

ПОРІВНЯЛЬНИЙ АНАЛІЗ МОДЕЛЕЙ ГЛИБОКОГО НАВЧАННЯ ДЛЯ КЛАСИФІКАЦІЇ ХВОРОБ РОСЛИН У РІЗНИХ КОЛЬОРОВИХ ПРОСТОРАХ

Чешенко Д.Р.¹, Мацуга О.М.²

¹ Дніпровський національний університет імені Олеся Гончара, Україна

² Дніпровський національний університет імені Олеся Гончара,

к. т. н, доцент, Україна

Анотація. У даній роботі проведено порівняльний аналіз впливу кольорових просторів на точність класифікації хвороб рослин за допомогою згорткових нейронних мереж. Було навчено три архітектури моделей у чотирьох різних кольорових просторах: RGB, HSV, LUV та LAB, що в сумі дало 12 моделей. Для дослідження використано датасет, який містить понад 79 тисяч оригінальних зображень, що належать 88 класам. Точність класифікації хвороб рослин було оцінено на навчальному та тестовому наборах даних. Результати показали, що ефективність класифікації залежить не лише від архітектури моделі, а й від обраного кольорового простору. Зокрема, LAB продемонстрував незначні переваги в моделях із меншою кількістю параметрів, тоді як RGB виявився стабільно ефективним у складніших моделях. HSV та LUV показали нижчу точність у більшості випадків. Отримані результати можуть сприяти покращенню систем діагностики хвороб рослин та знайти застосування в інших галузях, таких як металургія, для підвищення точності виявлення дефектів на зображеннях металевих поверхонь.

Ключові слова: нейронні мережі; згорткові нейронні мережі; глибоке навчання; комп'ютерний зір; класифікація; кольорові простори; хвороби рослин.

Вступ. Сучасний розвиток методів глибокого навчання та їх широке застосування в задачах комп'ютерного зору створюють нові можливості для автоматизації аналізу зображень у різних сферах діяльності. Одним із перспективних напрямів є використання таких методів для розпізнавання хвороб рослин за зображеннями їхніх листків. Традиційні методи, засновані на візуальному огляді рослин експертами, залишаються суб'єктивними, трудомісткими і малоефективними у випадках, що потребують оперативного реагування. Використання моделей глибокого навчання дозволяє автоматизувати процес розпізнавання хвороб рослин та підвищити його точність завдяки аналізу великого масиву зображень.

Останні дослідження демонструють, що ефективність моделей глибокого навчання, зокрема згорткових нейронних мереж, може залежати від кольорової інформації при розпізнаванні об'єктів, причому ступінь цієї залежності може змінюватися залежно від набору даних та методів навчання [1]. Відповідно можна припустити, що застосування різних кольорових просторів може вплинути на ефективність алгоритмів розпізнавання. В одному з останніх досліджень показано, що вибір кольорового простору може суттєво впливати на точність класифікації згортковою нейронною мережею, та виявлено, що окремі простори демонструють переваги у розпізнаванні окремих класів завдяки їх здатності ефективно виділяти як яскравість, так і кольорову інформацію [2].

Основною метою даної роботи є порівняльний аналіз трьох архітектур згорткових нейронних мереж для класифікації хвороб рослин із використанням різних кольорових просторів, зокрема, HSL, LUV та LAB. Аналіз націлений на порівняння точності класифікації в цих кольорових просторах.

Результати роботи можуть знайти застосування й в інших галузях, зокрема в металургії – наприклад, для підвищення точності розпізнавання дефектів та аномалій на зображеннях металевих поверхонь.

Основний матеріал

Для оцінки впливу різних кольорових просторів на точність класифікації хвороб рослин розглянуто три архітектури згорткових нейронних мереж.

В усіх трьох архітектурах для виявлення ознак використовується зв'язок блоків. Кожен блок представляє собою послідовність основних компонентів: двох згорткових шарів (Conv2D), шарів нормалізації пакетів (BatchNormalization) після кожного згорткового шару, операції пулінгу (MaxPooling2D або AveragePooling2D) та шару виключення (SpatialDropout2D) в кінці кожного блоку, за винятком останнього. Після цих блоків, використовується глобальний середній пулінг (GlobalAveragePooling2D) для переходу від просторових ознак до одновимірного вектору, який далі обробляється повнозв'язними шарами (Dense) для остаточної класифікації. Всі архітектури працюють із зображеннями розміром 256×256 з трьома каналами,

в якості функції активації у Conv2D та Dense шарах використовується функція ReLU, а у фінальному шарі функція softmax для класифікації 88 класів. Також усі архітектури використовують категоріальну крос-ентропію як функцію втрат і навчаються за допомогою стохастичного градієнтного спуску з моментумом (SGD, momentum=0.9).

У першій архітектурі використовується 6 блоків, які починаються з 8 фільтрів із поступовим збільшенням до 256, використовується чергування AveragePooling2D і MaxPooling2D, після GlobalAveragePooling2D слідує три послідовних Dense-шари з 1024, 512, 256 параметрами та Dropout з коефіцієнтом 0.3 між ними, що призводить до загальної кількості параметрів близько 2,13 мільйона.

У другій архітектурі використовується 5 блоків, які починаються з 8 фільтрів зі збільшенням до 128, але перед фінальним шаром використовується лише один Dense шар з 2048 нейронами, в якому застосовується L2-регуляризація з параметром 0.0001. Також використовується CosineDecay (початковий lr становить $7e-3$; мінімальний – $1e-5$) для зменшення швидкості навчання. Такий підхід дозволив досягнути значно меншої кількості параметрів, близько 742 тисяч.

У третій архітектурі використовується також 5 блоків, але вона відрізняється тим, що початковий блок містить 16 фільтрів з подальшим збільшенням їх кількості до 256 у наступних блоках. Крім того, з кожним блоком збільшується коефіцієнт SpatialDropout2D (від 0.05 у початкових блоках до 0.20 у фінальних). Як і в попередній архітектурі, застосовується один Dense шар з 2048 нейронами та L2-регуляризацією з параметром 0.0005, а також використовується CosineDecay для зміни швидкості навчання (початковий lr становить $1e-2$, мінімальний – $1e-8$). У результаті, загальна кількість параметрів моделі складає близько 1,89 мільйона, і для її навчання необхідно більше епох (50 епох порівняно з 30 для попередніх архітектур).

Для навчання і тестування моделей був використаний набір зображень “Plant Disease Classification Merged Dataset”, що охоплює 88 класів та містить понад 79 тис. зображень із загальним розміром 17,6 ГБ [3]. Зображення було

отримано з різних джерел, що включають як лабораторні, так і польові умови, що створює неоднорідність інформації. Саме ця неоднорідність, разом зі схожістю симптомів різних патологічних станів, становить одну з основних проблем при розпізнаванні хвороб рослин. Для навчання використовувалося 80% від загальної кількості зображень в наборі, для тестування – відповідно 20%.

Однією з проблем даного набору зображень є дисбаланс даних. У роботі було вирішено вирівняти розподіл зображень у навчальному наборі за допомогою технік аугментації. Процес аугментації полягав у застосуванні ряду геометричних та кольорових перетворень, що дозволило збільшити кількість зразків до 2000 зображень для кожного класу. Після балансування навчальний набір містив 176 тис. зображень. Тестовий набір містив 16 тис. зображень без аугментації, щоб відобразити реальний стан у природних умовах. Результати навчання всіх моделей наведені у табл. 1.

Таблиця 1

Результати навчання моделей

Модель	Кольоровий простір	Точність на навчальних даних	Точність на тестових даних
Модель 1	RGB	0.8980	0.9099
	HSV	0.8964	0.8941
	LUV	0.9036	0.8974
	LAB	0.8992	0.8972
Модель 2	RGB	0.9188	0.9256
	HSV	0.9312	0.9168
	LUV	0.9411	0.9245
	LAB	0.9394	0.9277
Модель 3	RGB	0.9168	0.9337
	HSV	0.9228	0.9287
	LUV	0.9290	0.9288
	LAB	0.9290	0.9321

Виходячи з наведених у табл. 1 результатів, вибір кольорового простору може впливати на показники точності моделей для класифікації хвороб рослин, причому переваги того чи іншого простору залежать від конкретної архітектури та методів обробки ознак під час їх проходження через шари

мережі. У моделях з більшою кількістю параметрів (моделі 1 та 3) використання RGB-простору дало трохи кращі результати, у той час, як модель з меншою кількістю параметрів (модель 2) продемонструвала незначну перевагу для LAB. HSV та LUV простори продемонстрували менш ефективні результати порівняно з RGB і LAB.

Висновки. Порівняльна оцінка точності моделей згорткових нейронних мереж у різних кольорових просторах показала, що традиційний RGB простір залишається надійним вибором для класифікації хвороб рослин, забезпечуючи високу точність розпізнавання. При цьому LAB може мати перевагу для більш простих архітектур. Подальші дослідження можуть бути зосереджені на розробці моделей, оптимізованих для LAB, а також на вивченні інших кольорових просторів для вдосконалення систем діагностики хвороб рослин.

ЛІТЕРАТУРА

1. Singh A., Bay A., Mirabile A. Assessing the importance of colours for CNNs in object recognition. ArXiv. 2020. URL: <https://arxiv.org/abs/2012.06917>
2. Xian Z., Huang R., Towey D., Yue D. Convolutional Neural Network Image Classification Based on Different Color Spaces. Tsinghua Science and Technology. 2025, Vol. 30, Issue 1. P. 402-417. DOI: <https://doi.org/10.26599/tst.2024.9010001>
3. Dobrovsky A. Plant Disease Classification Merged Dataset. URL: <https://www.kaggle.com/datasets/alinedobrovsky/plant-disease-classification-merged-dataset>

COMPARATIVE ANALYSIS OF DEEP LEARNING MODELS FOR PLANT DISEASE CLASSIFICATION IN DIFFERENT COLOR SPACES

Cheshenko Dmytro, Matsuga Olga

Abstract. *This study presents a comparative analysis of the impact of different color spaces on the accuracy of plant disease classification using convolutional neural networks. Three model architectures were trained in four color spaces – RGB, HSV, LUV, and LAB – resulting in a total of 12 models. The experiments were conducted on a dataset containing over 79,000 original images across 88 classes. Classification accuracy was evaluated on both training and test sets. The results indicate that classification performance depends not only on the model architecture but also on the chosen color space. In particular, LAB showed slight advantages in models with fewer parameters, while RGB consistently performed well in more complex models. HSV and LUV generally resulted in lower accuracy. These findings can contribute to improving plant disease*

diagnosis systems and may also be applicable in other fields such as metallurgy for enhancing the accuracy of defect detection on metal surface images.

Keywords: *neural networks; convolutional neural networks; deep learning; computer vision; classification; color spaces; plant diseases.*

REFERENCE

1. Singh A., Bay A., Mirabile A. Assessing the importance of colours for CNNs in object recognition. ArXiv. 2020. URL: <https://arxiv.org/abs/2012.06917>
2. Xian Z., Huang R., Towey D., Yue D. Convolutional Neural Network Image Classification Based on Different Color Spaces. Tsinghua Science and Technology. 2025, Vol. 30, Issue 1. P. 402-417. DOI: <https://doi.org/10.26599/tst.2024.9010001>
3. Dobrovsky A. Plant Disease Classification Merged Dataset. URL: <https://www.kaggle.com/datasets/alinedobrovsky/plant-disease-classification-merged-dataset>