Найвищу очікувану залученість (0,520 %) забезпечує сценарій із пріоритетом каруселей, що на 9,5 % перевищує структуру 2025 р.; відеоорієнтований сценарій дає 0,513 % (+7,9 %). Аналіз чутливості за фіксованої частки Reels (0,40) показує: кожен відсотковий пункт частки, перенесений із зображень до каруселей, збільшує ER_{mix} на (0,55 − 0,37)/100 = 0,0018 в. п., тобто приблизно на 0,4 % від базового рівня. Для приросту на 5 % частку зображень потрібно скоротити з 35 до ≈22 % (приблизно з 7 до 4–5 публікацій на місяць), а каруселей збільшити з 25 до ≈38 %.

Інтерпретуючи результати, слід ураховувати, що ER є непрямим показником: він відображає реакцію аудиторії на візуальний матеріал, а не сам імідж організації. Водночас формат визначає, наскільки повно реалізуються демонстративна й ідентифікаційна функції іміджу – візуалізація цінностей та формування впізнаваного візуального коду [2]. Каруселі лідирують і за переглядами: в усіх п’яти груп акаунтів за кількістю підписників вони мають у 1,5–2,4 раза більше переглядів, ніж статичні зображення [4]. Практичне значення полягає в тому, що наведена розрахункова схема дає змогу SMM-команді організації (зокрема закладу освіти) оцінити очікуваний ефект зміни контент-плану й порівняти власну залученість із загальним орієнтиром до проведення платних експериментів.

Обмеження дослідження: бенчмарки агрегують бренди різних галузей і розмірів, а не організації певного типу; ER враховує лише вподобання та коментарі без збережень і поширень; наведено середні значення без розподілів, тому статистичну значущість відмінностей не перевіряли; зв’язок формату із залученістю не можна трактувати як причинний, адже на нього впливають якість і зміст матеріалів [5]; сценарії припускають незмінність ER форматів за зміни їхніх часток.

Висновки. 1) За даними 2025 р. каруселі (0,55 %) і Reels (0,52 %) перевищують за залученістю статичні зображення (0,37 %); індекс переваги каруселей зріс з 1,22 до 1,49. 2) Середньозважена залученість контент-плану становить 0,475 % і узгоджується з опублікованим середнім 0,48 %. 3) Перенесення частки публікацій із зображень до каруселей чи Reels за незмінного обсягу може підвищити очікувану залученість на 7,9–9,5 % залежно від сценарію. 4) Результати орієнтовні й потребують перевірки на власних даних конкретної організації.

Список використаних джерел

1. Денисюк Ж. З. Візуальна комунікація як феномен масової культури. Вісник Національної академії керівних кадрів культури і мистецтв. 2022. № 2. С. 9-14.

2. Гарматюк О. В., Подзігун С. М. Формування іміджу підприємства засобами маркетингових комунікацій: стратегічні підходи та комунікативні інструменти. Економіка та суспільство. 2025. Вип. 75. С. 174-179. DOI: https://doi.org/10.32782/2524-0072/2025-75-21.

3. Lindgaard G., Fernandes G., Dudek C., Brown J. Attention web designers: you have 50 milliseconds to make a good first impression! Behaviour & Information Technology. 2006. Vol. 25, No. 2. P. 115-126. DOI: https://doi.org/10.1080/01449290500330448.

4. Cucu E. 2026 Instagram organic benchmarks. Socialinsider. 2026. URL: https://www.socialinsider.io/social-media-benchmarks/instagram (дата звернення: 14.10.2026).

5. Li Y., Xie Y. Is a picture worth a thousand words? An empirical study of image content and social media engagement. Journal of Marketing Research. 2020. Vol. 57, No. 1. P. 1-19.

УДК 004.8:631

ІНТЕГРАЦІЯ ІНСТРУМЕНТІВ ШТУЧНОГО ІНТЕЛЕКТУ Й ІНТЕЛЕКТУАЛЬНОГО АНАЛІЗУ ДАНИХ У ПІДГОТОВКУ ФАХІВЦІВ АГРОПРОМИСЛОВОГО КОМПЛЕКСУ (НА ПРИКЛАДІ ПРОГНОЗУВАННЯ СТАНУ ПОСІВІВ ЗА СУПУТНИКОВИМИ ДАНИМИ)

Тетяна Рижкова, Юлія Овсієнко

Полтавський державний аграрний університет, м. Полтава, Україна

Впровадження інструментів Штучного інтелекту (Artificial Intelligence, AI) й Інтелектуального аналізу даних (Data Mining) в агропромисловий комплекс (АПК) є стратегічним пріоритетом, закріпленим у державних ініціативах, зокрема в Стратегії цифрового розвитку інновацій України до

2030 року «WINWIN» [1]. Реалізація ініціатив вимагає від сучасних фахівців навичок ефективно використовувати цифрові інструменти для прийняття управлінських рішень. Відповідно, Міністерство освіти і науки України в актуальних рекомендаціях (2025 р.) визначає формування цифрових компетентностей і відповідальне впровадження AI в освітній процес ключовим завданням закладів вищої освіти (ЗВО). Серед іншого, наголошуючи, що технології мають трансформувати навчання через практико-орієнтовані підходи, а не ізольоване вивчення теорії [2].

Проте аналіз сучасних освітніх програм ЗВО аграрного профілю засвідчує, що дисципліни з Машинного навчання (Machine Learning, ML) часто викладаються на основі синтетичних або абстрактних наборів даних, без використання актуальної локальної інформації (наприклад, супутникових знімків конкретних полів, даних польових сенсорів) і без формулювання конкретних агрономічних завдань (наприклад, розрахунку диференційованих норм внесення добрив). Це знижує готовність випускників застосовувати AI на практиці, попри те, що алгоритми Випадкового лісу (Random Forest), Градієнтного бустингу (Gradient Boosting) і Нейронних мереж (Artificial Neural Networks, ANN) вже успішно використовуються у світовій практиці для моніторингу посівів і прогнозування врожайності за вегетаційними індексами [3; 4]. Вітчизняні дослідження також підтверджують ефективність цих підходів в умовах України: від оцінювання аномалій урожайності до прогнозування врожайності соняшнику на рівні окремих полів [5; 6; 7]. Таким чином, виникає суперечність між вимогами ринку праці, продиктованими державною стратегією, й існуючою методикою викладання, що зумовлює необхідність розробки наскрізних навчальних кейсів на основі реальних геопросторових даних.

Дослідження полягає в обґрунтуванні методичного підходу до інтеграції інструментів AI й Data Mining у підготовку майбутніх фахівців аграрної галузі через наскрізний навчальний кейс прогнозування стану посівів на основі супутникових даних.

Навчальний кейс побудовано за схемою, що має п’ять взаємопов’язаних компонентів: дані, ознаки, модель, оцінювання, рішення. Вихідними даними є знімки Sentinel-2 (рівень обробки L2A) за вегетаційний сезон, дані про врожайність за попередні роки і метеорологічні показники. На першому етапі здобувачі обчислюють нормалізований диференційний вегетаційний індекс за формулою (1):

$$NDVI = \frac{\rho_{NIR} - \rho_{\mathrm{Re}d}}{\rho_{NIR} + \rho_{\mathrm{Re}d}} \qquad (1)$$

де ρ_{NIR}, ρ_{Red} – коефіцієнти відбиття в ближньому інфрачервоному (канал B8) і червоному (канал B4) діапазонах.

Часовий ряд NDVI разом із метеорологічними ознаками (сума активних температур, кількість опадів) формує вектор ознак x. Для прогнозування застосовано регресію Random Forest, прогноз якої є середнім значенням прогнозів окремих дерев рішень, що визначається за формулою (2):

$$\hat{y} = \frac{1}{K}\sum_{k=1}^{K} T_k(x) \qquad (2)$$

де K – кількість дерев у моделі; $T_k(x)$ – прогноз k-го дерева для вектора ознак x.

Якість моделі оцінюють за середньоквадратичною похибкою (RMSE) і коефіцієнтом детермінації (R^2) за формулами (3) і (4):

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \qquad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y}_i)^2} \qquad (4)$$

де y_i – фактичне значення врожайності, т/га; $\hat{y}_i$ – прогнозоване значення; $\bar{y}$ – середнє фактичне значення; n – кількість спостережень.

Методично кейс реалізовано як цикл із чотирьох лабораторних занять у середовищі Python (бібліотеки scikit-learn, rasterio): підготовка й очищення даних; розрахунок індексів і формування ознак; навчання й перехресна перевірка моделі; інтерпретація результатів і формулювання агротехнологічного рішення.

Апробацію навченої моделі передбачено на дослідному полі Полтавського державного аграрного університету (49,70583° пн. ш., 34,53544° сх. д.). На його прикладі продемонстровано розв'язування двох типових завдань професійної діяльності.

Приклад 1. Моніторинг вегетації і прогноз урожайності. Фахівець формує часовий ряд NDVI для поля і за даними до середини вегетації отримує прогноз урожайності за кілька тижнів до збирання. Карта залишків ($y_i - \hat{y}_i$) показує ділянки, де модель систематично помиляється. Це сигнал для польової перевірки: ґрунтової неоднорідності, вимокання, пошкодження шкідниками.

Приклад 2. Прогнозування потреби в добривах. Карту NDVI кластеризують методом *k*-середніх на 3-4 зони з різним станом посівів. Для кожної зони норму азотного підживлення диференціюють за компенсаційною схемою, представленою формулою (5):

$$N_j = N_0 + k\left(\overline{NDVI} - NDVI_j\right) \qquad (5)$$

де N_j – норма азоту для *j*-ї зони, кг/га; N_0 – базова норма для поля, кг/га; $\overline{NDVI}$ – середнє значення індексу по полю; $NDVI_j$ – середнє значення індексу в *j*-й зоні; k – коефіцієнт чутливості, кг/га на одиницю NDVI, що встановлюється за агрохімічними рекомендаціями.

За результатами апробації на дослідному полі отримано RMSE = 0,42 т/га і R^2 = 0,87. Методичну цінність кейсу визначає не лише точність моделі: здобувачі проходять повний цикл роботи з даними, вчаться критично оцінювати прогноз (хмарність знімків, мала вибірка, перенавчання) і пов'язувати результат ML з конкретним агротехнологічним рішенням.

Інтеграцію AI в підготовку фахівців агропромислового комплексу доцільно здійснювати через наскрізні кейси на реальних даних, а не через ізольоване вивчення алгоритмів. Запропонований кейс поєднує розрахунок вегетаційних індексів, регресію Random Forest, кластеризацію і завершується практичним рішенням: прогнозом урожайності і диференційованою нормою добрив.

З метою підвищення прикладної цінності і масштабованості представленого в дослідженні підходу доцільним є: урахування еколого-економічного ефекту: диференційоване внесення добрив на основі ML-моделей дозволяє не лише оптимізувати витрати (економія до 15-20 %), але й суттєво знижувати вуглецевий слід аграрного виробництва, що відповідає глобальним цілям сталого розвитку; робота з неповними даними, коли оптичні знімки Sentinel-2 залежать від хмарності, до навчального кейсу доцільно додати використання радарних даних (Sentinel-1), що забезпечують всепогодний моніторинг вологості ґрунту і біомаси; розвиток Data Literacy, що націлено на розвиток технічних навичок (Python, scikit-learn), кейс формує критичне мислення: здобувачі вчаться розпізнавати Зміщення даних (Data Bias) та інтерпретувати «чорну скриньку» ML-моделі через аналіз Важливості ознак (Feature Importance).

Використання даних дослідного поля університету робить навчання прив'язаним до знайомої локації й придатним до відтворення в інших аграрних закладах освіти.

Список використаних джерел

1. Про схвалення Стратегії цифрового розвитку інновацій України до 2030 року "WINWIN" : розпорядження Кабінету Міністрів України від 14 січ. 2025 р. URL: https://winwin.gov.ua

2. Штучний інтелект у закладах вищої освіти: рекомендації для викладачів, студентів і працівників ЗВО : Міністерство освіти і науки України, 2025. URL: https://mon.gov.ua/news/shtuchnyi-intelekt-u-zakladakh-vyshchoi-osvity-rekomendatsii-dlia-vykladachiv-studentiv-i-pratsivnykiv-zvo

3. Application of machine learning methods and remote sensing data for crop yield forecasting / V. Zatserkovnyi et al. Visnyk of Taras Shevchenko National University of Kyiv. Geology. 2025. No. 4 (111). P. 114-121. DOI: https://doi.org/10.17721/1728-2713.111.13.

4. Aslan M. F., Sabanci K., Aslan B. Artificial intelligence techniques in crop yield estimation based on Sentinel-2 data: a comprehensive survey. Sustainability. 2024. Vol. 16, No. 18. Article 8277. DOI: https://doi.org/10.3390/su16188277.

5. Estimates of crop yield anomalies for 2022 in Ukraine based on Copernicus Sentinel-1, Sentinel-3 satellite data, and ERA-5 agrometeorological indicators / E. Panek-Chwastyk et al. Sensors. 2024. Vol. 24, No. 7. Article 2257. DOI: https://doi.org/10.3390/s24072257.

6. Machine learning in agriculture: a comprehensive updated review / L. Benos et al. Sensors. 2021. Vol. 21, No. 11. Article 3758. DOI: https://doi.org/10.3390/s21113758.

7. Site-specific sunflower yield forecasting based on spatial analysis and machine learning / V. H. Hnatiienko et al. Reports of the National Academy of Sciences of Ukraine. 2025. No. 4. P. 17-26. DOI: https://doi.org/10.15407/dopovidi2025.04.017.

УДК 004.8

ПОРІВНЯННЯ ЛІНІЙНОГО ТА КОСИНУСНОГО ГРАФІКІВ ШУМУ ДЛЯ ВИБОРУ КІЛЬКОСТІ КРОКІВ СЕМПЛЮВАННЯ В ІНФОРМАЦІЙНІЙ СИСТЕМІ ГЕНЕРАЦІЇ ЗОБРАЖЕНЬ НА ОСНОВІ ДИФУЗІЙНИХ МОДЕЛЕЙ

Дмитро Мокан

Миколаївський національний аграрний університет, м. Миколаїв, Україна

Науковий керівник: В. В. Співак,
асистент Миколаївський національний аграрний університет

Дифузійні моделі [1, 4] стали основою сучасних інформаційних систем генерації зображень. Час відповіді такої системи майже пропорційний кількості кроків семплювання, тому цей параметр є ключовим під час проєктування. Графік шуму визначає, як відношення сигнал/шум (ВСШ) розподіляється вздовж процесу, а отже, скільки кроків припадає на область, де зображення майже повністю втрачене [2, 5].

Принцип дифузійних моделей полягає в поступовому додаванні гауссового шуму до зображення в прямому процесі та навчанні нейромережі відновлювати зображення в зворотному процесі [1]. У вихідній постановці DDPM для генерації одного зображення потрібно близько тисячі послідовних викликів мережі, а детерміністичні семплери типу DDIM [3] дозволяють істотно скоротити їх кількість без повторного навчання. Саме тому питання, які кроки зберегти під час скорочення, має практичну вагу для проєктувальника системи.

Типова інформаційна система генерації зображень містить інтерфейс введення запиту, модуль кодування тексту, модуль семплювання, що багатократно викликає нейромережу-денойзер, та декодер; у моделях латентної дифузії [4] семплювання виконується в стисненому латентному просторі, проте кількість викликів денойзера залишається головним чинником затримки. Саме тому модуль налаштування параметрів семплера потребує обґрунтованих критеріїв вибору кількості кроків.

Мета дослідження – кількісно порівняти лінійний [1] і косинусний [2] графіки шуму за розподілом ВСШ уздовж $T = 1000$ кроків та оцінити частку кроків семплювання DDIM [3], що припадає на майже чистий шум.

Дослідження обчислювальне й не передбачає навчання моделі: використано лише аналітичні означення графіків із [1, 2]. У прямому процесі зашумлення зображення x_0 до кроку t має вигляд $x_t = \sqrt{\bar{\alpha}_t}\cdot x_0 + \sqrt{(1-\bar{\alpha}_t)}\cdot \varepsilon$, де ε – гауссів шум, а

$$\bar{\alpha}_t = \prod_{s=1}^{t}(1 - \beta_s) \qquad (1)$$

Для лінійного графіка β_t зростає від 10^{-4} до 0,02 [1]. Для косинусного $\bar{\alpha}_t = f(t)/f(0)$, $f(t) = \cos^2[(t/T + s)/(1 + s)\cdot\pi/2]$, $s = 0{,}008$, $\beta_t = \min(1 - \bar{\alpha}_t/\bar{\alpha}_{t-1}; 0{,}999)$ [2]. ВСШ на кроці t: