

for *Engineering and Technology*. 2024. Vol. 2, no. 2. P. 17-36. URL: <https://doi.org/10.59222/ustjet.2.2.2>.

3. Internet of Things and LoRaWAN-Enabled Future Smart Farming / B. Citoni et al. *IEEE Internet of Things Magazine*. 2019. Vol. 2, no. 4. P. 14-19. URL: <https://doi.org/10.1109/iotm.0001.1900043>.

4. The role of 5G network in revolutionizing agriculture for sustainable development: A comprehensive review / W. u. Rehman et al. *Energy Nexus*. 2025. Vol. 17. P. 100368. URL: <https://doi.org/10.1016/j.nexus.2025.100368>.

Мак А. А.,

здобувач вищої освіти спеціальності F3 Комп'ютерні науки
Науковий керівник: Пархоменко О. Ю., к.ф.-м.н., доцент кафедри економічної кібернетики, комп'ютерних наук та інформаційних технологій
Миколаївський національний аграрний університет
м. Миколаїв

ВИКОРИСТАННЯ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ (НА ОСНОВІ АРХІТЕКТУРИ ALEXNET) ДЛЯ ВИСОКОТОЧНОЇ ІДЕНТИФІКАЦІЇ ШКІДНИКІВ У ЗАКРИТОМУ ҐРУНТІ

Проблема своєчасного виявлення шкідників у тепличних господарствах є критично важливою для забезпечення стабільності врожаю та зниження використання хімічних засобів захисту рослин. Традиційні методи моніторингу (візуальний огляд, клейові пастки) є трудомісткими, суб'єктивними та не забезпечують оперативного реагування. Закритий ґрунт створює специфічні умови: контрольоване освітлення, висока щільність посадок та швидке поширення шкідників (павутинний кліщ, білокрилка, трипси) вимагають автоматизованих рішень [1]. Технології комп'ютерного зору на основі згорткових нейронних мереж (CNN) дозволяють вирішити цю задачу з точністю, недосяжною для ручних методів.

AlexNet, запропонована Krizhevsky et al. у 2012 році, стала проривною архітектурою завдяки використанню функції активації ReLU (зменшення проблеми зникаючого градієнта), dropout-регуляризації (запобігання перенавчанню) та ефективній реалізації на графічних процесорах. Модель складається з 5 згорткових шарів, 3 повнозв'язних шарів та softmax-класифікатора. Хоча сучасні архітектури (ResNet, EfficientNet) демонструють вищу точність, AlexNet зберігає переваги для задач з обмеженими обчислювальними ресурсами та середнім розміром навчальної вибірки (1000 – 10000 зображень) [2].

Для задачі ідентифікації шкідників доцільно використовувати попередньо навчену на ImageNet модель із подальшим fine-tuning (трансферне навчання). Це дозволяє скоротити необхідний обсяг розмічених даних на 40–60% та час

навчання в 3–5 разів порівняно з навчанням з нуля. Вхідні зображення мають бути приведені до розміру 227×227 пікселів (стандарт для AlexNet) та нормалізовані.

Збір даних здійснювався за допомогою камер Raspberry Pi HQ (12 Мп) із макрооб'єктивом, встановлених стаціонарно в трьох теплицях площею 500 м² кожна. Навчальна вибірка включала 3 450 зображень чотирьох класів: павутинний кліщ (1020), білокрилка (980), трипси (850) та фон (600). Застосовано аугментацію: обертання ($\pm 15^\circ$), масштабування (0,8–1,2x), зміну яскравості ($\pm 20\%$) та горизонтальне віддзеркалення, що збільшило вибірку до 8200 зображень.

Оцінка моделі проводилась на тестовій вибірці (10% даних) за метриками: accuracy (частка правильних прогнозів), precision (точність), recall (повнота) та F1-score. Матриця похибок дозволила виявити класи з найбільшою кількістю помилок.

Таблиця 1. Результати класифікації шкідників (AlexNet, fine-tuning)

Клас	Precision, %	Recall, %	F1-score, %	Кількість тестових зразків
Павутинний кліщ	92,4	89,7	91,0	205
Білокрилка	88,6	91,2	89,9	190
Трипси	85,1	83,6	84,3	170
Фон	96,2	97,8	97,0	180
Середнє (macro avg)	90,6	90,6	90,6	745

Отримана середня точність (macro F1 = 90,6%) є достатньою для практичного застосування. Найнижчі показники зафіксовано для класу трипсів через малий розмір об'єктів (1–2 мм) та їх схожість із пилком рослин. Час обробки одного зображення на NVIDIA Jetson Nano склав 0,12 с, що дозволяє працювати в реальному часі (8–10 кадрів/сек).

Для оцінки ефективності AlexNet було проведено порівняння з легшою моделлю (MobileNetV2) та більш глибокою (ResNet-18). Результати наведено в таблиці 2.

Таблиця 2. Порівняння архітектур CNN для ідентифікації шкідників

Архітектура	F1-score (macro), %	Час навчання, хв	Розмір моделі, МБ	Час інференсу, мс
MobileNetV2	87,2	45	14	35
AlexNet (fine-tuned)	90,6	62	240	120
ResNet-18	93,1	110	45	95

Хоча ResNet-18 демонструє вищу точність (+2,5% за F1), AlexNet забезпечує кращий баланс між точністю та обчислювальними витратами для розгортання на edge-пристроях. MobileNetV2 є найшвидшою, але поступається в точності на 3-4% [3].

Інтеграція моделі в систему моніторингу теплиці передбачає щогодинне отримання зображень із 5-10 камер, автоматичне спрацювання сповіщення при виявленні шкідника на будь-якому кадрі. За результатами польових випробувань тривалістю 3 місяці, система виявила 86% заселень шкідниками на стадії, коли популяція не перевищувала 5 особин на рослину. Своєчасне локальне застосування біологічних засобів (ентомофагів) дозволило скоротити використання хімічних пестицидів на 65% та знизити втрати врожаю на 12-15% порівняно з контрольною теплицею [3].

Основними обмеженнями залишаються: варіативність зовнішнього вигляду шкідників залежно від стадії розвитку (яйце, личинка, імаго), маскування на фоні рослинної поверхні та необхідність регулярного оновлення моделі на нових даних. Подальші дослідження мають бути спрямовані на використання архітектур із механізмом уваги (Vision Transformer), інтеграцію з IoT-датчиками мікроклімату для прогнозування появи шкідників, а також застосування методів безперервного навчання (continual learning) для адаптації моделі в реальному часі.

Для фермерських господарств із обмеженим бюджетом запропоновано «легкий» варіант розгортання системи на базі одноплатного комп'ютера Raspberry Pi 4 (4 ГБ RAM) із камерою HQ. У такій конфігурації модель AlexNet оптимізується за допомогою бібліотеки TensorFlow Lite (перетворення у формат TFLite з 8-бітним квантуванням), що зменшує розмір моделі з 240 МБ до 32 МБ та час інференсу до 55 мс на кадр (≈ 18 кадрів/сек) при незначному зниженні точності (F1-score 88,2%). Вартість такої системи (камера + Raspberry Pi + джерело живлення) становить приблизно \$200–250, що робить її доступною для малих тепличних господарств площею до 200 м². При цьому система працює в автономному режимі, надсилаючи сповіщення через LoRa-зв'язок або Wi-Fi [3].

Таким чином, використання згортової нейронної мережі AlexNet із застосуванням трансферного навчання забезпечує високу точність ідентифікації шкідників у закритому ґрунті (F1-score 90,6%). Розроблена система дозволяє автоматизувати моніторинг, знизити використання пестицидів на 65% та мінімізувати втрати врожаю. Запропонований підхід може бути масштабований на різні типи теплиць та культури після відповідного донавчання моделі.

Список використаних джерел

1. Deep Learning-Based Image Recognition of Agricultural Pests / W. Xu et al. *Applied Sciences*. 2022. Vol. 12, no. 24. P. 12896. URL: <https://doi.org/10.3390/app122412896>.

2. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*. 2017. Vol. 60, no. 6. P. 84–90. URL: <https://doi.org/10.1145/3065386>.

3. Dalal M, Mittal P. A Systematic Review of Deep Learning-Based Object Detection in Agriculture: Methods, Challenges, and Future Directions. *Comput Mater Contin*. 2025;84(1):57–91. <https://doi.org/10.32604/cmc.2025.066056>.

Мальченко А. І.

здобувачка першого (бакалаврського) рівня вищої освіти,
спеціальності Готельно-ресторанна справа

Науковий керівник: Гарбар Г. А., доктор економічних наук, професор
Миколаївський національний аграрний університет
м. Миколаїв

ЦИФРОВІ ТЕХНОЛОГІЇ В СИСТЕМІ ПРОДОВОЛЬЧОЇ БЕЗПЕКИ

Сучасна система продовольчої безпеки перебуває під впливом глобальних викликів, серед яких зміна клімату, порушення логістичних ланцюгів, геополітична нестабільність та зростання чисельності населення. За оцінками міжнародних організацій, для забезпечення продовольчих потреб населення світу до 2050 року необхідно суттєво підвищити ефективність аграрного виробництва та зменшити втрати на всіх етапах ланцюга постачання [3].

У цьому контексті цифрові технології стають ключовим інструментом трансформації агропродовольчої системи, забезпечуючи підвищення продуктивності, прозорості та стійкості виробництва. Під цифровими технологіями в аграрному секторі розуміють використання інноваційних рішень, таких як інтернет речей (IoT), штучний інтелект (AI), великі дані (Big Data), блокчейн та системи точного землеробства [1].

Роль цифрових технологій у забезпеченні продовольчої безпеки

Продовольча безпека визначається як стан, за якого всі люди мають фізичний, соціальний та економічний доступ до достатньої кількості безпечної та поживної їжі [4]. Цифровізація безпосередньо впливає на всі компоненти цього поняття: доступність, стабільність, якість і сталість.

Одним із ключових напрямів є точне землеробство, яке базується на використанні супутникових даних, GPS-навігації та сенсорних систем. Це дозволяє оптимізувати використання ресурсів (води, добрив, пального) та підвищити врожайність. Дослідження показують, що впровадження цифрових рішень у сільському господарстві сприяє зниженню витрат і підвищенню продуктивності виробництва [6].

Іншим важливим напрямом є використання Big Data та аналітичних платформ, які дозволяють прогнозувати врожайність, оцінювати ризики посух і шкідників, а також формувати ефективні управлінські рішення. Це підвищує стабільність продовольчого забезпечення та зменшує ймовірність кризових ситуацій.