و محور عمودی مقادیر دی‌اکسید نیتروژن هدف و پیش‌بینی شده نمایش داده شده است.

در شکل (۱۰) خروجی‌های هدف با دایره‌های قرمز و خروجی‌های شبکه عصبی پایه‌ای- شعاعی در پیش‌بینی دی‌اکسید نیتروژن با مربع‌های آبی رنگ به ازای داده‌های آموزشی نمایش داده شده است. محور افقی اندیس داده‌ها و محور عمودی مقادیر دی‌اکسید نیتروژن هدف و پیش‌بینی شده نمایش داده شده است. در شکل (۱۱) خروجی‌های هدف با دایره‌های قرمز و خروجی‌های شبکه عصبی پایه‌ای- شعاعی در پیش‌بینی دی‌اکسید نیتروژن با مربع‌های آبی رنگ به ازای داده‌های آزمایشی نمایش داده



شکل ۶- خروجی‌های هدف و خروجی‌های شبکه عصبی پایه‌ای- شعاعی به ازای داده‌های آموزشی (الف) و آزمایشی (ب) و کل داده‌ها

(ج)

الگوریتم یادگیری کلاخ و بدترین عملکرد متعلق به شبکه عصبی پایه‌ای- شعاعی است.

منابع

1. H. Seo and H. Lee, "How air pollutants influence on Environmental diseases?: Focused on Seoul Metropolitan Area," Seoul Studies, vol. 20, no. 3, pp. 39-59, 2019.
2. M. Greenstone and C. Fan, "Air quality life index, Annual Update," Energy Policy Institute at the University of Chicago: Chicago (IL) USA, vol. 1, 2020.
3. C. Li and S. Managi, "Estimating monthly global ground-level NO₂ concentrations using geographically weighted panel regression," Remote Sensing of Environment, vol. 280, p. 113152, 2022.
4. [4]. D. Iskandaryan, S. Di Sabatino, F. Ramos, and S. Trilles, "Exploratory Analysis and Feature Selection for the Prediction of Nitrogen Dioxide," AGILE: GIScience Series, vol. 3, pp. 1-11, 2022.
5. N. O. Lim, J. Hwang, S.-J. Lee, Y. Yoo, Y. Choi, and S. Jeon, "Spatialization and Prediction of Seasonal NO₂ Pollution Due to Climate Change in the Korean Capital Area through Land Use Regression Modeling," International Journal of Environmental Research and Public Health, vol. 19, no. 9, p. 5111, 2022.
6. S. R. Shams, A. Jahani, S. Kalantary, M. Moeinaddini, and N. Khorasani, "Artificial

نتیجه‌گیری

این مقاله مبتنی بر پیش‌بینی میزان آلاینده‌های دی‌اکسیدنیترژن با استفاده از روش‌های یادگیری ماشین است. در بخش دوم پیشینه تحقیق مرور شد و در بخش سوم الگوریتم یادگیری کلاخ، سیستم استنتاج فازی- عصبی تطبیق و شبکه عصبی پایه‌ای- شعاعی مرور شدند. در بخش چهارم به مراحل روش پیشنهادی در پیش‌بینی میزان آلاینده‌های دی‌اکسیدنیترژن پرداخته شد و در بخش پنجم شبیه‌سازی مسئله انجام و نتایج کمی و کیفی استفاده از سیستم استنتاج فازی- عصبی تطبیقی آموزش‌یافته با الگوریتم یادگیری کلاخ و شبکه عصبی پایه‌ای- شعاعی در پیش‌بینی میزان آلاینده‌های دی‌اکسیدنیترژن نمایش داده شد. با توجه به جداول (۱) و (۲) سیستم استنتاج فازی- عصبی تطبیقی آموزش‌یافته با الگوریتم یادگیری کلاخ و شبکه عصبی پایه‌ای- شعاعی به ترتیب با میانگین مربعات خطا ۰.۰۰۸۱ و ۰.۰۱۰۱ پیش‌بینی میزان آلاینده‌های دی‌اکسیدنیترژن را انجام دادند. بنابراین بهترین عملکرد متعلق به سیستم استنتاج فازی- عصبی تطبیقی آموزش‌یافته با

12. C. M. Dragomir, M. Voiculescu, D.-E. Constantin, and L. P. Georgescu, "Prediction of the NO₂ concentration data in an urban area using multiple regression and neuronal networks," in AIP Conference Proceedings, vol. 1694, no. 1: AIP Publishing LLC, p. 040003, 2015.
13. W. Al-Sorori and A. M. Mohsen, "New Caledonian crow learning algorithm: A new metaheuristic algorithm for solving continuous optimization problems," Applied Soft Computing, vol. 92, p. 106325, 2020.
14. A. Sabziparvar and M. B. Varkeshi, "Accuracy evaluation of ANN and Neuro-Fuzzy in global solar radiation," Iranian Journal of Physics Research, vol. 10, pp. 347-357, 2010.
15. W. Chen, Z.-J. Fu, and C.-S. Chen, Recent advances in radial basis function collocation methods. Springer, 2014.
16. I. Juhos, L. Makra, and B. Tóth, "Forecasting of traffic origin NO and NO₂ concentrations by Support Vector Machines and neural networks using Principal Component Analysis," Simulation Modelling Practice and Theory, vol. 16, no. 9, pp. 1488-1502, 2008.
- intelligence accuracy assessment in NO₂ concentration forecasting of metropolises air," Scientific Reports, vol. 11, no. 1, pp. 1-9, 2021.
7. R. Bhardwaj and D. Pruthi, "Development of model for sustainable nitrogen dioxide prediction using neuronal networks," International Journal of Environmental Science and Technology, vol. 17, no. 5, pp. 2783-2792, 2020.
8. J. A. Kamińska, "A random forest partition model for predicting NO₂ concentrations from traffic flow and meteorological conditions," Science of the Total Environment, vol. 651, pp. 475-483, 2019.
9. M. Masoudi and M. Gerami, "Status and prediction of NO₂ as an air pollutant in Isfahan, Iran," Fresenius Environmental Bulletin, vol. 27, pp. 2743-2750, 2018.
10. S. M. S. Cabaneros, J. K. S. Calautit, and B. R. Hughes, "Hybrid artificial neural network models for effective prediction and mitigation of urban roadside NO₂ pollution," Energy Procedia, vol. 142, pp. 3524-3530, 2017.
11. D. R. Michanowicz et al., "A hybrid land use regression/line-source dispersion model for predicting intra-urban NO₂," Transportation Research Part D: Transport and Environment, vol. 43, pp. 181-191, 2016.