

КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

на тему Метод нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання

Галузь знань 12 – Інформаційні технології
Шифр і назва галузі знань
Спеціальність 122 – Комп'ютерні науки
Шифр і назва спеціальності
Освітня програма Комп'ютерні науки
Назва освітньої програми

Виконав: студент групи КН-22-2 БДУ Дмитро БІЛАН
Група виконавця Підпис Ім'я, ПРІЗВИЩЕ
Керівник: д.т.н., проф. каф. КН МММ Едуард МАНЗЮК
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ
Нормоконтроль: к.т.н., доц. каф. КН SO Руслан БАГРІЙ
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ

До захисту допускаю:

Зав. кафедри КН, д.т.н., професор

11 червня 2026 р.

Олександр БАРМАК
Підпис Ім'я, ПРІЗВИЩЕ

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
Факультет інформаційних технологій
Кафедра комп'ютерних наук
Освітній ступінь бакалавр
Галузь знань 12 – Інформаційні технології
Спеціальність 122 – Комп'ютерні науки

ЗАТВЕРДЖУЮ
Завідувач кафедри комп'ютерних наук


(підпис)

д.т.н., професор Олександр БАРМАК
«22» січня 2026 року

ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ БАКАЛАВРА

1. Тема кваліфікаційної роботи бакалавра: «Метод нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання»

2. Завдання видано студенту Дмитру Білану
(ім'я, прізвище)

3. Керівник роботи професор кафедри КН Едуард Манзюк
(посада, ім'я, прізвище)

4. Затверджено наказом університету від «20» січня 2026 р. № 7

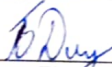
5. Дата видачі завдання студенту: «22» січня 2026 р.

6. Зміст пояснювальної записки (перелік задач) та вихідні дані:

Метою роботи є покращення точності, швидкості та автоматизації процесу контролю якості насіння сої шляхом розробки методу нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання, що дозволить замінити суб'єктивні ручні методи на об'єктивну, високопродуктивну систему, підвищити ефективність селекційної та виробничої діяльності в агропромисловому комплексі, зменшити втрати від помилкової класифікації та забезпечити стабільну якість посівного матеріалу.

7. Календарний план виконання кваліфікаційної роботи бакалавра:

№	Назва етапів (розділів) кваліфікаційної роботи бакалавра	Термін виконання	Примітка
1	Вибір напряму дослідження та узгодження теми кваліфікаційної роботи з керівником, складання календарного графіка виконання	січень 2026	Виконано
2	Ознайомлення з предметною областю, формулювання мети і задач дослідження, визначення об'єкта та предмета дослідження	лютий 2026	Виконано
3	Проектування методу розв'язання задачі, опис архітектурних рішень, розроблення математичних моделей та алгоритмів.	березень 2026	Виконано
4	Обґрунтування інструментарію розробки, програмна реалізація розробленого методу, проведення експериментального тестування та оцінювання ефективності.	квітень 2026	Виконано
5	Написання пояснювальної записки, урахування зауважень керівника, оформлення згідно з вимогами	травень 2026	Виконано
6	Розроблення презентаційних матеріалів та попередній захист кваліфікаційної роботи	травень 2026	Виконано
7	Отримання відгуку керівника, рецензії, перевірка пояснювальної записки на плагіат, нормоконтроль	червень 2026	Виконано
8	Підготовка до захисту та захист кваліфікаційної роботи	червень 2026	Виконано

Виконавець: студент групи КН-22-2  Дмитро БІЛАН
Група виконавця Підпис Ім'я, ПРІЗВИЩЕ

Керівник: д.т.н., проф. каф. КН  Едуард МАНЗЮК
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ

Анотація

Тема кваліфікаційної роботи бакалавра: «Метод нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання»

Виконавець кваліфікаційної роботи бакалавра: студент групи КН-22-2 Дмитро Білан

Керівник кваліфікаційної роботи бакалавра: д.т.н., професор кафедри КН Едуард Манзюк

Кваліфікаційна робота бакалавра містить:

Пояснювальна записка				Кількість додатків
Сторінок	Рисунків	Таблиць	Джерел інформації	
61	18	3	41	2

Метою кваліфікаційної роботи бакалавра є покращення точності, швидкості та автоматизації процесу контролю якості насіння сої шляхом розробки методу нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання.

Для досягнення цієї мети та експериментального підтвердження дієвості запропонованого методу реалізовано програмну систему.

Практичне значення роботи полягає у створенні доступного інструментарію для агрономів та виробників насіння, який дозволяє оперативно оцінювати якість насіння сої без залучення дорогого лабораторного обладнання. Запропонований підхід забезпечує автоматичну класифікацію насіння за класами якості.

Ключові слова: глибоке навчання, комп'ютерний зір, нейромережева класифікація, контроль якості насіння, MobileNetV2, візуальні ознаки.

Виконавець: студент групи КН-22-2 Білан Дмитро Дмитро БІЛАН
Група виконавця Підпис Ім'я, ПРІЗВИЩЕ

Зміст

Перелік скорочень	3
Вступ.....	4
Розділ 1 Характеристика предметної області: аналіз моделей, методів та реалізацій у сфері нейромережевої класифікації насіння сої	6
1.1 Аналіз предметної області.....	6
1.2 Огляд нейромережевих моделей класифікації насіння сої.....	8
1.3 Аналіз сучасних наукових підходів до ідентифікації дефектів сої.....	10
1.4 Огляд програмних рішень для аналізу насіння сої	13
1.5 Мета та завдання дослідження	16
Розділ 2 Розробка методу нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання	17
2.1 Математична формалізація задачі класифікації насіння сої.....	17
2.2 Архітектурні особливості застосування моделі MobileNetV2.....	19
2.3 Алгоритми нейромережевої класифікації насіння сої.....	27
2.4 Характеристика набору візуальних даних насіння сої.....	32
2.5 Опис метрик оцінювання якості моделі глибокого навчання.....	36
2.6 Сценарії проведення експерименту	39
2.7 Висновки до розділу 2.....	41
Розділ 3 Експериментальне дослідження методу нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання	43
3.1 Програмна реалізація веб-застосунку SoyNet AI	43
3.2 Аналіз результатів класифікації та обчислювальної швидкодії моделі глибокого навчання.....	50
3.2.1 Дослідження динаміки навчання та оптимізації вагових коефіцієнтів ..	50
3.2.2 Оцінка точності розпізнавання класів якості насіння сої	54
3.2.3 Експериментальне підтвердження обчислювальної ефективності та швидкості інференсу.....	57
Загальні висновки.....	61
Перелік посилань	62
Додатки	

Перелік скорочень

Скорочення, термін, позначення	Пояснення
БД	База даних
ІТ	Інформаційні технології
КН	Комп'ютерні науки
КРБ	Кваліфікаційна робота бакалавра
ПЗ	Пояснювальна записка
ХНУ	Хмельницький національний університет
ІІ	Штучний інтелект
AI	Artificial Intelligence
CNN	Convolutional Neural Network
FLOPs	Floating Point Operations
FN	False Negative
FP	False Positive
FPS	Frames Per Second
GAP	Global Average Pooling
GPU	Graphics Processing Unit
MAdds	Multiply-Accumulate Operations
RAM	Random Access Memory
RBAC	Role-Based Access Control
ReLU	Rectified Linear Unit
RGB	Red, Green, Blue
ROM	Read-Only Memory
TN	True Negative
TP	True Positive
XAI	Explainable Artificial Intelligence

Вступ

Актуальність. Зростання ролі сої як однієї з ключових експортних та олійних культур в Україні та світі супроводжується посиленням вимог до посівних якостей насіння, оскільки використання некондиційного матеріалу призводить до суттєвих втрат врожайності, від зниження схожості та появи домішок до значного зменшення врожаю через пошкодження чи хвороби. Традиційні методи візуального контролю якості насіння сої, які покладаються на ручну експертизу спеціалістів або частково механізовані лабораторні процедури, залишаються суб'єктивними, повільними, трудомісткими та малоефективними при великих обсягах насінневого матеріалу.

Сучасні досягнення в галузі комп'ютерного зору та глибокого навчання відкривають можливості для створення об'єктивних, швидких і масштабованих систем автоматичної класифікації насіння за такими параметрами, як ступінь пошкодження, наявність дефектів та іншими візуальні характеристики. Впровадження таких технологій дозволяє суттєво скоротити економічні витрати на неякісний посівний матеріал, підвищити конкурентоспроможність насіння, забезпечити стабільну якість на етапах сортування, сертифікації та виробництва, а також інтегрувати рішення в промислові лінії, портативні пристрої чи мобільні додатки для оперативного аналізу. Завдяки високій продуктивності нейромережевих моделей стає можливим раннє виявлення проблем якості, що особливо важливо в умовах інтенсивного землеробства, кліматичних викликів та жорсткої ринкової конкуренції.

Об'єкт дослідження – процес автоматизованого контролю якості насіння сої за візуальними ознаками.

Предмет дослідження – методи та засоби глибокого навчання, спрямовані на автоматизований контроль якості насіння сої за візуальними ознаками.

Мета кваліфікаційної роботи бакалавра – покращення точності, швидкості та автоматизації процесу контролю якості насіння сої шляхом розробки

методу нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання.

Завдання кваліфікаційної роботи бакалавра:

- здійснити системний аналіз предметної області щодо поточних методів візуального контролю та експертизи якості соєвого насіння;
- провести порівняльний огляд наявних інформаційних систем та програмних продуктів, призначених для автоматизованого моніторингу якості сільськогосподарської продукції;
- сформулювати та попередньо обробити масив навчальних даних для тренування моделі комп'ютерного зору;
- розробити метод нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання;
- провести експериментальне дослідження ефективності запропонованого методу класифікації, використовуючи розроблене програмне середовище.

Розділ 1 Характеристика предметної області: аналіз моделей, методів та реалізацій у сфері нейромережевої класифікації насіння сої

1.1 Аналіз предметної області

Інформаційні технології та автоматизація відіграють ключову роль у розвитку сучасних систем контролю якості насіння сільськогосподарських культур. Проблема низької якості насіння сої залишається надзвичайно актуальною в агропромисловому комплексі України та світу. Неякісний посівний матеріал призводить до зниження схожості та загальної врожайності, що спричиняє значні економічні збитки для насінницьких господарств і виробників [1].

Якість насіння сої за візуальними ознаками є комплексом параметрів, що безпосередньо впливають на посівні властивості: механічні пошкодження (биті, розтріскані, пошкоджені під час збирання), наявність домішок, зміни кольору, пліснява, пошкодження шкідниками чи хворобами, а також сортова чистота [2]. Основні прояви таких порушень якості проявляються у зміні зовнішнього вигляду насінин, що легко фіксується на зображеннях [3].

Зазвичай розрізняють два основні види дефектів насіння сої: механічні та біологічні. Механічні дефекти є більш поширеними, їх причини включають неправильне налаштування комбайнів під час збирання, пошкодження під час транспортування та зберігання, а також невідповідність умов сушіння (підвищена вологість) [4]. Біологічні дефекти пов'язані з зараженням пліснявою, хворобами чи шкідниками [5]. Щоб насіння могло називатися якісним, воно повинно відповідати вимогам стандартів щодо чистоти, відсутності домішок і пошкоджень, забезпечуючи високу схожість і врожайність. Неякісне насіння підвищує ризик втрат урожаю та знижує конкурентоспроможність посівного матеріалу [6].

Для оцінки якості насіння важливо враховувати еталон, визначений державними стандартами. На формування якості впливають умови збирання, режим сушіння, зберігання та транспортування. Особливе значення має візуальний аналіз зовнішнього вигляду: цілісність, однорідність кольору, відсутність тріщин, плісняви та сторонніх включень [7].

Традиційні методи візуального контролю є суб'єктивними та трудомісткими [8]. Сучасні дослідження демонструють високу ефективність методів глибокого навчання та комп'ютерного зору для автоматизованого виявлення дефектів насіння сої. Зокрема, легковагові конволюційні нейронні мережі дозволяють досягати високої точності класифікації дефектних насінин при низьких обчислювальних витратах [9].

Підходи на основі сегментації та класифікації зображень забезпечують точність виявлення поверхневих дефектів понад 95 % у реальному часі, а також демонструють переваги в швидкості порівняно з традиційними методами [10]. Інші роботи підтверджують ефективність CNN для онлайн-класифікації насіння сої з високими показниками F-score [11].

Застосування глибокого навчання для сегментації та виявлення домішок і пошкоджень досягає сегментаційної точності понад 97 %, а подібні моделі успішно застосовуються для оцінки якості сухого насіння після збирання [12]. Легковагові фреймворки дозволяють реалізувати детекцію в реальному часі на edge-пристроях [13].

Дослідження показують значний потенціал інтеграції комп'ютерного зору та штучного інтелекту для автоматизованого сортування насіння, виявлення дефектів і контролю якості в агровиробництві. Ці технології дозволяють переходити від ручного до повністю автоматизованого аналізу на етапах післязбиральної обробки, що суттєво підвищує продуктивність і точність. Особливо перспективними є розробки, адаптовані до умов українського сільського господарства, де вже ведуться роботи з впровадженням систем III для моніторингу стану рослинницької продукції, виявлення шкідників, хвороб та оцінки якості врожаю на основі комп'ютерного зору [14].

Окремі українські наукові колективи та конференції активно досліджують застосування комп'ютерного зору для автоматизованого аналізу насіння та рослин, включаючи створення прототипів систем для реального часу, що можуть бути адаптовані для насінницьких господарств і зернових комплексів [15]. Сучасні підходи на основі глибокого навчання дозволяють створювати системи, здатні в реальному часі виявляти повний спектр поверхневих дефектів насіння сої

з високою точністю та швидкістю, що робить їх придатними для інтеграції у виробничі лінії сортування [16]. Легковагові моделі комп'ютерного зору забезпечують ефективне розпізнавання дефектів навіть на пристроях з обмеженими обчислювальними ресурсами, що відкриває можливості для використання технології в польових умовах та на невеликих насінницьких підприємствах [17]. Застосування таких методів не лише підвищує об'єктивність оцінки якості, але й сприяє мінімізації економічних втрат за рахунок своєчасного вилучення некондиційного насіння та оптимізації технологічних процесів на всіх етапах: від збирання до сертифікації [18].

Розробка та впровадження методу нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання є важливою та перспективною задачею, оскільки традиційні підходи до візуального контролю якості залишаються суб'єктивними, повільними та трудомісткими.

1.2 Огляд нейромережевих моделей класифікації насіння сої

Сучасний розвиток методів глибокого навчання відкриває широкі можливості для автоматизованого аналізу зображень у сільському господарстві. Зокрема, комп'ютерний зір активно застосовується для оцінювання якості насіння, виявлення дефектів та хвороб та ознак . Використання нейронних мереж дозволяє автоматизувати процес аналізу візуальних характеристик насіння, що традиційно виконується експертами вручну, та підвищити точність і швидкість класифікації [19].

Методи глибокого навчання здатні автоматично виділяти важливі ознаки зображення, такі як форма, текстура, колір та структурні особливості поверхні насіння. Це дозволяє застосовувати їх для розв'язання задач класифікації сільськогосподарської продукції, зокрема насіння сої, на основі візуальних характеристик [20]. У багатьох дослідженнях доведено, що використання CNN забезпечує значно вищу точність розпізнавання у порівнянні з традиційними алгоритмами машинного навчання [21].

Однією з найбільш поширених архітектур глибокого навчання для аналізу зображень є згорткові нейронні мережі. CNN складаються з декількох типів шарів, включаючи згорткові, підвибіркові та повнозв'язні шари. Такі мережі здатні автоматично навчатися, виділяти просторові ознаки зображення та формувати ієрархічне представлення даних. Завдяки цьому CNN широко застосовуються у задачах класифікації рослин, плодів та насіння [22].

Однією з популярних моделей глибокого навчання для обробки зображень є архітектура ResNet. Вона була розроблена для вирішення проблеми деградації якості навчання при збільшенні глибини нейронної мережі. Основною ідеєю ResNet є використання залишкових з'єднань, які дозволяють передавати інформацію між шарами без втрати градієнтів під час навчання. Завдяки цьому мережі ResNet можуть містити десятки або навіть сотні шарів, що забезпечує високу точність класифікації зображень [23]. У задачах аграрного комп'ютерного зору такі моделі застосовуються для класифікації культур, виявлення хвороб рослин та оцінювання якості насіння [24].

Ще однією ефективною архітектурою є VGGNet, запропонована дослідниками Оксфордського університету. Ця модель використовує послідовність згорткових шарів з малими ядрами розміром 3×3 , що дозволяє будувати глибокі нейронні мережі з високою точністю розпізнавання. Архітектура VGG широко використовується як базова модель для навчання та перенавчання у задачах класифікації зображень [25]. У дослідженнях, пов'язаних із аналізом насіння та зернових культур, VGGNet показала хороші результати при визначенні дефектів і класифікації різних типів насіння [26].

Для задач, де важливими є швидкість роботи та ефективність використання обчислювальних ресурсів, застосовуються компактні архітектури нейронних мереж. Однією з таких моделей є MobileNetV2. Ця архітектура була розроблена спеціально для мобільних і вбудованих систем, де обмежені обчислювальні ресурси та енергоспоживання [27].

Модель MobileNetV2 використовує так звані *depthwise separable convolutions* розділені згортки, які значно зменшують кількість параметрів і

обчислювальних операцій порівняно з класичними згортковими шарами. Основною особливістю цієї архітектури є використання інвертованих залишкових блоків та лінійних вузьких шарів [27]. Така структура дозволяє зменшити складність моделі без суттєвої втрати точності.

Завдяки поєднанню компактності та високої ефективності MobileNetV2 широко використовується у задачах класифікації зображень, детекції об'єктів та аналізу біологічних даних [28]. У сфері аграрних досліджень ця модель застосовується для автоматичного визначення якості зерна, розпізнавання хвороб рослин та класифікації насіння за візуальними ознаками.

Крім того, для задач комп'ютерного зору широко використовуються моделі сімейства EfficientNet, які поєднують оптимізацію глибини, ширини та роздільної здатності мережі [29]. Ці моделі забезпечують високу точність при відносно невеликій кількості параметрів, що робить їх ефективними для аналізу зображень у різних прикладних задачах [30].

Застосування методів глибокого навчання, зокрема згорткових нейронних мереж, є найефективнішим для автоматизованого аналізу насіння сої. Дані алгоритми самостійно виділяють ключові ознаки, забезпечуючи високу точність без ручного налаштування. Особливої уваги заслуговує архітектуру MobileNetV2, завдяки використанню глибоких розділених згорток вона гарантує баланс між продуктивністю та мінімальними обчислювальними витратами, що ідеально підходить для обчислень у режимі реального часу.

1.3 Аналіз сучасних наукових підходів до ідентифікації дефектів сої

Активний розвиток методів комп'ютерного зору та глибокого навчання сприяв появі великої кількості наукових досліджень, присвячених автоматичній класифікації та оцінюванню якості насіння сільськогосподарських культур. Зокрема, для насіння сої застосовуються різні підходи, що базуються на CNN, системах комп'ютерного зору та методах аналізу зображень.

У роботі [31] запропоновано систему оцінювання якості насіння сої на основі згорткових нейронних мереж із використанням підходу Explainable Artificial Intelligence. У дослідженні було сформовано набір даних, що було поділено на п'ять категорій. Для класифікації використовувалась архітектура VGG-16 [32]. Запропонований підхід дозволив досягти високої точності класифікації та інтерпретувати рішення моделі за допомогою методів пояснюваного штучного інтелекту. Зміни точності та втрат під час навчання моделі глибокого навчання відображені на рисунку 1.1.




Figure 3. Training and Validation Process on the VGG-16

Рисунок 1.1 – Зміни точності та втрат при навчанні моделі [31]

На рисунку 1.1 лівий графік відображає зміну точності на тренувальному та валідаційному наборах даних: тренувальна точність поступово зростає майже до 0.99, тоді як валідаційна досягає приблизно 0.85-0.90 із невеликими коливаннями. Правий графік демонструє зміну функції втрат, де значення на тренувальних даних швидко зменшується майже до нуля, а на валідаційних даних спочатку знижується, але згодом коливається, що може свідчити про часткове перенавчання моделі. Загалом результати показують ефективність навчання моделі для задачі класифікації зображень насіння.

Наступні автори [33] дослідили можливість класифікації насіння сої на основі реконструкції RGB-зображень із гіперспектральних даних. У дослідженні використовувалися гіперспектральні зображення, які містять інформацію про спектральні характеристики насіння. Схема експериментальної системи отримання зображень насіння сої відображена на рисунку 1.2.




Рисунок 1.2 – Схема системи отримання зображень насіння [33]

На рисунку 1.2 показано схему експериментальної системи отримання зображень насіння сої. Система складається з камери зі спектрографом та об'єктивом, освітлювальних ламп і рухомої платформи для розміщення зразків. Камера фіксує зображення насіння, яке рівномірно освітлюється лампами, після чого отримані дані передаються на комп'ютер для подальшої обробки та класифікації.

У наступній роботі [34] запропоновано модель DAFFnet [35] для класифікації сортів насіння сої. Архітектура моделі поєднує 3D та 2D згорткові нейронні мережі з механізмом подвійної уваги. Для підвищення точності було використано модулі СВAM та Mobile Vision Transformer. Запропонована модель показала кращі результати класифікації порівняно з традиційними підходами аналізу гіперспектральних даних.

У дослідженні [36] розглянуто застосування глибокого навчання для автоматичного виявлення в'янення рослин сої на основі аналізу зображень. Автори використали згорткову нейронну мережу з попередньо навченою моделлю VGG16 для класифікації зображень рослин на здорові та уражені. Запропонований підхід демонструє можливість використання методів глибокого навчання для моніторингу стану рослин і раннього виявлення проблем, що впливають на якість і врожайність сої.

В наступній роботі [37] запропоновано підхід до автоматичного підрахунку насіння та оцінювання врожайності сої на основі комп'ютерного зору та глибокого навчання. Для збору даних використовувався наземний робот із камерами, який здійснював зйомку посівів сої.

Отримані зображення оброблялися за допомогою моделі P2PNet-Yield [38], що дозволяє оцінювати кількість насіння та прогнозувати врожайність. Результати дослідження показали, що використання нейромережевих методів значно скорочує час збору даних і підвищує ефективність агрономічних досліджень. Архітектура моделі P2PNet-Yield для оцінювання врожайності сої на основі зображень відображена на рисунку 1.3.

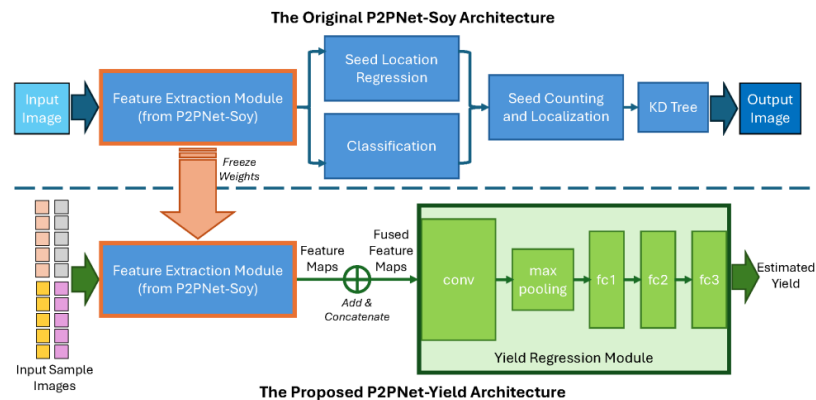


FIGURE 5
Our architecture, P2PNet-Yield, for soybean yield estimation. Training consists of two phases: first, training the P2PNet-Soy model so that its backbone (used as our feature extraction module) can extract useful information related to soybean seeds in the foreground; second, training our yield regression module to estimate yield values from the output feature maps of the feature extraction module.

Рисунок 1.3 – Архітектура моделі P2PNet-Yield для оцінювання врожайності [37]

На рисунку 1.3 представлена архітектура моделі P2PNet-Yield для оцінювання врожайності сої на основі зображень. Спочатку модуль P2PNet-Soy виконує виділення ознак із вхідних зображень та використовується для виявлення і підрахунку насіння, після чого отримані feature maps об'єднуються і подаються до модуля yield regression, що складається з шару згортки, max-pooling та кількох повнозв'язаних шарів. Цей модуль аналізує витягнуті ознаки і прогнозує оцінку врожайності для ділянки, використовуючи інформацію з кількох зображень рослин.

1.4 Огляд програмних рішень для аналізу насіння сої

Для автоматичного аналізу та класифікації насіння у сучасних дослідженнях використовуються різні програмні системи, що базуються на методах комп'ютерного зору та машинного навчання. Розглянемо декілька існуючих програмних систем, які використовуються для аналізу насіння.

Одним із відомих програмних рішень є SmartGrain [39] програмне забезпечення для високопродуктивного аналізу зображень насіння. Дана система дозволяє автоматично визначати контури насіння на цифрових зображеннях та обчислювати різні морфологічні параметри, зокрема довжину, ширину, площу, периметр та коефіцієнт округлості. Програма може обробляти велику кількість зображень у пакетному режимі та експортувати результати аналізу у форматі CSV для подальшої статистичної обробки. Інтерфейс програмного забезпечення SmartGrain відображено на рисунку 1.4.

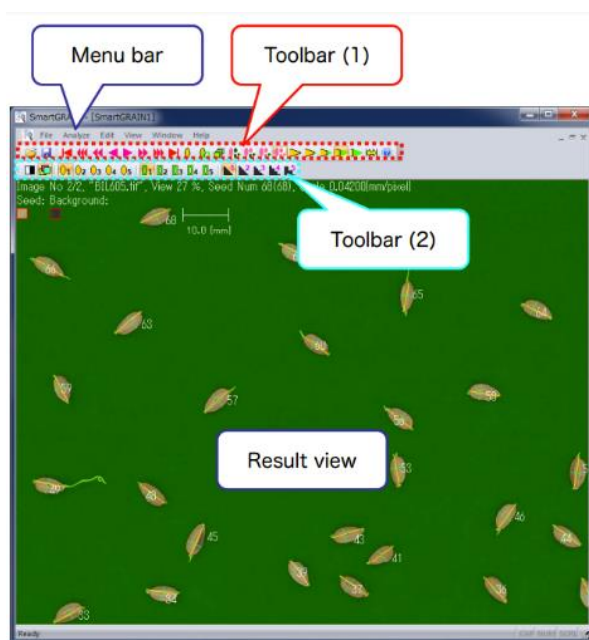


Рисунок 1.4 – Інтерфейс програмного забезпечення SmartGrain [39]

На рисунку 1.4 зображено інтерфейс програмного забезпечення SmartGrain, яке використовується для автоматичного аналізу зображень насіння.

Перевагами системи SmartGrain є висока швидкість обробки зображень, автоматичне визначення контурів насіння та можливість обробки великої кількості зразків. Недоліком системи є орієнтованість на аналіз геометричних параметрів насіння та не використання сучасних нейромережевих моделей глибокого навчання для класифікації.

Іншим прикладом програмного рішення є система SeedAIxpert [40], яка використовується для автоматизованого тестування насіння та оцінювання його якості. Система складається з камери, освітлення та програмного забезпечення для аналізу зображень, яке використовує алгоритми машинного навчання для

визначення параметрів насіння, зокрема розміру, форми та кольору. Система дозволяє автоматично визначати відсоток проростання, проводити фенотипування насіння та аналізувати якість проростків. Приклад роботи системи SeedAIxpert відображено на рисунку 1.5.




Рисунок 1.5 – Приклад роботи системи SeedAIxpert [40]

На рисунку 1.5 показано приклад роботи системи SeedAIxpert для аналізу зображень проростків насіння. Система використовує методи комп'ютерного зору для автоматичного виявлення проростків, визначення їхніх параметрів та оцінювання якості насіння. Перевагами даного рішення є висока точність аналізу, автоматизація процесу тестування та можливість обробки великої кількості зразків. Однак основним недоліком системи є необхідність використання спеціалізованого обладнання та висока вартість програмно-апаратного комплексу, що обмежує його застосування у невеликих лабораторіях або навчальних дослідженнях.

Аналіз існуючих програмних рішень показує, що більшість сучасних систем дозволяють автоматизувати аналіз насіння за допомогою комп'ютерного зору та машинного навчання. Проте вони або орієнтовані лише на морфологічний аналіз насіння, або потребують дорогого обладнання для отримання зображень. Це обґрунтовує необхідність розробки методу нейромережевої класифікації насіння сої за візуальними ознаками, який забезпечить високу точність розпізнавання та можливість використання стандартних RGB-зображень.

1.5 Мета та завдання дослідження

Метою кваліфікаційної роботи бакалавра є покращення точності, швидкості та автоматизації процесу контролю якості насіння сої шляхом розробки методу нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання. Для реалізації поставленої мети необхідно виконати такі задачі:

- здійснити системний аналіз предметної області щодо поточних методів візуального контролю та експертизи якості соєвого насіння;
- провести порівняльний огляд наявних інформаційних систем та програмних продуктів, призначених для автоматизованого моніторингу якості сільськогосподарської продукції;
- сформулювати та попередньо обробити масив навчальних даних для тренування моделі комп'ютерного зору;
- розробити метод нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання;
- провести експериментальне дослідження ефективності запропонованого методу класифікації, використовуючи розроблене програмне середовище.

Розділ 2 Розробка методу нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання

2.1 Математична формалізація задачі класифікації насіння сої

У рамках даного дослідження автоматизований контроль якості насіння сої розглядається як задача розпізнавання образів. Математично цей процес зводиться до задачі багатокласової класифікації з учителем. Головною метою є побудова такої математичної моделі, яка здатна проаналізувати вхідні візуальні ознаки об'єкта і самостійно віднести його до однієї з наперед заданих категорій.

Для формалізації цього процесу визначимо простір вхідних даних X , що являє собою множину всіх можливих цифрових зображень насіння сої. У комп'ютерному баченні кожне таке зображення $x \in X$ представляється у вигляді тривимірного масиву (тензора) чисел, що відображають інтенсивність пікселів у колірному просторі RGB. З іншого боку, визначимо дискретну множину можливих станів або класів якості насіння $Y = \{1, 2, \dots, K\}$, де K , це загальна кількість категорій, на які поділяється насіння (наприклад, здорове, бите, уражене хворобами тощо).

Оскільки візуальні ознаки насіння можуть мати високу природну варіативність і плавні переходи між класами (наприклад, ледь помітні тріщини або плями), задачу недоцільно вирішувати за допомогою жорстких логічних правил. Замість цього використовується ймовірнісний підхід. Модель будується так щоб для кожного вхідного зображення обчислювати ймовірність його належності до кожного з можливих класів. Відповідно до правила максимальної апостеріорної ймовірності, кінцеве рішення системи (передбачений клас \hat{y} для поданого на вхід зображення x) визначається як клас, для якого модель вираховувала найвище значення ймовірності:

$$\hat{y} = \operatorname{argmax}_{k \in Y} P(y = k | x, \theta) \quad (2.1)$$

де $P(y = k | x, \theta)$ це передбачена моделлю ймовірність того, що зображення x належить до класу k , а θ це сукупність усіх внутрішніх параметрів математичної моделі, які налаштовуються під час її навчання.

Для того, щоб модель могла коректно обчислювати ці ймовірності, її необхідно навчити на репрезентативному наборі даних. Нехай задано навчальну вибірку, яка складається з N пар об'єктів: самі зображення та відповідні їм істинні мітки класів, заздалегідь визначені експертом. Під час навчання система генерує власні передбачення для кожного зображення і порівнює їх з істинними мітками.

Для кількісної оцінки того, наскільки сильно передбачення моделі відхиляється від правильної відповіді на конкретному зображенні, використовується спеціальна функція втрат. Оскільки класи є взаємовиключними (одна насінина в один момент часу належить лише до одного основного класу), найефективнішою метрикою є функція категоріальної перехресної ентропії:

$$L(y_i, \hat{p}_i) = - \sum_{k=1}^K y_{ik} \log(\hat{p}_{ik}) \quad (2.2)$$

де \hat{p}_{ik} це розрахована моделлю ймовірність приналежності i -го зображення до класу k , а y_{ik} це індикатор істинного класу, який дорівнює 1, якщо зображення дійсно належить до класу k , і 0 у всіх інших випадках. Ця функція сильно штрафує модель, якщо вона впевнено видає хибний результат, і наближається до нуля, якщо передбачення точне.

Математична мета всього процесу розробки методу класифікації зводиться до розв'язання задачі мінімізації емпіричного ризику. Нам необхідно підібрати такий оптимальний набір параметрів моделі θ^* , який забезпечить найменше середнє значення функції втрат на всій сукупності зображень із навчальної вибірки:

$$\theta^* = \arg \min_{\theta} \left(\frac{1}{N} \sum_{i=1}^N L(y_i, F(x_i, \theta)) \right) \quad (2.3)$$

де $F(x_i, \theta)$ функція, що описує роботу самої моделі розпізнавання.

Важливо зазначити, що з математичної точки зору шукана функція $F(x_i, \theta)$ виконує складне нелінійне відображення з багатовимірного простору ознак (мільйонів пікселів вхідного зображення) у низьковимірний простір ймовірностей. При цьому на вихідний вектор передбачень накладається суворе математичне обмеження: сума обчислених ймовірностей для всіх K класів завжди має дорівнювати

одиниці, а кожне окреме значення має знаходитися в межах від 0 до 1. Це забезпечує коректність імовірнісної інтерпретації результатів класифікації насіння.

Крім того, мінімізація виключно емпіричного ризику не є кінцевою метою. Фундаментальною проблемою формалізації є досягнення моделлю високої здатності до узагальнення, тобто мінімізація істинного ризику очікуваної похибки на будь-яких нових, раніше не бачених даних. Вважається, що нові зображення насіння сої генеруються з того ж самого, але невідомого нам, істинного розподілу ймовірностей, що й навчальна вибірка.

Якщо набір параметрів θ^* буде занадто точно налаштований під рівняння (2.3), модель може просто «запам'ятати» навчальні приклади разом із їхніми випадковими шумами та специфічними умовами освітлення. Це призведе до явища перенавчання, коли похибка на навчальних даних прямує до нуля, але на нових фотографіях насіння система видає хибні результати.

Знайдений оптимальний набір параметрів θ^* повинен забезпечувати тонкий баланс: надійно мінімізувати функцію втрат, виявляючи спільні закономірності дефектів насіння, але при цьому залишатися стійким до природної варіативності нових візуальних ознак. Для досягнення цієї мети та забезпечення коректного відображення простору зображень у простір класів необхідно обрати відповідне сімейство функцій F , яке здатне ієрархічно виділяти візуальні ознаки.

2.2 Архітектурні особливості застосування моделі MobileNetV2

Для реалізації складної нелінійної функції $F(x, \theta)$, яка виконує відображення вхідного зображення насінниці у простір класів, у даній роботі застосовано архітектуру згорткової нейронної мережі. Враховуючи необхідність високої швидкості обробки даних та можливість подальшого розгортання системи на портативних пристроях із обмеженими обчислювальними ресурсами, за базову модель було обрано легковагову архітектуру MobileNetV2.

Головною архітектурною особливістю MobileNetV2 є використання глибинних роздільних згорток та інвертованих залишкових блоків. На відміну від

стандартних згорткових шарів, глибинна роздільна згортка розбиває процес обчислень на два етапи: просторову фільтрацію кожного каналу окремо та подальше комбінування отриманих ознак за допомогою згортки розміром 1×1 . Відповідно до розробленого методу, архітектура загальної моделі класифікації насіння сої складається з послідовності кількох ключових етапів перетворення тензорів:

1. Вхідний шар та попереднє оброблення, на вхід нейронної мережі подається зображення x фіксованої розмірності $224 \times 224 \times 3$ пікселів. Перед подачею до згорткових шарів значення інтенсивності пікселів масштабуються за допомогою функції нормалізації до діапазону $[-1, 1]$, що стабілізує процес градієнтного спуску та пришвидшує збіжність моделі.

2. Блок виділення просторових ознак, нормалізований тензор проходить через згорткову базу MobileNetV2 (без верхнього класифікаційного шару оригінальної мережі). Базова мережа діє як функція виділення ознак, генеруючи на виході багатовимірний тензор просторових ознак M просторової розмірності $H' \times W'$ із кількістю каналів D (для MobileNetV2 $D = 1280$).

3. Шар глобального усереднювального агрегування, Для переходу від тривимірних просторових карт ознак до одновимірного вектора застосовується операція GAP. Замість традиційного «вирівнювання», яке генерує величезну кількість параметрів, GAP обчислює середнє значення для кожного з D каналів ознак. Елемент v_d результуючого вектора v обчислюється за формулою:

$$v_d = \frac{1}{H'W'} \sum_{i=1}^{H'} \sum_{j=1}^{W'} M_{i,j,d} \quad (2.4)$$

де $M_{i,j,d}$ це активація нейрона в i -му рядку та j -му стовпці для каналу d . Цей крок суттєво зменшує ризик перенавчання моделі та робить її стійкою до просторових зсувів дефектів на зображенні насінини.

4. Шар регуляризації, з метою додаткового запобігання перенавчання до вектора ознак v застосовується оператор Dropout. У процесі навчання цей шар випадковим чином вимикає частину нейронів із заданою ймовірністю p (у даній моделі $p = 0.5$). Математично це виражається як поелементне множення вектора v на вектор r , згенерований з розподілу Бернуллі:

$$v_{\text{drop}} = v \odot r \quad (2.5)$$

де $r \sim \text{Bernoulli}(1 - p)$. Це змушує мережу не покладатися на окремі специфічні ознаки, а формувати більш робастне і розподілене представлення візуальних характеристик насіння.

5. Повнозв'язний класифікатор, фінальним етапом архітектури є щільний шар, який приймає на вхід регуляризований вектор ознак v_{drop} та виконує його лінійне перетворення. Для отримання кінцевих імовірностей належності до кожного з K класів якості насіння застосовується активаційна функція Softmax:

$$\hat{p}_k = \frac{\exp(w_k^T v_{\text{drop}} + b_k)}{\sum_{j=1}^K \exp(w_j^T v_{\text{drop}} + b_j)} \quad (2.6)$$

де \hat{p}_k це передбачена ймовірність того, що насінина належить до класу k (що відповідає значенню $F_k(x, \theta)$ з підрозділу 2.1);

w_k та b_k це вектор вагових коефіцієнтів та параметр зсуву повнозв'язного шару для відповідного класу.

Для більш глибокого розуміння обчислювальної ефективності обраної базової моделі необхідно детально розглянути структурні компоненти, що лежать в основі MobileNetV2, а саме: глибинну роздільну згортку та інвертовані залишкові блоки з лінійними вузькими місцями.

Глибинна роздільна згортка, у традиційних згорткових нейронних мережах стандартний шар виконує одночасно дві дії: фільтрацію просторових ознак та комбінування каналів. Це вимагає значних обчислювальних ресурсів. Архітектура MobileNetV2 розділяє цей процес на два незалежні етапи, що візуалізовано на рисунку 2.1.

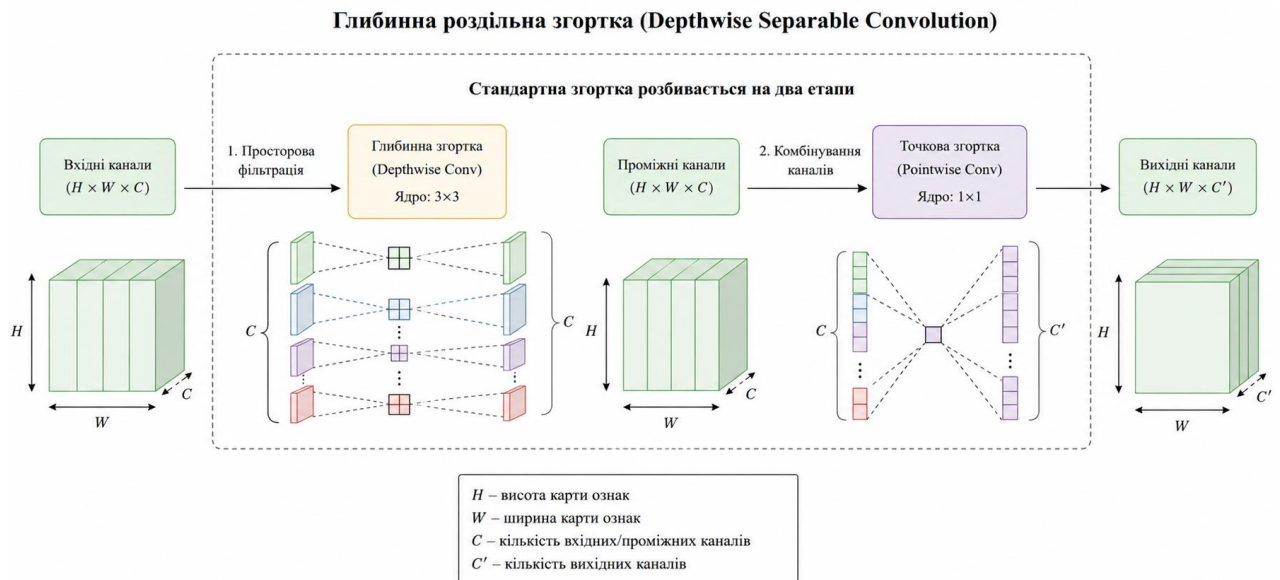


Рисунок 2.1 – Структурна схема глибинної роздільної згортки

Як показано на рисунку 2.1, глибинна роздільна згортка є фундаментальним механізмом декомпозиції, який дозволяє кардинально знизити обчислювальну складність нейронної мережі. У традиційному згортковому шарі фільтрація виконується одночасно у просторовому та каналному вимірах: кожен фільтр взаємодіє з усіма вхідними каналами одночасно для формування одного вихідного каналу. Такий монолітний підхід створює величезну кількість параметрів та вимагає колосальних обчислювальних ресурсів, що робить моделі занадто «важкими» для розгортання на периферійних пристроях в умовах реального агровиробництва. Архітектура MobileNetV2 елегантно вирішує цю проблему шляхом розділення процесу виділення ознак на дві ізольовані математичні операції.

Перший етап це просторова фільтрація. На цьому кроці застосовується єдиний двовимірний просторовий фільтр до кожного з C вхідних каналів цілком незалежно від інших. У контексті аналізу насіння сої цей етап має критичне значення: якщо попередній рівень мережі сформував набір каналів, що відповідають за різні кольорні градієнти або контурні карти, глибинна згортка дозволяє виокремити локальні морфологічні аномалії ізольовано. Вона обробляє лише геометрію зображення, виділяючи межі тріщин, краї пошкодженої оболонки або плямистості без передчасного змішування цієї інформації зі спектральними даними, зберігаючи при цьому початкову кількість проміжних каналів.

Оскільки глибинна згортка працює виключно в площині окремих каналів, отримана після неї інформація позбавлена міжканальних взаємозв'язків, які є необхідними для прийняття комплексних рішень. Для усунення цього недоліку застосовується другий етап, комбінування каналів, за допомогою точкової згортки. Вона використовує ядра розміром 1×1 для виконання лінійної комбінації просторово відфільтрованих каналів, формуючи необхідну кількість вихідних каналів C' . Саме цей крок дозволяє мережі синтезувати складні високорівневі ознаки. Наприклад, точкова згортка алгоритмічно об'єднує ізольовано знайдені патерни «зміни пігментації» та «порушення гладкості текстури» в єдиний семантичний вектор, який фінальний класифікатор згодом ідентифікує як клас «Уражене хворобами насіння».

З математичної точки зору, така просторово-канална декомпозиція забезпечує безпрецедентну оптимізацію процесу інференсу. Вартість обчислень у стандартній згортці є пропорційною добутку кількості вхідних та вихідних каналів на площу ядра. Розділення ж цих операцій перетворює мультиплікативну залежність на адитивну. На практиці це означає зменшення загальної кількості математичних операцій та вагових коефіцієнтів моделі у 8–9 разів (при використанні ядра 3×3). Завдяки цьому система набуває здатності обробляти візуальні дані просторової розмірності $H \times W$ безпосередньо з конвеєра в режимі реального часу, витрачаючи лише лічені мілісекунди на інспекцію кожної насінини, при цьому зберігаючи прецизійну точність розпізнавання дефектів.

Другою критично важливою інновацією є використання інвертованих залишкових блоків. У класичних залишкових мережах (наприклад, ResNet) блоки з'єднують шари з великою кількістю каналів, а всередині блоку відбувається стиснення для зменшення обчислень. У MobileNetV2 застосовано зворотну логіку, схему якої наведено на рисунку 2.2.

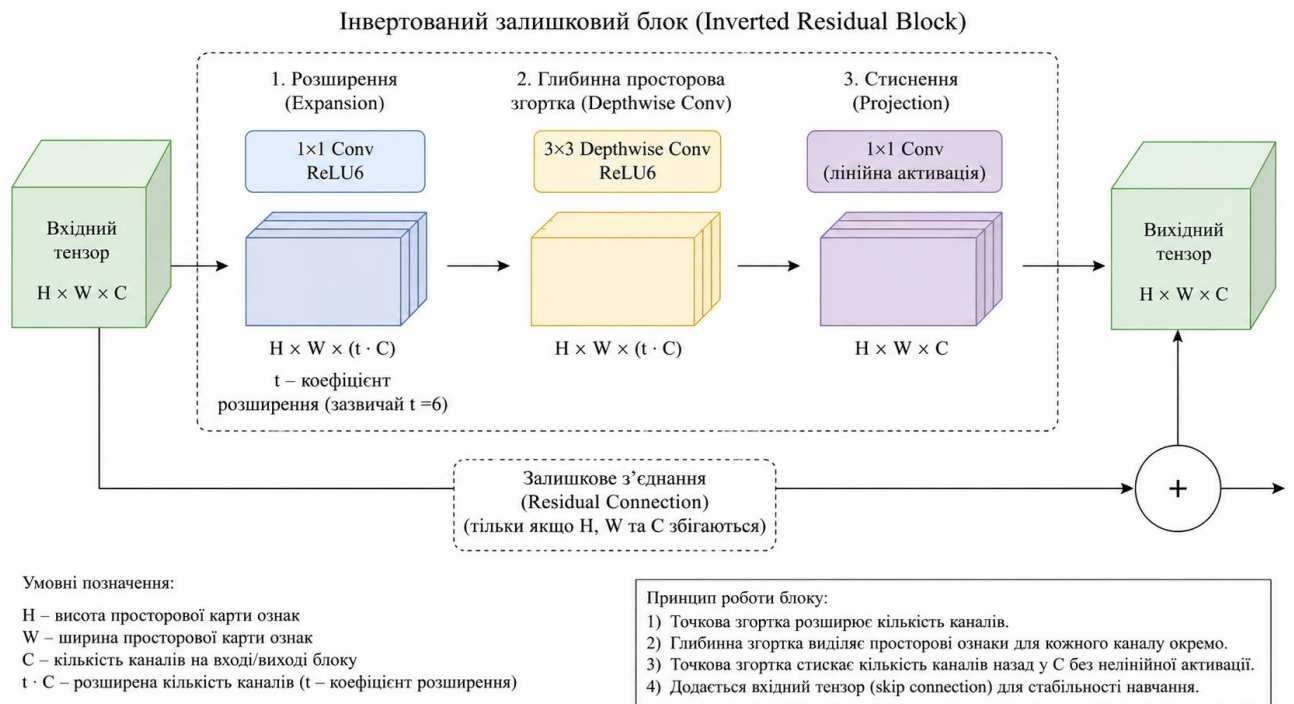


Рисунок 2.2 – Логічна схема інвертованого залишкового блоку

З рисунку 2.2, алгоритм інвертованого блоку складається з трьох етапів. Перший етап використовує точкову згортку 1×1 для збільшення кількості каналів вхідного тензора $H \times W \times C$ у t разів. Ознаки переходять у простір $H \times W \times (t \cdot C)$ із застосуванням стабільної для мобільних процесорів активації ReLU6.

На другому етапі глибинна згортка 3×3 незалежно обробляє кожен канал (також із ReLU6), фокусуючись на локальних геометричних дефектах насінини.

Третій етап стискає дані назад у низьковимірний простір згорткою 1×1 . Тут застосовується «лінійне вузьке місце» з лінійною активацією замість нелінійної, що запобігає незворотній втраті семантичної інформації. Крім того, за умови збігу розмірностей вхідного та вихідного тензорів, до блоку додається залишкове з'єднання. Воно забезпечує безперешкодне проходження градієнтів під час зворотного поширення помилки, гарантуючи стабільність навчання мережі.

Для візуалізації повного конвеєра перетворення даних, від отримання «сирого» зображення насінини до формування фінального класифікаційного вердикту, розроблено загальну архітектурну схему методу наведену на рисунку 2.3.




Рисунок 2.3 – Загальна архітектурна схема запропонованого методу класифікації насіння сої

Як видно з рисунка 2.3, розроблений конвеєр обробки даних концептуально розділений на два ієрархічні рівні: макрорівень загальної логіки функціонування та мікрорівень етапу «Обробка», який складається з трьох послідовних кроків.

Етап 1. Попереднє оброблення. Виконує нормалізацію пікселів вхідного зображення до стандартизованого діапазону. Це є обов'язковою умовою для стабілізації градієнтів та забезпечення рівномірного оновлення вагових коефіцієнтів під час навчання.

Етап 2. Екстракція ознак. Згорткова база MobileNetV2 діє як обчислювальне ядро, ієрархічно виділяючи специфічні мікротекстури дефектів сої. Після цього операція глобального усереднення просторово стискає масивні тривимірні карти ознак у компактний одновимірний вектор.

Етап 3. Класифікація ознак. Шар Dropout виконує роль імунітету проти перенавчання, руйнуючи випадкові зв'язки. Далі повнозв'язний шар комбінує виділені ознаки, а функція Softmax перетворює їх на нормований розподіл імовірностей для безпечного визначення кінцевого класу.

Така строга модульність чітко розмежує процеси зору (виділення ознак) та мислення, дозволяючи адаптувати класифікатор під нові стандарти якості без дороговартісного перенавчання всієї згорткової бази.

Для більш глибокого розуміння зв'язку між цими етапами, математичними перетвореннями та зміною розмірностей тензорів розроблено детальну схему, наведену на рисунку 2.4.

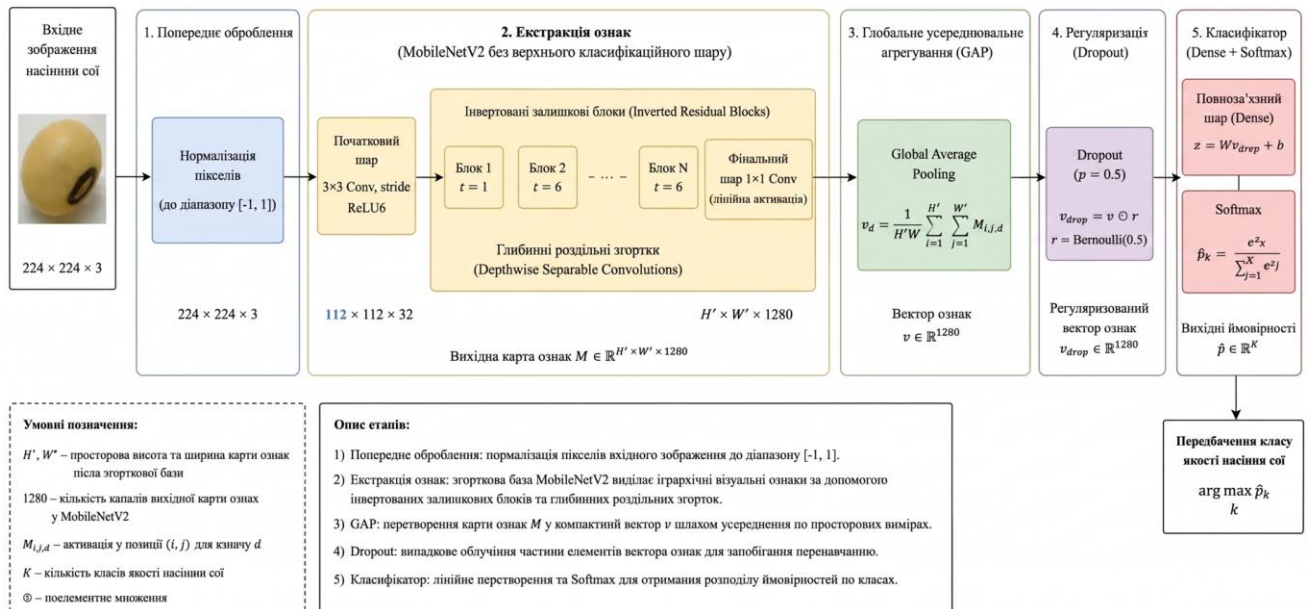


Рисунок 2.4 – Детальна схема екстракції ознак та нейромережевої класифікації насіння сої

Як деталізовано на рисунку 2.4, початкове зображення розміром $224 \times 224 \times 3$ після нормалізації та проходження через початковий шар перетворюється на тензор $112 \times 112 \times 32$. Далі серія інвертованих залишкових блоків формує фінальну карту ознак розмірністю $H' \times W' \times 1280$. Після операції GAP тривимірний тензор згортається у компактний вектор ознак \mathbb{R}^{1280} . Цей вектор подається на повнозв'язний шар, де обчислюються вихідні ймовірності \hat{p}_k та формується фінальне передбачення класу $\arg \max_k \hat{p}_k$. Така суворя відповідність розмірностей на кожному етапі гарантує обчислювальну ефективність методу.

Важливим аспектом обраної архітектури є використання концепції перенесення навчання. Оскільки базова модель MobileNetV2 була попередньо навчена на масштабному наборі даних ImageNet, її згорткові шари вже володіють здатністю розпізнавати базові геометричні примітиви, що значно скорочує час навчання та обсяг необхідних даних. Запропонована архітектура поєднує потужну здатність MobileNetV2 до екстракції складних візуальних патернів зі спеціально розробленою класифікаційною логікою, оптимізованою для конкретної задачі розпізнавання якості насіння сої.

2.3 Алгоритми нейромережевої класифікації насіння сої

Алгоритмічне забезпечення об'єднує математичні моделі та архітектурні рішення у єдину логічну послідовність за допомогою псевдокоду. У межах дослідження розроблено два взаємопов'язані алгоритми, що формують цілісний технологічний цикл.

Перший алгоритм описує процес розпізнавання насіння під час експлуатації системи. Другий алгоритм формалізує ресурсоемний процес двостадійної офлайн-оптимізації параметрів мережі. Такий алгоритмічний поділ гарантує, що експлуатаційна частина використовує вже готові вагові коефіцієнти і залишається обчислювально легкою. Це є критичною передумовою для успішної інтеграції моделі у швидкісні конвеєрні лінії сортування, де рішення ухвалюються в режимі жорсткого реального часу.

Алгоритм 2.1 – Нейромережева класифікація насіння сої за візуальними ознаками

Вхідні дані: Цифрове зображення насінини x ; набір оптимальних параметрів моделі θ^* .

Вихідні дані: Ідентифікований клас якості насінини \hat{y} .

1. $x_{raw} \leftarrow Resize(x, 224 \times 224)$ // Приведення вхідного масиву до стандартної розмірності

2. $x_{prep} \leftarrow Normalize(x_{raw}, [-1, 1])$ // Масштабування інтенсивності пікселів

3. $M \leftarrow MobileNetV2(x_{prep}, \theta_{base})$ // Екстракція ознак згортковою базою

4. $v \leftarrow GAP(M)$ // Агрегування просторових ознак за формулою (2.4)

5. $P(y = k | x, \theta) \leftarrow Softmax(v, w, b)$ // Розрахунок вектору ймовірностей за формулою (2.6)

6. $\hat{y} \leftarrow \arg \max_{k \in Y} P(y = k | x, \theta)$ // Вибір фінального рішення за правилом (2.1)

7. Повернути \hat{y}

Логіка Алгоритму 2.1 відображає процес інференсу, тобто прямого поширення сигналу крізь усі шари навченої нейронної мережі. Цей алгоритм активується виключно на етапі практичної експлуатації системи (наприклад, на сортувальній лінії), коли модель використовує вже оптимізований, заморожений набір вагових коефіцієнтів θ^* для аналізу нових, раніше невідомих даних.

На початковому етапі (кроки 1 та 2) відбувається підготовка вхідного цифрового сигналу. Оскільки згорткова архітектура MobileNetV2 оперує матрицями суворо визначеного розміру, оригінальне зображення насінини алгоритмічно масштабується до стандартизованого тензора розмірністю $224 \times 224 \times 3$ пікселі. Після цього виконується нормалізація: переведення абсолютних значень яскравості пікселів (від 0 до 255) у відносний діапазон $[-1, 1]$. Ця математична трансформація центрує дані навколо нуля, що є критично важливим для забезпечення чисельної стабільності, запобігання затуханню активацій та коректної роботи нелінійних функцій на наступних шарах мережі.

Третій крок становить обчислювальне ядро алгоритму. Нормалізований тензор x_{prep} пропускається через послідовність інвертованих залишкових блоків базової мережі. На цьому етапі відбувається ієрархічна екстракція візуальних патернів: від найпростіших градієнтів кольору до складних мікротекстур, що характеризують конкретні дефекти сої (тріщини, плями). Результатом цього кроку є багатовимірний тензор M , який містить просторово локалізовані карти ознак.

Ключовим моментом абстракції є четвертий крок, застосування операції Global Average Pooling. Цей оператор виконує математичне усереднення кожної двовимірної карти ознак, перетворюючи масивний тензор M на компактний одновимірний вектор v . Завдяки цьому кроку система набуває властивості трансляційної інваріантності: алгоритм починає ігнорувати точні координати розташування дефекту на поверхні насінини (зверху, збоку чи по центру), концентруючи всю увагу виключно на самому факті його наявності. Крім того, таке різке зменшення розмірності даних слугує потужним механізмом захисту від алгоритмічного перенавчання.

Фінальна стадія алгоритму (кроки 5 та 6) відповідає за прийняття рішення. Згенерований вектор ознак проходить через щільний шар, де функція Softmax нормує отримані значення, формуючи вектор імовірностей P . Кожен елемент цього вектора відображає ступінь впевненості моделі у належності насінини до одного з п'яти класів якості (здорове, бите, плямисте тощо). Завершується конвеєр застосуванням математичного правила $\arg \max$, яке обирає клас із максимальною ймовірністю, перетворюючи неперервний статистичний розподіл на єдину дискретну оцінку \hat{y} . Саме ця фінальна змінна безпосередньо передається на керуючий контролер конвеєра для фізичного відбраковування насіння.

Алгоритм 2.2 – Двостадійна оптимізація параметрів моделі

Вхідні дані: Навчальна вибірка зображень $D = \{(x_i, y_i)\}_{i=1}^N$; початкові ваги θ_{init} .

Вихідні дані: Налаштований набір вагових коефіцієнтів θ^* .

1. $\theta_{base} \leftarrow Freeze(\theta_{init})$ // Фіксація параметрів згорткової бази
 2. Для кожного пакета даних $(x_B, y_B) \in D$ виконувати:
 - $\hat{p} \leftarrow F(x_B, \theta)$ // Отримання передбачень для поточного пакета
 - $v_drop \leftarrow v \odot r$ // Регуляризація вектора ознак за формулою (2.5)
 - $Loss \leftarrow L(y, \hat{p})$ // Оцінка похибки за формулою (2.2)
 - $\theta \leftarrow Adam.Optimize(Loss)$ // Ітеративна мінімізація ризику згідно (2.3)
 3. $\theta_{base} \leftarrow Unfreeze(\theta, layers > 55)$ // Розмороження верхніх шарів для тонкої адаптації
 4. Повторити крок 2 з параметром швидкості навчання $lr = 10^{-5}$
 5. $\theta^* \leftarrow \theta$
 6. Повернути θ^*
-

Алгоритм 2.2 формалізує процедуру навчання моделі з використанням стратегії перенесення знань та поетапного тонкого налаштування. Застосування такого комплексного підходу є критично необхідним для вирішення задач агропромислової класифікації, де обсяг специфічних маркованих даних є недостатнім для повноцінного навчання глибокої нейромережі «з нуля» без ризику стрімкого перенавчання.

Перша стадія алгоритму (крок 1) виконує функцію так званого «прогріву». На цьому етапі відбувається жорстка фіксація (заморожування) матриць вагових коефіцієнтів усіх згорткових шарів базової архітектури MobileNetV2. Оскільки ці шари були попередньо оптимізовані на масштабному датасеті ImageNet, вони вже містять високоякісні фільтри для виділення універсальних геометричних примітивів (контурів, градієнтів, кутів).

Навчання (крок 2) відбувається виключно для нових, ініціалізованих випадковим чином ваг фінального повнозв'язного класифікатора. Такий алгоритмічний запобіжник є фундаментальним: оскільки на перших ітераціях похибка передбачення *Loss* є максимальною, пряме зворотне поширення цього гігантського градієнта крізь усю мережу призвело б до явища «катастрофічного забування», безповоротного руйнування корисних знань, вже закладених у згорткову базу.

Друга стадія (крок 3 та 4) ініціює процес глибокої доменної адаптації. Алгоритм виконує часткове «розмороження» верхніх глибинних шарів нейромережі. Математична логіка цього кроку полягає в тому, що початкові шари мережі відповідають за абстрактні ознаки (які є універсальними для будь-яких фотографій), тоді як верхні шари формують семантично складні патерни. Розморожування дозволяє специфічним нейронам переорієнтуватися та адаптувати свої вагові коефіцієнти до унікальних мікроознак насіння сої, таких як колірні некротичні плями, зморшкуватість або текстура механічних тріщин.

Важливою алгоритмічною умовою другої стадії є радикальне зменшення швидкості навчання, зазвичай на один-два порядки (наприклад, до 10^{-5}). Це гарантує, що оптимізатор вноситиме лише мікроскопічні корективи у вже добре налаштовані ваги, не виштовхуючи модель із локального мінімуму. Використання адаптивного оптимізатора Adam на обох стадіях гарантує динамічне обчислення індивідуальної швидкості навчання для кожного окремого параметра на основі перших та других моментів градієнта. У поєднанні з регулярною ін'єкцією шуму через шар Dropout (операція $v \odot r$), цей алгоритм ефективно згладжує ландшафт функції втрат, гарантуючи стабільну збіжність моделі до оптимального набору ваг θ^* з високою здатністю до узагальнення.

Для забезпечення цілісності опису запропонованого методу необхідно визначити головний алгоритм, який координує взаємодію процесів навчання та безпосереднього розпізнавання. Це дозволяє розглядати розроблену систему не як розрізнений набір математичних формул, а як єдиний, логічно завершений технологічний конвеєр обробки інформації, готовий до програмної імплементації. Такий системний підхід чітко розмежовує обчислювально складний етап підготовки моделі та оптимізований процес її практичної експлуатації, створюючи надійне підґрунтя для розробки кінцевого програмного забезпечення.

Алгоритм 2.3 – Загальна схема автоматизованого методу оцінки якості насіння сої

Вхідні дані: Навчальна вибірка зображень D ; нове вхідне зображення об'єкта x ; апріорні ваги ImageNet θ_{init} .

Вихідні дані: Кінцевий вердикт про категорію якості \hat{y} .

1. Етап підготовки (Навчання):

- Сформувати архітектуру $F(x, \theta)$ на базі MobileNetV2 за розділом 2.2.
- Виконати Алгоритм 2.2 для мінімізації емпіричного ризику (2.3).
- Отримати та зберегти набір оптимальних параметрів θ^* .

2. Етап експлуатації (Розпізнавання):

- Якщо отримано нове зображення x :
- Викликати Алгоритм 2.1 (Класифікація), передавши йому x та збережені ваги θ^* .
- Отримати ймовірнісний розподіл класів за формулою (2.6).
- Визначити фінальний клас \hat{y} за правилом максимізації (2.1).

3. Етап виводу:

- Сформувати результат класифікації для користувача.
 - **Повернути \hat{y} .**
-

Представлений алгоритм відображає повний життєвий цикл розробленого методу, концептуально розділений на дві стратегічні фази, що виконуються в різних апаратно-часових умовах.

Перша фаза (крок 1) це офлайн-навчання. На цьому етапі відбувається ітеративне налаштування внутрішніх зв'язків нейронної мережі шляхом обробки масиву історичних даних (навчальної вибірки). Математична модель "вчиться" розрізняти мікротекстури дефектів сої, посилаючись на процедуру складної двостадійної оптимізації, описану в Алгоритмі 2.2. Результатом цього обчислювально важкого процесу є створення статичного файлу вагових коефіцієнтів θ^* , який слугує цифровим зліпком отриманих мережею знань.

Друга фаза (крок 2 та 3) це онлайн-інференс, що описує безпосередню експлуатацію системи в реальному часі. Тут метод використовує вже сформований досвід (θ^*) для миттєвої обробки кожного нового вхідного кадру x , що надходить із камер сортувальної лінії. Завдяки посиланню на Алгоритм 2.1, головна схема наочно демонструє, як абстрактні тензори перетворюються на конкретні категорії якості. Фінальний етап виводу забезпечує конвертацію математичного результату у формат, придатний для подачі керуючого сигналу на скидач конвеєра або відображення в інтерфейсі оператора.

Таке суворе архітектурне розділення є критичним для практичної реалізації. Воно враховує інженерну специфіку задачі: етап навчання може тривати годинами та вимагати потужних серверів із графічними прискорювачами, тоді як етап розпізнавання оптимізований для виконання за лічені мілісекунди безпосередньо на малопотужних пристроях у цеху. Використання такої ієрархічної структури алгоритмів дозволяє повністю охопити роботу методу від формування математичного простору ознак до прийняття кінцевих агрономічних рішень.

2.4 Характеристика набору візуальних даних насіння сої

Для навчання, валідації та тестування розробленої архітектури нейронної мережі у даному дослідженні використовувався спеціалізований набір візуальних даних (датасет) насіння сої. Відповідний масив даних був отриманий з відкритої платформи для машинного навчання Kaggle, оригінальна назва «Soybean Seeds Classification Dataset» [41].

Загальний обсяг набору становить 5513 унікальних цифрових зображень. Важливою перевагою обраного датасету є те, що первинна класифікація насіння здійснювалася експертами відповідно до офіційних галузевих стандартів оцінки якості сої (зокрема, згідно зі стандартом GB1352-2009). Це забезпечує високу достовірність міток істинних класів, що є фундаментальною вимогою для коректного налаштування ваг моделі θ у процесі керованого навчання. Для наочної демонстрації специфіки вхідних даних наведено типовий зразок зображення з датасету, що належить до категорії битого насіння. Зображення битого насіння відображено на рисунку 2.5.




Рисунок 2.5 – Приклад візуальних даних із класу битого насіння

Як можна помітити, обраний формат та відсутність фонових перешкод дозволяють чітко ідентифікувати механічні пошкодження оболонки та внутрішню структуру насінини, що є критично важливим для коректної екстракції ознак на початкових шарах нейронної мережі.

Такий високий рівень стандартизації візуального представлення зберігається для всіх екземплярів сформованого масиву даних. Оскільки кожне зображення сфокусоване безпосередньо на об'єкті дослідження за стабільних умов освітлення, нівелюється негативний вплив тіней чи сторонніх артефактів зйомки, які часто стають причиною хибних спрацювань систем комп'ютерного зору.

Уся сукупність візуальних даних розділена на п'ять взаємовиключних категорій, що відображають різні фізичні стани, етапи дозрівання та дефекти насіння. Детальний кількісний розподіл зображень за класами, а також їхня відносна частка у загальній структурі датасету, наведено у таблиці 2.1.

Таблиця 2.1 – Кількісний розподіл зображень насіння сої за класами якості

№	Категорія якості насіння	Оригінальна назва класу	Кількість зображень	Частка вибірки, %
1	Здорове насіння	Intact soybeans	1201	21,78
2	Насіння з пошкодженою оболонкою	Skin-damaged soybeans	1127	20,44
3	Недозріле насіння	Immature soybeans	1125	20,41
4	Плямисте / уражене хворобами	Spotted soybeans	1058	19,19
5	Бите насіння	Broken soybeans	1002	18,18
Разом			5513	100,0

Аналіз даних, наведених у таблиці 2.1, свідчить про високий рівень збалансованості навчальної вибірки. Найбільш чисельний клас (Здорове насіння) містить 1201 зображення та складає 21,78 % від загального обсягу даних. Водночас найменш репрезентований клас (Бите насіння) налічує 1002 екземпляри, що відповідає 18,18 %. Різниця між максимальним та мінімальним значеннями становить лише 3,6 відсоткового пункту (або 199 зображень).

З математичної та алгоритмічної точок зору такий природний розподіл є вкрай сприятливим для навчання глибоких згорткових нейронних мереж. У задачах багатокласової класифікації значний дисбаланс даних часто призводить до деградації якості розпізнавання: алгоритм градієнтного спуску починає ігнорувати міноритарні класи, намагаючись мінімізувати загальну функцію втрат переважно за рахунок мажоритарних категорій. Оскільки частка кожного класу у даному датасеті

рівномірно коливається навколо ідеального показника у 20 % (для 5 класів), ризик виникнення алгоритмічного упередження зведено до абсолютного мінімуму. Нейронна мережа матиме змогу однаково ефективно коригувати свої вагові коефіцієнти для екстракції ознак як здорового насіння, так і специфічних дефектів.

Крім того, значна абсолютна кількість зображень у кожному класі (понад 1000 репрезентативних зразків) створює міцне статистичне підґрунтя для надійного навчання. Такий обсяг дозволяє системі засвоїти високу природну варіативність кольорів, геометричних форм та мікротекстур усередині кожної категорії. Навіть без застосування агресивних методів штучного збільшення вибірки, наявний датасет забезпечує достатнє інформаційне покриття, що є головною запорукою високої здатності навченої моделі до узагальнення під час аналізу нових, раніше невідомих фотографій насіння сої в умовах реального виробництва.

З технічної точки зору кожне зображення в датасеті збережене у растровому форматі .bmp. Використання цього формату гарантує відсутність артефактів стиснення та збереження оригінальної піксельної інформації щодо кольору й мікротекстури поверхні насінини.

Як видно з візуального аналізу вибірки, усі фотографії представляють собою попередньо сегментовані та відцентровані зображення окремих насінин, розміщені на однорідному чорному тлі. Таке попереднє низькорівневе оброблення (ізоляція об'єкта від фону) є надзвичайно корисним етапом підготовки даних. Воно дозволяє згортковій базі архітектури MobileNetV2 зосередити процес екстракції ознак виключно на морфологічних особливостях самої сої, виключаючи вплив сторонніх шумів чи елементів конвеєра.

Для практичної реалізації алгоритмів мінімізації емпіричного ризику (описаних у підрозділі 2.3) цей набір даних буде додатково приведений до єдиного тензорного розміру (наприклад, $224 \times 224 \times 3$), необхідного для подачі на вхідний шар обраної нейронної мережі, та розділений на незалежні навчальну, валідаційну і тестову вибірки.

2.5 Опис метрик оцінювання якості моделі глибокого навчання

Для кількісного оцінювання ефективності розробленого методу класифікації та верифікації здатності моделі MobileNetV2 до узагальнення, необхідно використовувати систему взаємодоповнюючих метрик. Оскільки задача розпізнавання якості насіння сої є багатокласовою, кожна метрика обчислюється на основі значень матриці помилок, яка враховує чотири типи прогнозів для кожного класу:

- TP – модель правильно ідентифікувала клас;
- TN – модель правильно відхилила клас;
- FP – модель помилково віднесла об'єкт до цього класу;
- FN – модель пропустила об'єкт цього класу.

Перехід від абсолютних значень матриці помилок до відносних статистичних показників зумовлений необхідністю отримання інваріантної оцінки якості моделі. Самі по собі числа TP або FN не дозволяють об'єктивно порівнювати різні архітектури, якщо вони тестуються на вибірках різного обсягу або з різним ступенем нерівномірності розподілу класів. Використання похідних метрик дозволяє нормалізувати ці дані, перетворюючи їх на стандартизовані коефіцієнти, що відображають специфічні аспекти прогностичної здатності нейронної мережі.

Важливим аспектом такого аналізу є врахування «ціни помилки» в контексті прикладної задачі агропромислового сектору. У математичній статистиці помилки першого та другого родів мають різну вагу. Для автоматизованого сортування насіння сої критичним є мінімізація саме пропусків дефектів, оскільки потрапляння зараженої одиниці у загальну партію може призвести до масштабних біологічних та фінансових втрат. Розрахунок комплексних метрик дозволяє досліднику зміщувати фокус моделі у бік більшої чутливості або, навпаки, вищої специфічності, залежно від вимог технологічного процесу.

Крім того, кожна з наведених нижче метрик є фактично математичною проекцією багатовимірної продуктивності нейронної мережі на одновимірну шкалу. Це дозволяє не лише констатувати факт успішного навчання, а й діагностувати

специфічні проблеми моделі: схильність до надмірної впевненості у хибних рішеннях або нездатність виділяти стійкі візуальні ознаки при низькій якості вхідного сигналу. Такий багатогранний підхід є галузевим стандартом у розробці інтелектуальних систем на базі архітектур типу MobileNet, де висока швидкість обчислень має обов'язково поєднуватися з прецизійною точністю класифікації.

Нижче наведено детальний опис основних показників, що зазвичай застосовуються в галузі глибокого навчання для системної оцінки класифікаційних методів:

1. Загальна точність, це найбільш розповсюджена метрика, що відображає частку правильних прогнозів серед усіх поданих зразків. Для архітектур сімейства MobileNet традиційно виділяють показники Top-1 Accuracy (найбільш імовірний клас збігається з істинним) та Top-5 Accuracy (істинний клас входить до п'ятірки найбільш імовірних). Математично загальна точність виражається формулою:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.7)$$

Хоча Accuracy є інтуїтивно зрозумілою, вона може бути оманливою у випадку дисбалансу класів (наприклад, якщо здорового насіння значно більше, ніж битого). Тому в даному дослідженні основна увага приділяється більш специфічним метрикам.

2. Точність за класом, метрика Precision (позитивна прогностична здатність) показує, яку частку об'єктів, що були віднесені моделлю до певного класу якості, справді належать до цього класу. Вона дозволяє оцінити "чистоту" роботи алгоритму та рівень хибних спрацювань:

$$Precision = \frac{TP}{TP + FP} \quad (2.8)$$

Високе значення Precision означає, що якщо модель ідентифікувала насінину як "уражену хворобою", то ймовірність помилки, є мінімальною.

3. Повнота, recall визначає частку об'єктів певного класу, які модель змогла знайти серед усіх існуючих представників цього класу у вибірці. Це критично важлива метрика для сортування насіння, оскільки вона показує здатність системи не пропускати дефектні зразки:

$$Recall = \frac{TP}{TP + FN} \quad (2.9)$$

Для контролю якості насіння сої висока повнота є пріоритетною, оскільки пропуск навіть однієї зараженої насінини може призвести до псування всієї партії.

4. F1-міра, оскільки часто існує обернена залежність між Precision та Recall, для отримання єдиної збалансованої оцінки використовується F1-міра. Вона є середнім гармонійним між точністю та повнотою і досягає свого максимуму лише тоді, коли обидва показники є високими:

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (2.10)$$

Саме F1-Score використовується у даній роботі як основний критерій при виборі найкращої ітерації моделі під час навчання.

5. Специфічні апаратно-орієнтовані метрики архітектури MobileNetV2. Окрім класичних статистичних метрик якості прогнозів, зразковою практикою при використанні моделей мобільного сімейства (згідно з оригінальною документацією Sandler et al., 2018) є оцінка їхньої обчислювальної ефективності. Оскільки розроблений метод класифікації насіння сої орієнтований на потенційне розгортання в умовах реального агропромислового виробництва (на вбудованих системах, мікроконтролерах або портативних терміналах), паралельно з точністю вимірюються специфічні профільні показники:

– Кількість параметрів та обсяг пам'яті. Ця метрика визначає загальну кількість вагових коефіцієнтів нейронної мережі, що підлягають навчанню. Вона напряму корелює з фізичним обсягом оперативної та постійної пам'яті, необхідної для збереження моделі на пристрої. Завдяки інвертованим залишковим блокам, MobileNetV2 дозволяє утримувати цей показник на рівні близько 2-3 мільйонів параметрів, що робить її ідеальною для Edge-пристроїв.

– Мультиплікативні операції та FLOPs. Floating Point Operations, це фундаментальна метрика, що визначає математичну складність одного проходу зображення через мережу. Використання глибинних роздільних згорток у MobileNetV2 дозволяє зменшити кількість MAdds майже у 8–10 разів порівняно зі

стандартними згортковими мережами типу VGG-16 чи ResNet, мінімізуючи тепловіддачу та енергоспоживання процесора.

– Затримка інференсу. Відображає час у мілісекундах, який витрачає апаратно-програмний комплекс на обробку одного вхідного зображення насінини. Для автоматизованих сортувальних ліній цей показник є критичним, оскільки пневматичні ежектори конвеєра вимагають прийняття рішення за долі секунди.

– Пропускна здатність. Метрика, що є похідною від затримки інференсу, та визначає кількість кадрів, які система здатна класифікувати за одну секунду. Математично пропускна здатність виражається формулою:

$$FPS = \frac{1}{T_{inference}} \quad (2.11)$$

де $T_{inference}$ це середній час обробки одного зображення у секундах. Високий показник FPS гарантує, що комп'ютерний зір не стане «вузьким місцем» і не гальмуватиме фізичну швидкість руху конвеєрної стрічки.

Використання наведеного комплексу класифікаційних та апаратно-орієнтованих метрик дозволяє всебічно оцінити розроблений метод. Це дає можливість не лише підтвердити високу математичну коректність роботи моделі з візуальними патернами сої, а й науково обґрунтувати її придатність та рентабельність для впровадження у реальні технологічні процеси.

2.6 Сценарії проведення експерименту

Для забезпечення об'єктивності результатів експериментів використовувався метод відкладеної вибірки. Основний масив емпіричних даних було розподілено у пропорції 80/20 (навчальна та валідаційна вибірки відповідно). Оскільки статичні зображення, на відміну від відеопотоку, не мають часової кореляції, поділ здійснювався випадковим чином, але з обов'язковим збереженням стратифікації пропорційного представлення кожного з п'яти класів якості у всіх вибірках. Навчальна вибірка застосовується для безпосередньої оптимізації ваг нейромережі, тоді як валідаційна для контролю гіперпараметрів та своєчасного

запобігання перенавчанню. Для фінальної перевірки та підтвердження узагальнюючої здатності алгоритму використовуються дані з ізольованої тестової підвибірki, яку модель не обробляла на етапі навчання.

Для всебічної та об'єктивної оцінки ефективності розробленого методу класифікації насіння сої програма експериментальних досліджень реалізується у вигляді наступної послідовності кроків:

Крок 1. Підготовка апаратно-програмного середовища. Розгортання ізольованого тестового середовища з використанням графічних прискорювачів для забезпечення відтворюваності результатів, пришвидшення процесу мінімізації емпіричного ризику та коректного вимірювання часових характеристик роботи алгоритмів.

Крок 2. Оцінка точності багатокласової класифікації. Тестування навченої нейромережі MobileNetV2 на здатність коректно розрізнити візуальні патерни дефектів сої. Базовий контроль якості здійснюється за допомогою аналізу матриці помилок на тестовій вибірці. Додатково для кожного з п'яти цільових класів (Здорове, Бите, Недозріле, З пошкодженою оболонкою, Уражене хворобами) обчислюються метрики Precision, Recall та збалансована F1-міра.

Крок 3. Дослідження стабільності процесу навчання. Перевірка здатності алгоритму до генералізації ознак. Оцінка здійснюється шляхом аналізу динаміки навчання: чисельного та візуального порівняння кривих функції втрат та загальної точності на навчальній і валідаційній вибірках протягом усіх епох. Це дозволяє підтвердити ефективність методів регуляризації.

Крок 4. Аналіз обчислювальної ефективності. Визначення здатності алгоритму функціонувати в умовах обмежених апаратних ресурсів, що є критичним для потенційного розгортання системи на портативних пристроях агрономів або промислових мікроконтролерах. На цьому етапі фіксується загальний розмір моделі (кількість параметрів) та вимірюється середній час інференсу, витрачений на повний цикл обробки однієї фотографії насінини.

Крок 5. Порівняльний аналіз та валідація стратегії навчання. Зіставлення отриманих експлуатаційних метрик до та після застосування стратегії тонкого

налаштування верхніх шарів архітектури. Кількісне обґрунтування доцільності використання Transfer Learning порівняно з навчанням базових моделей з нуля та підтвердження готовності системи до автоматизованого контролю якості сировини.

Для наочного представлення логіки та взаємозв'язку етапів тестування, загальну структурну схему програми експериментальних досліджень візуалізовано на рисунку 2.6.

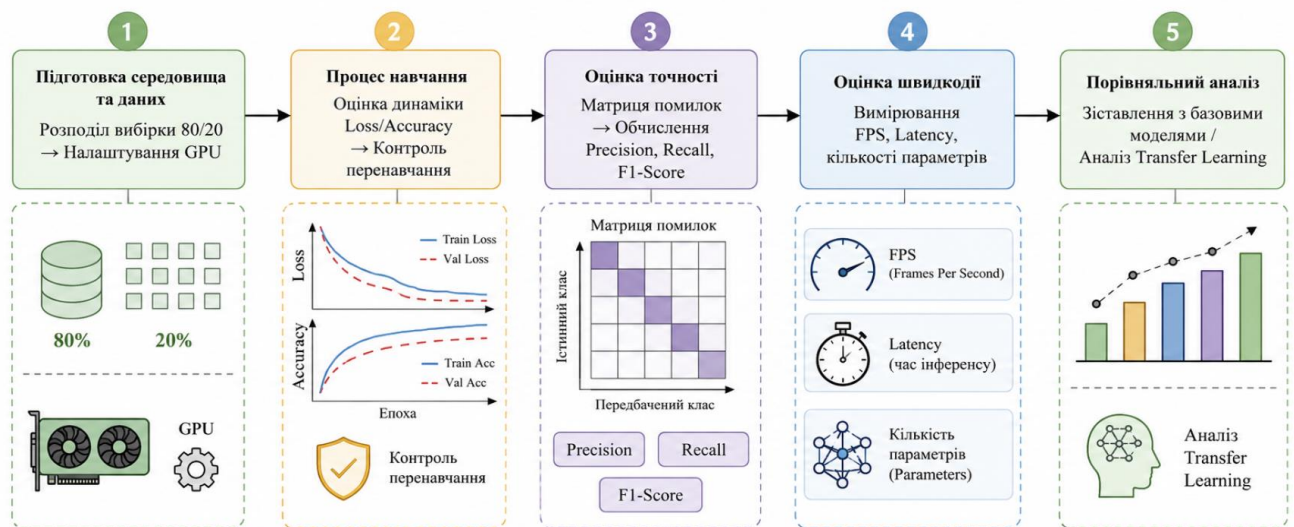


Рисунок 2.6 – Структурна схема програми експериментальних досліджень методу класифікації

Послідовне виконання описаних кроків забезпечить комплексну та об'єктивну оцінку розробленого методу. Отримані емпіричні дані дозволять не лише науково обґрунтувати доцільність заміни суб'єктивної ручної експертизи на автоматизований комп'ютерний зір, але й сформулюють надійну технічну базу для подальшої реалізації системи. Зокрема, підтверджені показники точності та швидкодії стануть фундаментом для створення спеціалізованого клієнт-серверного веб-застосунку, орієнтованого на оперативну роботу агрономів та працівників насіннєвих лабораторій.

2.7 Висновки до розділу 2

У другому розділі було здійснено комплексне теоретичне та алгоритмічне обґрунтування методу автоматизованої класифікації насіння сої за візуальними ознаками. Задачу агропромислового контролю якості було успішно переведено у

площину точних математичних обчислень шляхом її формалізації як імовірнісної багатокласової класифікації з учителем. Впровадження функції категоріальної перехресної ентропії та визначення процесу мінімізації емпіричного ризику дозволило сформулювати строгу мету для навчання інтелектуальної системи.

Як фундаментальне архітектурне рішення для екстракції візуальних ознак було обрано згорткову нейронну мережу сімейства MobileNetV2. Детальний аналіз її внутрішніх механізмів підтвердив її оптимальність для задач машинного зору в умовах обмежених обчислювальних ресурсів. Використання глибинних роздільних згорток та інвертованих залишкових блоків дозволило радикально знизити кількість математичних операцій без втрати здатності моделі виявляти складні мікротекстури дефектів сої. Доповнення згорткової бази специфічними шарами глобального усереднення та регуляризації забезпечило створення надійного класифікатора, стійкого до просторових зсувів на зображенні та алгоритмічного перенавчання.

Для практичної імплементації методу було проаналізовано репрезентативний датасет обсягом 5513 зображень, який відзначається високим рівнем збалансованості між п'ятьма класами якості. Спираючись на специфіку архітектури було сформовано комплексну систему оцінювання розробленого методу. Ця система поєднує класичні статистичні показники з критично важливими апаратно-орієнтованими метриками. Такий підхід гарантує, що модель не лише демонструватиме високу точність розпізнавання, але й відповідатиме часовим обмеженням пневматичних сортувальних машин.

Математичні, архітектурні та алгоритмічні рішення, викладені у даному розділі, формують повноцінну теоретичну базу та повністю готові до етапу практичної програмної реалізації та експериментального тестування, результати яких будуть наведені у наступному розділі роботи.

Розділ 3 Експериментальне дослідження методу нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання

3.1 Програмна реалізація веб-застосунку SoyNet AI

Для практичної апробації розробленого методу нейромережевої класифікації насіння сої та проведення експериментальних досліджень було спроектовано та реалізовано інтелектуальний веб-застосунок під назвою SoyNet AI. Система побудована за клієнт-серверною архітектурою, де користувацький інтерфейс забезпечує зручну взаємодію з користувачем, а серверна частина, відповідає за безпосереднє виконання інференсу моделі машинного навчання.

Вибір формату веб-застосунку зумовлений необхідністю забезпечення кросплатформності та швидкого безперешкодного доступу до аналітичного інструментарію. Це дозволяє експертам-агрономам та фахівцям насінневих лабораторій використовувати систему з будь-якого пристрою, що має доступ до мережі Інтернет. Такий підхід повністю усуває потребу у встановленні додаткового спеціалізованого програмного забезпечення чи наявності потужних локальних обчислювальних ресурсів на робочих місцях, оскільки всі ресурсоємні операції виконуються на стороні сервера.

Серверна логіка розробленого застосунку відповідає за прийом запитів із графічними файлами, їх попередню валідацію та передачу до ізольованого Python-середовища. У цьому модулі завантажена оптимізована архітектура MobileNetV2 здійснює швидкий математичний аналіз вхідних даних. Після завершення інференсу отримані результати у вигляді масивів ймовірностей конвертуються у стандартизований формат обміну даними та повертаються на клієнтську частину.

Візуальна взаємодія користувача з цим обчислювальним ядром реалізована через сучасний графічний інтерфейс. Головна сторінка застосунку знайомить користувача з можливостями системи та описує п'ять основних класів дефектів насіння сої, які здатна розпізнавати навчена нейромережева модель. Дана система відображена на рисунку 3.1.

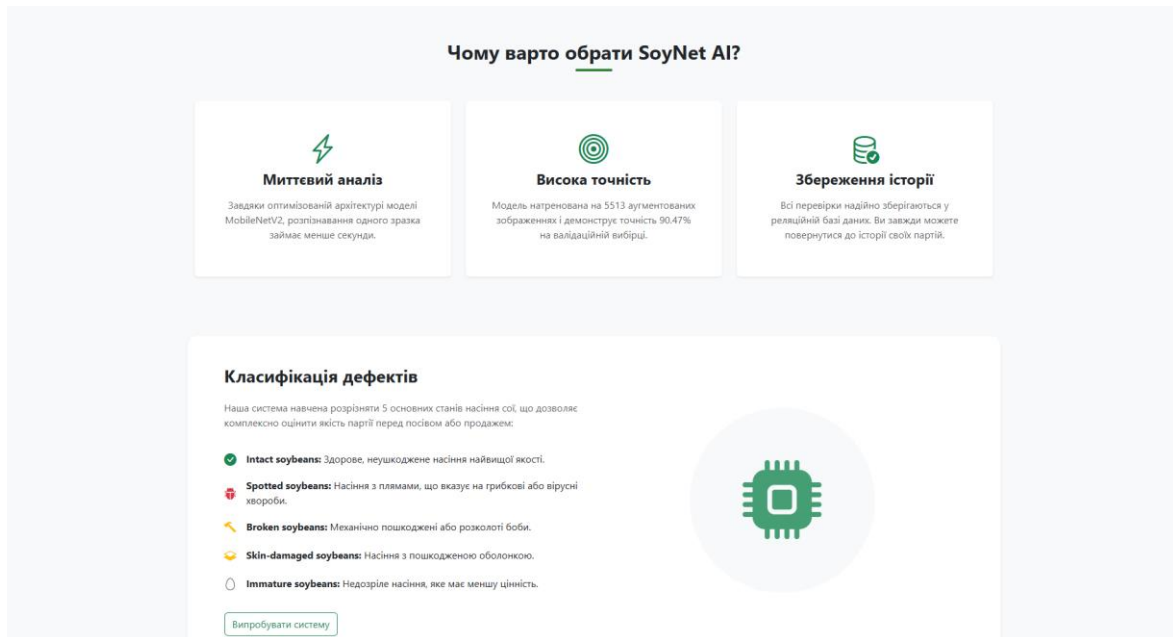


Рисунок 3.1 – Головна сторінка інтелектуального веб-застосунку SoyNet AI

Для забезпечення безпеки даних та персоналізації роботи застосовується система авторизації користувачів. Використання індивідуальних облікових записів є необхідною умовою для захисту інформації аграрних підприємств та забезпечення конфіденційності результатів інспекцій. Кожен користувач працює в ізольованому робочому середовищі, що гарантує збереження приватності досліджень та унеможливорює несанкціонований доступ до історії перевірок сторонніми особами. Після успішного входу в систему користувач отримує доступ до основного інструментарію, а саме до модуля сканер насіння.

Процес ініціалізації аналізу починається із завантаження цифрового зображення насінини. З метою оптимізації мережевого трафіку та забезпечення коректної роботи алгоритмів комп'ютерного зору, на клієнтському рівні реалізовано механізм попередньої валідації вхідних даних. Форма підтримує завантаження стандартних растрових форматів із лімітом розміру файлу до 5 МБ, що дозволяє уникнути перевантаження сервера та гарантує передачу якісних зображень без надмірного стиснення.

Важливою архітектурною особливістю форми завантаження є можливість додавання супровідних метаданих партії, таких як регіон, назва господарства, ідентифікатор поля та номер партії. Фактично, заповнення цих полів формує повноцінний цифровий паспорт досліджуваного зразка. Це дозволяє

структурувати дані для подальшої статистичної обробки та прив'язувати результати класифікації до конкретних партій посівного матеріалу. Завдяки такій архітектурі агрономи отримують змогу проводити просторовий та часовий аналіз поширення певних дефектів або хвороб сої в межах різних полів чи регіонів. Інтерфейс завантаження зображення насінини із супровідними даними відображено на рисунку 3.2.

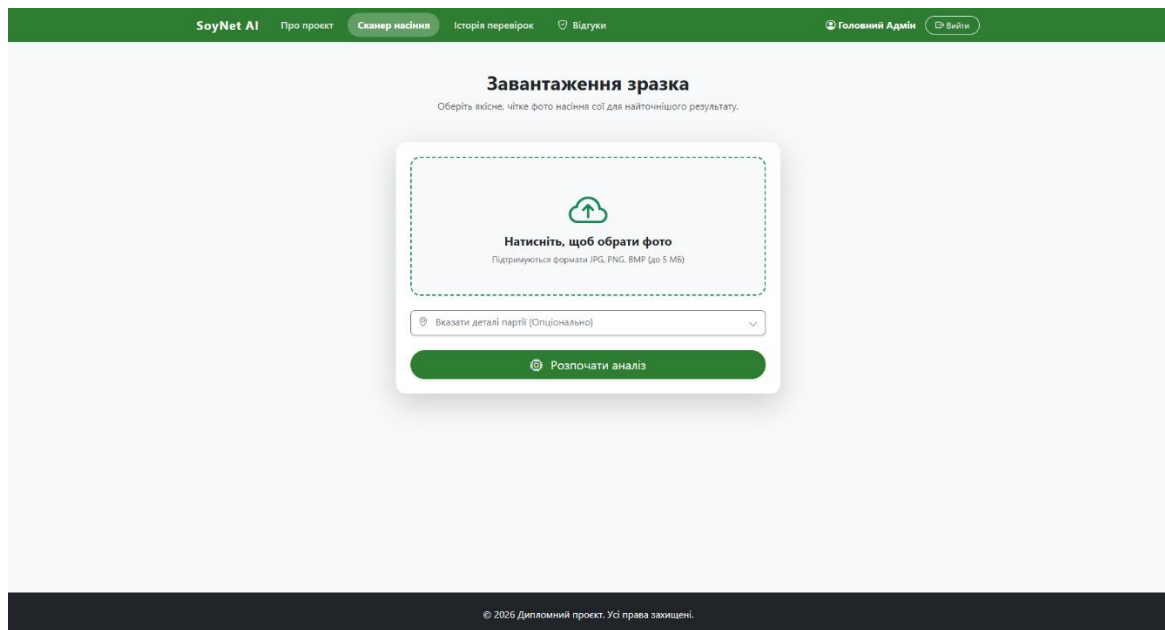


Рисунок 3.2 – Інтерфейс завантаження зображення насінини із супровідними даними

Після відправки форми зображення передається на сервер, де проходить етап попередньої обробки. Оскільки обрана архітектура нейронної мережі оперує тензорами суворо визначеної форми, вхідний графічний файл алгоритмічно масштабується до базової роздільної здатності 224x224 пікселі. Одночасно з ресайзингом проводиться нормалізація значень інтенсивності пікселів у діапазоні $[0, 1]$, що є критично важливим для забезпечення чисельної стабільності градієнтів та коректної роботи активаційних функцій на глибинних шарах мережі. Після виконання цих підготовчих операцій оброблений масив даних подається на вхід навченої моделі MobileNetV2. Завдяки використанню оптимізованих роздільних згорток, процес обробки займає долі секунди, що дозволяє системі працювати з високою пропускнуою здатністю. По завершенню інференсу користувач перенаправляється на сторінку результатів класифікації.

Дизайн інтерфейсу сторінки результатів розроблений із фокусом на максимальну інформативність та об'єктивність висновків. На сторінці виводиться завантажене зображення та головний діагноз із зазначенням відсотка впевненості моделі (наприклад, Broken soybeans із впевненістю 89.84%). Цей показник слугує для агронома кількісним індикатором надійності розпізнавання: чим вищий рівень впевненості, тим менша ймовірність помилкової ідентифікації через випадкові шуми або специфічні умови освітлення під час зйомки.

Для забезпечення строгої емпіричної верифікації роботи моделі та прозорості алгоритму прийняття рішень, система також генерує гістограму детального розподілу ймовірностей за всіма п'ятьма класами якості. Наявність повної статистичної картини за кожним класом дозволяє уникнути проблем «чорної скриньки», властивих багатьом інтелектуальним системам. Це дозволяє експерту наочно оцінити, наскільки впевнено алгоритм відмежував виявлений дефект від інших візуально схожих станів, наприклад, розрізняючи глибокі механічні тріщини та локальні плямистості, викликані хворобами. Візуалізація результатів класифікації та детального розподілу ймовірностей відображена на рисунку 3.3.

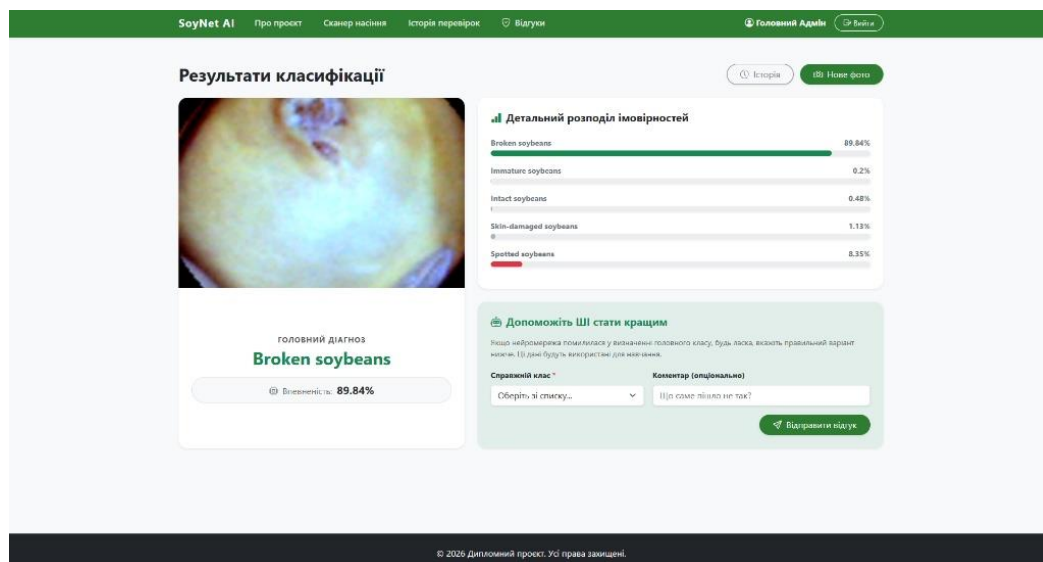


Рисунок 3.3 – Візуалізація результатів класифікації та детального розподілу ймовірностей

Для безперервного контролю якості інференсу в реальних умовах експлуатації та підтримки високого рівня достовірності технічної звітності, на сторінці результатів реалізовано блок зворотного зв'язку. Впровадження такого

інструменту реалізує на практиці сучасну концепцію «людина в циклі», яка є галузевим стандартом для розробки та впровадження надійних промислових інтелектуальних систем. Експерт має змогу підтвердити діагноз або вказати справжній клас у разі алгоритмічної помилки, доповнивши свій висновок текстовим коментарем щодо специфіки конкретного зразка.

Ці верифіковані фахівцем дані є критично важливими для формування наборів даних під майбутнє донавчання класифікатора. Зібрана у такий спосіб інформація дозволяє цілеспрямовано виявляти складні крайові випадки та специфічні патерни, на яких поточна версія моделі демонструє невпевненість. Такий механізм зворотного зв'язку гарантує, що процес оптимізації вагових коефіцієнтів під час наступних ітерацій перенавчання базуватиметься на реальних, найбільш проблемних прецедентах з виробництва, що суттєво підвищить загальну точність нейромережі.

Для забезпечення інформаційної безпеки, цілісності та надійності зберігання зібраної аналітики, усі проведені перевірки автоматично зберігаються в реляційній базі даних. Використання реляційної структури гарантує чітку консистентність даних та можливість їх ефективного зв'язування з обліковими записами користувачів і метаданими партій. Уся збережена історія транзакцій доступна користувачеві у розділі історія сканувань, який фактично виконує функцію електронного журналу аудиту якості посівного матеріалу.

Інтерфейс модуля історії спроектовано так, щоб забезпечити максимально швидкий та інтуїтивно зрозумілий доступ до ключових метрик кожної проведеної експертизи. Окрім перегляду загального хронологічного переліку транзакцій, функціонал сторінки передбачає можливість поглибленого аналізу завдяки інтерактивній кнопці «Деталі». Її використання дозволяє експерту миттєво відновити повний контекст раніше виконаного дослідження, включаючи вихідне зображення зразка, введені метадані партії та оригінальну гістограму розподілу ймовірностей. Такий рівень деталізації перетворює сторінку історії зі звичайного статичного архіву на динамічний аналітичний інструмент, що дає змогу відстежувати зміни якості насінневого матеріалу впродовж усього виробничого

сезону та приймати обґрунтовані управлінські рішення на базі накопичених даних. Сторінка історії сканувань та верифікації результатів відображена на рисунку 3.4.

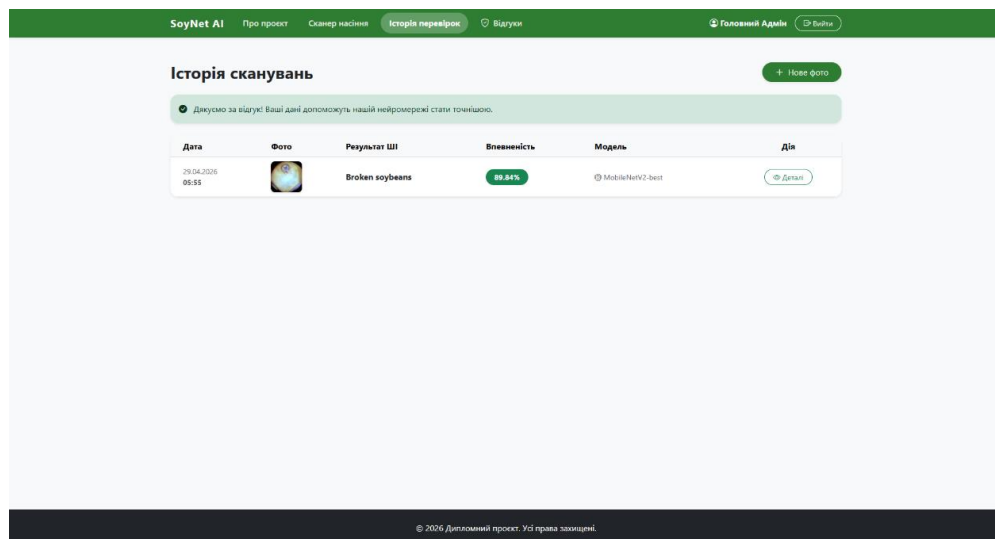


Рисунок 3.4 – Сторінка історії сканувань та верифікації результатів

Таблиця історії містить дату перевірки, мініатюру фотографії, ідентифікований результат із рівнем впевненості та інформацію про використану версію моделі. Даний модуль дозволяє агрономам оперативно повертатися до попередніх партій насіння, а розробникам збирати достовірну аналітику щодо загальної продуктивності та стабільності роботи інтелектуальної системи. Окрім базового перегляду, така структурована форма подачі інформації створює підґрунтя для запровадження розширених фільтрів та пошуку за конкретними партіями чи господарствами. Для розробників цей масив історичних даних слугує надійним індикатором так званого зсуву даних, ситуації, коли нові візуальні дані з реальних виробничих умов починають систематично відрізнятися від тих, на яких модель навчалася спочатку (наприклад, через зміну освітлення в лабораторії або появу нових підвидів хвороб). Це дозволяє вчасно виявляти необхідність оновлення вагових коефіцієнтів системи.

Для забезпечення безперервної емпіричної верифікації та контролю якості роботи системи на етапі практичної експлуатації, у вебзастосунку реалізовано спеціалізований модуль відгуки. Доступ до цього розділу є обмеженим і надається виключно адміністраторам системи. Обмеження доступу реалізовано на базі рольової моделі, що гарантує захист від несанкціонованого втручання або випадкового спотворення зібраної статистики звичайними користувачами. Лише

верифіковані адміністратори, які володіють достатньою експертизою, наділені правами модерувати ці дані. Це є критично важливим запобіжником проти явища «отруєння даних», яке може виникнути через випадково чи навмисно некоректно розмічені користувачами зразки перед етапом перенавчання.

Ця адміністративна панель акумулює всі повідомлення зворотного зв'язку, надіслані користувачами зі сторінки результатів класифікації у випадках незгоди з алгоритмічним вердиктом. Адміністратор має змогу аналізувати складні крайові випадки, коли нейромережа припустилася помилки, та переглядати уточнювальні коментарі експертів. У панелі кожний такий репорт представлений у вигляді зручної картки, де зіставлено початкове зображення, хибний вердикт штучного інтелекту та істинний клас, вказаний екпертом.

Фактично, даний модуль є програмним інструментом реалізації концепції активного навчання. Замість сліпого та ресурсоемного збору випадкових нових фотографій, система автоматично концентрує увагу адміністраторів на найбільш інформативних зразках, а саме тих, які знаходяться на межі розпізнавання для поточної моделі. Такий централізований збір верифікованих та розмічених спеціалістами даних є критично важливим етапом для підтримки високої точності розпізнавання, оскільки формує еталонну базу складних прецедентів для майбутніх ітерацій перенавчання моделі. Після модерації адміністратор може легко експортувати цей очищений масив нових даних для розширення тренувального датасету.

З точки зору архітектури користувацького інтерфейсу, модуль модерації спроектовано з урахуванням принципів ергономіки для швидкого опрацювання експертних оцінок. Інтерактивні елементи керування дозволяють здійснювати зручну візуальну навігацію та групування запитів. Оскільки кожен відгук супроводжується повним контекстом сканування, адміністратор має змогу виявляти приховані закономірності наприклад, систематичні помилки алгоритму при обробці зображень з певного господарства, які можуть бути спричинені специфічними умовами освітлення, налаштуваннями камер на місцях або появою нового локального підвиду хвороби насіння. Лише після ретельного аналізу та

остаточного підтвердження адміністратором, ці дані переходять у статус еталонних. Вкладка відгуків відображена на рисунку 3.5.

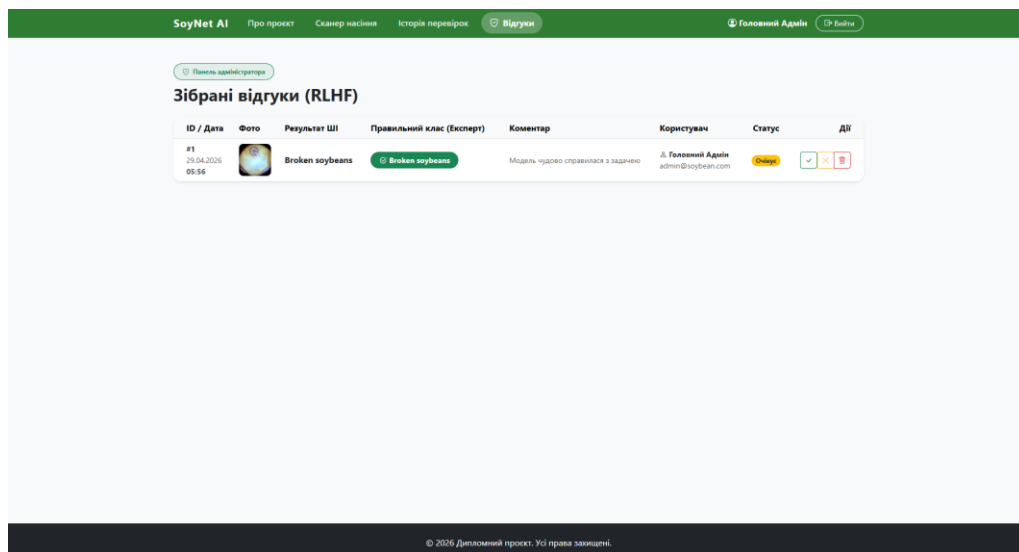


Рисунок 3.5 – Відповідна вкладка з прикладом отриманого відгуку

Розроблений інтелектуальний вебзастосунок SoyNet AI виступає не лише зручним графічним інтерфейсом для візуалізації роботи нейромережі, а й комплексною програмною платформою, що забезпечує повний цикл експлуатації та вдосконалення моделі. Реалізований функціонал доводить практичну життєздатність запропонованого методу в умовах реального агропромислового виробництва. Створене програмне середовище успішно вирішує завдання автоматизації візуального контролю якості посівного матеріалу та формує надійний інструментарій для безпосереднього проведення кількісних експериментальних досліджень ефективності алгоритму, детальний аналіз яких наведено у наступному підрозділі.

3.2 Аналіз результатів класифікації та обчислювальної швидкодії моделі глибокого навчання

3.2.1 Дослідження динаміки навчання та оптимізації вагових коефіцієнтів

Для об'єктивного оцінювання здатності розробленої нейромережевої моделі до генералізації візуальних ознак насіння сої було проведено детальний аналіз динаміки її навчання. Цей етап є критично важливим, оскільки він дозволяє не лише

констатувати кінцеву математичну точність, але й діагностувати внутрішні процеси оптимізації моделі, перевірити коректність обраних гіперпараметрів та довести стійкість розробленого методу до роботи в умовах реального агропромислового виробництва. Оцінка процесу навчання дає змогу переконатися, що високі показники точності є результатом виявлення справжніх закономірностей, а не наслідком звичайного запам'ятовування тренувальної вибірки моделлю.

Фундаментом для стабільного навчання стало коректне формування вхідного потоку інформації. Навчальна та валідаційна вибірки оброблялися пакетами по 32 зображення, що забезпечило оптимальний баланс між швидкістю оновлення градієнтів та раціональним використанням ресурсів графічного прискорювача. З метою підвищення стійкості моделі до варіативності фізичних умов на сортувальному конвеєрі, до навчальної вибірки було застосовано конвеєр штучної аугментації даних. Він включав випадкові горизонтальні та вертикальні відображення, ротації до 20%, а також динамічні зміни контрастності й яскравості. Це дозволило алгоритмічно розширити репрезентативність датасету та нівелювати вплив освітлення або випадкового кута розташування насінини під об'єктивом камери.

Безпосередній процес мінімізації емпіричного ризику відбувався у два етапи, що дозволило максимально ефективно використати обчислювальний потенціал обраної базової архітектури MobileNetV2. Перший етап базувався на парадигмі перенесення знань. На цій стадії всі згорткові шари моделі, які були попередньо навчені на масштабному наборі даних ImageNet, алгоритмічно заморожувалися. Оптимізації підлягали виключно ваги фінального повнозв'язного шару-класифікатора. Такий підхід гарантував збереження вже сформованих універсальних фільтрів виділення країв, ліній та базових текстур, м'яко адаптуючи їх під математичний простір п'яти класів якості сої.

Другий етап навчання полягав у процедурі тонкого налаштування (Fine-Tuning), яка ініціювалася після досягнення класифікатором початкової стабільності (після 15-ї епохи). Для цього було розморожено частину верхніх шарів згорткової бази, які відповідають за формування складних високорівневих семантичних ознак. Щоб запобігти явищу катастрофічного забування та різкому

руйнуванню існуючих корисних зв'язків великими градієнтами, базову швидкість навчання було зменшено на два порядки (до 10^{-5}). Це дозволило оптимізатору вносити лише філігранні корективи, адаптуючи верхні рівні абстракції моделі до специфічних мікротекstur дефектів сої: дрібних тріщин, зон ураження хворобами чи зморшкуватості недозрілої оболонки.

Для безперервного керування процесом навчання застосовувався потужний адаптивний алгоритм оптимізації Adam, а в ролі функції втрат виступала категоріальна перехресна ентропія. Щоб забезпечити максимальну автоматизацію та запобігти перенавчанню, в програмний код було інтегровано систему зворотних викликів. Алгоритм ReduceLROnPlateau динамічно зменшував швидкість навчання у моменти, коли функція втрат припиняла своє падіння, що сприяло більш плавному спуску в локальний мінімум. Водночас механізм ModelCheckpoint гарантував автоматичне збереження виключно тих вагових коефіцієнтів, які демонстрували найвищу загальну точність на незалежній валідаційній вибірці.

Комплексне застосування вищеописаних методів підготовки даних, двостадійної оптимізації та динамічного контролю гіперпараметрів створило надійне підґрунтя для успішного навчання. Зміна значень загальної точності та функції втрат на навчальній і валідаційній вибірках протягом усіх пройдених епох детально відображена на рисунку 3.6.

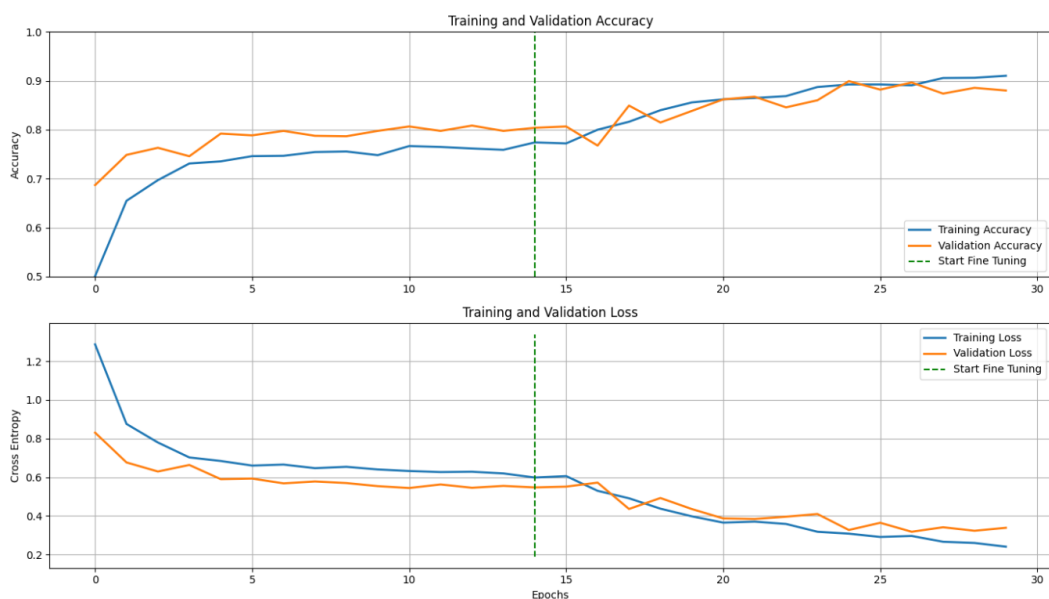


Рисунок 3.6 – Графіки зміни точності та втрат під час навчання моделі

Системний візуальний аналіз отриманих навчальних кривих дає змогу детально відстежити еволюцію оптимізації моделі та розкриває ключові аспекти поведінки алгоритму на різних стадіях навчання.

На першій стадії ініціалізації (епохи 0–14) градієнтний спуск застосовувався виключно до ваг фінального повнозв'язного шару-класифікатора. Як видно з верхнього графіка, на цьому етапі спостерігається стрімке і впевнене зростання точності: вже протягом перших трьох епох валідаційна точність здійснює різкий стрибок з 0.68 до майже 0.75, після чого плавно наближається до позначки 0.80. Водночас значення функції втрат демонструє стабільне зниження без різких аномальних коливань. Така поведінка системи має чітке наукове пояснення: попередньо навчені на масиві ImageNet фільтри базової архітектури MobileNetV2 одразу успішно виконують роль потужного екстрактора універсальних візуальних ознак, таких як базові кольорові градієнти, контури та геометричні примітиви. Цієї інформації виявилось достатньо для того, щоб новий класифікатор швидко знайшов базові закономірності для розділення насіння сої на класи.

Перехід до другої стадії, що на графіках відмічена вертикальною зеленою пунктирною лінією Start Fine Tuning, ініціював процес глибокої доменної адаптації моделі до специфіки предметної області. На цьому етапі було розморожено верхні згорткові блоки архітектури. Щоб уникнути ефекту забування та руйнування вже сформованих корисних фільтрів, базову швидкість навчання було превентивно зменшено на кілька порядків. Як чітко видно з обох графіків, цей крок повністю виправдав себе, дозволивши алгоритму вийти з локального мінімуму. Крива валідаційної точності отримала додатковий імпульс до зростання, стабільно наблизившись до позначки 0.90 на фінальних епохах. Відповідне продовження плавного зниження функції втрат на нижньому графіку свідчить про те, що нейромережа почала успішно розпізнавати семантично складні та специфічні для сої мікротекстури дефектів: мікротріщини, потемніння від хвороб, ознаки недозрілості або пошкодження оболонки, які неможливо було ідентифікувати за допомогою лише стандартних фільтрів ImageNet.

Важливим індикатором якості проведеної оптимізації, що беззаперечно підтверджується графіками, є відсутність ознак перенавчання. Протягом усього 30-епохового циклу криві валідаційної точності та втрат тісно корелюють із відповідними кривими навчальної вибірки. Валідаційні показники не демонструють деградації, яка зазвичай проявляється у стрімкому відриві кривої Training Loss вниз та зростанні Validation Loss вгору на пізніх ітераціях. Це є прямим доказом високої ефективності застосованого комплексу методів регуляризації. Зокрема, використання шару Dropout з імовірністю відключення нейронів 50% примусило мережу формувати резервні зв'язки та не покладатися на окремі пікселі зображення. Крім того, невеликі локальні флуктуації на валідаційних кривих є природним наслідком застосованої агресивної стратегії аугментації даних. Застосування випадкових поворотів, віддзеркалень, а також змін контрасту та яскравості дозволило імітувати реальні фізичні умови освітлення та положення насінин на промисловому конвеєрі, змусивши модель вивчати справжні морфологічні особливості дефектів, а не запам'ятовувати навчальну вибірку.

Підсумовуючи, аналіз динаміки навчання підтверджує надійну математичну збіжність розробленого алгоритму. Застосована стратегія двостадійної оптимізації у поєднанні з адаптивним оптимізатором Adam та механізмами динамічного зменшення кроку навчання забезпечила формування моделі. Алгоритм досяг оптимального балансу між точністю розпізнавання та здатністю до узагальнення, що робить отриману систему повністю готовою до детального кількісного оцінювання на рівні матриці помилок для окремих класів якості.

3.2.2 Оцінка точності розпізнавання класів якості насіння сої

Після підтвердження стабільності процесу навчання та відсутності перенавчання, що було доведено аналізом динаміки Loss та Accuracy, наступним кроком є детальна кількісна оцінка якості розпізнавання на рівні окремих категорій. Для багатокласової задачі контролю якості насіння загальна точність не є вичерпним

показником, оскільки не дозволяє виявити специфічні слабкі місця моделі та проаналізувати природу хибних спрацювань між візуально схожими дефектами.

Для формування об'єктивної оцінки розроблена модель, параметри якої були зафіксовані на етапі досягнення найкращих показників, була протестована на повному масиві незалежної валідаційної вибірки (1102 зображення). Процес тестування полягав у виконанні алгоритму прямого інференсу, де згенерований неймережею вектор імовірностей трансформувався у кінцеве рішення щодо класу насінини за правилом максимізації. Такий підхід дозволив покроково зіставити істинні експертні мітки якості з фактичними прогнозами системи. Результати цього зіставлення, які є необхідними для глибинного аналізу прогностичної здатності класифікатора, було формалізовано у вигляді двовимірної матриці помилок, яку наведено на рисунку 3.7.

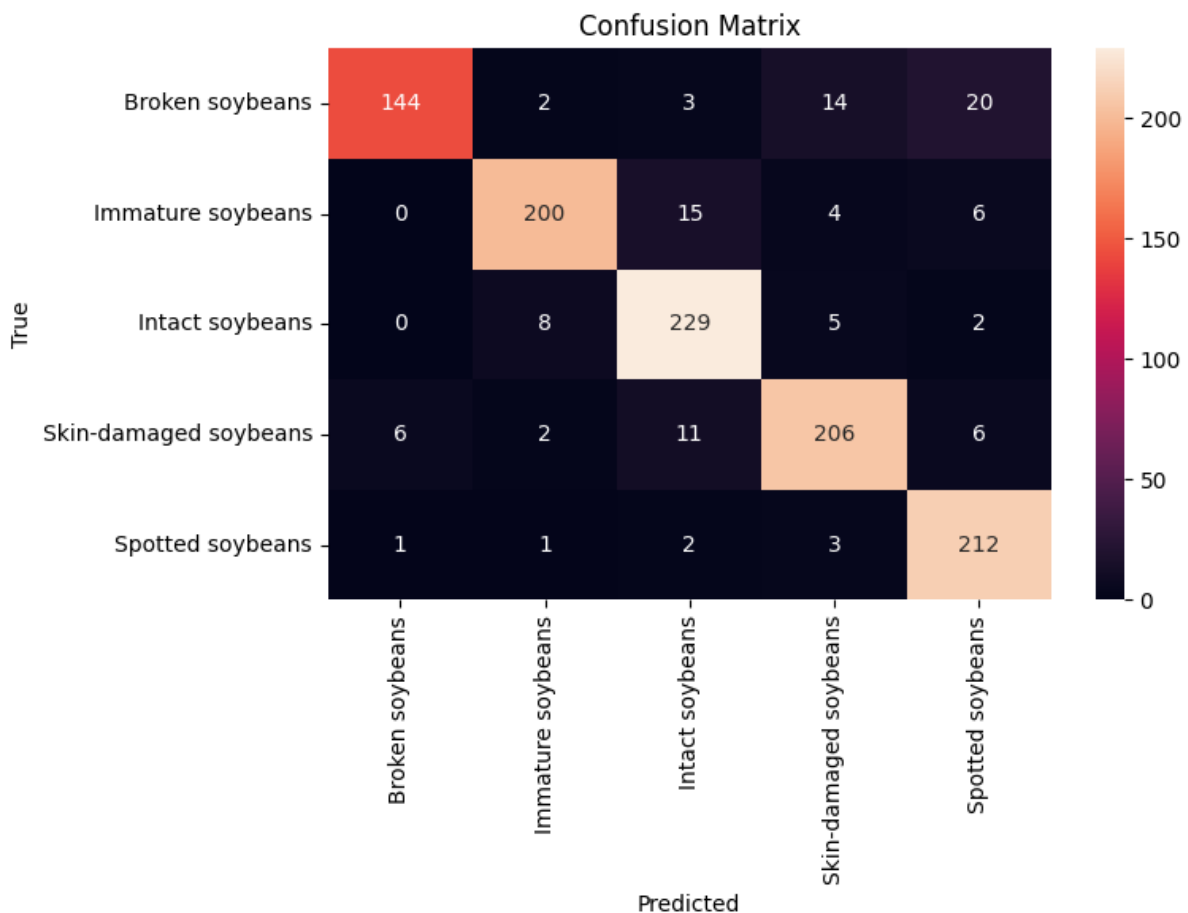


Рисунок 3.7 – Матриця помилок класифікації насіння сої

Аналіз головної діагоналі матриці помилок демонструє високу концентрацію правильних передбачень для всіх п'яти категорій. Однак,

найбільшу наукову та практичну цінність становить аналіз позадіагональних елементів, які ілюструють природу хибних спрацювань алгоритму. Наприклад, модель має певну схильність плутати біте насіння із плямистим (20 хибних класифікацій), та з пошкодженою оболонкою (14). З точки зору комп'ютерного зору це є закономірним: глибокі тріщини або відсутність частини насінини створюють на зображенні темні тіньові зони, які згорткова мережа може інтерпретувати як місце ураження або поверхневе пошкодження оболонки.

Для формалізації цих спостережень та переходу до стандартизованих оцінок, на базі отриманої матриці помилок було розраховано ключові класифікаційні метрики: точність за класом, повноту та збалансовану F1-міру. Результати розрахунків зведено у таблицю 3.1.

Таблиця 3.1 – Зведені результати оцінювання якості багатокласової класифікації

Категорія якості	Precision	Recall	F1-Score	Кількість зразків
Здорове насіння	0.88	0.94	0.91	244
Бите насіння	0.95	0.79	0.86	183
Недозріле насіння	0.94	0.89	0.91	225
З пошкодженою оболонкою	0.89	0.89	0.89	231
Плямисте/Хворе	0.86	0.97	0.91	219
Середнє значення	0.90	0.90	0.90	1102

Системний аналіз отриманих метрик дозволяє зробити важливі висновки щодо готовності системи до практичного впровадження. Насамперед варто відзначити високу надійність виявлення критичних біологічних дефектів. Найвищий показник повноти зафіксовано для класу плямисте насіння, який становить 0.97. Це є надзвичайно позитивним результатом для агропромислового сектору, оскільки плямистість найчастіше є ознакою ураження грибковими захворюваннями. Такий високий показник гарантує, що система майже ніколи не пропускає інфіковані насінини, допустивши лише 7 пропусків із 219 випадків, що зводить до мінімуму ризик зараження загальної партії посівного матеріалу.

Щодо чистоти класифікації, найвищі показники точності зафіксовано для битого та недозрілого насіння, 0.95 та 0.94 відповідно. Це означає, що у разі віднесення алгоритмом насіння до цих класів імовірність хибного спрацювання (False Positive) є мінімальною. Водночас еталонний цільовий клас здорове насіння демонструє високі та збалансовані показники з F1-мірою на рівні 0.91 та повнотою 0.94. Це свідчить про те, що нейромережа впевнено виділяє норму та не має тенденції безпідставно відбракувати якісний матеріал, що має пряму економічну вигоду для виробників.

Загальну збалансованість алгоритму підтверджує значення макросередньої F1-міри на рівні 0.90. Цей показник доводить, що розроблена модель не страждає від алгоритмічного упередження на користь мажоритарних класів і однаково успішно виявляє як здорові зерна, так і різні типи дефектів. Хоча нижні межі метрик, зокрема повнота для битого насіння на рівні 0.79, ще залишають простір для подальшого вдосконалення системи, поточні результати є цілком достатніми для прототипування ліній автоматизованого контролю.

Підсумовуючи, результати оцінювання матриці помилок та обчислених метрик беззаперечно підтверджують високу ефективність запропонованого методу на базі архітектури MobileNetV2. Алгоритм здатен розпізнавати п'ять станів насіння сої із загальною точністю близько 90%, забезпечуючи при цьому критично важливу чутливість до біологічних пошкоджень та надійність, необхідну для практичного застосування в агропромисловому комплексі.

3.2.3 Експериментальне підтвердження обчислювальної ефективності та швидкості інференсу

Критичним етапом валідації методу є оцінка його обчислювальної ефективності, оскільки в умовах реального агровиробництва модель має приймати рішення за доли секунди для синхронізації зі швидкісними пневматичними ежекторами. Для вимірювання продуктивності архітектури MobileNetV2 було застосовано спеціалізоване середовище бенчмаркінгу на базі TensorFlow. Задля

забезпечення високої достовірності результатів, методика тестування передбачала 10 ітерацій прогріву для стабілізації графа обчислень та подальше високоточне вимірювання затримки під час виконання 100 циклів інференсу на стандартизованих тензорах розмірністю 224x224x3 пікселі.

Апаратне забезпечення, на якому проводилося дослідження, включало обчислювальний модуль із графічним прискорювачем. Використання GPU-обчислень дозволило розкрити потенціал паралельної обробки тензорів, що є критичним для систем комп'ютерного зору. Проте архітектурні особливості обраної моделі MobileNetV2, зокрема використання інвертованих залишкових блоків, роблять її придатною і для роботи на центральних процесорах без суттєвої втрати продуктивності, що значно розширює перелік сумісного промислового обладнання.

Для експериментального підтвердження досягнення мети щодо покращення швидкості, було проведено порівняльне тестування розробленої моделі MobileNetV2 із класичною архітектурою глибокого навчання VGG16, яка часто використовується як базове рішення у задачах аграрного комп'ютерного зору. Результати порівняльного аналізу обчислювальної ефективності зведено у таблицю 3.2.

Таблиця 3.2 – Порівняльний аналіз обчислювальної ефективності та швидкодії моделей

Архітектура моделі	Кількість параметрів, млн	Обсяг пам'яті моделі, МБ	Середня затримка інференсу, мс	Пропускна здатність, FPS
VGG16	138,36	528,0	218,45	4,57
MobileNetV2	2,26	14,1	51,13	19,56

Системний аналіз отриманих метрик, наведених у таблиці 3.2, кількісно доводить обчислювальну перевагу запропонованого методу. Загальна кількість вагових коефіцієнтів розробленої моделі становить 2,26 млн, що у понад 60 разів менше порівняно зі 138 млн параметрів у VGG16. Відповідно, фізичний розмір файлу моделі зменшився з 528 МБ до 14,1 МБ. Така надзвичайна компактність дозволяє розгортати систему безпосередньо на периферійних пристроях, таких як

промислові мікроконтролери сортувальних машин, усуваючи потребу в дорогих серверах та постійному інтернет-з'єднанні.

Головним результатом тестування, який підтверджує досягнення мети дослідження, є показники швидкості. Середня затримка інференсу для базової моделі VGG16 склала 218,45 мс, що забезпечує лише 4,57 кадрів за секунду. Натомість запропонована модель MobileNetV2 витрачає на аналіз одного зображення в середньому 51,13 мс. У перерахунку на пропускну здатність це забезпечує стабільну обробку відеопотоку зі швидкістю 19,56 кадрів за секунду. Використання глибинних роздільних згорток дозволило пришвидшити процес класифікації у 4,28 раза порівняно з традиційними згортковими мережами. Отриманий показник майже у 20 FPS є достатнім для успішної синхронізації системи комп'ютерного зору з механічною швидкістю руху конвеєрної стрічки сучасних оптичних сепараторів насіння.

Додатково варто відзначити економічний та апаратний аспекти впровадження розробленого методу. Використання важких архітектур типу VGG16 вимагає встановлення потужних промислових комп'ютерів із сучасними відеокартами, що суттєво збільшує вартість розгортання кожної сортувальної лінії. Крім того, такі обчислювальні вузли генерують значну кількість тепла і потребують активного охолодження, що є проблематичним в умовах високої запиленості аграрних підприємств. Натомість компактність моделі MobileNetV2 знижує вимоги до апаратного забезпечення, дозволяючи використовувати бюджетні мікропроцесорні платформи або одноплатні комп'ютери зі вбудованими нейронними співпроцесорами. Це робить технологію автоматизованого комп'ютерного зору економічно доступною навіть для невеликих насінневих господарств.

Крім того, зафіксований показник у майже 20 кадрів за секунду не є остаточною межею продуктивності розробленої системи. У перспективі, за необхідності інтеграції алгоритму на ультрашвидкісні конвеєрні лінії, існує значний потенціал для подальшого пришвидшення інференсу. Застосування методів посттренувальної квантизації або конвертація навченої моделі в

оптимізовані формати TensorRT чи ONNX дозволить зменшити час обробки ще у 2-3 рази практично без втрати точності розпізнавання дефектів.

Підсумовуючи, аналіз обчислювальної ефективності експериментально підтвердив, що розроблений метод класифікації насіння сої не лише демонструє високу точність розпізнавання, але й успішно вирішує завдання суттєвого покращення швидкості. Поєднання легкості архітектури, мінімальних вимог до пам'яті та високої пропускну здатності робить систему економічно рентабельною та повністю готовою до інтеграції у промислові апаратно-програмні комплекси автоматизованого контролю якості.

3.3 Висновки до розділу 3

У третьому розділі проведено практичну апробацію методу шляхом створення вебзастосунку SoyNet AI. Програмна реалізація підтвердила ефективність клієнт-серверної архітектури та концепції «людина в циклі», що дозволяє фахівцям верифікувати результати й накопичувати дані для донавчання інтелектуального ядра.

Аналіз динаміки навчання засвідчив стабільну збіжність алгоритму та відсутність перенавчання. Використання стратегії двостадійної оптимізації забезпечило точну адаптацію нейромережі до специфічних мікротекstur дефектів сої. Кількісна оцінка виявила високу прогностичну здатність моделі: макро-середня F1-міра склала 0.90. Показник повноти для класу «плямисте/хворе» досяг 0.97, що гарантує надійне виявлення інфікованого насіння. Висока точність для битого та недозрілого насіння (0.95 та 0.94) підтверджує об'єктивність автоматизованого контролю.

Експериментально доведено обчислювальну перевагу архітектури MobileNetV2. Завдяки швидкодії у 19,56 FPS (у 4,28 рази швидше за VGG16) та малому обсягу пам'яті (14,1 МБ), модель можна інтегрувати у промислові контролери без значних витрат на обладнання. Результати досліджень підтверджують готовність методу до впровадження у реальне виробництво.

Загальні висновки

Метою кваліфікаційної роботи бакалавра було покращення точності, швидкості та автоматизації процесу контролю якості насіння сої шляхом розробки методу нейромережевої класифікації за візуальними ознаками із застосуванням глибокого навчання. Для досягнення цієї мети розроблено відповідний метод та клієнт-серверну інтелектуальну систему SoyNet AI.

Для досягнення мети поставлені та виконані наступні задачі:

- здійснено системний аналіз предметної області щодо поточних методів візуального контролю та експертизи якості соєвого насіння;
- проведено порівняльний огляд наявних інформаційних систем та програмних продуктів, призначених для автоматизованого моніторингу якості сільськогосподарської продукції;
- сформовано та попередньо оброблено масив навчальних даних для тренування моделі комп'ютерного зору;
- розроблено метод нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання;
- проведено експериментальне дослідження ефективності запропонованого методу класифікації, використовуючи розроблене програмне середовище.

Практичне використання розробленого методу автоматизує та підвищує об'єктивність контролю якості насіння сої, замінюючи ручну експертизу. Про це свідчать результати: макро-середня F1-міра склала 0.90, а Precision для битого та недозрілого насіння досягла 0.95 і 0.94, що підтверджує якісне розділення класів. Recall для критичного класу плямисте/хворе становить 0.97, гарантуючи надійне виявлення інфікованого матеріалу. Показники є високими, зважаючи на візуальну схожість окремих дефектів (наприклад, тіні від тріщин іноді сприймалися як хвороба). Подальші дослідження спрямовані на оптимізацію моделі для роботи на конвеєрі та збір складних прецедентів через модуль зворотного зв'язку для донавчання класифікатора.

Перелік посилань

1. Sable A. et al. Quantifying Soybean Defects: A Computational Approach to Seed Classification Using Deep Learning Techniques. *Agronomy*. 2024. Т. 14. № 6. 1098. URL: <https://doi.org/10.3390/agronomy14061098> (дата звернення: 13.03.2026).
2. Huang Z. et al. Deep learning based soybean seed classification. *Computers and Electronics in Agriculture*. 2022. Т. 202. 107393. URL: <https://doi.org/10.1016/j.compag.2022.107393> (дата звернення: 13.03.2026).
3. Zhao G. et al. Real-time recognition system of soybean seed full-surface defects based on deep learning. *Computers and Electronics in Agriculture*. 2021. Т. 187. 106230. URL: <https://doi.org/10.1016/j.compag.2021.106230> (дата звернення: 13.03.2026).
4. Lin W. et al. Online classification of soybean seeds based on deep learning. *Engineering Applications of Artificial Intelligence*. 2023. Т. 126. 106434. URL: <https://doi.org/10.1016/j.engappai.2023.106434> (дата звернення: 13.03.2026).
5. Qiang J., Qiao X., Yu Y., Liu Z. QseedNet: A lightweight deep-learning framework for detection of quarantine weed seeds in imported soybean inspection. *Industrial Crops and Products*. 2025. 118618. URL: <https://www.sciencedirect.com/science/article/pii/S0926669025018618> (дата звернення: 13.03.2026).
6. Ji B., Zhou H., Pan L., Xie F., Xie Y., Li Y., Bai J., Li P., Wang X. Automated soybean quality detection system using deep learning. *Smart Agricultural Technology*. 2025. Т. 12. 101473. URL: <https://doi.org/10.1016/j.atech.2025.101473> (дата звернення: 13.03.2026).
7. De Medeiros A. D. et al. Interactive machine learning for soybean seed and seedling quality classification. *Scientific Reports*. 2020. Т. 10. 11238. URL: <https://doi.org/10.1038/s41598-020-68273-y> (дата звернення: 13.03.2026).
8. Oliveira V. R., Souza M. A., Mello É. O. et al. Artificial intelligence applied to the classification of greenish seeds and prediction of physiological quality in soybean.

Ciência e Agrotecnologia. 2024. Т. 48. e01024. URL: <https://doi.org/10.1590/1413-7054202448003624> (дата звернення: 13.03.2026).

9. Shen Y. et al. Detection of surface defects in soybean seeds based on improved Yolov9. Scientific Reports. 2025. Т. 15. 92429. URL: <https://doi.org/10.1038/s41598-025-92429-3> (дата звернення: 13.03.2026).

10. Zhu S., Zhou L., Zhang C., Bao Y., Wu B., Chu H., Yu Y., He Y., Feng L. Identification of Soybean Varieties Using Hyperspectral Imaging Coupled with Convolutional Neural Network. Sensors. 2019. Vol. 19, No. 19. 4065. URL: <https://www.mdpi.com/1424-8220/19/19/4065> (дата звернення: 13.03.2026).

11. Chen M. et al. Classification and Recognition of Soybean Quality Based on Hyperspectral Imaging and Random Forest Methods. 2025. Т. 25. № 5. 1539. URL: <https://doi.org/10.3390/s25051539> (дата звернення: 13.03.2026).

12. Barbedo J. G. A. Deep Learning for Soybean Monitoring and Management. Seeds. 2023. Т. 2. № 3. 26. URL: <https://doi.org/10.3390/seeds2030026> (дата звернення: 13.03.2026).

13. Su Z., Wang Y., Xu Q., Gao R., Kong Q. LodgeNet: Improved rice lodging recognition using semantic segmentation of UAV high-resolution remote sensing images. Computers and Electronics in Agriculture. 2022. Т. 196. 106873. URL: <https://doi.org/10.1016/j.compag.2022.106873> (дата звернення: 13.03.2026).

14. Вісник Львівського національного університету природокористування. Серія «Агроінженерія». Львів : Львівський нац. ун-т природокористування, 2024. № 28. 235 с. URL: <https://sci.ldubgd.edu.ua/jsru/bitstream/123456789/14912/1/Агроінженерні%20дослідження%202024.pdf> (дата звернення: 13.03.2026).

15. Лиховид П. В., Біднина І. О. Штучний інтелект і його можливості в агрономії. Таврійський науковий вісник. Серія: Сільськогосподарські науки. 2024. № 137. С. 125–134. DOI: https://tnv-agro.ksauniv.ks.ua/archives/137_2024/18.pdf (дата звернення: 13.03.2026).

16. Oliveira G. S. d. et al. Leaf and Seed Hyperspectral Signatures Enable Early and Accurate Prediction of Soybean Seed Quality. AgriEngineering. 2025. Т. 7. № 12.

424. URL: <https://doi.org/10.3390/agriengineering7120424> (дата звернення: 13.03.2026).

17. Pang L. et al. Feasibility Study on Identifying Seed Variety of Soybean With Hyperspectral Imaging and Deep Learning. *Journal of Chemometrics*. 2025. Т. 39. № 5. e70035. URL: <https://doi.org/10.1002/cem.70035> (дата звернення: 13.03.2026).

18. Petronilio A. C. P. et al. A new tool to identify stressed soybean seeds based on multispectral imaging and machine learning. *Smart Agricultural Technology*. 2025. Т. 10. 100275. URL: <https://doi.org/10.1016/j.atech.2025.101042> (дата звернення: 13.03.2026).

19. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*. 2015. Т. 521. С. 436–444. URL: <https://doi.org/10.1038/nature14539> (дата звернення: 13.03.2026).

20. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. Cambridge: MIT Press, 2016. 775 p. URL: <https://mitpress.mit.edu/9780262035613/deep-learning/> (дата звернення: 13.03.2026).

21. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*. 2017. Т. 60. № 6. С. 84–90. URL: <https://doi.org/10.1145/3065386> (дата звернення: 13.03.2026).

22. Kamilaris A., Prenafeta-Boldú F. X. Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*. 2018. Т. 147. С. 70–90. URL: <https://doi.org/10.1016/j.compag.2018.02.016> (дата звернення: 13.03.2026).

23. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016. P. 770–778. URL: <https://arxiv.org/abs/1512.03385> (дата звернення: 13.03.2026).

24. Mohanty S. P., Hughes D. P., Salathé M. Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*. 2016. Т. 7. 1419. URL: <https://doi.org/10.3389/fpls.2016.01419> (дата звернення: 13.03.2026).

25. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. *International Conference on Learning Representations*. 2015. URL: <https://arxiv.org/abs/1409.1556> (дата звернення: 13.03.2026).

26. Ferentinos K. P. Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*. 2018. Т. 145. С. 311–318. URL: <https://doi.org/10.1016/j.compag.2018.01.009> (дата звернення: 13.03.2026).
27. Sandler M., Howard A., Zhu M., Zhmoginov A., Chen L. C. MobileNetV2: Inverted Residuals and Linear Bottlenecks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2018. Р. 4510–4520. URL: <https://arxiv.org/abs/1801.04381> (дата звернення: 13.03.2026).
28. Howard A. et al. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. 2017. URL: <https://arxiv.org/abs/1704.04861> (дата звернення: 13.03.2026).
29. Tan M., Le Q. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of the International Conference on Machine Learning*. 2019. URL: <https://doi.org/10.48550/arXiv.1905.11946> (дата звернення: 13.03.2026).
30. Shorten C., Khoshgoftaar T. M. A survey on image data augmentation for deep learning. *Journal of Big Data*. 2019. Т. 6. 60. URL: <https://doi.org/10.1186/s40537-019-0197-0> (дата звернення: 13.03.2026).
31. Putri S. V., Basuki S. Explainable AI-Driven Convolution Neural Network for Quality Grading of Soybean Seeds. *ELTIKOM*. 2025. Т. 9. № 2. URL: <https://doi.org/10.31961/eltikom.v9i2.1566> (дата звернення: 13.03.2026).
32. VGG16 model. Keras Applications documentation. URL: https://keras.io/api/applications/vgg/vgg_models/#vgg16-function (дата звернення: 13.03.2026).
33. Yang X. et al. Classification of soybean seeds based on RGB reconstruction of hyperspectral images. *PLOS ONE*. 2024. Т. 19. № 9. e0307329. URL: <https://doi.org/10.1371/journal.pone.0307329> (дата звернення: 13.03.2026).
34. Zhang L. et al. DAFFnet: Seed classification of soybean variety based on dual attention feature fusion networks. *The Crop Journal*. 2025. URL: <https://doi.org/10.1016/j.cj.2024.12.023> (дата звернення: 13.03.2026).

35. Chen Y., Chen Z., An Y., Lu C., Qiao X. DAFFNet: A Dual Attention Feature Fusion Network for Classification of White Blood Cells. arXiv. 2024. URL: <https://doi.org/10.48550/arXiv.2405.16220> (дата звернення: 13.03.2026).
36. Na M. H., Na I. S. Detection and Classification of Wilting in Soybean Crop using Cutting-edge Deep Learning Techniques. Legume Research. 2024. URL: <https://doi.org/10.18805/LRF-797> (дата звернення: 13.03.2026).
37. Feng J. et al. Robust soybean seed yield estimation using high-throughput ground robot videos. Frontiers in Plant Science. 2025. Т. 16. URL: <https://doi.org/10.3389/fpls.2025.1554193> (дата звернення: 13.03.2026).
38. Zhao J., Kaga A., Yamada T., Komatsu K., Hirata K., Kikuchi A., Hirafuji M., Ninomiya S., Guo W. Improved Field-Based Soybean Seed Counting and Localization with Feature Level Considered. Plant Phenomics. 2023. Т. 5. Article 0026. URL: <https://doi.org/10.34133/plantphenomics.0026> (дата звернення: 13.03.2026).
39. SmartGrain. High-Throughput Phenotyping Software for Measuring Seed Shape through Image Analysis. URL: <https://www.quantitative-plant.org/software/smartgrain> (дата звернення: 13.03.2026).
40. SeedAIxpert. Digital Seed Testing System. URL: <https://www.lemnatec.com/seedaixpert/> (дата звернення: 13.03.2026).
41. Soybean Seeds Classification Dataset. Kaggle. URL: <https://www.kaggle.com/datasets/aryashah2k/soybean-seedsclassification-dataset/data> (дата звернення: 13.03.2026).

ДОДАТКИ

Додаток А

Програмні коди

Програмний код, використаний у дослідженні, доступний у відкритому репозиторії GitHub: <https://github.com/BilanDS/soynet-ai-web> (дата звернення: 20.02.2026).

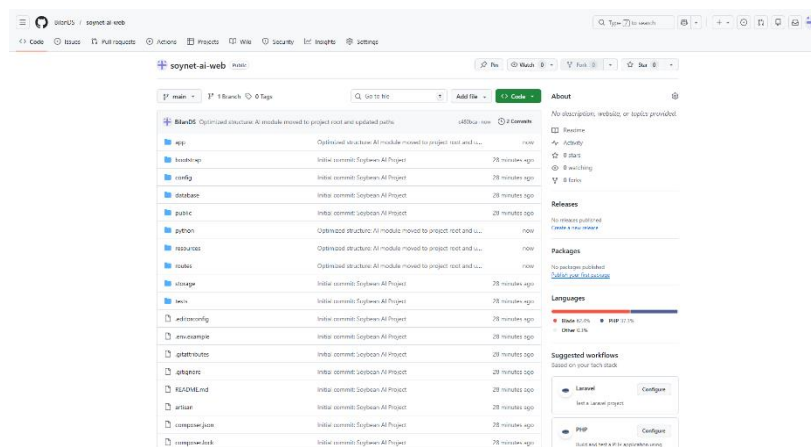


Рисунок А.1 – Головна сторінка репозиторію

Структура репозиторію наступна:

- модуль маршрутизації та контролерів (app/Http/Controllers, routes). Містить логіку обробки HTTP-запитів, управління та взаємодії з БД;
- модуль інтеграції штучного інтелекту (python). Містить програмний код для завантаження навчених моделей машинного навчання, підготовки завантажених зображень насіння сої та отримання результатів класифікації;
- модуль бази даних та моделей (database/migrations, app/Models). Забезпечує архітектуру реляційної бази даних. Містить міграції для створення таблиць користувачів, збереження історії сканувань та інші;
- модуль інтерфейсу користувача (resources/views). Забезпечує графічне відображення форм завантаження фотографій, візуалізацію результатів аналізу у вигляді графіків та адміністративну панель модерації відгуків.

Додаток Б

Презентаційний матеріал

КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

МЕТОД НЕЙРОМЕРЕЖЕВОЇ КЛАСИФІКАЦІЇ НАСІННЯ СОЇ ЗА ВІЗУАЛЬНИМИ ОЗНАКАМИ ІЗ ЗАСТОСУВАННЯМ ГЛИБОКОГО НАВЧАННЯ



Виконав:

студент 4 курсу, група КН-22-2

Дмитро БІЛАН



Керівник:

д.т.н., професор кафедри КН

Едуард МАНЗЮК

Актуальність

Зростання ролі сої як ключової експортної та олійної культури супроводжується посиленням вимог до посівних якостей насіння. Традиційні ручні методи візуального контролю залишаються суб'єктивними, повільними та малоефективними, що вимагає впровадження новітніх технологій:

- автоматизація класифікації насіння за ступенем пошкодження та наявністю дефектів за допомогою комп'ютерного зору та глибокого навчання;
- створення об'єктивних, швидких і масштабованих систем аналізу замість лабораторних процедур;
- скорочення економічних витрат на неякісний посівний матеріал та запобігання втратам врожайності;
- забезпечення стабільної якості на етапах сортування, сертифікації та виробництва;
- інтеграція рішень у промислові лінії чи портативні пристрої для оперативного аналізу.

Впровадження таких нейромережевих моделей дозволяє здійснювати раннє виявлення проблем якості. Це є надзвичайно важливим для підвищення конкурентоспроможності насіння в умовах інтенсивного землеробства, кліматичних викликів та жорсткої ринкової конкуренції.

Мета і задачі роботи

Об'єкт дослідження. Процес автоматизованого контролю якості насіння сої за візуальними ознаками.

Предмет дослідження. Методи та засоби глибокого навчання, спрямовані на автоматизований контроль якості насіння сої за візуальними ознаками.

Мета роботи. Покращення точності, швидкості та автоматизації процесу контролю якості насіння сої шляхом розробки методу неймережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання.



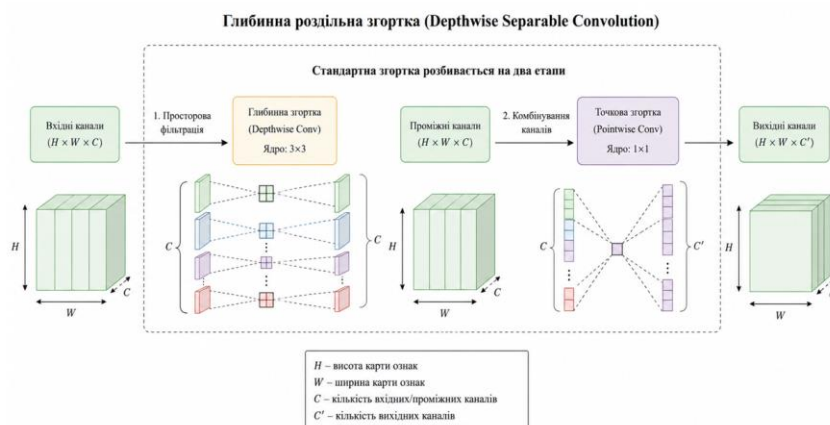
Загальна архітектурна схема запропонованого методу класифікації насіння сої



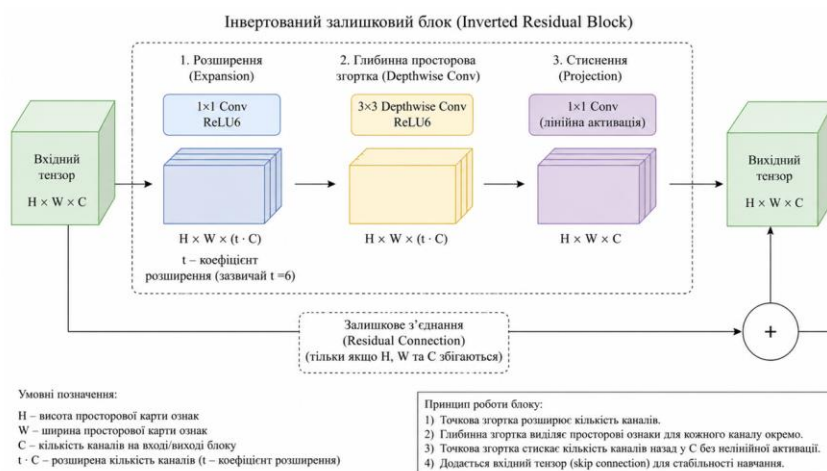
Таблиця кількісного розподілу зображень насіння сої за класами якості

№	Категорія якості насіння	Оригінальна назва класу	Кількість зображень	Частка вибірки, %
1	Здорове насіння	Intact soybeans	1201	21,78
2	Насіння з пошкодженою оболонкою	Skin-damaged soybeans	1127	20,44
3	Недозріле насіння	Immature soybeans	1125	20,41
4	Плямисте / уражене хворобами	Spotted soybeans	1058	19,19
5	Бите насіння	Broken soybeans	1002	18,18
Разом			5513	100,0

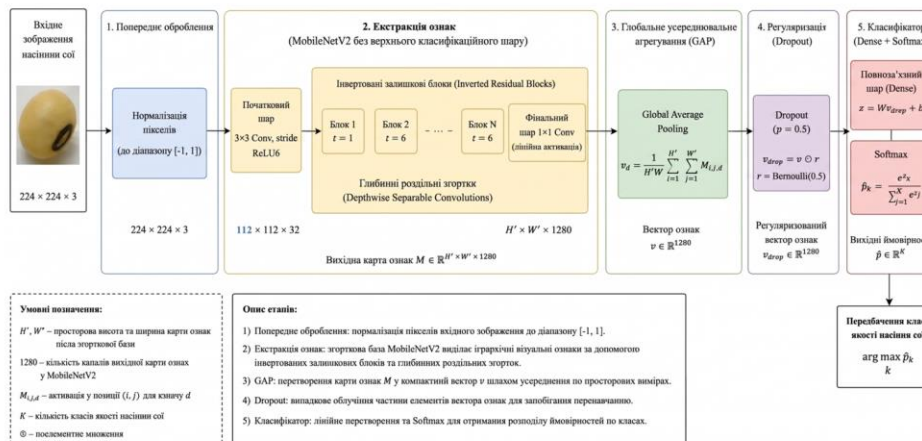
Структурна схема глибинної роздільної згортки



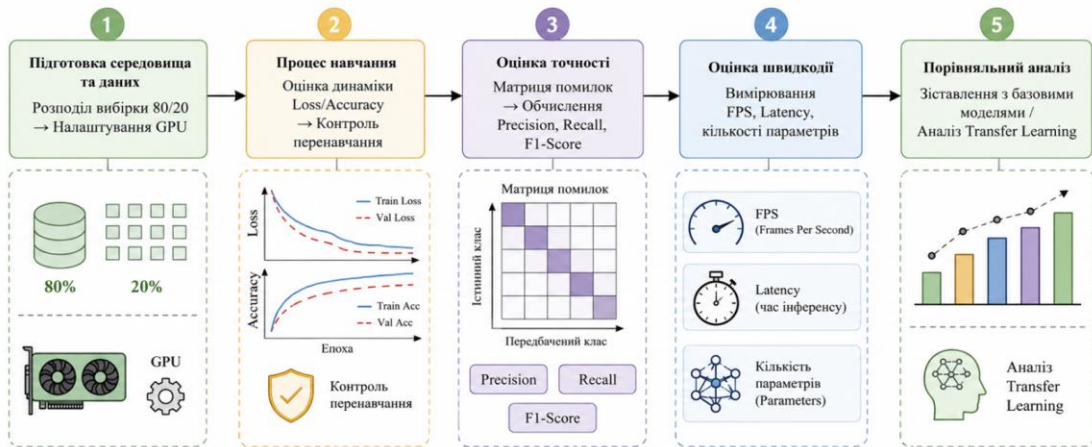
Логічна схема інвертованого залишкового блоку



Детальна схема екстракції ознак та нейромережевої класифікації насіння сої




Структурна схема програми експериментальних досліджень методу класифікації




⏪ ⏩ 🔍 🔄 📄

Графіки зміни точності та втрат під час навчання моделі



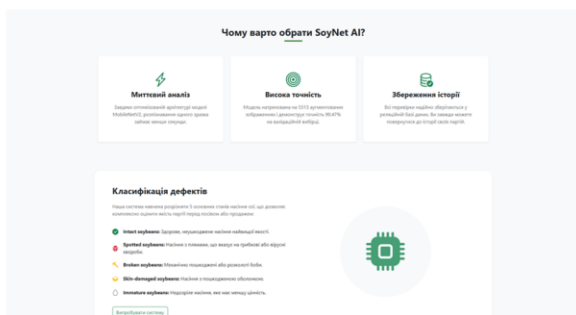
Матриця помилок класифікації насіння сої



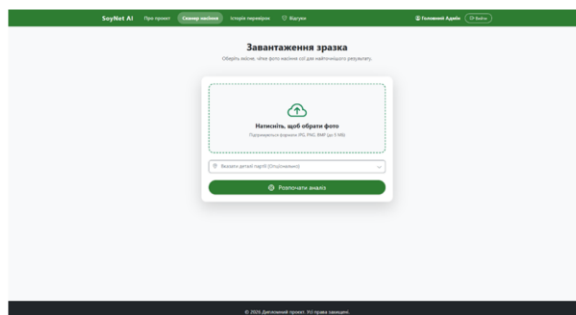
Зведені результати оцінювання якості багатокласової класифікації

Категорія якості	Precision	Recall	F1-Score	Кількість зразків
Здорове насіння	0.88	0.94	0.91	244
Бите насіння	0.95	0.79	0.86	183
Недозріле насіння	0.94	0.89	0.91	225
З пошкодженою оболонкою	0.89	0.89	0.89	231
Плямисте/Хворе	0.86	0.97	0.91	219
Середнє значення	0.90	0.90	0.90	1102

Зображення інтерфейсу веб-застосунку SoyNet AI

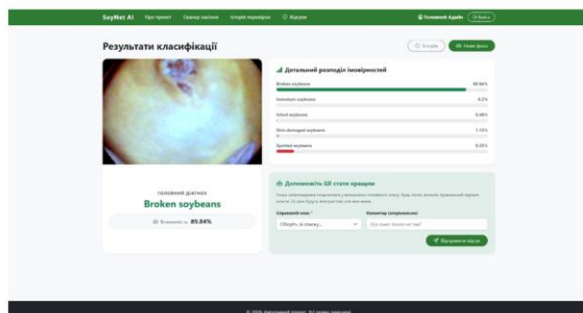


Головна сторінка

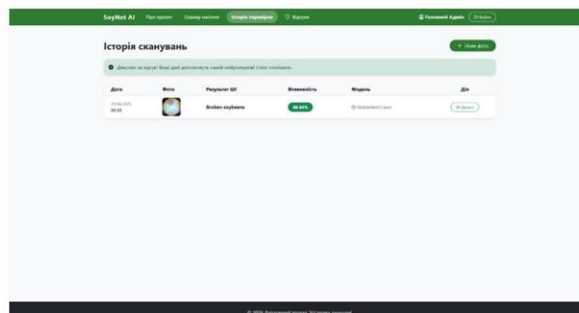


Сторінка сканера насіння

Зображення інтерфейсу веб-застосунку SoyNet AI



Візуалізація результатів розпізнавання



Візуалізація історії сканувань

Висновки

Для досягнення мети поставлені та виконані наступні задачі:

- здійснено системний аналіз предметної області щодо поточних методів візуального контролю та експертизи якості соєвого насіння;
- проведено порівняльний огляд наявних інформаційних систем та програмних продуктів, призначених для автоматизованого моніторингу якості сільськогосподарської продукції;
- сформовано та попередньо оброблено масив навчальних даних для тренування моделі комп'ютерного зору;
- розроблено метод нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання;
- проведено експериментальне дослідження ефективності запропонованого методу класифікації, використовуючи розроблене програмне середовище.

Результат розробки. Створено інтелектуальну систему SoyNet AI на базі глибокого навчання, яка повністю автоматизує візуальну експертизу та усуває суб'єктивність ручного контролю.

ДЯКУЮ ЗА УВАГУ!



Fri Jun 05 09:58:03 EEST 2026, Петровський Сергій Степанович, Хмельницький національний університет, ХНУ

Anti-Plagiarism (http://ap.km.ua) v-16.718

Максимальне співпадіння з одним документом 2.0%

Словники перевірки: UA, US, RU. **Помилка в документах: 12%**

ID: 273745 Назва: КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Метод нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання Додано в БД: 2026-06-05 Автора: Дмитро БІЛАН Керівники: Едуард МАНЗЮК Консультанти: Опоненти:	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми	Символи	Лексеми
	108164	846	3362 (3%)	52 (6%)

Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

Протокол аналізу звіту подібності науковим керівником

Заявляю, що я ознайомився (-лась) з Повним звітом подібності, який був згенерований Системою виявлення і запобігання плагіату щодо роботи:

Автор: Дмитро БІЛАН

Співавтор:

Назва: КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Метод нейромережевої класифікації наєніня сої за візуальними ознаками із застосуванням глибокого навчання

Науковий керівник: Едуард МАНЗЮК, д.т.н., доцент

Підрозділ: Кафедра комп'ютерних наук

Коефіцієнт подібності 1: 3.24%

Коефіцієнт подібності 2: 1.96%

Мікропробіли: 0

Заміна букв: 14

Інтервали: 0

Білі знаки: 192

Дата створення звіту: 2026-06-05 16:14:36.0

Після аналізу Звіту подібності констатую наступне:

Запозичення, виявлені в роботі є законними і не є плагіатом. Рівень подібності не перевищує допустимої межі. Таким чином робота незалежна і приймається.

Запозичення не є плагіатом, але перевищено граничне значення рівня подібностей. Таким чином робота повертається на доопрацювання.

Виявлено запозичення і плагіат або навмисні текстові спотворення (маніпуляції), як передбачувані спроби укриття плагіату, які роблять роботу невідповідною вимогам законодавства (Ст. 32. ЗУ Про вищу освіту, пункт 3.1, Ст. 42. ЗУ Про освіту) та вимог НАЗЯВО (Критерій 5), а також кодексу етики і процедур. Таким чином робота не приймається.

Обґрунтування:

2026-06-05

Дата

експерт

Петровський С.С. стз

РІШЕННЯ ЕКСПЕРТНОЇ КОМІСІЇ КАФЕДРИ КОМП'ЮТЕРНИХ НАУК

ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ

Назва кваліфікаційної роботи Метод нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання

Автор студент групи КН-22-2 Дмитро БІЛАН

Освітня програма Комп'ютерні науки

Рівень вищої освіти перший (бакалаврський)

Спеціальність 122 – Комп'ютерні науки

Науковий керівник: д.т.н., проф. каф. комп'ютерних наук Едуард МАНЗЮК

На основі аналізу кваліфікаційної роботи на дотримання вимог академічної доброчесності (у т.ч. відсутності ознак академічного плагіату) з урахуванням результатів перевірки роботи спеціалізованим програмними засобами комісія зробила такий висновок:

№	Висновок	Позначка про відповідність
1	Ознаки академічного плагіату	
1.1	Запозичення, виявлені в роботі, є законними і не є академічним плагіатом (далі – зазначаються підстави віднесення запозичень до правомірних, якщо потрібно). Робота приймається до захисту.	віповідіає
1.2	Виявлені запозичення не є академічним плагіатом, розмішені в розділах, які не описують безпосередньо авторське дослідження, але кількість цитат перевищує обсяг, виправданий поставленою метою роботи (далі – зазначаються детальні та аргументовані підстави віднесення запозичень до правомірних). Робота приймається до захисту, але має бути відкоригована.	
1.3	Виявлені запозичення не є академічним плагіатом, але частково розмішені в розділах, які описують безпосередньо авторське дослідження, а кількість цитат перевищує обсяг, виправданий поставленою метою роботи. Робота може бути допущена до захисту після того як буде відкоригована та доопрацьована і успішно пройде повторну перевірку на академічний плагіат.	
1.4	Робота містить навмисні текстові спотворення, передбачувані спроби укриття текстових запозичень або інші прояви академічного плагіату. Робота містить фабрикацію або фальсифікацію даних. Робота не допускається до захисту.	
2	Інші види порушень академічної доброчесності	відсутні

Підтвердження:

Запозичення, виявлені в роботі Дмитра Білана не є плагіатом, оскільки: запозичення розмішені в розділі огляду існуючих підходів, не описують безпосередньо авторську роботу і не стосуються її результатів; усі запозичення фрагментарні; до запозичень входять фрагменти, які не мають авторства і містять поширені конструкції та загальновідомі терміни, скорочення. Рівень подібності не перевищує допустимої межі. Таким чином, робота є законною та приймається до захисту.

Обсяг запозичень, визначений системами виявлення збігів/ідеїдентичності/схожості:

- за системою Anti-Plagiarism: 2%;

- за системою StrikePlagiarism КП1: 3,24%, КП2: 1,96%.

05.06.2026

Завідувач кафедри



Олександр БАРМАК

Гарант освітньої програми



Олександр МАЗУРЕЦЬ

Керівник кваліфікаційної роботи



Едуард МАНЗЮК



РЕЦЕНЗІЯ

на кваліфікаційну роботу бакалавра

студента *гр. КН-22-2 Дмитра БІЛАНА*

за темою: *Метод нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання*

1. Актуальність обраної теми

У сучасному агропромисловому комплексі питання контролю якості посівного матеріалу має критичне значення для забезпечення високої врожайності. Традиційні методи візуальної оцінки та сортування насіння залишаються багато в чому суб'єктивними та трудомісткими. З огляду на це, застосування передових технологій комп'ютерного зору та глибокого навчання для автоматизації процесу виявлення дефектів є надзвичайно своєчасним. Отже, тема кваліфікаційної роботи, присвячена розробці автоматизованого методу нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання, є актуальною в контексті розвитку інформаційних технологій, які можуть стати ефективним інструментом для вдосконалення аграрних процесів.

2. Повнота розкриття мети та завдань роботи

У процесі виконання кваліфікаційної роботи студент продемонстрував глибоке розуміння предметної області, чітко й аргументовано сформулювавши мету та завдання дослідження. Усі поставлені завдання, включаючи системний аналіз методів контролю, підготовку набору даних, розробку архітектури нейромережевої моделі та проведення експериментального тестування виконані в повному обсязі. Виконання дослідницької частини підтверджує високий рівень наукової підготовки здобувача та його здатність ефективно застосовувати теоретичні знання у практичній діяльності.

3. Зміст кожного розділу роботи

У першому розділі наведено характеристику предметної області: здійснено огляд сучасних нейромережевих моделей та аналіз інформаційних систем для ідентифікації дефектів сільськогосподарської продукції. Другий розділ присвячено математичній формалізації задачі та розробці методу класифікації з використанням оптимізованої архітектури глибокого навчання; детально описано алгоритми, метрики оцінювання та характеристики набору візуальних даних. У третьому розділі розкрито деталі програмної реалізації розробленої інформаційної системи та наведено результати

експериментальних досліджень динаміки навчання моделі, точності розпізнавання класів і загальної швидкодії.

4. Оцінка розробленого методу та його практична цінність

Експериментальне дослідження показало, що розроблений метод дозволяє ефективно вирішувати завдання автоматизованого аналізу насіння. Використання запропонованого підходу забезпечує високу точність розпізнавання класів якості при достатній швидкодії та оптимізованих вимогах до обчислювальних ресурсів. Практична цінність роботи полягає у розробці дієвого інструментарію, який дозволяє оперативно оцінювати якість посівного матеріалу і може бути інтегрований у виробничі лінії або використовуватися фахівцями для швидкої експертизи.

5. Якість оформлення кваліфікаційної роботи бакалавра

Кваліфікаційна робота оформлена відповідно до вимог чинних нормативних документів, що свідчить про належний рівень сформованості наукової культури здобувача. Чітка структурна організація матеріалу та стилістична послідовність викладеного змісту підтверджують якісну підготовку студента до майбутньої професійної діяльності.

6. Недоліки кваліфікаційної роботи бакалавра

Поряд із позитивними здобутками, робота має окремі незначні недоліки. Зокрема, у результатах експериментального дослідження було б доцільно більш детально висвітлити вплив різних умов навколишнього середовища (наприклад, зміна освітлення) на точність роботи моделі. Хоча в роботі присутні незначні недоліки, вони не впливають на її загальну наукову і практичну цінність.

7. Загальний висновок (допускається чи не допускається до захисту), та оцінка на яку заслуговує кваліфікаційна робота.

Враховуючи рівень виконання та забезпечення усіх необхідних вимог, робота може бути допущена до захисту. Рекомендована оцінка «*Відмінно*», 95/A

Рецензент

к.т.н., доц. кафр. КІС ЛНУ
Канунжен Маріє Вікторівна



ВІДГУК НАУКОВОГО КЕРІВНИКА на кваліфікаційну роботу бакалавра

студента *гр. КН-22-2 Дмитра Білана*

за темою *Метод нейромережевої класифікації насіння сої за візуальними ознаками із застосуванням глибокого навчання*

1. Актуальність теми

Тема випускної роботи Дмитра Білана є актуальною в контексті цифрової трансформації та інтеграції інтелектуальних систем у сучасний агропромисловий комплекс. Ефективне вирощування та експорт зернових культур вимагають суворого контролю якості посівного матеріалу, де традиційний ручний огляд є суб'єктивним та низькопродуктивним. Застосування інструментів комп'ютерного зору та архітектур глибокого навчання для автоматизації відбирання кондиційного насіння сої дозволяє мінімізувати економічні ризики агрогосподарств.

2. Відповідність роботи предметній області Стандарту спеціальності 122 Комп'ютерні науки

Зміст та результати кваліфікаційної роботи повністю задовольняють вимоги освітньо-професійного стандарту підготовки бакалаврів за спеціальністю 122 «Комп'ютерні науки». Дослідження охоплює етапи математичної формалізації процесу розпізнавання, декомпозиції обчислювальних алгоритмів, безпосередньої програмної реалізації застосунку. У роботі поєднано теоретичні засади комп'ютерного бачення з практичним застосуванням сучасних легковагових згорткових мереж.

3. Професійні та особистісні якості бакалавра

Протягом усього періоду проектування та дослідження Дмитро Білан зарекомендував себе як зрілий та цілеспрямований фахівець. Студент продемонстрував високу глибоку розуміння математичного апарату машинного навчання, а також розвинені практичні навички у сфері розробки інтелектуального програмного забезпечення.

4. Ступінь самостійності під час виконання кваліфікаційної роботи

Студент особисто виконав збір та адаптацію масиву візуальних даних, самостійно спроектував та імплементував схему оптимізації вагових коефіцієнтів моделі. Усі експериментальні дослідження розпізнавання дефектів сої були проведені студентом одноосібно.

5. Ступінь оволодіння методами дослідження

Студент продемонстрував упевнені навички роботи зі спеціалізованими фреймворками глибокого навчання, методами регуляризації та концепцією перенесення знань для точного налаштування моделей. Також успішно опанував підходи до веб-інтеграції інтелектуальних моделей за допомогою сучасних інструментів розробки.

6. Повнота та якість розкриття теми роботи

Завдання, що були поставлені перед студентом, виконано в повному обсязі. У пояснювальній записці подано ґрунтовний критичний аналіз існуючих морфологічних систем аналізу зерна, розкрито архітектурні переваги глибинних роздільних згорток. Створений працездатний застосунок наділений усім необхідним функціоналом. Результати експериментів підтвердили високу точність та обчислювальну ефективність запропонованого методу.

7. Логічність, послідовність, аргументованість, літературна грамотність викладення матеріалу

Матеріал кваліфікаційної роботи викладено у логічній послідовності, архітектура пояснювальної записки відповідає академічним вимогам. Теоретичні викладки та алгоритмічні схеми підкріплені відповідними математичними формулами, графіками, табличними даними. Текст написаний грамотною технічною мовою, термінологія витримана, висновки логічно випливають із результатів експериментів.

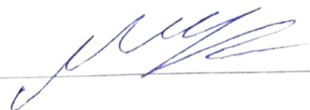
8. Можливість практичного застосування кваліфікаційної роботи бакалавра, окремих її частин

Розроблений метод нейромережевої класифікації та створений програмний інструментарій мають безпосередню практичну цінність для аграрного сектору. Крім того, низькі обчислювальні витрати оптимізованої моделі дозволяють інтегрувати розроблений алгоритм у перспективні промислові фотосепаратори або портативні мобільні пристрої моніторингу в польових умовах.

9. Висновок про можливість допуску кваліфікаційної роботи бакалавра до захисту, на яку оцінку заслуговує робота

Враховуючи високу актуальність теми, належну якість програмної реалізації та повну відповідність усім критеріям, що висувуються до випускних робіт бакалавра, кваліфікаційна робота Дмитра Білана допускається до захисту перед екзаменаційною комісією. Робота заслуговує на оцінку — «відмінно».

Керівник



д.т.н., проф. каф. КН Едуард МАНЗЮК