

PM_{2.5} Concentration Forecasting Using Decomposition Method and Artificial Neural Network

Salah Baizidi

Master Student, Department of Environmental Sciences, Faculty of Natural Resources, University of Kurdistan, Iran.

Jamil Amanollahi

* Associate professor at Department of Environmental Sciences, Faculty of Natural Resources, University of Kurdistan, Iran. **(Corresponding Author)** j.amanollahi@uok.ac.ir

Abstract

Background and purpose: One of the key indicators in discussions about air quality is the concentration of PM_{2.5} particulate matter. This research employs a combined model that utilizes the maximum overlap discrete wavelet transform, variational mode decomposition, and backpropagation neural network (MODWT-VMD-BPNN). This two-stage decomposition technique aims to predict PM_{2.5} levels in the city of Urmia.

Material and Methods: Data on air quality in Urmia City, including levels of particulate matter (PM₁₀ and PM_{2.5}), carbon dioxide (CO₂), sulfur dioxide (SO₂), nitrogen dioxide (NO₂), and nitrogen monoxide (NO), were obtained from the General Directorate of Environmental Protection for the years 2019 to 2023. Meteorological data were sourced from the General Directorate of Meteorology of West Azerbaijan Province. In the first stage of the analysis, the original PM_{2.5} data series was decomposed into two high-frequency detail levels (d₁ and d₂) and one low-frequency approximation level (a₂) using the Maximum Overlap Discrete Wavelet Transform (MODWT) model. In the second stage, each of these detail and approximation levels was further decomposed into eight variable modes using the Variable Mode Decomposition (VMD) model. Subsequently, each variable mode was simulated and predicted using a backpropagation neural network (BPNN). To evaluate the accuracy and performance of the proposed model, it was compared with the MODWT-BPNN, VMD-BPNN, and standard BPNN models.

Results: After reviewing the results, the MODWT-VMD-BPNN model achieved R=0.92, RMSE=3.8074, and MAE=2.8582 during training, and R=0.80, RMSE=2.7679, and MAE=2.1840 during testing, demonstrating superior accuracy and performance compared to the other models.

Conclusion: The two-stage decomposition models tackle mode mixing effectively and enhance the extraction and prediction of multiple frequencies in PM_{2.5} data with greater precision.

Keywords: Prediction, Particulate Matter PM_{2.5}, Wavelet Transform, Variational Mode Decomposition, Back Propagation Neural Network

Open Access Policy: This is an open access article under the terms of the Creative Commons Attribution License, which permits use, distribution and reproduction in any medium, provided the original work is properly cited. To view a copy of this licence, visit <https://creativecommons.org/licenses/by/4.0/>

Received: 2024/10/22

Accepted: 2025/03/11

Doi:10.22038/jreh.2025.25799

► **Citation:** Baizidi S, Amanollahi J. PM_{2.5} Concentration Forecasting Using Decomposition Method and Artificial Neural Network. *Journal of Research in Environmental Health*. 11(1):83-97.

پیش‌بینی غلظت PM_{2.5} با استفاده از روش ترکیبی تجزیه‌ی و شبکه عصبی

صلاح بایزیدی

دانش‌آموخته‌ی کارشناسی ارشد محیط‌زیست، دانشکده منابع طبیعی، دانشگاه کردستان، کردستان، ایران.

جمیل امان‌اللهی

* دانشیار گروه محیط‌زیست، دانشکده منابع طبیعی، دانشگاه کردستان، کردستان، ایران. (نویسنده مسئول)

j.amanollahi@uok.ac.ir

چکیده

زمینه و هدف: یکی از شاخص‌های مهم در بحث کیفیت هوا، غلظت ذرات معلق PM_{2.5} می‌باشد. بدین‌منظور در این پژوهش از مدل ترکیبی تبدیل موجک گسسته حداکثر همپوشانی- تجزیه مد متغیر- شبکه عصبی پس‌انتشار (MODWT-VMD-BPNN) بر پایه تکنیک تجزیه دو مرحله‌ای برای پیش‌بینی ذرات معلق PM_{2.5} شهر ارومیه استفاده شده است.

مواد و روش‌ها: سری داده‌های اصلی ذرات معلق PM_{2.5} ابتدا توسط مدل تبدیل موجک گسسته حداکثر همپوشانی به دوسطح جزئیات با فرکانس بالا (d_1 و d_2) و یک سطح تقریب با فرکانس پایین (a_2) تجزیه و در مرحله دوم هر کدام از سطوح جزئیات و سطح تقریب توسط مدل تجزیه مد متغیر به ۸ مود متغیر تجزیه شد. سپس هر کدام از مدهای متغیر توسط شبکه عصبی پس‌انتشار مدلسازی و پیش‌بینی شدند.

یافته‌ها: بر اساس نتایج مدل‌های ترکیبی (MODWT-BPNN) و (VMD-BPNN) نسبت به مدل تکی شبکه عصبی پس‌انتشار (BPNN) عملکرد بهتری داشته‌اند. و در بین مدل‌های ترکیبی مدل (MODWT-BPNN) به دلیل تحلیل سیگنال‌هایی دارای تغییرات ناگهانی و ناپیوستگی موضعی به وسیله‌ی موجک‌ها عملکرد بهتری نسبت به مدل (VMD-BPNN) دارد. مدل ترکیبی تجزیه دو مرحله‌ای (MODWT-VMD-BPNN) نسبت به دیگر مدل‌های تجزیه‌ای تک مرحله‌ای و مدل تکی شبکه عصبی پس‌انتشار با مقادیر معیارهای ارزیابی خطا شامل $RMSE = 3/8074$ ، $MAE = 2/8582$ و $R = 0/92$ در مرحله آموزش و $RMSE = 2/1840$ ، $MAE = 0/80$ و $R = 0/80$ در مرحله آزمون، عملکرد بهتری داشته است.

نتیجه‌گیری: مدل‌های تجزیه‌ای دو مرحله‌ای با تجزیه سطح جزئیات و سطح تقریب به ۸ مود می‌تواند مشکل آمیختگی مدها را حل کند و پیش‌بینی میزان غلظت PM_{2.5} را با دقت بهتری انجام دهد لذا این مدل می‌تواند برای پیش‌بینی آلاینده‌های جوی به کار گرفته شود.

کلیدواژه‌ها: پیش‌بینی، ذرات معلق PM_{2.5}، تبدیل موجک، تجزیه مد متغیر، شبکه عصبی پس‌انتشار

◀ **استناد:** بایزیدی ص، امان‌اللهی ج. پیش‌بینی غلظت PM_{2.5} با استفاده از روش ترکیبی تجزیه‌ی و شبکه عصبی. فصلنامه‌ی پژوهش در بهداشت محیط. بهار ۱۴۰۴؛ ۱۱(۱): ۸۳-۹۷.

تاریخ دریافت: ۱۴۰۳/۰۸/۰۱

تاریخ پذیرش: ۱۴۰۳/۱۲/۲۱

نوع مقاله: پژوهشی

مقدمه

آلودگی هوا به دلیل چندوجهی بودن به یک معضل زیست‌محیطی تبدیل شده است که در کشورهای در حال توسعه افزایش یافته است (۱). ذرات معلق یکی از مهم‌ترین فاکتورهای مؤثر در آلودگی هوا است (۲). ذرات معلق درشت (PM_{10}) دارای قطر آبرودینامیکی بزرگتر از $2.5/10$ میکرون و کوچکتر از ۱۰ میکرون هستند در حالی که ذرات ریز ($PM_{2.5}$) قطرشان $2.5/10$ میکرون یا کمتر است. ذرات معلق به تنهایی یا در واکنش با آلاینده‌های دیگر خطرات و آسیب‌های بسیار شدیدی بر سلامت و کیفیت زندگی انسان دارد (۳). ذرات معلق باعث انواع بیماری‌ها از جمله بیماری‌های ریوی، قلبی، تخریب بافت ریه و مرگ و میر زودرس می‌شوند (۴). ذرات معلق هم‌چنین سبب کاهش میدان دید می‌شوند (۵). آبیدين و همکاران در سال ۲۰۲۵ (۶) نشان دادند که رابطه‌ی معنی‌داری ($p\text{-value} < 0.05$) بین میزان افزایش غلظت ذرات $PM_{2.5}$ و مشکلات سلامتی از جمله سرفه، سردرد، سوزش چشم، تنگی نفس و خس‌خس سینه وجود دارد. ویو و همکاران در سال ۲۰۲۵ (۷) نشان دادند $PM_{2.5}$ خطر بیماری قلبی‌ریوی و سرطان ریه را به ترتیب از $26/4\%$ درصد به $26/73\%$ درصد افزایش می‌دهد. هم‌چنین بیان داشتند که مواد موجود در $PM_{2.5}$ می‌تواند شاخص خطر سلامت را از $1/26$ تا $2/47$ درصد افزایش دهد که این خطر قابل توجهی برای کارگران در فضای باز ایجاد می‌کند. زنگ و همکاران در سال ۲۰۲۴ (۸) اثرات بهداشتی اولیه مولکول‌های آلی محلول در آب که از $PM_{2.5}$ موجود در هوا سرچشمه می‌گیرند به عنوان سمیت عصبی و سمیت تنفسی شناسایی کردند. مولکول‌های آلی محلول در آب که از منابع بیوژنیک و انتشارات اقیانوسی سرچشمه می‌گیرند عمده‌تاً مسئول اثرات نوروکسیک بودند، در حالی که آن‌هایی که از سوزاندن زیست توده و آگروز بنزین بودند عمده‌تاً باعث سمیت تنفسی می‌شدند. در سال‌های اخیر روش‌های مختلفی برای پیش‌بینی کانون‌های شکل‌گیری و میزان غلظت ذرات معلق ارائه شده است (۹،۱۰،۱۱). شبکه‌های عصبی مصنوعی (ANN^2) یکی از روش‌های موفق در علوم جوی است که برای سیستم‌های غیرخطی به کار برده می‌شود. برخی از

مطالعات تجربی تأیید کرده‌اند که روش تجزیه‌ی تک‌مرحله‌ای و دو مرحله‌ای و بازسازی سیگنال باعث افزایش صحت پیش‌بینی سری‌های زمانی می‌شود (۱۲،۱۳). بر اساس این تئوری در مدل‌های ترکیبی در مرحله‌ی اول سیگنال اصلی به یک سری اجزا تجزیه می‌شود. سپس هر کدام از اجزا توسط مدل پیش‌بینی مدل‌سازی و پیش‌بینی می‌شوند و در نهایت نتایج پیش‌بینی هر کدام از اجزا با هم جمع بسته می‌شود و پیش‌بینی نهایی به دست می‌آید. در این رابطه در سال ۲۰۱۴، ژائو و همکاران (۱۲) با استفاده از مدل‌های رگرسیون چندگانه، رگرسیون اجزای اصلی، خودرگرسیون میانگین متحرک انباشته، شبکه عصبی رگرسیون عمومی و مدل ترکیبی تجزیه‌ی حالت تجربی تجمعی- شبکه عصبی رگرسیون عمومی به پیش‌بینی ذرات معلق $PM_{2.5}$ شهر شیآن واقع در کشور چین پرداختند. نتایج به دست آمده نشان داد که مدل ترکیبی تجزیه حالت تجربی تجمعی- شبکه عصبی رگرسیون عمومی به دلیل استفاده از مدل تجزیه‌ی سیگنال و روش غیرخطی شبکه عصبی نسبت به دیگر مدل‌های تکی دارای دقت پیش‌بینی بالاتری بود. لیو و همکاران در سال ۲۰۱۵ (۱۳) از چهار مدل ترکیبی تجزیه‌ی تک مرحله‌ای بر پایه تبدیل موجک، تجزیه‌ی حالت تجربی، تجزیه‌ی بسته‌های موجک و تجزیه‌ی حالت تجربی تجمعی سریع با مدل ماشین یادگیری سریع برای پیش‌بینی سرعت باد استفاده کردند. نتایج نشان می‌دهد که هر چهار مدل ترکیبی، عملکرد بهتری نسبت به مدل تکی ماشین یادگیری سریع در پیش‌بینی دارند. فنگ و همکاران در مطالعه‌ی خود در سال ۲۰۱۵ (۱۴) به پیش‌بینی ذرات معلق $PM_{2.5}$ با استفاده از مدل جغرافیایی مبتنی بر مسیر جرم هوا و تبدیل موجک با شبکه عصبی مصنوعی پرداختند. نتایج نشان داد که مدل جغرافیایی مبتنی بر مسیر جرم هوا و تبدیل موجک می‌تواند ابزارهای مفید و موثری برای بهبود دقت پیش‌بینی $PM_{2.5}$ باشد. بای و همکاران در سال ۲۰۱۶ (۱۵) از تبدیل موجک و شبکه عصبی پسانتشار برای پیش‌بینی غلظت آلاینده‌های PM_{10} ، SO_2 و NO_2 استفاده کردند. نتایج از برتری مدل ترکیبی تبدیل

¹ Particulate Matter² Artificial Neural Network

BiLSTM، STA-BiLSTM، ELM، TCN^{۱۱} و Attention-TCN عملکرد بهتری داشته است. حتی در پیش‌بینی‌های چندمرحله‌ای و چرخشی، این مدل کمترین تأثیر را از خطاهای تجمعی گرفته و پیش‌بینی‌های دقیق را با تعمیم به مناطق دیگر را ارائه کرده است. سو و همکاران در سال ۲۰۲۴ (۲۰) به پیش‌بینی شاخص کمبود تبخیر و تعرق روزانه برای پیش‌بینی خشکسالی هواشناسی با مدل هیبریدی VMD-BiLSTM^{۱۲} پرداختند. آن‌ها نشان دادند در مقایسه با مدل‌های تکی، مدل VMD-BiLSTM نه تنها می‌تواند عدم قطعیت پیش‌بینی خشکسالی هواشناسی ناشی از ناهمگونی مدل آب‌وهوا را کاهش دهد، بلکه دقت پیش‌بینی خشکسالی را در مناطق خشک و نیمه‌خشک بهبود می‌بخشد که می‌تواند مرجعی برای مقابله با وقوع خشکسالی و هشدار زودهنگام آن باشد. با توجه به اهمیت میزان دقت پیش‌بینی ذرات معلق PM_{2.5} در کمک به سلامت جامعه و با توجه به این‌که غلظت ذرات معلق PM_{2.5} دارای تغییرات ناگهانی و ناپیوستگی موضعی است استفاده از مدل‌های تجزیه می‌تواند گام مهمی در راستای افزایش دقت پیش‌بینی این آلودگی باشد. از طرفی نظر به این‌که مدل تجزیه تک‌مرحله‌ای به‌تنهایی نمی‌تواند فرکانس‌های چندگانه در سیگنال PM_{2.5} را استخراج کند مدل‌های تجزیه دو مرحله‌ای با تجزیه‌ی زیرسری‌ها به چندین مود و جمع بستن نتایج پیش‌بینی هر یک از مودها می‌تواند راه‌حل مناسبی برای پیش‌بینی ذرات معلق PM_{2.5} باشد. لذا در این تحقیق با استفاده از روش تجزیه‌ی مبتنی بر MODWT-VMD و شبکه‌ی عصبی میزان غلظت PM_{2.5} در شهر ارومیه پیش‌بینی می‌گردد و جهت ارزیابی میزان دقت مدل ذکر شده نتایج آن با نتایج مدل‌های دیگری مورد مقایسه قرار گرفت.

روش کار

منطقه مورد مطالعه

شهرستان ارومیه مرکز استان آذربایجان غربی با مساحت ۴۲ / ۷ کیلومتر مربع و موقعیت ممتاز جغرافیایی در ۲۰ کیلومتری دریاچه‌ی ارومیه قرار دارد. شهر ارومیه بر روی

موجک- شبکه عصبی پس‌انتشار نسبت به مدل تکی شبکه عصبی پس‌انتشار حاکی بود. وانگ و همکاران در سال ۲۰۱۷ (۱۶) به پیش‌بینی غلظت PM_{2.5} روز آینده با استفاده از روش تجزیه‌ی مبتنی بر تبدیل موجک- تجزیه مد متغیر و شبکه عصبی پس‌انتشار پرداختند. به‌منظور بهبود دقت پیش‌بینی غلظت PM_{2.5}، این محققان یک مدل ترکیبی تجزیه دو مرحله‌ای مبتنی بر تبدیل موجک، تجزیه‌ی حالت متغیر و شبکه عصبی پس‌انتشار را مورد استفاده قرار دادند و نتایج این مدل تجزیه‌ی دو مرحله‌ای را با مدل‌های تجزیه‌ی تک مرحله‌ای و مدل فردی مقایسه کردند. نتایج به‌دست آمده ناشی از برتری مدل ترکیبی تجزیه‌ی دو مرحله‌ای نسبت به دیگر مدل‌ها برای پیش‌بینی بود. قیمر و همکاران در سال ۲۰۲۴ (۱۷) از مدل حداکثر هم‌پوشانی تبدیل موجک گسسته (MODWT^۱) برای پیش‌بینی‌های قیمت برق نیم‌ساعته استفاده کرد آن‌ها مدل پیش‌بینی شبکه‌های عصبی را با پیوند عملکردی بردار تصادفی (CRVFL^۲) در یک رویکرد ترکیبی ادغام کردند. نتایج نشان داد که این ترکیبی تبدیل موجک MODWT-CRVFL دارای عملکرد بهتری در رابطه با پیش‌بینی قیمت برق در مقایسه با مدل‌های LSTM^۳ و MLP^۴ بوده است. فانگ و همکاران در سال ۲۰۲۴ (۱۸) به پیش‌بینی تولید نفت بر اساس تجزیه‌ی حالت متغیر و مدل یادگیری گروهی VMD^۵ پرداختند. نتایج آن‌ها نشان داد که مدل VMD می‌تواند به‌طور موثری دقت پیش‌بینی را در مقایسه با مدل‌های SVM^۶ و RNN^۷ افزایش دهد. خیو و همکاران در سال ۲۰۲۴ (۱۹) در تحقیقی با استفاده از مدل ترکیبی VMD-STA^۸-BiLSTM^۹-ELM^{۱۰} به پیش‌بینی میزان جداسازی CH₄ و ترسیب CO₂ با تزریق CO₂ به درزهای زغال سنگ پرداخت. نتایج آن‌ها نشان داد که مدل هیبریدی در دقت پیش‌بینی از مدل‌های VMD-ELM، STA-BiLSTM-ELM،

¹ Maximal Overlap Discrete Wavelet Transform

² Convolutional Random Vector Functional Link

³ Long Short-Term Memory

⁴ Multilayer Perceptron

⁵ Variational Mode Decomposition

⁶ Support Vector Machines

⁷ Recurrent Neural Networks

⁸ Spatiotemporal Attention Mechanism

⁹ Bidirectional Long Short-Term Memory Network

¹⁰ Extreme Learning Machine

¹¹ Temporal Convolutional Networks

موضوع استفاده از مدل‌های غیرترکیبی مانند SVM که به وجود نویز در داده‌ها و نوسانات ناگهانی حساس است و یا مدل LSTM که برای الگوهای طولانی‌مدت طراحی شده و به تغییرات ناگهانی حساس است را با چالش‌های مواجه کرده است. با توجه به این موارد به نظر می‌رسد استفاده از مدل‌های تجزیه‌ی ترکیبی روش مناسبی برای غلبه بر این محدودیت‌ها باشد.

مدل‌های تجزیه‌ای

مدل تبدیل موجک گسسته حداکثر همپوشانی (MODWT)

تبدیل موجک (WT) یک روش قدرتمند برای پردازش سیگنال‌های غیرایستا می‌باشد (۱۶). موجک به موجی گفته می‌شود که دارای طول محدود و میانگین صفر در آن طول باشد.

فرآیند تجزیه سیگنال $S(t)$ به صورت زیر است:

$$S(t) = d_1 + d_2 + \dots + d_m + a_m \quad (3-1)$$

که d_1 ، d_2 و d_m زیرمجموعه‌های جزئیات و a_m زیرمجموعه تقریب است.

به‌طور کلی تبدیل موجک (WT^A) به دو دسته تبدیل موجک پیوسته (CWT^9) و تبدیل موجک گسسته (DWT^{10}) تقسیم می‌شود. در تبدیل موجک پیوسته حجم اطلاعات بسیار بالا است که به همه‌ی آن‌ها در بازسازی تابع و تحلیل پیوستگی‌ها نیاز نیست و حتی می‌توان با نمونه‌برداری، ضرایب موجک را به‌نحوی به‌دست آورد که تابع اصلی را از آن‌ها بازسازی نمود (۲۳).

مدل تجزیه‌ی مد متغیر VMD

تجزیه‌ی مد متغیر یک روش تجزیه‌ی سیگنال کارآمد می‌باشد. این روش در سال ۲۰۱۴ توسط دراگومیرتسکی و زوسو معرفی شد (۲۴). در این روش یک سیگنال حقیقی به مدهایی تجزیه می‌شوند که خاصیت تنکی در

مدار ۳۷ درجه و ۳۲ دقیقه عرض شمالی و ۴۵ درجه و ۲ دقیقه طول شرقی از نصف‌النهار گرینویچ و ارتفاع ۱۳۳۲ متری از سطح دریاهای آزاد واقع شده است. این شهر در جلگه‌ی گسترده و سرسبزی به درازای ۷۰ کیلومتر و پهنای ۳۰ کیلومتر قرار گرفته است. در ارومیه فصل زمستان هوا سرد و تابستان نسبتاً گرم است متوسط دمای حداکثر در این شهر در گرم‌ترین ماه سال با ۳۱/۱ درجه سانتی‌گراد متعلق به اواسط تیر تا اوایل شهریورماه است و متوسط دمای هوا در همین دوره حداقل به ۱۶/۲ درجه سانتیگراد می‌رسد در مجموع به‌مدت ۱۶۴ روز در معرض بادهای با سرعت حداقل ۷ و حداکثر ۱۶ متر بر ثانیه است قرار می‌گیرد (۲۱).

داده‌ها

داده‌های متوسط روزانه مربوط به کیفیت هوای شهر ارومیه شامل دی‌اکسیدکربن (CO_2)، ذرات معلق (PM_{10})، دی‌اکسیدسولفور (SO_2)، ذرات معلق ($PM_{2.5}$)، دی‌اکسیدنیتروژن (NO_2) و مونواکسیدنیتروژن (NO) طی سال‌های ۱۳۹۹-۱۴۰۲ از اداره‌ی کل حفاظت محیط‌زیست و داده‌های هواشناسی شامل بارش کل روزانه (PR^1)، میانگین حداقل دما ($MinT^2$)، میانگین حداکثر دما ($MaxT^3$)، میانگین فشار جوی (AP^4)، میانگین حداکثر رطوبت نسبی روزانه سطح هوا ($MaxH^5$)، میانگین حداقل رطوبت نسبی روزانه سطح هوا ($MinH^6$) و سرعت باد روزانه (WS^7) (۲۲) به‌صورت روزانه در دوره زمانی مذکور از اداره‌ی کل هواشناسی استان آذربایجان غربی تهیه گردید. در محاسبات، داده‌های روزها استفاده شد که تمامی پارامترهای ذکرشده اندازه‌گیری شده باشد و در صورت عدم اندازه‌گیری حتی یک پارامتر در یک روز خاص، داده‌های روز ذکر شده حذف گردید.

پیش‌بینی ذرات معلق $PM_{2.5}$ شهر ارومیه

داده وابسته این پژوهش $PM_{2.5}$ است. در مباحث قبلی توضیح داده شد که میزان غلظت این آلودگی دارای تغییرات ناگهانی و ناپیوستگی موضعی است که این

¹ Precipitation

² Minimum Temperature

³ Maximum Temperature

⁴ Air Pressure

⁵ Maximum Humidity

⁶ Minimum Humidity

⁷ Wind Speed

⁸ Wavelet Transform

⁹ Continuous Wavelet Transform

¹⁰ Discrete Wavelet Transform

طیف فرکانسی دارند. این الگوریتم به گونه ای است که مدهای متغیر (VMs^1)، به طور همزمان محاسبه می شوند و هر یک از مدهای متغیر حول یک فرکانس مرکزی متمرکز هستند (۲۵). به منظور تعیین پهنای باند هر مود مراحل زیر انجام می شود (۲۶).

۱- محاسبه ی سیگنال تحلیلی با هر مود، با استفاده از تبدیل هیلبرت برای یک طرفه شدن طیف فرکانسی.

۲- انتقال طیف فرکانسی مود، با استفاده از اختلاط با یک سیگنال تک فرکانسی با فرکانس w_k به باند پایه برای هر مود (مرحله ی دمدولاسیون)

۳- استخراج سیگنال دمدولاسیون با کمک پهنای باند به وسیله تابع گوسی H

نتیجه به صورت رابطه زیر به دست می آید:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \text{ subject to } \sum_k u_k = f$$

(۳-۲)

در این فرمول $\{u_k\}: \{u_1, u_2, \dots, u_k\}$ و $\{\omega_k\}: \{\omega_1, \omega_2, \dots, \omega_k\}$ به ترتیب نشانه های اختصاری برای مجموعه ای از همه ی حالت ها و فرکانس های مرکز آنها است. $\delta(t)$ توزیع دیراک^۲ و * نشان پیچیدگی است. دراگومیرتسکی و زوسو (۲۰۱۴) برای در نظر گرفتن شرط بازسازی به صورت هم زمان از دو تابع جزای درجه دو (quadratic penalty term) و افزایش لگرانژی (Lagrangian multipliers) استفاده کردند.

مدل پیش بینی شبکه ی عصبی پس انتشار (BPNN^۳)

ساختار MLP اساساً یک آرایش لایه ای از نورون ها است که شامل سه لایه ی اصلی است: یک لایه ی ورودی (با یک تابع ورودی)، یک لایه ی پنهان و یک لایه ی خروجی نهایی. هر لایه شامل چندین نورون است که ساختار پایه مدل را تشکیل می دهد در تحقیق حاضر تعداد نورون ها برای لایه ی پنهان ۱۵ عدد در نظر گرفته شده است . MLP یک شبکه پیش خور است که مجموعه ورودی ها

را با استفاده از یک تابع فعال سازی غیرخطی به مجموعه ای از خروجی های دلخواه تبدیل می کند. با استفاده از الگوریتم Back Propagation برای تمرین، وزن ها به طور مکرر در MLP تغییر می کنند تا خطا بین خروجی ها و نتایج مورد انتظار به حداقل برسد (۲۵). از کل داده های مورد استفاده در این تحقیق ۸۰ درصد برای مرحله ی مدل سازی و ۲۰ درصد برای مرحله ی آموزش مدل MLP در نظر گرفته شده است. مدل پس انتشار یک قانون یادگیری برای پرسپترون چندلایه (MLP) است. این الگوریتم متشکل از ۴ گام است. بدین ترتیب که پس از انتخاب تصادفی ضرایب وزن شبکه، گام های زیر طی می شود:

- ۱- سطح فعالیت خروجی نورون ها در مسیر ورودی به خروجی محاسبه می شود.
- ۲- سپس به لایه خروجی پس انتشار می شود و ضرایب وزن لایه خروجی را تغییر می دهد.
- ۳- پس از آن به لایه های مخفی پس انتشار می شود و ضرایب وزن لایه های مخفی را تغییر می دهد.
- ۴- این الگوریتم تا هنگامی که شبکه به آستانه ی خطای مورد پذیرش برسد یا تعداد تکرارهای تعیین شده انجام شود تکرار می شود.

مدل های تجزیه و پیش بینی تک مرحله ای مدل ترکیبی تبدیل موجک گسسته حداکثر همپوشانی - شبکه عصبی پس انتشار (MODWT- BPNN)

در این مدل ترکیبی، ابتدا با استفاده از روش تبدیل موجک گسسته حداکثر همپوشانی، داده های PM_{2.5} اصلی به چندین سطوح جزئیات با فرکانس بالا و یک سطح تقریب با فرکانس پایین تجزیه می شود. در مرحله ی بعد هر کدام از سطوح، توسط شبکه عصبی پس انتشار مدل سازی می شود و در نهایت با جمع زدن نتایج پیش بینی هر کدام از سطوح، پیش بینی نهایی انجام می شود.

مدل ترکیبی تجزیه ی مد متغیر- شبکه عصبی پس انتشار (VMD- BPNN)

در مرحله ی اول داده های PM_{2.5} اصلی توسط مدل تجزیه ی مد متغیر به تعدادی از مدهای متغیر (VMs) تجزیه می شود و سپس در مرحله ی بعد هر یک از

¹ Variational Modes

² Dirac

³ Back Propagation Neural Network

مرحله‌ی پنجم با جمع‌زدن نتایج پیش‌بینی به‌دست آمده از هر سطح، پیش‌بینی نهایی انجام می‌گیرد.

یافته‌ها

آماده‌سازی داده‌ها و انتخاب متغیرهای مستقل

مؤثر

از میان داده‌ها پس از نرمال‌سازی و مرتب‌کردن، تعداد ۴۵۰ داده برای مرحله‌ی آموزش و ۳۰ داده برای مرحله‌ی آزمون مدل‌ها مورد استفاده قرار گرفت. داده‌های ذرات معلق PM_{2.5} یک روز آینده به‌عنوان متغیر وابسته و دیگر داده‌های هواشناسی و کیفیت هوا به‌عنوان متغیرهای مستقل مورد استفاده قرار می‌گیرد. در این مطالعه برای از بین بردن اثر هم‌خطی بین متغیرهای مستقل از روش گام به گام استفاده گردید. از میان متغیرهای مستقل وارد شده در مدل، متغیرهای CO، PM_{2.5} روز قبل، NO₂، MaxT و MinR در مدل باقی‌مانده و در نتیجه میزان غلظت این متغیرها بر میزان غلظت PM_{2.5} شهر ارومیه مؤثر بوده است (جدول ۱).

زیرمجموعه‌ها توسط مدل پیش‌بینی شبکه عصبی پس‌انتشار خطا پیش‌بینی شده و در نهایت با جمع‌زدن نتایج هر یک از زیرمجموعه‌ها، پیش‌بینی نهایی به‌دست می‌آید.

مدل‌های تجزیه و پیش‌بینی دو مرحله‌ای مدل

ترکیبی تبدیل موجک گسسته حداکثر

همپوشانی - تجزیه مد متغیر - شبکه عصبی

پس‌انتشار (MODWT- VMD- BPNN)

فرآیند کلی این روش در پنج مرحله به‌ترتیب زیر انجام می‌شود: در مرحله‌ی اول، داده‌های اصلی PM_{2.5} توسط مدل تبدیل موجک گسسته حداکثر همپوشانی به چندین سطوح جزئیات با فرکانس بالا و یک سطح تقریب با فرکانس پایین تجزیه می‌شود. در مرحله‌ی دوم، هر کدام از سطوح توسط مدل تجزیه مد متغیر به تعدادی از توابع مد متغیر (VMs) تجزیه می‌شوند. در مرحله‌ی سوم هر کدام از مدهای متغیر توسط مدل شبکه عصبی پس‌انتشار پیش‌بینی می‌شوند. در مرحله‌ی چهارم، با جمع‌زدن نتایج پیش‌بینی مدهای متغیر، نتیجه‌ی اولیه پیش‌بینی (سطوح تقریب و جزئیات) به‌دست می‌آید و در نهایت در

جدول ۱. میزان هم‌خطی بین همه متغیرهای مستقل

متغیرهای مستقل اولیه	VIF	متغیرهای مستقل نهائی	VIF
NO	۱/۶۲۴	NO ₂	۱/۳۴۷
NO ₂	۲/۳۰۶	CO	۱/۰۱۷
PM ₁₀	۱/۸۹۵	PM _{2.5} P	۱/۱۴۳
SO ₂	۱/۳۵۹	MAXT	۲/۵۵۷
CO	۱/۰۹۱	MINH	۲/۳۸۱
PM _{2.5} P	۱/۹۶۶		
MINT	۱۲/۷۷۶		
MAXT	۱۹/۹۰۱		
R	۱/۵۱۹		
MINH	۶/۵۰۳		
MAXH	۲/۹۸۶		
WS	۱/۳۸۲		
AP	۱/۴۵۷		

نتایج پیش‌بینی ذرات معلق $PM_{2.5}$ شهر ارومیه در مرحله‌ی آموزش

نتایج مدل ترکیبی تجزیه تک مرحله‌ای تبدیل

موجک گسسته حداکثر همپوشانی- شبکه عصبی

پس‌انتشار (MODWT- BPNN)

در مرحله‌ی اول، داده‌های اصلی $PM_{2.5}$ توسط مدل تبدیل موجک گسسته حداکثر همپوشانی به یک سطح تقریب با فرکانس پایین و چندین سطوح جزئیات با فرکانس بالا تجزیه می‌شود. در این تحقیق از موجک مادر (تابع) دابیشز (db) برای تجزیه سیگنال استفاده شده است. موجک‌های db پشتیبانی کاملی از سری‌های زمانی ارایه می‌دهند. برای پیدا کردن بهترین مقدار سطح تجزیه و بهترین نوع db، ابتدا سری زمانی در سطح‌های ۲ الی ۶ تجزیه شدند و شماره‌های ۲ الی ۵ برای db در نظر گرفته شد که در بین ۲۰ حالت، بهترین حالت از طریق محاسبه معیار ارزیابی خطای $RMSE^1$ انتخاب شد که شامل سطح تجزیه ۲ و شماره (db2) بود. بنابراین داده‌های اصلی $PM_{2.5}$ توسط مدل تبدیل موجک گسسته حداکثر همپوشانی به ۲ سطح جزئیات با فرکانس بالا (d_1 و d_2) و یک سطح تقریب با فرکانس پایین (a_2) تجزیه شدند که در (شکل ۱) نشان داده شده‌اند.

در مرحله‌ی بعد هر کدام از سطوح، توسط شبکه عصبی پس‌انتشار مدلسازی می‌شود که نتایج پیش‌بینی هر کدام از سطوح که توسط شبکه عصبی پس‌انتشار پیش‌بینی شده‌اند به‌طور جداگانه برای مرحله‌ی آموزش در (شکل ۲الف)) و برای مرحله‌ی آزمون در (شکل ۲ب)) نشان داده شده است.

نتایج پیش‌بینی هر کدام از سطوح جزئیات (d_1 و d_2) و سطح تقریب (a_2) براساس معیارهای ارزیابی به‌صورت عددی نیز در (جدول ۲) آمده است.

در نهایت با جمع‌زدن نتایج پیش‌بینی هر کدام از سطوح با هم، پیش‌بینی نهایی انجام می‌شود. که در این مدل، مقادیر $R=0/89$ ، $MAE=3/004$ و $RMSE=4/3736$ در مرحله‌ی آموزش و مقادیر $R=0/55$ ، $MAE=3/1432$ و $RMSE=3/7665$ برای مرحله‌ی آزمون به‌دست آمد.

جدول ۲. نتایج پیش‌بینی هر کدام از سطوح جزئیات (d_1 و d_2) و سطح تقریب (a_2) توسط مدل MODWT- BPNN در مرحله‌ی آموزش و آزمون

سطوح	Rآموزش	Rآزمون
d_1	۰/۸۹	۰/۳۱
d_2	۰/۷۲	۰/۲۴
a_2	۰/۹۱	۰/۴۲

نتایج مرحله آموزش مدل ترکیبی تجزیه تک

مرحله‌ای تجزیه مد متغیر- شبکه عصبی

پس‌انتشار (VMD- BPNN) در پیش‌بینی

ذرات معلق $PM_{2.5}$ شهر ارومیه

در مدل ترکیبی تجزیه‌ی مد متغیر - شبکه عصبی پس‌انتشار در مرحله‌ی اول داده‌های اصلی $PM_{2.5}$ توسط مدل تجزیه مد متغیر (VMD) به ۸ سیگنال تقریباً یکسان تجزیه شد و به نام‌های $VM_1, VM_2, \dots, VM_8$ نامگذاری گردید که در (شکل ۳) نمایش داده شده‌اند.

در مرحله‌ی دوم این مدل ترکیبی، کار پیش‌بینی ذرات معلق $PM_{2.5}$ برای روز آینده با وارد کردن مقادیر توابع مد متغیر به‌عنوان متغیر وابسته انجام شد که در این مدل، مقادیر $R=0/84$ ، $MAE=4/1541$ و $RMSE=5/2776$ در مرحله آموزش و مقادیر $R=0/24$ ، $MAE=3/9760$ و $RMSE=4/5697$ در مرحله آزمون به‌دست آمد.

نتایج مرحله‌ی آموزش (MODWT-VMD-)

BPNN در پیش‌بینی ذرات معلق $PM_{2.5}$ شهر

ارومیه


در این مدل ترکیبی تجزیه‌ی دو مرحله‌ای، در مرحله‌ی اول تجزیه، داده‌های اصلی $PM_{2.5}$ توسط مدل تبدیل موجک گسسته حداکثر همپوشانی به ۲ سطح جزئیات با فرکانس بالا (d_1 و d_2) و یک سطح تقریب با فرکانس پایین (a_2) تجزیه شدند (شکل ۱). سپس در مرحله‌ی دوم تجزیه، هر ۲ سطح جزئیات (d_1 و d_2) و یک سطح تقریب (a_2)، توسط مدل تجزیه مد متغیر، به ۸ توابع مد متغیر تجزیه می‌شوند که در شکل ۴ نمایش داده شده است.

نتایج پیش‌بینی هر کدام از سطوح که توسط مدل تبدیل موجک گسسته حداکثر همپوشانی - تجزیه مد متغیر -


¹ Root Mean Squared Error

سطوح، پیش‌بینی نهایی انجام گرفت که در این مدل، مقادیر $RMSE=3/8074$ ، $MAE=2/8585$ ، $R=0/92$ برای مرحله‌ی آموزش و مقادیر $MAE=2/1840$ ، $R=80$ و $RMSE=2/7679$ برای مرحله‌ی آزمون به‌دست آمد.


شبکه عصبی پس‌انتشار پیش‌بینی شده‌اند به‌طور جداگانه در شکل ۵ نمایش داده شده است. نتایج پیش‌بینی هر کدام از سطوح جزئیات (d_1 و d_2) و سطح تقریب (a_2) براساس معیارهای ارزیابی به‌صورت عددی نیز در جدول ۳ آمده است. در نهایت با جمع‌زدن نتایج پیش‌بینی به‌دست آمده از هر




شکل ۱. نتایج تجزیه ذرات‌معلق $PM_{2.5}$ به ۲ سطح جزئیات (d_1 و d_2) و یک سطح تقریب (a_2) توسط مدل تبدیل موجک گسسته حداکثر همپوشانی




شکل ۲. نتایج پیش‌بینی هر کدام از سطوح جزئیات (d_1 و d_2) و سطح تقریب (a_2)، (الف) در مدل MODWT- BPNN مرحله‌ی آموزش، (ب) در مرحله‌ی آزمون



شکل ۳. نتایج تجزیه ی ذرات معلق $PM_{2.5}$ به ۸ مد متغیر توسط مدل تجزیه مد متغیر



شکل ۴. نتایج تجزیه ی سطح جزئیات (الف) d_1 به ۸ مد متغیر، (ب) d_2 به ۸ مد متغیر و (ج) تجزیه ی سطح تقریب a_2 به ۸ مد متغیر توسط مدل تجزیه مد متغیر



شکل ۵. نتایج پیش بینی هر کدام از سطوح جزئیات (d_1 و d_2) و سطح تقریب (a_2) توسط مدل (MODWT-VMD-BPNN)، (الف) در مرحله آموزش، (ب) در مرحله آزمون

جدول ۳. نتایج پیش‌بینی هر کدام از سطوح جزئیات (d_1 و d_2) و سطح تقریب (a_2) توسط مدل تبدیل موجک گسسته حداکثر همپوشانی - تجزیه‌ی مد متغیر - شبکه عصبی پس‌انتشار براساس معیارهای ارزیابی در مرحله‌های آموزش و آزمون


آزمون	R آموزش	سطوح
۰/۴۰	۰/۸۸	d_1
۰/۲۴	۰/۸۶	d_2
۰/۷۰	۰/۹۴	a_2

نتایج مرحله آموزش مدل شبکه عصبی


پس‌انتشار (BPNN) در پیش‌بینی ذرات معلق

PM_{2.5} شهر ارومیه

در این پژوهش برای جلوگیری از افزایش خطا شبکه سه لایه مورد استفاده قرار گرفت. حداکثر تعداد نوروهای مخفی براساس قضیه کولموگوروف $2ni+1$ می‌تواند باشد. با توجه به این‌که در این تحقیق تعداد ورودی‌ها ۵ است مرز بالایی $2(5)+1=11$ مناسب خواهد بود. بنابراین تعداد نوروهای لایه مخفی از ۱ تا ۱۱ متغیر بوده و نهایتاً لایه پنهان با ۱۰ نرون کمترین میزان خطا را به‌خود



شکل ۶. نتایج مدل شبکه عصبی پس‌انتشار در مرحله‌ی آموزش



شکل ۷. نتایج مدل شبکه عصبی پس‌انتشار در مرحله‌ی آزمون

بحث

داشته‌اند. دلیل آن ناشی از آن است که داده‌های ذرات معلق $PM_{2.5}$ دارای نوسانات فرکانسی زیادی است. پیش‌بینی این داده‌ها تا حدودی مشکل است و مدل‌های پیش‌بینی سری‌های زمانی نمی‌توانند به‌طور مناسب این

بر اساس نتایج این پژوهش دو مدل (MODWT- BPNN) و (VMD- BPNN) نسبت به مدل تکی شبکه عصبی پس‌انتشار (BPNN) عملکرد بهتری

نوسانات را مدیریت کنند. بنابراین برای غلبه بر این مشکل، از مدل‌های تجزیه‌ای MODWT و VMD استفاده می‌شود. این مدل‌ها داده‌های ذرات معلق PM_{2.5} را به تعدادی زیرسری با فرکانس‌های متفاوت تجزیه می‌کنند و نوسانات ذاتی در داده‌های اصلی به‌طور کامل حفظ شده و باعث افزایش دقت پیش‌بینی می‌شود (۱۶). این نتایج با نتایج ژائو و همکاران همخوانی دارد. ژائو و همکاران در سال ۲۰۱۴ (۱۲) نشان دادند که مدل ترکیبی EEMD-GRNN با میزان کم خطا در مقایسه با مدل‌های تکی شامل مدل‌های MLR، PCR، ARIMA و GRNN، بهترین مدل برای پیش‌بینی غلظت یک روز آینده PM_{2.5} است. مقایسه‌ی هر دو مدل ترکیبی (MODWT-BPNN) و (VMD-BPNN) نشان می‌دهد که مدل (MODWT-BPNN) عملکرد بهتری نسبت به مدل (VMD-BPNN) دارد چرا که موجک‌ها برای تحلیل سیگنال‌هایی که حاوی تغییرات ناگهانی و ناپیوستگی موضعی هستند، مناسب‌ترند (۲۷). هم‌چنین تبدیلات موجک قادرند تا بسیاری از منظرهای پنهان داده‌هایی که دیگر روش‌های تحلیل سیگنال در شناسایی آن‌ها ناتوان هستند را شناسایی کند. تبدیل موجک قادر است تا اطلاعات مفیدی را که به‌سادگی از سیگنال اصلی قابل بازبایی نیستند را به‌دست آورد (۲۸). مدل ترکیبی تجزیه‌ی دو مرحله‌ای (MODWT-VMD-BPNN) نسبت به دیگر مدل‌های تجزیه‌ای تک‌مرحله‌ای و مدل تکی شبکه‌ی عصبی پسانتشار، بهترین عملکرد را در پیش‌بینی میزان غلظت ذرات معلق PM_{2.5} شهر ارومیه داشته است. در مدل‌های ترکیبی تجزیه‌ی دو مرحله‌ای به‌دلیل تفسیرپذیری بهتر، امکان استفاده از مدل‌های ساده‌تر در مرحله‌ی اول تجزیه، شناسایی تغییرات ناگهانی در مرحله‌ی اول و دسته‌بندی کردن آن‌ها در یک گروه خاص که این امر امکان بهینه‌سازی تدریجی نتایج را می‌دهد دارای برتری نسبت به مدل‌های ترکیبی تجزیه‌ی تک مرحله‌ای هستند. نتایج پیش‌بینی هر کدام از زیرسری‌ها در مرحله‌ی آموزش و آزمون که جزء تجزیه‌ی مرحله‌ی اول به‌حساب می‌آید نشان می‌دهد که زیرسری‌ها به‌خصوص d_2 در مرحله‌ی آزمون، پیش‌بینی خوبی نداشته‌اند. به‌طور معمول مهم‌ترین بخش سیگنال، سطح تقریب است که اطلاعات پیش‌زمینه‌ی داده‌ها را نشان می‌دهد (۲۹).

استفاده از نتایج دقیق مدل‌های پیش‌بینی در اطلاع‌رسانی به‌موقع به جامعه و انجام اقدامات احتیاطی توسط دولت و مردم می‌تواند سبب کاهش اثرات زیانبار آلودگی هوا به‌ویژه در مناطق شهری پرجمعیت و مناطق صنعتی شود. محدودیت مدل‌های تجزیه‌ی دو مرحله‌ای شامل پیچیدگی محاسباتی، نیاز به انتخاب بهینه‌ی پارامترها (تعداد زیرسری‌ها و تعداد مدها)، حساسیت به کیفیت و ویژگی داده‌های ورودی و نیاز به دانش تخصصی برای تحلیل و تفسیر نتایج است که استفاده از این مدل‌ها را محدود کرده است. در صورت رفع این موارد و بر اساس نتایج پژوهش حاضر استفاده از این مدل‌ها می‌تواند سبب افزایش دقت پیش‌بینی‌ها شود. در نهایت پیشنهاد می‌شود با توجه به امکان استفاده از مدل‌های مختلف در تجزیه‌ی مرحله‌ی اول و تجزیه‌ی مرحله‌ی دوم این مدل‌ها می‌توان با تحقیقات بیشتر در زمینه‌ی استفاده از مدل‌های مختلف دقت پیش‌بینی را افزایش داد.

نتیجه‌گیری

بر اساس این پژوهش می‌توان نتیجه گرفت استفاده از تبدیل موجک در مرحله‌ی اول تجزیه به‌دلیل توانایی آن در تحلیل سیگنال PM_{2.5} که دارای تغییرات ناگهانی و ناپیوستگی موضعی است مناسب است. اما این تبدیل دارای یک محدودیت است. تبدیل موجک به‌تنهایی نمی‌تواند فرکانس‌های چندگانه در سیگنال PM_{2.5} را استخراج کند، برای غلبه بر این مشکل از مدل تجزیه‌ی دوم، مدل تجزیه‌ی مد متغیر استفاده می‌شود و هر کدام از زیرسری‌ها (d_1 ، d_2 و a_2)، توسط مدل تجزیه‌ی مد متغیر به هشت مود متغیر تجزیه می‌شوند و در نهایت هر کدام از مدهای متغیر توسط شبکه عصبی پسانتشار پیش‌بینی می‌شوند و نتایج آن‌ها جمع بسته می‌شود و پیش‌بینی هر کدام از زیرسری‌ها توسط مدل تجزیه‌ای دو مرحله‌ای به‌دست می‌آید که نتایج پیش‌بینی هر کدام از زیرسری‌ها در مرحله‌ی آموزش و آزمون نشان می‌دهد که زیرسری‌ها نسبت به مدل تجزیه‌ی تک‌مرحله‌ای، پیش‌بینی بهتری داشته‌اند که این نتایج با نتایج وانگ و همکاران در سال ۲۰۱۷ (۱۶) همخوانی دارد.

تشکر و قدردانی: این مقاله برگرفته از نتایج به‌دست آمده در مدل‌سازی داده‌ها در کارگاه ارزیابی دانشگاه

عدم سرقت ادبی، انتشار دوگانه، تحریف داده‌ها و داده‌سازی را در این مقاله رعایت کرده‌اند. همچنین هر گونه تضاد منافع حقیقی یا مادی که ممکن است بر نتایج یا تفسیر مقاله تاثیر بگذارد را رد می‌کنند.

سهم نویسندگان: صلاح بایزیدی: مدل‌سازی، تحلیل داده-ها. جمیل امان‌الهی: مدل‌سازی صحت‌سنجی نتایج، نگارش مقاله

References

1. Esmaili, R. and Amini, F. L. 2021. Identification of hot spots PM_{2.5} in Mashhad air pollution. Journal of Climate Research. 44:63-68. (In Persian).
2. Dabiri, M. 2007. Environmental pollution (Air, Water, Soil, Sound). Etehat Tehran, pp400. (In Persian).
3. Mohammadian, M., Sojodi, L. and Etemadinejad, S. 2011. Survey of concentrations of PM_{2.5} inside and outside of shops in Sar's city center. Journal of Mazandaran University of Medical Sciences, 21: 72-79. (In Persian).
4. Deng, X., Zhang, F. and Rui, W. 2013. PM_{2.5} -induced oxidative stress triggers autophagy in human lung epithelial A549 cells. Toxicology in Vitro, 27(6): 17662-1770.
<https://doi.org/10.1016/j.tiv.2013.05.004> PMID:23685237
5. Mckendry, I. G. 2000. PM₁₀ levels in the lower Fraser valley, British Columbia, Canada: an overview of spatiotemporal variation and meteorological control, Journal of The Air and Waste Management Association, 50(3): 443-452.
<https://doi.org/10.1080/10473289.2000.10464025> PMID:10734716
6. Abidin, A. U., Munawaroh, A. L., Rosinta, A., Sulistiyani, A, Ardianta, i. and Iresha, F. M. 2025. Environmental health risks and impacts of PM_{2.5} exposures on human health in residential areas, Bantul, Yogyakarta, Indonesia. Toxicology Reports: 14: 101949.
<https://doi.org/10.1016/j.toxrep.2025.101949> PMID:40026480 PMCID:PMC11869533
7. Wu, Ch-H., Dang, T. T. M., Mutuku, J. K., Lin, L-M., Huang, B-W. and Chang-

کردستان است. بدین‌وسیله از کارمندان این کارگاه تشکر و قدردانی می‌گردد.

تعارض منافع: نویسندگان هیچ گونه تعارض منافع با یکدیگر ندارند.

حمایت مالی: منابع مالی این پژوهش توسط دانشگاه کردستان تامین شده است.

ملاحظات اخلاقی: نویسندگان تمام نکات اخلاقی شامل

- Chien, G-P. 2025. Evaluation of PM_{2.5} bound microplastics and plastic additives in several cities in Taiwan: Spatial distribution and human health risk. Science of The Total Environment, 959: 178213..
<https://doi.org/10.1016/j.scitotenv.2024.178213>
8. Zeng, Y., Yang, X., Zhang, A., Yuan, X., Zhai, J., Xing, C., Cai, B., Shi, S., Zhang, Y. and Zhang, Y. 2024. Source-specific health effects of internally exposed organics in urban PM_{2.5} based on human serum albumin adductome analysis. Science of The Total Environment, 955: 176958..
<https://doi.org/10.1016/j.scitotenv.2024.176958> PMID:39419214
9. Madanchi, P., Saeediyan, H. and Damizadeh, T. M. 2024. Evalution of meteorological data and satellite images in identifying dust phenomenon in desert areas (case study: Kerman province). Journal of Geography and Environmental Hazards, 13(4). (In Persian).
<https://doi.org/10.22067/geoe.2024.87528.1476>
10. Najjarian, M., Etemadfad, H. and Golmohammadi, M. 2024. Identification of the dust formation center with Tensor approach (Study Case: Sabzevar County). Journal of Geography and Environmental Hazards 13(2). (In Persian).
<https://doi.org/10.22067/geoe.2023.82992.1384>
11. Negahban, S., Ganjaeian, H., Ghaysarian, S. A. and Ebrahimi, A. 2024. Identifying the centers of dust and analyzing the factors influencing its occurrence based on remote sensing data

(Case Study: Southwest Iran). Journal of Geography and Environmental Hazards, 13(4). (In Persian).
<https://doi.org/10.22067/geoe.h.2024.8908.8.1504>.

12. Zhou, Q., Jiang, H., Wang, J. and Zhou, J. 2014. A hybrid model for PM2.5 forecasting based on ensemble empirical mode decomposition and a general regression neural network. Science of the Total Environment, 496: 264-274.
<https://doi.org/10.1016/j.scitotenv.2014.07.051> PMID:25089688

13. Liu, H., Tian, H. Q. and Li, Y. F. 2015. Four wind speed multi-step forecasting models using extreme learning machines and signal decomposing algorithms. Energy Convers. Manag. 100, 16-22.
<https://doi.org/10.1016/j.enconman.2015.04.057>

14. Feng, X., Li, Q., Zhu, Y., Hou, J., Jin, L. and Wang, J. 2015. Artificial neural network forecasting of PM2.5 pollution using air mass trajectory based geographic model and wavelet transformation. Atmos Environ, 107: 118-128.
<https://doi.org/10.1016/j.atmosenv.2015.02.030>

15. Bai, Y., Li, Y., Wang, X.X., Xie, J.J. and Li, C. 2016. Air pollutants concentrations forecasting using back propagation neural network based on wavelet decomposition with meteorological conditions. Atmospheric Pollution Research. 7, 557-566.
<https://doi.org/10.1016/j.apr.2016.01.004>

16. Wang, D., Liu, Y., Luo, H., Yue, Ch. and Cheng, Sh. 2017. Day-ahead PM2.5 concentration forecasting using WT-VMD based decomposition method and back propagation neural network improved by differential evolution. Int J Environ Res Public Health, 14(7): 764.
<https://doi.org/10.3390/ijerph14070764> PMID:28704955 PMCID:PMC5551202

17. Ghimire, S., Deo, R. C., Casillas-Perez, D., Sharma, E., Salcedo-Sanz, S., Barua, P. D. and Acharya, U. R. 2024. Half-hourly electricity price prediction with a hybrid convolution neural network-

random vector functional link deep learning approach. Applied Energy, 374: 123920.

<https://doi.org/10.1016/j.apenergy.2024.123920>

18. Fang, J., Yan, Z., Lu, X. and Zhao, Z. 2024. An oil production prediction approach based on variational mode decomposition and ensemble learning model. Computers & Geosciences, 193: 105734.

<https://doi.org/10.1016/j.cageo.2024.105734>

19. Xue, H., Wang, G., Li, X. and Du, F. 2024. Predictive combination model for CH4 separation and CO2 sequestration with CO2 injection into coal seams: VWD-STABiLSTM-ELM hybrid neural network modeling. Energy, 313: 133744.
<https://doi.org/10.1016/j.energy.2024.133744>

20. Su, T., Liu, D., Cui, X., Dou, X., Lei, B., Cheng, X., Yuan, M. and Chen, R. 2024. Prediction of DEDI index for meteorological drought with the VMD-CBiLSTM hybrid model. Journal of Hydrology. 641:131805.
<https://doi.org/10.1016/j.jhydrol.2024.131805>

21. Rahimpour, A., Amanollahi, J. and Tzanis, C. G. 2021. Air quality data series estimation based on machine learning approaches for urban environments. Air Quality, Atmosphere & Health. 14: 191-201.
<https://doi.org/10.1007/s11869-020-00925-4>

22. Ghasemi, A. and Amanollahi, J. (2019). Integration of ANFIS model and forward selection method for air quality forecasting. Air Quality and Atmospheric Health. 12: 59-72.

<https://doi.org/10.1007/s11869-018-0630-0>

23. Raei, R., Mohammadi, S. and Fendereski, H. 2015. Forecasting stock index with neural network and wavelet transform. Journal of Asset Management and Financing. 1: 55-74. (In Persian). 20.1001.1.23831170.1394.3.1.4.4

24. Dragomiretskiy, K. and Zosso, D. 2014. Variational mode decomposition. IEEE T Signsl Proces, 62: 531-544. <https://doi.org/10.1109/TSP.2013.2288675>
25. Tahmasebi, M. K., Kahoo, A. R. and Kalateh, A. N. 2017. Ground-roll noise suppression by time-frequency filtering based on variational mode decomposition. Journal of Research on Applied Geophysics. 3. 177-188. (In Persian). <https://doi.org/10.1016/j.jappgeo.2018.10.025>.
26. Khalkhali Shandiz, S. and Khezzrzhadeh, H. 2021. Application of moving vehicle response and variational mode decomposition (VMD) for indirect damage detection in bridges. Modares Civil Engineering Journal. 21 (1), 31-46. (In Persian). 20.1001.1.24766763.1400.21.1.13.6.
27. Quiroz, R. C., Yarleque, Ch., Posadas, A., Mares, V. and Immerzeel, W. W. 2011. Improving daily rainfall estimation from NDVI using a wavelet transform. Environmental Modelling and Software, 26(2): 201-209. <https://doi.org/10.1016/j.envsoft.2010.07.006>
28. Daubechies, I. 1992. Ten lectures on wavelet. Society for Industrial Mathematics. <https://doi.org/10.1137/1.9781611970104> PMid:18296155
29. Karbasi, M and Dindar, S. 2019. Comparison of wavelet-MLP and wavelet-GMDH models in forecasting EC and SAR at Zayandeh-Rood RIVER. Environmental Sciences. 16 (4), 135-152. (In Persian).