



АҚПАРАТТЫҚ-КОММУНИКАЦИЯЛЫҚ ТЕХНОЛОГИЯЛАР
ИНФОРМАЦИОННО-КОММУНИКАЦИОННЫЕ ТЕХНОЛОГИИ
INFORMATION AND COMMUNICATION TECHNOLOGIES

АҚПАРАТТЫҚ ЖҮЙЕЛЕР
ИНФОРМАЦИОННЫЕ СИСТЕМЫ
INFORMATION SYSTEMS

DOI 10.51885/1561-4212_2024_3_208
MFTAA 44.29.01

А.Е. Тукушова¹, С.Ж. Рахметуллина¹, А.В. Пененко²

¹Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті,
Өскемен қ., Қазақстан

*E-mail: aralytm.tukushova@mail.ru**

E-mail: SRakhmetullina@edu.ektu.kz

²РФА СБ Есептеу математикасы және математикалық геофизика институты,
Новосибирск қ., Ресей

E-mail: a.penenko@yandex.ru

ӨСКЕМЕН ҚАЛАСЫ ДЕРЕКТЕР МЫСАЛЫНДА АТМОСФЕРАЛЫҚ АУАНЫҢ ЛАСТАНУЫН БОЛЖАУ АЛГОРИТМІН ӨЗІРЛЕУ

РАЗРАБОТКА АЛГОРИТМА ДЛЯ ПРЕДСКАЗАНИЯ ЗАГРЯЗНЕНИЯ АТМОСФЕРНОГО ВОЗДУХА НА ПРИМЕРЕ ДАННЫХ Г. УСТЬ-КАМЕНОГОРСКА

DEVELOPMENT OF AN ALGORITHM FOR PREDICTING ATMOSPHERIC AIR POLLUTION USING THE EXAMPLE OF DATA OF THE CITY OF UST-KAMENOGORSK

Аңдатпа. Атмосфералық ауаның ластануы қазіргі қалалардың өзекті мәселелерінің бірі болып табылады. Бұл мақалада Өскемен қаласының деректері мысалында ауаның ластану деңгейін болжау алгоритмін өзірлеу қарастырылады. Экологиялық мониторинг міндеттерінде машиналық оқытуды пайдалану қауіпті тенденцияларды уақтылы анықтауға және зиянды азайту үшін шаралар қабылдауға мүмкіндік береді. Жұмыста модельді дамытудың негізгі кезеңдері, деректерді талдау, алгоритмді таңдау және оның дәлдігін бағалау сипатталған.

Түйін сөздер: машиналық оқыту, TCN моделі, атмосфераның ластануы, болжау, нейрондық желі.

Аннотация. Загрязнение атмосферного воздуха является одной из актуальных проблем современных городов. В данной статье рассматривается разработка алгоритма для предсказания уровня загрязнения воздуха на примере данных города Усть-Каменогорск. Использование машинного обучения в задачах экологического мониторинга позволяет своевременно выявлять опасные тенденции и принимать меры для минимизации вреда. В работе описаны основные этапы разработки модели, анализ данных, выбор алгоритма и оценка его точности.

Ключевые слова: машинное обучение, модель TCN, атмосферное загрязнение, прогнозирование, нейронная сеть

Abstract. Atmospheric air pollution is one of the urgent problems of modern cities. This article discusses the development of an algorithm for predicting the level of air pollution using the example of data from the city of Ust-Kamenogorsk. The use of machine learning in environmental monitoring tasks makes it possible to identify dangerous trends in a timely manner and take measures to minimize harm. The paper describes the main stages of model development, data analysis, algorithm selection and evaluation of its accuracy.

Keywords: machine learning, TCN model, atmospheric pollution, forecasting, neural network

Kipicne. Қоғамның тұрақты дамуын қамтамасыз ету табиғи ортаның тұрақты жағдайынсыз мүмкін емес. Атмосфералық ауа тіршілік ету ортасының қажетті бөлігі болып табылады және адам денсаулығына айтарлықтай әсер етеді (Sokhi, R. S., et al., 2022, Oliveri Conti, G., Heibati, B., Kloog, I., et al., 2017, Duisebekova K.S., et al., 2020).

Өнеркәсіптік қаланың атмосфералық ауа сапасының мониторингі жүйесіндегі өзекті міндеттер: атмосфералық ауаның ластануын модельдеу және болжау; ластану көздерінің орналасуы мен қуатын бағалау; қоспалар көздерінен бөлінетін ластанушы заттардан барынша зардап шеккен аумақтарды айқындау болып табылады. Математикалық модельдеу әдістерін, ақпараттық технологияларды және бақылау деректерін ортақ пайдалану қоршаған ортаны бақылау мәселелерін шешудің тиімді құралы болып табылады. Бұл үнемі өзгеріп отыратын параметрлер жағдайындағы жағдайды кез келген уақытта бағалауға ғана емес, сонымен қатар атмосфералық ауаның сапасын жақсартуға бағытталған іс-шараларды ұйымдастыру бойынша басқарушылық шешімдер қабылдау үшін ұсыныстарды уақтылы дайындауға мүмкіндік береді (А.В. Пененко, С.Ж. Рахметуллина, 2013).

Зерттеу жұмысының мақсаты: Болжау моделдерін салыстырып, тиімді модельді таңдап, таңдалған болжау моделі негізінде атмосфералық ауаның ластануын болжау алгоритмін әзірлеп, Өскемен қаласы деректер мысалында нәтижелер алу.

Соңғы уақытта машиналық оқыту әдістерін қолдана отырып болжау алгоритмдері атмосфералық ауаның ластануы саласында белсенді түрде әзірленуде және қолданылуда:

- ластану деңгейін болжау үшін қолдануға болады, бұл халықтың денсаулығына қауіп төндіретін аймақтарды анықтауға мүмкіндік береді,

- улы заттардың шығарындылары немесе бөлшектердің жоғары концентрациясы сияқты ауаның ластануының экстремалды мәндерінің пайда болуын болжауға көмектесуі мүмкін, бұл қоғамды алдын ала қорғау үшін шаралар қабылдауға мүмкіндік береді,

- шектеулі ресурстарды ластану нормативтерінен асып кету ықтималдығы жоғары жерлерге және уақыттарға бағыттауға көмектесетін ауа сапасын бақылау жүйелерін онтайландыру үшін пайдалануға болады,

- қоршаған ортаны қорғаудың тиімді стратегияларын әзірлеуге мүмкіндік беретін ауаның сапасына ластануды азайту жөніндегі түрлі шаралардың ықтимал әсерін бағалау үшін жұмылдырылуы мүмкін.

Осылайша, машиналық оқыту әдістерін қолдана отырып, атмосфералық ауаның ластануын болжау, ауа сапасын бақылау мен басқарудың тиімділігін арттырудың және қоршаған орта мен адамдардың денсаулығын қорғаудың тиімді шараларын әзірлеудің маңызды құралы болып табылады (Surakhi O., Serhan S., Salah I., 2020, Yue-Shan Chang, et al., 2020, Hsin-Ta Chiao, et al., 2020, Labusov M.V., 2020).

Материалдар және зерттеу әдістері

Ауаның ластануын талдауға және болжауға арналған заманауи бағдарламалық орта машиналық оқыту әдістері мен нейрондық желілерді қолдануға негізделген. Қазіргі уақытта уақыт қатарларын болжауға арналған ең танымал нейрондық желілерге: қайталанатын нейрондық желі (ағылш. Recurrent Neural Network; RNN), оның ішінде қысқа жиілікті жад элементтерінің ұзын тізбегін пайдаланатын сандар мен нейрондық желілер (ағылш. Long short-term memory; LSTM) және аддитивті регрессиясы бар нейрондық желі (ағылш. Prophet), уақытша конволюциялық желілер (Temporal Convolutional Networks).


Уақытша конволюциялық желілерді қолдану механизмі "Temporal Convolutional Networks for Action Segmentation and Detection" мақаласында егжей-тегжейлі сипатталған

(Colin lea, 2016). Негізгі идея-жіңішке конволюциялық қабаттар (dilation) негізінде кодтаушы блоктан (Encoder) және шифрды шешуші блоктан (Decoder) тұратын архитектура құрылды, оның негізінде бейне ағынын сегментациялау тапсырмасы орындалады (1-сурет). Әр түрлі жұқаруы бар блоктардың шығуын қорытындылау ResNet-ке ұқсас градиенттердің ыдырау мәселесін шешеді.

Бір өлшемді конволюциялық қабатта біз кіріс деректерінде конволюция операциясын орындау үшін K ұзындығының конволюциялық ядросын қолданамыз, нәтижесінде белгілі бір позициядағы объектілер картасы пайда болады. X реттілік кірістері үшін Y объектілерінің Шығыс картасының i -ші позициясы үшін есептеу формуласы келесідей:

$$Y[i] = \sigma(\sum_j(X[i + j] * W[j]) + b) \tag{1}$$

мұндағы $Y [i]$ i – қадамдағы модельдің болжамын көрсететін шығыс тізбегінің i -ші элементін білдіреді; $X[i + j]$ – кіріс тізбегінің $(i + j)$ -ші элементін білдіреді, мұндағы j -і-ге қатысты орын ауыстыру; $W [j]$ – модель салмағының параметрлерін білдіреді; b – шығыс мәліметтерінің ауытқуларын ендіруде пайдаланатын, модельдің ауытқу параметрі [7, 9].



1-сурет. Encoder-Decoder Temporal Convolutional желісінің архитектурасы
 Ескерту – (Colin lea, 2016) алынды

Уақытша конволюциялық желілер (TCN) ауаның ластануын талдау және болжау үшін таңдалды, өйткені олардың ұзақ уақытқа тәуелділікті жұқару арқылы тиімді өңдеу қабілеті (dilation), сондай-ақ қайталанатын желілерде кездесетін градиенттердің әлсіреу мәселесін шешеді.

1-кесте. Уақытша конволюциялық желілер (TCN) мен қайталанатын нейрондық желілерді (RNN, LSTM) критерийлер бойынша салыстыру

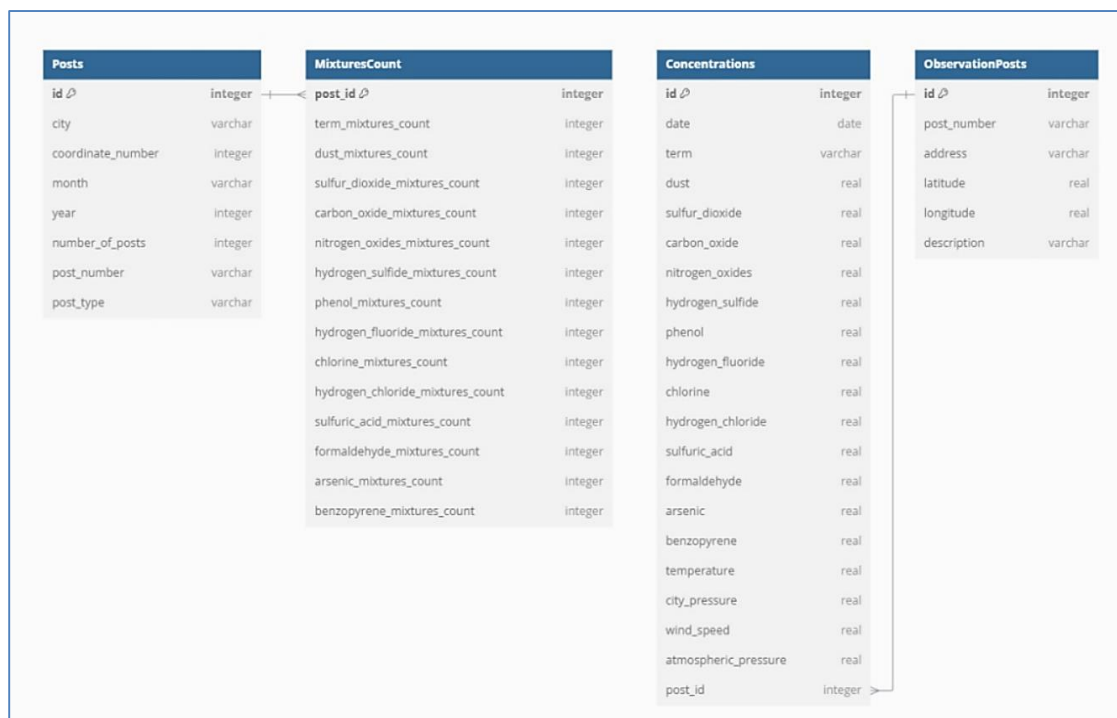
Критерий	Уақытша конволюциялық желілер (TCN)	Қайталанатын нейрондық желілер (RNN, LSTM)
Ұзақ уақытқа тәуелділікті өңдеу	Жұқару арқылы тиімді (dilation)	Өте ұзақ тізбектерде қиындықтар туындауы мүмкін

Градиенттердің әлсіреуі мәселесі	Желі архитектурасының арқасында шешілді	Әсіресе классикалық RNN-де бар
Өнімділік және жылдамдық	Параллелдеу арқасында жылдам	Дәйекті өңдеуге байланысты баяу
<i>Ескерту – автормен құрастырылған</i>		

TCN есептеулерді параллельдеуге мүмкіндік береді, бұл оларды RNN және LSTM-мен салыстырғанда тезірек және тиімдірек етеді. Сонымен қатар, TCN деректерді болжауды да, сегменттеуді де қолдай отырып, уақыт серияларын өңдеуде икемділікті қамтамасыз етеді және оларды болжау жүйелеріне біріктіруді жеңілдететін қарапайым архитектураға ие (Wei, Xiaoyan & Xu, Ying., 2023, Szymon H., Mariusz F., Rafał J., 2022, Yves R., Rasa Z., 2018, Adven M., 2019, Sateesh N Hosamane, 2023).

Атмосфералық ауаны ластаушы заттар туралы деректер «Казгидромет» ресми деректерінен алынды, бұл Өскемен қаласының әртүрлі 7 пост бойынша атмосфералық ауа мониторингінің күнделікті деректері. Деректер жиынтығы жол бойынша 2018 жылдан 2022 жылға дейінгі күнді және бағандарында PM 2.5 бөлшектері, PM 10 бөлшектері, SO₂, CO, NO₂, O₃, H₂S негізгі ауа ластауыштарын (Stephanie Lima Jorge Galvão, et al., 2022, Xi Gong, et al., 2022, Abirami S., Chitra P., 2022, Khawaja Hassan Waseem et al., 2022, Yannan Xie, Mengxiang Chen, 2022, Sankar Ganesh, et al., 2022) және метеорологиялық мәліметтерді қамтиды.

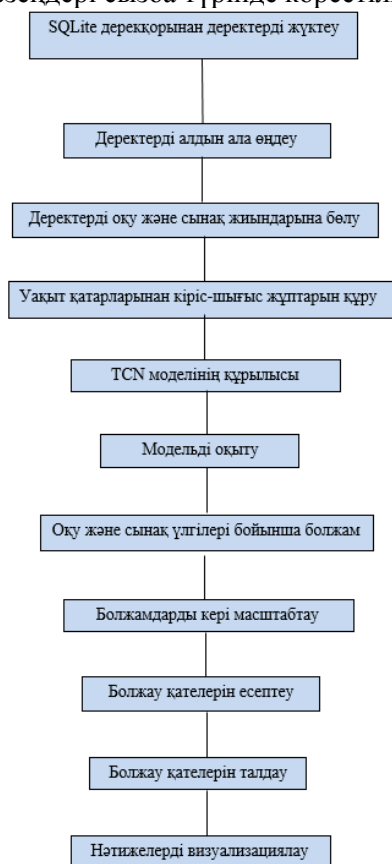
Мәліметтер қорын құру үшін SQLite тандалды, себебі бұл серверді орнатуды қажет етпейтін, қарапайым шешім. Бұл жергілікті қосымшаларға, мобильді құрылғыларға және шағын жобаларға ыңғайлы. SQLite кросс-платформа болып табылады, аз ресурстарды пайдаланады және стандартты SQL қолдайды. SQLite-та құрылған мәліметтер қорының құрылымы (2-сурет).



2-сурет. Мәліметтер қоры құрылымы

Ескерту – автормен құрастырылған

Нәтижелері және оларды талқылау. Қарастырылып отырған зерттеу жұмысында атмосфералық ауаның ластануын болжау алгоритмін әзірлеу сұрағы қойылып, оның алгоритмі уақытша конволюциялық желілер (TCN) моделі негізінде ұсынылып отыр. Болжау моделін іске асыру кезеңдері сызба түрінде көрсетілген (3-сурет).



3-сурет. Болжау моделін іске асыру кезеңдері

Ескерту – автормен құрастырылған


Деректерді талдаудың алғашқы қадамы SQLite дерекқорына қосылу болды. SQL сұрауларының көмегімен бақылау бекеттері, ластаушы заттардың концентрациясы, сондай-ақ ауадағы қоспалардың құрамы туралы ақпаратты қамтитын бірнеше кестеден деректер алынды. Бұл деректер data frame data-ға жүктелді, онда бастапқы өңдеу жүргізілді: уақыт белгілерін түрлендіру және деректердің тұтастығын қамтамасыз ету үшін өткізіп алған мәндерді толтыру. Бұл тәсіл барлық қол жетімді уақыт қатарларын ескеруге мүмкіндік береді

Модельдеу үшін деректерді дайындау. Модельді құрудың мақсаты ретінде күкірт диоксидінің (SO_2) концентрациясы таңдалды, өйткені ол ауаны ластайтын негізгі заттардың бірі болып табылады. Деректерді қалыпқа келтіру үшін `minmaxscaler` қолданылды, ол барлық көрсеткіштердің мәндерін бір диапазонға жеткізді, бұл модельдің тұрақты жұмыс істеуі үшін қажет. `Create_dataset()` функциясының көмегімен оқыту және тестілеу үшін мәліметтер жиынтығы құрылды.

Модель уақытша конволюциялық желі архитектурасы (TCN) негізінде Keras кітапханасының көмегімен жасалған. Ол ReLU белсендіру функциясы бар үш конволюциялық

кабаттан және нәтижелерді тегістеу үшін Flatten соңғы қабатынан тұрады (4-сурет).

Модель Adam оңтайландырғышын және (MSE) орташа квадраттық қате жоғалту функциясын қолдана отырып құрастырылды. Модельді оқыту 50 дәуір бойы жаттығу деректерінде жүргізілді, деректер пакетінің өлшемі 16 болды, бұл модельді деректерге бейімдеу үшін жеткілікті итерациялар санын қамтамасыз етті.



4-сурет. TCN моделінің архитектурасы

Ескерту – автормен құрастырылған

Модельді бағалау және қателерді талдау. Оқытудан кейін модель жаттығу және сынақ деректер жиынтығында сыналды. Болжамдар MINMAXSCALER көмегімен SO₂ концентрациясының нақты мәндерін алу үшін кері түрлендірілді. Модельдің сапасын бағалау үшін екі деректер жиынтығы үшін де MSE – орташа квадраттық қате есептелді.

$$\varepsilon_x = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (2)$$

мұндағы ε_x – орташа квадраттық қате (MSE); Σ – «қосындыны» білдіреді; n – іріктеу өлшемі; Y_i – деректердің нақты мәні; \hat{Y}_i – деректердің болжамды мәні.

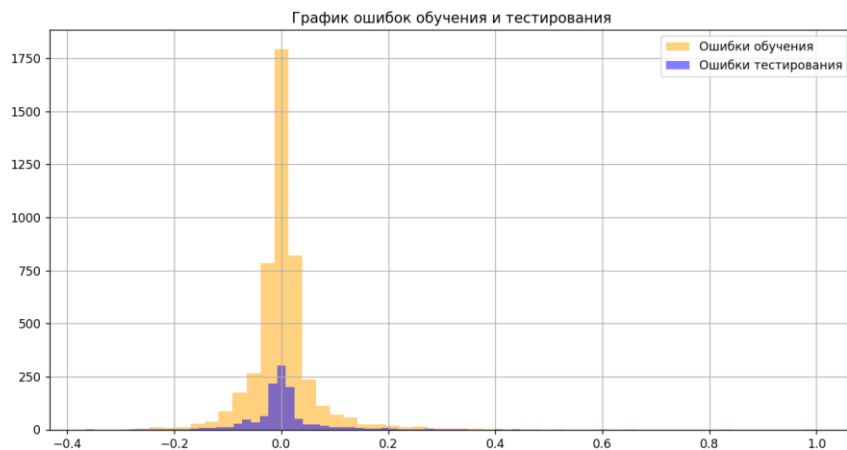
MSE мәні неғұрлым төмен болса, модель мәндерді дәл болжай алады дегенді білдіреді. Есептелген MSE мәндері:

$$\varepsilon_{\text{Training}} = 0,0046,$$

$$\varepsilon_{\text{Tasting}} = 0,0056.$$


Жаттығу жиынтығы үшін орташа квадраттық қате (MSE) 0.0046, ал сынақ үшін 0.0056 болды, бұл модельдің жоғары дәлдігін көрсетеді. MSE мәні неғұрлым төмен болса, модель соншалықты мәндерді жақсы болжай алды дегенді білдіреді.

Екі деректер жиынтығы үшін де болжау қателіктерінің гистограммалары тұрғызылып, бейнеленді (5-сурет). Бұл гистограмма қателердің таралуын нақты талдауға мүмкіндік береді.



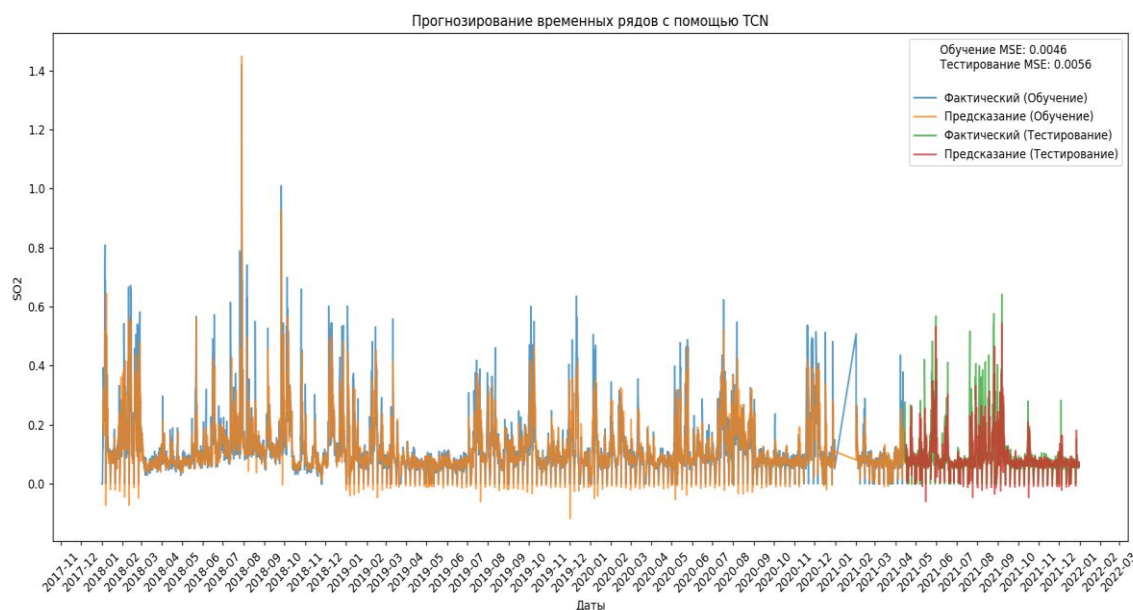
5-сурет. Оқыту және сынақ деректер жинағы бойынша болжау қателерінің гистограммасы
Ескерту – автормен құрастырылған

Аномалияларды анықтау үшін қателіктердің стандартты ауытқуы қолданылды және графиктерде қателіктерден бас тартуды көрсететін нүктелер бөлінді (6-сурет).



6-сурет. Аномальды нүктелерді анықтау графигі
Ескерту – автормен құрастырылған

Нәтижелерді көрнекі түрде көрсету үшін SO_2 концентрациясының нақты және болжамды мәндерін, көрсететін графиктер салынды. Графикте сондай-ақ есептелген MSE – орташа квадраттық қателіктердің мәні көрсетілген (7-сурет).



7-сурет. Temporal Convolutional networks моделі арқылы күкірт оксидінің таралуын болжау
Ескерту – автормен құрастырылған

Жаттығу деректерінде жоғары болжау дәлдігін көрсетті және үлкен болжау қателіктері бар бірнеше қалыптан тыс нүктелерді анықтады, бұл штаттан тыс оқиғаларды немесе ауадағы ластаушы заттарды көрсетеді. TCN моделі әртүрлі уақыт аралықтарында деректерді талдауға мүмкіндік беретін архитектурасының арқасында, уақыт қатарларындағы ұзақ мерзімді тәуелділіктерді тиімді есепке алу қабілетін көрсетті (7-сурет).

Қорытынды. Уақытша конволюциялық желілерге (TCN) негізделген модель күкірт диоксиді (SO_2) сияқты ауадағы ластаушы заттардың концентрациясын болжаудың жоғары дәлдігін көрсетті. Ол уақытша тәуелділіктерді тиімді қарастырады және ауа сапасын басқару саласында неғұрлым негізделген шешімдер қабылдауға көмектесу арқылы экологиялық көрсеткіштерді болжау үшін пайдалануға болады. TCN архитектурасы үлкен өлшемді уақыт қатарларымен жұмыс істеуге және деректердегі ауытқуларды анықтауға мүмкіндік береді, бұл оны экологияда болжаудың қуатты құралы етеді.

Уақытша конволюциялық желілер (TCN) мен қайталанатын нейрондық желілер (RNN, LSTM) моделдеріне салыстыру жасалды. Тиімді модель ретінде TCN таңдалынды, таңдалған болжау моделі негізінде атмосфералық ауаның ластануын болжау алгоритмі әзірленіп, Өскемен қаласының 2018-2022 жылғы деректер мысалында нәтижелер алынды.

Мүдделер қақтығысы. Авторлар мүдделер қақтығысының жоқтығын мәлімдейді.

Әдебиеттер тізімі

- Abirami S., Chitra P. "Probabilistic air quality forecasting using deep learning spatial-temporal neural network" 22 September 2022 DOI: <https://doi.org/10.1007/s10707-022-00479-w>
- Adven M. "Machine learning algorithms in air quality modeling" September 2019 DOI: 10.22034/gjesm.2019.04.0
- Colin Lea, Michael D. Flynn, Rene Vidal, Austin Reiter, Gregory D. Hager Temporal Convolutional Networks for Action Segmentation and Detection [Online]. – Nov 16, 2016. – Aug 18, 2021. –

- <https://arxiv.org/abs/1611.05267>.
- Duisebekova K.S., Kozhamzharova D.K., Rakhmetulayeva S.B., Umarov F.A., Aitimov M. Zh. Development of an information-analytical system for the analysis and monitoring of climatic and ecological changes in the environment The 11th International Conference on Ambient Systems, Networks and Technologies (ANT) April 6-9, 2020, Warsaw, Poland, 578–583
- Khawaja Hassan Waseem, Hammad Mushtaq, Fazeel Abid, Adnan M. Abu-Mahfouz, Asadullah Shaikh, Mehmet Turan, Jawad Rasheed "Forecasting of Air Quality Using an Optimized Recurrent Neural Network": 18 October 2022 Network. Processes 2022, 10, 2117. <https://doi.org/10.3390/pr10102117>
- Labusov M.V. "Nejronnye seti dolgoj kratkosrochnoj pamjati i ih ispol'zovanie dlja modelirovaniya finansovyh vremennyh rjadov" Innovacii i investicii, no. 3, 2020, pp. 167-171.
- Oliveri Conti, G., Heibati, B., Kloog, I. et al. A review of AirQ Models and their applications for forecasting the air pollution health outcomes. *Environ Sci Pollut Res* 24, 6426–6445 (2017). <https://doi.org/10.1007/s11356-016-8180-1>
- Sateesh N Hosamane "Prediction of PM10 pollution using principal component regression and hybrid artificial neural network model" May 2023, 44(5): 1256-1263
- Sankar Ganesh, S., Arulmozhivarman, Pachaiyappan and Tatavarti, Rao. "Forecasting Air Quality Index Using an Ensemble of Artificial Neural Networks and Regression Models" *Journal of Intelligent Systems*, vol. 28, no. 5, 2019, pp. 893-903. <https://doi.org/10.1515/jisys-2017-0277>
- Sokhi, R. S., Moussiopoulos, N., Baklanov, A., Bartzis, J., Coll, I., Finardi, S., Friedrich, R., Geels, C., Grönholm, T., Halenka, T., Ketzel, M., Maragkidou, A., Matthias, V., Moldanova, J., Ntziachristos, L., Schäfer, K., Suppan, P., Tsegas, G., Carmichael, G., Franco, V., Hanna, S., Jalkanen, J.-P., Velders, G. J. M., and Kukkonen, J.: Advances in air quality research – current and emerging challenges, *Atmos. Chem. Phys.*, 22, 4615–4703, <https://doi.org/10.5194/acp-22-4615-2022>, 2022.
- Stephanie Lima Jorge Galvão, Júnia Cristina Ortiz Matos, Yasmin Kaore Lago Kitagawa, Flávio Santos Conterato, Davidson Martins Moreira, Prashant Kumar, Erick Giovani Sperandio Nascimento "Particulate Matter Forecasting Using Different Deep Neural Network Topologies and Wavelets for Feature Augmentation" 29 July 2022 / Revised: 23 August 2022 / Accepted: 1 September 2022 / Published: 8 September 2022 <https://doi.org/10.3390/atmos13091451>
- Surakhi O., Serhan S., Salah I. On the ensemble of recurrent neural network for air pollution forecasting: Issues and challenges // *Adv. Sci. Technol. Eng. Syst. J.* – 2020. – T. 5. – C. 512-526 // <https://doi.org/10.25046/aj050265>
- Szymon H., Mariusz F., Rafał J. Air Quality Modeling with the Use of Regression Neural Networks *Int. J. Environ. Res. Public Health* 2022, 19(24), <https://doi.org/10.3390/ijerph192416494>
- Wei, Xiaoyan & Xu, Ying. Research on carbon emission prediction and economic policy based on TCN-LSTM combined with attention mechanism. *Frontiers in Ecology and Evolution*. <https://doi.org/10.3389/fevo.2023.1270248>
- Xi Gong, Lin Liu, Yanhong Huang, Bin Zou, Yeran Sun, Li Luo, Yan Lin "A pruned feed forward neural network (pruned-FNN) approach to measure air pollution exposure" December 5th, 2022 DOI: <https://doi.org/10.21203/rs.3.rs-2322627/v1>
- Yannan Xie, Mengxiang Chen "Secondary Modeling of Air Quality Based on LSTM Cycle Neural Network" *Guangdong Polytechnic of Environmental Protection Engineering* 2022 <https://doi.org/10.1088/1742-6596/2400/1/012045>
- Yue-Shan Chang, Hsin-Ta Chiao, Satheesh Abimannan, Yo-Ping Huang, Yi-Ting Tsai, Kuan-Ming Lin, An LSTM-based aggregated model for air pollution forecasting, *Atmospheric Pollution Research*, Volume 11, Issue 8, 2020, Pages 1451-1463.
- Yves R., Rasa Z. "Machine Learning Approaches for Outdoor Air Quality Modelling: A Systematic Review" Received: 15 November 2018; Accepted: 8 December 2018; Published: 11 December 2018 <http://dx.doi.org/10.3390/app8122570>
- Пененко А.В., Рахметуллина С.Ж., Алгоритмы локализации источников загрязнения атмосферного воздуха на основе данных автоматизированной системы экологического мониторинга, Сиб.

электрон. матем. изв., 2013, том 10, 35– 54 // Penenko A.V., Rahmetullina S.Zh., Algoritmy lokalizacii istochnikov zagryaznenija atmosfernogo vozduha na osnove dannyh avtomatizirovannoj sistemy jekologicheskogo monitoringa, Sib. jelektron. matem. izv., 2013, tom 10, 35-54.

Information about authors

Tukushova Arailym – master of computer sciences, D. Serikbayev East Kazakhstan technical university, Ust-Kamenogorsk, Kazakhstan, E-mail: araylym.tukushova@mail.ru, ORCID: 0000-0002-9959-6021, +7 777 579 84 00

Rakhmetullina Saule – PhD in Technical sciences, associate professor, D. Serikbayev East Kazakhstan technical university, Ust-Kamenogorsk, Kazakhstan, E-mail: SRakhmetullina@edu.ektu.kz, ORCID: 0000-0002-3142-0249, +7 77051861368

Penenko Aleksey – Doctor of Physical and Mathematical Sciences, Institute of Computational Mathematics and Mathematical Geophysics SB RAS, Novosibirsk, Russia, E-mail: a.penenko@yandex.ru, ORCID: 0000-0003-2580-6580, +7 913 742 49 55