#### Journal of Research in Environmental Health Volume 11, Issue 1, Spring 2025

# PM<sub>2.5</sub> 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 (PM<sub>10</sub> and PM<sub>2.5</sub>), carbon dioxide (CO<sub>2</sub>), sulfur dioxide (SO<sub>2</sub>), nitrogen dioxide (NO<sub>2</sub>), 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 PM2.5 data series was decomposed into two high-frequency detail levels  $(d_1 \text{ and } d_2)$  and one low-frequency approximation level (a<sub>2</sub>) 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 PM2.5 data with greater precision.

**Keywords:** Prediction, Particulate Matter PM<sub>2.5</sub>, 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 <u>https://creativecommons.org/licenses/by/4.0/</u>

Received: 2024/10/22 Accepted: 2025/03/11 Doi:10.22038/jreh.2025.25799

Citation: Baizidi S, Amanollahi J. PM<sub>2.5</sub> Concentration Forecasting Using Decomposition Method and Artificial Neural Network. *Iranian Journal of Research in Environmental Health.* Spring 2025; 11(1):83-97.

بهی و شبکه عصبے	تركيبي تجزي	تفاده از روش	ت <b>PM</b> <sub>2.5</sub> با اس	یشبینی غلظہ
-----------------	-------------	--------------	----------------------------------	-------------

چکیدہ	<b>صلاح بایزیدی</b> دانشآموختهی کارشناسی ارشد
جکیده زمینه و هدف: یکی از شاخصهای مهم در بحث کیفیت هوا، غلظت ذرات معلق درات می باشد. بدین منظور در این پژوهش از مدل ترکیبی تبدیل موجک گسسته حداکثر (MODWT-VMD-BPNN) سی انتشار (MODWT-VMD-BPNN) مواد و روشها: سری داده های اصلی ذرات معلق 2.5 PM شهر ارومیه استفاده مواد و روشها: سری داده های اصلی ذرات معلق 2.5 PM ابتدا توسط مدل تبدیل موجک گسسته حداکثر هم پوشانی به دوسطح جزئیات با فرکانس بالا (of و 2) و یک سطح تقریب با فرکانس پایین (a) 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 منتیر توسط مدل تجزیه مد متغیر به ۸ مود منفیر تجزیه شد. سپس هر کدام از مدهای منیز توسط مدل تجزیه مد متغیر به ۸ مود منفیر تجزیه شد. سپس هر کدام از مدهای منیز توسط مدل تجزیه مد متغیر به ۸ مود مینی تجزیه شد. سپس هر کدام از مدهای می بافتهها: بر اساس نتایج مدل های ترکیبی (MODWT-BPNN) و ( - VMD- VMD) سبت به مدل تکی شبکه عصبی پسانتشار (BPNN) و ( - VMD- VMD) اسبت به مدل تکی شبکه عصبی پسانتشار (BPNN) به دلیل تحلیل سیگنال هایی دارای تغییرات ناگهانی و ناپیوستگی موضعی به وسیلهی موجکها عملکرد بهتری نسبت به مدل (MODWT-BPNN) دارد. مدل ترکیبی تجزیه ای تک مرحلهای و مدل بهتری نسبت به مدل (MODWT-BPNN) دارد. مدل ترکیبی تجزیه و مرحلهای بهتری نسبت به مدل (MODWT-BPNN) دارد. مدل ترکیبی تجزیه ای تک مرحلهای و مدل بهتری نسبت به مدل (MODWT-WD-BPNN) دارد. مدل ترکیبی تجزیه ای تک مرحلهای و مدل بهتری نسبت به مدل (MODWT-BPNN) دارد. مدل ترکیبی تجزیه و مرحلهای و مدل بهدی مرحله و مرحلهای ارزیابی خطا شامل ۲۰۹۲۰۶ عملکرد تکی شبکه عصبی پسانتشار با مقادیر میارهای ارزیابی خطا شامل ۲۰۸۰۴ مرکنه مرحله و مرحله آرمون، عملکرد بهتری داشته است. مرکنه را منهای تجزیهای دو مرحله آرمون و محلکرد بهتری داشته است. مرکنه مرحله و مرحله آرمون، عملکرد بهتری داشته است. مود میتواند مشکل آمیختگی مدها را حل کند و پیش بینی میزان غلظت دی ام را ب کرفته شود. مرکنه شود.	دانش اموخته ی کارشناسی ارشد محیط زیست، دانشکده منابع طبیعی، دانشگاه کردستان، کردستان، جمیل امان اللهی * دانشیار گروه محیط زیست، دانشکده منابع طبیعی، دانشگاه کردستان، کردستان، ایران. (نویسنده مسئول) j.amanollahi@uok.ac.ir
استناد: بایزیدی ص، اماناللهی ج. پیشبینی غلظت PM <sub>2.5</sub> با استفاده از روش ترکیبی تجزیهی و شبکه عصبی. فصلنامهی پژوهش در بهداشت محیط. بهار ترکیبی تجزیهی و شبکه عصبی. فصلنامهی پژوهش در بهداشت محیط.	تاریخ دریافت: ۱۴۰۳/۰۸/۰۱ تاریخ پذیرش:۱۴۰۳/۱۲/۲ نوع مقاله: پژوهشی

.97-82 :(1)11;14.4

٨۴

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 می شود. 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 می شود و پیشبینی نهایی بهدست 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 ذراتمعلق PM<sub>2.5</sub> شهر شیان واقع در کشور چین پرداختند. نتایج بهدست آمده نشان داد که مدل ترکیبی تجزیه حالت تجربی تجمعی- شبکه عصبی رگرسیون عمومی بهدلیل 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 ذراتمعلق PM<sub>2.5</sub> 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<sub>2.5</sub> باشد. بای و همکاران در سال ۲۰۱۶ (۱۵) از تبدیل موجک و شبکه عصبی پسانتشار برای پیشبینی غلظت آلایندههای PM<sub>10</sub> ، SO<sub>2</sub> و NO<sub>2</sub> استفاده کردند. نتایج از برتری مدل ترکیبی تبدیل

مقدمه

آلودگی هوا بهدلیل چندوجهی بودن به یک معضل زیستمحیطی تبدیل شده است که در کشورهای در حال توسعه افزایش یافته است (۱). ذرات معلق یکی از مهم ترین فاکتورهای مؤثر در آلودگی هوا است (۲). ذراتمعلق درشت (PM<sup>1</sup>10) دارای قطر آیرودینامیکی بزرگتر از ۲/۵ میکرون و کوچکتر از ۱۰ میکرون هستند در حالی که ذرات ریز ( $PM_{2.5}$ ) قطرشان ۲/۵ میکرون یا كمتر است. ذراتمعلق بهتنهایی یا در واكنش با آلایندههای دیگر خطرات و آسیبهای بسیار شدیدی بر سلامت و کیفیت زندگی انسان دارد (۳). ذراتمعلق باعث انواع بیماریها ازجمله بیماریهای ریوی، قلبی، تخریب بافت ریه و مرگومیر زودرس می شوند (۴). ذرات معلق هم چنین سبب کاهش میدان دید می شوند (۵). آبیدین و همکاران در سال ۲۰۲۵ (۶) نشان دادند که رابطهی معنیداری (p-value < ۰/۰۵) بین میزان افزایش غلظت ذرات PM<sub>2.5</sub> و مشكلات سلامتى ازجمله سرفه، سردرد، سوزش چشم، تنگینفس و خسخس سینه وجود دارد. ویو و همکاران در سال ۲۰۲۵ (۷) نشان دادندPM<sub>2.5</sub> خطر بیماری قلبی ریوی و سرطان ریه را بهترتیب از ۲۶/۴ درصد به ۲۶/۷۳ درصد افزایش میدهد. هم چنین بیان داشتند که مواد موجود در  $PM_{2.5}$  می تواند شاخص خطرسلامت را از ۱/۲۶ تا ۲/۴۷ درصد افزایش دهد که این خطر قابل توجهی برای کارگران در فضای باز ایجاد می کند. زنگ و همکاران در سال ۲۰۲۴ (۸) اثرات بهداشتی اولیه مولکولهای آلی محلول در آب که از PM2.5 موجود در هوا سرچشمه می گیرند به عنوان سمیت عصبی و سمیت تنفسی شناسایی کردند. مولکولهای آلی محلول در آب که از منابع بیوژنیک و انتشارات اقیانوسی سرچشمه می گیرند عمدتاً مسئول اثرات نوروتوکسیک بودند، در حالي كه آنهايي كه از سوزاندن زيست توده و اگزوز بنزین بودند عمدتاً باعث سمیت تنفسی میشدند. در سالهای اخیر روشهای مختلفی برای پیشبینی کانونهای شکل گیری و میزان غلظت ذراتمعلق ارائه شده است (۹،۱۰،۱۱). شبکههای عصبی مصنوعی (ANN<sup>۲</sup>) یکی از روشهای موفق در علوم جوی است که برای سیستمهای غیرخطی به کار برده می شود. برخی از

<sup>&</sup>lt;sup>1</sup> Particulate Matter

<sup>&</sup>lt;sup>2</sup> Artificial Neural Network

موجک- شبکه عصبی پسانتشار نسبت به مدل تکی شبکه عصبی پسانتشار حاکی بود. وانگ و همکاران در سال ۲۰۱۷ (۱۶) به پیش بینی غلظت PM2.5 روز آینده با استفاده از روش تجزیه یمبتنی بر تبدیل موجک- تجزیه مد متغیر و شبکه عصبی پسانتشار پرداختند. به منظور بهبود دقت پیش بینی غلظت 2.5 PM، این محققان یک مدل ترکیبی تجزیه دو مرحله ای مبتنی بر تبدیل موجک، تجزیه حالت متغیر و شبکه عصبی پسانتشار را مورد استفاده قرار دادند و نتایج این مدل تجزیه دو مرحله ای را با مدل های تجزیه ی تک مرحله ای و مدل فردی مقایسه کردند. نتایج به دست آمده ناشی از برتری مدل ترکیبی تجزیه دو مرحله ای نسبت به دیگر مدل ها برای پیش بینی بود. قیمیر و همکاران در سال ۲۰۲۴ (۱۷) از

(MODWT) برای پیشبینیهای قیمت برق نیمساعته استفاده کرد آنها مدل پیشبینی شبکههای عصبی را با پیوند عملکردی بردار تصادفی (CRVFL<sup>۲</sup>) 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<sup>۳</sup> و MLP<sup>۴</sup> بوده است. فانگ و همکاران در سال 2024 (۱۸) به پیش بینی تولید نفت بر اساس تجزیهی حالت متغیر و مدل یادگیری گروهی m VMD پرداختند. نتایج آنها نشان داد که مدل  $m VMD^{4}$ می تواند به طور موثری دقت پیش بینی را در مقایسه با مدلهای  $SVM^{\flat}$  و  $RNN^{\vee}$  افزایش دهد. خیو و همکاران در سال ۲۰۲۴ (۱۹) در تحقیقی با استفاده از مدل به VMD-STA<sup>۸</sup>-BiLSTM<sup>۹</sup>-ELM<sup>۱</sup> ترکیبی پیش بینی میزان جداسازی CH4 و ترسیب CO<sub>2</sub> با تزريقCO<sub>2</sub> به درزهای زغال سنگ يرداخت. نتايج آنها نشان داد که مدل هیبریدی در دقت پیشبینی از مدل های VMD-ELM، STA-BiLSTM-ELM، مدل های

#### TCN'' ELM STA-BiLSTM BiLSTM

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<sup>۱۴</sup> پرداختند. آنها نشان دادند در مقایسه با مدلهای تکی، مدل VMD-BiLSTM نەتنها مىتواند عدم قطعيت يېشبينى خشكسالى هواشناسی ناشی از ناهمگونی مدل آبوهوا را کاهش دهد، بلکه دقت پیش بینی خشکسالی را در مناطق خشک و نیمه خشک بهبود می بخشد که می تواند مرجعی برای مقابله با وقوع خشکسالی و هشدار زودهنگام آن باشد. با توجه به اهمیت میزان دقت پیش بینی ذرات معلق PM2.5 در كمك به سلامت جامعه و با توجه به این كه غلظت ذراتمعلق PM<sub>2.5</sub> 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 این که مدل تجزیه تکمر حلهی بهتنهایی نمی تواند فرکانسهای چندگانه در سیگنال PM<sub>2.5</sub> را استخراج کند مدلهای تجزیه دو مرحلهی با تجزیهی زیرسریها به چندین مود و جمع بستن نتایج پیشبینی هر یک از مودها می تواند راه حل مناسبی برای پیشبینی ذراتمعلق PM<sub>2.5</sub> باشد. لذا در این تحقیق با استفاده از روش تجزیهی مبتنی بر MODWT-VMD و شبکهی عصبی میزان غلظت PM<sub>2.5</sub> در شهر ارومیه پیشبینی می گردد و جهت ارزیابی میزان دقت مدل ذکر شده نتایج آن با نتایج مدلهای دیگری مورد مقایسه قرار گرفت.

## روشکار

## منطقه مورد مطالعه

شهرستان ارومیه مرکز استان آذربایجانغربی با مساحت ۷/ ۴۲ کیلومترمربع و موقعیت ممتاز جغرافیایی در ۲۰ کیلومتری دریاچهی ارومیه قرار دارد. شهر ارومیه بر روی

<sup>&</sup>lt;sup>1</sup> Maximal Overlap Discrete Wavelet Transform

<sup>&</sup>lt;sup>2</sup> Convolutional Random Vector Functional Link

<sup>&</sup>lt;sup>3</sup> Long Short-Term Memory

<sup>&</sup>lt;sup>4</sup> Multilayer Perceptron

<sup>&</sup>lt;sup>5</sup> Variational *Mode* Decomposition

<sup>&</sup>lt;sup>6</sup> Support Vector Machines

<sup>&</sup>lt;sup>7</sup> Recurrent Neural Networks

<sup>&</sup>lt;sup>8</sup> Spatiotemporal Attention Mechanism

<sup>&</sup>lt;sup>9</sup> Bidirectional Long Short-Term Memory Network

<sup>&</sup>lt;sup>10</sup> Extreme Learning Machine

<sup>&</sup>lt;sup>11</sup> 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 بهنظر 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:  $S(t) = d_1 + d_2 + \dots + d_m + a_m$  (۳-۱)

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

بهطور کلی تبدیل موجک (<sup>۸</sup>WT) به دو دسته تبدیل موجک پیوسته (<sup>۳</sup>CWT) و تبدیل موجک گسسته (<sup>۱</sup>'T) 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 آورند 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

- <sup>8</sup> Wavelet Transform
- <sup>9</sup> Continuous Wavelet Transform
- <sup>10</sup> Discrete Wavelet Transform

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 ۱/۱۳ درجه سانتی گراد متعلق به اواسط تیر تا اوایل شهریورماه است و متوسط دمای هوا در همین دوره حداقل به ۱۶/۲ درجه سانتیگراد می سد در مجموع به مدت ۱۶۴ روز در معرض بادهای با سرعت حداقل ۷ و حداکثر ۱۶ متر بر ثانیه است قرار می گیرد (۲۱).

#### دادەھا

دادههای متوسط روزانه مربوط به کیفیت هوای شهر اروميه شامل دىاكسيدكربن (CO2)، ذراتمعلق (PM<sub>10</sub>)، دىاكسيدسولفور (SO<sub>2</sub>)، ذراتمعلق (PM<sub>2.5</sub>)، دىاكسيدنيتروژن (NO2) و مونواكسيدنيتروژن (NO) طی سالهای ۱۴۰۲–۱۳۹۹ از ادارهی کل حفاظت محیطزیست و دادههای هواشناسی شامل بارش کل روزانه (PR<sup>1</sup>)، میانگین حداقل دما (MinT<sup>۲</sup>)، میانگین حداکثر دما (MaxT<sup>r</sup>)، میانگین فشار جوی (AP<sup>\*</sup>)، میانگین حداکثر رطوبت نسبی روزانه سطح هوا (MaxH<sup>۵</sup>)، میانگین حداقل رطوبت نسبی روزانه سطح هوا (\*MinH) و سرعت باد روزانه (WS<sup>v</sup>) (۲۲) به صورت روزانه در دوره زمانی مذکور از ادارهی کل هواشناسی استان آذربایجان غربی تهیه گردید. در محاسبات، دادههای روزها استفاده شد که تمامی پارامترهای ذکرشده اندازگیری شده باشد و در صورت عدم اندازه گیری حتی یک پارامتر در یک روز خاص، دادههای روز ذکر شده حذف گردید.

## پیشبینی ذراتمعلق PM<sub>2.5</sub> شهر ارومیه

داده وابسته این پژوهش PM<sub>2.5</sub> است. در مباحث قبلی توضیح داده شد که میزان غلظت این آلودگی دارای تغییرات ناگهانی و ناپیوستگی موضعی است که این

- <sup>2</sup> Minimum Temperature
- <sup>3</sup> Maximum Temperature
- <sup>4</sup> Air Pressure
- <sup>5</sup> Maximum Humidity
- <sup>6</sup> Minimum Humidity
- <sup>7</sup> Wind Speed

<sup>&</sup>lt;sup>1</sup> Precipitation

طیف فرکانسی دارند. این الگوریتم به گونهای است که مدهای متغیر (VMs<sup>۱</sup>)، 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). 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 با به باند پایه برای هر مود (مرحله ی دمدولاسیون) باند بایه برای هر مود (مرحله ی دمدولاسیون) 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  $\{u_k\}: \{u_1, u_2, ..., u_k\}$  و  $\{w_k\}: \{\omega_1, \omega_2, ..., \omega_k\}$  بهترتیب نشانههای اختصاری برای مجموعهای از همهی حالتها و فرکانسهای مرکز آنها است.(t) توزیع دیراک<sup>7</sup> و \* نشان پیچیدگی است. دراگومیرتسکی و زوسو (۲۰۱۴) برای در نظر گرفتن شرط بازسازی به صورت همزمان از دو تابع جزای درجه دو (quadratic penalty term) و افزاینده لاگرانژی ( Lagrangian multipliers

## مدل پیشبینی شبکهی عصبی پسانتشار ("BPNN)

ساختار MLP اساساً یک آرایش لایهای از نورونها است که شامل سه لایهی اصلی است: یک لایهی ورودی (با یک تابع ورودی)، یک لایهی پنهان و یک لایهی خروجی نهایی. هر لایه شامل چندین نورون است که ساختار پایه مدل را تشکیل میدهد در تحقیق حاضر تعداد نورونها برای لایهی پنهان ۱۵ عدد در نظر گرفته شده است . MLP یک شبکه پیشخور است که مجموعه ورودیها

<sup>1</sup> Variational Modes

را با استفاده از یک تابع فعالسازی غیرخطی به مجموعهای از خروجیهای دلخواه تبدیل میکند. با استفاده از الگوریتم Back Propagation برای تمرین، وزنها به طور مکرر در MLP تغییر میکنند تا خطا بین خروجیها و نتایج مورد انتظار به حداقل برسد (۲۵). از کل دادههای مورد استفاده در این تحقیق ۸۰ درصد برای مرحلهی مدل سازی و ۲۰ درصد برای مرحلهی آموزش مدل MLP در نظر گرفته شده است. مدل پس انتشار یک قانون یادگیری برای پر سپترون چندلایه (MLP) است. این الگوریتم متشکل از ۴ گام است. بدین ترتیب که پس از انتخاب تصادفی ضرایب وزن شبکه، گامهای زیر طی می شود:

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

# مدلهای تجزیه و پیشبینی تک مرحلهای مدل ترکیبی تبدیل موجک گسسته حداکثر همپوشانی – شبکه عصبی پس/نتشار (MODWT-BPNN)

در این مدل ترکیبی، ابتدا با استفاده از روش تبدیل موجک گسسته حداکثر همپوشانی، دادههای PM<sub>2.5</sub> اصلی به چندین سطوح جزئیات با فرکانس بالا و یک سطح تقریب با فرکانس پایین تجزیه میشود. در مرحلهی بعد هر کدام از سطوح، توسط شبکه عصبی پسانتشار مدلسازی میشود و درنهایت با جمعزدن نتایج پیشبینی هر کدام از سطوح، پیشبینی نهایی انجام میشود.

# مدل ترکیبی تجزیهی مد متغیر- شبکه عصبی پس/نتشار ( VMD- BPNN)

در مرحلهی اول دادههای PM<sub>2.5</sub> اصلی توسط مدل تجزیهی مد متغیر به تعدادی از مدهای متغیر (VMs) تجزیه میشود و سپس در مرحلهی بعد هر یک از

<sup>&</sup>lt;sup>2</sup> Dirac

<sup>&</sup>lt;sup>3</sup> Back Propagation Neural Network

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 یسانتشار (MODWT- VMD- BPNN)

فرآیند کلی این روش در پنج مرحله بهترتیب زیر انجام میشود: در مرحلهی اول، دادههای اصلی PM<sub>2.5</sub> PM، 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 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

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

#### يافتهها

## آمادهسازی دادهها و انتخاب متغیرهای مستقل مؤثر

از میان دادهها پس از نرمالسازی و مرتب کردن، تعداد ۴۵۰ داده برای مرحلهی آموزش و ۳۰ داده برای مرحلهی آزمون مدلها مورد استفاده قرار گرفت. دادههای ذراتمعلق PM<sub>2.5</sub> یک روز آینده بهعنوان متغیر وابسته و دیگر دادههای هواشناسی و کیفیت هوا بهعنوان متغیرهای مستقل مورد استفاده قرار می گیرد. در این مطالعه برای از بین بردن اثر همخطی بین متغیرهای مستقل از روش گام به گام استفاده گردید. از میان متغیرهای مستقل واردشده در مدل، متغیرهای CO، PM<sub>2.5</sub> روز قبل، NO<sub>2</sub> ، MaxT وMinR در مدل باقیمانده و در نتیجه میزان غلظت این متغیرها بر میزان غلظت PM<sub>2.5</sub> شهر ارومیه (جدول است .() بوده مؤثر

VIE	متغيرهای	VIE	متغيرهای	
VII	مستقل نھائی	VII	مستقل اوليه	
١/٣۴٧	$NO_2$	1/874	NO	
١/• ١٧	CO	۲/۳۰۶	NO <sub>2</sub>	
1/148	PM <sub>2.5 P</sub>	١/٨٩۵	$PM_{10}$	
۲/۵۵۷	MAXT	١/٣۵٩	$SO_2$	
۲/۳۸۱	MINH	١/•٩١	CO	
		1/988	PM <sub>2.5 P</sub>	
		17/778	MINT	
		19/901	MAXT	
		١/۵١٩	R	
		۶/۵۰۳	MINH	
		۲/۹۸۶	MAXH	
		١/٣٨٢	WS	
		1/401	AP	

#### جدول ۱. میزان همخطی بین همه متغیرهای مستقل

# نتایج پیشبینی ذراتمعلق PM<sub>2.5</sub> شهر ارومیه در مرحلهی آموزش نتایج مدل ترکیبی تجزیه تکمرحلهای تبدیل موجک گسسته حداکثر همپوشانی– شبکه عصبی پس/نتشار (MODWT- BPNN)

در مرحله اول، داده مای اصلی PM<sub>2.5</sub> توسط مدل تبدیل موجک گسسته حداکثر همیوشانی به یک سطح تقریب با فرکانس پایین و چندین سطوح جزئیات با فركانس بالا تجزیه می شود. 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 انتخاب شد که شامل سطح تجزیه ۲ و شماره (db2) بود. بنابراین دادههای اصلی PM<sub>2.5</sub> توسط مدل تبدیل موجک گسسته حداکثر همپوشانی به ۲ سطح جزئیات با فرکانس بالا (d1 و d2) و یک سطح تقریب با فرکانس پایین (a<sub>2</sub>) تجزیه شدند که در (**شکل ۱)** نشان داده شدهاند.

در مرحلهی بعد هر کدام از سطوح، توسط شبکه عصبی پسانتشار مدلسازی میشود که نتاج پیشبینی هر کدام از سطوح که توسط شبکه عصبی پسانتشار پیشبینی شدهاند بهطور جداگانه برای مرحلهی آموزش در (شکل شدهاند بهطور جداگانه برای مرحلهی آموزش در (شکل داده شده است.

نتایج پیشبینی هر کدام از سطوح جزئیات (d<sub>1</sub> و d<sub>2</sub>) و سطح تقریب (a<sub>2</sub>) براساس معیارهای ارزیابی بـهصـورت عددی نیز در (**جدول ۲**) آمده است.

در نهایت با جمعزدن نتایج پیشبینی هر کدام از سطوح با هم، پیشبینی نهایی انجام می شود. که در این مدل، مقادیر MAE=۳/۱۰۴، R=۰/۸۹ و MAE=۴/۳۷۳۶ در مرحلهی آموزش و مقادیر RMSE=۳/۱۴۳۲ ، RISE=۳/۷۶۶۵

<sup>1</sup> Root Mean Squared Error

جدول ۲. نتایج پیشبینی هر کدام از سطوح جزئیات (d و d2) و سطح تقریب (a2) توسط مدل MODWT- BPNN در

مرحلهی آموزش و آزمون

سطوح	Rآموزش	<b>R</b> آزمون
$d_1$	٠/٨٩	۰ /۳ ۱
$d_2$	٠/٧٢	•/74
a <sub>2</sub>	٠/٩١	٠/۴٢

# نتایج مرحله آموزش مدل ترکیبی تجزیه تک مرحلهای تجزیه مد متغیر– شبکه عصبی پس/نتشار (VMD- BPNN) در پیشبینی ذراتمعلق PM2.5 شهر ارومیه

در مدل ترکیبی تجزیهی مد متغیر – شبکه عصبی پسانتشار در مرحلهی اول دادههای اصلی 2.5 PM توسط مدل تجزیه مد متغیر (VMD) به ۸ سیگنال تقریباً یکسان تجزیه شد و به نامهای NM1,VM2,...,VM8 سیگنال تقریباً نامگذاری گردید که در (**شکل ۳**) نمایش داده شدهاند. در مرحلهی دوم این مدل ترکیبی، کار پیشبینی در مرحلهی دوم این مدل ترکیبی، کار پیشبینی در مرحلهی دوم این مدل ترکیبی مار پیشبینی در مرحله مده منعیر وابسته انجام شد که در این توابع مد متغیر بهعنوان متغیر وابسته انجام شد که در این مدل، مقادیر ۸۴–RE، ۸۴ AFI و RMSE=۵/۲۷۷۶ در مرحله آموزش و مقادیر ۲۶/۰۶ بهدست آمد.

# نتایج مرحلهی آموزش (-MODWT-VMD) BPNN در پیشبینی ذراتمعلق PM<sub>2.5</sub>شهر ارومیه

در این مدل ترکیبی تجزیهی دو مرحلهای، در مرحلهی اول تجزیه، دادههای اصلی PM2.5 توسط مدل تبدیل موجک گسسته حداکثر همپوشانی به ۲ سطح جزئیات با فرکانس بالا (d و d) و یک سطح تقریب با فرکانس پایین (a2) تجزیه شدند (**شکل ۱**). سپس در مرحلهی دوم تجزیه، هر ۲ سطح جزئیات (d و d) و یک سطح تقریب (a2)، توسط مدل تجزیه مد متغیر، به ۸ توابع مد متغیر تجزیه می شوند 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 –

شبکه عصبی پسانتشار پیشبینی شدهاند بهطور جداگانه در **شکل ۵** نمایش داده شده است. نتایج پیشبینی هر کدام از سطوح جزئیات (d1 و d2) و سطح تقریب (a2) براساس معیارهای ارزیابی بهصورت عددی نیز در **جدول ۳** آمده است. در نهایت با جمعزدن نتایج پیشبینی بهدست آمده از هر

سطوح، پیشبینی نهایی انجام گرفت که در این مدل، مقادیر RMSE=۳/۸۰۷۴ ، MAE=۲/۸۵۸۵ ، R=۰/۹۲، MAE=۲/۱۸۴۰ برای مرحلهی آموزش و مقادیر RMSE=۲/۱۸۴۰ ، R=۸۰ و RMSE=۲/۷۶۷۹ برای مرحلهی آزمون بهدست آمد.



شکل ۱. نتایج تجزیه ذراتمعلق PM<sub>2.5</sub> به ۲ سطح جزئیات (d<sub>2</sub> و d<sub>2</sub>) و یک سطح تقریب (a<sub>2</sub>) توسط مدل تبدیل موجک گسسته حداکثر همپوشانی



شکل ۲. نتایج پیشبینی هر کدام از سطوح جزئیات (d1 و d2) و سطح تقریب (a2)، (الف) در مدل MODWT- BPNN مرحلهی آموزش، (ب) در مرحلهی آزمون



شکل ۳. نتایج تجزیهی ذراتمعلق PM2.5 به ۸ مد متغیر توسط مدل تجزیه مد متغیر

						(ج)						(ب)						(الف)
95 95	[~~~	www	nin	min	min	~	8 0	Allower Allow Allow A	with a the second second		wayaan ahaa ka sa	www.e	F 0	111 \$100 0 + + + - + + + + + + + + + + + + + +				- 1000
0	0	100	200	300	400	500	0	100	200	300	400	500	-20	100	200	300	400	500
1WU 30	-					_	WW 0			····		WW90 -	W					
- 10	0	100	200	300	400	500	0	100	200	300	400	500	50	100	200	300	400	500
0 10 0	~~~	ww	vin	~		~ ·	VM2	······································	v	~~~~W	N/W		200			-		- 10-
-10	0	100	200	300	400	500	0	100	200	300	400	500	0	100	200	300	400	500
NM3	h	~~~W	Win	~~~WWW	www.	-	SMV S	Warman	******			Wee -	SWA	attenting		·····	www.	Ner-
-0	0	100	200	300	400	500	0	100	200	300	400	500	.20	100	200	300	400	500
MMA DO		~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~	~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~	www.ww	www	-	WWW DO				llan-mananan	-	WWW NWW			Manual Milling	witerenter	-
	0	100	200	300	400	500	0	100	200	300	400	500	0	100	200	300	400	500
VM5	~	Ň	~~~~	$\sim \sim \sim$	$\sim \sim$	~ ·	SWA					-	SMV SMV	thread thread the	and the ser	- adding addi	14	with -
-10	0	100	200	300	400	500	0	100	200	300	400	500	0	100	200	300	400	500
VM6	h	www	min-	min	min	in .	9WA			-		NN -	NMS	At			-	
	0	100	200	300	400	500	0	100	200	300	400	500	0	100	200	300	400	500
LWN 00	ditte danse	-				41M	EN O	-		-		- beer	W 0	****				
0.2	0	100	200	300	400	500	0	100	200	300	400	500	10	100	200	300	400	500
10 0 C	2	~					SW0						SWA SWA			+		and-
-10	0	100	200	300	400	500	-5	100	200	300	400	500	0	100	200	300	400	500

شکل ۴. نتایج تجزیهی سطح جزئیات (الف)d1 به ۸ مد متغیر، (ب) d2 به ۸ مد متغیر و (ج) تجزیهی سطح تقریب a2 به ۸ مد متغیر توسط مدل تجزیه مد متغیر



شکل ۵. نتایج پیشبینی هر کدام از سطوح جزئیات (d1 و d2) و سطح تقریب (a2) توسط مدل (MODWT-VMD-BPNN)، (الف) در مرحله آموزش، (ب) در مرحله آزمون

سطوح	<b>R</b> آموزش	آزمون
$d_1$	•/\\	٠/۴٠
$d_2$	٠/٨۶	•/74
$a_2$	۰/۹۴	•/Y•

نتایج مرحله آموزش مدل شبکه عصبی پسانتشار (BPNN) در پیشبینی ذراتمعلق PM2.5شهر ارومیه

در این پژوهش برای جلوگیری از افزایش خطا شبکه سه لایه مورد استفاده قرار گرفت. حداکثر تعداد نورونهای مخفی براساس قضیه کولموگوروف 1+2n1 میتواند باشد. با توجه به این که در این تحقیق تعداد ورودیها ۵ است مرز بالایی 11=1+(5)2 مناسب خواهد بود. بنابراین تعداد نورونهای لایه مخفی از ۱ تا ۱۱ متغیر بوده و نهایتا لایه پنهان با ۱۰ نورون کمترین میزان خطا را بهخود

اختصاص داد. درنهایت مدل شبکهی عصبی پسانتشار مناسب بهدست آمده، از یک لایه ورودی با ۵ پارامتر، یک لایه مخفی با ۱۰ نورون و لایهی خروجی با ۱ پارامتر هدف تشکیل شده است. در این مدل، مقادیر ۲۸/۸۱ هدف تشکیل شده است. در این مرحله مقادیر ۲۲/۸۶۶ MAE=۴/۲۸۶۶ و مقادیر ۲۲/۲۰۴ آموزش نشان داده شده در **شکل ۶** و مقادیر ۲۲/۲۰۴ مدده شده در **شکل ۷** بهدست آمد.



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

داشتهاند. دلیل آن ناشی از آن است که دادههای ذراتمعلق PM2.5 دارای نوسانات فرکانسی زیادی است. پیشبینی این دادهها تا حدودی مشکل است و مدلهای پیشبینی سریهای زمانی نمیتوانند بهطور مناسب این

نوسانات را مدیریت کنند. بنابراین برای غلبه بر این مشکل، از مدلهای تجزیهای MODWT و VMD استفاده می شود. این مدل ها داده های ذرات معلق PM2.5 را به تعدادی زیرسری با فرکانسهای متفاوت تجزیه می کنند و نوسانات ذاتی در دادههای اصلی به طور کامل حفظ شده و باعث افزایش دقت پیشبینی می شود (۱۶). این نتایج با نتایج ژائو و همکاران هم خوانی دارد. ژائو و همکاران در سال ۲۰۱۴ (۱۲) نشان دادند که 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<sub>2.5</sub> است. مقایسهی هر دو مدل تركيبى (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). هم چنین 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 بازیابی 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 ذراتمعلق PM<sub>2.5</sub> 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 به حساب می آید نشان میدهد که زیرسریها بهخصوص a2 در مرحلهی آزمون، پیشبینی خوبی نداشتهاند. بهطور معمول مهم ترین 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 احتياطي توسط دولت و مردم مي تواند سبب كاهش اثرات زيانبار الودكي هوا بهویژه در مناطق شهری پرجمعیت و مناطق صنعتی شود. محدودیت مدلهای تجزیهی دو مرحلهای شامل پیچیدگی محاسباتی، نیاز به انتخاب بهینهی پارامترها (تعداد زیر سری ها 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 مدل ها را محدود کرده است. در صورت رفع این موارد و بر اساس نتایج پژوهش حاضر استفاده از این مدلها می تواند سبب افزایش دقت پیشبینیها شود. در نهایت پیشنهاد می شود با توجه به امکان استفاده از مدلهای مختلف در تجزیهی مرحلهی اول و تجزیهی مرحلهی دوم این مدلها می توان با تحقیقات بیشتر در زمینهی استفاده از مدلهای مختلف دقت پیشبینی را افزایش داد.

## نتيجهگيرى

بر اساس این پژوهش می توان نتیجه گرفت استفاده از تبدیل موجک در مرحلهی اول تجزیه بهدلیل توانایی آن در تحلیل سیگنال PM<sub>2.5</sub> که دارای تغییرات ناگهانی و ناپيوستگى موضعى است مناسب است. اما اين تبديل دارای یک محدودیت است. تبدیل موجک بهتنهایی نمی تواند فرکانس های چندگانه در سیگنال PM<sub>2.5</sub> را استخراج کند، برای غلبه بر این مشکل از مدل تجزیهی دوم، مدل تجزیهی مد متغیر استفاده می شود و هر کدام از زیرسریها (d1، d2 و a2)، توسط مدل تجزیهی مد متغیر به هشت مود متغیر تجزیه می شوند 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 زیرسری ها نسبت به مدل تجزیهی تکمرحلهای، پیش بینی بهتری داشته اند که این نتایج با نتایج وانگ و همکاران در سال ۲۰۱۷ (۱۶) هم خوانی 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. هم چنین هر گونه تضاد منافع حقیقی یا مادی که ممکن است بر نتایج یا تفسیر مقاله تاثیر بگذارد را رد می کنند.

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

### References

1. Esmaili, R. and Amini, F. L. 2021. Identification of hot spots PM2.5 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 PM2.5 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. PM2.5 -induced oxidative stress triggers autophagy in human lung epithelial A549 cells. Taxicology inVitro, 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. <u>https://doi.org/10.1080/10473289.2000.10</u> 464025 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 PM2.5 exposures on human health in residential areas, Bantul, Yogyakarta, Indonesia. Toxicology Reports: 14: 101949. <u>https://doi.org/10.1016/j.toxrep.2025.1019</u> <u>49</u> PMid:40026480 PMCid:PMC11869533 7. Wu, Ch-H., Dang, T. T. M., Mutuku, J. K., Lin, L-M., Huang, B-W. and Changکردستان است. بدینوسیله از کارمندان این کارگاه تشکر و قدردانی می گردد. تعارض منافع: نویسندگان هیچ گونه تعارض منافع با

تعارص منافع: نویسندگان هیچ کونه تعارص منافع با یکدیگر ندارند.

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

ملاحظات اخلاقى: نويسندگان تمام نكات اخلاقى شامل

Chien, G-P. 2025. Evaluation of PM2.5 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.2024.17 8213

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 PM2.5 based on human serum albumin adductome analysis. Science of The Total Environment, 955: 176958..

https://doi.org/10.1016/j.scitotenv.2024.17 6958 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). <u>https://doi.org/10.22067/geoeh.2024.8752</u>8.1476.

10. Najjarian, M., Etemadfard, 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/geoeh.2023.8299 2.1384.

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

۹۵

(Case Study: Southwest Iran). Journal of Geography and Environmental Hazards, 13(4).(In Persian). https://doi.org/10.22067/geoeh.2024.8908 8.1504.

12. Zhou, Q., Jiang, H., Wang, J. and Zhou, J. 2014. A hybridmodel for PM2.5 forecasting based on ensemble empirical mode decomposition and a general regression neural nrtwork. Science of the 496: Total Environment, 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.2015.0 4.057

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.2015.0 2.030

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

https://doi.org/10.1016/j.apenergy.2024.12 3920

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.2024.1057 34

19. Xue, H., Wang, G., Li, X. and Du, F. 2024. Predictive combination model for CH4 separation and CO2 sequestrarion with CO2 injection into coal seams: VWD-STA-BiLSTM-ELM hybrid neural network modeling. Energy, 313: 133744. https://doi.org/10.1016/j.energy.2024.1337 44

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.2024.131

805

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 AssetManagement 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 Khezrzadeh, 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. <u>https://doi.org/10.1016/j.envsoft.2010.07.0</u> 06

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).