



Forecasting the Occurrence of Dust Storms using the Accuracy Assessment of Artificial Neural Networks in Selected Stations in the Western Half of Iran

Fatemeh Vatanparast Galeh Juq¹, Bromand Salahi²  , Batool Zeinali³

1. Ph.D. student in Climatology, Department of Physical Geography, Faculty of Social Sciences, University of Mohaghegh Ardabili, Ardabil, Iran.
2. Professor of Climatology, Department of Physical Geography, Faculty of Social Sciences, University of Mohaghegh Ardabili, Ardabil, Iran. (Corresponding Author). E. salahi@uma.ac.ir
3. Professor of Climatology, Department of Physical Geography, Faculty of Social Sciences, University of Mohaghegh Ardabili, Ardabil, Iran.

ARTICLE INFO

Keywords

Dust Storm
Prediction
Modeling
Neural Network
Western Half of Iran

Article History:

Received:

27 Nov 2024

Received in revised form:

13 Feb 2024

Accepted:

20 Feb 2024

Available online:

21 Jun 2025

ABSTRACT

Today, the phenomenon of dust is one of the most important natural hazards and has left adverse effects on human health, agriculture and the environment. The purpose of this research is to predict the frequency of dust storms in 17 selected stations in the western half of Iran. For this purpose, dust codes and horizontal visibility of less than 1 km during the statistical period (1987-2023) were used to calculate the frequency. Then Radial Basis Functions (RBF), Multilayer Perceptron (MLP), Fuzzy Neural Inference System (ANFIS) and Support Vector Regression (SVR) neural networks are used to predict dust and humidity, temperature, precipitation, wind speed and direction data as Input data and data of days with dust as a target were used in the modeling. The data were divided into two groups, 80% of the data were used for training and the other 20% were used for testing the network. The comparison results of the used models showed that the highest value of correlation coefficient in Kermanshah, Ramhormoz and Eslamabad-E-Gharb stations was 0.99, 0.97 and 0.95, respectively, based on the results of the RBF model. In general, this model has provided the best performance due to less error and more correlation in the stations; Therefore, due to its high ability, it can be a quick solution in predicting the amount of dust and its distribution. The output results of the RBF model for dust forecasting in the future (2024-2040) showed that dust storms are more likely to occur in Abadan and Ahvaz and, like the observation period, Aligudarz can be considered as a low-wind station in the region.

Citation: Vatanparast, F., Salahi, B. & Zeinali, B. (2025). Forecasting the Occurrence of Dust Storms using the Accuracy Assessment of Artificial Neural Networks in Selected Stations in the Western Half of Iran, Journal of Geography, 23 (84), 21-39.

 <http://10.22034/JIGA.2025.2046840.1356>



© The Author (s).
an open access article under the CC BY license (<https://creativecommons.org/licenses/by/4.0/>)

Publisher: Iranian Geographical Associati This is

Extended Abstract

Introduction

Dust is a characteristic of dry areas or any area that is located near the source of dust generation and benefits from its consequences by being located in the path of dust systems. Dust storms are one of the natural hazards that can have adverse effects on human health, agriculture and the environment. Iran is one of the arid regions of the world that is affected by severe dust storm events. The primary source of dust storms in western Iran often originates from Iraq, Syria and Saudi Arabia

Methodology

In this study, hourly dust data (horizontal visibility and current weather codes), average temperature, precipitation, humidity, and wind speed and direction data for 1987-2023 were used. Clustering was performed using the (FCM) method. In order to accurately predict future dust storms, RBF, MLP, ANFIS, and SVR neural network models were used, and to select the appropriate model, the accuracy criteria of Mean Square Error (MSE), Root Mean Square Error (RMSE), and correlation coefficient (R) were used. After selecting the appropriate model, the forecast of changes in dusty days for the coming years (2024-2040) was made and the output data was zoned.

Results and Discussion

Analysis based on the FCM method showed that the critical situation cluster includes Abadan and Ahvaz stations. The results of the evaluation and testing indicators of models for dust prediction showed that the best performance for dust estimation based on less error and more correlation is the RBF neural network model. The results of simulation of the observed and predicted values of dust storms of the studied stations for the test data by RBF showed that the curves of the observed and predicted values are close to each other; therefore, this model was able to model and predict days with dust storms with acceptable accuracy using the input variables. The forecast of dust conditions in the years 2024-2040 showed the highest dust frequency for Abadan, Ahvaz and Masjed-e-Suleiman stations, which are equal to 204, 185 and 144 days, respectively.

Conclusion

Paying attention to the dangers of dust storms, identifying the areas affected by them, and realistically predicting them will improve the quality of life and increase human health, and can be effective in environmental planning and optimal and desirable protection of natural resources. The results of this study showed that artificial neural network methods have higher superiority and accuracy and can extract hidden relationships between inputs and outputs.

Funding

There is no funding support.

Authors' Contribution

All of the author approved the content of the manuscript and agreed on all aspects of the work.

Conflict of Interest

Author declared no conflict of interest.

Acknowledgments

We are grateful to all the scientific consultants of this paper.

References

- 1) Adiguzel, E., Ozer, E., Akgundogdu, A. & Yilmaz, A.E. (2019). Prediction of dust particle size effect on efficiency of photovoltaic modules with ANFIS: an experimental study in Aegean region, Turkey Solar Energy, 177, 690–702.
<https://doi.org/10.1016/j.solener.2018.12.012>.
- 2) Ahmadaali, K. A., Parsinejad, M. & Rahmani, B. (2009). Estimation of saturation percentage of soil using multiple regression, ANN, and ANFIS techniques, Computer and Information Science, 2, 127.
<http://dx.doi.org/10.5539/cis.v2n3p127>.


- 3) Al-Dousari, A., Omar, A., Al-Hemoud, A., Aba, A., Alrashedi, M., Alrawi, M., Rashki, A., Petrov, P., Ahmed, M. & Al-Dousari, N. (2022). A Success Story in Controlling Sand and Dust Storms Hotspots in the Middle East, *Atmosphere*, 13(1335).
<https://doi.org/10.3390/atmos13081335>.
- 4) Alizadeh-Choobari, O., Ghafarian, p. & Owlad, E. (2016). Temporal variations in the frequency and concentration of dust events over Iran based on surface observations, *International Journal of Climatology*, 36, 2050–2062.
<http://dx.doi.org/10.1002/joc.4479>.
- 5) Alshammari, R.K., Alrwais, O. & Aksoy, M. S. (2024). Machine Learning Forecast of Dust Storm Frequency in Saudi Arabia Using Multiple Features, *Atmosphere*, 15(5), 520.
<https://doi.org/10.3390/atmos15050520>.
- 6) An, L., Che, H., Xue, M., Zhang, T., Wang, H., Wang, Y. & Zhang, X. (2018). Temporal and spatial variations in sand and dust storm events in East Asia from 2007 to 2016, Relationships with surface conditions and climate change. *Science of the Total Environment*, 633, 452-462.
<https://doi.org/10.1016/j.scitotenv.2018.03.068>.
- 7) Ardon-Dryer, K., Mock, C., Reyes, J. & Lahav, G. (2020). The effect of dust storm particles on single human lung cancer cells, *Environmental Research*, 181, 108891.
<https://doi.org/10.1016/j.envres.2019.108891>.
- 8) Aryal, Y. (2022). Application of Artificial Intelligence Models for Aeolian Dust Prediction at Different Temporal Scales: A Case with Limited Climatic Data, *AI*, 3, 707–718.
<https://doi.org/10.3390/ai3030041>.
- 9) Asyali, M.H., Colak, D., Demirkaya, O. & Inan, M.S. (2006). Gene expression profile classification: a review. *Curr. Bioinform*, 1, 55–73. <http://dx.doi.org/10.2174/157489306775330615>.
- 10) 10. Chen, S., Cowan, C. F. N. & Grant, P. M. (1991). Orthogonal Least Squares Learning Algorithm for Radial Basis Function Networks, *IEEE Transactions on Neural Networks*, 2(2), 302-309.
<https://doi.org/10.1109/72.80341>.
- 11) Csavina, J., Field, J., Felix, O., Corral-Avitia, A. Y., Saez, A. E. & Betterton, E. (2014). Effect of wind speed and relative humidity on atmospheric dust concentrations in semi-arid climates, *Science of the Total Environment*, 487(1), 82-90. <https://doi.org/10.1016/j.scitotenv.2014.03.138>.
- 12) Dahiya, S., Singh, B., Gaur, S., Garg, V. K. & Kushwaha, H. S. (2007). Analysis of groundwater quality using fuzzy synthetic evaluation, *Journal of Hazardous Materials*, 147(3), 938-946.
<https://doi.org/10.1016/j.jhazmat.2007.01.119>.
- 13) Darvishi Boloorani, A., Soleimani, M., Neysani Samany, N., Bakhtiari, M., Qareqani, M., Papi, R. & Mirzaei, S. (2023). Assessment of Rural Vulnerability to Sand and Dust Storms in Iran, *Atmosphere*, 14(2), 281. <https://doi.org/10.3390/atmos14020281>.
- 14) Ebrahimi-Khusfi, Z., Taghizadeh-Mehrjardi, R. I., Kazemi, M. & Nafarzadegan, A.R. (2021b). Predicting the ground-level pollutants concentrations and identifying the influencing factors using machine learning, wavelet transformation, and remote sensing techniques, *Atmospheric Pollution Research*, 12(5), 101064. <https://doi.org/10.1016/j.apr.2021.101064>.
- 15) Ebrahimi-Khusfi, Z., Taghizadeh-Mehrjardi, R. & Nafarzadegan, A. R. (2021a), Accuracy, uncertainty, and interpretability assessments of ANFIS models to predict dust concentration in semi-arid regions, *Environmental Science and Pollution Research*, 28, 6796–6810.
<https://doi.org/10.1007/s11356-020-10957-z>.
- 16) Fattahi Masrou, P. & Rezazadeh, M. (2022). Spatio-Temporal Distribution of Various Types of Dust Events in the Middle East during the Period 1996-2015, *Journal of the Earth and Space Physics*, 47(4), 231-248. <https://doi.org/10.22059/jesphys.2021.321010.1007306>.
- 17) Foody, G. M. (2004). Supervised image classification by MLP and RBF neural networks with and without an exhaustively defined set of classes, *International Journal of Remote Sensing*, 25(15), 3091–3104. <http://dx.doi.org/10.1080/01431160310001648019>.
- 18) Garcia Nieto, P.J., Sanchez Lasheras, F., Garcia-Gonzalo, E. & de Cos Juez, F.J. (2018). PM₁₀ concentration forecasting in the metropolitan area of Oviedo (Northern Spain) using models based on SVM, MLP, VARMA and ARIMA: A case study, *Science of The Total Environment*, 621, 753-761.
<https://doi.org/10.1016/j.scitotenv.2017.11.291>.
- 19) Gholami, G., Mohamadifar, A. & Collins, A. L. (2020a). Spatial mapping of the provenance of storm dust: Application of data mining and ensemble modelling, *Atmospheric Research*, 233 (104716).
<https://doi.org/10.1016/j.atmosres.2019.104716>.
- 20) Gholami, H., Mohamadifar, A.A., Sorooshian, A. & Jansen, J. D. (2020b). Machine-learning algorithms for predicting land susceptibility to dust emissions: The case of the Jazmurian Basin, Iran, *Atmospheric Pollution Research*, 11(8), 1303-1315.
<https://doi.org/10.1016/j.apr.2020.05.009>

- 21) Goudarzi, G. R., Hopke, P. K. & Yazdani, M. (2021). Forecasting PM_{2.5} concentration using artificial neural network and its health effects in Ahvaz, Iran, *Chemosphere*, 283, 131285. <https://doi.org/10.1016/j.chemosphere.2021.131285>.
- 22) Goudie, A. S. (2019). Dust storms and human health. In extreme weather events and human health: international case studies, Cham: Springer International Publishing, 13-24. https://doi.org/10.1007/978-3-030-23773-8_2.
- 23) Goudie, A.S. (2020). Dust storms and human health. *Extreme Weather Events and Human Health*, Springer, Cham, 13–24. http://dx.doi.org/10.1007/978-3-030-23773-8_2.
- 24) Goudie, A. S. & Middleton, N. (2006). *Desert dust in the global system*. New York: Springer Berlin Heidelberg.
- 25) Guan, Q., Sun, X., Yang, J., Pan, B., Zhao, S. & Wang, L. (2017). Dust Storms in Northern China, Long-Term Spatiotemporal Characteristics and Climate Controls, *Journal of Climate*, 30 (17), 6683–6700. <https://doi.org/10.1175/JCLI-D-16-0795.1>
- 26) Hamzeh, N. H., Kaskaoutis, D. G., Rashki, A. & Mohammadpour, K. (2021). Long-Term Variability of Dust Events in Southwestern Iran and Its Relationship with the Drought, *Atmosphere*, 12, 1350. <https://doi.org/10.3390/atmos12101350>.
- 27) Hamzeh, N. H., Ranjbar Saadat Abadi, A., M. C. G. O., Habibi, M. & Schoner, W. (2022). Analyses of a lake dust source in the middle east through models performance, *Remote Sensing*, 14(9), 1-24. <https://doi.org/10.3390/rs14092145>.
- 28) Huang, M., Peng, G., Zhang, J. & Zhang, S. (2006). Application of artificial neural networks to the prediction of dust storms, In *Northwest China Journal of Global and Planetary Change*, (52), 216–224. <http://dx.doi.org/10.1016/j.gloplacha.2006.02.006>.
- 29) Icer, S. (2013). Automatic segmentation of corpus collasum using Gaussian mixture modeling and Fuzzy C means methods, *Comput. Methods Programs Biomed*, 112, 38–46 . <https://doi.org/10.1016/j.cmpb.2013.06.006>.
- 30) Jang, J. S. R. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665–685. <http://dx.doi.org/10.1109/21.256541>.
- 31) Ji Ren, Q. D. E., Li, N. & Zhang, W. (2022). Research on Sand-Dust Storm Forecasting Based on Deep Neural Network With Stacking Ensemble Learning, *Research Article*, 10(38), 111855–111863 <http://dx.doi.org/10.1109/ACCESS.2022.3216309>.
- 32) Jish Prakash, P., Stenchikov, G. L., Kalenderski, S., Osipov, S. & Bangalath, H. K. (2015). The impact of dust storms on the Arabian Peninsula and the Red Sea, *Atmos. Chem. Phys*, 15, 199–222. <https://doi.org/10.5194/acp-15-199-2015>.
- 33) Kaboodvandpour, S., Amanollahi, J., Qhavam, S. & Mohammadi, B. (2015). Assessing the accuracy of multiple regressions, ANFIS, and ANN models in predicting dust storm occurrences in Sanandaj, Iran, *Natural Hazards*, 78, 879–893. DOI:10.1007/s11069-015-1748-0.
- 34) Labban, AH. & Butt, M .J. (2021). Analysis of sand and dust storm events over Saudi Arabia in relation with meteorological parameters and ENSO, *Arabian Journal of Geosciences*, 14(1), 1-12. <https://doi.org/10.1007/s12517-020-06291-w>.
- 35) Li, J., Garshick, E., Al-Hemoud, A., Huang, S. & Koutrakis, P. (2020). Impacts of meteorology and vegetation on surface dust concentrations in Middle Eastern countries, *Science of the Total Environment*, 712, 136597. <https://doi.org/10.1016/j.scitotenv.2020.136597>.
- 36) Li, J., Garshick, E., Huang, S. & Koutrakis, P. (2021). Impacts of El Niño-Southern Oscillation on surface dust levels across the world during, *Science of the Total Environment*, 769, 144566. <https://doi.org/10.1016/j.scitotenv.2020.144566>.
- 37) Liddicoat, C., Bi, P., Waycott, M., Glover, J., Lowe, A. J. & Weinstein, P. (2018). Landscape biodiversity correlates with respiratory health in Australia, *Journal of Environ Manag*, 206, 113–122. <https://doi.org/10.1016/j.jenvman.2017.10.007>.
- 38) Mahmoudi, L., Amiri Doumari, S., Safarianzengir, V., Maleki, R., Kianinejad, S. & Kianian, M. K. (2020). Monitoring and Prediction of Dust and Investigating its Environmental Impacts in the Western Half of Iran and the Eastern Borders of Turkey and Iraq, Using Remote Sensing and GIS, *Journal of the Indian Society of Remote Sensing*, 49(5).
- 39) <https://doi.org/10.1007/s12524-020-01224-2>
- 40) Mahmoudi, L. & Ikegaya, N. (2023). Identifying the Distribution and Frequency of Dust Storms in Iran Based on Long-Term Observations from over 400 Weather Stations, *Sustainability*, 15(16), 12294. <https://doi.org/10.3390/su151612294>.
- 41) Maleki, H., Sorooshian, A., Goudarzi, G., Baboli, Z., Birgani, Y. T. & Rahmati, M. (2019). Air pollution prediction by using an artificial neural network model, *Clean Technologies and Environmental Policy*, 21(6), 1341–1352. <https://doi.org/10.1007/s10098-019-01709-w>.

- 42) Middleton, N. J. (2017). Desert dust hazards, a global review, *Aeolian Res*, 24, 53–63. <https://doi.org/10.1016/j.aeolia.2016.12.001>.
- 43) Moghanlo, S., Alavinejad, M., Oskoei, V., Najafi Saleh, H., Mohammadi, A. A., Mohammadi, H. & DerakhshanNejad, Z. (2021). Using artificial neural networks to model the impacts of climate change on dust phenomenon in the Zanjan region, north-west Iran, *Urban Climate*, 35, 100750. <https://doi.org/10.1016/j.uclim.2020.100750>.
- 44) Nabavi, S. O., Haimberger, L., Abbasi, R. & Samimi, C. (2018). Prediction of Aerosol Optical Depth in West Asia Using Deterministic Models and Machine Learning Algorithms, *Aeolian Research*, 35, 69–84. <https://doi.org/10.1016/j.aeolia.2018.10.002>.
- 45) Opp, C., Groll, M., Abbasi, H. & Foroushani, MA. (2021). Causes and effects of sand and dust storms: What has past research taught us? A survey, *Journal of Risk and Financial Management*, 14(7), 1-25. <https://doi.org/10.3390/jrfm14070326>.
- 46) Rahmati, O., Panahi, M., Ghiasi, S.S., Deo, R.C., Tiefenbacher, J.P., Pradhan, B., Jahani, A., Goshtasb, H., Kornejady, A., Shahabi, H., Shirzadi, A., Khosravi, H., Moghaddam, D.D., Mohtashamian, M. & Bui, D.T. (2020a). Hybridized neural fuzzy ensembles for dust source modeling and prediction, *Atmospheric Environment*, 224, 117320. doi: <https://doi.org/10.1016/j.atmosenv.2020.117320>.
- 47) Rahmati, O., Mohammadi, F., Ghiasi, S. S., Tiefenbacher, J., Davoudi Moghaddam, D., Coulon, F., Asadi Nalivan, O. & Bui, D. T. (2020b). Identifying sources of dust aerosol using a new framework based on remote sensing and modelling, *Science of The Total Environment*, 737, 139508. <https://doi.org/10.1016/j.scitotenv.2020.139508>.
- 48) Rashki, A., Middleton, N. J. & Goudie, A. S. (2021). Dust storms in Iran – Distribution, causes, frequencies and impacts, *Aeolian Research*, 48, 100655. <https://doi.org/10.1016/j.aeolia.2020.100655>.
- 49) Raudkivi, A. J. (2013). *Hydrology: An advanced introduction to hydrological processes and modelling*, Elsevier.
- 50) Schepanski K. (2018). Transport of mineral dust and its impact on climate, *Geosciences*, 8(5), 1-19. <https://doi.org/10.3390/geosciences8050151>.
- 51) Schober, P., Boer, C. & Schwarte, L. A. (2018). Correlation coefficients: appropriate use and interpretation, *Anesth Analg*, 126, 1763–1768. <https://doi.org/10.1213/ANE.0000000000002864>.
- 52) Shi, L., Jiahua Zhang, J., Zhang, D., Igbawua, T. & Liu, Y. (2020). Developing a dust storm detection method combining Support Vector Machine and satellite data in typical dust regions of Asia, *Advances in Space Research*, 65(4), 1263-1278, <https://doi.org/10.1016/j.asr.2019.11.027>.
- 53) Smola, A. J. & Schölkopf, B. (2004). A tutorial on support vector regression, *Statistics and computing*, 14(3), 199-222. <https://doi.org/10.1023/B%3ASTCO.0000035301.49549.88>.
- 54) Taghizadeh-mehrjardi, R., Toomanian, N., Khavaninzadeh, A., Jafari, A. & Triantafilis, J. (2016). Predicting and mapping of soil particle-size fractions with adaptive neuro-fuzzy inference and ant colony optimization in central Iran, *Eur J Soil Sci*, 67, 707–725. <https://doi.org/10.1111/ejss.12382>.
- 55) Tsai, C. W., Christina, W. & Chen, C. K. (2023). River-dust induced airborne particulate matter forecasting using a hybrid model of improved complete ensemble empirical mode decomposition with adaptive noise and radial basis function neural network, *Atmospheric Environment*, 312(1), 119991. <https://doi.org/10.1016/j.atmosenv.2023.119991>.
- 56) Vapnik, V. (2013). *The nature of statistical learning theory*, Springer science & business media.
- 57) Venkatesan, P. & Anitha, S. (2006). Application of a radial basis function neural network for diagnosis of diabetes mellitus, *Current Science*, 91(9), 1195–1199. <http://eprints.nirt.res.in/id/eprint/789>.
- 58) Wang, W., Samat, A., Abuduwaili, J., De Maeyer, P., d. & Voorde, T. V. D. (2023). Machine learning-based prediction of sand and dust storm sources in arid Central Asia, *International Journal of Digital Earth*, 16(1), 1530-1550. <https://doi.org/10.1080/17538947.2023.2202421>.
- 59) Willmott, C.J. (1982). Some comments on the evaluation of model performance, *Bulletin American Meteorological Society*, 63, 1309-1313. [https://doi.org/10.1175/1520-0477\(1982\)063%3C1309:SCOTEO%3E2.0.CO;2](https://doi.org/10.1175/1520-0477(1982)063%3C1309:SCOTEO%3E2.0.CO;2).
- 60) Wong, M.S., Xiao, F., Nichol, J., Fung, J., Kim, J., Campbell, J. & Chan, P. W. (2015). A multi-scale hybrid neural network retrieval model for dust storm detection, a study in Asia, *Atmospheric Research*, 158, 89-106.

https://ui.adsabs.harvard.edu/link_gateway/2015AtmRe.158...89W/doi:10.1016/j.atmosres.2015.02.006.

- 61) Wu., Y., Bo, W, Li, S., & Guo, Y. (2021). Sand and dust storms in Asia: a call for global cooperation on climate change, *The Lancet Planetary Health*, 5(6), e329-e330.
[https://doi.org/10.1016/s2542-5196\(21\)00082-6](https://doi.org/10.1016/s2542-5196(21)00082-6).
- 62) Xu, Z., Hou, Z., Han, Y., Guo, W. (2016). A diagram for evaluating multiple aspects of model performance in simulating vector fields, *Geosci Model Dev*, 9, 4365–4380.
<https://doi.org/10.5194/gmd-2016-172>.
- 63) Yadav, V., Yadav, A. K., Singh, V., Tej & Singh, T. (2024). Artificial neural network an innovative approach in air pollutant prediction for environmental applications: A review, *Results in Engineering*, 22, 102305,
<https://doi.org/10.1016/j.rineng.2024.102305>.
- 64) Yang, Q., Yuan, Q., Li, T., Shen, H. & Zhang, L. (2017). The relationships between PM2. 5 and meteorological factors in China: Seasonal and regional variations, *International journal of environmental research and public health*, 14(12), 1-19.
<https://doi.org/10.3390/ijerph14121510>.
- 65) Yilmaz, I., & Oguz Kaynar, O. (2011). Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils, *Expert Systems with Applications*, 38(5), 5958-5966,
<https://doi.org/10.1016/j.eswa.2010.11.027>.
- 66) Zaheer, K., Saeed, S. & Tariq, S. (2023). Prediction of aerosol optical depth over Pakistan using novel hybrid machine learning model, *Research Article - Atmospheric & Space Sciences*, 71, 2009–2029.
<https://doi.org/10.1007/s11600-023-01072-x>.
- 67) Zeinali, B., Vatanparast Ghaleh juq, F., Teymouri, M., Das, S., Ruhi, F. & Sihag, P. (2023). Selection of the best clustering technique in order to zone the frequency of dust storms in Iran, *Arab J Geosci*, 16, 74, 1-15.
<https://doi.org/10.1007/s12517-022-11135-w>.





پیش‌بینی وقوع طوفان‌های گرد و غبار با استفاده از ارزیابی دقت شبکه‌های عصبی مصنوعی در ایستگاه‌های منتخب نیمه غربی ایران

فاطمه وطن‌پرست قلعه‌جوق^۱، برومند صلاحی^۲، بتول زینالی^۳

۱. دانشجوی دکترای آب و هواشناسی، گروه جغرافیای طبیعی، دانشکده علوم اجتماعی، دانشگاه محقق اردبیلی، اردبیل، ایران.

۲. استاد، گروه جغرافیای طبیعی، دانشکده علوم اجتماعی، دانشگاه محقق اردبیلی، اردبیل، ایران. (نویسنده مسئول) E: salahi@uma.ac.ir

۳. استاد، گروه جغرافیای طبیعی، دانشکده علوم اجتماعی، دانشگاه محقق اردبیلی، اردبیل، ایران. E: zeynali.b@uma.ac.ir

چکیده

اطلاعات مقاله

واژگان کلیدی:

پیش‌بینی
شبکه عصبی
طوفان گرد و غبار
مدل‌سازی
نیمه غربی ایران

امروزه پدیده گرد و غبار در شمار مهم‌ترین مخاطرات طبیعی قرار گرفته و اثرات نامطلوبی بر سلامتی انسان، کشاورزی و محیط‌زیست برجای گذاشته است. هدف پژوهش حاضر پیش‌بینی فراوانی طوفان‌های گرد و غبار در ۱۷ ایستگاه منتخب نیمه غربی ایران است. بدین منظور، برای محاسبه فراوانی از کدهای گرد و غبار و دید افقی کمتر از ۱ کیلومتر دوره آماری ۱۹۸۷-۲۰۲۳ استفاده شد. سپس شبکه‌های عصبی توابع پایه شعاعی (RBF)، پرسپترون چندلایه (MLP)، سیستم استنتاج عصبی-فازی (ANFIS) و رگرسیون بردار پشتیبان (SVR) جهت پیش‌بینی گرد و غبار انتخاب شد. داده‌های رطوبت، دما، بارش، سرعت و جهت باد به‌عنوان داده‌های ورودی و داده روزهای توأم با گرد و غبار به‌عنوان هدف، در مدل‌سازی‌ها به کار گرفته شد. داده‌ها به دو گروه تقسیم شدند. از ۸۰ درصد داده‌ها برای آموزش و از ۲۰ درصد دیگر برای آزمون شبکه استفاده شد. نتایج مقایسه مدل‌های مورد استفاده نشان داد که بر اساس نتایج حاصل از مدل RBF، بیشترین مقدار ضریب همبستگی در ایستگاه‌های کرمانشاه، رامهرمز و اسلام‌آبادغرب به ترتیب برابر با ۰/۹۹، ۰/۹۷ و ۰/۹۵ بوده است. در مجموع، این مدل به دلیل خطای کمتر و همبستگی بیشتر در ایستگاه‌ها بهترین عملکرد را ارائه نموده است؛ بنابراین به دلیل داشتن توانایی بالا، می‌تواند یک راهکار سریع در پیش‌بینی مقدار گرد و غبار و پراکنش آن باشد. نتایج خروجی مدل RBF برای پیش‌بینی گرد و غبار در آینده (۲۰۲۴-۲۰۴۰) نشان داد احتمال رخداد طوفان‌های گرد و غبار در آبادان و اهواز بیشتر بوده و همانند دوره مشاهداتی، الیگودرز را می‌توان جزو ایستگاه کم‌باد منطقه به حساب آورد.

تاریخ دریافت:

۱۴۰۳/۰۹/۰۷

تاریخ بازنگری:

۱۴۰۳/۱۱/۲۵

تاریخ پذیرش:

۱۴۰۳/۱۲/۰۲

تاریخ چاپ:

۱۴۰۳/۰۳/۰۱

استناد: وطن‌پرست قلعه‌جوق، فاطمه؛ صلاحی، برومند و زینالی، بتول. (۱۴۰۴). پیش‌بینی وقوع طوفان‌های گرد و غبار با استفاده از ارزیابی دقت شبکه‌های عصبی مصنوعی در ایستگاه‌های منتخب نیمه غربی ایران، نشریه جغرافیا، ۲۳(۸۴)، ۳۹-۲۱.

<http://10.22034/JIGA.2025.2046840.1356>



مقدمه و پیشینه

گرد و غبار خصوصیات مناطق خشک یا هر منطقه‌ای است که در مجاورت منبع تولید گرد و غبار قرار دارد و با قرارگیری در مسیر گذر سامانه‌های گرد و غباری از پیامدهای آن نیز بهره‌ور می‌شود (صلاحی و همکاران، ۱۳۹۴: ۷۴؛ Guan et al, 2017: 6684). درواقع طوفان‌های گرد و غبار یکی از مخاطرات طبیعی هستند که می‌توانند به دیگر مناطق نیز منتقل شوند و بر تغییرات آب‌وهوای جهانی نیز اثر بگذارند (یزدان پناه درو، ۱۳۹۷: ۳۷؛ An et al, 2018; Schepanski et al, 2018). زندگی و سلامت انسان را در معرض خطر قرار دهند (Yang et al, 2017: 2; Goudie, 2019: 14; Ardon et al, 2020: 2; Goudie, 2020: 14; Opp et al, 2021: 2; Wu et al, 2021: 329; Darvishi Boloorani et al, 2023: 2). باعث کاهش بهره‌وری خاک و اختلال در ارتباط شوند (Jish Prakash et al, 2015: 200)، بر پوشش گیاهی و نیروگاه‌های خورشیدی (Li et al, 2021; Labban and Butt, 2021: 2)، محصولات زراعی و زمین‌های کشاورزی اثر بگذارند (عقیفی، ۱۳۹۶: ۱۸۵؛ مدبر پور و همکاران، ۱۳۹۸: ۹۲؛ امیر عضدی و همکاران، ۱۳۹۹: ۶۵؛ Rashki et al, 2021: 54). خاورمیانه یکی از مناطق خشک جهان است که تحت تأثیر رویدادهای بسیار شدید طوفان‌های گرد و غبار قرار گرفته است (Li et al, 2020; Hamzeh et al, 2022: 2). طوفان‌های گرد و غبار که بر ایران تأثیر می‌گذارند هم از منابع داخلی و هم از منابع خارجی می‌آیند (Hamzeh et al, 2021). منشأ اولیه طوفان‌های گرد و غبار در غرب ایران اغلب از منابع انتشار در مرزهای غربی ایران، یعنی عراق، سوریه و عربستان سعودی سرچشمه می‌گیرد (Al-Dousari, 2022; Mahmoudi et al, 2023; موغلی و همکاران، ۱۳۹۷: ۱۷۹). انتشار گرد و غبار و حمل رسوب تحت تأثیر فعل و انفعالات پیچیده زمین-اتمسفر، سرعت باد زیاد، فرسایش خاک، خاک بدون پوشش و رطوبت قرار دارد (Csavina et al, 2014: 83). با توجه به اثرات مخرب و خطرناک طوفان‌های گرد و غبار، اقدامات جدیدی برای شناسایی و کنترل پیدایش آن‌ها در منطقه مورد نیاز است. علاوه بر این، کاهش اثرات فاجعه‌بار طوفان‌های گرد و غبار برای همه بخش‌ها بسیار مهم است (Rahmati et al, 2020a). شبکه عصبی مصنوعی نوعی ساختار ریاضی است که قابلیت نشان دادن فرایندها و ساختار مطلوب غیرخطی برای ارتباط بین ورودی و خروجی‌های هر سیستمی را دارد. این شبکه با داده‌های موجود طی فرایند تعلیم، آموزش دیده و برای پیش‌بینی در آینده مورد استفاده قرار می‌گیرد که دارای خصوصیات توانایی آموزش، توانایی تعمیم و واکاوی برابر است (Dahiya et al, 2007: 940). به دلیل آسیب‌های ناشی از طوفان‌های گرد و غبار در سال‌های گذشته، توجه بسیاری از محققان به این پدیده جلب شده و شناسایی، مدل‌سازی و پیش‌بینی خطرات پدیده گرد و غبار در مناطق غبارآلود ایران و جهان برای بهبود آمادگی در برابر بلایا و پیشگیری از خسارت، مورد پژوهش و بررسی قرار گرفته است. در سال‌های اخیر، روش‌های هوش مصنوعی و شبکه‌های عصبی که به‌صورت بسته سیاه عمل می‌کنند به‌طور گسترده در مباحث هیدرولوژی و اقلیمی استفاده شده‌اند که در ادامه به برخی از این پژوهش‌ها اشاره می‌شود:

(Kaboodvandpour et al, 2017: 879) به ارزیابی دقت مدل‌های شبکه عصبی مصنوعی ANFIS^۱ و ANN^۲ در پیش‌بینی طوفان گرد و غبار سنج در ایران پرداختند. آزمون‌های پیش‌بینی نشان داد که دقت مدل ANFIS بالاتر است و دستاوردهای (Rahmati et al, 2020a) برای جنوب شرق ایران و (Ebrahimi-Khusfi, 2021a: 6796) در مناطق نیمه‌خشک ایران از یافته‌های آنان پشتیبانی می‌کند. در پژوهش (Maleki et al, 2019: 1341) پیش‌بینی آلودگی هوا با

^۱ Multiple Regression^۲ Adaptive Neuro Fuzzy Inference System^۳ Artificial Neural Networks

استفاده از ANN در شهر اهواز طی دوره آماری (۲۰۰۹-۲۰۱۰) عملکرد مناسب مدل و میزان ضریب همبستگی ۵۹/۹ و مقدار (RMSE)^۱ برابر با ۰/۸۷ را نشان داد که پژوهش (Goudarzi et al, 2021) با نتایج و یافته‌های آنان در اهواز همسو است و یافته‌های (Moghanlo et al, 2021: 178) با مدل مذکور در زنجان بیشترین مقدار PM₁₀ را برای سال ۲۰۴۳ نشان داد. در پژوهش (Rahmati et al, 2020b) شناسایی منابع گرد و غبار با ماشین بردار پشتیبان (SVM)^۲ جنگل تصادفی (RF)^۳ و تصاویر ماهواره‌ای MODIS در شرق ایران عملکرد بهتر مدل RF را نشان داد. در مطالعات (Mahmoudi et al, 2020) پیش‌بینی گرد و غبار در نیمه غربی ایران و مرزهای شرقی ترکیه و عراق با مدل‌های ANFIS و تابع پایه شعاعی (RBF)^۴ نشان داد دقت RBF بیشتر از مدل ANFIS برای پیش‌بینی است. در پژوهش (Gholami et al, 2020b: 1303) نیز پیش‌بینی گرد و غبار در حوضه جازموریان ایران با مدل ANFIS عملکرد قابل قبولی را نشان نداد. پیش‌بینی منشأ گرد و غبار طوفان استان خوزستان در پژوهش (Gholami et al, 2020a) با استفاده از الگوریتم داده‌کاوی RF، SVM، RBF و مدل‌سازی گروهی (EM)^۵ بالاترین دقت مدل EM را ارائه داد. (Ebrahimi-Khusfi, 2021b) به‌منظور پیش‌بینی ذرات PM₁₀ در کلان‌شهر اصفهان، عملکرد مدل (SVR)^۶ را با اعمال تبدیل موجک بررسی کردند. مشخص شد که عوامل مؤثر بر تغییرات زمانی این ذرات، رطوبت خاک و خشک‌سالی می‌باشد.

(Nabavi et al, 2018: 69) در غرب آسیا مدل‌های رگرسیون چندخطی (MLR)^۷، RF، خطوط رگرسیون تطبیقی چند متغیره (MARS)^۸، (SVM) و (ANN) را برای پیش‌بینی عمق نوری آئروسول (AOD)^۹ استفاده کردند. نتایج پیش‌بینی غلظت PM₁₀ منطقه شهری اویدو (شمال اسپانیا) در مطالعات (Garcia Nieto et al, 2018: 753) با استفاده از مدل‌های مبتنی بر SVM و (MLP)^{۱۰} نشان داد که SVM برای پیش‌بینی یک ماه و هفت ماه آینده بهتر عمل می‌کند. ترکیب این مدل با تصاویر ماهواره‌ای MODIS جهت شناسایی طوفان‌های گرد و غبار آسیا با دقت بیشتری همراه بود. (Shi et al, 2020: 1263) بررسی ANFIS و (MLP-NN)^{۱۱} جهت پیش‌بینی گرد و غبار جنوب غربی ایالت متحده از سال ۱۹۹۰ تا ۲۰۲۰ در پژوهش (Aryal, 2020: 707) عملکرد بهتر ANFIS را بر مبنای میزان همبستگی و RMSE نشان داد. در مغلوستان (Ji Ren et al, 2022: 111855) برای پیش‌بینی گرد و غبار از شبکه عصبی (LSTM)^{۱۲} و CNN^{۱۳} استفاده کردند. در پاکستان (Zaheer et al, 2023: 2009) به پیش‌بینی AOD با مدل‌های یادگیری ماشین (ML)^{۱۴}، SVR و MLR پرداختند. نتایج نشان داد مدل هیبریدی SVR برای پیش‌بینی عمق نوری هواویز (آئروسول) مناسب است. در پژوهش (Tsai et al, 2023) پیش‌بینی ذرات معلق در هوا (PM₁₀) با MLP و RBF بر مبنای معیارهای ارزیابی MAPE و RMSE خطای زیادی را در پیش‌بینی نشان داد. در آسیای مرکزی خشک (Wang et al, 2023: 1530) به پیش‌بینی

^۱ Root Mean Square Error (RMSE)

^۲ Support Vector Machine

^۳ Random Forest

^۴ Radial Basis Function

^۵ Ensemble Modelling

^۶ Support Vector Regression

^۷ Multiple Linear Regression

^۸ Multivariate Adaptive Regression Splines

^۹ Aerosol Optical Depth

^{۱۰} Multilayer Perceptron

^{۱۱} Multi-Layered Perceptron Artificial Neural Network

^{۱۲} Long Short Term Memory

^{۱۳} Convolutional Neural Network

^{۱۴} Machine learning

گرد و غبار بر اساس روش‌های ML، SVM و RF پرداختند که مدل RF بهترین عملکرد را نشان داد. پیش‌بینی طوفان‌های گرد و غبار عربستان سعودی در پژوهش (Alshammari et al, 2024) با استفاده از مدل‌های (TCN)، MLP و LSTM سازگاری بهتر مدل TCN را بر مبنای معیارهای ارزیابی RMSE و R^2 نشان داد. در مطالعات (Yadav et al, 2024) پیش‌بینی آلاینده‌های هوا با مدل ANN مشخص شد که مدل از دقت لازم برای پیش‌بینی برخوردار است. با توجه به مزایا، توانایی و قابلیت روش‌های مختلف شبکه عصبی مصنوعی در تحلیل داده‌ها برای پیش‌بینی اهداف مختلف، بیشتر مطالعات از این روش‌ها فقط برای پیش‌بینی استفاده کرده‌اند و کاربرد آن‌ها در بررسی تغییرات دوره‌های آبی نادیده گرفته شده است؛ بنابراین هدف پژوهش حاضر استفاده از توان روش‌های MLP (پرسپترون چندلایه)، RBF (توابع پایه شعاعی)، ANFIS (سیستم استنتاج عصبی - فازی) و SVR (رگرسیون بردار پشتیبان) جهت پیش‌بینی طوفان‌های گرد و غبار طی سال‌های آبی (۲۰۲۴-۲۰۴۰) در ایستگاه‌های منتخب غرب و جنوب غرب ایران بر مبنای مدل مناسب است.

مبانی نظری

خوشه‌بندی فازی (FCM)^۲

رویکرد FCM از عضویت فازی استفاده می‌کند و درجه‌ای از عضویت را برای هر کلاس تعیین می‌کند (Icer et al, 2013: 40). فرض مدل‌سازی FCM تشکیل خوشه‌های جدید از نقاط داده‌ای است که دارای مقادیر عضویت نزدیک به کلاس‌های موجود هستند (Asyali et al, 2006: 57). در خوشه‌بندی C-means فازی، چهار مرحله اصلی برای خوشه‌بندی وجود دارد: در مرحله اول، تعداد خوشه‌ها تعریف می‌شود. سپس الگوریتم با مرکز خوشه تصادفی به صورت اولیه مقداردهی می‌شود. مرکزهای خوشه‌ای بر اساس احتمال عضویت برای نقاط داده مجدداً محاسبه و مرکزها به روز می‌شوند. محاسبه سانتروئیدها و فرآیند به‌روزرسانی تا زمانی که به همگرایی رسیده یا تعداد تعاملات مشخص شده به دست آید، ادامه می‌یابد (Zeinali et al, 2023: 6).

شبکه عصبی مبتنی بر توابع پایه شعاعی (RBF)

شبکه عصبی (RBF) بر پایه یادگیری نظارت شده است و جایگزین مناسبی برای مدل MLP هست و در مدل‌سازی داده‌های غیرخطی هم خوب عمل می‌کند (Venkatesan and Anitha, 2006: 1197). ساختار این مدل شبیه به MLP است و از سه لایه ورودی، پنهان و خروجی تشکیل شده است (Chen et al, 1991: 303; Foody, 2004: 3093). با استفاده از رابطه (۱) تعریف می‌شود.

$$y_k(X) = \sum_{j=1}^M w_{kj} \phi_j(X) + w_{ko} \quad \text{رابطه (۱)}$$


که در آن M تعداد توابع پایه، T بردار داده ورودی، w_{kj} ارتباط وزنی بین تابع پایه و لایه خروجی و ϕ_j تابع غیرخطی واحد زاست که معمولاً به صورت گوسی شکل است (رابطه ۲).

$$\phi_j(X) = \exp\left(-\frac{\|x - \mu_j\|^2}{2\sigma_j^2}\right) \quad \text{رابطه (۲)}$$

^۱ Temporal Convolutional Network

^۲ Fuzzy c-means clustering

که x و μ به ترتیب ورودی و مرکز واحد RBF هستند. σ_j گسترش تابع پایه گوسی است (Foody, 2004). وزن‌ها با استفاده از الگوریتم حداقل میانگین مربعات LMS پس از تعیین مراکز واحدهای RBF بهینه می‌شوند. شکل (۱) نمایی از ساختار شبکه RBF مورد استفاده در این پژوهش را نشان می‌دهد.



شکل ۱. ساختار شبکه RBF
منبع: (نگارنگان، ۱۴۰۳)

شبکه عصبی پرسپترون چندلایه (MLP)

یکی از رایج‌ترین تکنیک‌های شبکه عصبی است (اسفندیاری درآباد، ۱۳۸۹: ۴۵) که از سه لایه ایجاد شده است: لایه ورودی که در آن داده‌ها به شبکه معرفی می‌شوند. لایه پنهان که در آن داده‌ها پردازش می‌شوند (با یک یا چندلایه) و لایه خروجی که در آن نتایج برای ورودی‌های داده شده تولید می‌شود (Ahmadaali et al, 2009; Raudkivi et al, 2013). با استفاده از رابطه (۳) بیان می‌شود.

$$X_o = f(\sum_n X_n W_{no}) \quad \text{رابطه (۳)}$$

در این رابطه $f()$ تابع فعال‌سازی، X_n فعال‌سازی لایه پنهان، W_{no} ارتباط متقابل بین h امین گره لایه پنهان است (Yilmaz and Kaynar, 2011: 5959).

سیستم استنباط عصبی-فازی تطبیقی (ANFIS)

سیستم‌های فازی-عصبی از ترکیب منطق فازی با شبکه‌های عصبی مصنوعی به وجود آمده‌اند. یک شبکه تطبیقی، یک ساختار پیشرو چندلایه است که رفتار کلی خروجی آن به وسیله مقدار یک مجموعه از پارامترهای قابل بازسازی مشخص می‌گردد. به بیان دیگر ساختمان شبکه تطبیقی دربرگیرنده مجموعه‌ای از گره‌های به هم پیوسته است که بی‌واسطه به هم مرتبط شده‌اند و در آن هر گره یک واحد واکاوی به حساب می‌آید. ANFIS یکی از رایج‌ترین سیستم‌های عصبی فازی است که یک سیستم فازی سوگنو «Sugeno» را در یک ساختار عصبی اجرا می‌کند (Jang, 1993: 667).

شبکه عصبی رگرسیون بردار پشتیبان (SVR)

ماشین بردار پشتیبان (SVM) یک نوع الگوریتم یادگیری ماشین نظارت شده است که برای طبقه‌بندی، سنجش و برآورد تابع برازش داده‌ها در مسائل رگرسیون نیز به کار می‌رود به گونه‌ای که در آن حداقل خطا در طبقه‌بندی داده‌ها یا تابع برازش اتفاق می‌افتد. این روش بر اساس تئوری آموزش آماری بوده و از اصل کمینه‌سازی خطای ساختاری بهره می‌برد و سبب یک جواب مطلوب سراسری می‌شود (Vapnik, 2013). هدف مدل SVR که مدل رگرسیونی SVM می‌باشد این

است که تابع $F(x)$ را برای الگوهای آموزشی X به گونه‌ای شناسایی کند که بیشترین حاشیه را از مقادیر آموزشی y داشته باشد (Smola et al, 2004: 200; Vapnik, 2013).

روش تحقیق

در این پژوهش از آمار و اطلاعات هواشناسی ایستگاه‌های همدید منتخب واقع در غرب و جنوب غرب ایران با جامعه آماری بلندمدت (۱۹۸۷-۲۰۲۳) استفاده گردید. داده‌ها پس از دریافت از سازمان هواشناسی مورد پردازش قرار گرفت. به منظور خوشه‌بندی محدوده مورد بررسی از نظر فراوانی وقوع طوفان‌های گرد و غباری، از داده‌های ساعتی گرد و غبار (قدرت دید افقی و کدهای هوای حاضر) استفاده شده است. با توجه به اینکه داده‌های گرد و غبار از سایر پدیده‌های هواشناسی متمایز نشده‌اند؛ بنابراین از بین صفر تا ۹۹ کد بیان‌کننده هوای حاضر، کدهای پدیده گرد و غبار (۶، ۷، ۸، ۹، ۳۰، ۳۱، ۳۲، ۳۳ و ۳۵) و داده‌های دید افقی کمتر از ۱ کیلومتر پالایه شد (Goudie and Middleton, 2006; Alizadeh-Choobari et al, 2016: 2051; Fattahi Masrou et al, 2022: 232). سپس با استفاده از روش (FCM) خوشه‌بندی گردید. به دلیل اینکه ورودی این مدل حداقل باید دو پارامتر باشد؛ بنابراین پارامتر داده‌های روزهای توأم با طوفان‌های گرد و غباری با قدرت دید کمتر از ۱ کیلومتر برای کل ایستگاه‌های مورد مطالعه به دو دسته داده‌های فراوانی طوفان‌های با قدرت دید کمتر از ۵۰۰ متر و کمتر از ۱۰۰۰ متر متمایز شد.

به منظور پیش‌بینی دقیق طوفان‌های گرد و غبار برای آینده با استفاده از مدل‌های کاربردی RBF، MLP، ANFIS و SVR داده‌های میانگین سرعت و جهت باد، میانگین دما، میانگین رطوبت نسبی به درصد و میانگین بارش ۲۴ ساعته به عنوان ورودی در مدل‌سازی‌ها و داده خروجی و هدف، روزهای توأم با گرد و غبار در نظر گرفته شد. ۸۰ درصد داده‌ها به عنوان آموزش و ۲۰ درصد باقیمانده برای آزمون به شبکه معرفی گردید. در این پژوهش، از نرم‌افزار پایتون برای فرایند آموزش مدل‌ها و ساخت شبکه استفاده شد. به منظور مقایسه و ارزیابی روش‌های مختلف پیش‌بینی، از معیارهایی مانند میانگین مجذور خطا (MSE)، مربع مجذور میانگین خطا (RMSE) و ضریب همبستگی R^2 استفاده شد. در نهایت مدل مناسب و بهینه بر اساس این معیارها استخراج گردید. این معیارها به ترتیب با رابطه‌های (۴)، (۵) و (۶) بیان می‌شوند.

$$MSE = \frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2 \quad \text{رابطه (۴)}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (P_i - O_i)^2}{n}} \quad \text{رابطه (۵)}$$

$$R = \frac{\sum_{i=1}^N (P_i - \bar{O})^2 - \sum_{i=1}^N (P_i - O_i)^2}{\sum_{i=1}^N (P_i - \bar{O})^2} \quad \text{رابطه (۶)}$$

در این رابطه‌ها، P_i مقدار پیش‌بینی شده و O_i مقدار مشاهده شده، O میانگین مقادیر مشاهده شده و N تعداد مشاهدات است (Willmott, 1982: 1310; Taghizadeh-mehrjardi et al, 2016: 708; Xu et al, 2016: 4366; Schober et al, 2018: 1664; Liddicoat et al, 2018: 114; Adigüzel et al, 2019: 691). پیش‌بینی تغییرات روزهای توأم با گرد و غبار برای سال‌های آتی (۲۰۲۴-۲۰۴۰) شد و با بهره‌گیری از نرم‌افزار ArcGIS


^۱ Mean Squared Error (MSE)

^۲ Correlation Coefficient

داده‌های خروجی پهنه‌بندی شد تا مناطقی که در آینده احتمال دارد بیشتر با گرد و غبار درگیر باشند اولویت‌سنجی و مشخص شوند.

محدوده مورد مطالعه

در این پژوهش، ایستگاه‌های واقع در غرب و جنوب غرب ایران که شامل ۱۷ ایستگاه است مورد بررسی قرار گرفته است. نام و موقعیت پهنه مورد مطالعه در شکل ۲ آورده شده است.




شکل ۲. جایگاه جغرافیایی و براکنش ایستگاه‌های مورد مطالعه
منبع: (نگارندگان، ۱۴۰۳)

بحث و یافته‌ها

نتیجه تحلیل‌های صورت گرفته بر مبنای روش FCM نشان داد که محدوده مورد بررسی در شرایطی که دید افقی کمتر از هزار متر هست به پنج خوشه (شکل ۳) طبقه‌بندی می‌گردد و بر اساس آن نواحی طوفان‌های گرد و غباری بر روی ایستگاه‌های منتخب نشان داده شد. خوشه یک شامل ایستگاه‌های آبادان و اهواز است. این خوشه در پهنه وضعیت بحرانی و به‌عنوان هسته‌های اصلی فراوانی طوفان‌های گرد و غباری قرار می‌گیرد و نسبت به پهنه‌های دیگر به نظارت زیست‌محیطی، مدیریت و برنامه‌ریزی بیشتری نیاز دارد. علت فراوانی طوفان‌های گرد و غبار در این ایستگاه‌ها جایگاه جغرافیایی آن‌ها، واقع شدن در گذرهای اصلی ورود سامانه‌های جوی، نزدیکی به منابع گرد و غباری، ویژگی‌های فیزیکی و طبیعی آن‌ها می‌باشد. خوشه دوم نیز شامل ایستگاه‌های بستان، بندر ماهشهر، مسجدسلیمان و سرپل ذهاب می‌باشد و این ایستگاه‌ها در حاشیه غرب و جنوب غرب ایران قرار گرفته‌اند. خوشه سوم شامل ایستگاه‌های دزفول، کرمانشاه، ایلام و دهلران می‌باشد. طوفان‌های گرد و غباری در این ایستگاه‌ها از کشورهای همسایه غربی شامل صحرای سوریه، عربستان، آفریقا و عراق توسط سامانه‌های همدیدی وارد می‌شوند. خوشه چهارم شامل ایستگاه‌های اسلام‌آباد غرب، بیجار، سنج، کنگاور و رامهرمز می‌باشد و ایستگاه الیگودرز در خوشه پنج قرار دارد که جزو طبقه کم‌باد منطقه به حساب می‌آید.

شاخص‌های آماری برای آزمایش مدل‌های RBF، MLP، SVR و ANFIS جهت پیش‌بینی گرد و غبار به شرح جدول ۱ می‌باشد. در این جدول با توجه به معیارهای ارزیابی میانگین مجذور خطا، ریشه میانگین مربعات خطا و ضریب همبستگی

درمجموع می‌توان دریافت که بهترین عملکرد برای تخمین گرد و غبار، مربوط به مدل شبکه عصبی RBF بوده و به این معنا که این مدل خطای کمتر و همبستگی بیشتری دارد و تنها مدل MLP در ایستگاه کنگاور عملکرد بهتری از مدل RBF دارد؛ بنابراین طبق مدل‌سازی انجام گرفته و نتایج به دست آمده از مقایسه مدل‌ها، دقت و اطمینان مدل شبکه عصبی RBF برای پیش‌بینی تأیید می‌شود که در ادامه برای پیش‌بینی نیز از این مدل استفاده گردید. لازم به ذکر است که مقادیر درج شده برای داده‌های آزمون می‌باشد.




شکل ۳. خوشه‌بندی فراوانی طوفان‌های گرد و غباری با استفاده از الگوریتم FCM
منبع: (نگارندگان، ۱۴۰۳)

جدول ۱. معیارهای ارزیابی مدل‌ها در پیش‌بینی متغیر گرد و غبار ایستگاه‌های منتخب

ایستگاه	مدل RBF			مدل MLP			مدل ANFIS			مدل SVR		
	R	RMSE	MSE	R	RMSE	MSE	R	RMSE	MSE	R	RMSE	MSE
آبادان	۰/۶۲	۳/۴۷	۱۲/۰۸	۰/۲۴	۴/۲	۱۷/۷	۰/۰۱	۱۵/۳۱	۳۴	۰/۷۶	۵/۰۵	۲۵/۵
اهواز	۰/۷۴	۳/۴۵	۱۱/۹۵	۰/۷۹	۳/۹۵	۱۵/۶۵	۰/۰۱	۱۱/۴	۱۸	۰/۱۱	۶/۱۲	۳۷/۵۴
الیگودرز	۰/۸۵	۵/۹۰	۲۴/۵۵	۰/۸۰	۴/۹۵	۲۴/۵۷	۰/۱۸	۶/۳۸	۴۰/۷۵	۰/۴۷	۶/۵۲	۳۵/۳۲
اسلام‌آباد غرب	۰/۹۵	۰/۸۷	۱/۴۱	۰/۸۸	۲/۵۹	۶/۷۲	۰/۲۶	۴/۹۷	۲۴/۷۷	۰/۲۴	۲/۸۸	۸/۳۴
ایلام	۰/۸۰	۰/۳۹	۱۷/۷۵	۰/۴۴	۱۷/۷۹	۱۷/۷۹	۰/۶۵	۸/۵۶	۷۳/۳۷	۰/۴۷	۳/۶۹	۱۳/۶۳
بندر ماهشهر	۰/۸۳	۲/۹۸	۸/۹۲	۰/۳۷	۵/۲۴	۲۷/۵۰	۰/۰۵	۱۲/۶	۴۰	۰/۰۸	۶/۸۵	۴۶/۹۴
بیجار	۰/۸۵	۴/۸۲	۲۳/۲۶	۰/۴۹	۴/۹۲	۲۴/۲۱	۰/۰۷	۷/۳۳	۵۳/۸۰	۰/۵۸	۴/۹۲	۲۴/۷۰
بستان	۰/۶۱	۳/۶۹	۵۹/۱۷	۰/۱۳	۹/۴۹	۹۰/۰۶	۰/۰۸	۱۹/۸۱	۳۹	۰/۴۱	۵/۸۲	۶۰/۹۸
دهلران	۰/۸۶	۴/۱۲	۱۷/۰۵	۰/۴۴	۵/۳۴	۲۸/۵۸	۰/۰۸	۱۰/۱	۵۰	۰/۳۲	۵/۱۸	۲۶/۸۴
دزفول	۰/۶۸	۲/۳۸	۵/۷۰	۰/۶۷	۲/۷۷	۷/۶۹	۰/۰۹	۱۲/۷۲	۱۶	۰/۱۶	۵/۹۴	۳۵/۳۵
خرم‌آباد	۰/۹۵	۰/۶۱	۰/۳۷	۰/۹۰	۱/۰۶	۱/۱۴	۰/۳۹	۱/۸۷	۳/۵	۰/۳۲	۲/۱۱	۴/۴۶
کنگاور	۰/۸۱	۰/۹۹	۰/۹۹	۰/۸۰	۰/۶۴	۰/۶۴	۰/۱۴	۱/۶۹	۲/۸۷	۰/۴۲	۱/۱۴	۱/۳۲
کرمانشاه	۰/۹۹	۶/۹۵	۴۸/۳۵	۰/۷۶	۷/۲۱	۵۲/۱۲	۰/۰۱	۱۲/۴۷	۶۷	۰/۲۵	۳/۷۹	۱۴/۴۱
مسجدسلیمان	۰/۹۱	۴/۵۶	۲۰/۸۱	۰/۸۱	۵/۴۲	۲۹/۳۹	۰/۰۴	۱۷/۷۷	۵۵	۰/۳۲	۶/۸۰	۴۶/۲۸
رامهرمز	۰/۹۷	۰/۴۲	۰/۱۸	۰/۷۳	۱/۲۸	۱/۶۵	۰/۳۴	۲/۸۷	۸/۲۵	۰/۲۸	۲/۸۷	۸/۲۵
سندج	۰/۸۶	۲/۲۴	۵/۰۵	۰/۶۷	۶/۵۶	۱۰/۲۶	۰/۲۸	۶/۵۲	۲۰/۵۰	۰/۱۵	۲/۲۳	۴/۹۷
سرپل ذهاب	۰/۷۱	۶/۳۲	۴۰/۰۱	۰/۶۷	۶/۵۶	۴۳/۱۵	۰/۰۷	۱۶/۱۲	۸۱	۰/۵۵	۸/۵۶	۷۳/۳۰

منبع: (یافته‌های پژوهش)


(شکل ۴) مقادیر متغیر هدف اندازه‌گیری شده بر روی محور X و مقادیر متغیر پیش‌بینی شده توسط مدل مذکور بر روی محور Y برای یک نمونه از ایستگاه‌ها (آبادان) را نشان می‌دهد. درواقع به‌نوعی میزان نزدیکی خروجی‌های شبکه را به مقادیر واقعی نشان می‌دهد که این شکل بیانگر نزدیکی مقادیر به محور قطری نمودار است.



شکل ۴. نمودار دیاگرام برای آزمایش نتایج RBF برای ایستگاه آبادان
منبع: (نگارندگان، ۱۴۰۳)


شکل (۵ و ۶)، نتایج شبیه‌سازی مقادیر مشاهداتی و پیش‌بینی شده طوفان گرد و غبار ایستگاه‌ها برای داده‌های آزمایش توسط شبکه عصبی RBF را نشان می‌دهد. همان‌طور که ملاحظه می‌شود به دلیل همبستگی قابل قبول داده‌های پیش‌بینی شده به‌وسیله شبکه عصبی و داده‌های واقعی در ایستگاه‌های منتخب، منحنی‌های مقادیر مشاهداتی و پیش‌بینی شده به همدیگر نزدیک است و در برخی از ایستگاه‌ها تفاوت‌هایی دیده می‌شود که آن هم تنها برای یک سال قابل مشاهده است و در طول سال‌های دیگر منحنی‌های مرحله آزمون مدل، بسیار نزدیک به منحنی‌های آموزش هستند؛ بنابراین نتایج پژوهش حاضر نشان می‌دهد شبکه عصبی اجرا شده با استفاده از پنج متغیر ورودی توانست روزهای توأم با طوفان گرد و غبار را با دقت قابل قبول مدل‌سازی و پیش‌بینی کند. مطابق این شکل، بهبود عملکرد در ایستگاه‌هایی که از فراوانی گرد و غبار متوسطی برخوردار هستند قابل مشاهده است.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی



شکل ۵. نتایج شبکه عصبی RBF در مرحله آزمون مدل


منبع: نگارندگان، ۱۴۰۳




شکل ۶. نتایج شبکه عصبی RBF در مرحله آزمون مدل
منبع: (نگارندگان، ۱۴۰۳)

پهنه‌بندی فراوانی گرد و غبار

بر اساس مقادیر به دست آمده از داده‌های مشاهداتی، مجموع فراوانی سالانه گرد و غبار در ۱۷ ایستگاه مورد مطالعه پهنه‌بندی شد. بر اساس این پهنه‌بندی، سه ایستگاه آبادان، اهواز و بستان بیشترین فراوانی گرد و غبار را به ترتیب برابر با ۴۷۸، ۳۹۰ و ۳۶۸ روز به خود اختصاص داده‌اند. کمترین مقدار فراوانی گرد و غبار را هم ایستگاه‌های واقع در استان لرستان، کردستان و قسمت‌های وسیعی از استان کرمانشاه با فراوانی بین ۲۸ روز در الیگودرز تا ۱۰۷ روز در کرمانشاه شامل می‌شوند (شکل ۷).




شکل ۷. فراوانی گرد و غبار در محدوده مورد مطالعه طی سال‌های مشاهداتی (۱۹۸۷-۲۰۲۳) بر اساس مدل RBF
منبع: (نگارندگان، ۱۴۰۳)




شکل ۸. همانند شکل ۷ ولی برای سال‌های آتی (۲۰۲۴-۲۰۴۰)
منبع: (نگارندگان، ۱۴۰۳)


پایش و پیش‌بینی وضعیت گرد و غبار در سال‌های آتی بیشترین مقدار فراوانی گرد و غبار را برای ایستگاه‌های آبادان، اهواز و مسجدسلیمان نشان می‌دهد که به ترتیب برابر با ۲۰۴، ۱۸۵ و ۱۴۴ روز است. می‌توان گفت که این ایستگاه‌ها در سال‌های آتی در وضعیت بحرانی و در اولویت بیشتر در معرض گرد و غبار قرار خواهند گرفت. بعد از این ایستگاه‌ها، ایستگاه‌های بندرماهشهر، بستان، سرپل ذهاب و دزفول در رتبه بعدی از نظر بیشترین میزان فراوانی گرد و غبار قرار دارند که میزان گرد و غبار در آن‌ها به ترتیب برابر با ۱۱۶، ۱۱۴، ۸۶ و ۸۱ روز است. ایستگاه کرمانشاه و ایستگاه‌های واقع در استان لرستان و کردستان کمترین مقدار گرد و غبار را برای سال‌های آتی نشان می‌دهند و فراوانی گرد و غبار در آن‌ها بین ۴۶ روز در کرمانشاه تا ۳ روز در الیگودرز می‌باشد (شکل ۸).

در شکل (۹) مقادیر گرد و غبار پیش‌بینی شده برای ۱۷ سال آینده، با رنگ بنفش و مقادیر مشاهده شده با رنگ سبز برای ایستگاه‌های آبادان و اهواز قابل مشاهده است و سری زمانی ایستگاه‌های دیگر در شکل (۱۰) گزارش شده‌اند. با توجه به خطا سنجی صورت گرفته و داده‌های حاصل از آن می‌توان با اطمینان شاخص گرد و غبار را با این مدل برای ایستگاه‌های مورد مطالعه پیش‌بینی نمود و توان مدل شبکه عصبی RBF را در مدل‌سازی و پیش‌بینی روند تغییرات سری زمانی مورد پایش و ارزیابی قرار داد. ارزیابی و پایش شدت گرد و غبار رخ داده در سال‌های مشاهداتی نشان می‌دهد که در سال‌های ۲۰۲۲ و ۲۰۰۹ فراوانی گرد و غبار رخ داده در همه ایستگاه‌ها رو به افزایش بوده و بیشترین مقدار را داشته است. در مقابل در طول سال‌های ۲۰۰۱ تا ۲۰۰۴ از شدت گرد و غبار رخ داده کاسته شده است. در سال‌های پیش‌بینی شده نیز بیشترین فراوانی وقوع گرد و غبار در محدوده مورد بررسی برای سال‌های ۲۰۲۶، ۲۰۳۴ و ۲۰۳۵ انتظار می‌رود. همانند دوره مشاهداتی ایستگاه‌های آبادان و اهواز بیشترین و ایستگاه الیگودرز کمترین میزان رخداد گرد و غبار را برای سال‌های آتی به خود اختصاص داده‌اند. در حالت کلی وضعیت بحرانی طی سال‌های آتی برای هیچ‌کدام از ایستگاه‌ها مشاهده نشده و روند گرد و غبار به صورت آهسته و ملایم است.



شکل ۹. نمودار فراوانی گرد و غبار سالانه در سال‌های پیش‌بینی شده برای ایستگاه‌های آبادان و اهواز
منبع: (نگارندگان، ۱۴۰۳)





شکل ۱۰. همانند شکل ۹ ولی برای دیگر ایستگاه‌ها
منبع: (نگارنگان، ۱۴۰۳)

نتیجه گیری

با توجه به مطالعات انجام گرفته در داخل و خارج از کشور، در زمینه پیش‌بینی مناطق مستعد گرد و غبار طی سال‌های آینده که بتواند دیدی جامع‌تر از آینده گرد و غبار را ایجاد کند، پژوهش‌های اندکی انجام شده است. چراکه توجه به خطرات طوفان‌های گرد و غبار، شناسایی مناطق تحت تأثیر آن و پیش‌بینی واقع‌بینانه آن موجب ارتقای کیفیت زندگی و افزایش سلامت انسان می‌شود و می‌تواند در برنامه‌ریزی‌های محیطی و حفاظت بهینه و مطلوب از منابع طبیعی مؤثر باشد. اکثر مطالعات نشان دادند که روش‌های شبکه عصبی مصنوعی نسبت به روش‌های خطی مانند رگرسیون از برتری و دقت بالاتری برخوردار هستند و می‌توانند روابط پنهان بین ورودی‌ها و خروجی‌ها را استخراج کنند. در پژوهشی (Wong et al, 2015: 89) نتیجه گرفتند مدل شبکه عصبی ANN در پیش‌بینی طوفان‌های گرد و غبار آسیا و بخش‌هایی از چین قابلیت لازم را دارد. (Huang et al, 2016: 2016) در شمال غرب چین هم به نتایج مشابهی دست یافتند؛ بنابراین در این پژوهش سعی کردیم برای بررسی دقت پیش‌بینی گرد و غبار، چند مدل را در ایستگاه‌های منتخب با هم مقایسه کنیم. پارامترهای ورودی دما، رطوبت، بارش، سرعت و جهت باد بود و فراوانی گرد و غبار به عنوان پارامتر خروجی مدل‌ها در نظر گرفته شد. ناهمساز با پژوهش (کیخسروی و همکاران، ۱۳۹۸: ۴۳) برای کارخانه سیمان سبزوار، پژوهش (پور غلام آمیجی و همکاران، ۱۴۰۰: ۵۶) برای استان خوزستان و پژوهش (ارجمندی و همکاران، ۱۴۰۳: ۱) و همساز با پژوهش (Mahmoudi et al, 2020) برای جنوب غرب ایران، در بین مدل‌ها بر مبنای معیارهای ارزیابی در مرحله آزمایش مدل، توان شبکه عصبی RBF در پیش‌بینی دقیق به اثبات رسید و بعد از آن مدل MLP قابلیت بالایی را در پیش‌بینی نشان داد؛ بنابراین از روش RBF برای پیش‌بینی گرد و غبار در آینده استفاده شد. لازم به ذکر است که انتخاب مناسب چگونگی ثبت خروجی مدل تا اندازه زیادی در بهبود عملکرد مدل‌ها نقش دارد. بدون شک جهت اعتبارسنجی نتایج به دست آمده از این پژوهش، لازم است که پژوهش‌های بیشتری برای به کارگیری مدل‌های ترکیبی در مدل‌سازی و پیش‌بینی زمانی- مکانی طوفان‌های گرد و غبار در مناطق درگیر و تحت تأثیر این مخاطره انجام شود.

حامی مالی

این اثر حامی مالی نداشته است.

سهم نویسندگان

پژوهشگران در انجام این پژوهش سهم برابر دارند.

تضاد منافع

نویسندگان اعلام می‌دارند، هیچ تضاد منافی در رابطه با نویسندگی و یا انتشار این مقاله ندارند.

تقدیر و تشکر

بنابر اظهار نویسنده مسئول، این مقاله مستخرج از رساله دکتری است و از مسئولین انتشار تشکر می‌کنند.

منابع

- (۱) ارجمندی، حمیدرضا؛ خیرعلی پور؛ کامران و عمارلویی، علی (۱۴۰۳). پیش‌بینی غلظت گرد و غبار در مقیاس آزمایشگاهی با استفاده از فناوری‌های پردازش تصویر و هوش مصنوعی، پژوهش‌های مکانیک ماشین‌های کشاورزی، (۱۳(۲)، ۹-۱.
<https://doi.org/10.22034/jrmam.2024.14177.642>
- بینی میانگین دمای ماهانه ایستگاه سینوپتیک اسفندیاری، فریبا؛ حسینی، اسعد؛ آزادی، محمد و حجازی زاده، زهرا (۱۳۸۹). پیش (شبکه عصبی مصنوعی پرسپترون چند لایه. جغرافیا (فصلنامه علمی انجمن جغرافیایی ایران)، MLP سنج با استفاده از مدل (۶۵-۴۵، (۲۷)۸
- (۲) امیرعزیدی، امیررضا؛ جعفری، محمد؛ زارع، سلمان و خسروی، حسن (۱۳۹۹). اولویت بندی و شناسایی کانون های گرد و غبار در استان فارس، جغرافیا (فصلنامه علمی انجمن جغرافیایی ایران)، ۱۸(۶۴)، ۶۴-۷۸.
- (۳) پورغلام آمیجی، مسعود؛ انصاری قوجقار؛ محمد و احمدالی، خالد (۱۴۰۰). پیش‌بینی طوفان‌های گرد و غبار در استان خوزستان با استفاده از شبکه‌های عصبی مصنوعی، نیوار، (۱۱۴-۱۱۵)، ۴۵-۷۵.
<https://doi.org/10.30467/nivar.2021.303747.1200>
- (۴) صلاحی، برومند؛ مرادی، مسعود و عالی جهان، مهدی (۱۳۹۴). واکاوی شرایط همدید- سنجش از دور رخداد توفان گرد و خاک در شمال غرب ایران (مهر ۱۳۹۲)، جغرافیا (فصلنامه علمی انجمن جغرافیایی ایران)، ۱۳(۴۴)، ۷۳-۹۳.
- (۵) عقیقی، محمد ابراهیم (۱۳۹۶). پایش ریزگردها با استفاده از تصاویر چند طیفی ماهواره مادیس در جنوب غربی ایران، جغرافیا (فصلنامه علمی انجمن جغرافیایی ایران)، ۱۵(۵۵)، ۱۸۴-۱۹۴.
<https://doi.org/10.22034/iga.2025.2045564.1347>
- (۶) کیخسروی، سید سعید؛ نژادکورکی، فرهاد و امین طوسی، محمود (۱۳۹۸). ارزیابی دقت شبکه‌های عصبی مصنوعی (MLP و RBF) در پیش‌بینی گرد و غبار کارخانه سیمان سبزوار، مجله پژوهش در بهداشت محیط، (۱)۵، ۵۲-۴۳.
<https://doi.org/10.22038/jreh.2019.38083.1277>
- (۷) مدبرپور، علی؛ گندمکار، امیر و خداقلی، مرتضی (۱۳۹۸). بررسی زمانی- مکانی مخاطره گرد و غبار (مطالعه موردی: ایستگاه های یاسوج و دوگنبدان)، جغرافیا (فصلنامه علمی انجمن جغرافیایی ایران)، ۱۷(۶۱)، ۱۰۸-۹۱.
- (۸) موغلی، مرضیه و نخعی نژاد فرد، احمد رضا (۱۳۹۷). تحلیل آمار فضایی ریزگردهای استان خوزستان، جغرافیا (فصلنامه علمی انجمن جغرافیایی ایران)، ۱۶(۵۶)، ۱۷۸-۱۹۱.
- (۹) یزدان پناه درو، کیومرث؛ عبدی، عطاءالله؛ کامران دستجردی، حسن و جوکار، فرزاد (۱۳۹۷). تحلیل ژئوپلیتیک امنیت زیست محیطی پدیده ریزگردها مطالعه موردی: جنوب غرب آسیا، جغرافیا (فصلنامه علمی انجمن جغرافیایی ایران)، ۱۶(۵۶)، ۵۱-۳۶.

- 10) Adıguzel, E., Ozer, E., Akgundogdu, A. & Yılmaz, A.E. (2019). Prediction of dust particle size effect on efficiency of photovoltaic modules with ANFIS: an experimental study in Aegean region, Turkey Solar Energy, 177, 690-702.
<https://doi.org/10.1016/j.solener.2018.12.012>.

- 11) Ahmadaali, K. A., Parsinejad, M. & Rahmani, B. (2009). Estimation of saturation percentage of soil using multiple regression, ANN, and ANFIS techniques, *Computer and Information Science*, 2, 127. <http://dx.doi.org/10.5539/cis.v2n3p127>.
- 12) Al-Dousari, A., Omar, A., Al-Hemoud, A., Aba, A., Alrashedi, M., Alrawi, M., Rashki, A., Petrov, P., Ahmed, M. & Al-Dousari, N. (2022). A Success Story in Controlling Sand and Dust Storms Hotspots in the Middle East, *Atmosphere*, 13(1335). <https://doi.org/10.3390/atmos13081335>.
- 13) Alizadeh-Choobari, O., Ghafarian, p. & Owlad, E. (2016). Temporal variations in the frequency and concentration of dust events over Iran based on surface observations, *International Journal of Climatology*, 36, 2050–2062. <http://dx.doi.org/10.1002/joc.4479>.
- 14) Alshammari, R.K., Alrwais, O. & Aksoy, M. S. (2024). Machine Learning Forecast of Dust Storm Frequency in Saudi Arabia Using Multiple Features, *Atmosphere*, 15(5), 520. <https://doi.org/10.3390/atmos15050520>.
- 15) An, L., Che, H., Xue, M., Zhang, T., Wang, H., Wang, Y. & Zhang, X. (2018). Temporal and spatial variations in sand and dust storm events in East Asia from 2007 to 2016, Relationships with surface conditions and climate change. *Science of the Total Environment*, 633, 452-462. <https://doi.org/10.1016/j.scitotenv.2018.03.068>.
- 16) Ardon-Dryer, K., Mock, C., Reyes, J. & Lahav, G. (2020). The effect of dust storm particles on single human lung cancer cells, *Environmental Research*, 181, 108891. <https://doi.org/10.1016/j.envres.2019.108891>.
- 17) Aryal, Y. (2022). Application of Artificial Intelligence Models for Aeolian Dust Prediction at Different Temporal Scales: A Case with Limited Climatic Data, *AI*, 3, 707–718. <https://doi.org/10.3390/ai3030041>.
- 18) Asyali, M.H., Colak, D., Demirkaya, O. & Inan, M.S. (2006). Gene expression profile classification: a review. *Curr. Bioinform*, 1, 55–73. <http://dx.doi.org/10.2174/157489306775330615>.
- 19) 10. Chen, S., Cowan, C. F. N. & Grant, P. M. (1991). Orthogonal Least Squares Learning Algorithm for Radial Basis Function Networks, *IEEE Transactions on Neural Networks*, 2(2), 302-309. <https://doi.org/10.1109/72.80341>.
- 20) Csavina, J., Field, J., Felix, O., Corral-Avitia, A. Y., Saez, A. E. & Betterton, E. (2014). Effect of wind speed and relative humidity on atmospheric dust concentrations in semi-arid climates, *Science of the Total Environment*, 487(1), 82-90. <https://doi.org/10.1016/j.scitotenv.2014.03.138>.
- 21) Dahiya, S., Singh, B., Gaur, S., Garg, V. K. & Kushwaha, H. S. (2007). Analysis of groundwater quality using fuzzy synthetic evaluation, *Journal of Hazardous Materials*, 147(3), 938-946. <https://doi.org/10.1016/j.jhazmat.2007.01.119>.
- 22) Darvishi Boloorani, A., Soleimani, M., Neysani Samany, N., Bakhtiari, M., Qareqani, M., Papi, R. & Mirzaei, S. (2023). Assessment of Rural Vulnerability to Sand and Dust Storms in Iran, *Atmosphere*, 14(2), 281. <https://doi.org/10.3390/atmos14020281>.
- 23) Ebrahimi-Khusfi, Z., Taghizadeh-Mehrjardi, R. I., Kazemi, M. & Nafarzadegan, A.R. (2021b). Predicting the ground-level pollutants concentrations and identifying the influencing factors using machine learning, wavelet transformation, and remote sensing techniques, *Atmospheric Pollution Research*, 12(5), 101064. <https://doi.org/10.1016/j.apr.2021.101064>.
- 24) Ebrahimi-Khusfi, Z., Taghizadeh-Mehrjardi, R. & Nafarzadegan, A. R. (2021a), Accuracy, uncertainty, and interpretability assessments of ANFIS models to predict dust concentration in semi-arid regions, *Environmental Science and Pollution Research*, 28, 6796–6810. <https://doi.org/10.1007/s11356-020-10957-z>.
- 25) Fattahi Masrou, P. & Rezazadeh, M. (2022). Spatio-Temporal Distribution of Various Types of Dust Events in the Middle East during the Period 1996-2015, *Journal of the Earth and Space Physics*, 47(4), 231-248. <https://doi.org/10.22059/jesphys.2021.321010.1007306>.
- 26) Foody, G. M. (2004). Supervised image classification by MLP and RBF neural networks with and without an exhaustively defined set of classes, *International Journal of Remote Sensing*, 25(15), 3091–3104. <http://dx.doi.org/10.1080/01431160310001648019>.
- 27) Garcia Nieto, P.J., Sanchez Lasheras, F., Garcia-Gonzalo, E. & de Cos Juez, F.J. (2018). PM₁₀ concentration forecasting in the metropolitan area of Oviedo (Northern Spain) using models based on SVM, MLP, VARMA and ARIMA: A case study, *Science of The Total Environment*, 621, 753-761. <https://doi.org/10.1016/j.scitotenv.2017.11.291>.
- 28) Gholami, G., Mohamadifar, A. & Collins, A. L. (2020a). Spatial mapping of the provenance of storm dust: Application of data mining and ensemble modelling, *Atmospheric Research*, 233 (104716). <https://doi.org/10.1016/j.atmosres.2019.104716>.

- 29) Gholami, H., Mohamadifar, A.A., Sorooshian, A. & Jansen, J. D. (2020b). Machine-learning algorithms for predicting land susceptibility to dust emissions: The case of the Jazmurian Basin, Iran, *Atmospheric Pollution Research*, 11(8), 1303-1315.
<https://doi.org/10.1016/j.apr.2020.05.009>.
- 30) Goudarzi, G. R., Hopke, P. K. & Yazdani, M. (2021). Forecasting PM2.5 concentration using artificial neural network and its health effects in Ahvaz, Iran, *Chemosphere*, 283, 131285.
<https://doi.org/10.1016/j.chemosphere.2021.131285>.
- 31) Goudie, A. S. (2019). Dust storms and human health. In extreme weather events and human health: international case studies, Cham: Springer International Publishing, 13-24.
<https://doi.org/10.1007/978-3-030-23773-8-2>.
- 32) Goudie, A.S. (2020). Dust storms and human health. *Extreme Weather Events and Human Health*, Springer, Cham, 13–24. http://dx.doi.org/10.1007/978-3-030-23773-8_2.
- 33) Goudie, A. S. & Middleton, N. (2006). *Desert dust in the global system*. New York: Springer Berlin Heidelberg.
- 34) Guan, Q., Sun, X., Yang, J., Pan, B., Zhao, S. & Wang, L. (2017). Dust Storms in Northern China, Long-Term Spatiotemporal Characteristics and Climate Controls, *Journal of Climate*, 30 (17), 6683-6700. <https://doi.org/10.1175/JCLI-D-16-0795.1>
- 35) Hamzeh, N. H., Kaskaoutis, D. G., Rashki, A. & Mohammadpour, K. (2021). Long-Term Variability of Dust Events in Southwestern Iran and Its Relationship with the Drought, *Atmosphere*, 12, 1350.
<https://doi.org/10.3390/atmos12101350>.
- 36) Hamzeh, N. H., Ranjbar Saadat Abadi, A., M. C. G, O., Habibi, M. & Schoner, W. (2022). Analyses of a lake dust source in the middle east through models performance, *Remote Sensing*, 14(9), 1-24.
<https://doi.org/10.3390/rs14092145>.
- 37) Huang, M., Peng, G., Zhang, J. & Zhang, S. (2006). Application of artificial neural networks to the prediction of dust storms, In *Northwest China Journal of Global and Planetary Change*, (52), 216-224. <http://dx.doi.org/10.1016/j.gloplacha.2006.02.006>.
- 38) Icer, S. (2013). Automatic segmentation of corpus collasum using Gaussian mixture modeling and Fuzzy C means methods, *Comput. Methods Programs Biomed*, 112, 38–46 .
<https://doi.org/10.1016/j.cmpb.2013.06.006>.
- 39) Jang, J. S. R. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685. <http://dx.doi.org/10.1109/21.256541>.
- 40) Ji Ren, Q. D. E., Li, N. & Zhang, W. (2022). Research on Sand-Dust Storm Forecasting Based on Deep Neural Network With Stacking Ensemble Learning, *Research Article*, 10(38), 111855-111863
<http://dx.doi.org/10.1109/ACCESS.2022.3216309>.
- 41) Jish Prakash, P., Stenchikov, G. L., Kalenderski, S., Osipov, S. & Bangalath, H. K. (2015). The impact of dust storms on the Arabian Peninsula and the Red Sea, *Atmos. Chem. Phys*, 15, 199–222.
<https://doi.org/10.5194/acp-15-199-2015>.
- 42) Kaboodvandpour, S., Amanollahi, J., Qhavami, S. & Mohammadi, B. (2015). Assessing the accuracy of multiple regressions, ANFIS, and ANN models in predicting dust storm occurrences in Sanandaj, Iran, *Natural Hazards*, 78, 879–893. DOI:10.1007/s11069-015-1748-0.
- 43) Labban, AH. & Butt, M. J. (2021). Analysis of sand and dust storm events over Saudi Arabia in relation with meteorological parameters and ENSO, *Arabian Journal of Geosciences*, 14(1), 1-12.
<https://doi.org/10.1007/s12517-020-06291-w>.
- 44) Li, J., Garshick, E., Al-Hemoud, A., Huang, S. & Koutrakis, P. (2020). Impacts of meteorology and vegetation on surface dust concentrations in Middle Eastern countries, *Science of the Total Environment*, 712, 136597.
<https://doi.org/10.1016/j.scitotenv.2020.136597>.
- 45) Li, J., Garshick, E., Huang, S. & Koutrakis, P. (2021). Impacts of El Niño-Southern Oscillation on surface dust levels across the world during, *Science of the Total Environment*, 769, 144566.
<https://doi.org/10.1016/j.scitotenv.2020.144566>.
- 46) Liddicoat, C., Bi, P., Waycott, M., Glover, J., Lowe, A. J. & Weinstein, P. (2018). Landscape biodiversity correlates with respiratory health in Australia, *Journal of Environ Manag*, 206, 113–122.
<https://doi.org/10.1016/j.jenvman.2017.10.007>.
- 47) 38. Mahmoudi, L., Amiri Doumari, S., Safarianzengir, V., Maleki, R., Kianinejad, S. & Kianian, M. K. (2020). Monitoring and Prediction of Dust and Investigating its Environmental Impacts in the Western Half of Iran and the Eastern Borders of Turkey and Iraq, Using Remote Sensing and GIS, *Journal of the Indian Society of Remote Sensing*, 49(5).
<https://doi.org/10.1007/s12524-020-01224-2>
- 49) Mahmoudi, L. & Ikegaya, N. (2023). Identifying the Distribution and Frequency of Dust Storms in Iran Based on Long-Term Observations from over 400 Weather Stations, *Sustainability*, 15(16), 12294.

- <https://doi.org/10.3390/su151612294>.
- 50) Maleki, H., Sorooshian, A., Goudarzi, G., Baboli, Z., Birgani, Y. T. & Rahmati, M. (2019). Air pollution prediction by using an artificial neural network model, *Clean Technologies and Environmental Policy*, 21(6), 1341-1352.
<https://doi.org/10.1007/s10098-019-01709-w>.
 - 51) Middleton, N. J. (2017). Desert dust hazards, a global review, *Aeolian Res*, 24, 53–63.
<https://doi.org/10.1016/j.aeolia.2016.12.001>.
 - 52) Moghanlo, S., Alavinejad, M., Oskoei, V., Najafi Saleh, H., Mohammadi, A. A., Mohammadi, H. & DerakhshanNejad, Z. (2021). Using artificial neural networks to model the impacts of climate change on dust phenomenon in the Zanjan region, north-west Iran, *Urban Climate*, 35, 100750.
<https://doi.org/10.1016/j.uclim.2020.100750>.
 - 53) Nabavi, S. O., Haimberger, L., Abbasi, R. & Samimi, C. (2018). Prediction of Aerosol Optical Depth in West Asia Using Deterministic Models and Machine Learning Algorithms, *Aeolian Research*, 35, 69–84.
<https://doi.org/10.1016/j.aeolia.2018.10.002>.
 - 54) Opp, C., Groll, M., Abbasi, H. & Foroushani, MA. (2021). Causes and effects of sand and dust storms: What has past research taught us? A survey, *Journal of Risk and Financial Management*, 14(7), 1-25. <https://doi.org/10.3390/jrfm14070326>.
 - 55) Rahmati, O., Panahi, M., Ghiasi, S.S., Deo, R.C., Tiefenbacher, J.P., Pradhan, B., Jahani, A., Goshtasb, H., Kornejady, A., Shahabi, H., Shirzadi, A., Khosravi, H., Moghaddam, D.D., Mohtashamian, M. & Bui, D.T. (2020a). Hybridized neural fuzzy ensembles for dust source modeling and prediction, *Atmospheric Environment*, 224, 117320. doi: <https://doi.org/10.1016/j.atmosenv.2020.117320>.
 - 56) Rahmati, O., Mohammadi, F., Ghiasi, S. S., Tiefenbacher, J., Davoudi Moghaddam, D., Coulon, F., Asadi Nalivan, O. & Bui, D. T. (2020b). Identifying sources of dust aerosol using a new framework based on remote sensing and modelling, *Science of The Total Environment*, 737, 139508.
<https://doi.org/10.1016/j.scitotenv.2020.139508>.
 - 57) Rashki, A., Middleton, N. J. & Goudie, A. S. (2021). Dust storms in Iran – Distribution, causes, frequencies and impacts, *Aeolian Research*, 48, 100655.
<https://doi.org/10.1016/j.aeolia.2020.100655>.
 - 58) Raudkivi, A. J. (2013). *Hydrology: An advanced introduction to hydrological processes and modelling*, Elsevier.
 - 59) Schepanski K. (2018). Transport of mineral dust and its impact on climate, *Geosciences*, 8(5), 1-19.
<https://doi.org/10.3390/geosciences8050151>.
 - 60) Schober, P., Boer, C. & Schwarte, L. A. (2018). Correlation coefficients: appropriate use and interpretation, *Anesth Analg*, 126, 1763–1768.
<https://doi.org/10.1213/ANE.0000000000002864>.
 - 61) Shi, L., Jiahua Zhang, J., Zhang, D., Igbawua, T. & Liu, Y. (2020). Developing a dust storm detection method combining Support Vector Machine and satellite data in typical dust regions of Asia, *Advances in Space Research*, 65(4), 1263-1278,
<https://doi.org/10.1016/j.asr.2019.11.027>.
 - 62) Smola, A. J. & Schölkopf, B. (2004). A tutorial on support vector regression, *Statistics and computing*, 14(3), 199-222.
<https://doi.org/10.1023/B%3ASTCO.0000035301.49549.88>.
 - 63) Taghizadeh-mehrjardi, R., Toomanian, N., Khavaninzadeh, A., Jafari, A. & Triantafilis, J. (2016). Predicting and mapping of soil particle-size fractions with adaptive neuro-fuzzy inference and ant colony optimization in central Iran, *Eur J Soil Sci*, 67, 707–725.
<https://doi.org/10.1111/ejss.12382>.
 - 64) 54. Tsai, C. W., Christina, W. & Chen, C. K. (2023). River-dust induced airborne particulate matter forecasting using a hybrid model of improved complete ensemble empirical mode decomposition with adaptive noise and radial basis function neural network, *Atmospheric Environment*, 312(1), 119991.
<https://doi.org/10.1016/j.atmosenv.2023.119991>.
 - 65) Vapnik, V. (2013). *The nature of statistical learning theory*, Springer science & business media.
 - 66) Venkatesan, P. & Anitha, S. (2006). Application of a radial basis function neural network for diagnosis of diabetes mellitus, *Current Science*, 91(9), 1195–1199.
<http://eprints.nirt.res.in/id/eprint/789>.
 - 67) Wang, W., Samat, A., Abuduwaili, J., De Maeyer, P., d. & Voorde, T. V. D. (2023). Machine learning-based prediction of sand and dust storm sources in arid Central Asia, *International Journal of Digital Earth*, 16(1), 1530-1550.
<https://doi.org/10.1080/17538947.2023.2202421>.

- 68) Willmott, C.J. (1982). Some comments on the evaluation of model performance, Bulletin American Meteorological Society, 63, 1309-1313.
[https://doi.org/10.1175/1520-0477\(1982\)063%3C1309:SCOTEO%3E2.0.CO;2](https://doi.org/10.1175/1520-0477(1982)063%3C1309:SCOTEO%3E2.0.CO;2).
- 69) Wong, M.S., Xiao, F., Nichol, J., Fung, J., Kim, J., Campbell, J. & Chan, P. W. (2015). A multi-scale hybrid neural network retrieval model for dust storm detection, a study in Asia, Atmospheric Research, 158, 89-106.
https://ui.adsabs.harvard.edu/link_gateway/2015AtmRe.158...89W/doi:10.1016/j.atmosres.2015.02.006.
- 70) Wu., Y., Bo, W, Li, S., & Guo, Y. (2021). Sand and dust storms in Asia: a call for global cooperation on climate change, The Lancet Planetary Health, 5(6), e329-e330.
[https://doi.org/10.1016/s2542-5196\(21\)00082-6](https://doi.org/10.1016/s2542-5196(21)00082-6).
- 71) Xu, Z., Hou, Z., Han, Y., Guo, W. (2016). A diagram for evaluating multiple aspects of model performance in simulating vector fields, Geosci Model Dev, 9, 4365–4380.
<https://doi.org/10.5194/gmd-2016-172>.
- 72) Yadav, V., Yadav, A. K., Singh, V., Tej & Singh, T. (2024). Artificial neural network an innovative approach in air pollutant prediction for environmental applications: A review, Results in Engineering, 22, 102305,
<https://doi.org/10.1016/j.rineng.2024.102305>.
- 73) Yang, Q., Yuan, Q., Li, T., Shen, H. & Zhang, L. (2017). The relationships between PM2. 5 and meteorological factors in China: Seasonal and regional variations, International journal of environmental research and public health, 14(12), 1-19.
<https://doi.org/10.3390/ijerph14121510>.
- 74) Yilmaz, I., & Oguz Kaynar, O. (2011). Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils, Expert Systems with Applications, 38(5), 5958-5966,
<https://doi.org/10.1016/j.eswa.2010.11.027>.
- 75) Zaheer, K., Saeed, S. & Tariq, S. (2023). Prediction of aerosol optical depth over Pakistan using novel hybrid machine learning model, Research Article - Atmospheric & Space Sciences, 71, 2009–2029.
<https://doi.org/10.1007/s11600-023-01072-x>.
- 76) Zeinali, B., Vatanparast Ghaleh juq, F., Teymouri, M., Das, S., Ruhi, F. & Sihag, P. (2023). Selection of the best clustering technique in order to zone the frequency of dust storms in Iran, Arab J Geosci, 16, 74, 1-15.
<https://doi.org/10.1007/s12517-022-11135-w>.