

СМОЛІЄНКО ДАНИЛО

Хмельницький національний університет
e-mail: dsmolienko@gmail.com

ПЕТРОВСЬКИЙ СЕРГІЙ

Хмельницький національний університет
ORCID ID: 0000-0002-0590-0484
e-mail: petrovskijs69@gmail.com

МЕТОД ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ

У статті запропоновано метод прогнозування забруднення доріг на основі підходу глибокого активного навчання. Метод дозволяє моделювати майбутню динаміку зміни рівня забрудненості дорожнього покриття в часі на відміну від існуючих підходів, орієнтованих на аналіз поточного стану. Основою методу є застосування рекурентної нейронної мережі LSTM та техніка збільшення розмірності даних. Головна мета дослідження – розробити метод прогнозування забруднення доріг на основі підходу глибокого активного навчання та дослідити його ефективність. Це дозволить вживати вчасні заходи для зменшення забруднення та поліпшення якості інфраструктури доріг.

Ключові слова: забруднення доріг, глибоке активне навчання, прогнозування, нейромережі, транспорт.

SMOLIENKO DANYLO, PETROVSKYI SERHII
Khmelnytskyi National University

PREDICTION METHOD FOR PUBLIC ROAD POLLUTION BASED ON DEEP ACTIVE LEARNING APPROACH USING IMAGE ANALYSIS

The study proposes a method of predicting road pollution based on the approach of deep active learning. The proposed method allows modeling the future dynamics of changes in the level of road surface pollution over time, in contrast to existing approaches, which are mainly focused on the analysis of the current state in real time. The main goal of the work is to improve road pollution control and management systems by providing accurate forecasting of the level of pollution based on input data. This will allow timely measures to reduce pollution and improve the quality of road infrastructure.

The basis of the proposed method is the use of a recurrent LSTM neural network. In addition, the technique of increasing the dimensionality of the data by introducing lags (time-shifted variables) is used to more effectively take into account historical dependencies when building a predictive model.

In addition, the work improved the procedure for measuring the current level of pollution based on a combination of neural networks CNN (for analyzing road surface images) and LSTM (for modeling the temporal dynamics of changes).

The proposed comprehensive approach makes it possible to determine the current state and predict the future level of road infrastructure pollution with high accuracy. The developed method can be applied in practice for planning cleaning works, optimizing road maintenance schedules and other purposes in the field of transport infrastructure management.

The obtained results allow us to conclude that lengthening the process of learning the model, i.e. increasing the number of epochs through multiple analysis and adjusting the weight coefficients of the neural network, has a positive effect on the accuracy of predictive calculations of the level of pollution for a given future period. Thus, it can be argued that the proposed approach is effective for solving the given task.

The research also confirmed the effectiveness of the proposed method based on deep active learning for solving the task of predicting road pollution.

Keywords: road pollution, deep active learning, forecasting, neural networks, transport.

Вступ

Забрудненість доріг є актуальною проблемою сучасних міст [1]. Зростання кількості транспорту та обсягів відходів призводить до погіршення стану дорожньої інфраструктури. Це негативно позначається на економіці, екології та здоров'ї населення. Тому питання контролю та прогнозування рівня забрудненості є вкрай важливим.

Існуючі підходи до вирішення проблеми контролю та прогнозування забрудненості доріг мають ряд суттєвих недоліків. Зокрема, традиційні ручні методи, що базуються на безпосередньому спостереженні та зборі даних людьми, є досить трудомісткими та потребують значних людських і часових ресурсів.

Щодо автоматизованих рішень, які ґрунтуються на класичних алгоритмах машинного навчання, то вони часто не забезпечують необхідної точності прогнозних моделей внаслідок недостатньої здатності до узагальнення та виявлення складних залежностей у даних.

Тому актуальним є розробка інноваційного підходу на основі технологій глибокого активного навчання, який поєднував би високу точність зі швидкістю та автоматизацією процесів аналізу даних і прогнозування. Це дозволить підвищити ефективність систем моніторингу та контролю стану доріг.

Метою даного дослідження є розробка методу прогнозування забруднення доріг на основі підходу глибокого активного навчання та оцінка його ефективності.

Аналіз існуючих рішень

Проблема прогнозування забруднення доріг є актуальною та такою, що вивчається тривалий час. Існуючі теоретичні та практичні напрацювання мають певні обмеження. Зокрема, традиційні математичні

моделі не завжди забезпечують необхідну точність через складність формалізації всіх чинників впливу.

Останнім часом активно розвивається напрям глибокого активного навчання [2] як ефективний підхід машинного навчання для прогнозних задач. Він дозволяє будувати точні моделі з мінімальним обсягом даних для навчання. Але наявні розробки цього напрямку для прогнозування забрудненості доріг [3] все ще мають певні обмеження. Зокрема, дослідження показують залежність якості моделей від умов зйомки даних та обмеженість їх застосування для різних регіонів. Крім того, такі моделі потребують великої кількості апаратних ресурсів, що значно збільшує затрати на їх використання.

Також потребує вдосконалення процедура отримання навчальних даних, яка наразі значною мірою залежить від ручної розмітки експертами.

Крім цього, існують різні підходи до моделювання та прогнозування забруднення доріг. Математичні моделі дозволяють формалізувати залежності між параметрами цього процесу у вигляді рівнянь. Зокрема, з використанням моделі часових рядів можна проаналізувати історичні дані та екстраполювати виявлені тенденції у майбутнє. Проте такий підхід не завжди адекватно відображає вплив зовнішніх факторів.

Альтернативою є стохастичне моделювання з урахуванням ймовірнісного характеру деяких змінних. Це дає змогу побудувати розподіли ймовірностей прогнозованого рівня забруднення залежно від реалізації випадкових факторів. Проте потребує значного обсягу статистичних даних для адекватного оцінювання параметрів моделей.

Найпопулярнішими підходами до вирішення поставленої проблеми на сьогодні є підходи до нейронних мереж, які мають багато переваг. Зокрема, детально розглядаються такі методи:

1) згорткові нейронні мережі (CNN) [4]. Вони добре підходять для розпізнавання зображень, можуть виділяти ключові характеристики, як-от краї, контури, текстури. Однак CNN чутливі до зміни орієнтації зображення.

2) рекурентні нейронні мережі (RNN) [5]. Вони враховують історичний контекст та ефективні для моделювання часових рядів. Проте страждають від проблем градієнта.

3) мережі LSTM [6]. Це посилена версія RNN, яка вирішує деякі її недоліки. LSTM містить спеціальні вентиля для кращої обробки даних. Однак LSTM вимагає великих обчислювальних ресурсів.

4) багатошаровий перцептрон (MLP) [7]. Може застосовуватися для класифікації зображень та прогнозування. Проте MLP має проблеми з локальними мінімумами під час навчання.

Для задач прогнозування забруднення доріг найбільш підходять CNN та LSTM моделі, які поєднують переваги глибокого навчання з обробкою часових рядів даних. Проте потрібно враховувати їх недоліки та можливі удосконалення. Отже, актуальним завданням є розробка універсального та автоматизованого методу саме прогнозування майбутнього рівня забрудненості доріг на основі глибокого активного навчання з врахуванням недоліків попередніх підходів.

Виклад основного матеріалу

Створення методу прогнозування забруднення доріг на основі підходу глибокого активного навчання дозволить створити структуровану та організовану роботу для поводження з відходами на дорогах. Для роботи такого методу було створено три модулі: модуль прогнозування забруднення дороги, модуль збільшення розмірності вхідних даних, модуль визначення рівня забруднення на дорозі з зображення.

Для прогнозування забруднення доріг розроблено нейромережеву модель на основі поєднання довгої короткочасної пам'яті та згорткової нейронної мережі. Така гібридна архітектура дозволяє враховувати як локальні закономірності за рахунок згортки, так і моделювати довгострокові тенденції з використанням рекурентних шарів.

Побудова моделі включає підготовку наборів даних, формування вхідних векторів з урахуванням історичного контексту, налаштування параметрів згорткових та рекурентних шарів. Навчання моделі здійснюється методом зворотного поширення помилки з подальшою оптимізацією на основі градієнтного спуску. Архітектура має наступний вигляд:

1. **підготовка даних:** збір часового ряду вимірювань рівня забруднення за тривалий період, формування вхідної послідовності з лагами, нормалізація, розподіл на навчальну, валідаційну та тестову вибірки.

2. **створення моделі:** вхідний шар для часового ряду \rightarrow 1D згорткові шари для виділення ознак \rightarrow MaxPooling шари для регуляризації та інваріантності \rightarrow LSTM шар для моделювання залежностей \rightarrow повнозв'язний шар \rightarrow вихідний шар з лінійною активацією.

3. **навчання моделі.** Модель представляється як функція f , що намагається наблизити $y - y = f(x, \theta)$,

де: θ – параметри моделі, які підлаштовуються в процесі навчання.

Використовуючи алгоритм зворотного поширення помилки можна отримати оновлення ваг моделі на основі градієнта функції втрат. Після цього за обраним оптимізатором Adam, що об'єднує переваги одразу декількох існуючих методів, відбувається налаштування швидкості навчання для кожного параметра, що прискорює конвергенцію:

$$\theta' = \theta - \alpha \nabla \theta L(\theta),$$

де α - швидкість навчання.

Саме навчання в основному полягає у функції втрат $L(\theta)$ середньоквадратичної похибки RMSE, яка є доцільною через свою чутливість до великих похибок і підходить для задач регресії та прогнозування:

$$L(\theta) = 1/N \sum (y - f(x; \theta))^2$$

де: N - розмір набору даних.

4. застосування оптимізатора Adam та методу ранньої зупинки.
5. підбір гіперпараметрів на валідаційній вибірці.
6. оцінка якості моделі.

Запропонована архітектура демонструє високу ефективність у прогнозуванні зміни рівня забрудненості доріг завдяки поєднанню просторового та часового моделювання даних за рахунок CNN та LSTM відповідно.

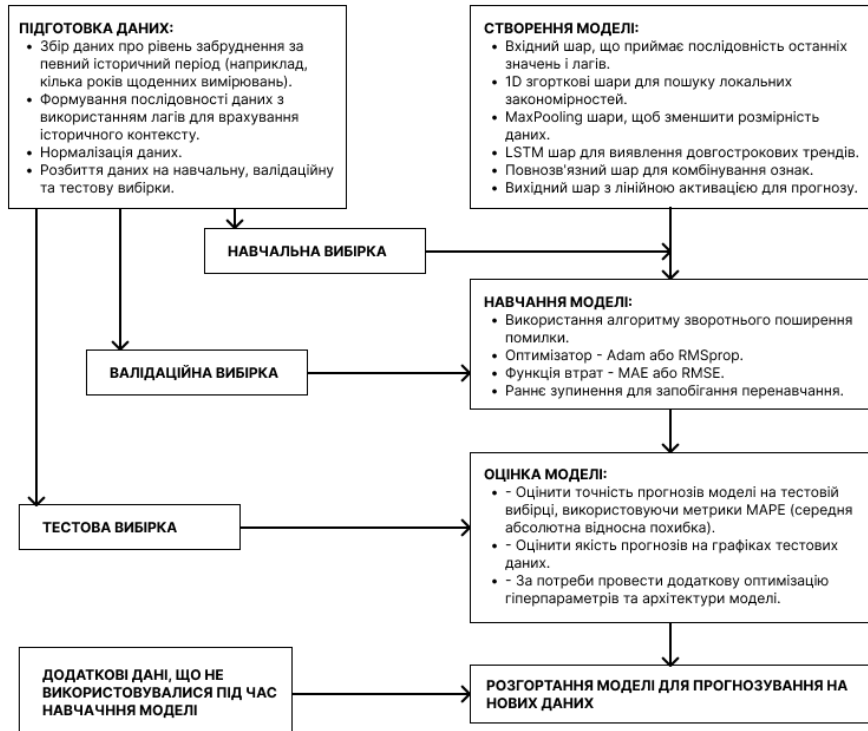


Рис. 1. Схема нейромережевої моделі прогнозування

Для покращення ефективності прогнозувальної моделі було застосовано метод збільшення розмірності вхідних даних на основі додавання лагів - зміщених у часі значень часового ряду. Це дозволяє врахувати попередню історію та контекст, що підвищує здатність моделі виявляти різноманітні тимчасові закономірності, тренди та сезонності.

Також було використано 1D згорткові шари, які автоматично виділяють найбільш інформативні ознаки з послідовності лагів та поточних даних. Поєднання лагів і згортки надає моделі як глобальний часовий контекст, так і можливість аналізу локальних особливостей, що в комплексі покращує якість прогнозних розрахунків.

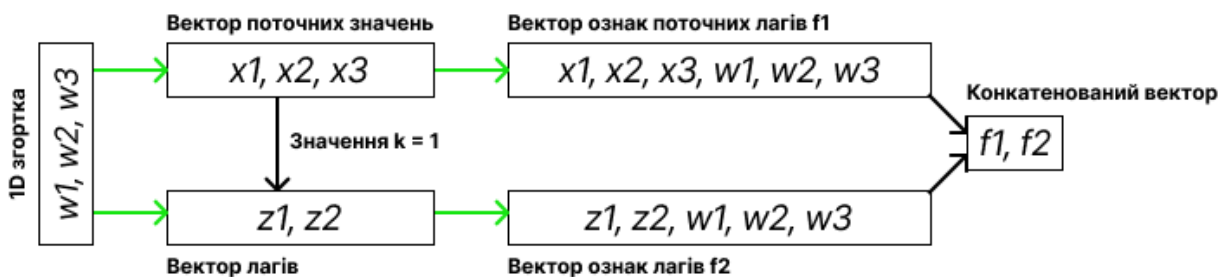


Рис. 2. Комбінування векторів даних для збільшення розмірності

Для визначення поточного рівня забрудненості доріг розроблено комбінований підхід на основі двох моделей глибокого навчання: згорткових та рекурентних нейронних мереж. CNN аналізує зображення та виділяє візуальні ознаки наявності бруду, а LSTM додатково враховує часові закономірності та історичний контекст.

Результати подаються у відносних відсотках забрудненості за шкалою від 0 до 100%. Це значення зручне для подальшого використання, зокрема як вхідний параметр для моделювання динаміки змін рівня забруднення. Запропонована комбінація LSTM та CNN демонструє високу точність оцінки поточного стану дорожнього покриття.



Рис. 3. Схема неймережевої моделі визначення рівня забруднення

Запропонований метод прогнозування забруднення доріг на основі глибокого активного навчання має наступні етапи реалізації:

1. Вхідні дані: часовий ряд показника забрудненості + лагові змінні. Здійснюється фільтрація та нормалізація даних.
2. Формування входів моделі.
3. Нормалізація ваг згорткового шару.
4. Навчання неймережі для прогнозування.
5. Отримання прогнозованого рівня забруднення.
6. Перевірка якості за допомогою функцій. При потребі - зміна гіперпараметрів.
7. Оцінка на тестовій вибірці.

Перевага такого підходу до прогнозування - можливість отримати кількісні значення прогнозованого рівня забруднення для прийняття обґрунтованих рішень щодо очищення доріг.

Експериментальні результати

Для дослідження ефективності методу прогнозування забруднення доріг використано набір даних зі зображеннями однієї дороги в різний час та з різним рівнем забруднення.




Рис. 4. Приклад фото з датасету

Зображення зроблені в місті Хмельницький, Україна, у різний час доби та дні тижня. Загалом датасет налічує 500 зображень, з яких 40% - навчальна вибірка, 40% - валідаційна вибірка, а 20% - тестова.

Переваги такого набору даних:

- різні умови на дорозі: забрудненість, освітлення тощо
- різний час зйомки дозволяє створити єдиний часовий ряд

Це дозволить краще навчити модель прогнозування рівня забруднення на основі зображень та часових характеристик.

Після нормалізації, зображення з набору даних буде виглядати наступним чином:




Рис. 5. Перетворене зображення.

Для оцінки ефективності розробленого методу прогнозування забруднення доріг було проведено дослідження точності прогнозування відносно різної кількості епох (ітерацій) навчання нейромережевої моделі. Суть дослідження полягала у порівнянні точності прогнозів забруднення доріг при різних значеннях кількості навчальних ітерацій моделі. Таке дослідження проводилося за допомогою метрики MAE. Під час експериментів використовувались різні значення кількості епох навчання в діапазоні від 10 до 700.




Рис. 6 – результати дослідження ефективності

Коли протягом періоду дослідження було проаналізовано 10 зразків відповідних параметрів, точність прогнозу становила 1,24%, але коли було проаналізовано 700 зразків, точність прогнозу зросла до 97,84%.

Висновок

Дослідження розв'язує поставлену проблему і пропонує метод прогнозування забруднення доріг на основі підходу глибокого активного навчання. Результати показали, що досліджуваний метод є ефективним засобом для прогнозування, що відкриває можливість у полегшенні управління забрудненням на дорогах за допомогою зображень.

Триваліше навчання моделі (збільшення кількості епох) покращує точність прогнозування, що дозволяє виконувати надточні прогнози для будь-якої з доріг. Зі збільшенням кількості аналізованих зразків вхідних даних точність методу зростає (наприклад, з 1,24% для 10 зразків до 97,84% для 700).

Запропонований метод на основі глибокого навчання ефективно вирішує задачу прогнозування забруднення доріг.

Література

1. Екологічний паспорт області - Хмельницький, ХОВА, 2023. URL: https://www.adm-km.gov.ua/?page_id=7157
2. A Comparative Survey of Deep Active Learning. URL: <https://arxiv.org/pdf/2203.13450.pdf>.
3. VPP: Visual Pollution Prediction Framework Based on a Deep Active Learning Approach Using Public

Road Images. URL: <https://www.mdpi.com/2227-7390/11/1/186>

4. Згортькова нейронна мережа – просте пояснення CNN та її застосування. URL: <https://evergreens.com.ua/ua/articles/cnn.html>

5. Що таке RNN і LSTM у Deep Learning? URL: <https://www.unite.ai/uk/%D1%89%D0%BE-%D1%82%D0%B0%D0%BA%D0%B5-rnns-%D1%96-lstms-%D1%83-%D0%B3%D0%BB%D0%B8%D0%B1%D0%BE%D0%BA%D0%BE%D0%BC%D1%83-%D0%BD%D0%B0%D0%B2%D1%87%D0%B0%D0%BD%D0%BD%D1%96/>

6. LSTMs Explained: A Complete, Technically Accurate, Conceptual Guide with Keras. URL: <https://medium.com/analytics-vidhya/lstms-explained-a-complete-technically-accurate-conceptual-guide-with-keras-2a650327e8f2>

7. Multilayer perceptron and neural networks. URL: https://www.researchgate.net/publication/228340819_Multilayer_perceptron_and_neural_networks

8. Deep Active Learning from the Perspective of Active Learning Theory. URL: https://link.springer.com/chapter/10.1007/978-981-10-5660-4_5

9. Recent advances in deep learning theory URL: <https://arxiv.org/abs/2012.10931>

10. A Novel Road Crack Detection Technology Based on Deep Dictionary Learning and Encoding Networks. URL: <https://www.mdpi.com/2076-3417/13/22/12299>

References

1. Ekolohichniy pasport oblasti - Khmelnytskyi, KhOVA, 2023. URL: https://www.adm-km.gov.ua/?page_id=7157

2. A Comparative Survey of Deep Active Learning. URL: <https://arxiv.org/pdf/2203.13450.pdf>

3. VPP: Visual Pollution Prediction Framework Based on a Deep Active Learning Approach Using Public Road Images. URL: <https://www.mdpi.com/2227-7390/11/1/186>

4. Zghortkova neironna merezha – proste poiasnennia CNN ta yii zastosuvannia. URL: <https://evergreens.com.ua/ua/articles/cnn.html>

5. Shcho taке RNN і LSTM u Deep Learning? URL: <https://www.unite.ai/uk/%D1%89%D0%BE-%D1%82%D0%B0%D0%BA%D0%B5-rnns-%D1%96-lstms-%D1%83-%D0%B3%D0%BB%D0%B8%D0%B1%D0%BE%D0%BA%D0%BE%D0%BC%D1%83-%D0%BD%D0%B0%D0%B2%D1%87%D0%B0%D0%BD%D0%BD%D1%96/>

6. LSTMs Explained: A Complete, Technically Accurate, Conceptual Guide with Keras. URL: <https://medium.com/analytics-vidhya/lstms-explained-a-complete-technically-accurate-conceptual-guide-with-keras-2a650327e8f2>

7. Multilayer perceptron and neural networks. URL: https://www.researchgate.net/publication/228340819_Multilayer_perceptron_and_neural_networks

8. Deep Active Learning from the Perspective of Active Learning Theory. URL: https://link.springer.com/chapter/10.1007/978-981-10-5660-4_5

9. Recent advances in deep learning theory. URL: <https://arxiv.org/abs/2012.10931>

10. A Novel Road Crack Detection Technology Based on Deep Dictionary Learning and Encoding Networks. URL: <https://www.mdpi.com/2076-3417/13/22/12299>