

استفاده از الگوریتم‌های یادگیری مولد عمیق به منظور تخمین غلظت ذرات معلق در شهر تهران

حسین باقری^۱

محمدحسن زالی^۲

تاریخ دریافت مقاله: ۱۴۰۰/۰۶/۳۰

تاریخ پذیرش مقاله: ۱۴۰۰/۱۱/۲۶

چکیده

در دهه‌های اخیر، سطح غلظت ذرات معلق در کلان‌شهر تهران افزایش یافته است که این امر، مخاطرات فراوانی را برای محیط‌زیست و سلامت شهروندان به همراه داشته است. یکی از خطرناک‌ترین نوع آلودگی‌ها، آلودگی ذرات معلق کمتر از ۲/۵ میکرون (PM2.5) هست که مدل‌سازی، پایش و پیش‌بینی آن را بسیار حیاتی می‌نماید. برآورد غلظت این ذرات در سطح شهر تهران به دلیل وجود منابع گوناگون آلودگی و کمبود ایستگاه‌های هواشناسی و عدم توزیع مناسب ایستگاه‌ها موضوعی چالش‌برانگیز است. یکی از منابع جایگزین، استفاده از داده‌های به دست آمده از طریق تصاویر ماهواره‌ای شامل داده‌های ابروسل با توان تفکیک مکانی بالاست. با این حال تخمین مقادیر آلودگی سطحی از روی داده‌های ابروسل ماهواره‌ای به سادگی امکان‌پذیر نیست و نیازمند توسعه مدل‌های مناسب نظیر مدل‌های داده مینا و استفاده از تکنیک‌های یادگیری ماشینی می‌باشد. در این راستا هدف این مقاله ایجاد یک مدل به منظور تخمین میزان غلظت ذرات معلق در سطح شهر تهران با استفاده از داده‌های حاصل از مدل‌های هواشناسی و داده‌های ابروسل به دست آمده از تصاویر ماهواره‌ای مودیس به کمک الگوریتم‌های یادگیری عمیق مولد هست. برای این منظور سه نوع شبکه یادگیری عمیق بر مبنای مدل‌های مولد یعنی شبکه خود رمزنگار عمیق، شبکه باور عمیق بولتزن و شبکه مولد تخصصی شرطی برای تخمین غلظت PM2.5 با استفاده از داده‌های زمینی و ماهواره‌ای جمع‌آوری شده، توسعه داده شد. سپس ارزیابی دقت مدل‌های ایجاد شده توسط شبکه‌های مذکور بر روی داده‌های تست انجام شد و عملکرد آن‌ها مورد بررسی و مقایسه قرار گرفت. ارزیابی دقت نشان داد که شبکه خود رمزنگار ترکیب شده با مدل بردار پشتیبان مینا با همبستگی ۰/۶۹ و دقت (RMSE) ۱۰/۳۴ میکروگرم بر مترمکعب بالاترین کارایی را در مقایسه با سایر مدل‌ها به دست می‌دهد که می‌تواند به منظور مدل‌سازی میزان غلظت ذرات در سطح شهر تهران مورد استفاده قرار گیرد.

واژه‌های کلیدی: مدل‌های عمیق مولد، یادگیری عمیق، شبکه‌های خود رمزنگار، غلظت PM2.5، عمق لایه‌ی نوری ابروسل، مودیس.

۱- استادیار گروه نقشه‌برداری، دانشکده عمران و حمل‌ونقل، دانشگاه اصفهان، اصفهان، ایران (نویسنده مسئول) h.bagheri.en@gmail.com

۲- کارشناسی گروه نقشه‌برداری، دانشکده عمران و حمل‌ونقل، دانشگاه اصفهان، اصفهان، ایران zalimohammad1999@gmail.com

۱- مقدمه

در مطالعات زیادی کاربرد داده‌های ابروسل همراه با اندازه‌گیری‌های هواشناسی برای تخمین غلظت PM2.5 مورد بررسی و تحقیق قرار گرفته است (Peng et al., 2009; Peters et al., 2001). سنجنده‌های ماهواره‌ای همانند Aqua و Terra، نصب‌شده بر روی ماهواره مودیس (MODIS)، امکان اندازه‌گیری روزانه داده‌های ابروسل در یک منطقه وسیع را فراهم کرده‌اند. اخیراً یک امکان بازیابی داده‌های ابروسل با رزولوشن مکانی بالا (یک کیلومتر) توسط الگوریتم MAIAC^۳ فراهم شده است که به صورت گسترده برای مطالعات کیفیت هوا استفاده می‌شود. داده‌های ابروسل در این الگوریتم بر مبنای پردازش داده‌های Aqua و Terra به صورت سری زمانی به دست می‌آید. مطالعات قبلی عمدتاً بر تخمین غلظت PM2.5 با استفاده از داده‌های هواشناسی توسط ایستگاه‌های سینوپتیک و داده‌های ابروسل اندازه‌گیری شده توسط ماهواره در وضوح پایین‌تر (حدود ۱۰ کیلومتر) در تهران متمرکز بوده است. در یک مطالعه اولیه، سعی شد غلظت PM2.5 با استفاده از داده‌های ۱۰ کیلومتری ابروسل DT^۴ در یک بازه زمانی کوتاهی از مشاهدات تخمین زده شود. در این مطالعه میزان همبستگی غلظت PM2.5 پیش‌بینی شده و غلظت PM2.5 مشاهده شده نزدیک ۰/۵۵ بوده است (Sotoudehian & Arhami, 2014).

در یک تحقیق دیگر، قطبی و همکاران، توانستند غلظت PM2.5 را در شهر تهران با دقت بالاتر ($R^2=0.73$) با استفاده از داده‌های سه کیلومتری ابروسل DT و داده‌های هواشناسی به دست آمده از ایستگاه‌های آب‌وهوایی تخمین بزنند (Ghotbi et al., 2016). آن‌ها از تعداد نمونه کم (۳۳۲ نمونه) که از تعدادی ایستگاه‌های کنترل کیفیت هوا در بازه زمانی کوتاهی از مارس تا نوامبر ۲۰۰۹ جمع‌آوری شده بود استفاده کردند. تنها مطالعه‌ای که در تهران با استفاده از داده‌های MAIAC AOD انجام شده است همبستگی کمتر از ۰/۵ را به طور میانگین برای تخمین غلظت PM2.5 گزارش داده است (Nabavi et al., 2019). همچنین تخمین غلظت PM2.5

در سال‌های اخیر افزایش سطح آلودگی هوا در کلان‌شهرها، توجه شهرداری‌ها، سازمان‌های حفاظت محیط‌زیست و سایر مسئولین امر را برای اندازه‌گیری و پایش غلظت مواد آلاینده جلب کرده است. این اندازه‌گیری‌ها به منظور مدل‌سازی آلودگی هوا و پیش‌بینی تغییرات مکانی و زمانی آن مورد استفاده قرار می‌گیرد و ابزار مناسبی برای بررسی تأثیر راهکارهای کنترل و کاهش آلودگی هوا فراهم می‌آورد.

یکی از شهرهایی که به شدت از معضل آلودگی هوا رنج می‌برد، کلان‌شهر تهران است. گسترش روزافزون شهر تهران، افزایش جمعیت در آن، ساخت کارخانه‌ها و کارگاه‌های صنعتی در اطراف آن، افزایش استفاده از وسایل نقلیه و تغییرات کاربری اراضی، موجب افزایش آلودگی هوای این شهر در دهه‌های اخیر شده و خسارات فراوانی را در محیط‌زیست و برای سلامت شهروندان به بار آورده است.

در بین آلاینده‌های مختلف، ذرات معلق (PM)^۱ با اندازه کوچک‌تر از ۲/۵ میکرون عامل اصلی بیماری‌های مختلف نظیر بیماری‌های قلبی و عروقی (Dominici et al., 2006)، بیماری‌های تنفسی (Klemm et al., 2000) و سکته‌های قلبی (Lippmann et al., 2000) است؛ بنابراین تخمین غلظت PM2.5 برای مطالعات در حوزه کنترل آلودگی هوا و سلامت و همچنین بررسی‌های اپیدمیولوژیکی بسیار ضروری است. عموماً اندازه‌گیری غلظت PM2.5 از طریق مشاهدات و اندازه‌گیری ایستگاه‌های زمینی کنترل کیفیت هوا و ایستگاه‌های سینوپتیک هواشناسی صورت می‌گیرد؛ اما به علت کمبود ایستگاه‌های زمینی در شهر تهران و تنوع منابع پدیدآورنده آلودگی هوا، تخمین دقیق میزان آلودگی هوا و میزان ذرات معلق با مشکل روبه‌رو می‌شود. یکی دیگر از منابعی که برای اندازه‌گیری غلظت PM2.5 به کار گرفته می‌شود عمق لایه‌ی نوری ابروسل (AOD)^۲ است.

3- Multiangle Implementation of Atmospheric Correction

4- Dark Target

1- Particulate Matter

2- Aerosol Optical Depth

مکان‌مبنا با بهره‌گیری از شبکه باور عمیق ابداع گردید که از اندازه‌گیری داده‌های ایروسل، داده‌های هواشناسی و سایر اطلاعات مکان‌مبنا به منظور تخمین غلظت ذرات معلق استفاده شده است. (Lianfa Li, 2020) در تحقیقی دیگر، از یک شبکه خود رمزنگار عمیق برای تخمین غلظت PM2.5 و PM10 از داده‌های ایروسل استفاده شد (Li et al., 2017). همچنین در مطالعه‌ای که اخیراً صورت گرفته، از یک شبکه خودسازگار برای یافتن رابطه بین داده‌های ایروسل و غلظت PM2.5 استفاده شده است (Chen et al., 2021).

همان‌گونه که از بررسی تاریخچه مقالات مشخص شد، الگوریتم‌های مختلف یادگیری ماشین عمدتاً بر مبنای رگرسیون خطی و اخیراً الگوریتم‌های یادگیری عمیق برای بررسی غلظت آلودگی هوا توسعه یافته‌اند، اما تاکنون قابلیت‌های الگوریتم‌های یادگیری عمیق مولد در مدل‌سازی غلظت ذرات معلق در سطح شهر تهران مورد بررسی قرار نگرفته است. در نتیجه، در این مقاله به بررسی قابلیت و مقایسه دقت انواع شبکه‌های یادگیری عمیق مولد نظیر شبکه‌های مولد تخصصی، شبکه باور عمیق بولتزمن و شبکه خود رمزنگار عمیق برای تخمین مقادیر غلظت PM2.5 از روی مقادیر ایروسل جمع‌آوری شده توسط تصاویر ماهواره مودیس پرداخته می‌شود.

۲- منطقه مورد مطالعه


منطقه مورد مطالعه شهر تهران، پایتخت ایران، دارای جمعیت ۱۳/۳ میلیون نفر است (Habibi et al., 2017). این شهر در عرض جغرافیایی ۳۵°۳۵' تا ۳۵°۴۸' شمالی و طول جغرافیایی ۵۱°۱۷' تا ۵۱°۳۳' شرقی قرار دارد. مرتفع‌ترین نقطه در تهران دارای ارتفاع ۱۸۰۰ متر و کم‌ارتفاع‌ترین نقطه آن دارای ارتفاع ۹۰۰ متر از سطح آب‌های آزاد است. یکی از اصلی‌ترین منابع آلودگی هوا در تهران، استفاده از وسایل حمل‌ونقل و ناوگان نسبتاً قدیمی است که عامل تولید حدود ۸۵ درصد آلودگی و ۷۰ درصد PM هستند (Shahbazi et al., 2016). همچنین فعالیت‌های انسانی همانند تغییر کاربری‌های

از طریق تصاویر ماهواره‌ای با رزولوشن مکانی بالا همانند لندست در مطالعات متعدد بررسی شده است و به دلیل اینکه این تصاویر توان تفکیک زمانی پایین‌تری (هر ۱۵ روز یک تصویر) داشته‌اند برای نگاشت روزانه غلظت PM2.5 مناسب نیستند (Jafarian & Behzadi, 2020).

علاوه بر بحث داده، جنبه دیگر مدل‌سازی، نوع مدلی است که برای تخمین غلظت PM2.5 از داده‌های ایروسل و داده‌های هواشناسی به کار می‌رود. به‌طور کلی مدل‌هایی که برای تخمین غلظت PM2.5 با استفاده از داده‌های ایروسل اندازه‌گیری شده توسط ماهواره به کار می‌روند، در سه دسته کلی قرار می‌گیرند: مدل‌های شبیه‌سازی شیمیایی (Beckerman et al., 2013; Vienneau et al., 2010) مدل‌های آماری (Hoek et al., 2018) و مدل‌های نیمه تجربی (Gupta & Christopher, 2009).

در میان این مدل‌ها، مدل‌های آماری بیشترین استفاده را نسبت به سایر مدل‌ها دارند که در آن‌ها روش‌های مبتنی بر یادگیری ماشینی به صورت گسترده برای تخمین غلظت PM2.5 استفاده می‌شوند. مدل رگرسیون خطی ساده یکی از ساده‌ترین و پرکاربردترین مدل‌هایی است که برای برآورد غلظت PM2.5 مورد استفاده قرار گرفته است. علاوه بر مدل رگرسیون خطی، مدل‌های یادگیری ماشینی پیشرفته نیز برای تخمین غلظت PM2.5 استفاده شده‌اند (Arciszewska & McClatchey, 2001; Gupta & Christopher, 2009; Hersbach et al., 2020; Sayer et al., 2015).

دسته‌ای دیگر از مدل‌های یادگیری ماشینی که اخیراً محبوب شده‌اند، مدل‌های یادگیری عمیق هستند که قابلیت تخمین یک متغیر را از چندین متغیر ورودی دارند. در سال‌های اخیر روش‌های مبتنی بر شبکه‌های عصبی عمیق عملکرد خوبی از خودشان در مسائل مختلف طبقه‌بندی و رگرسیون نشان داده‌اند. همچنین از روش‌های مبتنی بر یادگیری عمیق برای تخمین غلظت PM2.5 از طریق اطلاعات ماهواره‌ای استفاده شده است. در مطالعه‌ای که به تازگی انجام شده، یک شبکه هوشمند



نگاره ۱: نمایی از منطقه مورد مطالعه، شهر تهران
موقعیت ایستگاه‌های کنترل کیفیت هوا توسط دایره‌های نارنجی مشخص شده است

ارضی و تغییر پوشش گیاهی در مناطق شهری و حومه شهر استفاده می‌شود. این روش‌ها تنوع شرایط آب‌وهوایی و عوامل انسانی دخیل در تولید آلاینده‌های محلی را نادیده می‌گیرند. این مورد زمانی حادث می‌شود که اندازه‌گیری مداوم غلظت $PM_{2.5}$ توسط ایستگاه‌های موجود باگذشت زمان امکان‌پذیر نیست که در عمل به معنی کم شدن تعداد ایستگاه‌های زمینی اندازه‌گیری است. برای مثال از بین همین ۲۳ ایستگاه، برخی از آنها به دلیل مشکلات و نقایص فنی در برخی از بازه‌های زمانی، داده‌ای را ثبت ننموده‌اند. در نتیجه داده‌های ابروسل جمع‌آوری شده توسط ماهواره‌ها می‌توانند این نقایص را جبران نمایند.

۳- مواد تحقیق
۳-۱- داده‌های ذرات معلق $PM_{2.5}$
میانگین روزانه غلظت $PM_{2.5}$ توسط شرکت کنترل کیفیت هوای تهران جمع‌آوری می‌شود. نگاره ۱ موقعیت ایستگاه‌های کنترل کیفیت هوا را نشان می‌دهد. همان‌طور که در نگاره ۱ نشان داده شده است، کیفیت هوای شهر تهران توسط ۲۳ ایستگاه که در سراسر شهر پخش شده پایش می‌شود. سطح PM به صورت ساعتی توسط دستگاه TEOM اندازه‌گیری می‌شود (Sotoudeheian & Arhami, 2014).

۳-۲- داده‌های ماهواره‌ای ابروسل
با وجود گسترش مناسب ایستگاه‌های پایش، این تعداد ایستگاه برای نگاهت غلظت $PM_{2.5}$ با وضوح بالا از شهر تهران کافی نیستند. معمولاً روش‌های درون‌یابی برای تخمین و نگاهت غلظت $PM_{2.5}$ در مناطق بین ایستگاه‌ها

داده‌های ابروسل می‌تواند برای مدل‌سازی تغییرات غلظت $PM_{2.5}$ در مکان‌هایی بین ایستگاه‌های کنترل کیفیت هوا استفاده شود. سنسورهای فضایی می‌توانند داده‌های ابروسل را به صورت روزانه اندازه‌گیری کنند. در واقع

لایه‌های هوایی (همرفت) و انتقال آلودگی به سطوح بالاتر را فراهم می‌کند و باعث کاهش غلظت آلاینده‌ها در سطح می‌شود. افزایش یا کاهش تابش فرابنفش باعث افزایش یا کاهش فعل و انفعالات آلاینده‌ها در اتمسفر می‌شود که موجب انتقال آن‌ها به سطوح بالاتر یا پایین‌تر می‌گردد. همچنین سرعت و جهش باد تأثیر بسزایی در انباشت آلاینده‌ها یا تخلیه آن‌ها از سطح شهر دارد. اطلاعات تکمیلی در تحقیقات (Peng et al., 2009; Peters et al., 2001) ارائه شده است. عموماً داده‌های هواشناسی همانند PM2.5 توسط ایستگاه‌های زمینی هواشناسی جمع‌آوری می‌شوند. با این حال، ECMWF یکی از معروف‌ترین مدل‌های جهانی آب و هوایی است که می‌تواند توزیع یکنواخت داده‌های هواشناسی را در سرتاسر جهان فراهم کند و به‌عنوان جایگزین ایستگاه‌های هواشناسی مورد استفاده قرار گیرد. داده‌های هواشناسی حاصل از نسل پنجم تجزیه و تحلیل مجدد ECMWF^۱ با عنوان ERA5 با رزولوشن مکانی حدود ۱۲ کیلومتر و به‌صورت روزانه عرضه می‌شوند. برای به‌کار گرفتن داده‌های هواشناسی، نیاز هست تا مقدار آن‌ها را در موقعیت ایستگاه‌های هواشناسی تخمین زد. به‌این منظور، داده‌های هواشناسی در موقعیت هدف با روش‌های درونیابی همانند کریجینگ^۲ مقداردهی می‌شوند. دو نوع محبوب از کریجینگ، معمولی^۳ و یونیورسال^۴ برای درونیابی داده‌های هواشناسی استفاده می‌شوند. در کنار انواع کریجینگ، یک پارامتر مهم دیگر که باید به‌صورت صحیح تنظیم شود سمیوریوگرام (semi-variogram) هست که در انواع مختلف خطی، کره‌ای، گاوسی و توانی طراحی شده است و باید برحسب نوع داده مورد مطالعه به‌طور درستی انتخاب شود (Bagheri et al., 2014). جدول ۱ داده‌های هواشناسی مورد استفاده در این مطالعه به همراه پارامترهای درونیابی کریجینگ برای هر پارامتر را نشان می‌دهد.

داده‌های ابروسل مشخص‌کننده میزان ابروسل موجود در اتمسفر است که به‌صورت ستونی با اندازه‌گیری میزان عمق نوری ناپدیدشده توسط ابروسل، اندازه‌گیری می‌شود. دو نوع داده‌های ابروسل که به‌صورت گسترده استفاده می‌شوند حاصل از بازیابی توسط الگوریتم‌های DT و DB هستند که توسط ماهواره مودیس (Aqua/Terra) به‌دست می‌آیند. الگوریتم DT بیشتر در مناطق با تراکم بالای پوشش گیاهی استفاده می‌شود که این موضوع، استفاده از آن را در مناطق شهری محدود می‌کند (Levy et al., 2013).

DB بیشتر در مناطق با سطوح روشن قابل استفاده هست (Hsu et al., 2013) که شامل مناطق شهری می‌شود. با این وجود هر دو الگوریتم منجر به اندازه‌گیری داده با رزولوشن ۳ تا ۱۰ کیلومتر می‌شوند که این موضوع ما را در اندازه‌گیری غلظت PM با دقت و رزولوشن بالا محدود می‌کند. محصول جدید داده‌های ابروسل، خروجی الگوریتم MAIAC است که از اندازه‌گیری‌هایی به‌صورت سری زمانی توسط سنسورهای Aqua و Terra به‌دست آمده است. همان‌طور که ذکر شد اندازه‌گیری داده‌های ابروسل به‌صورت ستونی در اتمسفر صورت می‌گیرد، درحالی‌که اندازه‌گیری غلظت PM2.5 به‌صورت سطحی نزدیک به ایستگاه‌های زمینی است. در نتیجه توسعه یک مدل که مقدار غلظت PM2.5 را از داده‌های ابروسل محاسبه کند چالش برانگیز می‌باشد.

۳-۳- داده‌های هواشناسی

علاوه بر داده‌های ابروسل، مطالعات متعددی نقش قابل توجه داده‌های هواشناسی برای برآورد غلظت PM2.5 را نشان می‌دهند (Peng et al., 2009; Peters et al., 2001). به‌عنوان مثال، پارامتر لایه مرزی، مرز میان غلظت آلاینده‌ها در سطح نزدیک به زمین را با غلظت آلاینده‌ها در سطوح بالاتر اتمسفر مشخص می‌کند.


دمای هوا نیز رابطه مستقیمی با غلظت آلاینده‌ها دارد، به‌گونه‌ای که در دماهای پایین میزان غلظت آلودگی افزایش می‌یابد در حالی که افزایش دمای هوا امکان جابه‌جایی سریع‌تر

1- European Centre for Medium-Range Weather Forecasts


2- Kriging

3- Ordinary


4- Universal




ب) نقشه سالیانه درونیابی شده فشار سطح (هکتوپاسکال)



الف) نقشه سالیانه درونیابی شده ارتفاع لایه مرزی (متر)



د) نقشه سالیانه سرعت (متر بر ثانیه) و جهت وزش باد



ج) نقشه سالیانه درونیابی شده دما (سانتی گراد)

نگاره ۲: نقشه‌های میانگین برخی از پارامترهای هواشناسی (ارتفاع لایه مرزی، فشار هوا، دمای هوا و سرعت و جهت باد) در سطح شهر تهران. نقشه‌های نشان داده شده با استفاده از درونیابی با توان تفکیک ۱۱ km از میانگین مشاهدات در بازه زمانی ژانویه ۲۰۱۳ تا ژانویه ۲۰۱۴ تهیه شده‌اند

قرار می‌گیرند. در مجموع ۱۳ متغیر ورودی ($X^{13 \times 1}$) شامل داده‌های ایروسل ماهواره‌ای، داده‌های هواشناسی، اطلاعات موقعیت جغرافیایی، شماره روز در سال، برای تخمین غلظت PM2.5 به کار گرفته می‌شوند. این داده‌ها در بازه زمانی ژانویه ۲۰۱۳ تا ژانویه ۲۰۲۰ به دست آمده‌اند که در موقعیت ایستگاه‌های سنجش آلودگی هوا برای آموزش شبکه مورد استفاده قرار گرفتند.

روش شناسی

در این مقاله الگوریتم‌های یادگیری عمیق مولد برای مدل‌سازی رابطه بین داده‌های عمق نوری ایروسل و غلظت PM2.5 استفاده شده است. در شبکه‌های مولد هدف یادگیری توزیع درست داده‌های موجود در مجموعه داده‌های آموزش است. به عبارت دیگر، هدف یادگیری تابعی است که قادر باشد یک تخمین درست از توزیع داده‌ها را به دست آورد (Ruthotto & Haber, 2021). با یافتن توزیع مناسب امکان استخراج

جدول ۱: پارامترهای هواشناسی مورد استفاده به همراه تنظیمات درونیابی کریجینگ هر پارامتر

داده هواشناسی	نوع کریجینگ	سمی و ریوگرام
دمای نقطه شبنم	یونیورسال	کره‌ای
درجه حرارت	یونیورسال	کره‌ای
لایه مرزی	معمولی	کره‌ای
شاخص پوشش گیاهی	معمولی	کره‌ای
فشار سطحی	یونیورسال	پاور
سرعت باد	معمولی	کره‌ای
جهت باد	معمولی	کره‌ای
تابش فرابنفش ورودی بر سطح	معمولی	کره‌ای
تابش خورشید در سطح زمین	معمولی	کره‌ای

نگاره ۲ نقشه‌های میانگین سالیانه چند نمونه از پارامترهای هواشناسی را در سطح شهر تهران نشان می‌دهد. علاوه بر داده‌های فوق، موقعیت جغرافیایی (طول و عرض جغرافیایی) و روز مشاهده در سال (DOY) به عنوان متغیرهای ورودی در تخمین غلظت PM2.5 مورد استفاده

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (۳۳)

استفاده از الگوریتم‌های یادگیری مولد عمیق به منظور تخمین غلظت ... / ۱۳

شبکه خود رمزنگار از دو بلوک اصلی رمزگذار^۲ و رمزگشا^۳ تشکیل شده است (نگاره ۳). وظیفه بلوک رمزگذار استخراج ویژگی‌های جدید و سطح بالا از روی ویژگی‌های ورودی و وظیفه رمزگشا بازسازی ویژگی‌های ورودی است. اگر رمزنگار و رمزگشا را به ترتیب با a و A نمایش دهیم، داریم:

$$a = x \rightarrow F$$

$$A = F \rightarrow x$$

که در آن A ، a به گونه‌ای تعیین می‌شوند که رابطه زیر مینیمم شود:

$$a, A = \arg \min \|x - (A \cdot a)\|^2$$

در ساده‌ترین حالت، با تنها یک لایه پنهان، قسمت رمزنگار، متغیر $x \in \mathbb{R}^d$ را دریافت کرده و آن را به متغیر $h \in \mathbb{R}^p$ نگاشت می‌کند که h نیز از نگاشت زیر به دست می‌آید:

$$h = \sigma(Wx + b)$$

که به h متغیر نهفته گفته می‌شود. σ یک تابع فعال‌سازی همانند ReLU می‌باشد، W ماتریس وزن و b هم مقدار خطایی است که به شبکه اعمال می‌کنیم. پس از آن، قسمت رمزگشا، h را به x' نگاشت می‌کند:

$$x' = \sigma'(W'h + b')$$

که σ' ، W' و b' به ترتیب تابع فعال‌ساز، ماتریس وزن و بایاس شبکه رمزگشا می‌باشد. زمانی الگوریتم موفق به استخراج ویژگی می‌شود که اختلاف ویژگی‌های تولید شده و ورودی به حداقل میزان ممکن برسد. در واقع یک تابع هزینه (Loss) بر مبنای نرم دوم (L_2) تعریف می‌شود تا این اختلاف را کمینه سازد:

$$\text{Loss}(x, x') = \|x - x'\|^2 = \|x - \sigma'(W'(\sigma(Wx + b)) + b')\|^2$$

پس از کمینه‌سازی، ویژگی استخراج شده توسط بلوک رمزگذار (x) به عنوان ویژگی‌های سطح بالا وارد یک مدل رگرسیون می‌شوند. در مسئله تخمین غلظت $PM_{2.5}$ ، ویژگی‌های ورودی مانند داده‌های ابروسل و پارامترهای هواشناسی به شبکه وارد می‌شوند تا از ویژگی‌های بهتری

ویژگی کارا نیز فراهم می‌شود؛ بنابراین شبکه‌های یادگیری عمیق مولد پتانسیل قابل توجهی برای یادگیری ویژگی‌های سطح بالا دارند که می‌توانند در تخمین و رگرسیون مقادیر هدف مورد استفاده قرار گیرند.

در این مقاله سعی بر استفاده و مقایسه شبکه‌های یادگیری عمیق مولد به منظور یافتن مدلی برای تخمین مقادیر غلظت $PM_{2.5}$ از روی مقادیر داده‌های ابروسل در محل ایستگاه‌ها می‌باشد. با این روش مدل توسعه داده شده می‌تواند برای پیش‌بینی مقدار غلظت $PM_{2.5}$ از روی داده‌های ابروسل و مشاهدات هواشناسی در مکان‌های مابین ایستگاه‌ها (فاقد اندازه‌گیری زمینی) به کار رود. در این حالت داده‌های ابروسل استخراج شده در محل یک ایستگاه زمینی یک متغیر ورودی است و غلظت $PM_{2.5}$ زمینی اندازه‌گیری شده یک متغیر مستقل است. علاوه بر داده‌های ابروسل بازیابی شده از مشاهدات ماهواره‌ها، داده‌های هواشناسی کارایی خود را در تخمین غلظت $PM_{2.5}$ به عنوان داده‌های کمکی نشان داده‌اند. به این صورت، مسئله مورد نظر به یک مسئله رگرسیون تبدیل می‌شود که هدف یافتن مدلی به منظور تخمین غلظت $PM_{2.5}$ از روی داده‌های ابروسل و هواشناسی است. در ادامه ساختار شبکه‌های عمیق مولد مورد استفاده در این مقاله مورد بررسی قرار می‌گیرد.

۳-۴- شبکه خود رمزنگار عمیق

یکی از شبکه‌های عصبی عمیق که برای مسائل رگرسیون توسعه داده شده است شبکه خود رمزنگار عمیق (DAE)^۱ است. در این نوع شبکه‌ها، رمزنگار، ویژگی‌ها را از داده‌ها استخراج می‌کند. دو نوع ویژگی برای داده‌ها وجود دارد، ویژگی‌های ورودی که به شبکه وارد شده‌اند و ویژگی‌هایی که توسط شبکه تولید شده‌اند. استخراج ویژگی خودکار توسط شبکه، این امکان را فراهم کرده است که یک تابع پیچیده نگاشت بین ویژگی‌های ورودی و متغیرهای نهایی یاد گرفته شود (Li, Yu, & Qin, 2017). به بیان دیگر، یک

2- Encoder

3- Decoder

1- Deep Auto Encoder

که توسط شبکه تولید می‌شود برای پیش‌بینی مقدار غلظت PM2.5 استفاده شود.

۳-۵- شبکه مولد تخصصی شرطی

شبکه‌های مولد تخصصی (GAN) در سال ۲۰۱۴ طراحی شدند (Goodfellow et al., 2014). یک نوع از شبکه‌های GAN با قابلیت به‌کارگیری در مسائل نظارت‌شده، شبکه‌های GAN شرطی (CGAN)^۲ می‌باشد (Mirza & Osindero, 2014). همان‌گونه که در نگاره ۴ نشان داده شده است، شبکه‌های مولد تخصصی از دو تابع مولد^۳ و تفکیک‌کننده^۴ تشکیل شده‌اند. تابع مولد وظیفه تولید داده‌های جدید را از قسمت فضای پنهان^۵ که در ابتدا به‌صورت دلخواه به‌عنوان ورودی به شبکه وارد می‌شود را دارد. سپس داده‌های تولیدشده و داده‌های اصلی وارد تفکیک‌کننده که وظیفه جداسازی داده‌های واقعی^۶ از داده‌های ساختگی^۷ را دارد می‌شوند. این فرآیند همانند یک بازی صفر و یک می‌ماند که شبکه مولد همواره سعی بر فریب شبکه تفکیک‌کننده دارد و این فرآیند تا زمانی ادامه دارد که دو شبکه به یک نقطه تعادل برسند. در این نقطه تعادل، مقدار خطای شبکه تفکیک‌کننده برابر با ۰/۵ و مقدار خطای شبکه مولد بین ۰/۵ تا ۱/۵ است. مولد و تفکیک‌کننده هر دو دارای نگاهت‌های غیرخطی هستند. اگر شبکه مولد را با G و تفکیک‌کننده را با D نمایش دهیم، مولد یک نگاهت از توزیع فضای پنهان $d_z(z)$ با استفاده از تابع $G(z)$ انجام می‌دهد تا داده x از روی متغیر تصادفی Z تولید شود. در ادامه، تابع تفکیک‌کننده $D(x)$ مشخص می‌کند که آیا x توسط مولد تولید شده است یا داده واقعی می‌باشد. برای این منظور، مولد و تفکیک‌کننده هم‌زمان آموزش داده می‌شوند و پارامترهای مولد و تفکیک‌کننده به‌گونه‌ای تنظیم می‌شوند تا مقدار $\log(1-D(G(z)))$ برای مولد و $\log D(x)$ برای

تفکیک‌کننده به مقدار کمینه خود دست یابند. در شبکه‌های مولد تخصصی شرطی، هم مولد و هم تفکیک‌کننده با استفاده از یک پارامتر دیگر به نام y مشروط می‌شوند. y می‌تواند هر نوع داده کمکی نظیر برجسب داده‌ها باشد. در شبکه‌های مولد تخصصی شرطی y به‌عنوان ورودی به مولد و تفکیک‌کننده داده می‌شود. بنابراین تابع هزینه تحت شرط y به‌صورت زیر تعریف می‌شود:

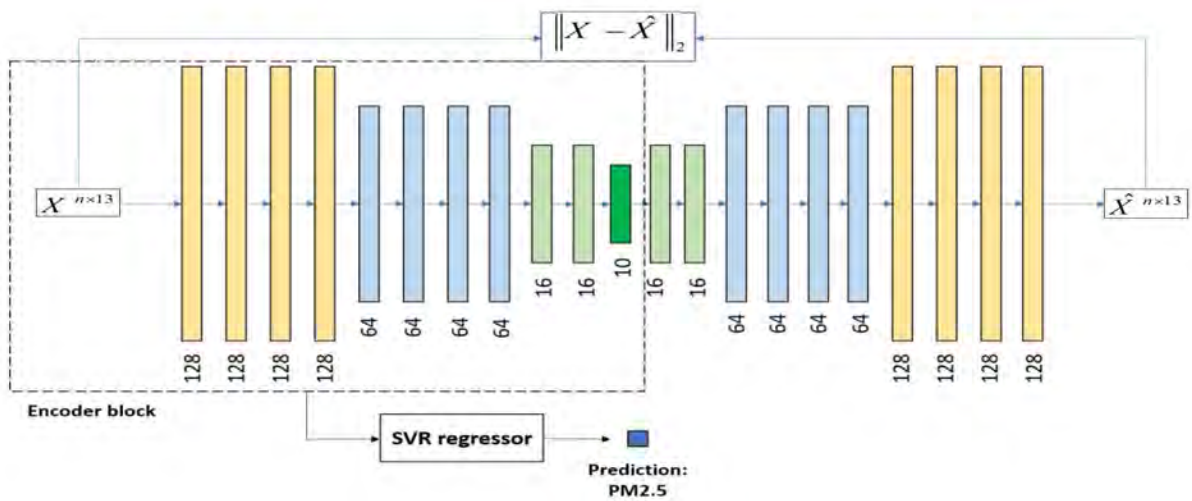
$$\text{MinMaxV}(D,G) = E_{x \sim dx} [\log D(x|y)] + E_{z \sim p(z)} [\log(1-D(G(z|y)))]$$

در این مقاله رگرسیون بین داده‌های غلظت PM2.5 و داده‌های ایروسل و هواشناسی توسط شبکه‌های CGAN صورت گرفته است. شبکه بر اساس رابطه‌ای که تفکیک‌کننده برای تشخیص داده‌های واقعی و غیرواقعی به‌دست آورده است، کار نگاهت غلظت PM2.5 را انجام می‌دهد.

۳-۶- مدل یادگیری عمیق بولتزمن

ماشین‌های بولتزمن، مدل‌های یادگیری عمیق تصادفی هستند که فقط دارای دو نوع گره هستند: گره‌های مخفی و گره‌های قابل مشاهده، درحالی‌که هیچ گره خروجی ندارد. عدم وجود گره خارجی به آن‌ها خاصیت تصادفی بودن داده است. برخلاف سایر شبکه‌های قدیمی که در آن‌ها هیچ ارتباطی بین گره‌های ورودی وجود نداشت، در ماشین‌های بولتزمن بین گره‌های ورودی ارتباط برقرار شده است. این ویژگی به آن‌ها این توانایی را داده است که اطلاعات را بین یکدیگر به اشتراک بگذارند و تولیدکننده داده‌های بعدی، خودشان باشند. زمانی که به آن‌ها ورودی داده می‌شود، قادر هستند تمام پارامترها، الگوها و همبستگی‌های میان داده‌ها را به‌دست آورند (Hinton, 2012). ماشین‌های محدود بولتزمن (RBM)^۸ به‌عنوان یک نوع خاص و محبوب ماشین‌های بولتزمن، شبکه‌های عصبی دولا به باقابلیت مولد بودن هستند که قادر به یادگیری احتمال توزیع در داده‌های ورودی هستند (Hinton, 2012). در این ماشین‌ها ارتباط میان

- 1- Generative Adversarial Neural Network
- 2- Conditional GAN
- 3- Generator
- 4- Discriminator
- 5- Latent space
- 6- real
- 7- fake



نگاره ۳: ساختار شبکه خود رمزنگار عمیق مورد استفاده به منظور تخمین غلظت PM2.5

بنابراین وزن‌ها در هر مرحله تکرار برای کمینه کردن این خطا سرشکن می‌شوند. به بیان دقیق‌تر اگر احتمال خروجی $h^{(1)}$ ، از ورودی $v^{(0)}$ و وزن‌های W ، به صورت زیر نمایش داده شود:

$$P(h^{(1)} | v^{(0)}; W)$$

و در مرحله بازگشت، (مرحله بازسازی ورودی‌ها)، احتمال خروجی $v^{(1)}$ از ورودی $h^{(1)}$ با وزن W به صورت زیر محاسبه شود:

$$P(v^{(1)} | h^{(1)}; W)$$

تابع توزیع احتمال توأم به صورت $P(v, h)$ باید مینیم شود تا اختلاف توزیع‌های احتمال تعریف‌شده در بالا به حداقل برسد.

۴- پیاده‌سازی و نتایج

نگاره ۳ ساختار شبکه خود رمزنگار مورد استفاده شامل تعداد لایه‌ها و تعداد نرون‌های درون هر لایه را نشان می‌دهد. همان‌گونه که در نگاره ۳ نشان داده شده است شبکه از دو بلوک اصلی رمزگذار و رمزگشا تشکیل شده است. ویژگی‌های استخراج‌شده توسط شبکه وارد یک مدل رگرسیون بر مبنای ماشین بردارهای پشتیبان (SVR)^۱ می‌شوند. وظیفه SVR تخمین PM2.5 از روی ویژگی‌های تولیدشده توسط رمزنگار هست. در طراحی شبکه از تابع فعال‌سازی ReLU^۲ برای تمام لایه‌ها به جز لایه آخر استفاده

گره‌های مخفی و گره‌های قابل مشاهده محدود شده‌اند که این موضوع اجرا کردن آن‌ها را نسبت به شبکه‌های بولتزمن آسان‌تر کرده است. همان‌طور که قبلاً گفته شد ماشین‌های محدود بولتزمن شبکه‌هایی دولایه هستند که این دولایه به صورت کامل توسط یک گراف دوطرفه به یکدیگر متصل شده‌اند. به این معنی که هر گره در لایه قابل مشاهده با هر گره در لایه پنهان در ارتباط است، اما هیچ دو گره‌ای در یک لایه یکسان با هم در ارتباط نیستند (نگاره ۸).

در یک RBM، یک نمودار دوبخشی متقارن داریم که هیچ دو واحد در یک گروه به هم متصل نیستند. چندین RBM می‌توانند به صورت پشت سر هم به یکدیگر متصل شوند و از طریق روند نزولی شیب و الگوریتم انتشار مجدد تنظیم شوند. چنین شبکه‌ای را شبکه باور عمیق می‌نامند (نگاره ۸). در یک بلوک RBM اگر ورودی‌ها در لایه مرئی، $v^{(0)}$ ، ماتریس وزن و c بایاس شبکه باشد، خروجی لایه مرئی برابر است با:

$$h^{(1)} = S(v^{(0)T} W + c)$$

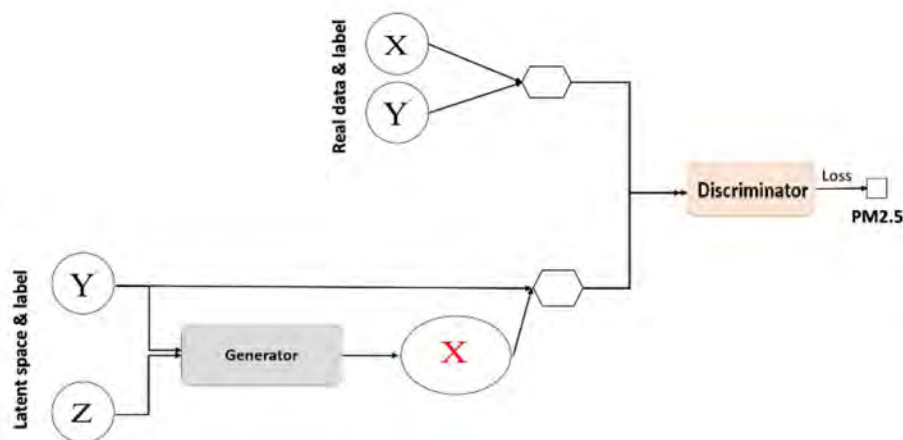
که در آن S تابع فعال‌سازی می‌باشد. در فرآیند بازسازی داریم:

$$v^{(1)} = S(h^{(1)} W^T + a)$$

اختلاف میان $v^{(0)}$ - $v^{(1)}$ می‌تواند به عنوان خطای بازسازی در نظر گرفته شود که در فرآیند آموزش تلاش می‌شود وزن‌ها به گونه‌ای تنظیم شوند تا این خطا به حداقل برسد.

1- Support Vector Regressor

2- Rectified Linear Unit



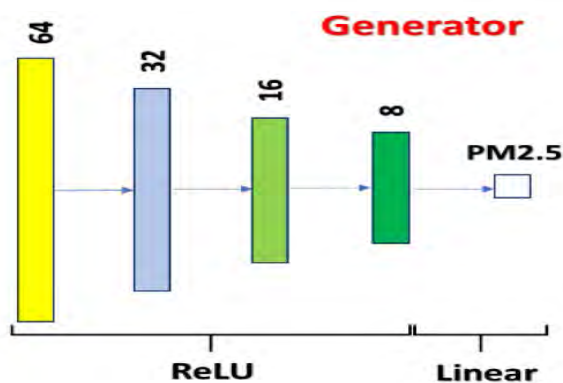
نگاره ۴: ساختار شبکه CGAN
 مورد استفاده به منظور تخمین
 غلظت PM2.5

جعلی مورد استفاده قرار می‌گیرد. در فرآیند آموزش دادن شبکه مولد تخصصی چالش‌های زیادی هستند که می‌توانند مشکل‌ساز شوند و فرآیند یادگیری شبکه‌های مولد تخصصی را نسبت به سایر شبکه‌های عصبی سخت‌تر کنند. یکی از بزرگ‌ترین این چالش‌ها که در فرآیند پیاده‌سازی این مقاله نیز مشکل‌ساز شد مشکل عدم همگرایی در شبکه‌های مولد تخصصی است. یادگیری شبکه‌های مولد تخصصی بر اساس یک بازی مجموع صفر (نظریه بازی) می‌باشد.


مولد همواره سعی بر فریب دادن تشخیص‌دهنده دارد به‌صورتی که توان تشخیص داده‌های تولیدشده از داده‌های واقعی را نداشته باشد و تشخیص‌دهنده نیز سعی بر ناکام گذاشتن شبکه مولد دارد که این موضوع موجب عدم همگرایی می‌شود. راه‌حل مناسب برای حل این مشکل یافتن مقادیر مناسب برای هر لایه در شبکه‌های مولد و

شده است. همچنین به‌منظور جلوگیری از بیش‌برازش از نرم L_2 با پارامتر تنظیم‌کننده $0/001$ در تمامی لایه‌ها استفاده شده است. شبکه با بهینه‌ساز Adam و با نرخ یادگیری $0/001$ در 200 اپک آموزش داده شده است. همچنین در تنظیم ماشین بردار پشتیبان از هسته تابع پایه شعاعی (RBF) با پارامتر تنظیم‌کننده 100 استفاده شده است.

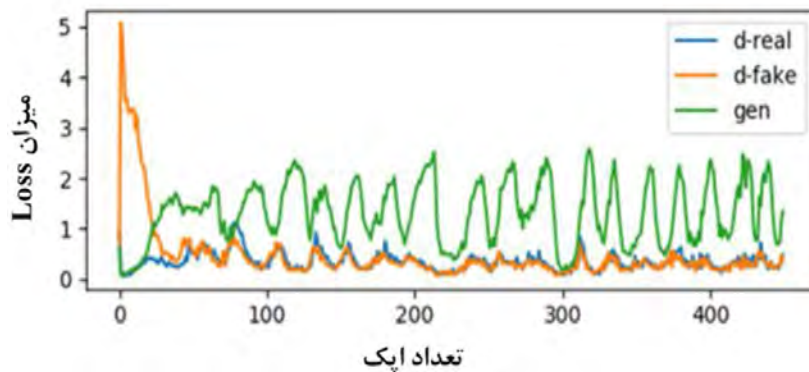
نگاره ۴ ساختار شبکه CGAN مورد استفاده در این تحقیق به‌منظور تخمین داده‌های غلظت PM2.5 را با استفاده از داده‌های ایروسل و پارامترهای هواشناسی نشان می‌دهد. در قسمت مولد ۴ لایه تمام متصل از نرون‌ها، همان‌گونه که در نگاره ۶ نشان داده شده است، برای تولید داده‌های جعلی از داده‌های ورودی ایروسل و پارامترهای هواشناسی به‌کار می‌رود. سپس شبکه تفکیک‌کننده با ساختار نمایش داده شده در نگاره ۵ به‌منظور تشخیص داده‌های واقعی و



نگاره ۶: ساختار مولد در شبکه CGAN



نگاره ۵: ساختار تفکیک‌کننده در شبکه CGAN



نگاره ۷: آموزش شبکه CGAN تا رسیدن به نقطه تعادل، d-real خطای تابع تفکیک کننده برای داده‌های واقعی، d-fake خطای تابع تفکیک کننده برای داده‌های جعلی و gen خطای تابع مولد را نشان می‌دهد

برای آموزش شبکه‌ها، داده‌های جمع‌آوری شده در بازه زمانی ۲۰۲۰-۲۰۱۳ شامل ویژگی‌هایی نظیر عمق نوری ابروسل، پارامترهای هواشناسی، موقعیت جغرافیایی و شماره روز سال به صورت یک بردار $X^{13 \times 1}$ به شبکه وارد شد. همچنین مقادیر زمینی PM2.5 به دست آمده از ایستگاه‌های کنترل کیفیت هوا به عنوان برچسب برای آموزش شبکه در نظر گرفته شد. داده‌های به دست آمده به سه دسته داده‌های آموزشی، اعتبارسنجی و داده‌های تست تقسیم گردید. داده‌های آموزشی برای آموزش شبکه و داده‌های اعتبارسنجی برای بررسی عملکرد شبکه‌ها در حین آموزش و تعیین هاپیرپارامترها نظیر ساختار شبکه، تعداد لایه‌ها و تعداد نرون‌ها مورد استفاده قرار گرفت. در نهایت مدل‌های به دست آمده طی فرآیند آموزش و اعتبارسنجی توسط داده‌های تست مورد ارزیابی قرار گرفتند. در پایان نتایج حاصل از ارزیابی توسط معیارهای مختلف اندازه‌گیری دقت با یکدیگر مقایسه گردید که در جدول ۲ برحسب معیارهایی نظیر جذر میانگین مربعات خطا (RMSE)^۵، میانگین مطلق خطاها (MAE)^۶ و ضریب همبستگی (R^2) ارائه شده است.

علاوه بر مدل‌های یادگیری عمیق مولد، مدل‌های خطی (ساده، Ridge، Lasso) که در مدل‌سازی مقادیر غلظت بسیار مورد استفاده قرار گرفته‌اند هم به منظور مقایسه پیاده‌سازی شدند. همان‌طور که در جدول ۲ نشان داده شده است، شبکه خود رهنگار عمیق با رسیدن به RMSE با مقدار

تشخیص دهنده است. برای تشخیص اینکه شبکه دچار عدم همگرایی نشده باشد، باید میزان تابع خطای دو شبکه مولد و تشخیص دهنده در یک بازه تعادل قرار بگیرد که این بازه تعادل مقدار خطای میانگین ۰/۵ یا حداکثر ۰/۷ تا ۰/۸ برای تشخیص دهنده و میزان خطای مولد بین ۱ تا ۲ است. در نگاره ۷ فرآیند آموزش دو شبکه مولد و تفکیک کننده نشان داده شده است.


همان‌گونه که در نگاره ۷ نشان داده شده است، شبکه تفکیک کننده با خطای کمتر از ۰/۵ داده‌های جعلی^۱ و واقعی^۲ را از هم تفکیک نموده است که نشان دهنده عملکرد و آموزش مناسب تابع تشخیص هست. اما میزان خطای شبکه مولد که هدف در فریب دادن شبکه تشخیص دارد بین مقادیر ۱ تا ۲ در حال نوسان هست. در نهایت با رسیدن به نقطه تعادل دو شبکه درجایی با هزینه حدود ۰/۵ برای تابع تشخیص و ۱/۵ برای تابع مولد، فرآیند آموزش متوقف می‌شود.

نگاره ۸ ساختار شبکه باور عمیق مورد استفاده در این مقاله را نشان می‌دهد. برای تخمین PM2.5 از دو بلوک RBM تشکیل شده است. لایه اول به عنوان لایه مرئی^۳ و لایه بعدی به عنوان لایه پنهان^۴ در نظر گرفته شده است. در نتیجه شبکه در مجموع با دو لایه پنهان با ۶۴ و ۸ نرون و یک لایه ورودی (مرئی) ساخته می‌شود.

- 1- Fake
- 2- Real
- 3- visible
- 4- hidden

5- Root Mean Square Error

6- Mean Absolute Error



نگاره ۸: ساختار شبکه باور عمیق تشکیل شده از بلوک‌های RBM به منظور تخمین غلظت PM2.5

CGAN بر روی این داده‌ها با چالش‌های فراوانی همراه بوده است، در ابتدا الگوریتم با عدم همگرایی مواجه بوده که این موضوع در شبکه‌های GAN بسیار رایج است و باید خطای تفکیک‌کننده به عدد ۰/۵ همگرا شود و خطای مولد نیز در بازه ۰/۵ و ۱/۵ قرار گیرد که این موضوع در مسائل رگرسیون و کار با داده‌هایی با دامنه تغییرات زیاد مسئله را کمی مشکل می‌کند.

زمانی که دامنه تغییرات داده‌ها زیاد باشد مولد به راحتی می‌تواند داده‌هایی تولید کند که تفکیک‌کننده نتواند به خوبی میزان درست یا غلط بودن آن‌ها را به درستی تشخیص دهد و همین موضوع باعث می‌شود بعد از چند مرحله آموزش الگوریتم، شاهد پایین آمدن سریع مقدار خطای مولد و بالا

۸/۷۸ میکروگرم بر مترمکعب بر روی داده‌های آموزشی و ۱۰/۳۴ میکروگرم بر مترمکعب بر روی داده‌های تست دارای بهترین میزان RMSE در میان الگوریتم‌های موجود می‌باشند. همچنین از نظر سایر معیارها نیز نظیر MAE و R^2 ، شبکه خود رمزنگار بالاترین دقت را نسبت به سایر مدل‌ها به دست داده است. پس از آن شبکه بولتزمن با داشتن مقادیر نزدیک به مقادیر شبکه خود رمزنگار عمیق، عملکرد مطلوبی را از خود نشان داده است. عملکرد شبکه CGAN در تخمین غلظت PM2.5 از مقادیر داده‌های ابروسل، پایین‌تر از سایر شبکه‌های مولد عمیق هست با این حال شبکه CGAN نسبت به الگوریتم‌های رگرسیون خطی بر روی داده‌های تست عملکرد بهتری را از خود نشان داده است. استفاده از شبکه

جدول ۲: مقایسه نتایج الگوریتم‌ها

مدل مورد استفاده		نتایج بر روی داده‌های یادگیری			نتایج بر روی داده‌های آزمون		
		RSME ($\mu\text{g}/\text{m}^3$)	MAE ($\mu\text{g}/\text{m}^3$)	R^2	RSME ($\mu\text{g}/\text{m}^3$)	MAE ($\mu\text{g}/\text{m}^3$)	R^2
رگرسیون خطی	ساده	۱۱/۱۲	۸/۷۶	۰/۵۸	۱۵/۰۱	۱۱/۵۲	۰/۵۷
	لاسو (Lasso)	۱۱/۲۲	۸/۸۵	۰/۵۷	۱۲/۱۴	۹/۴۶	۰/۵۵
	ریدج (Ridge)	۱۱/۱۰	۸/۷۵	۰/۵۹	۱۴/۵۰	۱۱/۰۴	۰/۵۷
عمیق مولد	شبکه خود رمزنگار عمیق	۸/۷۸	۶/۶۷	۰/۷۷	۱۰/۳۴	۷/۹۵	۰/۶۹
	شبکه یادگیری عمیق بولتزمن	۹/۷۹	۷/۶۹	۰/۷۰	۱۰/۶۰	۸/۴۰	۰/۶۶
	CGAN	۱۲/۱۸	۹/۳۱	۰/۵۳	۱۱/۹۲	۹/۰۷	۰/۵۲

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (...)

استفاده از الگوریتم‌های یادگیری مولد عمیق به منظور تخمین غلظت ... / ۱۹

مدل خود رمزنگار تعلیم داده شده بر اساس مقدار ابروسل و پارامترهای هواشناسی درونیابی شده، پیش‌بینی شد. با توجه به اینکه در برخی پیکسل‌ها به دلیل ابر یا عوامل دیگر مقادیر ابروسل از دست رفته‌اند و در نتیجه امکان تخمین $PM_{2.5}$ در این نقاط با استفاده از مدل امکان‌پذیر نیست، از تکنیک درونیابی کریجینگ برای تخمین نهایی غلظت مورد استفاده قرار گرفت تا امکان تهیه نقشه آلودگی هوا با رزولوشن یک کیلومتری فراهم شود. نگاره ۹ نقشه‌های آلودگی هوای تهیه شده در روزهای مدنظر را نشان می‌دهد. همان‌گونه که در نگاره ۹ الف نشان داده شده است، در روز اول ژانویه سال ۲۰۱۸ بیشتر مناطق تهران دارای آلودگی هوا بیشتر از مقدار ۷۳ میکروگرم بر مترمکعب می‌باشند که با گزارش شرکت کنترل کیفیت هوا مبنی برای آلودگی هوا برای تمام گروه‌ها مطابقت دارد.


بر اساس گزارش شرکت کنترل کیفیت هوا غلظت $PM_{2.5}$ بین ۴۰ تا ۹۸ در ایستگاه‌های مختلف گزارش شده است که با مقادیر تخمین زده توسط الگوریتم شبکه عمیق (نقشه الف) مطابقت دارد. همچنین در نگاره ۹ (ب) قابلیت مدل در تهیه نقشه آلودگی هوا در یک روز پاک (۲۵ فوریه ۲۰۱۸) نشان داده شده است.

بنابر مقادیر تخمین زده توسط مدل اکثر نقاط دارای میزان غلظت کمتر از ۲۴ میکروگرم بر مترمکعب هست که بیانگر پاکی هوا در تاریخ مدنظر است. همچنین ایستگاه‌های

رفتن خطای تفکیک‌کننده باشیم تا جایی که از یک مرحله به بعد میزان خطای مولد پایین‌تر از خطای تفکیک‌کننده یا برابر با آن می‌شود. به همین دلیل شبکه تفکیک بسیار قوی‌تر از شبکه مولد ساخته شده است که البته خود این موضوع هم باز چالش عدم همگرایی شبکه را به وجود می‌آورد و اگر شبکه مولد از یک مقدار ضعیف‌تر باشد مجدداً عدم همگرایی به وجود خواهد آمد.

در میان الگوریتم‌های خطی، بالاترین دقت توسط الگوریتم لاسو با RSME به میزان ۱۲/۱۴ میکروگرم بر مترمکعب و MAE به مقدار ۹/۴۶ میکروگرم بر مترمکعب بر روی داده‌های تست به دست آمده است که اهمیت استفاده از پارامتر بهینه‌ساز در این الگوریتم‌ها را نشان می‌دهد. با این حال دقت رگرسیون‌های خطی بسیار پایین‌تر از الگوریتم‌های یادگیری عمیق مولد هست.

به منظور بررسی دقیق‌تر عملکرد مدل خود رمزنگار توسعه داده شده، نقشه آلودگی هوا برای آلاینده $PM_{2.5}$ با رزولوشن یک کیلومتر برای دو روز آلوده (یکم ژانویه ۲۰۱۸) برای همه گروه‌ها و روز پاک (۲۵ فوریه ۲۰۱۸) تهیه شد (نگاره ۹). برای این منظور در هر پیکسل ماهواره‌ای مقدار ابروسل از داده‌های مودیس استخراج شد. همچنین مقادیر پارامترهای هواشناسی (حاصل از مدل ERA5) در هر پیکسل، با استفاده از درونیابی به روش کریجینگ مشخص شد. سپس در هر پیکسل مقدار غلظت $PM_{2.5}$ با استفاده از



ب) ۲۵ فوریه ۲۰۱۸: روز پاک

الف) ۱ ژانویه ۲۰۱۸: روز آلوده

نگاره ۹: نقشه آلودگی هوای شهر تهران

۵- نتیجه گیری

در این مقاله امکان استفاده از شبکه‌های عمیق عصبی مولد برای تخمین مقادیر غلظت PM2.5 از داده‌های روزانه ایروسل ماهواره‌ای و هواشناسی در سطح شهر تهران مورد بررسی قرار گرفت. برای این منظور سه مدل یادگیری عمیق مولد، یعنی شبکه باور عمیق بولتزنمن، شبکه خود رمزنگار عمیق، شبکه مولد تخصصی شرطی پیاده‌سازی شد. به منظور مقایسه، عملکرد شبکه‌ها به روی داده‌های تست مورد مقایسه و ارزیابی قرار گرفت. نتایج نشان داد که شبکه خود رمزنگار عمیق و بولتزنمن در مسائل رگرسیون تخمین آلودگی هوا از داده‌های ایروسل که دارای دامنه تغییرات بزرگی هستند نسبت به شبکه‌های مولد تخصصی عملکرد بهتری دارند. با این حال شبکه مولد تخصصی نسبت به مدل‌های کلاسیک نظیر رگرسیون خطی دقت بالاتری را در تخمین غلظت PM2.5 به دست می‌دهد.

منابع و مأخذ

- 1- Arciszewska, C., & McClatchey, J. (2001). The importance of meteorological data for modelling air pollution using ADMS-Urban. *Meteorological Applications*, 8(3), 345-350.
- 2- Bagheri, H., Sadeghian, S., & Sadjadi, S. Y. (2014). The Assessment of using an Intelligent Algorithm for the Interpolation of Elevation in the DTM Generation. *PFG Photogrammetrie, Fernerkundung, Geoinformation*, 197-208.
- 3- Beckerman, B. S., Jerrett, M., Martin, R. V., van Donkelaar, A., Ross, Z., & Burnett, R. T. (2013). Application of the deletion/substitution/addition algorithm to selecting land use regression models for interpolating air pollution measurements in California. *Atmospheric environment*, 77, 172-177.
- 4- Chen, B., You, S., Ye, Y., Fu, Y., Ye, Z., Deng, J., Hong, Y. (2021). An interpretable self-adaptive deep neural network for estimating daily spatially-continuous PM2.5 concentrations across China. *Science of The Total Environment*, 768, 144724.

زمینی در این روز مقادیر بین ۸ تا ۲۶ میکروگرم بر مترمکعب را برای غلظت PM2.5 ثبت نموده‌اند که با مقادیر نمایش داده شده در نقشه ب تطابق دارد. به بیان دیگر نقشه‌های به دست آمده توانایی مدل عمیق خود رمزنگار در تخمین ذرات معلق PM2.5 را ثابت می‌کند. به طور کلی تخمین مقدار آلودگی سطحی از داده‌های ایروسل ماهواره‌ای و داده‌های هواشناسی فرآیند پیچیده و چالش برانگیزی می‌باشد. خصوصاً زمانی که هدف برآورد آلودگی در رزولوشن‌های زمانی روزانه و رزولوشن مکانی بالا (یک کیلومتر) باشد. مقالات پیشین دقت‌های برآورد PM2.5 را در سطح شهر تهران با همبستگی‌های ۰/۵۵ و حتی کمتر را گزارش کرده‌اند (Sotoudehian & Arhami, 2014, Ghotbi et al., 2016, Nabavi et al., 2019)

به طور کلی دقت تخمین غلظت PM2.5 به عواملی چون دقت بازیابی داده‌های ایروسل در منطقه مورد نظر، دقت و رزولوشن داده‌های هواشناسی و پیچیدگی الگوریتم وابسته می‌باشد. همانگونه که در مقاله بیان شد، رزولوشن داده‌های هواشناسی پایین‌تر است و درونیابی برای رسیدن به رزولوشن بالاتر تأثیر خود را در دقت نهایی می‌گذارد. از طرفی الگوریتم‌های پیچیده‌تر منجر به مدل‌سازی و تخمین دقیق‌تر می‌شوند، مسئله‌ای که در مقاله مورد بررسی قرار گرفته است. همچنین مقالات قبلی نشان داده‌اند پارامترهای هواشناسی و فیزیکی دیگری مثل حجم ترافیک، تخمین‌های اولیه از میزان آلودگی گسیل شده از آگروز ماشین‌ها و سایر ویژگی‌ها در تخمین آلودگی PM2.5 مؤثر هستند که به دلیل نبود داده از پارامترهای مذکور در منطقه مورد مطالعه (عدم وجود اندازه‌گیری)، منجر به تخمین آلودگی با دقت پایین‌تر (همبستگی کمتر) می‌شود. با این وجود از جدول نتایج و نقشه‌های آلودگی هوا برای دو روز نمونه پاک و آلوده، می‌توان نتیجه گرفت که الگوریتم مورد نظر با همبستگی حدود ۷۰٪ قادر به برآورد قابل قبولی از میزان غلظت PM2.5 و تغییرات آن در سطح شهر تهران با رزولوشن یک کیلومتر می‌باشد که در مطالعات قبلی تحقق نیافته بود.

- and regression models. *Pollution*, 6(3), 521-529.
- 15- Klemm, R. J., Mason Jr, R. M., Heilig, C. M., Neas, L. M., & Dockery, D. W. (2000). Is daily mortality associated specifically with fine particles? Data reconstruction and replication of analyses. *Journal of the Air & Waste Management Association*, 50(7), 1215-1222.
- 16- Levy, R., Mattoo, S., Munchak, L., Remer, L., Sayer, A., Patadia, F., & Hsu, N. (2013). The Collection 6 MODIS aerosol products over land and ocean. *Atmospheric Measurement Techniques*, 6(11), 2989-3034.
- 17- Li, L. (2020). A robust deep learning approach for spatiotemporal estimation of satellite AOD and PM_{2.5}. *Remote Sensing*, 12(2), 264.
- 18- Li, T., Shen, H., Yuan, Q., Zhang, X., & Zhang, L. (2017). Estimating ground-level PM_{2.5} by fusing satellite and station observations: a geointelligent deep learning approach. *Geophysical Research Letters*, 44(23), 11,985-911,993.
- 19- Lippmann, M., Ito, K., Nadas, A., & Burnett, R. T. (2000). Association of particulate matter components with daily mortality and morbidity in urban populations. *Research report (Health Effects Institute)*(95), 5-72, discussion 73.
- 20- Mirza, M., & Osindero, S. (2014). Conditional generative adversarial nets. *arXiv preprint arXiv:1411.1784*.
- 21- Nabavi, S. O., Haimberger, L., & Abbasi, E. (2019). Assessing PM_{2.5} concentrations in Tehran, Iran, from space using MAIAC, deep blue, and dark target AOD and machine learning algorithms. *Atmospheric Pollution Research*, 10(3), 889-903.
- 22- Ni, X., Cao, C., Zhou, Y., Cui, X., & P Singh, R. (2018). Spatio-temporal pattern estimation of PM_{2.5} in Beijing-Tianjin-Hebei Region based on MODIS AOD and meteorological data using the back propagation neural network. *Atmosphere*, 9(3), 105.
- 23- Peng, R. D., Bell, M. L., Geyh, A. S., McDermott, A., Zeger, S. L., Samet, J. M., & Dominici, F. (2009). Emergency admissions for cardiovascular and respiratory diseases and the chemical composition of fine particle air pollution. *Environmental health perspectives*, 117(6), 957-963.
- 5- Dominici, F., Peng, R. D., Bell, M. L., Pham, L., McDermott, A., Zeger, S. L., & Samet, J. M. (2006). Fine particulate air pollution and hospital admission for cardiovascular and respiratory diseases. *Jama*, 295(10), 1127-1134.
- 6- Ghotbi, S., Sotoudeheian, S., & Arhami, M. (2016). Estimating urban groundlevel PM₁₀ using MODIS 3km AOD product and meteorological parameters from WRF model. *Atmospheric Environment*, 141, 333-346.
- 7- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S. Bengio, Y. (2014). Generative adversarial nets. *Advances in neural information processing systems*, 27.
- 8- Gupta, P., & Christopher, S. A. (2009). Particulate matter air quality assessment using integrated surface, satellite, and meteorological products: Multiple regression approach. *Journal of Geophysical Research: Atmospheres*, 114(D14).
- 9- Habibi, R., Alesheikh, A. A., Mohammadinia, A., Sharif, M. (2017). An Assessment of Spatial Pattern Characterization of Air Pollution: A Case Study of CO and PM_{2.5} in Tehran, Iran. *ISPRS International Journal of Geo-Information*, 6(9).
- 10- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., Schepers, D. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 14(730), 1999-2049.
- 11- Hinton, G. E. (2012). A practical guide to training restricted Boltzmann machines. In *Neural networks: Tricks of the trade* (pp. 599-619): Springer.
- 12- Hoek, G., Beelen, R., De Hoogh, K., Vienneau, D., Gulliver, J., Fischer, P., & Briggs, D. (2008). A review of land-use regression models to assess spatial variation of outdoor air pollution. *Atmospheric environment*, 42(33), 7561-7578.
- 13- Hsu, N., Jeong, M. J., Bettenhausen, C., Sayer, A., Hansell, R., Seftor, C., Tsay, S. C. (2013). Enhanced Deep Blue aerosol retrieval algorithm: The second generation. *Journal of Geophysical Research: Atmospheres*, 118(16), 9296-9315.
- 14- Jafarian, H., & Behzadi, S. (2020). Evaluation of PM_{2.5} emissions in Tehran by means of remote sensing

24- Peters, A., Dockery, D. W., Muller, J. E., & Mittleman, M. A. (2001). Increased particulate air pollution and the triggering of myocardial infarction. *Circulation*, 103(23), 2810-2815.

25- Ruthotto, L., & Haber, E. (2021). An introduction to deep generative modeling. *GAMM-Mitteilungen*, e202100008.

26- Shahbazi, H., Taghvaei, S., Hosseini, V., Afshin, H. (2016) A GIS based emission inventory development for Tehran. *Urban Climate*, 17, 216-229

27- Sayer, A., Hsu, N., Bettenhausen, C., Jeong, M. J., & Meister, G. (2015). Effect of MODIS Terra radiometric calibration improvements on Collection 6 Deep Blue aerosol products: Validation and Terra/Aqua consistency. *Journal of Geophysical Research: Atmospheres*, 120(23), 12,157-112,174.

28- Sotoudeheian, S., & Arhami, M. (2014). Estimating ground-level PM 10 using satellite remote sensing and ground-based meteorological measurements over Tehran. *Journal of Environmental Health Science and Engineering*, 12(1), 1-13.

29- Vienneau, D., De Hoogh, K., Beelen, R., Fischer, P., Hoek, G., & Briggs, D. (2010). Comparison of land-use regression models between Great Britain and the Netherlands. *Atmospheric environment*, 44(5), 688-696.