

پیش‌بینی آلودگی ۲۴ ساعته غلظت آلاینده‌های هوا با استفاده از مدل ترکیبی شبکه عصبی بازگشتی در شهر همدان

صابر قاسمیان مظاهر^۱، علی رضا اسفندیاری مقدم^{۲*}، منصور اسماعیل پور^۳

۱- دانشجوی دکترای تخصصی مدیریت فناوری اطلاعات، دانشگاه آزاد اسلامی، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران.

۲- گروه علم اطلاعات و دانش شناسی، دانشگاه آزاد اسلامی، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران.

۳- گروه کامپیوتر، دانشگاه آزاد اسلامی، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران.

چکیده

آلودگی هوا از مهم‌ترین چالش‌های کلان‌شهرها به شمار می‌رود و پیامدهای جدی بر سلامت انسان و پایداری محیط زیست بر جای می‌گذارد. به‌کارگیری روش‌های دقیق و هوشمند در پیش‌بینی وضعیت آلودگی هوا می‌تواند نقش مؤثری در تصمیم‌گیری‌های مدیریتی و کاهش اثرات آلاینده‌ها ایفا کند. در این پژوهش با هدف تحلیل عوامل مؤثر بر افزایش آلاینده‌های هوا در شهر همدان، یک مدل ترکیبی مبتنی بر شبکه عصبی بازگشتی (RNN) توسعه داده شد. داده‌های مربوط به دو سال و نیم متوالی گردآوری و پس از پیش‌پردازش، برای آموزش مدل به کار گرفته شدند. این مدل با استفاده از داده‌های مربوط به آلاینده‌های $PM_{2.5}$ ، PM_{10} ، O_3 ، NO ، NO_x ، NO_2 ، SO_2 و CO ، در کنار پارامترهای جوی شامل دما، رطوبت، سرعت و جهت باد و همچنین داده‌های مرتبط با تردد خودروها و فرسودگی ناوگان حمل‌ونقل، توانست غلظت آلاینده‌ها را برای بازه زمانی ۲۴ ساعته آینده پیش‌بینی کند. نتایج نشان داد مدل پیشنهادی با دقتی بیش از ۹۷ درصد عملکردی قابل اعتماد داشته و می‌تواند به عنوان ابزاری کارآمد در مدیریت کیفیت هوا و حفاظت از سلامت عمومی مورد استفاده قرار گیرد.

کلید واژه‌ها: آلودگی هوا، پیش‌بینی، مدل‌سازی، شبکه عصبی بازگشتی، همدان.

مقدمه

رشد سریع شهرنشینی، گسترش فعالیت‌های صنعتی و افزایش وابستگی به وسایل نقلیه موتوری در شهرهای بزرگ و صنعتی، منجر به افت محسوس کیفیت هوا و تشدید آلودگی‌های زیست‌محیطی شده است. آلودگی هوا نه تنها سلامت انسان‌ها را تهدید می‌کند، بلکه آثار مخربی بر اکوسیستم‌ها و روند تغییرات اقلیمی دارد. این پدیده پیچیده و چندوجهی، حوزه‌های متنوعی از جمله فیزیک، شیمی، مهندسی، پزشکی و اقتصاد را در بر می‌گیرد و نیازمند بررسی‌های میان‌رشته‌ای است. تجربه‌ی زیسته‌ی افراد در شهرهای آلوده، از جمله ابتلا به بیماری‌های تنفسی یا مشاهده‌ی آسیب‌های انسانی ناشی از آلودگی، انگیزه‌ای قوی برای پرداختن به این موضوع فراهم کرده است. با توجه به اثرات زیان‌بار آلودگی هوا بر سلامت انسان و سایر موجودات زنده، این مسئله به یکی از اولویت‌های بهداشت عمومی تبدیل شده است (Espinosa 2005) و ((Brunekreef and Holgate 2002). مطالعات متعدد نشان داده‌اند که بین آلودگی هوا و شیوع بیماری‌های قلبی-عروقی و تنفسی ارتباط مستقیمی وجود دارد (Gorai, Tuluri, and Tchounwou 2014). در پاسخ به این چالش‌ها، پژوهشگران تلاش کرده‌اند با توسعه‌ی سامانه‌های پیش‌بینی آلودگی هوا، اطلاعات قابل اتکایی را در اختیار مدیران شهری، برنامه‌ریزان و عموم مردم قرار دهند. با توجه به ماهیت پیچیده و متغیر آلودگی هوا در ابعاد زمانی و مکانی، مدل‌سازی و پیش‌بینی آن با دشواری‌های خاصی همراه است ((Ross 2005. از این‌رو، استفاده از روش‌های نوین مانند هوش مصنوعی و مدل‌های فازی-عصبی مورد توجه قرار گرفته است؛ چرا که این روش‌ها توانایی بالایی در تحلیل سیستم‌های پیچیده و غیرخطی دارند. یکی از ابزارهای مؤثر در کاهش ابعاد داده‌ها و انتخاب ورودی‌های کلیدی، تحلیل مؤلفه‌های اصلی (PCA) است. این روش با ایجاد متغیرهای مستقل جدید، به ساده‌سازی فرآیند مدل‌سازی کمک می‌کند ((Sahoo, Patra, and Khatua 2015). همچنین، به دلیل رفتار غیرخطی و پیچیده‌ی تغییرات دما و غلظت آلاینده‌ها، روش‌های سنتی مدل‌سازی پاسخ‌گوی نیازهای پیش‌بینی دقیق نیستند (Statheropoulos, Vassiliadis, and Pappa 1998). بهره‌گیری از مدل‌های هوشمند در پیش‌بینی پدیده‌های پیچیده‌ی زیست‌محیطی، با توجه به پیچیدگی‌های ذاتی پدیده‌هایی مانند آلودگی هوا، مورد توجه قرار گرفته است.

استفاده از روش‌های هوشمند مبتنی بر شبکه‌های عصبی و سیستم‌های فازی-عصبی، به‌عنوان ابزارهایی کارآمد در مدل‌سازی و پیش‌بینی این فرآیندها شناخته شده‌اند ((Moussiopoulos, Sahm, and Kessler 1995). یکی از مدل‌های برجسته در این زمینه، سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) است که با ترکیب منطق فازی و توانایی یادگیری شبکه‌های عصبی، قابلیت بالایی در تحلیل و پیش‌بینی رفتارهای غیرخطی و پیچیده دارد (Kolehmainen et al. 2000). مطالعات متعدد نشان داده‌اند که الگوریتم‌های یادگیری تکاملی مانند الگوریتم ازدحام ذرات (PSO)، می‌توانند عملکرد شبکه‌های عصبی را بهبود بخشیده و از گیر افتادن در نقاط بهینه‌ی محلی جلوگیری کنند (Sahoo, Patra, and Khatua 2015; Statheropoulos, Vassiliadis, and Pappa 1998). همچنین، جلال کمالی (۲۰۱۵) با بهره‌گیری از مدل‌های ANFIS-GA و ANFIS-PSO توانست پارامترهای کیفی آب زیرزمینی در دشت کرمان را با دقت بالا تخمین بزند ((Jang and others 1992). در حوزه‌ی پیش‌بینی دما نیز مطالعات مشابهی صورت گرفته است. برای مثال، صلاحی و همکاران با استفاده از شبکه‌ی عصبی پرسپترون چندلایه (MLP)، موفق به پیش‌بینی حداکثر دمای شهر اردبیل شدند ((Jalalkamali 2015). تکتاز نیز با بهره‌گیری از مدل‌های ANFIS و ARIMA، حداکثر دمای ترکیه را پیش‌بینی کرده و عملکرد برتر ANFIS را نشان داد ((Salahi et al. 2010). قربانی و همکاران با استفاده از مدل‌های ANFIS، ANN و GP توانستند دمای حداکثر، حداقل و میانگین شهر تبریز را با دقت بالا پیش‌بینی کنند (Tektaş 2010). در سال‌های اخیر، تمرکز پژوهش‌ها به سمت مدل‌های یادگیری عمیق و ترکیبی سوق یافته است تا دقت پیش‌بینی آلودگی هوا افزایش یابد. یکی از رویکردهای مؤثر در این زمینه، مدل ترکیبی CNN-LSTM است که به دلیل توانایی در تحلیل داده‌های زمانی و مکانی، به‌ویژه در پیش‌بینی غلظت آلاینده‌هایی مانند PM_{2.5}، عملکرد قابل توجهی داشته است. مطالعه Bekkar و همکاران (Ghorbani et al. 2012) نشان داد که استفاده از مدل CNN-LSTM در پیش‌بینی آلودگی هوای شهر پکن، با ترکیب داده‌های جوی و اطلاعات ایستگاه‌های مجاور، موجب افزایش چشمگیر دقت پیش‌بینی شده است. همچنین، Zhao و همکاران (Bekkar et al. 2021) با بهره‌گیری از شبکه‌های عصبی بازگشتی دوطرفه

(Huang and Kuo 2018) و (Garg and Jindal 2021) در مطالعه‌ای حقیقیان، س. و همکاران، ۱۴۰۲) نتایج پژوهش نشان‌دهنده‌ی اثرات بهداشتی ناشی از آلودگی هوا در کلان‌شهرها بوده است؛ از جمله افزایش میزان کل مرگ‌ومیر، مرگ‌های قلبی-عروقی و تنفسی، و بستری‌شدن در بیمارستان به‌علت بیماری انسداد مزمن ریوی و سکته‌ی قلبی. این یافته‌ها بیانگر روند افزایشی آلودگی هوا در مناطق شهری هستند (۱۴۰۲). در پژوهش محمد رحیم رمضان، اسماعیل رمضان پور روش شبکه‌های عصبی فازی نسبت به سایر روش‌ها از قدرت بالایی در شناسایی روندهای موجود در داده‌ها برخوردار است و در تمامی روش‌های اندازه‌گیری خطا، نسبت به سایر روش‌ها خطای کمتری دارد. نتایج تحقیق نشان می‌دهد که این روش، با توجه به میزان پایین خطا، دارای همگرایی سریع و توانایی تقریب بالایی است و برای پیش‌بینی قیمت نفت مناسب ارزیابی می‌شود. علاوه بر این، با توجه به میزان خطای هر یک از روش‌ها، نتایج نشان می‌دهد روش‌هایی که از میانگین داده‌های قبلی به همراه یک یا دو ضریب تصحیح (آلفا و بتا) استفاده می‌کنند، نسبت به روش‌هایی که بر پایه یک تابع خطی، نمایی یا ترکیبی و یک روند ثابت به پیش‌بینی می‌پردازند، عملکرد بهتری دارند. در تحقیق بر اساس پژوهش‌های انجام‌شده توسط امیرحسین حلبیان و محمد، داده‌های پیش‌بینی‌شده‌ی بارش ماهانه با استفاده از شبکه‌ای با ساختار و معماری خاص، تطابق قابل‌توجهی با داده‌های واقعی دارند. نتایج حاصل از آموزش مجدد شبکه و آزمون آن با لایه‌های پنهان و ضرایب یادگیری متنوع، در ترکیب با الگوریتم ژنتیک، نشان داد که این ترکیب موجب کاهش خطای پیش‌بینی و افزایش سرعت محاسبات می‌شود. در پژوهش فریده سبحانی فرد و همکاران استفاده از روش MCGA در بهینه‌سازی پیش‌بینی رشد اقتصادی با شبکه عصبی مصنوعی، از الگوریتم ژنتیک ترکیبی با میانگین متحرک (MCGA) به‌منظور بهینه‌سازی نتایج حاصل از شبکه عصبی مصنوعی در تحلیل سری‌های زمانی و پیش‌بینی رشد اقتصادی استفاده شده است. به‌منظور آموزش شبکه عصبی، از شبیه‌سازی مونت‌کارلو بهره گرفته شد تا دقت مدل در پیش‌بینی داده‌های سری زمانی افزایش یابد. آموزش مبتنی بر الگوریتم‌های تکاملی به‌عنوان روشی مؤثر برای کنترل پیچیدگی مدل‌ها در نظر گرفته شده است. در پژوهش، مهرداد رفیع پور، علی اصغر آل‌شیخ از داده‌های مربوط به غلظت‌های گذشته آلاینده مونوکسید کربن

(Bi-LSTM) که اطلاعات زمانی گذشته و آینده را هم‌زمان پردازش می‌کنند، عملکرد بهتری نسبت به مدل‌های سستی مانند ARIMA در پیش‌بینی غلظت آلاینده‌ها ارائه کردند. در مجموع، مدل‌های یادگیری عمیق مانند CNN-LSTM، به دلیل توانایی بالا در استخراج ویژگی‌های پیچیده از داده‌های چندبعدی، نسبت به روش‌های سستی دقت بیشتری در پیش‌بینی غلظت آلاینده‌هایی نظیر PM_{2.5} دارند و می‌توانند نقش مؤثری در مدیریت کیفیت هوا ایفا کنند. به‌عنوان نمونه، مطالعه‌ای توسط Delavar و همکاران ((Zhao et al. 2019) در خصوص آلودگی هوای تهران نشان داد که مدل‌های یادگیری ماشین، به‌ویژه شبکه‌های عصبی خودبازگشتی غیر خطی (NARX)، در مقایسه با مدل‌های رگرسیون معمولی، نتایج دقیق‌تری ارائه می‌دهند. این نتایج گواهی بر توانایی مدل‌های یادگیری عمیق در ارائه‌ی پیش‌بینی‌های دقیق‌تر و کاربردی‌تر هستند. البته، بسیاری از پژوهش‌ها به برخی از محدودیت‌ها و چالش‌های این روش‌ها نیز اشاره کرده‌اند. برای نمونه، مدل‌های یادگیری عمیق مانند Bi-LSTM و LSTM، به دلیل پیچیدگی بالای محاسباتی و نیاز به داده‌های حجیم برای آموزش، با مشکلاتی همچون افزایش زمان محاسباتی و نیاز به منابع پردازشی بالا روبه‌رو هستند (Delavar et al. 2019). طراحی مدل ترکیبی برای پیش‌بینی آلودگی هوا با رویکرد داده‌محور، یکی از چالش‌های اساسی در این حوزه است. یکی از محدودیت‌های مدل‌هایی که صرفاً بر داده‌های محلی تکیه دارند، غفلت از تأثیر جابه‌جایی آلاینده‌ها از مناطق مجاور است. همان‌طور که در مطالعه‌ی Xayasouk و همکاران (Salman et al. 2018) نیز اشاره شده، این محدودیت‌ها می‌تواند دقت و تعمیم‌پذیری مدل‌های پیش‌بینی را کاهش دهد. برای ارتقاء عملکرد این مدل‌ها، پژوهش‌های اخیر پیشنهاد داده‌اند که از داده‌های چندمنظوره شامل اطلاعات جوی، ترافیکی و سوابق تاریخی آلودگی استفاده شود. به‌عنوان نمونه، Huang و همکاران ((Xayasouk, Lee, and Lee 2020) نشان دادند که ادغام داده‌های مکانی از ایستگاه‌های هم‌جوار، موجب بهبود قابل توجهی در دقت پیش‌بینی می‌شود. ترکیب مدل‌های یادگیری عمیق با الگوریتم‌های دیگر نیز رویکردی مؤثر در کاهش خطاهای محاسباتی و افزایش دقت پیش‌بینی به شمار می‌رود. مدل‌هایی مانند CNN-GRU توانسته‌اند با بهره‌گیری از ویژگی‌های مکانی و زمانی، عملکرد قابل‌قبولی ارائه دهند.

روش پیشنهادی

در این پژوهش، به‌منظور طراحی یک مدل پیش‌بینی دقیق برای آلودگی هوای شهر همدان، ابتدا داده‌های مربوط به غلظت آلاینده‌ها و پارامترهای جوی از مجمع پایگاه های ثبت اطلاعات و اخذ داده از هشت نقطه در استان همدان با اخذ مجوزهای لازم از مراجع ذی‌ربط، از مرکز هواشناسی - محیط زیست استان همدان جمع‌آوری گردید. داده‌های اولیه شامل اطلاعات مربوط به آلاینده‌های PM_{10} ، $PM_{2.5}$ ، NO ، O_3 ، NO_2 ، NO_x و CO ، به‌همراه متغیرهای جوی نظیر دما، رطوبت، سرعت و جهت باد بودند. در مرحله نخست، داده‌ها مورد پالایش و تحلیل مقدماتی قرار گرفتند؛ داده‌های ناقص یا نامشخص حذف شده و داده‌های باقی‌مانده با استفاده از روش‌های استاندارد نرمال‌سازی و مرتب‌سازی، برای ورود به مدل آماده شدند. سپس، مدل شبکه عصبی بازگشتی (RNN) به عنوان چارچوب اصلی پیش‌بینی انتخاب و پیاده‌سازی شد. این مدل با بهره‌گیری از قابلیت‌های یادگیری توالی‌محور، توانایی بالایی در تحلیل داده‌های غیرخطی و وابسته به زمان دارد و برای پیش‌بینی غلظت آلاینده‌ها در بازه‌های زمانی آینده مناسب است. در مراحل بعدی، فرآیند آموزش مدل با استفاده از داده‌های تاریخی انجام شد و عملکرد آن از طریق آزمایش‌های متعدد مورد ارزیابی قرار گرفت. برای سنجش دقت مدل، خروجی‌های پیش‌بینی‌شده با داده‌های واقعی مقایسه گردید و میزان خطای پیش‌بینی با استفاده از شاخص‌های آماری مناسب محاسبه شد. در ادامه، تنظیمات مدل به‌گونه‌ای بهینه‌سازی شد که بتواند عوامل مؤثر در انتشار و تغییرات آلودگی هوا را با دقت بالا شناسایی و پیش‌بینی کند. در فلوچارت شماره ۱، روند اجرای مراحل مختلف این پژوهش از مرحله جمع‌آوری داده‌ها تا آموزش، آزمایش و ارزیابی مدل، به‌صورت گام‌به‌گام نمایش داده شده است.


موقعیت شهر همدان

جمعیت کل استان همدان ۱,۸۸۲,۱۲۳ نفر و ۳۷۴,۶۰۰ خانوار است. سهم قابل توجهی از آلودگی هوا به دلیل سوزاندن سوخت‌های فسیلی مانند زغال سنگ، نفت، بنزین و گاز برای تولید انرژی برق یا حمل‌ونقل است. مونوکسید کربن بالا ناشی از مصرف سوخت فسیلی، آلاینده‌های سمی را در هوا منتشر می‌کند. در شکل ۱، نمایی از نقشه استان همدان نشان داده شده است.

به‌همراه اطلاعات هواشناسی و ترافیکی موجود استفاده شد تا بتوان میزان این آلاینده را در بازه زمانی ۲۴ ساعت آینده پیش‌بینی کرد. برای این منظور، شبکه عصبی مصنوعی به‌کار گرفته شد که با بهره‌گیری از روش‌های محاسباتی پیشرفته، دقت مطلوبی در پیش‌بینی ارائه داد. شبکه عصبی مورد استفاده، از نوع غیرخطی و با ساختار چندلایه بوده و نسبت به مدل‌های کلاسیک آماری، عملکرد بهتری در شناسایی الگوهای پیچیده و غیرخطی از خود نشان داده است. این روش، با تکیه بر داده‌های تجربی و الگوریتم‌های یادگیری، توانایی بالایی در تقریب و پیش‌بینی مقادیر آلاینده‌ها دارد. بررسی مطالعات مشابه نشان می‌دهد که استفاده از روش‌های محاسباتی پیشرفته مانند شبکه‌های عصبی، الگوریتم‌های ژنتیک و شبیه‌سازی مونت‌کارلو، در سال‌های اخیر رشد چشمگیری داشته و به‌عنوان ابزارهای مؤثر در مدل‌سازی و پیش‌بینی داده‌های محیطی شناخته می‌شوند، استفاده از الگوریتم درخت تصادفی نتایج بهتری نسبت به مدل‌های پایه مانند Dummy ارائه کرده است. همچنین، پژوهش کرمی و همکاران (کرمی et al. 2023) با بهره‌گیری از رویکرد ترکیبی، به ارزیابی معیارهای مؤثر در پیش‌بینی آلودگی هوا پرداخته و نشان داده‌اند که ترکیب الگوریتم جنگل تصادفی (RF) با الگوریتم ژنتیک (GA)، نسبت به مدل ماشین بردار پشتیبان (SVM) عملکرد بهتری دارد. در مجموع، استفاده از مدل‌های ترکیبی یادگیری ماشین و داده‌های چندمنظوره می‌تواند راهکاری مؤثر برای افزایش دقت و کاهش پیچیدگی محاسباتی در پیش‌بینی آلودگی هوا باشد. با این حال، بهره‌گیری از روش‌های مبتنی بر یادگیری عمیق، مستلزم دسترسی به پایگاه داده‌های حجیم و دقیق است. به‌عنوان مثال، در برخی مطالعات، نمونه‌برداری با نرخ ۶۰ بار در ساعت برای یک سال کامل انجام شده که منجر به تولید بانک داده‌ای بسیار بزرگ شده است. با توجه به محدودیت‌های موجود در تجهیزات و فرآیند داده‌گیری در بسیاری از مناطق، استفاده از چنین روش‌هایی در عمل با دشواری‌های جدی مواجه است. در پژوهش حاضر، با در نظر گرفتن محدودیت‌های داده‌ای، یک مدل ترکیبی مبتنی بر تحلیل داده‌ها و شبکه عصبی بازگشتی (RNN) برای پیش‌بینی آلودگی هوای شهر همدان طراحی شده است.



فلوچارت ۱: روند اجرای روش پیشنهادی به منظور پیش بینی آلودگی هوا



شکل ۱: شمایی از نقشه استان همدان و سهم میزان انتشار آلاینده ها

عوامل آلودگی هوا در شهر همدان

ذرات معلق و ترکیبات شیمیایی، غالباً نامرئی هستند و همین ویژگی موجب می‌شود که بسیاری از شهروندان نسبت به سطح واقعی آلودگی و پیامدهای آن آگاهی کافی نداشته باشند. در یک دسته‌بندی کلی، منابع آلاینده در شهرهای مختلف استان همدان ثبت شده در سازمان محیط زیست و هواشناسی ثبت شده و به به شش گروه اصلی تقسیم می‌شوند:

افزایش مداوم آلاینده‌های هوا در مناطق شهری و صنعتی استان همدان، موجب شده است که دسترسی به هوای پاک و سالم به چالشی جدی تبدیل شود. این وضعیت، نگرانی‌های گسترده‌ای را در حوزه سلامت عمومی و پایداری زیست‌محیطی به‌وجود آورده است. آلاینده‌های هوا، به‌ویژه

نوع آلاینده ها	منابع انتشار	سهم تقریبی در آلودگی
آلاینده های حمل و نقل	خودرو های شخصی و خصوصی	بیش از ۶۰٪
آلاینده های صنعتی	کارخانه ها و واحد های خصوصی	۱۵٪ تا ۳۰٪
آلاینده های مسکونی	سیستم های گرمایشی و مصرف انرژی	تا ۱۵٪
آلاینده های کشاورزی	سوزاندن بقایای گیاهی کود شیمیایی	کمتر از ۵٪
آلاینده های نیروگاهی	احتراق سوخت های فسیلی در نیروگاه	متغیر و وابسته به منطقه
مخاطرات طبیعی	گرد و غبار ، آتش سوزی ، فوران آتشفشان	کمتر از ۵٪

مانند مونوکسید کربن، هیدروکربن‌ها، اکسیدهای نیتروژن و ذرات معلق دارند. این آلاینده‌ها نه تنها موجب آسیب به لایه ازن می‌شوند، بلکه با ایجاد مشکلات تنفسی و قلبی، سلامت عمومی را تهدید می‌کنند.

عوامل کلیدی مؤثر در آلودگی هوای همدان به شرح زیر هستند:

- **حمل و نقل شهری:** وسایل نقلیه موتوری، به‌ویژه خودروهای بنزینی، سهم عمده‌ای در انتشار آلاینده‌هایی

افزایش غلظت آلاینده‌ها می‌شوند، هرچند سهم آن‌ها در همدان کمتر از ۵٪ برآورد شده است.


شرایط جوی و اقلیمی: عوامل اقلیمی مانند دما، رطوبت، سرعت و جهت باد، نقش مهمی در پراکندگی یا تجمع آلاینده‌ها دارند. برای مثال، در شرایط سکون هوا، غلظت آلاینده‌ها در یک منطقه می‌تواند به‌طور چشمگیری افزایش یابد. نمودار دایره‌ای (۲) توزیع نسبی سهم هر یک از منابع آلاینده را به‌صورت بصری نمایش می‌دهد و درک بهتری از فراوانی و پراکندگی آن‌ها در سطح شهر همدان ارائه می‌کند.

• **گازهای سمی و ذرات معلق:** ناشی از احتراق سوخت‌های فسیلی و فعالیت‌های صنعتی، این ترکیبات به‌دلیل اندازه میکروسکوپی‌شان به‌راحتی وارد سیستم تنفسی شده و بیماری‌هایی نظیر آسم، برونشیت و بیماری‌های قلبی را تشدید می‌کنند.

• **فعالیت‌های روزمره انسانی:** استفاده بی‌رویه از وسایل نقلیه شخصی، سیستم‌های گرمایشی و مصرف انرژی در زندگی شهری، سهم قابل توجهی در افزایش آلودگی هوا دارد.

• **منابع طبیعی:** دیده‌هایی مانند گرد و غبار، آتش‌سوزی جنگل‌ها و فوران‌های آتشفشانی نیز در برخی مواقع موجب

سهم آلاینده‌های هوا در همدان



شکل ۲: نمودار دایره‌ای توزیع آلاینده‌ها در همدان

موجب گرایش گسترده شهروندان به استفاده از خودروهای شخصی شده است. این روند منجر به افزایش ترافیک، مصرف سوخت و در نتیجه، تولید آلاینده‌های بیشتر شده است.

• **فرسودگی ناوگان حمل‌ونقل عمومی:** بیش از ۸۶٪ از ناوگان حمل‌ونقل عمومی کشور دچار فرسودگی هستند. خودروهای قدیمی با استانداردهای پایین زیست‌محیطی، سهم قابل توجهی در انتشار گازهای سمی مانند مونوکسید کربن، اکسیدهای نیتروژن و ذرات معلق دارند.

• **ترافیک سنگین و توقف‌های مکرر:** در شرایط ترافیکی، خودروها اغلب در حالت درجا کار می‌کنند که این امر

افزایش چشم‌گیر تعداد خودروهای شخصی در شهرهای ایران، به‌ویژه در کلان‌شهرهایی مانند تهران، اصفهان و مشهد، به یکی از عوامل اصلی در تشدید آلودگی هوا تبدیل شده است. بر اساس آمار رسمی، منابع متحرک شامل خودروهای سواری، موتورسیکلت‌ها و وسایل نقلیه عمومی، بیش از ۶۰٪ از ذرات معلق و حدود ۸۲٪ از گازهای آلاینده موجود در هوا را تولید می‌کنند.

دلایل اصلی تأثیرگذاری منابع متحرک بر آلودگی هوا عبارت‌اند از:

• **افزایش تعداد خودروهای شخصی:** رشد جمعیت شهری و ضعف زیرساخت‌های حمل‌ونقل عمومی،

منجر به مصرف بیشتر سوخت و افزایش انتشار آلاینده‌ها می‌شود.

- **کیفیت پایین سوخت و ضعف در نظارت فنی:** سوخت‌های مصرفی در بسیاری از خودروها فاقد استانداردهای لازم هستند و نبود نظارت مؤثر بر اجرای معاینه فنی، موجب افزایش آلودگی ناشی از عملکرد نامناسب خودروها شده است. مجموع این عوامل، نقش منابع متحرک را به‌عنوان یکی از مؤثرترین عوامل در آلودگی هوای شهری تثبیت کرده‌اند. بنابراین، اصلاح سیاست‌های حمل‌ونقل، نوسازی ناوگان، ارتقاء کیفیت سوخت و توسعه حمل‌ونقل عمومی می‌تواند نقش مهمی در کاهش آلودگی هوا و بهبود کیفیت زندگی شهری ایفا کند.

بانک داده

بانک داده آلودگی هوا در استان همدان مورد استفاده در این پژوهش توسط سازمان محیط زیست و سازمان هواشناسی استان همدان تهیه شده و شامل مجموعه‌ای جامع از اطلاعات

محیطی و جوی منطقه $PM_{2.5}$ ، PM_{10} ، O_3 ، NO ، NO_x ، NO_2 ، SO_2 است. این پایگاه داده با نظارت مستمر و به‌روزرسانی دوره‌ای، داده‌های مربوط به غلظت آلاینده‌های هوا را که در ایستگاه‌های با دستگاه‌های سنجش مختلف مانند نمونه بردار از ذرات هوا pm_{10} و $pm_{2.5}$ - آنالیزر گاز حاصل از احتراق CO_2 - پایش گرد و غبار - آنالیزر چند منظوره testo ... انجام شده و اندازه‌گیری می‌شوند، و علاوه بر داده‌های مربوط به آلاینده‌ها، اطلاعات هواشناسی نظیر دما، رطوبت نسبی، سرعت و جهت باد نیز در این بانک ثبت شده و در کنار داده‌های کیفی هوا ذخیره می‌شوند. این ترکیب داده‌ای امکان تحلیل هم‌زمان تأثیر عوامل جوی بر غلظت آلاینده‌ها را فراهم می‌سازد. بانک داده مذکور به‌عنوان منبعی ارزشمند برای پژوهشگران، تحلیلگران و مدیران شهری، بستری مناسب برای مطالعه روندهای آلودگی هوا، طراحی مدل‌های پیش‌بینی و تدوین راهکارهای زیست‌محیطی فراهم کرده است. دسترسی به این داده‌ها پس از انجام هماهنگی‌های لازم و پذیرش تعهدات اخلاقی و پژوهشی، در اختیار نویسندگان این تحقیق قرار گرفت (جدول ۱).

جدول ۱- ویژگی‌های آماری داده‌های مورد استفاده

متغیر	واحد اندازه‌گیری	حداقل مقدار	حداکثر مقدار	میانگین	انحراف معیار
$PM_{2.5}$	$\mu g/m^3$	5	180	62.4	28.7
PM_{10}	$\mu g/m^3$	10	250	95.3	40.2
O_3	ppb	2	110	38.6	18.5
NO	ppb	1	120	42.1	20.9
NO_2	ppb	3	130	55.7	25.3
NO_x	ppb	6	210	97.4	41.8
SO_2	ppb	2	90	24.6	12.1
CO	ppm	0.2	12.0	3.8	1.9
دما	$^{\circ}C$	-10	38	18.7	9.4
رطوبت نسبی	%	15	95	52.3	20.6
سرعت باد	m/s	0.2	12.5	3.4	1.7
جهت باد	درجه	0	360	—	—
حجم تردد خودرو	دستگاه/ساعت	120	950	465.2	210.7

شاخص کیفیت هوا و آلاینده‌های اصلی

شاخص کیفیت هوا (AQI) ابزاری استاندارد برای سنجش و گزارش وضعیت آلودگی هوا در مناطق مختلف است که بر اساس اندازه‌گیری غلظت آلاینده‌های گوناگون تعیین می‌شود. این شاخص به‌طور مستقیم با سلامت عمومی ارتباط دارد و به‌صورت عددی و رنگی، میزان خطر آلودگی را برای عموم مردم نمایش می‌دهد.

مهم‌ترین آلاینده‌هایی که در محاسبه AQI نقش دارند عبارت‌اند از:
۱- ذرات معلق $PM_{2.5}$ و PM_{10} : این ذرات از جمله اصلی‌ترین آلاینده‌های هوا هستند که در بسیاری از ایستگاه‌های نظارتی اندازه‌گیری می‌شوند. ورود این ذرات به دستگاه تنفسی می‌تواند منجر به بروز بیماری‌های ریوی، قلبی و التهابی شود.

ویژگی‌ها در یک مقیاس یکنواخت قرار گیرند. فرمول این تبدیل به صورت زیر است:

$$X_{\text{norm}} = \frac{X - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}}$$

که در آن:

- X مقدار اصلی داده،
- X_{min} کمترین مقدار در مجموعه داده،
- X_{max} بیشترین مقدار در مجموعه داده،
- و X_{norm} مقدار نرمال‌شده است.

این روش در پروژه حاضر برای آماده‌سازی داده‌های ورودی به مدل شبکه عصبی بازگشتی (RNN) مورد استفاده قرار گرفته است.

رابطه نرمال‌سازی به صورت رابطه (۱) است:

$$X_{\text{normalize}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (1)$$

نرمال‌سازی داده‌ها و آماده‌سازی برای مدل‌سازی

در مرحله پیش‌پردازش داده‌ها، نرمال‌سازی به عنوان یکی از گام‌های کلیدی برای افزایش دقت مدل و کاهش تأثیر مقادیر ناهمگون مورد استفاده قرار گرفت. از آنجا که داده‌های مربوط به آلودگی هوا و پارامترهای جوی دارای واحدها و مقیاس‌های متفاوتی هستند، نرمال‌سازی به یکسان‌سازی این مقیاس‌ها کمک می‌کند و از غلبه متغیرهای با دامنه عددی بزرگ بر فرآیند یادگیری جلوگیری می‌نماید. در این پژوهش، از روش مقیاس‌بندی کمینه-بیشینه (Min-Max Scaling) استفاده شده است. در این روش، مقدار اصلی داده x با استفاده از کمترین مقدار x_{min} و بیشترین مقدار x_{max} در مجموعه داده، به مقدار نرمال‌شده $x_{\text{normalize}}$ در بازه $[0, 1]$ تبدیل می‌شود. این تبدیل نه تنها موجب هم‌مقیاس شدن داده‌ها می‌شود، بلکه حساسیت مدل نسبت به داده‌های پرت را نیز کاهش می‌دهد و موجب بهبود عملکرد مدل در مراحل آموزش و پیش‌بینی می‌گردد.

مدل‌سازی با استفاده از شبکه‌های عصبی بازگشتی

پس از آماده‌سازی داده‌ها، مرحله بعدی بر اساس فلوچارت (۱)، طراحی و پیاده‌سازی مدل پیش‌بینی با استفاده از شبکه‌های عصبی بازگشتی (RNN) است. شبکه‌های عصبی

۲- ازن (O_3) در سطح زمین، ازن به عنوان یک آلاینده خطرناک شناخته می‌شود که به‌ویژه در فصل تابستان و شرایط جوی گرم، غلظت آن افزایش می‌یابد و می‌تواند موجب تحریک مجاری تنفسی شود.

۳- اکسیدهای نیتروژن NO ، NO_2 ، NO_x این گازها عمدتاً از احتراق سوخت‌های فسیلی و ترافیک وسایل نقلیه تولید می‌شوند و اثرات مخربی بر سلامت دستگاه تنفسی دارند.

۴- دی‌اکسید گوگرد (SO_2) حاصل فعالیت‌های صنعتی و احتراق سوخت‌های فسیلی است و می‌تواند موجب تشدید بیماری‌های تنفسی و تحریک مجاری هوایی شود.

۵- مونوکسید کربن (CO) این گاز بی‌رنگ و بی‌بو، در اثر احتراق ناقص سوخت‌ها تولید می‌شود و در غلظت‌های بالا می‌تواند منجر به مسمومیت شدید و اختلال در انتقال اکسیژن در بدن شود (جدول ۱).

ایستگاه‌های نظارت بر کیفیت هوا، غلظت این آلاینده‌ها را به صورت مداوم ثبت می‌کنند تا با استفاده از شاخص AQI ، وضعیت هوای مناطق مختلف را ارزیابی و اطلاع‌رسانی کنند.


نرمال‌سازی داده‌ها

نرمال‌سازی داده‌ها یکی از مراحل کلیدی در پیش‌پردازش اطلاعات است که نقش مهمی در افزایش دقت مدل‌های یادگیری ماشین و کاهش تأثیر مقادیر ناهمگون دارد. در تحلیل داده‌های محیطی و آلودگی هوا، متغیرها از واحدها و مقیاس‌های متفاوتی برخوردارند؛ برای مثال، غلظت آلاینده‌ها بر حسب میکروگرم بر متر مکعب اندازه‌گیری می‌شود، در حالی که دما بر حسب درجه سانتی‌گراد و رطوبت به صورت درصد بیان می‌شود. در صورت عدم نرمال‌سازی، متغیرهایی با مقادیر عددی بزرگ‌تر می‌توانند تأثیر نامتناسبی بر عملکرد مدل داشته باشند و موجب سوگیری در فرآیند یادگیری شوند. نرمال‌سازی این مشکل را برطرف کرده و موجب بهبود همگرایی مدل و افزایش دقت پیش‌بینی می‌شود. یکی از رایج‌ترین روش‌های نرمال‌سازی، مقیاس‌بندی کمینه-بیشینه (Min-Max Scaling) است. در این روش، داده‌ها به یک بازه مشخص (معمولاً بین ۰ و ۱) تبدیل می‌شوند تا تمامی


می‌کنند. این ساختار به‌ویژه برای داده‌های محیطی و زمانی مانند غلظت آلاینده‌ها مناسب است، زیرا قادر است الگوهای پنهان در داده‌های متوالی را شناسایی کرده و پیش‌بینی‌های دقیق‌تری ارائه دهد. در شکل ۱، نمایی زیستی از یک نورون مصنوعی و اجزای آن به‌صورت شماتیک نمایش داده شده است.

یادگیری، ویژگی اصلی این سیستم‌هاست که آن‌ها را انعطاف‌پذیر و قادر به حل مسائل جدید می‌سازد. مدل اولیه ریاضی نرون در شکل ۴ ارائه شده است.

مصنوعی، سامانه‌هایی برای پردازش داده‌های پیچیده هستند که از ساختار عصبی مغز انسان الهام گرفته‌اند. این شبکه‌ها شامل مجموعه‌ای از گره‌های پردازشی (نورون‌های مصنوعی) هستند که به‌صورت موازی و یکپارچه برای حل مسائل عمل می‌کنند. در ساختار RNN، گره‌ها به‌صورت توالی‌محور به یکدیگر متصل‌اند و قادرند وابستگی‌های زمانی بین داده‌ها را تحلیل کنند. هر گره می‌تواند فعال یا غیرفعال باشد و اتصالات بین گره‌ها دارای وزن‌هایی هستند که در فرآیند آموزش به‌روزرسانی می‌شوند. یال‌هایی با وزن مثبت موجب فعال‌سازی گره‌ها شده و یال‌های با وزن منفی آن‌ها را غیرفعال



شکل ۳: شمایی از یک نرون به همراه اجزای ورودی، خروجی، هسته و پشته



شکل ۴: شمایی از مدل اولیه نرون

آموزش شبکه، فرآیندی است که طی آن، وزن‌های بهینه برای ورودی‌ها تعیین می‌شود تا خروجی نهایی کمترین خطا را نسبت به مقدار مطلوب داشته باشد. در آغاز آموزش، وزن‌ها به‌صورت تصادفی مقداردهی می‌شوند و طی فرآیند یادگیری، به مقادیر بهینه نزدیک‌تر می‌شوند. پس از آموزش، شبکه وارد مرحله آزمایش می‌شود. در این مرحله، شبکه ورودی‌های جدید (نمونه‌های آزمایش) را دریافت کرده و خروجی آن‌ها را تخمین می‌زند.

اطلاعات از طریق ورودی‌ها (دندریت‌ها) به نرون وارد می‌شوند که مقادیر آن‌ها به‌صورت $(x_1, x_2, \dots, x_m)$ نمایش داده می‌شود. در شبکه عصبی مصنوعی، به هر ورودی یک وزن $(w_1, w_2, \dots, w_m)$ اختصاص داده می‌شود، که نشان‌دهنده اهمیت هر ورودی است. ورودی‌ها پس از ضرب در وزن‌هایشان با هم جمع شده (Σ) و به خروجی نرون (آکسون) منتقل می‌شوند. سپس تابع فعالیت بر این مجموع اعمال می‌شود.

خروجی این فرآیند از طریق سیناپس‌ها به نرون‌های دیگر منتقل شده و این عملیات تا لایه خروجی ادامه پیدا می‌کند.

ساختار نورون مصنوعی و فرآیند یادگیری در شبکه‌های عصبی بازگشتی

در شبکه‌های عصبی مصنوعی، اطلاعات از طریق ورودی‌ها (معادل دندریت‌ها در نورون زیستی) وارد نورون می‌شوند. این ورودی‌ها به صورت برداری از مقادیر عددی نمایش داده می‌شوند:

$$(x_1, x_2, \dots, x_m)$$

به هر ورودی، یک وزن متناظر اختصاص داده می‌شود:

$$(w_1, w_2, \dots, w_m)$$

که بیانگر اهمیت نسبی هر ورودی در فرآیند تصمیم‌گیری نورون است. سپس، مجموع وزنی ورودی‌ها محاسبه می‌شود:

$$z = \sum_{i=1}^m w_i x_i$$

این مقدار z به تابع فعال‌سازی (Activation Function)

وارد می‌شود تا خروجی نهایی نورون تولید گردد. خروجی حاصل از این فرآیند از طریق سیناپس‌ها به نورون‌های دیگر منتقل شده و این عملیات تا رسیدن به لایه خروجی شبکه ادامه می‌یابد. فرآیند آموزش شبکه شامل تنظیم وزن‌ها به گونه‌ای است که خروجی مدل با مقدار مطلوب (هدف) کمترین اختلاف را داشته باشد. در آغاز آموزش، وزن‌ها به صورت تصادفی مقداردهی می‌شوند و طی مراحل یادگیری، با استفاده از الگوریتم‌هایی مانند گرادیان نزولی، به سمت مقادیر بهینه حرکت می‌کنند. پس از تکمیل آموزش، شبکه وارد مرحله آزمایش می‌شود. در این مرحله، ورودی‌های جدید (نمونه‌های آزمایشی) به مدل ارائه شده و خروجی‌های پیش‌بینی شده با مقادیر واقعی مقایسه می‌شوند تا عملکرد مدل ارزیابی گردد. مکانیسم آموزش در واقع از اطلاعات ذخیره شده طی آموزش برای پاسخ‌گویی به نمونه‌های جدید استفاده می‌کند. هرچه تطابق خروجی‌های تخمینی با پاسخ‌های واقعی بیشتر باشد، نگاشت شبکه به سیستم اصلی دقیق‌تر خواهد بود. ساختار غیرخطی شبکه‌های عصبی مصنوعی، امکان تحلیل روابط پیچیده و مدل‌سازی سری‌های زمانی خطی و غیرخطی را فراهم می‌سازد. در این پژوهش، تمرکز بر استفاده از شبکه‌های عصبی بازگشتی (RNN) است که به دلیل توانایی

در پردازش داده‌های دنباله‌دار و وابسته به زمان، برای پیش‌بینی آلودگی هوا در بازه‌های زمانی آینده بسیار کارآمد هستند.

شبکه‌های عصبی بازگشتی:

شبکه‌های عصبی بازگشتی (Recurrent Neural Networks – RNN)

به طور خاص برای پردازش داده‌های ترتیبی و سری‌های زمانی طراحی شده‌اند. برخلاف شبکه‌های عصبی پیش‌خور (Feedforward Neural Networks) که فاقد حافظه داخلی هستند، RNN‌ها از ساختاری حلقوی برخوردارند که امکان ذخیره‌سازی و استفاده از اطلاعات مراحل قبلی را در پردازش‌های بعدی فراهم می‌سازد. در این ساختار، خروجی هر مرحله به عنوان بخشی از ورودی مرحله بعدی در نظر گرفته می‌شود. این ویژگی موجب می‌شود که مدل بتواند وابستگی‌های زمانی و الگوهای پنهان در داده‌های دنباله‌دار را شناسایی کرده و در پیش‌بینی‌های خود لحاظ کند. با توجه به حجم وسیع داده‌های محیطی و محدودیت‌های سخت‌افزاری و نرم‌افزاری موجود، ساختار پیشنهادی RNN در این پژوهش به صورت ساده‌سازی شده طراحی شده است. این ساختار در شکل (۵) نمایش داده شده و شامل اجزای زیر است:


• **ورودی‌ها (x_t) تا (x_1) :** داده‌های ترتیبی که به مدل ارائه می‌شوند

• **حالت‌های پنهان (h_t) تا (h_1) :** حافظه داخلی مدل که اطلاعات مرحله قبل را ذخیره و منتقل می‌کند

• **خروجی‌ها (y_t) تا (y_1) :** نتایج پیش‌بینی شده در هر مرحله

• **اتصالات حلقوی:** نشان‌دهنده انتقال اطلاعات از مرحله قبلی به مرحله فعلی

این ساختار پایه‌ای برای آموزش مدل RNN در پیش‌بینی آلودگی هوا در شهر همدان فراهم می‌سازد و در مراحل بعدی مقاله، فرآیند آموزش، آزمایش و ارزیابی عملکرد مدل بر اساس این ساختار تشریح خواهد شد



شکل ۵: ساختار ترکیبی شبکه عصبی مصنوعی به منظور پیش‌بینی مولفه‌های آلاینده هوا

• صحت‌سنجی (Validation): در این مرحله، مدل با

داده‌هایی که در فرآیند آموزش شرکت نداشتند، مورد ارزیابی قرار گرفت. این مرحله مشابه آزمون گرفتن از دانش‌آموزان با منابع جدید و متفاوت است.


تمام مراحل فوق در محیط نرم‌افزار MATLAB® پیاده‌سازی شدند. نسبت داده‌های آموزش به آزمایش برابر با ۷۰ به ۳۰ در نظر گرفته شد. برای صحت‌سنجی، از روش دسته‌بندی چرخشی تصادفی (Randomized K-Fold Cross Validation) استفاده شد تا از تعمیم‌پذیری مدل اطمینان حاصل شود.

پس از اجرای مدل، مقادیر پیش‌بینی‌شده با مقادیر واقعی مقایسه شدند. برای ارزیابی دقت مدل، از رگرسیون خطی بین میانگین مقادیر پیش‌بینی‌شده و واقعی استفاده شد. نتایج حاصل در شکل (۶) نمایش داده شده‌اند و ضریب تعیین (R^2) برابر با ۰.۹۷۷۸ به دست آمد. این مقدار نشان‌دهنده دقت بالای مدل در پیش‌بینی آلودگی هوا و نزدیکی قابل‌توجه خروجی‌های مدل به داده‌های واقعی است.

ارزیابی روش پیشنهادی

با توجه به حجم بالای نمونه‌برداری داده‌ها حداقل ۶۰ نوبت در روز برای هر مؤلفه-پیاده‌سازی کامل این داده‌ها با توجه به محدودیت‌های سخت‌افزاری و نرم‌افزاری موجود، برای نویسندگان این پژوهش عملاً امکان‌پذیر نبود. از این‌رو، ساختار مدل پیشنهادی به صورت سلسله‌مراتبی و پیوسته طراحی شد تا ضمن حفظ دقت، با منابع موجود نیز سازگار باشد. برای پیش‌بینی میزان آلودگی هوا در شهر همدان، پس از جمع‌آوری و پیش‌پردازش داده‌ها، از شبکه عصبی بازگشتی (RNN) به عنوان مدل اصلی استفاده شد. فرآیند مدل‌سازی شامل سه مرحله اصلی بود:

- **آموزش (Training):** در این مرحله، مدل با استفاده از داده‌های واقعی و الگوریتم یادگیری پس انتشار (Backpropagation) آموزش داده شد. این مرحله مشابه آموزش مفاهیم به دانش‌آموزان از منابع مشخص است.
- **آزمایش (Testing):** مدل آموزش‌دیده با داده‌هایی از همان منابع مورد آزمون قرار گرفت تا عملکرد آن در شرایط مشابه ارزیابی شود.



شکل ۶: ارزیابی عملکرد مدل از طریق مقایسه میانگین مقادیر پیش‌بینی‌شده و واقعی

تحلیل رگرسیون مقادیر پیش‌بینی‌شده و واقعی

در جدول ۸، نتایج حاصل از تحلیل رگرسیون بین مقادیر پیش‌بینی‌شده توسط مدل شبکه عصبی بازگشتی (RNN) و مقادیر واقعی آلاینده‌های هوا در شهر همدان ارائه شده است. این جدول شامل ضریب تعیین (R^2)، شیب خط رگرسیون، مقدار انحراف معیار خطا و میانگین مطلق خطا برای هر یک از مؤلفه‌های آلاینده می‌باشد. هدف از این تحلیل، بررسی میزان تطابق خروجی‌های مدل با داده‌های واقعی و ارزیابی دقت پیش‌بینی برای هر آلاینده است. مقدار R^2 به عنوان شاخص اصلی در این ارزیابی، بیانگر میزان همبستگی بین داده‌های واقعی و پیش‌بینی‌شده است؛ به طوری که مقدار ۰.۹۷۷۸ برای کل مدل نشان‌دهنده دقت بسیار بالای پیش‌بینی‌ها و نزدیکی قابل توجه خروجی مدل به مقادیر واقعی است. این نتایج نشان می‌دهند که مدل پیشنهادی RNN با وجود محدودیت‌های سخت‌افزاری و حجم بالای داده‌ها، توانسته است عملکرد قابل قبولی در پیش‌بینی غلظت آلاینده‌ها ارائه دهد و می‌تواند به عنوان ابزاری مؤثر در مدیریت کیفیت هوا مورد استفاده قرار گیرد.


به منظور ارزیابی عملکرد مدل شبکه عصبی بازگشتی در پیش‌بینی غلظت ذرات معلق $PM_{2.5}$ ، داده‌های واقعی مربوط به انتشار این آلاینده در مدت ۳۰ روز از فصل بهار در شهر همدان با داده‌های پیش‌بینی‌شده مقایسه شدند. این مقایسه در قالب نمودار میله‌ای شکل (۸) نمایش داده شده است. نمودار مذکور در نرم‌افزار Excel پردازش شده و شامل دو میله برای هر روز است: یکی نمایانگر مقدار واقعی و دیگری نشان‌دهنده مقدار پیش‌بینی‌شده توسط مدل. این نمودار امکان بررسی بصری میزان تطابق بین داده‌های واقعی و خروجی مدل را فراهم می‌سازد و به عنوان ابزاری مؤثر برای تحلیل دقت پیش‌بینی در بازه زمانی مشخص مورد استفاده قرار گرفته است. مطابق با نتایج حاصل از این نمودار، مدل پیشنهادی

توانسته است روند تغییرات روزانه غلظت $PM_{2.5}$ را با دقت قابل قبولی بازسازی کند. این تطابق نشان‌دهنده توانایی مدل در شناسایی الگوهای زمانی و پاسخ‌گویی به نوسانات محیطی در داده‌های واقعی است.


تحلیل نمودار میله‌ای مقایسه‌ای PM_{10} شکل ۸

به منظور ارزیابی عملکرد مدل شبکه عصبی بازگشتی در پیش‌بینی غلظت ذرات معلق PM_{10} ، یک نمودار میله‌ای (شکل ۸) طراحی شده است که مقایسه‌ای بین مقادیر مشاهده‌شده و مقادیر پیش‌بینی‌شده این آلاینده را در طول ۳۰ روز از فصل بهار در شهر همدان نمایش می‌دهد. این نمودار با استفاده از داده‌های پردازش‌شده در نرم‌افزار Excel تهیه شده و شامل دو میله برای هر روز است: یکی نمایانگر مقدار واقعی و دیگری نشان‌دهنده مقدار پیش‌بینی‌شده توسط مدل. PM_{10} به ذرات معلق با قطر ۱۰ میکرومتر یا کمتر اطلاق می‌شود که از جمله آلاینده‌های رایج هوا محسوب می‌گردند. این ذرات به دلیل اندازه کوچک خود، قابلیت نفوذ به عمق ریه‌ها را دارند و می‌توانند موجب تشدید بیماری‌های تنفسی مانند آسم و افزایش خطر ابتلا به مشکلات قلبی-عروقی شوند. از این رو، نظارت دقیق و پیش‌بینی قابل اعتماد سطوح PM_{10} نقش مهمی در تدوین و اجرای استراتژی‌های مؤثر مدیریت کیفیت هوا و حفاظت از سلامت عمومی ایفا می‌کند. مطابق با نمودار شکل ۸، مدل پیشنهادی توانسته است روند تغییرات روزانه غلظت PM_{10} را با دقت قابل قبولی بازسازی کند. تطابق نسبی بین مقادیر واقعی و پیش‌بینی‌شده نشان‌دهنده توانایی مدل در شناسایی الگوهای زمانی و پاسخ‌گویی به نوسانات محیطی است. این نتایج، کارایی مدل را در کاربردهای عملی و تصمیم‌گیری‌های زیست‌محیطی تأیید می‌کنند.

نتایج رگرسیون پیش‌بینی مؤلفه‌های آلودگی هوا			
$PM_{2.5}$	PM_{10}	O_3	NO_x
۰.۹۷۷۲	۰.۹۷۴۵	۰.۹۵۳۵	۰.۹۹۹۷
NO_2	NO	CO	SO_2
۰.۹۸۵	۰.۹۶۰۵	۰.۹۷۹۳	۰.۹۹



شکل ۷: تطبیق آماری میانگین مقادیر پیش‌بینی‌شده با میانگین مشاهدات واقعی



شکل ۸: مقایسه میانگین مقادیر پیش‌بینی‌شده و واقعی در غلظت PM_{10}


پرتوهای فرابنفش، از جمله آسیب‌های پوستی، چشمی و تأثیرات منفی بر اکوسیستم‌های طبیعی دارد.

ازون در سطح زمین: منشأ، اثرات و تحلیل داده‌های مدل
با وجود نقش حفاظتی ازون (O_3) در لایه استراتوسفر، این گاز در سطح زمین به‌عنوان یکی از آلاینده‌های خطرناک شناخته می‌شود که می‌تواند تأثیرات منفی قابل‌توجهی بر سلامت انسان داشته باشد. ازون سطحی زمانی تشکیل می‌شود که آلاینده‌هایی نظیر اکسیدهای نیتروژن (NO_x) و ترکیبات آلی فرار (VOCs) در حضور نور خورشید وارد واکنش‌های فتوشیمیایی می‌شوند. منابع اصلی انتشار این ترکیبات شامل وسایل نقلیه موتوری، واحدهای صنعتی و نیروگاه‌ها هستند. آلودگی ازون در مناطق شهری، به‌ویژه در


بررسی تطبیقی غلظت‌های مشاهده‌شده و پیش‌بینی‌شده ازون در فصل بهار نمودار میله‌ای شماره (۹)، مقایسه‌ای میان غلظت‌های واقعی گاز ازون (O_3) و مقادیر پیش‌بینی‌شده توسط مدل را در بازه‌ای ۳۰ روزه از فصل بهار به تصویر می‌کشد. این نمودار ابزاری مؤثر برای ارزیابی دقت مدل در بازتولید داده‌های محیطی بوده و می‌تواند در تحلیل عملکرد مدل‌های پیش‌بینی آلودگی هوا مورد استفاده قرار گیرد. ازون (O_3) یکی از گازهای طبیعی موجود در جو زمین است که نقش حیاتی در حفظ تعادل زیست‌محیطی ایفا می‌کند. در لایه استراتوسفر، ازون به‌صورت یک لایه متمرکز تجمع یافته و با جذب بخش قابل‌توجهی از اشعه ماوراء بنفش خورشید، از ورود آن به سطح زمین جلوگیری می‌نماید. این ویژگی حفاظتی ازون، نقش مهمی در کاهش خطرات ناشی از

از آلودگی ازون قرار دارند. در شکل (۱۰)، مقایسه‌ای میان غلظت‌های مشاهده‌شده از اکسیدهای نیتروژن (NO_x) و مقادیر پیش‌بینی‌شده توسط مدل در طول ۳۰ روز از فصل بهار ارائه شده است. این نمودار، عملکرد مدل در بازتولید داده‌های واقعی را نشان داده و می‌تواند در ارزیابی دقت پیش‌بینی‌های مربوط به آلاینده‌های اولیه مؤثر باشد

روزهای گرم و آفتابی، شیوع بیشتری دارد. قرار گرفتن در معرض غلظت‌های بالای ازون می‌تواند منجر به بروز علائمی نظیر تحریک مجاری تنفسی، سرفه، درد قفسه سینه و تنگی نفس شود. همچنین، این گاز می‌تواند علائم بیماری‌هایی مانند آسم و سایر اختلالات تنفسی را تشدید کند. گروه‌های حساس از جمله کودکان، سالمندان و افراد مبتلا به بیماری‌های تنفسی، بیش از سایرین در معرض خطرات ناشی



شکل ۹: بررسی آماری میانگین خروجی مدل در مقایسه با داده‌های واقعی اُزون




شکل ۱۰: بررسی آماری میانگین خروجی مدل در مقایسه با داده‌های واقعی

بالا تولید می‌شوند و از منابعی نظیر وسایل نقلیه موتوری، نیروگاه‌ها و صنایع سنگین منتشر می‌گردند. NO_x نقش کلیدی در تشکیل ازون سطحی و ذرات معلق دارد و از مهم‌ترین آلاینده‌های اولیه در جو شهری محسوب می‌شود. در شکل (۱۱)، نتایج حاصل از تحلیل رگرسیونی بین داده‌های مشاهده‌شده و مقادیر پیش‌بینی‌شده توسط مدل برای غلظت

اکسیدهای نیتروژن (NO_x)، منشأ، ویژگی‌ها و تحلیل رگرسیونی

NO_x که مخفف اکسیدهای نیتروژن است، به گروهی از گازهای بسیار واکنش‌پذیر اطلاق می‌شود که شامل اکسید نیتریک (NO) و دی‌اکسید نیتروژن (NO_2) هستند. این ترکیبات عمدتاً در اثر احتراق سوخت‌های فسیلی در دمای

NO_x در طول ۳۰ روز از فصل بهار ارائه شده است. این نشان می‌دهد و می‌تواند به‌عنوان شاخصی برای ارزیابی دقت مدل در پیش‌بینی آلاینده‌های اولیه مورد استفاده قرار گیرد. نمودار میزان تطابق بین داده‌های واقعی و خروجی مدل را




شکل ۱۱: بررسی آماری میانگین خروجی مدل در مقایسه با داده‌های واقعی


آلاینده مهم، دی‌اکسید گوگرد (SO₂) و دی‌اکسید کربن (CO₂)، در بازه‌ای ۳۰ روزه از فصل بهار می‌پردازند. این نمودارها میزان دقت مدل در بازتولید داده‌های واقعی را نشان داده و می‌توانند در ارزیابی عملکرد مدل‌های پیش‌بینی آلودگی هوا مورد استفاده قرار گیرند. دی‌اکسید گوگرد (SO₂) گازی است که عمدتاً در اثر سوختن سوخت‌های فسیلی حاوی گوگرد، مانند زغال‌سنگ و نفت، تولید می‌شود. همچنین در برخی فرآیندهای صنعتی خاص، از جمله ذوب فلزات و تولید اسید سولفوریک، به‌عنوان محصول جانبی آزاد می‌گردد. SO₂ یکی از عوامل اصلی در تشکیل باران اسیدی محسوب می‌شود و می‌تواند اثرات مخربی بر کیفیت هوا، سلامت انسان و اکوسیستم‌های طبیعی داشته باشد. قرار گرفتن در معرض این گاز ممکن است منجر به تحریک دستگاه تنفسی، تشدید بیماری‌های ریوی و افزایش حساسیت به عوامل بیماری‌زا شود. نتایج پیش‌بینی مدل و داده‌های واقعی مربوط به غلظت SO₂ در شکل (۱۳) ارائه شده‌اند. این مقایسه می‌تواند به‌عنوان شاخصی برای ارزیابی دقت مدل در پیش‌بینی آلاینده‌های گوگردی مورد استفاده قرار گیرد.

اثرات زیست‌محیطی و سلامت‌محور اکسیدهای نیتروژن (NO_x) اکسیدهای نیتروژن (NO_x) زمانی تولید می‌شوند که سوخت‌های فسیلی در دماهای بالا، مانند آنچه در موتور خودروها، نیروگاه‌ها و فرآیندهای صنعتی رخ می‌دهد، سوزانده می‌شوند. این گازها از جمله آلاینده‌های اولیه هوا محسوب می‌شوند و نقش مهمی در شکل‌گیری پدیده‌هایی نظیر باران اسیدی و مه‌دود فتوشیمیایی دارند. هر دو پدیده می‌تواند اثرات مخربی بر اکوسیستم‌های طبیعی، کیفیت آب و خاک، و سلامت انسان داشته باشند. NO_x همچنین می‌تواند موجب تحریک سیستم تنفسی شود و افراد را در معرض خطر ابتلا به عفونت‌های تنفسی، سرفه‌های مزمن، و تشدید بیماری‌هایی نظیر آسم قرار دهد. گروه‌های حساس مانند کودکان، سالمندان و بیماران تنفسی، آسیب‌پذیری بیشتری در برابر این آلاینده دارند. در شکل (۱۲)، نتایج پیش‌بینی مدل در خصوص مولفه دی‌اکسید نیتروژن (NO₂) ارائه شده است. این نمودار میزان دقت مدل در بازتولید غلظت‌های واقعی NO₂ را در طول ۳۰ روز از فصل بهار نشان می‌دهد و می‌تواند به‌عنوان شاخصی برای ارزیابی عملکرد مدل در پیش‌بینی آلاینده‌های ثانویه مورد استفاده قرار گیرد.

تحلیل غلظت‌های SO₂ و CO₂ منشأ، اثرات و ارزیابی مدل شکل‌های (۱۳) و (۱۴) به مقایسه میان غلظت‌های مشاهده‌شده و مقادیر پیش‌بینی‌شده توسط مدل برای دو



شکل ۱۲: بررسی آماری میانگین خروجی مدل در مقایسه با داده‌های واقعی




شکل ۱۳: بررسی آماری میانگین خروجی مدل در مقایسه با داده‌های واقعی

در جو شده‌اند. این افزایش یکی از عوامل اصلی در تشدید پدیده گرمایش جهانی و تغییرات اقلیمی محسوب می‌شود. افزایش غلظت CO₂ موجب جذب بیشتر انرژی تابشی خورشید در جو و افزایش دمای سطح زمین می‌شود. این روند می‌تواند پیامدهای گسترده‌ای از جمله ذوب یخ‌های قطبی، افزایش سطح آب دریاها، تغییر الگوهای بارندگی و بروز پدیده‌های جوی شدید به‌همراه داشته باشد.

دی‌اکسید کربن (CO₂) منشأ، نقش در تغییرات اقلیمی و

ارزیابی مدل

دی‌اکسید کربن (CO₂) یکی از گازهای گلخانه‌ای طبیعی موجود در جو زمین است که نقش مهمی در تنظیم دمای سیاره ایفا می‌کند. با این حال، فعالیت‌های انسانی نظیر سوزاندن سوخت‌های فسیلی، جنگل زدایی و برخی فرآیندهای صنعتی، منجر به افزایش قابل‌توجه غلظت CO₂




شکل ۶: ترسیم میانگین مقادیر پیش‌بینی شده بر اساس میانگین مقادیر واقعی در CO₂

جمع‌بندی ارزیابی مدل پیشنهادی

در این بخش، عملکرد مدل پیشنهادی به‌خوبی مورد ارزیابی قرار گرفت. نتایج حاصل از پیش‌بینی غلظت آلاینده‌های مختلف، از جمله O_3 ، NO_x ، NO_2 ، SO_2 و CO_2 ، در بازه زمانی ۳۰ روزه از فصل بهار، نشان‌دهنده دقت بالای مدل در باز تولید داده‌های واقعی است. به‌طور خاص، میانگین ضریب تطابق بین مقادیر مشاهده‌شده و پیش‌بینی‌شده برای تمامی مولفه‌ها بیش از ۰.۹۷ گزارش شده است که بیانگر قابلیت اعتماد بالای مدل در شرایط محیطی متغیر می‌باشد. این نتایج در نمودارهای ارائه‌شده در اشکال (۷) تا (۱۴) به‌وضوح قابل مشاهده هستند و نشان می‌دهند که مدل توانسته است با دقت بالا رفتار آلاینده‌ها را در طول زمان شبیه‌سازی کند. با توجه به این سطح از دقت، می‌توان گفت که روش پیشنهادی ظرفیت بالایی برای استفاده در مطالعات پیش‌بینی آلودگی هوا و تصمیم‌گیری‌های زیست‌محیطی دارد. در بخش بعدی، لازم است به‌صورت مفصل به تحلیل نتایج، بررسی نقاط قوت و محدودیت‌های مدل، و پیشنهادات برای بهبود عملکرد آن پرداخته شود تا ارزیابی جامع‌تری از روش پیشنهادی ارائه گردد.

بحث روش پیشنهادی

در این پژوهش، به‌منظور پیش‌بینی آلودگی هوای شهر همدان، از شبکه‌های عصبی بازگشتی (RNN) بهره گرفته شده است. آلودگی هوا به‌عنوان یک پدیده پیچیده، پویا و چندوجهی، تأثیرات گسترده‌ای بر سلامت انسان، کیفیت زندگی و پایداری محیط زیست دارد. از این‌رو، توسعه ابزارهای پیش‌بینی دقیق و قابل اعتماد برای پایش و مدیریت کیفیت هوا، از اهمیت حیاتی برخوردار است. شبکه‌های عصبی بازگشتی به دلیل توانایی در مدل‌سازی داده‌های سری زمانی و درک وابستگی‌های زمانی میان متغیرها، گزینه‌ای مناسب برای تحلیل الگوهای آلودگی هوا محسوب می‌شوند. در این مطالعه، مدل پیشنهادی با استفاده از داده‌های واقعی مربوط به مولفه‌های آلاینده در شهر همدان آموزش داده شده و عملکرد آن در بازتولید غلظت‌های مشاهده‌شده مورد ارزیابی قرار گرفته است. شکل (۱۵) نمایی از پراکندگی داده‌ها و مولفه‌های آلودگی طی بیش از دو سال را ارائه می‌دهد که تنوع و نوسانات زمانی آلاینده‌ها را به‌خوبی نشان می‌دهد. این تصویر زمینه‌ای مناسب برای تحلیل عملکرد مدل در شرایط واقعی فراهم می‌سازد و اهمیت انتخاب روش‌های یادگیری عمیق در مواجهه با داده‌های پیچیده محیطی را برجسته می‌کند.



شکل ۱۵: روند تغییرات و پراکندگی مولفه‌های آلاینده‌های هوا در دوره ۳۰ ماهه


تجربی و تحلیل عملکرد مدل در شرایط واقعی صورت گرفته و نتایج حاصل، دقت بالای آن را در پیش‌بینی غلظت آلاینده‌ها تأیید می‌کند.

ارزیابی عملکرد مدل با استفاده از شاخص‌های کمی

برای تحلیل دقیق عملکرد شبکه عصبی پیشنهادی، استفاده از شاخص‌های کمی ضروری است. یکی از مهم‌ترین این شاخص‌ها، دقت پیش‌بینی (Accuracy) است که توانایی مدل در بازتولید صحیح مقادیر واقعی را نشان می‌دهد. این معیار از رابطه (۲) محاسبه می‌شود و به‌عنوان شاخصی کلیدی در ارزیابی کیفیت مدل در پیش‌بینی غلظت آلاینده‌ها مورد استفاده قرار گرفته است. دقت بالا در خروجی مدل، به‌ویژه در شرایط محیطی متغیر، نشان‌دهنده توانایی شبکه عصبی بازگشتی در یادگیری الگوهای پیچیده و وابستگی‌های زمانی میان داده‌ها است. در این پژوهش، مقدار میانگین دقت برای مولفه‌های مختلف آلاینده بیش از ۰.۹۷ گزارش شده است که بیانگر عملکرد قابل اتکای مدل در پیش‌بینی آلودگی هوا می‌باشد.

چالش‌های مدل‌سازی و انتخاب معماری پیشنهادی

یکی از چالش‌های اساسی در مدل‌سازی آلودگی هوا، حجم بالای داده‌ها و پیچیدگی روابط میان عوامل مؤثر بر آن است. این پدیده تحت تأثیر متغیرهای متعدد محیطی، انسانی و صنعتی قرار دارد که تعاملات غیرخطی و وابستگی‌های زمانی میان آن‌ها، تحلیل و پیش‌بینی دقیق را دشوار می‌سازد. در این پژوهش، با توجه به محدودیت‌های موجود در داده‌ها و ماهیت ترتیبی آن‌ها، از شبکه‌های عصبی بازگشتی (RNN) به‌عنوان ابزاری قدرتمند برای مدل‌سازی سری‌های زمانی استفاده شده است. این شبکه‌ها با بهره‌گیری از حافظه داخلی، قادرند الگوهای پیچیده و وابستگی‌های بلندمدت در داده‌های زمانی را شناسایی کرده و تغییرات آلودگی هوا را در طول زمان به‌طور مؤثر مدل‌سازی نمایند. ساختار شبکه عصبی بازگشتی پیشنهادی در شکل (۱۷) نمایش داده شده است. این معماری، که در قلب شکل (۵) نیز به‌عنوان ساختار اصلی مدل به‌کار رفته، شامل لایه‌های بازگشتی با قابلیت یادگیری وابستگی‌های زمانی و بهینه‌سازی پارامترها بر اساس داده‌های ورودی است. انتخاب این ساختار بر اساس آزمون‌های



شکل ۱۷: ساختار شبکه عصبی بازگشتی به منظور پیش‌بینی آلودگی هوا

$$\text{دقت} = (\text{تعداد کل نمونه ها}) / (\text{تعداد نمونه های پیش بینی شده صحیح}) \quad (۲)$$

شاخص از رابطه (۲) محاسبه شده و در تحلیل‌های این پژوهش، مقدار میانگین آن برای مولفه‌های مختلف آلاینده بیش از ۰.۹۷ گزارش شده است که بیانگر عملکرد قابل اتکای

شاخص دقت (Accuracy) یکی از مهم‌ترین معیارهای ارزیابی عملکرد مدل پیشنهادی است که نشان می‌دهد مدل تا چه اندازه توانایی پیش‌بینی صحیح مقادیر واقعی را دارد. این

مدل در شرایط محیطی متغیر می‌باشد. علاوه بر دقت، برای بررسی اختلاف میان مقادیر پیش‌بینی‌شده و واقعی، از شاخص‌های خطا نیز استفاده شده است. دو کمیت اصلی در این زمینه عبارتند از:

• **میانگین خطای مطلق (MAE):** که میانگین قدر مطلق اختلاف بین مقادیر پیش‌بینی‌شده و واقعی را نشان می‌دهد.

• **ریشه میانگین مربع خطا (RMSE):** که حساسیت بیشتری نسبت به خطاهای بزرگ دارد و برای ارزیابی پایداری مدل در پیش‌بینی‌های دقیق‌تر مناسب‌تر است. استفاده هم‌زمان از این شاخص‌ها امکان تحلیل جامع‌تری از عملکرد مدل را فراهم می‌سازد و نقاط قوت و ضعف آن را در مواجهه با داده‌های واقعی مشخص می‌کند.

$$3) \text{ (تعداد نمونه ها) } / \text{ (مجموع قدر مطلق خطا) } = \text{ میانگین خطای مطلق}$$

$$4) \text{ (تعداد نمونه ها) } / \text{ (مجموع مربعات خطاها) } = \sqrt{\text{ ریشه میانگین مربع خطا}}$$

تحلیل عددی عملکرد مدل بر اساس شاخص‌های کمی

در جدول (۲)، سه شاخص کلیدی شامل دقت پیش‌بینی

(Accuracy)، میانگین خطای مطلق (MAE) و ریشه میانگین مربع خطا (RMSE) برای هشت پارامتر مؤثر در آلودگی هوا طی یک دوره یک‌ساله ارائه شده‌اند. این شاخص‌ها به منظور ارزیابی جامع عملکرد مدل پیشنهادی در پیش‌بینی غلظت آلاینده‌ها مورد استفاده قرار گرفته‌اند.

• **دقت پیش‌بینی:** نشان‌دهنده توانایی مدل در بازتولید صحیح مقادیر واقعی است و بیانگر میزان تطابق بین خروجی مدل و داده‌های مشاهده شده می‌باشد.

• **MAE:** میزان متوسط اختلاف مطلق بین مقادیر پیش‌بینی‌شده و واقعی را نشان می‌دهد و برای سنجش خطاهای عمومی مدل مناسب است.

RMSE با حساسیت بیشتر نسبت به خطاهای بزرگ، شاخصی دقیق‌تر برای ارزیابی پایداری و دقت مدل در شرایط متغیر محیطی محسوب می‌شود. ارقام ارائه‌شده در جدول (۲) نشان می‌دهند که مدل پیشنهادی در پیش‌بینی آلاینده‌های مختلف عملکردی قابل‌تکاف داشته و توانسته است با دقت بالا و خطای کم، رفتار آلودگی هوا را در طول یک سال شبیه‌سازی کند.

جدول (۲): مقادیر دقت پیش‌بینی، قدر مطلق خطا و ریشه مربع خطای پارامترها در طول پیش‌بینی یکسال برای مولفه‌ها

PM2.5			PM10			O ₃			NO _x		
Accuracy	MAE	RMSE	Accuracy	MAE	RMSE	Accuracy	MAE	RMSE	Accuracy	MAE	RMSE
۹۷.۷٪	۲.۳	۸.۴۴	۹۸.۶٪	۱.۸	۴.۲۵	۹۵٪	۱.۳۸	۳.۱۹	۹۸.۱٪	۲.۳۰	۵.۳۷
NO ₂			NO			CO			SO ₂		
۹۸.۸٪	۲.۴۳	۳.۶۲	۹۶.۶٪	۱.۹۴	۵.۰۸	۹۷.۲٪	۲.۶۱	۶.۵	۹۸.۲٪	۱.۷۷	۳.۹۷

نتیجه‌گیری و پیشنهادات آینده

در این مطالعه، به محدودیت‌های موجود در داده‌های آلودگی هوا توجه ویژه‌ای شده است. همان‌طور که مشخص است، دستیابی به داده‌های کافی، دقیق و با کیفیت برای آموزش مدل‌های پیچیده، به‌ویژه در حوزه آلودگی هوا، همواره یکی از چالش‌های اساسی در مطالعات محیطی بوده است. با این حال، استفاده از شبکه‌های عصبی بازگشتی (RNN) به‌عنوان روشی مبتنی بر یادگیری عمیق، امکان مدل‌سازی مؤثر داده‌های محدود و سری‌های زمانی را فراهم کرده است. نتایج

حاصل از ارزیابی مدل نشان می‌دهد که شبکه عصبی بازگشتی قادر است با دقت بالا، غلظت آلاینده‌های هوا را در شهر همدان پیش‌بینی کند. مقایسه داده‌های پیش‌بینی‌شده با داده‌های واقعی، نزدیکی قابل‌توجهی میان این دو مجموعه را نشان می‌دهد که بیانگر توانایی مدل در بازتولید رفتار واقعی آلودگی هوا است. این دقت بالا، مدل پیشنهادی را به ابزاری کاربردی برای مدیریت و کنترل آلودگی هوا در شهر همدان تبدیل کرده است. از جمله مزایای مهم این مدل، قابلیت درک پویایی و تغییرات زمانی آلودگی هوا است. با در نظر گرفتن

قابل‌اتکا در پیش‌بینی غلظت آلاینده‌ها ارائه دهد. این مدل با درک وابستگی‌های زمانی و یادگیری الگوهای پیچیده، قابلیت بالایی در شبیه‌سازی رفتار آلودگی هوا در شرایط واقعی دارد و می‌تواند به‌عنوان ابزاری مؤثر در تصمیم‌گیری‌های مدیریتی و سیاست‌گذاری‌های زیست‌محیطی مورد استفاده قرار گیرد. با توجه به پیامدهای گسترده و تهدیدکننده آلودگی هوا بر سلامت عمومی و محیط زیست، بهره‌گیری از روش‌های نوین پیش‌بینی مانند شبکه‌های عصبی بازگشتی، گامی مؤثر در جهت مدیریت هوشمند کیفیت هوا و کاهش مخاطرات آن به‌شمار می‌رود. این رویکرد نه تنها امکان شناسایی الگوهای پنهان در داده‌های زیست‌محیطی را فراهم می‌سازد، بلکه زمینه‌ساز تصمیم‌گیری‌های پیشگیرانه و سیاست‌گذاری‌های مبتنی بر داده در سطح شهری و ملی خواهد بود. در شرایطی که آلودگی هوا به‌عنوان یکی از عوامل اصلی مرگ‌ومیر زودرس شناخته می‌شود، توسعه و به‌کارگیری چنین ابزارهایی ضرورتی انکارناپذیر در مسیر حفظ سلامت جامعه و پایداری زیست‌محیطی است.

نتیجه‌گیری نهایی

آلودگی هوا یکی از مهم‌ترین چالش‌های زیست‌محیطی عصر حاضر است که نه تنها سلامت انسان را تهدید می‌کند، بلکه آثار مخربی بر اکوسیستم‌ها، لایه اوزن، بارندگی‌های اسیدی و تغییرات اقلیمی برجای می‌گذارد. از این‌رو، پیش‌بینی دقیق و علمی آلودگی هوا و اتخاذ اقدامات مؤثر برای کاهش آن، ضرورتی حیاتی در مسیر حفاظت از سلامت عمومی و پایداری محیط زیست به‌شمار می‌رود. یکی از چالش‌های اصلی در مدل‌سازی آلودگی هوا، حجم بالای داده‌ها و پیچیدگی روابط میان عوامل مؤثر بر آن است. در این پژوهش، با توجه به محدودیت‌های موجود در داده‌های محیطی، از شبکه‌های عصبی بازگشتی (RNN) به‌عنوان ابزاری قدرتمند برای مدل‌سازی سری‌های زمانی استفاده شده است. این شبکه‌ها با بهره‌گیری از حافظه داخلی، توانایی یادگیری الگوهای پیچیده و وابستگی‌های زمانی را دارند و می‌توانند به‌طور مؤثر تغییرات آلودگی هوا را در طول زمان شبیه‌سازی کنند. در این مطالعه، به محدودیت‌های داده‌ای نیز توجه ویژه‌ای شده است. همان‌طور که می‌دانیم، دستیابی به داده‌های

تأثیر عوامل مختلف در طول زمان، مدل می‌تواند روندهای پیچیده و غیرخطی آلودگی را به‌طور دقیق‌تری شبیه‌سازی کند. این ویژگی، امکان تصمیم‌گیری مؤثرتر برای مسئولان شهری در زمینه کاهش آلودگی و حفاظت از سلامت شهروندان را فراهم می‌سازد. در مجموع، مدل شبکه عصبی بازگشتی ارائه‌شده در این پژوهش، راهکاری مؤثر و قابل‌اتکا برای پیش‌بینی آلودگی هوا در شهرهایی با محدودیت داده و پیچیدگی بالای عوامل مؤثر محسوب می‌شود. با مدل‌سازی روابط غیرخطی و وابستگی‌های زمانی، این مدل می‌تواند نقش مهمی در ارتقاء کیفیت هوا و سلامت عمومی ایفا کند. با این حال، پیشنهاد می‌شود در پژوهش‌های آینده:

- از داده‌های تکمیلی و چندمنبعی برای بهبود دقت مدل استفاده شود؛
- ساختارهای پیشرفته‌تری مانند LSTM یا GRU برای مدل‌سازی وابستگی‌های بلندمدت بررسی شوند؛
- مدل برای پیش‌بینی آلودگی هوا در سایر شهرها و مناطق با شرایط اقلیمی متفاوت توسعه یابد؛
- تأثیر سیاست‌های کنترل آلودگی و مداخلات زیست‌محیطی در خروجی مدل لحاظ گردد.

در این پژوهش، به‌منظور پیش‌بینی آلودگی هوای شهر همدان، از شبکه‌های عصبی بازگشتی (RNN) بهره گرفته شده است. آلودگی هوا به‌عنوان یک چالش پیچیده، چندوجهی و جهانی، تأثیرات گسترده‌ای بر سلامت انسان، کیفیت زندگی و پایداری محیط زیست دارد. پیش‌بینی دقیق و قابل‌اعتماد این پدیده، نقش کلیدی در اتخاذ اقدامات پیشگیرانه، مدیریت بهینه منابع و ارتقاء سیاست‌های زیست‌محیطی ایفا می‌کند. اهمیت این موضوع به‌حدی است که سازمان جهانی بهداشت (WHO) آلودگی هوا را یکی از مهم‌ترین عوامل خطر برای سلامت انسان معرفی کرده است. قرار گرفتن در معرض آلاینده‌های هوا می‌تواند منجر به بروز بیماری‌های قلبی و عروقی، اختلالات تنفسی، انواع سرطان و حتی مرگ زودرس شود. از این‌رو، توسعه ابزارهای هوشمند برای پایش و پیش‌بینی آلودگی هوا، ضرورتی اجتناب‌ناپذیر در مسیر حفاظت از سلامت عمومی و محیط زیست محسوب می‌شود. مدل شبکه عصبی بازگشتی ارائه‌شده در این مطالعه، با وجود محدودیت‌های داده‌ای، توانسته است عملکردی دقیق و

مدل‌های پیش‌بینی، می‌توان از الگوریتم‌های بهینه‌سازی هوشمند مانند الگوریتم کلونی زنبور عسل (Bee Colony Optimization)، الگوریتم انبوه ذرات (Particle Swarm Optimization)، الگوریتم ژنتیک و سایر روش‌های فراابتکاری بهره گرفت. این الگوریتم‌ها می‌توانند در بهینه‌سازی پارامترهای مدل، افزایش دقت پیش‌بینی و کاهش خطاهای محاسباتی نقش مؤثری ایفا کنند. در این پژوهش، پیش‌بینی غلظت آلاینده‌های مختلف از جمله PM_{10} ، $PM_{2.5}$ ، NO ، CO ، SO_2 ، NO_x و NO_2 مورد بررسی قرار گرفته است. هر یک از این آلاینده‌ها تأثیرات متفاوتی بر سلامت انسان و محیط زیست دارند:

- $PM_{2.5}$ و PM_{10} ذرات معلق هستند که می‌توانند به عمق ریه‌ها نفوذ کرده و منجر به بیماری‌های تنفسی و قلبی شوند.
 - O_3 ازون: موجب تحریک مجاری تنفسی و تشدید علائم آسم می‌شود.
 - NO_x و SO_2 : در تشکیل باران‌های اسیدی نقش دارند و می‌توانند به پوشش گیاهی و منابع آبی آسیب برسانند.
 - CO مونوکسید کربن: با کاهش ظرفیت حمل اکسیژن خون، خطرات جدی برای سلامت انسان ایجاد می‌کند.
- بنابراین، پیش‌بینی دقیق غلظت هر یک از این آلاینده‌ها، نه تنها برای پایش کیفیت هوا، بلکه برای اتخاذ اقدامات مؤثر در جهت کاهش آلودگی و حفاظت از سلامت عمومی و محیط زیست، ضروری و حیاتی است.

منابع

- 1- Brunekreef, B. & Holgate, S.T., 2002, Air Pollution and Health, The Lancet 360(9341), PP. 1233 1242
- 2- Chan-Yeung, M., 2000, Air Pollution and Health, Hong Kong Medical Journal 6(4), PP. 390 398
- 3- Gorai, A.K., Tuluri, F. & Tchounwou, P.B., 2014, A GIS Based Approach for Assessing the Association between Air Pollution and Asthma in New York State, USA, International Journal of Environmental Research and Public Health, 11(5), PP. 4845 4869.
- 4- Ross, T.J., 2009, Fuzzy Logic with Engineering Applications, John Wiley & Sons. Sahoo, M.M., Patra, K. & hatua, K., 2015, Inference of Water Quality Index Using

کافی و با کیفیت برای آموزش مدل‌های یادگیری عمیق، به‌ویژه در حوزه آلودگی هوا، همواره یک چالش بوده است. با این حال، نتایج حاصل از ارزیابی مدل نشان می‌دهد که شبکه عصبی بازگشتی، حتی با داده‌های محدود، قادر به ارائه پیش‌بینی‌هایی دقیق و قابل‌اعتماد در شهر همدان بوده است. مقایسه داده‌های پیش‌بینی‌شده با داده‌های واقعی، نزدیکی قابل‌توجهی میان این دو مجموعه را نشان می‌دهد که بیانگر توانایی بالای مدل در بازتولید رفتار واقعی آلودگی هوا است. این دقت بالا، مدل پیشنهادی را به ابزاری کاربردی برای مدیریت و کنترل آلودگی هوا در مناطق شهری تبدیل کرده است. با استفاده از این مدل، مسئولان و تصمیم‌گیرندگان می‌توانند سیاست‌های مؤثرتری در زمینه کاهش آلودگی و حفاظت از سلامت شهروندان اتخاذ کنند. یکی دیگر از مزایای مهم این مدل، توانایی آن در مدل‌سازی پویایی و تغییرات زمانی آلودگی هوا است؛ ویژگی‌ای که به‌ویژه در مناطق شهری با نوسانات سریع و ناگهانی آلاینده‌ها، اهمیت بالایی دارد. در مجموع، مدل شبکه عصبی بازگشتی ارائه‌شده در این پژوهش، راهکاری مؤثر، انعطاف‌پذیر و قابل‌اتکا برای پیش‌بینی آلودگی هوا در شرایط داده‌ای محدود و محیط‌های پیچیده محسوب می‌شود. این مدل با درک روابط غیرخطی و وابستگی‌های زمانی، می‌تواند نقش مهمی در ارتقاء کیفیت هوا، حفاظت از سلامت عمومی و توسعه سیاست‌های زیست‌محیطی ایفا کند.

پیشنهادهات

در این پژوهش، تمرکز اصلی بر پیش‌بینی غلظت آلاینده‌های هوا با استفاده از شبکه‌های عصبی بازگشتی بوده است. هدف، ارائه روشی کارآمد برای بهبود مدل‌سازی چندوجهی آلودگی هوا و افزایش دقت پیش‌بینی در شرایط داده‌ای محدود بوده است. با این حال، به جنبه‌های بالینی و پیامدهای زیست‌محیطی ناشی از آلودگی هوا، از جمله بیماری‌های قلبی عروقی، اختلالات تنفسی، کاهش بارش و تهدیدات سلامت در بازه‌های زمانی کوتاه‌مدت و بلندمدت، کمتر پرداخته شده است. پیشنهاد می‌شود در تحقیقات آینده، این ابعاد نیز به صورت جامع مورد بررسی قرار گیرند تا ارتباط میان داده‌های پیش‌بینی‌شده و اثرات واقعی آلودگی هوا بر سلامت انسان و محیط زیست بهتر تبیین شود. همچنین، برای ارتقاء عملکرد

- 16-Jalalkamali, A. (2015). Using Hybrid Fuzzy Models to Predict Spatiotemporal Groundwater Quality Parameters. *Earth Science Informatics*, 8(4), 885–894.
- 17-Salahi, B. et al. (2010). Prediction of Maximum Temperatures Using Artificial Neural Network Model. *Geographic Research*, 25(3), 57–78.
- 18-Tektas, M. (2010). Weather Forecasting Using ANFIS and ARIMA Models: A Case Study for Istanbul. *Environmental Research, Engineering and Management*, 51, 5–10.
- 19-Ghorbani, M.A. et al. (2012). Prediction of Air Temperature Using Artificial Intelligent Methods. *Journal of Engineering and Applied Sciences*, 7(2), 134–142.
- 20-Bekkar, A. et al. (2021). Air-Pollution Prediction in Smart City: Deep Learning Approach. *Journal of Big Data*, 8(161).
- 21-Zhao, J. et al. (2019). LSTM-Fully Connected Neural Network for PM2.5 Concentration Prediction. *Chemosphere*, 220, 486–492.
- 22-Delavar, M.R. et al. (2019). Improving Air Pollution Prediction Based on Machine Learning: A Case Study in Tehran. *ISPRS Int. J. Geo-Information*, 8(99).
- 23-Salman, A.G. et al. (2018). Single & Multi-Layer LSTM Model with Intermediate Variables for Weather Forecasting. *Procedia Computer Science*, 135, 89–98.
- 24-Xayasouk, T. et al. (2020). Air Pollution Prediction Using LSTM and Deep Autoencoder Models. *Sustainability*, 12(6), 2570.
- 25-Huang, C.-J. & Kuo, P.-H. (2018). A Deep CNN-LSTM Model for PM2.5 Forecasting in Smart Cities. *Sensors*, 18(7), 2220.
- 26-Garg, S. & Jindal, H. (2021). Evaluation of Time Series Forecasting Models for PM2.5 Estimation. In: 6th Int. Conf. for Convergence in Technology (I2CT).
- 27-Le, V.-D. et al. (2020). Spatiotemporal Deep Learning Model for Citywide Air Pollution Prediction. In: *IEEE BigComp*.
- ANFIA and PCA, *Aquatic Procedia*, 4: PP. 1099–1106.
- 5- Statheropoulos, M., Vassiliadis, N. & Pappa, A., 1998, Principal Component and Canonical Correlation Analysis for Examining Air Pollution and Meteorological Data, *Atmospheric Environment*, 32(6), PP. 1087–1095.
- 6- Moussiopoulos, N., Sahm, P. & Kessler, C., 1995, Numerical Simulation of Photochemical Smog Formation in Athens, Greece a Case Study, *Atmospheric Environment*, 29(24), PP. 3619–3632.
- 7- Kolehmainen, M., Martikainen, H., Hiltunen, T. & Ruuskanen, J., 2000, Forecasting Air Quality Parameters Using Hybrid Neural Network Modelling, *Urban Air Quality: Measurement, Modelling and Management*, Springer, PP. 277–286.
- 8- Brunekreef, B. & Holgate, S.T. (2002). Air Pollution and Health. *The Lancet*, 360(9341), 1233–1242.
- 9- Chan-Yeung, M. (2000). Air Pollution and Health. *Hong Kong Medical Journal*, 6(4), 390–398.
- 10-Gorai, A.K., Tuluri, F. & Tchounwou, P.B. (2014). A GIS Based Approach for Assessing the Association between Air Pollution and Asthma in New York State, USA. *Int. J. Environ. Res. Public Health*, 11(5), 4845–4869.
- 11-Ross, T.J. (2009). *Fuzzy Logic with Engineering Applications*. John Wiley & Sons.
- Sahoo, M.M., Patra, K. & Hatua, K. (2015). Inference of Water Quality Index Using ANFIA and PCA. *Aquatic Procedia*, 4, 1099–1106.
- 12-Statheropoulos, M., Vassiliadis, N. & Pappa, A. (1998). Principal Component and Canonical Correlation Analysis for Examining Air Pollution and Meteorological Data. *Atmospheric Environment*, 32(6), 1087–1095.
- 13-Moussiopoulos, N., Sahm, P. & Kessler, C. (1995). Numerical Simulation of Photochemical Smog Formation in Athens, Greece: A Case Study. *Atmospheric Environment*, 29(24), 3619–3632.
- 14-Kolehmainen, M. et al. (2000). Forecasting Air Quality Parameters Using Hybrid Neural Network Modelling. In: *Urban Air Quality: Measurement, Modelling and Management*. Springer, 277–286.
- 15-Jang, J.-S. (1992). Self-Learning Fuzzy Controllers Based on Temporal Backpropagation. *IEEE Trans. Neural Networks*, 3(5), 714–723.