

АВТОМАТИЗОВАНА СИСТЕМА ДІАГНОСТИКИ ДОРОЖНЬОГО ПОКРИТТЯ З КОМПЛЕКСУВАННЯМ ЗОБРАЖЕНЬ

Д.В. Сторожик, А.Г. Протасов

Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського». 03056, м. Київ, Берестейський проспект, 37. E-mail: a.g.protasov@gmail.com

Пропонується система діагностики дорожнього покриття, в основі роботи якої лежить процес опрацювання зображень дефектів, які були отримані у видимому та інфрачервоному діапазонах спектру. До складу системи входять ходові лабораторії на автомобільному шасі, які збирають дані від камер, а також підсистеми обробки зображень і підтримки прийняття рішень. Підсистема обробки зображень забезпечує перетворення отриманих зображень у видимому та інфрачервоному спектрах до формату, придатному для їх комплексування (злиття). Для здійснення операції комплексування було обрано метод злиття зображень з адаптивним визначенням ваг, який реалізовується нейронною мережею. При побудові даної нейронної мережі було використано принцип мультимодальної обробки, де для зображення кожної модальності використовуються свої згорткові шари для виділення ознак, які оцінюються повнозв'язними шарами для визначення вагових коефіцієнтів. Після завершення процедури комплексування отримане зображення передається на підсистему підтримки прийняття рішень, яка класифікує дефекти та встановлює їх геометричні розміри. Для визначення розмірів використовується згорткова нейронна модель, що реалізує процедуру сегментації зображень. У механізмі логічного висновку на основі моделі подання знань, отриманих з бази знань, робиться висновок щодо рівня дефектності ділянки дороги. Кінцевим елементом підсистеми є програмне забезпечення з інтерфейсом користувача, на який виводиться добута інформація з минулих кроків, паспорт дороги, нормативні акти, інформація про минулі ремонтні роботи та дані про бюджетне забезпечення. Бібліогр. 15, табл. 1, рис. 7.

Ключові слова: автоматизовані системи діагностики, нейронні мережі, дорожнє покриття

Вступ. В умовах стрімкого розвитку транспортної інфраструктури та збільшення навантаження на дорожнє покриття автоматизовані системи діагностики набувають особливого значення. Ці системи дозволяють оперативно та точно оцінювати стан дорожнього покриття, значно підвищуючи безпеку дорожнього руху та ефективність управління дорожньою інфраструктурою.

Автоматизація діагностики дорожнього покриття також сприяє значному зниженню витрат. Традиційні методи діагностики часто вимагають значних трудових і фінансових ресурсів. Автоматизовані системи навпаки дозволяють здійснювати швидкий і точний аналіз великих ділянок дороги без потреби у великих командах інспекторів. Це не лише знижує прямі витрати на діагностику, але й підвищує ефективність планування ремонтних робіт, зменшуючи ризик виникнення несподіваних проблем та аварій на дорогах [1].

Враховуючи сучасні екологічні виклики, автоматизовані системи діагностики також відіграють роль у сталому розвитку. Швидке виявлення та усунення дефектів дорожнього покриття сприяє зменшенню вуглецевого сліду, оскільки покращення стану доріг знижує витрати пального та емісії від транспортних засобів.

Інтеграція автоматизованих систем діагностики з іншими смарт-технологіями, такими як інтелектуальні транспортні системи (ITS), відкриває нові

можливості для створення єдиної, ефективної інфраструктури. Це дозволяє не тільки керувати поточним станом доріг, але й прогнозувати майбутні потреби в обслуговуванні, оптимізувати трафік і підвищувати загальну ефективність транспортної системи.

У контексті автоматизованих систем діагностики дорожнього покриття основні виклики полягають у забезпеченні точності даних, ефективності обробки великих обсягів інформації та впливі зовнішніх умов на якість сенсорних вимірювань [2–4]. Точність даних є критичною для правильної оцінки стану доріг, уникнення недооцінки або переоцінки дефектів [5]. Обробка великих баз даних вимагає розробки складних алгоритмів, які можуть ефективно аналізувати та інтерпретувати складні дані. Змінні зовнішні умови, такі як освітлення та погода, можуть істотно впливати на роботу сенсорів, вимагаючи адаптивності системи до різних умов.

Аналіз останніх досліджень і публікацій. У процесі розвитку обчислювальних чіпів та різноманіття архітектури нейромережових моделей часто головним чинником, що впливає на загальну якість процесу, стає якість та інформативність даних [6]. Це обумовлює використання додаткових каналів взаємодії з об'єктом дослідження. Прикладом такого процесу є мультисенсорна діагностика [7, 8]. Доведено, що використання додаткових джерел інформації, отриманих у декількох

спектральних діапазонах, підвищує точність роботи нейронних мереж при обробці зображень [7, 9]. Використання мультисенсорних методів діагностики також дає можливість застосування сучасних методів машинного навчання для автоматизації обробки та оцифрування даних [10].

Сьогодні стало актуальним інтегроване використання камер в видимому та інфрачервоному спектрах [11, 12]. Таке поєднання має дати змогу ліквідувати негативні фактори кожного методу завдяки позитивним параметрам іншого. Так, для фото у видимому випромінюванні важливо мати хороше освітлення, важливу роль відіграє забруднення дорожнього покриття, тіні та засвічення об'єктиву. Для інфрачервоних камер неякісне освітлення і короткострокові тіні не впливають на якість зображення, а також ми отримуємо таку раніше не доступну характеристику, як температура об'єкта, що може посилити аналітичну базу. Однак коливання температури навколишнього середовища, неоднорідність коефіцієнта випромінювання та довгострокові тіні є негативними факторами при тепловій діагностиці [8, 9].

Додатковою проблемою використання мультисенсорних систем є необхідність обробляти кожен канал інформації окремо. Для того, щоб прибрати цей недолік, можна скористатися комплексуванням (злиттям) зображень – поєднанням двох або більше зображень одного об'єкта з метою покращення якості та інформативності результуючого зображення [13, 14]. Як видно з визначення, позитивним ефектом комплексування є підвищення інформативності фінального зображення навіть в умовах, коли інформативність кожного початкового зображення низька [15]. Методи комплексування зображень мають велике різноманіття, однак лідером є клас методів, заснованих на вейвлет-перетворенні [11, 12].

Метою роботи є дослідження можливостей реалізації методів злиття зображень, отриманих в різних спектральних діапазонах, в автоматизованій системі діагностики стану дорожнього покриття.

Виклад основного матеріалу. В основі запропонованої системи діагностики лежить процес опрацювання зображень дефектів, які були отримані у видимому та інфрачервоному діапазонах спектру.

Оцінка інформативності комплексованих зображень може бути оцінена завдяки ентропії Шенона:

$$H(X) = -\sum_{i=1}^n p(x_i) \log_2(x_i),$$

де $p(x_i)$ – імовірність кожного пікселя x_i ; n – кількість можливих значень пікселів.

Взаємна інформація визначається наступним чином:

$$MI(X, Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)},$$

де $p(x)$ – імовірність кожного значення пікселя зображення X ; $p(y)$ – імовірність кожного значення пікселя зображення Y ; $p(x, y)$ – взаємна ймовірність кожного пікселя зображень X і Y .

На рис. 1 показано результат злиття зображення дорожнього дефекту, отриманого у видимому та інфрачервоному діапазонах спектру.

Структуру системи діагностики дорожнього покриття, що пропонується, показано на рис. 2.

До складу системи входять ходові лабораторії на автомобільному шасі, які рухаються по поверхні дорожнього покриття та збирають дані від камер видимого та інфрачервоного спектру. На борту лабораторії також знаходяться GPS трекер і прилади для освітлення дорожньої поверхні. Отримані від камер дані потрапляють на бортовий комп'ютер (ПК) для локального зберігання та передачі інформації до централізованого хмарного сховища. Дані з хмарного сховища відбираються в підсистему обробки зображень для їх попередньої обробки та для реалізації алгоритму комплексування.

Процес попередньої обробки двоспектральних зображень показано на рис. 3.

При обробці теплових зображень послідовно виконуються такі операції: обрізання зображення для видалення неінформативних індикаторів по краях, фільтрація шуму адаптивним медіанним фільтром, збільшення контрасту, замальовування неінформативного індикатора по центру зображення, реєстрація (трансформація) інфрачервоного зображення відносно видимого шляхом використання методу градієнтного спуску та оцінки взаємної інформації. Для обробки зображення ви-




Рис. 1. Зображення дефекту дорожнього покриття: а – у видимому спектрі; б – у інфрачервоному спектрі; в – комплексоване зображення




Рис. 2. Структура автоматизованої системи діагностики стану дорожнього покриття

димого спектра використано лише одну операцію – зменшення роздільної здатності.

Останнім перетворенням у підсистемі обробки зображень є комплексування зображень на базі вейвлет-перетворення, яке поєднує інформаційні характеристики зображень обох спектрів. Для здійснення операції комплексування було обрано метод злиття зображень з адаптивним визначенням ваг. Алгоритм реалізації методу полягає у наступному:

1. Реалізовується вейвлет-перетворення для кожного зображення:

$$W_A = \text{wavelet}(A); W_B = \text{wavelet}(B),$$

де W_A і W_B – вейвлет-коефіцієнти для зображень A і B відповідно.

2. Для визначення вагових коефіцієнтів на основі вейвлет-коефіцієнтів використовується нейронна мережа NN :

$$\alpha, \beta = NN(W_A, W_A, \theta),$$

де α і β – вагові коефіцієнти для кожного вейвлет-коефіцієнта W_A і W_B відповідно, θ позначає

параметри нейронної мережі, які оптимізуються для максимізації інформативності результуючого зображення F .

Цільова функція для оптимізації інформації має вигляд:

$$\theta = \arg \max_{\theta} MI(F; A, B),$$

де $MI(F; A, B)$ – взаємна інформація між результуючим зображенням F і вхідними зображеннями A і B .

Ця функція вимірює ефективність зберігання інформації у злитому зображенні, отриманому від вхідних зображень.

3. Злиття зображень здійснюється з використанням вагових коефіцієнтів:

$$F(x, y) = \text{inverse_wavelet}(\alpha \cdot W_A + \beta \cdot W_B),$$

де «inverse_wavelet» – зворотнє вейвлет-перетворення, яке перетворює вейвлет-коефіцієнти назад у просторовий домен для формування результуючого зображення F .




Рис. 3. Процес обробки зображень в підсистемі

Архітектуру нейронної мережі для методу злиття зображень з адаптивним визначенням ваг показано на рис. 4. Ця мережа складається з двох однакових блоків згорткових шарів для зображення кожного спектру.

Кожен блок має два згорткових шари. Перший шар містить 32 фільтри розміром 3×3 , другий — 64 розміром 3×3 , після кожного згорткового шару виконується макспулінг розміром 2×2 . Завершують мережу три повнозв'язні шари розмірами 128, 62 і 2 нейрони. При побудові даної нейронної мережі було використано принцип мультимодальної обробки, де для зображення кожної модальності використовуються свої згорткові шари для виділення ознак, після чого ознаки оцінюються повнозв'язними шарами для визначення вагових коефіцієнтів.

Після завершення процедури комплексування отримане зображення передається разом з координатами GPS на підсистему підтримки прийняття рішень, де зображення попередньо класифікують відповідно до типу дефекту (класифікацію виконує згорткова нейронна мережа), після чого

інформацію відправляють, залежно від класу, на відповідну нейронну модель для встановлення геометричних розмірів дефекту дороги. Для цього використовується згорткова нейронна модель, що реалізує процедуру сегментації зображень (рис. 5).

Цей нейромережевий класифікатор, побудований для обробки та класифікації зображень, використовує глибокі згорткові нейронні мережі (CNN). Його структура складається з кількох етапів обробки даних: попередньої обробки, кількох конволюційних блоків для витягування ознак, залишкових блоків для збереження градієнта під час навчання та повнозв'язних шарів для кінцевої класифікації. Вхідний шар зменшує розмір зображень до 256×256 пікселів для оптимізації обчислювальних ресурсів.

Основна робота нейромережі виконується в конволюційних блоках, де перші два блоки використовують фільтри 3×3 для витягування основних і детальних ознак, застосовуючи активацію ReLU і нормалізацію партій (Batch Normalization) для стабільності. Залишкові блоки з більшим числом фільтрів застосовують принцип залишкового зв'язку для покращення здатності до навчання. У результаті плоский шар перетворює виходи конволюційних шарів у вектор, який передається на повнозв'язні шари, що виконують кінцеву класифікацію. Завершується модель вихідним шаром з активацією Softmax для багатокласової класифікації, генеруючи ймовірності для кожного з шести класів.

Дані GPS, комплексоване зображення, клас дефекту, площа дефекту записуються в базу даних для зберігання. У механізмі логічного висновку на основі моделі подання знань, отриманих з бази знань, робиться висновок щодо рівня дефектності ділянки дороги. Фрагмент продукційної моделі подання знань для підсистеми підтримки прийняття рішень показано в таблиці.




Рис. 4. Архітектура нейронної мережі для реалізації методу злиття зображень з адаптивним визначенням ваг




Рис. 5. Архітектура згорткової нейронної мережі для класифікації дефектів дорожнього покриття

Фрагмент продукційної моделі подання знань

Умова	Висновок
Тип дефекту = тріщина загальна поперечна	Характер дефекту = лінійний і коефіцієнт вагомості $K_v = 0,08$ і коефіцієнт приведення до площі $K_s = 0,15$
Тип дефекту = тріщина повздовжня	Характер дефекту = лінійний і коефіцієнт вагомості $K_v = 0,1$ і коефіцієнт приведення до площі $K_s = 0,1$
Дефектність дорожнього покриття > 50 %	Рівень дефектності = критичний




Рис. 6. Інтерфейс користувача

Кінцевим елементом підсистеми є програмне забезпечення з інтерфейсом для користувача (рис. 6). Інтерфейс забезпечує зручний аналіз і прийняття рішення щодо проведення ремонтних робіт. На нього виводиться добута інформація з минулих кроків, паспорт дороги, нормативні акти, інформація про минулі ремонтні роботи та дані про бюджетне забезпечення. Дані щодо бюджетного планування дозволять операторам враховувати фінансові обмеження при прийнятті рішень про ремонт.

Користувач на основі наявних даних приймає рішення щодо ремонтних робіт. Після чого, виходячи з графіку ремонтних робіт, відправляється бригада усунення дефектності (підсистема ремонту дорожнього покриття) і цикл повторюється.

Експериментальна перевірка роботи системи. Для перевірки ефективності роботи системи експериментально було зібрано 6000 реальних зображень дорожніх дефектів у двох спектральних діапазонах. При експерименті використовувалась тепловізійна камера Wintact WT3320, що

мала роздільну здатність детектора 320×240 і теплову чутливість 0,07 К, які дозволяли отримувати зображення при температурі повітря, вищій на 15 °С. На рис. 7 продемонстровані деякі з отриманих зображень.

Розроблена система отримала високі оцінки продуктивності обробки великих об’ємів даних, високу адаптивність до різних методів отримання даних за рахунок використання гнучких методів обробки та використанню нейронних мереж. Комбінація даних двох спектрів дозволила отримати високу точність класифікації дефектів дорожнього покриття (більше 95 %) в умовах наявності інформаційних завад. Такі результати дозволяють говорити про високу ефективність розробленої системи діагностики дорожнього покриття.

Висновки

Запропонована автоматизована система діагностики стану дорожнього покриття, яка базується на злитті зображень у двох спектральних діапазонах, дозволила отримати високу точність класифікації дефектів дорожнього покриття (більше 95 %) в умовах наявності інформаційних завад. Експериментальна перевірка системи була реалізована з використанням реальних даних у кількості 6000 зображень, отриманих в оптичному та інфрачервоному діапазонах і яка підтвердила високу продуктивність обробки великих об’ємів даних, а також високу адаптивність до різних методів отримання даних.

Для обробки та класифікації зображень було побудовано нейромережевий класифікатор, який використовує глибокі згорткові нейронні мережі. Висновок щодо рівня дефектності ділянки дороги генерується механізмом логічного висновку на ос-

	Вибійни	Сітка тріщин	Тріщини загальні поперечні	Тріщини повздовжні	Косі тріщини	Бездефектна поверхня
Оптичне зображення						
Теплове зображення						

Рис. 7. Зображення дорожніх дефектів, отриманих експериментально

нові моделі подання знань, отриманих із запропонованої бази знань.

За рахунок використання гнучких методів обробки інформації та застосування нейронних мереж було підвищено ефективність автоматизованого процесу діагностики стану дорожнього покриття.

Список літератури/References

1. Протасов А.Г., Сторожик Д.В. (2023) Технології автоматизації діагностики дорожнього покриття. *Вчені записки ТНУ імені В.І. Вернадського*. Том 34(73), 2, Ч.1, 219–227. DOI: <https://doi.org/10.32782/2663-5941/2023.2.1/35>
2. Protasov, A.G., Storozhik, D.V. (2023) Technologies for automation of road surface diagnostics. *Vcheni Zapysky TNU*, Vol. 34(73), 2, Pt. 1, 219–227. <https://doi.org/10.32782/2663-5941/2023.2.1/35> [in Ukrainian].
3. Su, Y., Kang, S., Chang, J., Hsieh, S. (2010) Using dual lights for robotic pavement inspection. In: *Proceedings of SICE Annual Conference*, Vol. 1.
4. Bystrov, A., Hoart, E., Tran Thuy-Yung et al. (2018) Sensors for automotive remote road surface classification. *IEEE International Conference on Vehicular Electronics and Safety*. DOI: <https://doi.org/10.1109/ICVES.2018.8519499>
5. Elseicy, A., Alonso-Díaz, A., Solla, M. et al. (2022) Combined use of GPR and other NDTs for road pavement assessment: *An Overview Remote Sens.*, 14, 4336. DOI: <https://doi.org/10.3390/rs14174336>
6. Fangyu, L., Liu, J., Wang, L. (2022) Asphalt pavement crack detection based on convolutional neural network and infrared thermography. *IEEE Transactions on Intelligent Transportation Systems*.
7. Sun, Z., Li, L., Liu, L. et al. (2022) On the importance of building high-quality training datasets for neural code search. *Proceedings of the 44th International Conference on Software Engineering*.
8. Rad, R. (2024) Vision transformer for multispectral satellite imagery: Advancing landcover classification. *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*.
9. Sham, J.F.C., Memon, S.A., Lo, T.Y. (2013) Application of continuous surface temperature monitoring technique for investigation of nocturnal sensible heat release characteristics by building fabrics in Hong Kong. *Energy and Buildings*, 58, 1–10. DOI: <https://doi.org/10.1016/j.enbuild.2012.11.025>
10. Solla, M., Lagüela, S., Gonzales-Jorge, H. et al. (2014) Approach to identify cracking in asphalt pavement using GPR and infrared thermographic methods: Preliminary findings. *NDT&E Int.*, 62, 55–65. DOI: <https://doi.org/10.1016/j.ndteint.2013.11.006>
11. Сторожик, Д.В., Протасов, А.Г., Муравйов, О.В. та ін. (2022) Автоматизація процесу теплового неруйнівного контролю шляхом застосування методу комплексування термограм. *Техн. діагност. та неруйнівн. контроль*, 2, 20–23. DOI: <https://doi.org/10.37434/tdnk2022.02.03>
12. Storozhik, D.V., Protasov, A.G., Muraviov, O.V., et al. (2022) Automation of thermal non-destructive testing process by applying the method of complexing thermographs. *Tekh. Diahnost. ta Neruiniv. Kontrol*, 2, 20–23. DOI: <https://doi.org/10.37434/tdnk2022.02.03> [in Ukrainian].
13. Zhang, Dengsheng (2019) Wavelet transform. *Fundamentals of image data mining: Analysis, Features, Classification and Retrieval*, 35–44.
14. Сторожик Д.В., Протасов А.Г. (2022) Технології опрацювання зображень на основі комплексування даних (Огляд). *Техн. діагност. та неруйнівн. контроль*, 4, 17–26. DOI: <https://doi.org/10.37434/tdnk2022.04.03>
15. Storozhik, D.V., Protasov, A.G. (2022) Image processing technologies based on complexing data (Review). *Tekh. Diahnost. ta Neruiniv. Kontrol*, 4, 17–26. DOI: <https://doi.org/10.37434/tdnk2022.04.03> [in Ukrainian].
16. Eisler, K., Homma, C., Goldammer, M. et al. (2013) Fusion of visual and infrared thermography images for advanced assessment in non-destructive testing. *Review Science Instruments*, 84, 064902. DOI: <https://doi.org/10.1063/1.4808280>
17. Changqi Sun, Cong Zhang, Naixue Xiong (2020) Infrared and Visible Image Fusion Techniques Based on Deep Learning: A Review. *Electronics*, 9, 21–62. DOI: <https://doi.org/10.3390/electronics9122162>
18. Линник М.О., Наконечный А.Й. (2023) Методы та алгоритми комплексування зображень і теплових сигналів. *Computer systems and networks*, 5(1), 60–71. DOI: <https://doi.org/10.23939/csn2023.01.060>
19. Linnyk, M.O., Nakonechnyi, A.Y. (2023) Methods and algorithms for complexing images and thermal signals. *Computer systems and networks*, 5(1), 60–71. DOI: <https://doi.org/10.23939/csn2023.01.060> [in Ukrainian].

AUTOMATED ROAD SURFACE DIAGNOSTIC SYSTEM WITH IMAGE COMPLEXING

D.V. Storozhik, A.G. Protasov

NTUU «Igor Sikorsky Kyiv Polytechnic Institute». 37 Beresteysky Ave., 03056, Kyiv, Ukraine.

E-mail: a.g.protasov@gmail.com

The road surface diagnostic system is proposed. The basis of the system operation is processing images of defects that were obtained in the visible and infrared ranges of the spectrum. The system includes running laboratories on the car chassis that collect data from cameras, as well as image processing and decision support subsystems. The image processing subsystem provides conversion of the received images in the visible and infrared spectra to a format suitable for their complexation (fusion). The method of image fusion with adaptive determination of weights, which is implemented by a neural network, was chosen for the implementation of the complexing operation. When building this neural network, the principle of multimodal processing was applied, where each modality is represented using its own convolutional layers to highlight features that are evaluated by fully connected layers to determine weighting coefficients. After the completion of the complexing procedure, the obtained image is transferred to the decision support subsystem, which classifies the defects and establishes their geometric dimensions. To determine the dimensions, a convolutional neural model is used, which implements the image segmentation procedure. In the mechanism of logical conclusion, based on the model of presentation of knowledge obtained from the knowledge base, a conclusion is made regarding the level of defectiveness of the road section. The final element of the subsystem is software with a user interface that displays information obtained from past steps, a road passport, regulatory acts, information on past repair work, and data on budget support. 15 Ref., 1 Tabl., 7 Fig.

Keywords: *automated diagnostic systems, neural networks, road surface*

Отримано 11.07.2024

Отримано у переглянутому вигляді 15.08.2024

Прийнято 24.09.2024