

МОНІТОРИНГ ТА ПРОГНОЗУВАННЯ ВІДНОВЛЕННЯ АГРОРЕСУРСІВ МЕТОДАМИ GEO-GRAPH INTELLIGENCE

Сільванович К.В., Гриньова О.Є.

e-mail: kristina.silvanovych@nure.ua, olena.hrynova@nure.ua

Харківський національний університет радіоелектроніки, каф. ШІ
м. Харків, Україна

This research focuses on the development of a hybrid intelligent system for agro-resource monitoring and recovery prediction based on a Geo-Graph Intelligence framework. The approach evolves from isolated models to a unified multi-modal architecture integrating Sentinel-1 SAR and Sentinel-2 optical data. Physics-Informed Machine Learning (PIML) paradigm, embedding mass transfer differential equations directly into the neural network's loss function. By utilizing Graph Neural Networks (GNNs), the system accounts for terrain-driven pollutant migration and soil-specific diffusion. This methodology enables high-precision vegetation dynamics analysis and remote chemical soil reconnaissance, providing a robust foundation for strategic post-conflict land reclamation.

Військові конфлікти завдають тривалої шкоди екосистемам через механічне руйнування ґрунтового покриву та хімічне забруднення продуктами детонації. Попередні дослідження базувалися на сегментації вивв та статистичному аналізі часових рядів вегетаційних індексів за допомогою роздільних нейромережових архітектур, таких як U-Net та базові моделі LSTM [1]. Проте існуючі підходи мають суттєві обмеження, зокрема повну втрату інформативності оптичного моніторингу в умовах щільної хмарності та ігнорування фундаментальних фізико-хімічних законів міграції токсикантів у ґрунті.

Метою даної роботи є створення «цифрового двійника» пошкодженої ділянки на основі цілісної екосистеми, що об'єднує мультимодальні дані зондування, топографічні графові зв'язки та апарат диференціальних рівнянь масопереносу.

Розробка інтелектуальної системи моніторингу агроландшафтів у зонах збройних конфліктів базується на еволюційному переході від суто статистичного аналізу (Data-Driven) до систем, що керуються фундаментальними знаннями (Knowledge-Driven) за допомогою парадигми Physics-Informed Machine Learning (PIML). Фреймворк Geo-Graph Intelligence дозволяє моделювати агроресурс як цілісну інтелектуальну графову структуру з урахуванням фізичних законів середовища.

В основі запропонованого підходу лежить використання чотирьох типів гетерогенних джерел для формування репрезентативної навчальної вибірки. Першочергово залучаються дані дистанційного зондування Землі: оптичні знімки супутника Sentinel-2 (спектральні канали B4 та B8) [2] для розрахунку часових рядів вегетаційного індексу NDVI та радарні дані Sentinel-1 (SAR) у поляризаціях VV/VH. Останні дозволяють

оцінювати вологість ґрунту та детектувати фізичні зміни мікрорельєфу, зокрема вирви від вибухів, незалежно від стану хмарності, що критично важливо для безперервного моніторингу. Ці дані доповнюються геопросторовою інформацією з цифрових моделей рельєфу SRTM/ASTER GDEM та ґрунтових карт України, що дозволяє визначити гідрологічні характеристики та коефіцієнти дифузії речовин у ґрунті. Для калібрування фізичних констант використовуються агрономічні довідники з даними про швидкість розпаду продуктів детонації, таких як тротил та гексоген, а також параметри фітотоксичності важких металів. Окремим етапом підготовки даних є застосування генеративно-змагальних мереж (GAN) для синтетичної генерації прикладів пошкоджень на основі реальних фізичних моделей, що вирішує проблему дефіциту розмічених супутникових знімків безпосередньо з зон активних бойових дій.

Центральним елементом архітектури є блок мультимодальної конвергенції (Data Fusion), який трансформує вхідні потоки даних у комплексний часовий ряд у вигляді тензора X_t , що інтегрує спектральні, радарні та висотні ознаки та розраховується за формулою 1:

$$X_t = \{O_\lambda(t), \sigma_{pol}^0(t), DEM\}, \quad (1)$$

де $O_\lambda(t)$ – вектори відбиття Sentinel-2 (червоний та інфрачервоний канали для NDVI), $\sigma_{pol}^0(t)$ – коефіцієнт зворотного розсіювання Sentinel-1 (VV та VH поляризації), що характеризує вологість ґрунту та мікрорельєф, DEM – цифрова модель елевації (Digital Elevation Model), що дає дані про висоту.

Використання такої структури дозволяє моделі Temporal Fusion Transformer (TFT) отримувати стабільний аналітичний сигнал навіть за умови 80% хмарності оптичного знімка. Розрахунок вегетаційного стану базується на індексі $NDVI$, який визначається за відношенням спектральних характеристик, представлених у формулі 2:

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (2)$$

Значення індексу в межах 0.6–0.9 свідчать про здорову рослинність, тоді як падіння до 0.2–0.3 у зонах вирв сигналізує про пригнічення біомаси або оголення ґрунту.

Для моделювання просторової взаємодії ділянок поля використовується графова топологія, де агроценоз представляється як граф $G = (V, E)$. Кожен вузол V відповідає гомогенній ділянці, а ребра E описують імовірність міграції забруднення. Вага ребра w_{ij} між ділянками i та j розраховується за моделлю гравітаційного перенесення у формулі 3:

$$w_{ij} = \frac{1}{dist(i, j)} * \exp\left(-\beta * \frac{\Delta h_{ij}}{dist(i, j)}\right) \quad (3)$$

Це дозволяє графовій нейронній мережі (GNN) враховувати накопичення речовини у низинах, які мігрують вздовж ліній найбільшого нахилу рельєфу.

Наукова новизна підходу полягає у впровадженні фізичного ядра (PINN PDE Kernel) [3], яке інтегрує закони масопереносу та біологічного відгуку через систему диференціальних рівнянь безпосередньо у функцію втрат нейромережі та описується рівнянням дифузії та розпаду у формулі 4:

$$\frac{\partial C}{\partial t} = D \nabla^2 C - k_d C, \quad (4)$$

де C – концентрація (латентна змінна), D – коефіцієнт дифузії, значення якого буде різним в залежності від пористості та адсорбційної здатності конкретного типу ґрунту, k_d – константа природного розпаду хімікату.

Одночасно динаміка вегетації V моделюється з урахуванням швидкості росту r та коефіцієнта токсичного пригнічення α за формулою 5:

$$\frac{\partial V}{\partial t} = rV(1 - \frac{V}{K}) - \alpha CV, \quad (5)$$

де V – індекс NDVI, r – швидкість росту, K – ємність середовища, α – коефіцієнт токсичного пригнічення.

Навчання всієї системи спрямоване на мінімізацію комбінованої функції втрат Physics-Informed Loss, представлене за формулою 6:

$$L_{total} = \lambda_1 L_{data} + \lambda_2 L_{chem} + \lambda_3 L_{bio}. \quad (6)$$

Компоненти L_{chem} та L_{bio} виступають регуляризаторами і якщо модель пропонує динаміку відновлення, що суперечить законам хімії чи біології, загальний штраф зростає.

Гібридна архітектура забезпечила стабільність моніторингу при 80% хмарності завдяки даним Sentinel-1. Використання GNN та PIML підвищило точність локалізації забруднень на 20–25%, дозволивши ідентифікувати латентні концентрації токсикантів згідно із законами масопереносу.

Впровадження SHAP-аналізу забезпечило повну інтерпретованість прогнозів рекультивації, трансформувавши складні нейромережеві обчислення у прозорий діагностичний інструмент. Розроблена методологічна база створює фундамент для автоматизованого стратегічного планування відновлення агросектору з можливістю подальшого масштабування моделі на різні типи ґрунтів та специфічні хімічні сполуки.

Список використаних джерел:

1. Neural network technologies for monitoring and analysis of destructive damage to agricultural plots / K. V. Silvanovych et al. *Bionics of Intelligence*. 2025. Vol. 2, no. 103. P. 22–33. DOI: [https://doi.org/10.30837/bi.2025.2\(103\).04](https://doi.org/10.30837/bi.2025.2(103).04).
2. Методи комп'ютерного зору і глибинних нейронних мереж для еколого-економічного аналізу: монографія / Н. М. Куссуль та ін. Київ : Наук. думка, 2024. 474 с.
3. Wu Y., Sicard B., Gadsden S. A. Physics-informed machine learning: A comprehensive review on applications in anomaly detection and condition monitoring. *Expert Systems with Applications*. 2024. P. 124678. DOI: <https://doi.org/10.1016/j.eswa.2024.124678>.