



Б. Р. Вишинський, М. М. Сенів

Національний університет "Львівська політехніка", м. Львів, Україна

СИСТЕМА АВТОМАТИЗОВАНОГО ПРОГНОЗУВАННЯ ЗМІН ПЛОЩІ ЛІСОВОГО ПОКРИВУ МЕТОДАМИ ШТУЧНОГО ІНТЕЛЕКТУ

Зміни лісового покриву є одним із ключових екологічних викликів, які впливають на стійкість природних екосистем, баланс вуглецю та ефективність управління лісовими ресурсами. Розглянуто підходи до застосування машинного та глибокого навчання для завдання прогнозування змін лісового покриву на підставі супутникових зображень. Виявлено, що підходи із застосуванням глибокого навчання та геоінформаційного моделювання демонструють найбільшу ефективність прогнозування змін площі лісового покриву. З'ясовано, що поєднання різних методів глибокого навчання у гібридні моделі підвищує ефективність і точність прогнозування. Визначено недоліки сучасних наявних досліджень, зокрема – відсутність механізму інтерпретації результатів та інтеграції карт індексів вегетації. Розроблено комбінований метод із застосуванням згорткових нейронних мереж архітектури U-Net та рекурентних нейронних мереж архітектури LSTM у поєднанні із геоінформаційною моделлю CLUE-S, який дає змогу прогнозувати зміни лісового покриву та визначати індекси, які найбільше впливають на формування прогнозу. Розроблено прототип системи, яка реалізує комбінований метод, та проведено двоетапне навчання нейронної мережі на сформованому наборі даних із 42 локацій території Українських Карпат. Проведено дослідження процесу навчання нейронної мережі та визначено, що перенавчання моделі не відбулось, ефективність моделі настає від 10-12 епох, після чого значення метрик стабілізуються. Визначені показники якості моделі містять значення функції втрат – 0,02711, середньої абсолютної похибки (MAE) – 0,03762 та кореня середньоквадратичної похибки (RMSE) – 0,05096. Визначено, що прогнозування відновлення лісового покриву характерне високою точністю (AUC) – 0,98 та найбільше залежить від індексу NDVI (–0,602), тоді як для зменшення лісистості має помірну точність (AUC) – 0,64 і найбільше пов'язане зі зміною індексу NDRE (0,318), що дало змогу виокремити найбільш інформативні вегетаційні показники для моделі. Сформовано прогнозоване зображення та зображення розміщення змін на актуальному супутниковому зображенні для візуалізації та практичного застосування для керування лісовими ресурсами. Виявлено, що розроблений метод поєднує переваги глибокого навчання, зокрема – точність, та гнучкість в інтеграції додаткових даних для формування прогнозу змін лісового покриву, і результати його застосування можуть слугувати основою для планування превентивних заходів зі запобігання знелісненню та ефективного розподілу ресурсів.

Ключові слова: аналіз супутникових зображень; машинне навчання; рекурентні нейронні мережі; згорткові нейронні мережі; логістична регресія; геоінформаційні моделі.

Вступ / Introduction

Рослини є ключовим елементом біосфери, який забезпечує стабільність клімату, біорізноманіття, регулювання балансу води та захисту ерозії ґрунтів. За оцінками організації FAO (англ. *Food and Agriculture Organization*) [19, 45], у період з 1990 по 2020 рр. Земля втратила близько 420 млн га лісу, що становить понад 10,3 % від світового лісового покриву, а щорічний темп втрат – 10 млн га. Основними причинами таких змін є інтенсивне сільське господарство, незаконне вирубування дерев, урбанізація та лісові пожежі. Зокрема, ця проблема стосується й лісів України, де, згідно зі статистикою [16], приблизно 33 % лісів виконують охоронну функцію, тобто забезпечують екологічний захист довкілля. Лісистість в Україні зростає, але не досягає загального показника 20 %, за якого дерева позитивно

впливають на довкілля.

Згадані вище екологічні проблеми вимагають інструментів для моніторингу та управління лісовими ресурсами, зокрема – із застосуванням сучасних інформаційних технологій. За результатами дослідження [20], глобальний ринок розроблення програмного забезпечення для управління лісами буде зростати із середньорічним темпом 22,39 % у період з 2024 по 2032 роки. Прикладом застосування інформаційних рішень сталого розвитку є інтеграція IoT (англ. *Internet of Things*) [1, 8], штучного інтелекту (ШІ) [10, 50] та супутникових технологій [36, 47] для підвищення ефективності моніторингу лісового покриву.

Моніторинг має певні обмеження у виявленні прихованих або довготермінових процесів. Для подолання цих недоліків застосовують методи прогнозування, які

Інформація про авторів:

Вишинський Богдан Романович, магістрант, кафедра програмного забезпечення. Email: bohdan.vyshynskiy.mpzip.2024@lpnu.ua; <https://orcid.org/0009-0001-4890-9905>

Сенів Максим Михайлович, канд. техн. наук, доцент, кафедра програмного забезпечення. Email: maksym.m.seniv@lpnu.ua; <https://orcid.org/0000-0003-1044-4628>

Цитування за ДСТУ: Вишинський Б. Р., Сенів М. М. Система автоматизованого прогнозування змін площі лісового покриву методами штучного інтелекту. Науковий вісник НЛТУ України. 2025, т. 35, № 6. С. 60–69.

Citation APA: Vyshynskiy, B. R., & Seniv, M. M. (2025). System for automated forecasting of forest cover change using artificial intelligence techniques. *Scientific Bulletin of UNFU*, 35(6), 60–69. <https://doi.org/10.36930/40350607>

дають змогу передбачати потенційні загрози та здійснювати превентивне планування заходів [28, 47]. Для прогнозування потенційних загроз використовують масиви історичних даних і алгоритми для автоматизації відповідних процесів [24, 30], що робить цей підхід масштабованим у довготерміновій перспективі.

Отже, доцільність створення методу прогнозування змін у лісових масивах зі залученням сучасних технологій зумовлена необхідністю переходу від традиційного моніторингу до проактивного управління лісовими ресурсами. Такий метод створює можливості для своєчасного планування лісовідновлювальних заходів, зниження екологічних ризиків та підвищення ефективності управління лісовими екосистемами.

Об'єкт дослідження – автоматизація процесу прогнозування змін площі лісового покриву методами штучного інтелекту.

Предмет дослідження – методи і засоби аналізу супутникових зображень для прогнозування змін площі лісового покриву, що дасть змогу виявити просторово-часові закономірності на зображеннях та сформулювати прогноз змін, а також проаналізувати вплив індексних показників на прогноз.

Мета роботи – розробити метод комплексного прогнозування змін площі лісового покриву на підставі супутникових зображень і карт вегетаційних індексів, який має поєднувати глибоке навчання (згорткові та рекурентні нейронні мережі) та геоінформаційні моделі, що сукупно забезпечить створення прогнозованого зображення майбутнього стану лісового покриву та основу для визначення коефіцієнтів впливу вегетаційних індексів на формування прогнозу.

Для досягнення зазначеної мети визначено такі основні завдання дослідження:

- проаналізувати стан проблеми деградації лісів та підходи до прогнозування змін площі лісового покриву, що дасть змогу визначити переваги та недоліки наявних підходів та аргументувати вибір методів та архітектур моделей машинного навчання для прогнозування змін площі лісового покриву;
- розробити комбінований метод, який поєднує можливості нейронних мереж та геоінформаційних моделей, для автоматизації процесу прогнозування змін площі лісового покриву, що дасть змогу генерувати прогнозоване зображення змін та визначити коефіцієнти впливу вегетаційних індексів на ці зміни;
- розробити прототип системи, який імплементує запропонований комбінований метод, що дасть змогу реалізувати моделі глибокого навчання, провести навчання та отримати результати прогнозування та обчислення коефіцієнтів впливу вегетаційних індексів на прогноз;
- сформулювати навчальний набір даних і провести навчання моделі глибокого навчання для прогнозування змін площі лісового покриву, що дасть змогу визначити параметри навчання та навчити модель для подальшого застосування у прогнозуванні змін;
- здійснити експериментальну перевірку точності комбінованого методу та проаналізувати результати, сформовані розробленим прототипом системи, що підтвердить практичну доцільність застосування розробленого методу для вирішення завдання прогнозування змін площі лісового покриву.

Аналіз останніх досліджень та публікацій. Сучасні дослідження [6, 12, 31] демонструють значний прогрес у використанні автоматизованих методів, особливо машинного навчання та глибокого навчання, для підви-

щення точності, швидкості та масштабованості прогнозів у лісових екосистемах. Автори досліджень вказують на такі недоліки ручного аналізу, як висока трудомісткість та затримки в часі. Автоматизований аналіз має переваги у високій швидкості, можливості обробляти великі обсяги даних та об'єктивності. Недоліками автоматизованого аналізу є залежність від якості даних, потреба у валідації та складність налаштування системи. Автоматизовані алгоритми, наприклад, LandTrendr, VCT (англ. *Vegetation Change Tracker*), CCDC (англ. *Continuous Change Detection and Classification*) на підставі супутникових даних значно перевершують ручний аналіз за швидкістю та масштабованістю, забезпечуючи точність ~80 % для виявлення різних змін у лісах [12].

У працях [2, 27, 32, 43] автори приділяють увагу ланцюгам Маркова (англ. *Markov Chains*), клітинним автоматам (англ. *Cellular Automata*) та поєднанню цих методів SA-Markov для прогнозування змін земного покриву. Дослідження підтверджують, що ці методи залишаються популярними завдяки простоті реалізації та інтерпретованості результатів, однак їх точність (коефіцієнт каппа Коена 81-85 %) може поступатися сучасним підходам, що робить їх обмеженими щодо врахування складних просторових взаємодій та нелінійних процесів.

Автори досліджень [39, 44] застосовують логістичну регресію та байєсові моделі для оцінювання ймовірності зменшення кількості лісу та аналізу впливу показників, таких як рельєф, антропогенний тиск, відстані до краю лісу, доріг та населених пунктів. Моделі на підставі логістичної та байєсової регресії демонструють точність ROC (англ. *Receiver-operating Characteristic Curve*) 80-92 %, що робить їх ефективними для планування заходів із збереження лісів.

У роботах [33, 41] проведено дослідження моделювання змін землекористування на регіональному та локальному рівнях за допомогою моделей CLUE (англ. *Conversion of Land Use and its Effects*) та CLUE-S (англ. *CLUE for Small regional extent*), які враховують попит на типи землекористування, просторову придатність та економічні показники. Ці моделі дають змогу моделювати різні сценарії розвитку та оцінювати наслідки для ландшафтів та агролісів із точністю коефіцієнта каппа 61-81 % та ROC > 80 %. Недоліками такого підходу є високі вимоги до історичних даних, параметризація за допомогою експертних оцінок та обмеження у деталізації переходів, які вирішують вдосконаленою моделлю trans-CLUE-s [26].

Згідно з даними сучасних досліджень [11, 13, 14], методи машинного та глибокого навчання привертають дедалі більше уваги до вирішення завдань сталого розвитку – прогнозування температури, кількості опадів та екстремальних погодних явищ – із високою точністю істинності прогнозів 90-95 %. У такий спосіб машинне навчання перевершує ефективність традиційних методів на 18-22 %. Автори досліджень також підкреслюють виклики під час застосування методів машинного навчання та потребу у високоякісних даних для тренування.

Чимало дослідників [5, 18, 22, 29] застосовують Random Forest та CNN (англ. *Convolutional Neural Network*) для вирішення завдань класифікації та прогнозування у сферах сільського господарства, енергетики та міського планування. Завдяки застосуванню CNN вдалось досягнути зменшення споживчих ресурсів на 18,7

% і операційних витрат на 16,2 %, та отримати високі показники точності у діапазоні 96-99,5 %.

Дослідження [6, 15] розглядають застосування RNN (англ. *Recurrent Neural Network*) для оброблення даних, таких як спектральні канали та послідовності зображень, для прогнозування змін землекористування та лісового покриву. LSTM (англ. *Long Short-Term Memory*) моделі демонструють високу точність у завданнях, які працюють із часовими рядами супутникових зображень та екологічних індексів. Гібридні підходи, які поєднують CNN та LSTM, дають можливість досягати точності понад 95 % у регіональних дослідженнях, що доводить ефективність застосування LSTM для роботи із довготривалими залежностями та нелінійними процесами порівняно із простими RNN. Одним із викликів застосування гібридних підходів машинного та глибокого навчання є принцип "чорної скриньки" – складність обґрунтування рішень моделі, що ускладнює розуміння результатів.

Основні критерії системи прогнозування змін площі лісового покриву за допомогою супутникових зображень містять [24, 28]: високу точність сегментації лісових ділянок; гнучкість в інтеграції мультиспектральних даних; інтерпретованість результатів, зокрема – кількісне подання впливу вхідних даних; можливість використовувати глибокі навчання; здатність працювати з історичними даними (зображеннями та картами); здатність виявляти як втрати, так і відновлення лісу.

У роботах [4, 9, 15] автори використали вегетаційні індекси NDVI (англ. *Normalized Difference Vegetation Index*), NDRE (англ. *Normalized Difference Red Edge Index*), NDMI (англ. *Normalized Difference Moisture Index*) та NBR (англ. *Normalized Burn Ratio*), що дало можливість отримати прогнозовані значення індексів із низькими показниками похибки RMSE (англ. *Root Mean Squared Error* – середньоквадратична похибка) <0,03 та MAE (англ. *Mean Absolute Error* – середня абсолютна похибка) 0,03-0,04.

Отже, проведений аналіз останніх досліджень та публікацій підтверджує ефективність застосування сучасних підходів машинного навчання для вирішення завдань прогнозування змін лісових масивів. Попри значні досягнення дослідників у застосуванні нових методів машинного та глибокого навчання, залишається невирішеним питання інтерпретації отриманих результатів, зокрема – визначення впливу вегетаційних індексів на зміни лісового покриву. Це створює потребу у розробленні методу, що забезпечить високу точність прогнозу, інтерпретацію результатів та кількісну оцінку впливу індексів на прогноз.

Матеріали та методи дослідження. Під час дослідження застосовано методи машинного навчання: згорткові нейронні мережі, рекурентні нейронні мережі та логістична регресія. Прототип системи реалізовано за допомогою методу асинхронного програмування у середовищі Node.js мовою програмування JavaScript (TypeScript). Використано бібліотеку Tensorflow.js для реалізації методів машинного навчання.

Для формування навчальних наборів даних для нейронних мереж та логістичної регресії використано супутникові зображення та карти вегетаційних індексів (NDVI, NDRE, NDMI, NBR) із відкритого інформаційного ресурсу Copernicus Browser [7]. Зображення уніфіковано за форматом та просторовими параметрами:

розмір зображення 1024×1024 пікселів, формат PNG, масштаб 500 м, система координат WGS84. Для навчання нейронних мереж сформовано набір із 378 супутникових зображень 42 локацій лісів Українських Карпат за період серпень-вересень з 2017 по 2025 роки. Для логістичної регресії використано ті самі 42 локації, наведено у форматі карт вегетаційних індексів.

Графіки та таблиці було побудовано із використанням таких програмних інструментів, як Microsoft Excel та Google Sheets.

Результати дослідження та їх обговорення / Research results and their discussion

Опис комбінованого методу U-Net + LSTM та CLUE-S. Запропонований комбінований метод складається із двох частин: системи нейронних мереж та геоінформаційної моделі (рис. 1). Система нейронних мереж наведена поєднанням шарів CNN архітектури U-Net [37] та RNN архітектури LSTM [23]. Комбінація CNN та RNN дає змогу приймати на вході супутникові зображення, вилучати просторові ознаки із зображень, додавати часові залежності до отриманих ознак та отримувати прогнозоване супутникове зображення. Геоінформаційна модель, реалізована за допомогою CLUE-S [48], отримує на вході прогнозоване зображення та карти вегетаційних індексів, а результатом виконання моделі є карти змін лісового покриву на підставі прогнозу, моделі просторової придатності, алокаційна карта змін та вагові коефіцієнти впливу вегетаційних індексів.

Крок 1. Отримання вхідних даних. На першому етапі отримують супутникові зображення для території дослідження L за період $T = \{t_1, t_2, \dots, t_n\}$, де кожне t_i відповідає певному року спостереження. Кожне зображення можна подати як тривимірний масив для t -го періоду [37]:

$$I_t = f_t(x, y, c) \in \mathbb{R}^{H \times W \times C}, \forall t \in T, \quad (1)$$

де: H – висота зображення; W – ширина зображення; C – кількість каналів; x, y – координати пікселя.

Для території дослідження $L \in \Omega$ також формують карти вегетаційних індексів $V = \{v_{j,t} | j = 1..k, i = 1..n\}$.

Крок 2. Створення прогнозованого зображення. Отримані зображення подаються до нейронної мережі U-Net + LSTM. З використанням мережі U-Net на етапі звуження мережі виконується вилучення просторових ознак на зображенні для t -го року [37]:

$$F_t = \text{Encoder}(I_t), \forall t \in T. \quad (2)$$

Послідовність ознак $F_{t_1}, F_{t_2}, \dots, F_{t_n}$ подають до LSTM, яка виявляє часові закономірності змін і повертає прогнозовані просторові ознаки для наступного періоду [23]:

$$\hat{F}_{t+1} = \text{LSTM}(F_{t_1}, F_{t_2}, \dots, F_{t_n}), \forall t \in T. \quad (3)$$

На етапі розширення U-Net отримані ознаки декодуються у зображення [37]:

$$\hat{I}_{t+1} = \text{Decoder}(\hat{F}_{t+1}), \forall t \in T, \quad (4)$$

де \hat{I}_{t+1} – прогнозоване супутникове зображення.

Крок 3. Формування бінарних карт змін. Для виявлення змін формують бінарне покриття для прогнозованого зображення \hat{I}_{t+1} та карти NDVI $v_{1,t}$. Пікселі цих зображень класифікуються за пороговим значеннями τ_p та τ_{NDVI} і формуються відповідні бінарні карти та карта змін [48]:

$$L_{t+1}(i, j) = \begin{cases} 1, \hat{L}_{t+1}(i, j) \geq \tau_p, \forall t \in T, \\ 0, \text{інакше} \end{cases} \quad (5)$$

$$L_{t+1}^{NDVI}(i, j) = \begin{cases} 1, v_{t+1}(i, j) \geq \tau_{NDVI}, \forall t \in T, \\ 0, \text{інакше} \end{cases} \quad (6)$$

$$\Delta L_t(i, j) = L_{t+1}(i, j) - L_t^{NDVI}(i, j), \forall t \in T. \quad (7)$$

Крок 4. Формування логістичних моделей придатності. Придатність території будуються на підставі карт вегетаційних індексів та використовується логістична модель придатності – ймовірність переходу пікселів з одного класу в інший. У такий спосіб модель визначає території, які більш схильні до певного типу зміну.

Нагадаємо, логістична модель придатності, або логістична функція придатності (англ. *Logistic Fit Model*), це математичний інструмент еволюційних алгоритмів (на-

приклад, генетичних), що оцінює, наскільки добре певний розв'язок (індивід) відповідає заданим критеріям (приспосованості), перетворюючи ці критерії в числову вагу для вибору найкращих рішень у процесі оптимізації, наприклад, у задачах управління запасами чи транспорті. Це спосіб дає змогу кількісно визначити "якість" чи "придатність" управлінського рішення (наприклад, ефективність маршруту, мінімізація витрат, швидкість доставки) для подальшого відбору рішення та його покращення.

В нашому випадку логістична модель придатності формує навчальні вибірки для проведення логістичної регресії шляхом побудови бінарних масок та формування так званої матриці ознак, тобто багатовимірного масиву значень усіх індексів, який розгортають у двовимірну матрицю кількості пікселів та кількості ознак.

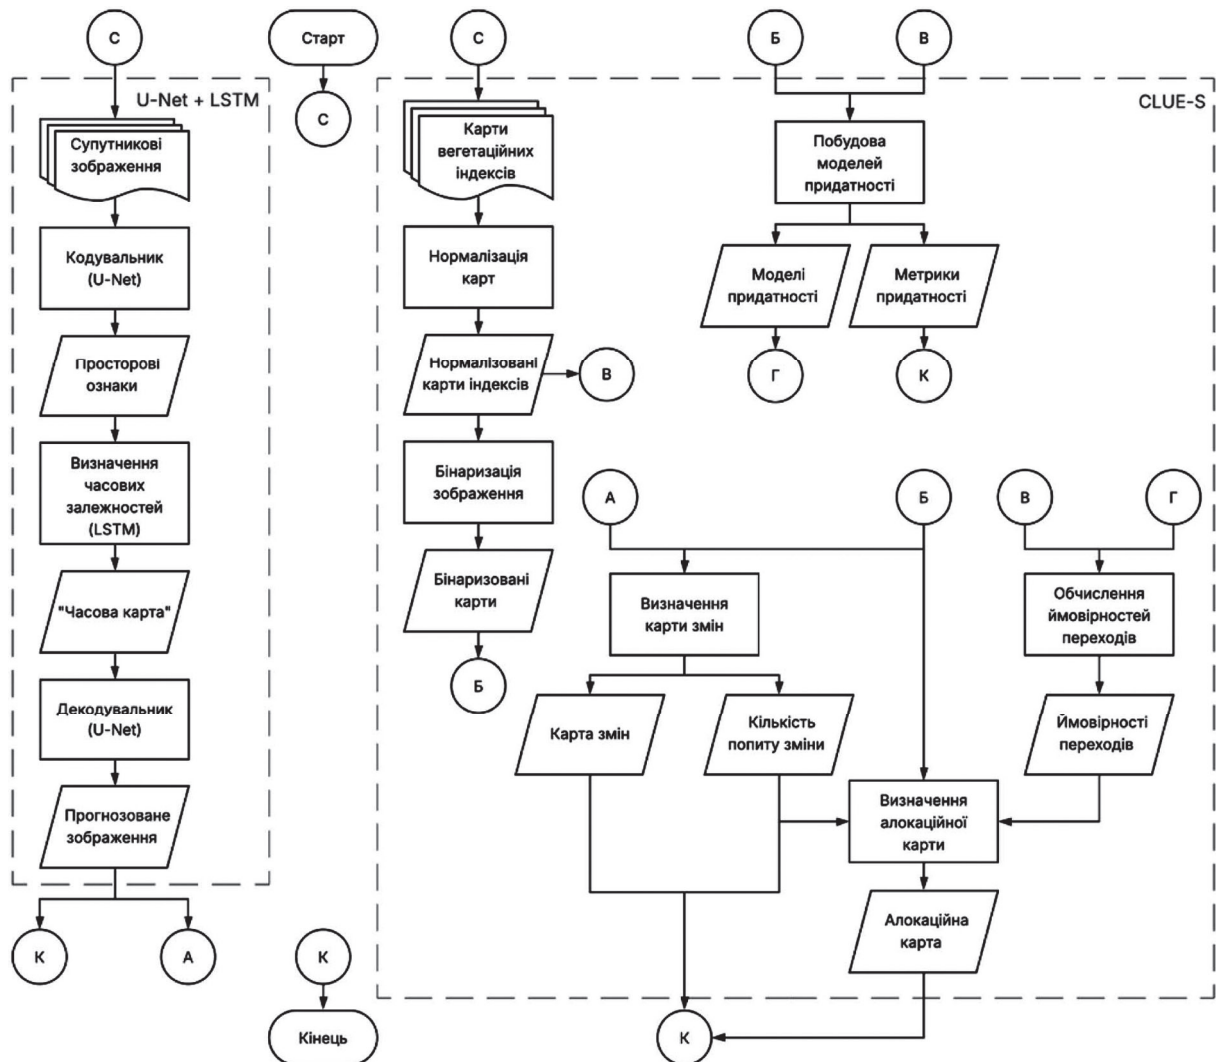


Рис. 1. Комбінований метод U-Net + LSTM та CLUE-S для прогнозування змін лісового покриття / Combined method U-Net + LSTM, and CLUE-S for forest cover change prediction

Формують регресійну модель відповідності, що визначає ймовірність переходу пікселя з одного класу в інший за такою формулою [48]:

$$P(i, j) = \sigma \left(\sum_{k=1}^m w_k x_k(i, j) + b \right), \quad (8)$$

де: $\sigma = 1 / (1 + e^{-z})$ – логістична функція; $x_k(i, j)$ – значення k -го індексу в пікселі; w_k, b – вага k -го індексу та зсув.

Зміна попиту обчислюється як різниця між площею лісу на прогнозованому зображенні та площею лісу на актуальній NDVI-карті [48]:

$$\Delta A_t = \sum_{i=1}^H \sum_{j=1}^W L_{t+1}(i, j) - \sum_{i=1}^H \sum_{j=1}^W L_t^{NDVI}(i, j), \forall t \in T. \quad (9)$$

Крок 5. Формування алокаційної карти змін. На підставі прогнозованих даних формується карта потенційних змін, яка враховує прогнозовану бінарну карту L_{t+1} , карту ймовірностей переходів $P(i, j)$ та зміну попиту ΔA . Алокаційна карта відображає розміщення змін на підставі останнього супутникового зображення [48]:

$$R_t = I_t \circ f(L_{t+1}, P(i, j), \Delta A), \forall t \in T, \quad (10)$$

де \circ – операція накладання зображень.

Архітектура нейронної мережі U-Net + LSTM.
Для моделі прогнозування змін лісового покриву вико-

ристано гібридну архітектуру, яка поєднує U-Net для просторового аналізу супутникових зображень та LSTM для моделювання часових залежностей (рис. 2).




Рис. 2. Схема архітектури нейронної мережі U-Net + LSTM / Diagram of the U-Net + LSTM Neural Network Architecture

Кожне вхідне супутникове зображення, описане у формулі (1), обробляється блоком кодування U-Net, який складається із трьох послідовних згорткових блоків (32, 64 та 128 фільтри) із функцією активації ReLU (англ. *Rectified Linear Unit*). Результатом кодувальника є багатовимірний масив ознак F_t .

Отримані ряди ознак подаються до шару LSTM, який реалізує часову пам'ять моделі і складається із 256 елементів стану (U), які визначають глибину репрезентації часових закономірностей. Цей шар навчають враховувати динаміку змін у лісовому покриві між роками. Результатом виконання LSTM є прогнозований багатовимірний масив ознак \hat{F}_{t+1} .

Прогнозований багатовимірний масив використовують як вхідні дані блоку декодування U-Net, який складається із двох блоків (64 та 32 фільтри), функції активації ReLU і збільшує отриманий масив до розміру

вхідних зображень. На фінальному кроці застосовують згортковий шар із сигмоїдною функцією активації, який перетворює отриманий масив даних у двовимірне прогнозоване зображення \hat{I}_{t+1} .

Формування вхідних даних. Вхідні дані містять окремий тестовий набір для моделі U-Net + LSTM та карти вегетаційних індексів. Тестовий набір складається із серії з 9 уніфікованих супутникових зображень однієї локації у період серпень-вересень з 2017 по 2025 рр., аналогічних за характеристиками до навчального набору даних. Разом із супутниковими зображеннями сформовано карти вегетаційних індексів вибраної локації для розширення інформаційного контексту. Індексні карти (табл. 1) використовують як додаткові вхідні дані для моделі CLUE-S, де вони слугують основою для побудови логістичної регресії, класифікації пікселів та оцінювання ймовірності переходів між класами.

Табл. 1. Порівняльна характеристика вегетаційних індексів (власні узагальнення на підставі авторського аналізу джерел) / Comparative characteristics of vegetation indices (own generalisations based on the author's analysis of sources)

Індекс	Призначення	Інтерпретація	Вплив на прогнозування
NDVI	Визначення щільності та активності зеленої рослинності	Значення від -1 до 1: < 0 – вода, хмари, сніг або нежива поверхня; 0-0,2 – ґрунт або мертва рослинність; 0,2-0,5 – середня рослинність; 0,5-1 – здорова рослинність.	Виявлення змін густоти рослинності у часі
NDRE	Визначення вмісту хлорофілу та ранніх змін у фізіологічному стані рослин	Значення від -1 до 1, зазвичай > 0,3 свідчить про здорову рослинність.	Підвищення точності прогнозів деградації або відновлення лісу
NDMI	Оцінювання вологості рослин і ґрунту	Значення від -1 до 1: < 0 – сухі або вирубані ділянки; 0-0,3 – помірна вологість; > 0,3 – висока вологість.	Враховання водного балансу у прогнозах
NBR	Виявлення наслідків пожеж або вирубування лісів	Значення від -1 до 1: < 0 – сильно пошкоджені території; 0-0,4 – помірно пошкоджені території; > 0,4 – непошкоджена рослинність.	Ідентифікація ділянок після пожеж або вирубок

Метрики оцінювання точності комбінованого методу. Для забезпечення процесу оцінювання ефективності запропонованого комбінованого методу прогнозування змін площі лісового покриву використано такі

показники, як RMSE, MAE та AUC (англ. *Area Under Curve*) [15, 38].

Для оцінювання результатів прогнозування U-Net та LSTM застосовано MAE та RMSE, оскільки ці метрики

дали змогу кількісно оцінити відхилення прогнозованих значень від фактичних і є стійкими до невеликих помилок [15]:

$$MAE = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i), \quad (11)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2}, \quad (12)$$

де: n – загальна кількість пікселів на зображенні; y_i – значення i -го пікселя на фактичному зображенні; \bar{y}_i – значення i -го пікселя на прогнозованому зображенні.

Для оцінювання результатів логістичної регресії в геоінформаційній моделі CLUE-S застосовано показник AUC, який оцінює здатність моделі правильно розрізняти класи, наприклад, пікселі зображення "ліс" та "не ліс". AUC добре працює в умовах дисбалансу класів і не залежить від конкретного вибраного порогу фільтрації [38]:

$$TRP = \frac{TP}{TP + FN}, \quad (13)$$

$$FRP = \frac{FP}{FP + TN}, \quad (14)$$

$$AUC = \int_0^1 TRP(FPR) dFPR, \quad (15)$$

де: TP – кількість правильно передбачених позитивних прикладів; FP – кількість негативних прикладів, помилково визначених як позитивних; TN – кількість правильно передбачених негативних прикладів; FN – кількість позитивних прикладів, помилково визначених як негативних.

Навчання та тестування нейронної мережі U-Net + LSTM. Оскільки для однієї локації доступні супутникові зображення за певний проміжок часу, пряме використання великих наборів даних у навчанні є недоречним. Для цього застосовано метод "ковзного вікна" [25, 40, 51], адаптований для роботи із просторо-часовими даними. Формально цей метод описують через послідовність k вхідних зображень та результуюче зображення [51], а саме:

$$X_t = \{I_1, I_2, \dots, I_t\} \rightarrow Y_t = I_{t+k}, \quad \forall t \in T, \quad (16)$$

де: X_t – вхідна послідовність із k зображень; Y_t – цільове зображення.

Для заданої довжини вікна k та періоду T кількість сформованих послідовностей для однієї локації становить $N = T - k$ і кожна послідовність може бути наведена чотиривимірним масивом вхідних зображень та тривимірним масивом результуючого зображення [51]:

$$X_t \in \mathbb{R}^{H \times W \times C \times k}, \quad \forall t \in T, \quad (17)$$

$$Y_t \in \mathbb{R}^{H \times W \times C}, \quad \forall t \in T. \quad (18)$$

Для довжини вікна $k = 3$ та 42 локацій з періодом спостереження $T = 9$ сформовано 252 послідовності для навчання моделі U-Net + LSTM.

Процес навчання проведено у два етапи: основний та додатковий. Під час основного етапу з інтенсивністю навчання 0,001 упродовж 21 епохи модель визначила загальні структури, а під час додаткового – з інтенсивністю 0,0001 упродовж 15 епох стабілізувала навчання та зменшила ризик перенавчання. Згідно з динамікою параметрів (рис. 3) процес навчання не показав ознак перенавчання (метрики зменшувались синхронно) та отримав найкращу продуктивність після ~10-12 епох.

Навчання проводилось на MacBook Pro (Apple M3 Max, 36 ГБ об'єднаної пам'яті) з використанням MPS-пришвидження із загальним часом 14386571 мс (~14386 с). Остаточні метрики натренованої моделі містять функцію втрат 0,02711, MAE 0,03762 та RMSE 0,05096, що вказує на збалансованість моделі із низьким рівнем систематичних і випадкових помилок.

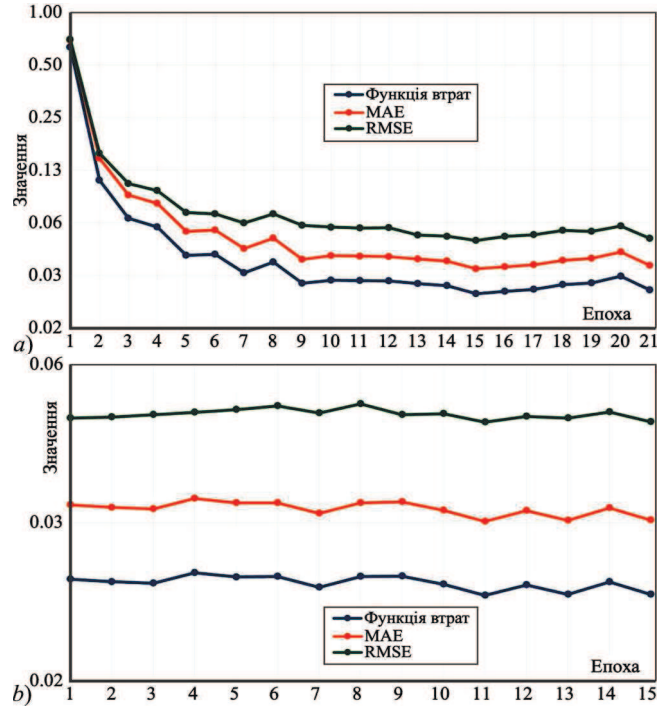


Рис. 3. Зміна значень функції втрат, MAE та RMSE під час основного (a) та додаткового (b) навчання моделі U-Net + LSTM / Variation in loss function values, MAE, and RMSE during main (a) and additional (b) training of the U-Net + LSTM model

Застосування та результати CLUE-S. У моделі CLUE-S використано прогнозоване зображення лісового покриву, отримане із моделі U-Net + LSTM, та вегетаційні карти NDVI, NDMI, NDRE, NBR обраної локації.

Сформовано карти змін та кількість пікселів, які перейшли з одного класу в інший (класи "ліс" та "не ліс") між прогнозованим зображенням та актуальною картою: кількість пікселів зміни "ліс" на "не ліс" – 461, кількість пікселів зміни "не ліс" на "ліс" – 2063.

Визначено коефіцієнти впливу вегетаційних індексів в CLUE-S із відповідними значеннями (табл. 2). Результати свідчать про високу точність (AUC 0,98) моделі під час прогнозування відновлення лісів з найвпливовішим індексом NDVI (-0,602) та помірну точність (AUC 0,64) – прогнозування зменшення лісів з найвпливовішим індексом NDRE (0,318).

Табл. 2. Точність моделі CLUE-S та вагові коефіцієнти вегетаційних індексів для прогнозування змін лісового покриву / CLUE-S Model Accuracy and Vegetation Index Weight Coefficients for Forecasting Forest Cover Changes

Тип зміни покриву	AUC	NDVI	NDMI	NDRE	NBR
З "не ліс" у "ліс"	0,98	-0,602	-0,265	0,261	-0,454
З "ліс" у "не ліс"	0,64	-0,313	-0,171	0,318	-0,132

Сформовано алокаційну карту, яка відображає розміщення змін лісового покриву на підставі актуального супутникового зображення (рис. 4,с), де зелений колір позначає ділянки можливого заліснення, червоний – втрату лісового покриву, синій – стабільні території втрати лісу.




Рис. 4. Порівняння актуального зображення (а), прогнозованого зображення (b) та зображення виявлених змін лісового покриву (с), отриманих комбінованим методом U-Net + LSTM та CLUE-S / Comparison of the current image (a), the predicted image (b), and the detected forest cover change image (c) obtained using the combined method U-Net + LSTM and CLUE-S

Отже, результати проведеного дослідження підтверджують ефективність комбінованого методу прогнозування змін площі лісового покриву на підставі супутникових зображень та карт вегетаційних індексів. Застосування запропонованого методу дало змогу з високою точністю спрогнозувати відновлення лісу та ідентифікувати найвпливовіші індекси, що, на відміну від традиційних методів машинного навчання, дає змогу пояснити внесок окремих індексів у формування прогнозу та створює можливості для подальшого аналітичного опрацювання під час планування лісових ресурсів.

Обговорення результатів дослідження. У дослідженні [42] оцінено надземну біомасу лісу за допомогою CNN, CNN-LSTM та Random Forest на підставі мультиспектральних даних. Автори порівняли застосування обраних методів для оцінювання використаних даних супутників Sentinel-1, Sentinel-2, Landsat-8. Унаслідок гібридна модель CNN-LSTM із мультиджерельними даними досягла найкращої точності коефіцієнта детермінації 0,74, що перевершує результати окремих моделей на 5-10 %.

Автори роботи [49] провели дослідження виявлення змін лісового покриву в Амазонії за допомогою CNN. За допомогою порівняння трьох CNN-архітектур (SharpMask, U-Net та ResNet) із класичними методами машинного навчання (Random Forest) визначили, що ResUnet має найкращі результати за показниками коефіцієнта капша та IoU (англ. *Intersection Over Union*) 0,94 для двох часових інтервалів. CNN-моделі забезпечили кращу деталізацію та не потребували після оброблення для виділення шуму в даних.

У роботі [3] проведено дослідження виявлення змін лісового покриву за допомогою глибокого навчання у провінції Хунань, Китай. Оцінено параметри функції втрат у моделях U-Net++, U-Net, LinkNet, DeepLabV3+ та STANet на багатотемпоральних Sentinel-2 зображеннях. Результатом дослідження є отримана характеристика точності 0,795 для U-Net++, що дає змогу швидко та точно виявляти зміни лісового покриву на великих територіях.

Автори дослідження [35] застосували LSTM та Conv1D для класифікації сільськогосподарських культур за супутниковими даними і порівняли LSTM, XGBoost, Random Forest, SVM для класифікації літніх культур. За результатами Conv1D досягнув найвищої точності (85,54 %), а LSTM – найнижчої (82,41 %), що робить Conv1D доцільним у застосуванні для завдання виявлення сезонних ознак.

У дослідженні [34] автори провели систематичний аналіз методів глибокого навчання для сегментації та виявлення знеліснення за супутниковими зображеннями. Аналіз охоплює моделі U-Net, DeepLab V3, ResNet, FCN та аналіз багаточасових стратегій. Глибокі моделі значно підвищили точність та ефективність виявлення змін, особливо в разі використання багаточасових даних. Автори також вказали на важливість мультиспектральних даних і гнучкість архітектури для оцінювання складних ландшафтів.

Проведене обговорення результатів дослідження показало, що моделі глибокого навчання та їх гібриди демонструють високу точність у завданнях прогнозування, класифікації та виявлення змін лісового покриву. Гібридні моделі та багатоджерельні дані істотно підвищують точність оцінювання змін покриву, а глибоке навчання перевершує класичні алгоритми машинного навчання, особливо в разі застосування складних даних. Важливим напрямом дослідження залишається підвищення інтерпретованості моделей, інтеграція різних типів даних і стійкість до обмежених навчальних вибірок. Проведене дослідження враховує всі ці особливості та пропонує гібридний метод глибокого навчання та геоінформаційного моделювання, який забезпечує як високу точність прогнозування змін лісового покриву, так і можливість інтегрувати дані вегетаційних індексів та пояснити результати прогнозу.

Отже, внаслідок виконаної роботи можна сформулювати такі наукову новизну та практичну значущість результатів дослідження.

Наукова новизна отриманих результатів дослідження – удосконалено метод прогнозування змін площі лісового покриву на підставі оброблення супутникових зображень за допомогою згорткової та рекурентної нейронних мереж і геоінформаційної моделі CLUE-S, який, на відміну від наявних, інтегрує карти вегетаційних індексів та інтерпретує результати прогнозування через показники вагомості їхнього впливу, що дало змогу визначити індекси, які найбільше впливають на формування прогнозованих змін.

Практична значущість результатів дослідження – отримані результати можна безпосередньо застосувати у процесах управління лісовими ресурсами, зокрема – на території Українських Карпат, для підвищення ефективності контролю лісів та визначення зон підвищеного ризику втрати лісового покриву, що створює підґрунтя для планування превентивних заходів із запобігання

зnelісненню та раціонального розподілу наявних ресурсів в умовах їх обмеженості.

Висновки / Conclusions

Розроблено комбінований метод прогнозування змін площі лісового покриву із застосуванням глибокого навчання та геоінформаційної моделі, який дає змогу інтегрувати серію супутникових зображень та карти вегетаційних індексів території лісу для формування прогнозованого зображення, яке визначає критичні зони та вплив індексів на прогнозовані зміни. За результатами проведеного дослідження можна зробити такі основні висновки.

1. Проаналізовано стан проблеми деградації лісів і підходів до прогнозування змін площі лісового покриву та визначено, що попри значні досягнення дослідників у застосуванні нових методів машинного та глибокого навчання залишається невирішеним питання інтерпретації отриманих результатів, зокрема – визначення вегетаційних індексів, що впливають на зміни лісового покриву. Це створює потребу у розробленні методу, що забезпечить високу точність прогнозу, інтерпретацію результатів та кількісну оцінку впливу індексів на прогноз.
2. Розроблено комбінований метод глибокого навчання та геоінформаційного моделювання для автоматизації процесу прогнозування змін площі лісового покриву, який прогнозує та визначає вплив вегетаційних індексів за допомогою супутникових зображень та карт індексів.
3. Розроблено прототип системи, який реалізує комбінований метод за допомогою нейронної мережі U-Net + LSTM та геоінформаційної моделі CLUE-S, для оброблення вхідних зображень, генерації прогнозованої карти змін та обчислення коефіцієнтів впливу вегетаційних індексів.
4. Сформовано навчальний набір із 378 супутникових зображень та проведено двоетапне навчання моделі U-Net + LSTM із застосуванням методу "ковзного вікна", що дало можливість сформувати 252 послідовності зображень для навчання та визначити мінімальну кількість епох, потрібну для досягнення стабільності моделі, яка становить ~10-12 епох.
5. Проведено експериментальну перевірку точності комбінованого методу та проаналізовано результати, сформовані розробленим прототипом системи, які свідчать про збалансованість моделі із низьким рівнем систематичних і випадкових помилок (функція втрат 0,02711, MAE 0,03762 та RMSE 0,05096), а також високу точність (AUC 0,98) визначення територій з потенціалом відновлення лісу з найвпливовішим індексом NDVI (-0.602) та помірну точність (AUC 0,64) ідентифікації територій втрати лісу з найвпливовішим індексом NDRE (0,318). Використання цього методу дає змогу отримувати візуальний прогноз змін площі лісового покриву, оцінювати вплив окремих вегетаційних індексів у формування прогнозу та визначити найбільш інформативні показники індексів.

References

1. Ali, G., Mijwil, M. M., Adamopoulos, I., & Ayad, J. (2025). Leveraging the Internet of Things, Remote Sensing, and Artificial Intelligence for Sustainable Forest Management. *Babylonian Journal of Internet of Things*, 2025, 1–65. <https://doi.org/10.58496/bjiot/2025/001>
2. Asif, M., Kazmi, J. H., Tariq, A., Zhao, N., Guluzade, R., Soufan, W., Almutairi, K. F., Sabagh, A. E., & Aslam, M. (2023). Modeling of Land Use and Land Cover changes and prediction using CA-Markov and Random Forest. *Geocarto International*, 38(1), 1–20. <https://doi.org/10.1080/10106049.2023.2210532>
3. Bairwa, B., Sharma, R., Kundu, A., Sammen, S. S., Alsheri, F., Pande, C. B., Orban, Z., & Salem, A. (2025). Predicting changes in land use and land cover using remote sensing and land change modeler. *Frontiers in Environmental Science*, 13, article ID 1540140. <https://doi.org/10.3389/fenvs.2025.1540140>
4. Bellout, A., Dliou, A., Latif, R., Saddik, A., Cherrat, E. M., & Bouharroud, R. (2025). Machine Learning-Based Prediction and Multispectral Analysis for Precision Irrigation Management. *Statistics, Optimization & Information Computing*, 13(4), 1654–1678. <https://doi.org/10.19139/soic-2310-5070-2178>
5. Boulent, J., Foucher, S., Théau, J., & St-Charles, P.-L. (2019). Convolutional Neural Networks for the Automatic Identification of Plant Diseases. *Frontiers in Plant Science*, 10. <https://doi.org/10.3389/fpls.2019.00941>
6. Casas-Gómez, P., Torres, J. F., Linares, J. C., Troncoso, A., & Martínez-Álvarez, F. (2024). Forecasting basal area increment in forest ecosystems using deep learning: A multi-species analysis in the Himalayas. *Ecological Informatics*, article ID 102951. <https://doi.org/10.1016/j.ecoinf.2024.102951>
7. Copernicus Browser. (n.d.). Copernicus Browser. URL: <https://browser.dataspace.copernicus.eu>
8. Cui, F. (2020). Deployment and integration of smart sensors with IoT devices detecting fire disasters in huge forest environment. *Computer Communications*, 150, 818–827. <https://doi.org/10.1016/j.comcom.2019.11.051>
9. Davidson, C., Jaganathan, V., Sivakumar, A. N., Czarniecki, J. M. P., & Chowdhary, G. (2022). NDVI/NDRE prediction from standard RGB aerial imagery using deep learning. *Computers and Electronics in Agriculture*, 203, article ID 107396. <https://doi.org/10.1016/j.compag.2022.107396>
10. de Bem, P., de Carvalho Junior, O., Fontes Guimarães, R., & Troncoso Gomes, R. (2020). Change Detection of Deforestation in the Brazilian Amazon Using Landsat Data and Convolutional Neural Networks. *Remote Sensing*, 12(6), article ID 901. <https://doi.org/10.3390/rs12060901>
11. de Burgh-Day, C. O., & Leeuwenburg, T. (2023). Machine learning for numerical weather and climate modelling: a review. *Geoscientific Model Development*, 16(22), 6433–6477. <https://doi.org/10.5194/gmd-16-6433-2023>
12. Ding, N., & Li, M. (2023). Mapping Forest Abrupt Disturbance Events in Southeastern China – Comparisons and Tradeoffs of Landsat Time Series Analysis Algorithms. *Remote Sensing*, 15(22), article ID 5408. <https://doi.org/10.3390/rs15225408>
13. Donnelly, J., Daneshkhan, A., & Abolfathi, S. (2024). Forecasting global climate drivers using Gaussian processes and convolutional autoencoders. *Engineering Applications of Artificial Intelligence*, 128, article ID 107536. <https://doi.org/10.1016/j.engappai.2023.107536>
14. Fu, Y., Zhuang, H., Shen, X., & Li, W. (2023). Assessment and prediction of regional climate based on a multimodel ensemble machine learning method. *Climate Dynamics*, 61, 4139–4158. <https://doi.org/10.1007/s00382-023-06787-7>
15. Gao, P., Du, W., Lei, Q., Li, J., Zhang, S., & Li, N. (2023). NDVI Forecasting Model Based on the Combination of Time Series Decomposition and CNN – LSTM. *Water Resources Management*, 37, 1481–1497. <https://doi.org/10.1007/s11269-022-03419-3>
16. General characteristic of Ukrainian forests. (n.d.). State Forest Resources Agency of Ukraine. URL: <https://forest.gov.ua/en/areas-activity/forests-ukraine/general-characteristic-ukrainian-forests>
17. Geng, J., Shen, S., Cheng, C., & Dai, K. (2022). A hybrid spatiotemporal convolution-based cellular automata model (ST-CA) for land-use/cover change simulation. *International Journal of Applied Earth Observation and Geoinformation*, 110, article ID 102789. <https://doi.org/10.1016/j.jag.2022.102789>
18. Geng, Z., Zhang, Y., Li, C., Han, Y., Cui, Y., & Yu, B. (2020). Energy optimization and prediction modeling of petrochemical industries: An improved convolutional neural network based on cross-feature. *Energy*, 194, article ID 116851. <https://doi.org/10.1016/j.energy.2019.116851>
19. Global Forest Resources Assessment. (2020). Global Forest Resources Assessment. Food and Agriculture Organization of the Uni-

- ted Nations. GlobalFRA. URL: <https://www.fao.org/forest-resources-assessment/past-assessments/fra-2020/en/>
20. Global Forestry Management Software Market Size Study, by Deployment Model, by Enterprise Size, by Technology, by Application, and Regional Forecasts 2022-2032. (2024). Global Information, Inc. (GII) – Premium market research reports. URL: <https://www.giiresearch.com/report/bzc1579874-global-forestry-management-software-market-size.html>
 21. Grytsyuk, M. Y., & Gryciuk, Y. I. (2017). The risks analysis in projects management of sustainable tourism development in the Carpathian region of Ukraine. *Scientific Bulletin of UNFU*, 27(5), 164–174. <https://doi.org/10.15421/40270532>
 22. Guhan, T., & Revathy, N. (2024). EMLARDE tree: ensemble machine learning based random de-correlated extra decision tree for the forest cover type prediction. *Signal, Image and Video Processing*, 18, 8525–8536. <https://doi.org/10.1007/s11760-024-03470-0>
 23. Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
 24. Khan, S. H., He, X., Porikli, F., & Bennamoun, M. (2017). Forest Change Detection in Incomplete Satellite Images With Deep Neural Networks. *IEEE Transactions on Geoscience and Remote Sensing*, 55(9), 5407–5423. <https://doi.org/10.1109/tgrs.2017.2707528>
 25. Khandelwal, P., Konar, J., & Brahma, B. (2020). Training RNN and its Variants Using Sliding Window Technique. In: *2020 IEEE International Students Conference on Electrical, Electronics and Computer Science (SCEECS)*. IEEE. 1–5. <https://doi.org/10.1109/sceecs48394.2020.93>
 26. Kiziridis, D. A., Mastrogianni, A., Pleniou, M., Tsiftsis, S., Xystrakis, F., & Tsiripidis, I. (2023). Improving the predictive performance of CLUE-S by extending demand to land transitions: The trans-CLUE-S model. *Ecological Modelling*, 478, article ID 110307. <https://doi.org/10.1016/j.ecolmodel.2023.110307>
 27. Koko, A. F., Yue, W., Abubakar, G. A., Hamed, R., & Alabsi, A. A. N. (2020). Monitoring and Predicting Spatio-Temporal Land Use/Land Cover Changes in Zaria City, Nigeria, through an Integrated Cellular Automata and Markov Chain Model (CA-Markov). *Sustainability*, 12(24), article ID 10452. <https://doi.org/10.3390/su122410452>
 28. Leta, M. K., Demissie, T. A., & Tränckner, J. (2021). Modeling and Prediction of Land Use Land Cover Change Dynamics Based on Land Change Modeler (LCM) in Nashe Watershed, Upper Blue Nile Basin, Ethiopia. *Sustainability*, 13(7), article ID 3740. <https://doi.org/10.3390/su13073740>
 29. Li, X. (2024). A framework for promoting sustainable development in rural ecological governance using deep convolutional neural networks. *Soft Computing*, 28, 3683–3702. <https://doi.org/10.1007/s00500-023-09617-4>
 30. Liu, J., Yue, C., Pei, C., Li, X., & Zhang, Q. (2023). Prediction of Regional Forest Biomass Using Machine Learning: A Case Study of Beijing, China. *Forests*, 14(5), article ID 1008. <https://doi.org/10.3390/f14051008>
 31. Liu, J., Zuo, Y., Wang, N., Yuan, F., Zhu, X., Zhang, L., Zhang, J., Sun, Y., Guo, Z., Guo, Y., Song, X., Song, C., & Xu, X. (2021). Comparative Analysis of Two Machine Learning Algorithms in Predicting Site-Level Net Ecosystem Exchange in Major Biomes. *Remote Sensing*, 13(12), article ID 2242. <https://doi.org/10.3390/rs13122242>
 32. Mallhi, R. K. M., Anand, A., Srivastava, P. K., Kiran, G. S., Petropoulos, P. G., & Chalkias, C. (2020). An Integrated Spatiotemporal Pattern Analysis Model to Assess and Predict the Degradation of Protected Forest Areas. *ISPRS International Journal of Geo-Information*, 9(9), article ID 530. <https://doi.org/10.3390/ijgi9090530>
 33. Mamanis, G., Vrahnakis, M., Chouvardas, D., Nasiakou, S., & Kleftoyanni, V. (2021). Land Use Demands for the CLUE-S Spatiotemporal Model in an Agroforestry Perspective. *Land*, 10(10), article ID 1097. <https://doi.org/10.3390/land10101097>
 34. Mazzia, V., Khaliq, A., & Chiaberge, M. (2019). Improvement in Land Cover and Crop Classification based on Temporal Features Learning from Sentinel-2 Data Using Recurrent-Convolutional Neural Network (R-CNN). *Applied Sciences*, 10(1), article ID 238. <https://doi.org/10.3390/app10010238>
 35. Muhammad, R., Zhang, W., Abbas, Z., Guo, F., & Gwiazdzinski, L. (2022). Spatiotemporal Change Analysis and Prediction of Future Land Use and Land Cover Changes Using QGIS MOLUSCE Plugin and Remote Sensing Big Data: A Case Study of Linyi, China. *Land*, 11(3), article ID 419. <https://doi.org/10.3390/land11030419>
 36. Reiche, J., Hamunyela, E., Verbesselt, J., Hoekman, D., & Herold, M. (2018). Improving near-real time deforestation monitoring in tropical dry forests by combining dense Sentinel-1 time series with Landsat and ALOS-2 PALSAR-2. *Remote Sensing of Environment*, 204, 147–161. <https://doi.org/10.1016/j.rse.2017.10.034>
 37. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (Eds). *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. MICCAI 2015, 9351. Springer, Cham. pp. 234–241. https://doi.org/10.1007/978-3-319-24574-4_28
 38. Saha, S., Saha, M., Mukherjee, K., Arabameri, A., Ngo, P. T. T., & Paul, G. C. (2020). Predicting the deforestation probability using the binary logistic regression, random forest, ensemble rotational forest, REPTree: A case study at the Gumani River Basin, India. *Science of The Total Environment*, 730, article ID 139197. <https://doi.org/10.1016/j.scitotenv.2020.139197>
 39. Sankarrao, L., Ghose, D. K., & Rathinsamy, M. (2021). Predicting land-use change: Intercomparison of different hybrid machine learning models. *Environmental Modelling & Software*, 145, article ID 105207. <https://doi.org/10.1016/j.envsoft.2021.105207>
 40. Shi, X., Huang, G., Hao, X., Yang, Y., & Li, Z. (2022). Sliding window and dual-channel CNN (SWDC-CNN): A novel method for synchronous prediction of coal and electricity consumption in cement calcination process. *Applied Soft Computing*, article ID 109520. <https://doi.org/10.1016/j.asoc.2022.109520>
 41. Sun, C., Bao, Y., Vandansambuu, B., & Bao, Y. (2022). Simulation and Prediction of Land Use/Cover Changes Based on CLUE-S and CA-Markov Models: A Case Study of a Typical Pastoral Area in Mongolia. *Sustainability*, 14(23), article ID 15707. <https://doi.org/10.3390/su142315707>
 42. Sylvain, J.-D., Drolet, G., Thiffault, É., & Anctil, F. (2024). High-resolution mapping of tree species and associated uncertainty by combining aerial remote sensing data and convolutional neural networks ensemble. *International Journal of Applied Earth Observation and Geoinformation*, 131, article ID 103960. <https://doi.org/10.1016/j.jag.2024.103960>
 43. Tariq, A., & Mumtaz, F. (2023). A series of spatio-temporal analyses and predicting modeling of land use and land cover changes using an integrated Markov chain and cellular automata models. *Environmental Science and Pollution Research*, 30, 47470–47484. <https://doi.org/10.1007/s11356-023-25722-1>
 44. Tariq, A., Jiango, Y., Li, Q., Gao, J., Lu, L., Soufan, W., Almutairi, K. F., & Habib-ur-Rahman, M. (2023). Modelling, mapping and monitoring of forest cover changes, using support vector machine, kernel logistic regression and naive bayes tree models with optical remote sensing data. *Heliyon*, 9(2), article ID e13212. <https://doi.org/10.1016/j.heliyon.2023.e13212>
 45. The State of the Worlds Forests. (2020). Food and Agriculture Organization of the United Nations. URL: <https://www.fao.org/state-of-forests>
 46. Torskyi, O. I., & Hrytsiuk, Y. I. (2025). Application of machine learning to enhance the efficiency of automated software testing. *Scientific Bulletin of UNFU*, 35(4), 142–149. <https://doi.org/10.36930/40350416>
 47. Tucker, C. J., & Townshend, J. R. G. (2000). Strategies for monitoring tropical deforestation using satellite data. *International Journal of Remote Sensing*, 21(6-7), 1461–1471. <https://doi.org/10.1080/014311600210263>
 48. Verburg, P. H., Soepboer, W., Veldkamp, A., Limpiada, R., Espaldon, V., & Mastura, S. S. A. (2002). Modeling the Spatial

- Dynamics of Regional Land Use: The CLUE-S Model. *Environmental Management*, 30(3), 391–405. <https://doi.org/10.1007/s00267-002-2630-x>
49. Yang, Z., Tang, C., Cao, X., & Leng, M. (2022). Forest Cover Semantic Change Detection Based on High-Resolution Network Remote Sensing Data. In: *BDIOT 2022: 2022 the 5th International Conference on Big Data and Internet of Things*. ACM. pp. 70–76. <https://doi.org/10.1145/3561801.3561813>
50. Yuh, Y. G., Tracz, W., Matthews, H. D., & Turner, S. E. (2023 b). Application of machine learning approaches for land cover monitoring in northern Cameroon. *Ecological Informatics*, 74, article ID 101955. <https://doi.org/10.1016/j.ecoinf.2022.101955>
51. Zhen, L., Zhang, L., Yang, T., Zhang, G., Li, Q., & Ouyang, H. (2022). Simultaneous prediction for multiple source – loads based sliding time window and convolutional neural network. *Energy Reports*, 8, 6110–6125. <https://doi.org/10.1016/j.egyr.2022.04.041>

B. R. Vyshynskyi, M. M. Seniv

Lviv Polytechnic National University, Lviv, Ukraine

SYSTEM FOR AUTOMATED FORECASTING OF FOREST COVER CHANGE USING ARTIFICIAL INTELLIGENCE TECHNIQUES

Forest cover changes play a crucial role in the ecosystem, which makes this aspect important to maintain. Modern machine learning approaches and geoinformation models show significant results in predicting forest changes. The modern studies show promising results of using hybrid methods that combine different machine learning techniques to achieve greater model accuracy. Current challenges of machine learning techniques for predicting forest cover changes include lack of result interpretation and integration of vegetation indexes into analysis. This study proposes a combined method that integrates convolutional neural network (CNN) based on U-Net architecture and recurrent neural network (RNN) based on LSTM architecture with a geoinformation model CLUE-S to predict forest cover changes and quantify the influence of vegetation indices through their weight coefficients. The combined method is implemented via a software system with two steps of the neural network learning process which uses satellite images of 42 locations in the Ukrainian Carpathians region. The study investigated the process of learning of the neural network, and it has been spotted that no overfitting was present during learning, the model becomes most effective after 10-12 learning epochs. The final metrics of the trained model are loss function – 0.0271, mean absolute error (MAE) – 0.03762 and root mean squared error (RMSE) – 0.05096. The results show high predictive accuracy (AUC) – 0.98 for forest cover recovery with NDVI (–0.602) identified as the most influential index, and moderate accuracy (AUC) – 0.64 for forest cover loss with NDRE (0.318) as the most influential index. The results also include predicted satellite image of forest cover changes that can be practically used for further planning in forest management system. As the result, the proposed combined method demonstrates both the high accuracy characteristic of modern machine learning approaches and the flexibility required for integrating additional external data into forest change prediction. The outcomes of this study may serve as a foundation for informed planning of preventive measures against deforestation and for the effective allocation of limited resources.

Keywords: satellite image analysis; machine learning; recurrent neural networks; convolutional neural networks; logistic regression; geoinformation models.