

Ляшенко С. О.¹,
Фесенко А. М.¹,
Кісь В. М.¹,
Кісь М. В.¹,
Євстратов М. Д.²

¹Державний біотехнологічний
університет,

Е-mail:

lyashenkosa05@ukr.net

alla.ecology3006@gmail.com

vkisprof@ukr.net

²Харківський національний
університет радіоелектроніки
м. Харків, Україна

Е-mail:

mykola.yevstratov@nure.ua

**ОБҐРУНТУВАННЯ ЕФЕКТИВНОСТІ
УПРАВЛІННЯ БЕЗПІЛОТНИМИ
ЛІТАЛЬНИМИ АПАРАТАМИ ДЛЯ
ПОТРЕБ СІЛЬСЬКОГОСПОДАРСЬКОГО
ВИРОБНИЦТВА НА ОСНОВІ
ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖЕВОВОГО
ПІДХОДУ**

DOI: <https://doi.org/10.31359/2311-441X-2025-27-67>

УДК 631:004.81; 004.9:63

Ляшенко С.О., Фесенко А.М., Кісь В.М., Кісь М.В., Евстратов М.Д.
Обґрунтування ефективності управління безпілотними літальними апаратами для потреб сільськогосподарського виробництва на основі застосування нейромережевого підходу

Анотація. Важливим вектором розвитку сільськогосподарського виробництва є використання штучного інтелекту та автоматизованих систем керування в різних галузях агробізнесу. Головними складовими застосування автоматизованих систем управління є ефективність, спрощення та безпечність людської праці у сільськогосподарському виробництві на різних роботах. Застосування нейромережевого підходу у системі керування різними автоматизованими системами та механізмами дає можливість підвищити ефективність робочого процесу. Метою роботи є підвищення точності траєкторії польоту дрона шляхом розроблення моделі прогнозування траєкторії на основі нейромережевого підходу. За використання набору відеоматеріалів для навчання нейронної мережі було розроблено модель для прогнозування траєкторії польоту БПЛА. За допомогою інструменту 3D-моделювання Blender було створено набір даних, що відображає різні умови навколишнього середовища. Архітектура нейронної мережі включає блоки довготривалої короткочасної пам'яті (LSTM), які здатні обробляти послідовні дані. Це робить їх ідеальними для прогнозування динамічної траєкторії руху БПЛА.

Отримані результати свідчать, що нейронна мережа показує кращу продуктивність у реальних сценаріях порівняно з традиційними методами прогнозування траєкторії. Інтеграція LSTM дозволила ефективно навчатися та узагальнювати часові дані, фіксуючи складні рухи і взаємодію з навколишнім середовищем. Це дослідження не тільки демонструє можливість використання нейромережевого навчання для прогнозування траєкторії БПЛА, але й управління діями худоби, автоматизованого збирання і сортування врожаю, управління рослинами і ґрунтом тощо. Крім того, прогнозування траєкторії в реальному часі може значно підвищити ефективність і швидкість прийняття рішень. Наукова новизна отриманих результатів полягає в розробці та навчанні моделей на базі нейромережевого підходу спеціально призначених для прогнозування траєкторії польоту дронів. Це дослідження

демонструє ефективність запропонованого підходу і його здатність підвищувати точність прогнозування траєкторії БПЛА.

Ключові слова: сільськогосподарське виробництво; автоматизовані системи керування; нейронна мережа; траєкторія БПЛА; дрони; прогнозування траєкторії; архітектура нейронної мережі; синтетичний набір даних; 3D-модельовання.

Liashenko S., Fesenko A., Kis V., Kis M., Yevstratov M. Substantiation of the effectiveness of unmanned aerial vehicle control for the needs of agricultural production based on the application of a neural network approach

Abstract. An important vector for the development of agricultural production is the use of artificial intelligence and automated control systems in various branches of agribusiness. One of the main components of the application of automated control systems is the efficiency, simplification and safety of human labor in agricultural production in various jobs. The use of a neural network approach in the control system of various automated systems and mechanisms in various jobs makes it possible to increase their efficiency. The aim of the work is to increase the accuracy of predicting the flight trajectory of a drone by developing a trajectory prediction model based on a neural network approach. Based on a set of video materials for training a neural network, a model for predicting the flight trajectory of a UAV was developed. Using the Blender 3D modeling tool, a set of data was created based on the display of various scenarios of environmental conditions. The neural network architecture includes long-short-term memory (LSTM) blocks that are able to process sequential data, making them ideal for predicting the dynamic trajectory of a UAV.

The results show that the neural network showed better performance in real-world scenarios compared to traditional trajectory prediction methods. The integration of LSTM allowed for effective learning and generalization of temporal data, capturing complex movements and interactions with the environment. This study not only demonstrates the possibility of using neural network learning for UAV trajectory prediction, but also livestock management, automated crop harvesting and sorting, plant and soil management, etc. In addition, real-time trajectory prediction can significantly improve the efficiency and speed of decision-making. The scientific novelty of the results lies in the development and training of learning models based on the neural network approach, specifically designed for drone flight trajectory prediction. This study demonstrates the effectiveness of the proposed approach and its ability to increase the accuracy of UAV trajectory prediction.

Keywords: agricultural production; automated control systems; neural network; UAV trajectory; drones; trajectory prediction; neural network architecture; synthetic dataset; 3D modeling.

Вступ.

Агробізнес - це важлива складова української економіки. Наразі агропромисловий комплекс перебуває у процесі трансформації. Інтенсивно запроваджуються сучасні сільськогосподарські технології. Вектор розвитку сільськогосподарського виробництва спрямований від традиційного землеробства до точного та експериментального, побудованого на використанні штучного інтелекту та автоматизованих систем управління. Одна з важливих складових застосування автоматизованих систем управління - ефективність, спрощення та безпечність людської праці у сільськогосподарському виробництві. Створення високоінтелектуального виробництва оптимізує тимчасові та трудові ресурси. Розробка високоінтелектуального виробництва дозволить суб'єкту господарювання отримати конкурентні переваги та значний економічний ефект. Застосування технологій штучного інтелекту (ШІ) сприяє розширенню можливостей людини на робочому місці, а в деяких випадках ШІ стає її заміною при виконанні різних робіт у сільськогосподарському виробництві [1, 2].

Аналіз стану справ

Технології ШІ мають значний потенціал для сільськогосподарського виробництва за допомогою аналізу умов проведення робіт у конкретних регіонах та визначення того, що необхідно робити для підвищення ефективності виробництва.

Переваги застосування інтелектуальних технологій керування в сільськогосподарському виробництві, дають можливості покращити роботи з: управління худобою; автоматизованого збирання і сортування врожаю; управління рослинами і ґрунтом; точного фермерства; картографування врожайності; автоматизації зрошення.

Підвищення ефективності управлінських рішень, а також підвищення рівня знань та доступу до інформації пов'язане з можливістю ШІ надавати більш точні прогнози щодо врожайності, цінності та ринкові ризики та ін. Цифрові технології і нове обладнання вже допомагають фермерам і агробізнесам працювати ефективніше, економити кошти і застосовувати більш точні і екологічні методи. Завдяки автоматизації багато завдань тепер виконуються без ручної праці [1-3].

Аналіз значної кількості сучасних досліджень дозволив систематизувати знання про наявні технології ШІ, які проявили себе як успішні методи вирішення проблем у сфері агропромислового виробництва [2-4].

Крім того, використання ШІ та роботизованих механізмів у сільському господарстві може вирішувати і такі важливі завдання, як усунення проблем із кадрами, зменшення шкідливого впливу хімічних засобів на людей та навколишнє середовище, підвищення врожайності оброблюваних культур, збільшення продуктивності підприємств, зниження собівартості агровиробництва. Подальшими етапами дослідження може стати докладне вивчення різних технологій та методів ШІ для пошуку їх найкращого використання у різних сферах людської життєдіяльності (у тому числі у сільському господарстві), визначення їхнього ефективного поєднання між собою та обґрунтування оптимальної внутрішньої структури [3, 4].

Завдяки застосуванню штучного інтелекту автоматизація сільського господарства дає можливість зменшувати ризики для самих фермерів і пришвидшувати їх роботу. Для успішного застосування ШІ використовується велика кількість даних, що дає можливість побудувати моделі для штучного інтелекту та машинного навчання. Це допоможе, наприклад, обрати правильний час для сівби насіння, визначити набір культур, вибір гібридного насіння для отримання більшого врожаю тощо. Розглянуті системи штучного інтелекту можуть допомогти покращити загальну якість отриманого врожаю. Крім того, розробка автоматизованих механічних систем, які використовують комп'ютерний зір і штучний інтелект, дасть можливість здійснювати контроль бур'янів шляхом розпилювання різного типу гербіцидів [4-6]. При цьому інтелектуальні механізми зі штучним інтелектом можуть різко скоротити кількість хімічних речовин, що використовуються на полях, і таким чином покращити якість сільськогосподарської продукції та підвищити економічність [6].

Мотивація. Підвищення ефективності виконання різного виду сільськогосподарських робіт, покращення логістики вантажів, збереження навколишнього середовища підкреслюють нагальну потребу в розробці та впровадженні інноваційних технологічних рішень для розвитку технологічних можливостей [4, 5].

Більшість методів прогнозування поведінки динамічних систем базуються на використанні інформації про параметри математичних моделей та властивості середовища. Однак відсутність такої апріорної інформації призводить до неефективності використання традиційних параметричних методів, а часто й до їх непрацездатності. Крім того, наявність нестационарності, нелінійності та різних видів невизначеностей у моделях реальних систем призводить до неефективності використання традиційних

непараметричних методів. За цих умов найефективнішим підходом є використання сучасних методів обчислювального інтелекту, зокрема нейронних мережових методів.

Нейромережовий підхід до використання дронів залишається актуальним. Він надає можливість запобігти неідеальному людському фактору та впроваджувати сучасні технології. Інтелектуальне розпізнавання нейронною мережею об'єктів, що використовуються у сільськогосподарському виробництві, за допомогою таких пристроїв як дрони, може здійснюватися в автономному режимі без присутності людини, а це підвищує ефективність [6].

Існують такі типи інформаційних технологій, що використовуються в сільському господарстві: технології точного сільського господарства; технології прогнозування врожайності сільськогосподарських культур та проведення моніторингу стану полів у режимі реального часу; обробка полів проти шкідників та бур'янів БПЛА; інформаційні технології прийняття управлінських рішень у сільському господарстві [5].

У сучасному світі, де інформаційні технології розвиваються надзвичайними темпами, важливи питанням сучасності є розробка рішень по застосуванні ефективних методів виявлення та прогнозування траєкторій БПЛА, які можна використовувати для різних цілей у сільськогосподарському виробництві [6].

Постановка проблеми. В наш час існують різні методи прогнозування траєкторії руху залежно від типу траєкторії руху об'єктів. При цьому виникають декілька проблем, таких як точність прогнозування, де прості моделі погано працюють, якщо навколо багато різнотипних об'єктів. Другою проблемою є відсутність пояснення, де нейронні мережі прогнозують зміну траєкторії, але невідомо, чому вона змінилася. Найбільш сучасні методи прогнозування траєкторії руху у натовпі базуються на моделі, що поєднує фізику процесу та нейронні мережі. Відповідно цього завжди розглядаються три сили: рух до пункту призначення, намагання уникнення зіткнення з іншими перешкодами, а також намагання не зіткнутися з рухаючимися людьми та іншими перешкодами, такими як транспортні засоби тощо [6-8].

Модель навчається на даних, коли люди прискорюються, сповільнюються або опиняються в неприємних ситуаціях, рухаються в неправильному напрямку та змушені змінити пункт призначення. Це робить рухи більш реалістичними та природними, наближаючись до поведінки людей. Було протестувано запропонований метод на реальних траєкторіях та порівняно його продуктивність з існуючими моделями навчання. Модель краще прогнозувала рухи та краще працювала в складних сценах та мала менше зіткнень. Поєднання фізики та нейронних мереж дає кращі результати для людей та потенційно для безпілотних літальних апаратів. Метод Social-NCE дозволяє навчити модель розпізнавати безпечні траєкторії від потенційно небезпечних траєкторій, які можуть спричинити зіткнення, генеруючи негативні вибірки на основі близькості інших об'єктів. Останнім часом безмодельні методи, засновані на глибокому навчанні, демонструють високу точність прогнозування [7-9].

Траєкторія руху неживих об'єктів підпорядковується законам фізики і часто може бути виведена за допомогою формул і рівнянь. Таким чином, виявлення іноді легше передбачити навіть вручну. Наприклад, у дослідженні [7] автори запропонували модель, яка поєднує вдосконалену LSTM, що прогнозує наступну точку траєкторії на основі історії руху та фіксує залежності між кроками в часі. Використовуючи фільтр Калмана визначили, алгоритм LSTM-KF дає хороший ефект. Однак цей підхід не враховує динамічні та екологічні фактори, наприклад, погодні умови, що знижує точність і обмежує застосування в режимі реального часу [7, 8].

Ці методи ефективні у середовищі, в якому були розроблені. Однак вони не реалізуються в повітряних середовищах, і немає достатньо даних для аналізу та висновків за допомогою конкретного методу. У завданнях БПЛА дрони працюють у

тривимірному просторі (3D), де важливі висота, швидкість та кути огляду, і простого слідування траєкторії недостатньо [7, 8].

Ще один підхід до прогнозування траєкторії руху транспортних засобів зосереджений на моделюванні потенційних майбутніх взаємодій між об'єктами. Соціальна LSTM застосовує мережі довгої короткочасної пам'яті (LSTM) для моделювання соціальних взаємодій та навчання на часових даних. LSTM також широко використовується для прогнозування траєкторій руху неживих об'єктів. Інші досліджували рух транспортних засобів і спостерігали, що невизначеність прогнозування виникає через взаємодію з навколишніми об'єктами, коли транспортні засоби змінюють свій маршрут. На основі цього було розглянуто модель з модулем майбутніх відносин (FRM), який оцінює ймовірність того, що транспортні засоби займають сусідні смуги руху та взаємодіють. Модуль обчислює розподіли ймовірностей на рівні смуг руху та потенційні зони взаємодії, використовуючи розподіли графових згорткових мереж (GCN) та гаусової суміші (GM) для моделювання взаємодій, таких як керування поточними дорожніми умовами та демонстрація різних моделей поведінки. Траєкторії можуть змінюватися через взаємодію з навколишніми об'єктами [7, 8].

Предметом дослідження є сучасний підхід з використанням нейронної мережі навчання, спеціально розробленої для прогнозування траєкторії польоту безпілотного літального апарату (БПЛА) [5-8].

Метою роботи є підвищення точності та ефективності прогнозування траєкторії польоту БПЛА в сільськогосподарському виробництві шляхом розробки моделі прогнозування траєкторії польоту на основі нейромережових технологій.

Для отримання очікуваних результатів було використано штучно створений набір даних, що включає анімації, зокрема моделі дронів, а також різні типи фонів та житлових комплексів для урізноманітнення набору даних. Ці анімації були створені за допомогою програми 3D-моделювання Blender, що дозволяє навчати модель в умовах, максимально наближених до реальності, без необхідності використання відеоматеріалів, а також дає можливість застосовувати реальні відео, на яких була протестована навчена нейронна мережа [6-8].

Архітектура нейронної мережі включає блоки довготривалої короткочасної пам'яті (LSTM), які вміють обробляти послідовні дані, що робить їх ідеальними для прогнозування динамічних траєкторій руху БПЛА. Процес навчання включав кілька етапів, починаючи з попереднього навчання, а потім налаштування на специфічні для БПЛА руху та траєкторії [7-9].

У цій роботі описано розробку та реалізацію моделі, побудовану з використанням нейромережового підходу до навчання для прогнозування траєкторії польоту з використанням RCNN навчання та прогнозних LSTM. Основну концепцію цих кроків можна описати наступним чином:

- Дослідження було розділено на роботу з нейронною мережею розпізнавання RCNN, створення набору даних для неї, пошук рідкісних знімків з БПЛА за різних умов та використання програмного забезпечення для створення штучного набору даних з метою розширення та диверсифікації обсягу даних, на яких навчається нейронна мережа.

- При проектуванні розрахункової траєкторії польоту БПЛА було використано нейронну мережу LSTM. Для цього було знайдено матеріали, зокрема відео польоту потрібного об'єкта на тестових базах. Для урізноманітнення даних у програмному забезпеченні було отримано правдоподібні відео, які навчали нейронну мережу краще прогнозувати траєкторію польоту БПЛА. Перелік категорій навчання: розробка набору фото-відео матеріалу для навчання та перевірки; доповнення наборів показників; розробка моделі нейронної мережі; розробка моделі LSTM для прогнозування траєкторій

польоту; використання набору відео-фотоматеріалів для навчання та перевірки з метою розпізнавання та створення траєкторій [7-9].

Навчання нейронної мережі – багатетапний процес, у якому використовувалися як штучно згенеровані анімації, так і реальні кадри для забезпечення моделі різноманітним набором даних, створених за допомогою Blender, складного програмного забезпечення для 3D-моделювання та анімації. Цей інструмент надав нам можливість контролювати такі змінні навколишнього середовища як умови освітлення, фон і траєкторії польоту моделей дронів з високою точністю.

За допомогою Blender моделювались різні погодні умови: від яскравого сонячного світла до похмурого неба, від туманних ранків до дощових вечорів. Текстури та кольори фонового середовища можна змінювати, щоб відобразити різні ландшафти, такі як нерівна місцевість та відкриті поля [7, 9].

Наприклад, основні показники можна представити так:

– масштабні перетворення відображаються за допомогою таких даних, де S – матриця масштабування, застосована до координат зображення (x, y) ; S_x та S_y – масштабні коефіцієнти в горизонтальному та вертикальному напрямках, відповідно; x', y' – нові координати після масштабування;

– перетворення обертання включає поворот зображення на кут, який описується матрицею обертання R ;

– системи частинок Blender можна використовувати для моделювання факторів навколишнього середовища, таких як дощ, сніг або пил, і які можуть впливати на видимість дрона. Рух цих частинок можна описати законами руху Ньютона, де складовими є F – сила, що застосовується до частинок; m – маса частинок; a – прискорення; V – швидкість; x – положення; Δt – зміна часу;

– що стосується освітлення (E), Blender дозволяє динамічно налаштувати освітлення, яке може суттєво вплинути на зовнішній вигляд дрона в анімації. Змінюючи інтенсивність, колір та положення джерел світла, можна відтворити різний час доби, погодні умови та ефекти тіней [7]. Ці умови освітлення можна описати такими параметрами як інтенсивність світла I , кут падіння θ та відстань від джерела світла d , які впливають на освітленість об'єкта відповідно до закону обернених квадратів;

– крім того, освітлення та ефекти навколишнього середовища, такі як тіні та відблиски на корпусі дрона, також були ретельно налаштовані для імітації різного часу доби та погодних умов. Складовими дослідження були: λ – довжина хвилі світла; t – час; $L_0(x, \omega, \lambda, t)$ – яскравість вихідного світла з довжиною хвилі λ у точці x та момент часу t , у напрямку ω ; $L_e(x, \omega, \lambda, t)$ – яскравість випромінюваного світла; $\int_{\Omega} \dots d\omega$ інтеграл по півсфері вхідних напрямків; $f_r(x, \omega, \omega', \lambda, t)$ – двонаправлена функція розподілу відбиття (BRDF), що визначає частку світла з довжиною хвилі λ у момент часу t від напрямку ω' , яке відбивається в напрямку ω у точці x ; $L_i(x, \omega', \lambda, t)$ – яскравість вхідного світла з довжиною хвилі λ від напрямку ω' у момент часу t , $-\omega' * n$ – поглинання вхідного значення заданим кутом [8-10].

Blender також дозволяє моделювати зіткнення та взаємодії між дроном та іншими об'єктами, які можна прогнозувати за допомогою принципів динаміки твердого тіла. Ці взаємодії можуть змінювати траєкторію польоту дрона настільки, що нейронна мережа повинна навчитися розуміти весь спектр потенційної поведінки в реальному світі.

Ці перетворення значно посилюють здатність моделі розпізнавати об'єкти з різних ракурсів та за умов освітлення, які точно імітують мінливість у природних умовах. Завдяки включенню низки доповнених даних нейронна мережа може отримати доступ до ширшого спектру досвіду, тим самим покращуючи її здатність узагальнювати дані від навчальних до реальних застосувань.

Включення цих методів у навчання передбачає випадкове застосування серії перетворень до кожного зображення в наборі даних, перш ніж воно буде передано в нейронну мережу. Це гарантує, що мережа рідко бачить одне й те саме зображення двічі, це зменшує час перенавчання та сприяє розвитку більш загального розуміння ознак, пов'язаних з важливими об'єктами. Зрештою, доповнення даних сприяє створенню більш універсальної та адаптивної моделі, яка може забезпечити надійну продуктивність за різних умов навколишнього середовища та варіацій зовнішнього вигляду об'єктів. Цей процес навчання є фундаментальним для розробки сучасних нейронних мереж, які ефективно функціонуватимуть у динамічних та непередбачуваних реальних сценаріях [8, 9].

Blender створив багато синтетичних сценаріїв з точним контролем над кожним аспектом анімації, що дозволяє моделювати реальні складнощі у віртуальному середовищі. У прагненні до вдосконалення можливостей нейронної мережі для розпізнавання дронів та прогнозування траєкторії було створено детальну анімацію дрона. Високореалістичні та різноманітні схеми польоту слугували навчальним майданчиком для нейронної мережі. У Blender рух дрона анімується за допомогою інтерполяції ключових кадрів, яка визначає початкову та кінцеву точки послідовності рухів, а Blender обчислює проміжні кадри. Для складних маневрів криву анімації можна математично описати за допомогою серії контрольних точок, що утворюють сплайн, зазвичай, сплайн Без'є у 3D-просторі (1):

$$B(t) = \sum_{i=0}^n \binom{n}{i} (1-t)^{n-1} t^i P_i, t \in [0,1], \quad (1)$$

де $B(t)$ – положення дрона на кривій Без'є в момент часу t ;
 P_i – контрольні точки; $\binom{n}{i}$ – біноміальні коефіцієнти.

Ця формула забезпечує плавні переходи між ключовими кадрами та реалістичні траєкторії руху.

Архітектури нейронних мереж. Для цього дослідження було обрано архітектуру, яка могла б забезпечити виявлення об'єктів у відеоматеріалах. Це вимагає високоточних можливостей розпізнавання. Серед різних розглянутих варіантів особливу удагу було приділено архітектурі згорткової нейронної мережі, відомій як RCNN (Region-based Convolutional Neural Networks -згорткової нейронної мережі на базі регіонів). Її було обрано за здатність точно розмежовувати та класифікувати об'єкти на зображеннях та відео. RCNN ефективні у виявленні візуальних шаблонів та структур на зображеннях завдяки своїй здатності до локального сприйняття та ієрархічної обробки інформації. Вони найкраще підходять для обробки статичних зображень та відеоконтакту.

RCNN застосовуються до відео шляхом обробки кожного кадру як окремого зображення, бо вони не враховують часові залежності між послідовними кадрами. Оскільки дослідження не вимагало врахування швидкості об'єктів, відео можна було розділити на окремі кадри. Зрештою, для досягнення цілей була обрана гібридна модель, що поєднує згорткові шари інтелектуальних інформаційних технологій для ефективного сприйняття візуальних шаблонів у кадрах та шари на основі механізмів уваги для обробки часових залежностей у послідовності кадрів. Цей підхід враховує як просторові, так і часові аспекти відеопотоку, забезпечуючи високу точність виявлення об'єктів та прогнозування траєкторії [11].

Дизайн гібридної моделі стратегічно використовує сильні сторони RCNN, компенсуючи водночас їхні обмеження. Завдяки інтеграції механізмів уваги модель отримує здатність відстежувати об'єкти в різних кадрах, що є критично важливим для захоплення руху та прогнозування майбутнього розташування. Такий подвійний фокус

як на безпосередніх візуальних деталях, так і на ширшому часовому контексті створює надійну основу для розуміння та інтерпретації динамічних сцен. Універсальність гібридної моделі робить її потужним інструментом для широкого спектру застосувань, від автоматизованих систем спостереження до передових систем допомоги водієві (ADAS) у транспортних засобах, де точне відстеження об'єктів навколо транспортного засобу може бути життєво важливим для безпеки та навігації.

Як підсумок, цей складний підхід до аналізу відео використовує найновіші досягнення в технології нейронних мереж, тим самим встановлює новий стандарт для точного та ефективного виявлення об'єктів та прогнозування траєкторії. Потенціал цієї технології у новому погляді на те, як ми взаємодіємо з візуальними даними та аналізуємо їх [9-11].

Після того, як модель LSTM згенерувала прогнози для наступного часового кроку, ці прогнози порівнювалися з наземними просторовими координатами дрона. Розбіжності між прогнозованими та фактичними позиціями надають зворотний зв'язок моделі, який використовується для оновлення її параметрів під час процесу навчання. Шляхом ітеративного коригування параметрів на основі цього зворотного зв'язку, LSTM поступово покращувала свою прогностичну точність з часом. Процес навчання та вдосконалення має вирішальне значення для забезпечення того, щоб LSTM ефективно вивчала динаміку рухів дрона та могла робити точні прогнози навіть у складних та непередбачуваних сценаріях. Крім того, здатність LSTM обробляти послідовні дані робить її добре придатною для моделювання динамічних систем, таких як траєкторія дрона, де минулі спостереження суттєво впливають на майбутню поведінку [9-11].

Процес навчання. Процес навчання нейронної мережі можна описати наступною формулою, яка характеризує оновлення ваг мережі на кожному кроці навчання:

$$W_{t+1} = W_t - \alpha * \nabla L(W_t), \quad (2)$$

де W_t – вага моделі на t кроці;
 α – швидкість навчання;
 $\nabla L(W_t)$ – градієнт функції відносно ваги на t кроці.

Навчання проводилося з використанням методу зворотного поширення помилки, що сприяло ефективному налаштуванню вагових коефіцієнтів мережі для мінімізації помилок розпізнавання та прогнозування. Зворотне поширення помилки є основним алгоритмом навчання нейронної мережі, який особливо добре підходить для вирішення складних завдань, що передбачають високий рівень обчислювальної складності, таких як прогнозування траєкторій об'єктів у відеопотоках.

Під час зворотного поширення, після прямого проходу через мережу, де вхідні дані обробляються шар за шаром для отримання вихідного сигналу, обчислюється похибка. Ця похибка є різницею між прогнозованим і фактичним бажаним вихідним сигналом. Алгоритм зворотного поширення потім переходить до обчислення градієнта похибки відносно кожної ваги за правилом ланцюга, поширюючи похибку назад від вихідного шару до вхідного шару. Такий систематичний підхід дозволяє ідентифікувати та виправляти внесок кожної ваги в загальну похибку [8, 9].

Рівняння (2) є фундаментальним компонентом алгоритму зворотного поширення, де W_{t+1} – це оновлені ваги після виконання кроку, керованого градієнтом функції втрат, а α – скаляр, який контролює розмір кроку, відомий як швидкість навчання. Швидкість навчання є критичним гіперпараметром у навчанні нейронних мереж, оскільки вона визначає, наскільки ваги коригуються під час кожного оновлення. Якщо швидкість навчання занадто велика, мережа може перевищити мінімум функції втрат, що призводить до дивергентної поведінки. І навпаки, якщо швидкість навчання занадто

мала, процес навчання може стати надмірно повільним і застрягти в локальних мінімумах.

Гradient $\nabla L(W_t)$ визначає напрямок, у якому функція втрат зростає найшвидше. Тому, щоб мінімізувати втрати, ми рухаємося в протилежному напрямку, тобто віднімаємо gradient від поточних вагових коефіцієнтів. Цей процес повторюється ітеративно протягом багатьох епох або ітерацій, причому кожне оновлення спрямоване на зменшення функції втрат, доки алгоритм не збіжиться до мінімуму, в ідеалі до глобального мінімуму [10, 11].

Крім того, розширюючи цю концепцію, можна ввести інші варіації алгоритму gradientного спуску для покращення процесу навчання. Наприклад, методи на основі імпульсу, такі як SGD з імпульсом можуть допомогти прискорити gradientні вектори в правильному напрямку, тим самим призводячи до швидшої збіжності [10]:

$$V_{t+1} = \beta * V_t + \nabla L(W_t), \quad (3)$$

$$W_{t+1} = W_t - \alpha * V_{t+1}. \quad (4)$$

де V – це швидкість (тобто, накопичений gradient);
 β – коефіцієнт імпульсу, зазвичай приймають у діапазоні від 0,9 до 0,99.

Коефіцієнт імпульсу допомагає згладити оновлення, а також допомагає для більш ефективного управління. Крім імпульсу, такі алгоритми, як RMSprop та Adam вводять адаптивні швидкості навчання для кожного параметра:

$$S_{t+1} = \delta * S_t + (1 - \delta) * (\nabla L(W_t))^2, \quad (5)$$

$$W_{t+1} = W_t - \frac{\alpha}{\sqrt{S_{t+1} + \epsilon}} * \nabla L(W_t). \quad (6)$$

У правилі оновлення RMSprop S_t – це ковзне середнє квадратів gradientів, δ – коефіцієнт спаду, а ϵ – малий скаляр, доданий до знаменника, щоб уникнути ділення на нуль. Цей адаптивний механізм допомагає зменшити gradient ваг, які отримують великі оновлення, що призводить до більш стабільного та ефективного навчання [8-10].

Ретельно розроблені анімаційні дані були створені в Blender та використані для навчання моделі розпізнавати та прогнозувати поведінку дрона під час польоту. Згорткові шари вміло витягують ознаки із зображень та є важливими для інтерпретації візуальної інформації дрона на різних фонах та в умовах освітлення [7, 9]. Операцію згортки в цих шарах можна представити так:

$$(f * g)(t) = \int_{-\infty}^{\infty} f(\tau)g(t - \tau)d\tau, \quad (7)$$

де f – функція зображення, g – функція ядра, $*$ позначає операцію згортки.

Нейронну мережу було навчено за допомогою зворотного поширення помилки, з коригуванням вагових коефіцієнтів для мінімізації похибки між прогнозованим та фактичним положеннями дронів. Як функція втрат могла бути використана середньоквадратична помилка (MSE), яка є стандартною для задач регресії (8):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (8)$$

де y_i – істинне значення (фактичне положення кадру дрона),
 \hat{y}_i – значення, передбачене мережею,
 n – кількість вибірок.

Шляхом ітерації протягом численних епох мережа оптимізує свої ваги, щоб зменшити цю втрату, ефективно навчаючись прогнозувати траєкторію руху дрона на основі анімованих даних. Цей метод не лише забезпечив безпечний та контрольований спосіб генерування навчальних даних, але й дозволив включити сценарії, які можуть бути рідкісними або важкими для захоплення в реальних кадрах, тим самим покращуючи експозицію та досвід нейронної мережі.

Завдяки використанню цих передових методів оптимізації навчання нейронних мереж стає надійнішим та ефективнішим, що дозволяє розробляти складні моделі, вони можуть виконувати широкий спектр завдань від простої класифікації до складних прогнозів траєкторій у динамічних середовищах.

Крім того, цей підхід сприяє постійному вдосконаленню та адаптації, гарантуючи, що нейронна мережа залишається стійкою та адаптивною до змінюваних викликів та середовищ [9-11].

Результати. Модель RCNN була навчена розпізнаванню за допомогою багатоетапного процесу. Спочатку було зібрано значний набір даних, що містить зображення з позначеними екземплярами дронів, де відображено як фактичні відеозаписи свідків, так і зображення зроблені в Blender. Ці зображення потім були використані для попереднього навчання моделі на загальних візуальних ознаках за допомогою таких методів, як навчання з викладачем за допомогою згорткових нейронних мереж (CNN). Під час навчання модель навчилася розрізняти різні об'єкти, включаючи дрон, шляхом ітеративного налаштування своїх параметрів для мінімізації заделегідь визначеної функції втрат. Продуктивність навченої моделі RCNN оцінювалася за допомогою окремих наборів даних ваалідації та вимірювання таких показників, як точність, повнота та середня точність (mAP) на різних зображеннях. Відповідно ітеративного процесу навчання модель RCNN досягла високої точності розпізнавання дронів на зображеннях, демонструючи свою ефективність у реальних застосуваннях [7-9].

З метою підвищення точності моделі для об'єктів різних масштабів та розмірів може знадобитися точне налаштування. Більш точні параметри результатів представлені в таблиці 1.

Для розрахунку середньої точності (mAP) та середньої повноти (mAR) усереднили значення AP та AR по всіх класах та областях зображення.

Спочатку усереднимо значення AP по всіх класах та областях зображення наступним чином:

$$mAP = \frac{(77 + 65 + 82 + 45 + 71 + 73)}{6} = 68,5$$

Тепер усереднимо значення AR по всіх класах та областях зображення:

$$mAR = \frac{(65 + 69 + 78 + 40 + 71 + 78)}{6} = 66,83$$

Таким чином, середня точність (mAP) становить приблизно 68,5, а середня повнота (mAR) – приблизно 66,83.

Прогнозування траєкторії руху. Траєкторія руху прогнозується на основі даних про траєкторію, наданих усіма дронами. Вважається, що кожна сцена проходить попередню обробку, що дає просторові координати для кожного i -го об'єкта в момент часу t [9].

Таблиця 1

Виміри для оцінки якості моделі

Виміри	IoU розрахунок	Максимальне виявлення	Площа	Значення, %
Середня точність (AP)	0,50:0,95	100	всі	77
Середня точність (AP)	0,50	100	всі	65
Середня точність (AP)	0,75	100	всі	82
Середня точність (AP)	0,5:0,95	100	мала	45
Середня точність (AP)	0,5:0,95	100	середня	71
Середня точність (AP)	0,5:0,95	100	велика	73
Середня відгук (AR)	0,5:0,95	1	всі	65
Середня відгук (AR)	0,5:0,95	10	всі	69
Середня відгук (AR)	0,5:0,95	100	всі	78
Середня відгук (AR)	0,5:0,95	100	мала	40
Середня відгук (AR)	0,5:0,95	100	середня	71
Середня відгук (AR)	0,5:0,95	100	велика	78

Попередньо оброблена інформація отримується із зображень, які представлені в обмежувальних рамках, що охоплюють відповідні об'єкти дослідження. Вхідні дані містять вектор координат $\{x_t, y_t\}$, який дає уявлення про мінімальну та максимальну просторову протяжність об'єктів дослідження в момент часу t .

Ми можемо обчислити похибку прогнозування, яка є відстанню між прогнозованим місцем розташування та фактичним місцем розташування у момент часу $t-s$ у майбутньому. Цей крок попередньої обробки є важливим, оскільки він дозволяє нам ізолювати та витягувати відповідні об'єкти зі сцени, тим самим забезпечуючи подальший аналіз та прогнозування траєкторій руху. Отримуючи просторові координати кожного розглянутого об'єкта в різні моменти часу, можна спостерігати за їх рухами з часом та робити висновки про потенційні закономірності поведінки [9-11].

Аналізуючи зміни траєкторії руху БПЛА можна відмітити, що модель старанно намагається передбачити майбутні траєкторії з достатньою точністю. Тим не менш, спостерігалися помилки в продуктивності, оскільки моделі бракувало точного налаштування. Можна відмітити, що прямі маршрути демонстрували вищу точність. І навпаки, відхилення або повороти траєкторій іноді можуть створювати проблеми, що призводить до збільшення помилок виявлення у моделі [9].

Для тривалості траєкторії від 1 до 5 с ми отримали різноманітні дані для різних типів траєкторій (табл. 2). Це дозволяє нам оцінити точність прогнозування руху в різні часові інтервали. Найнижча середня похибка спостерігалася для повільного руху як на коротких, так і на довгих траєкторіях. Ці результати свідчать про те, що складність прогнозування траєкторії безпосередньо пов'язана з типом та тривалістю руху [9, 10].

Таблиця 2

Середня похибка різних типів маршрутів

Тип маршрута	Середня похибка, %	Тривалість, с
Прямий шлях	12,5	1
Прямий шлях	9,7	5
Поворот	36,2	1
Поворот	28,9	5
Повільний рух	10,6	1
Повільний рух	6,4	5

Результати, представлені в цьому дослідженні, демонструють високу ефективність використання гібридної архітектури RCNN+LSTM для виявлення та прогнозування траєкторій безпілотних літальних апаратів (БПЛА). Запропонований підхід базується на застосуванні згорткової нейронної мережі на основі областей (RCNN) для точного розпізнавання об'єктів у відеокадрах та мережі довгострокової короткострокової пам'яті (LSTM) для захоплення часових залежностей та створення прогнозів щодо майбутніх позицій дронів. Цей комбінований метод забезпечує надійну точність виявлення та досить точне короткострокове прогнозування траєкторії протягом кількох секунд. Складність полягає у нерегулярному та криволінійному русі досліджуваного об'єкта.

Запропонований метод включає інтеграцію детектора на основі CNN з предиктором часових рядів LSTM та використання синтетичного набору даних, створеного в Blender, для охоплення широкого спектру сценаріїв польоту, освітлення та погодних умов. Реальні відеодані, хоча й обмежені, забезпечили додаткову перевірку, підтвердивши, що частина RCNN підтримує високу продуктивність виявлення (таблиця 1) і що модуль LSTM правильно оцінює рух дрона, включаючи зміни напрямку (таблиця 2) [9].

Аналіз (таблиця 1) показує, що модель має збалансований коефіцієнт повноти та точності $mAP \approx 68,5\%$ та $mAR \approx 66,83\%$, незважаючи на те, що точність виявлення знижується, коли дрон займає дуже мало пікселів на зображенні (дрібномасштабні об'єкти). Таблиця 2 показує, що найменші середні помилки (близько 6,4–10,6%) були отримані на траєкторіях польоту в повільному русі, тоді як повороти призводять до вищих помилок прогнозування до 28,9–36,2%. Це свідчить про загальну проблему для рекурентних підходів: стаціонарний рух передбачається достатньо точним, тоді як раптовий поворот призводить до більшої розбіжності між прогнозованими та реальними траєкторіями. Отримані результати показують, що точність виявлення крихтливих або віддалених об'єктів знижується, це вказує на необхідність покращення оптики або додаткового точного налаштування [9].

На практиці ці результати можуть бути застосовані для автоматизованого відстеження БПЛА, створення безпечних повітряних маршрутів та систем безпеки в режимі реального часу над об'єктами сільськогосподарського виробництва.

Висновки. У роботі наведено аналіз сфери застосування БПЛА в сільському господарстві. Наукова новизна отриманих результатів полягає в розробці та навчанні моделей, побудованих на застосуванні нейромережевого підходу, щодо прогнозування траєкторії польоту БПЛА і сприяє підвищенню точності прогнозування траєкторії БПЛА для підвищення ефективності сільськогосподарського виробництва.

Покращення функціональності запропонованої моделі здійснювалось шляхом розширення її можливостей від розпізнавання об'єктів на відео та зображеннях до аналізу даних Google Earth. У дослідженні використовувалася гібридна модель, що поєднує згорткові нейронні мережі на основі регіонів (RCNN) та мережі довгої короткочасної пам'яті (LSTM). RCNN використовувалися для точного виявлення об'єктів в окремих кадрах, тоді як мережі LSTM фіксували часові залежності та прогнозували траєкторії об'єктів між кадрами. Запропонований підхід дозволяє моделі точно відстежувати об'єкти та прогнозувати їхній рух у динамічних сценах. Шляхом ітеративного налаштування параметрів на основі зворотного зв'язку від прогнозованих та фактичних положень, модель з часом покращувала точність прогнозування.

Результати дослідження показують, що нейронна мережа досягла високої точності в прогнозуванні траєкторії, причому модель показала кращу продуктивність у реальних сценаріях порівняно з традиційними методами. Інтеграція LSTM дозволила ефективно навчатися мережі та узагальнювати часові показники, фіксуючи складні рухи

та ефективну взаємодію з навколишнім середовищем. Це дослідження демонструє можливість використання нейромережевого підходу і для прогнозування траєкторії БПЛА, але дає потенційну можливість застосування цих рішень у сфері агробізнесу чи логістики [9, 10].

Список використаних джерел

1. Гарафонов О., Маргасова В. Перспективи впровадження інноваційних технологій розвитку агропромислового комплексу України. *Socio-economic relations in the digital society*. 2022. № 3 (45). С. 19–28. DOI: <https://doi.org/10.55643/ser.3.45.2022.475>.
2. Information and Communication Technology (ICT) in Agriculture: A Report to the G20 Agricultural Deputies. Rome: FAO, 2017. 57 p.
3. Болтянська Н.І., Маніта І.Ю., Подашевська О. Проблеми і перспективи розвитку інформаційних технологій в сільському господарстві. *Праці Таврійського державного агротехнологічного університету імені Дмитра Моторного*. 2020. Т. 20. № 4. С. 175–185. DOI: 10.31388/2078-0877-2020-20-4-175-185.
4. Апуневич І.П. Штучний інтелект як рушій змін у сучасному сільському господарстві. «Агробіологія», 2024. № 2. С. 6-13.
5. AgroDSS: A decision support system for agriculture and farming / M. Kukar et al. *Computers and Electronics in Agriculture*. 2023. 161 p., P. 260-271.
6. Kumari, S., Venkatesh, V.G., Tan, F.T.C. (2023). Application of machine learning and artificial intelligence on agriculture supply chain: a comprehensive review and future research directions. *Ann Oper Res*. DOI: 10.1007/s10479-023-05556-3
7. Yue, J., Manocha, D., & Wang, H. Human trajectory prediction via neural social physics. *Computer Vision – ECCV 2022*. ECCV 2022. Lecture Notes in Computer Science, 2022, vol. 13694. Springer, Cham. DOI: 10.1007/978-3-031-19830-4_22.
8. Liu, Y., Yan, Q., & Alahi, A. Social NCE: Contrastive learning of socially-aware motion representations. *IEEE/CVF International Conference on Computer Vision (ICCV)*, 2021, pp. 15118-15129. DOI: 10.48550/arXiv.2012.11717.
9. Bezsonov, O., Liashenko, S., Rudenko, O., Rutska, S., & Vashchenko, K. (2025) Using a deep learning network to predict flight path. *Radioelectronic and Computer Systems*, 2025(1), 71-84. doi: <https://doi.org/10.32620/reks.2025.1.5>
10. Qin, W., Tang, J., Lu, C., & Lao, S. Trajectory prediction based on long short-term memory network and Kalman filter using hurricanes as an example. *Computational Geosciences*, 2021, vol. 25, pp. 1005-1023. DOI: 10.1007/s10596-021-10037-2.
11. An, Y., Liu, A., Liu, H., & Geng, L. Multidimensional trajectory prediction of UAV swarms based on dynamic graph neural network. *IEEE access*, 2024, vol. 12, pp. 57033-57042. DOI: 10.1109/ACCESS.2024.3391374.