

МРНТИ 28.23.15
УДК 004.8

<https://doi.org/10.51889/2021-3.1728-7901.10>

Ж. А. Бурибаев^{1*}, Ж. Е. Амиргалиева², А. С. Атанязова¹,
З. М. Меліс¹, Д. Д. Даулетия¹

¹ Қазақстан Республикасының Ұлттық Университеті, Алматы, Қазақстан

² Институт информационных и вычислительных технологий, г. Алматы, Казахстан

*e-mail: zholdas_87@mail.ru

ПРИМЕНЕНИЕ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ КЛАССИФИКАЦИИ РАЗНОВИДНОСТЕЙ СОРНЫХ РАСТЕНИЙ

Аннотация

В статье рассматривается актуальность внедрения интеллектуальных систем обнаружения сорных растений, в целях экономии гербицидов и пестицидов, также получения экологически чистых продуктов. Проведен краткий обзор научных работ исследователей, в которых описываются разработанные ими методы идентификации, классификации и дискриминации сорняков на основе алгоритмов машинного обучения, сверточных нейронных сетей и алгоритмов глубокого обучения. В данной исследовательской работе представлена программа обнаружения вредителей сельскохозяйственных угодий с использованием алгоритмов K-Nearest Neighbors, Random Forest и Decision Tree. Набор данных собран из 4 видов сорных растений, такие как ширица, амброзия, вьюнок и костер. По итогам проведенной оценки, точность обнаружения сорняков классификаторами K-Nearest Neighbors, Random Forest и Decision Tree составила 83.3%, 87.5%, и 80%. Количественные результаты, полученные на реальных данных, демонстрируют, что предлагаемый подход может обеспечить хорошие результаты классификации изображений сорняков с низким разрешением.

Ключевые слова: сельское хозяйство, сорные растения, машинное обучение, сегментация, метод Оцу, классификация, оценка алгоритмов.

Аңдатпа

Ж. А. Бурибаев¹, Ж. Е. Амиргалиева², А. С. Атанязова¹, З. М. Меліс¹, Д. Д. Даулетия¹

АРАМШӨП ТҮРЛЕРІН ЖІКТЕУ ҮШІН МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІН ҚОЛДАНУ

¹ Әл-Фараби атындағы Қазақ ұлттық университеті, Алматы қ., Қазақстан

² Ақпараттық және есептеуіш технологиялар институты, Алматы қ., Қазақстан

Мақалада гербицидтер мен пестицидтерді үнемдеу, сондай-ақ экологиялық таза өнімдер алу мақсатында арамшөптерді анықтаудың зияткерлік жүйелерін енгізудің өзектілігі қарастырылады. Зерттеушілердің ғылыми жұмыстарына қысқаша шолу жасалды, онда машиналық оқыту алгоритмдері, орама нейрондық желілер және терең оқыту алгоритмдері негізінде арамшөптерді анықтау, жіктеу және ажырату әдістері сипатталған. Бұл зерттеу жұмысында k-Nearest Neighbors, Random Forest және Decision Tree алгоритмдерін қолдана отырып, ауыл шаруашылығы алқаптарының зиянкестерін анықтау бағдарламасы ұсынылған. Деректер жиынтығы *amaranthus*, *ambrosia*, *bindweed* және *bromus* сияқты арамшөптердің 4 түрінен жиналды. Жүргізілген бағалау қорытындысы бойынша K-Nearest Neighbors, Random Forest және Decision Tree классификаторларының арамшөптерді анықтау дәлдігі 83.3%, 87.5% және 80% құрады. Нақты деректерден алынған сандық нәтижелер, ұсынылған тәсіл арамшөптердің төмен рұқсаттағы суреттерін жіктеудің жақсы нәтижелерін бере алатындығын көрсетеді.

Түйін сөздер: ауыл шаруашылығы, арамшөптер, машиналық оқыту, сегментация, Оцу әдісі, жіктеу, алгоритмдерді бағалау.

Abstract

Zh. A. Buribaev¹, Zh. E. Amirgalieva², A. S. Ataniyazova¹, Z. M. Melis¹, D. D. Dauletiya¹

APPLICATION OF MACHINE LEARNING ALGORITHMS FOR THE CLASSIFICATION OF WEEDS

¹ Al-Farabi Kazakh National University, Almaty, Kazakhstan

² Institute of Information and Computing Technologies, Almaty, Kazakhstan

The article considers the relevance of the introduction of intelligent weed detection systems, in order to save herbicides and pesticides, as well as to obtain environmentally friendly products. A brief review of the researchers' scientific works is carried out, which describes the methods of identification, classification and discrimination of weeds developed by them based on machine learning algorithms, convolutional neural networks and deep learning algorithms.

This research paper presents a program for detecting pests of agricultural land using the algorithms K-Nearest Neighbors, Random Forest and Decision Tree. The data set is collected from 4 types of weeds, such as amaranthus, ambrosia, bindweed and bromus. According to the results of the assessment, the accuracy of weed detection by the classifiers K-Nearest Neighbors, Random Forest and Decision Tree was 83.3%, 87.5%, and 80%. Quantitative results obtained on real data demonstrate that the proposed approach can provide good results in classifying low-resolution images of weeds.

Keywords: agriculture, weeds, machine learning, segmentation, Otsu method, classification, evaluation of algorithms.

Введение

Сельскохозяйственная отрасль является одной из главных отраслей экономики нашей страны, поскольку данная отрасль ежегодно дает в бюджет государства 35-40% дохода, также 15% всей рабочей силы страны трудоустроено именно в этом секторе. Борьба с сорняками и мониторинг заболеваний сельскохозяйственных культур стала актуальной задачей при роботизации сельского хозяйства [1]. Мониторинг заболеваний и сорняков на этапах выращивания очень важен для выявления и предотвращения болезни и устранения значительных потерь урожая, а традиционные методы выполнения этого процесса требуют больших затрат и человеческих ресурсов, к тому же подвергают работников опасности загрязнения вредными химическими веществами. Поэтому разработка системы борьбы с вредителями, которая выполняет обнаружение и удаление сорняков является основной областью исследований в сельскохозяйственной отрасли.

В нынешнее время наиболее оптимальным средством для борьбы с вредителями является масштабное применение гербицидов, но не учитывается факт неравномерного роста сорных растений. В результате, посевы также попадают под обработку химикатами, применяемые для уничтожения сорняков, что может нанести вред окружающей среде. Ранее используемые технологии могли различать лишь наличие или отсутствие растений, они не были способны на разделение их на сорняки и сельскохозяйственные культуры. Новые технологии позволяют более эффективное распыление гербицидов, применяя их только в нужных площадках, чтобы сохранить урожай и защитить окружающую среду [3, 9]. Внедрение интеллектуальных систем обнаружения сорняков также решит проблему экономии гербицидов и пестицидов, которые являются востребованными средствами для борьбы с болезнями растения, различными сорняками и переносчиками опасных заболеваний в промышленном сельскохозяйственном производстве.

Применение автономных роботов и автоматизированных систем в сельском хозяйстве может привести к существенной минимизации человеческих усилий, необходимых для выполнения нескольких сельскохозяйственных задач. В целях решений этих задач, были предложены новые системы классификации, способные идентифицировать сельскохозяйственные культуры, отличая их от нежелательных вредоносных растительностей [8, 13]. Целью нашей работы является идентификация и классификация сорных растений за счет разработки системы обнаружения и различения сорняков на основе алгоритмов машинного обучения. Для достижения этой цели сформулированы такие задачи, как анализ существующих методов к решению проблем роботизации сельского хозяйства, формирование датасета изображений сорных растений, встречающихся на полевых площадях нашей страны и разработка программного обеспечения, которое выполняет функцию обнаружения сорняков, отличая их от зерновых и овощных культур.

Обзор литературы

Авторы научной работы [1] провели исследования в целях разработки метода на основе машинного обучения, позволяющий роботу выполнять точную классификацию сорных растений. Предложенный подход основан на трехэтапной процедуре: сначала осуществляется сегментация по пикселям, удаление фона, а в следующем этапе выполняется процесс извлечения участка изображения, содержащие сорные растения. На последнем этапе проводится классификация сорняков с помощью сверточных нейронных сетей. Результаты данной работы имеют хорошие показатели на сложных данных, но для повышения точности, требуются улучшения между этапами сегментации и классификации.

В статье [2] предложен алгоритм обработки изображения для классификации сорных растений на узкие и широкие сорняки. Научная работа [3] направлена на исследование проблем загрязнения окружающей среды из-за распыления химических гербицидов на больших полевых площадках. В связи с этим, была разработана система идентификации разновидностей сорняков с помощью технологии цифровой обработки изображений и машинного зрения. Авторы этой работы утверждают, что предложенный им метод эффективен для классификации сорных растений, что позволит сэкономить время и затраты удаления сорняков с полей.

В исследовательской работе [4] рассмотрена проблема семантической сегментации на основе сверточных нейронных сетей, которая разделяет растения сахарной свеклы и сорняков от фона. Разработанная авторами система была оценена на сельскохозяйственном роботе в трех городах Германии и Швейцарии. Результаты данной работы являются хорошими и сама система нашла применение в полевых условиях в режиме реального времени.

Авторами научной работы [5] была разработана программа, которая выполняет обнаружение сорняков в посевах сельскохозяйственных культур, а также различение сорных растений травянистого и

широколиственного вида. Применяя сверточных сетей, исследователи получили результаты с высокой точностью при классификации всех классов сорных растений. Но авторы не провели оценку алгоритмов, которые они использовали для классификации сорняков, что позволила бы определить лучший алгоритм по качеству, производительности и скорости работы.

В статье [6] сделан обобщенный обзор на достижения в области обнаружения сорняков с помощью машинного зрения и методов обработки изображений. Представлено подробное описание процедур, таких как предварительная обработка, сегментация, извлечение признаков и классификация. Также авторами были обсуждены проблемы, возникающие при обнаружении сорняков и решения, которые позволяют распознавать в различных условиях освещения и в различных стадиях роста сорняков.

Новая система, предложенная в статье [7] основана на сверточной сети со структурой кодер-декодер, а также содержит пространственную информацию путем рассмотрения последовательностей изображений. По экспериментальным оценкам, точность классификации сельскохозяйственных культур и сорняков превышает точность других современных подходов, так как представленная система хорошо подходит для невидимых полей в различных условиях окружающей среды.

В исследовательской работе [8] предложен новый подход, направленный на минимизирование человеческих ресурсов, которые требуются для обучения алгоритмов классификации и на генерацию больших наборов данных сельскохозяйственных культур.

Авторы статьи [9] разработали новый алгоритм обобщения неконтролируемых наборов данных, который позволяет выбирать автоматически из большого набора данных наиболее информативные подмножества. Этот подход эффективен для ускорения и упрощения процесса маркировки пикселей для семантической сегментации зеленых растительностей. Для реализации предложенного метода были использованы конвейеры, включающие в себя двух разных сверточных нейронных сетей.

В исследовательской работе [10] рассматриваются решения проблемы фенотипирования, то есть процесса наблюдения физических характеристик растений. Эксперименты проводились в целях различения морковей, находящихся на ранней стадии роста листьев от сорняков. Также представлен базовый набор данных для дискриминации сельскохозяйственных культур и сорных растений для дальнейшего стимулирования исследований в области земледелия, так как отсутствие общедоступных наборов данных является одним из препятствий для развития систем автоматического обнаружения сорняков.

Предлагаемый метод на основе полностью сверточной сети в статье [11] обеспечивает более высокую точность классификации и может эффективно классифицировать пиксели рисовых саженцев, фона и сорняков на изображениях рисовых полей и определять положение их областей. Этот подход был сравнен с классическими моделями семантической сегментации FCN и U-Net и превосходит их по некоторым параметрам.

Методология, представленная в статье [12] состоит из двух этапов. На первом этапе выполняется сегментация фона с использованием максимального правдоподобия, а второй этап посвящен на ручную разметку сорняков. Проведен сравнительный анализ архитектур глубокого обучения SegNet и UNET, и по оценке методологии выявлены результаты и преимущества использованных архитектур.

В научной работе [13] для различения сельскохозяйственных культур и сорных растений была использована сегментация на основе метода 3D-Otsu, а классификация выполнена путем сжатия трехмерных векторов изображения с помощью метода анализа основных компонентов(РСА). Комбинируя два метода, авторы предложили программу обнаружения сорняков, работающую в реальном времени.

Исследователи научной работы [14] провели анализ морфологических признаков для классификации сельскохозяйственных культур и сорных растений в отраслях сельскохозяйственного производства. На основе дескрипторов особых точек, таких как Гистограмма направленных градиентов и Локальные бинарные шаблоны, авторы представили метод извлечения признаков с наименьшей вычислительной сложностью и с более высоким разрешением.

В статье [15] авторы рассматривают проблему автоматизации процесса удаления сорняков с использованием алгоритмов машинного обучения. Собранный набор данных состоит из 4 видов коммерческих сельскохозяйственных культур и 2 видов сорных растений. В данной работе выполнено сравнение производительности алгоритмов классификации, искусственных нейронных сетей и сверточных нейронных сетей. Проанализировав вышеперечисленные исследовательские работы, рассмотрены проблемы прополки с помощью выборочного опрыскивания или механического удаления обнаруженных сорняков. Определены преимущества представленных алгоритмов, методов и технологий идентификации сорных растений, на основе результатов сравнительного анализа производительности алгоритмов для классификации сельскохозяйственных культур и сорняков, была представлена программа обнаружения вредителей с использованием классических алгоритмов машинного обучения.

Методология исследований

Сегментация. Для сегментации изображений выбран метод Оцу, являющийся адаптивным алгоритмом на основе бинаризации. Алгоритм использует максимальное значение дисперсии, то есть отклонения от средней яркости между фоном и выбранным изображением в качестве правила выбора порога. Сперва идет процесс

деления изображения на передний и задний план в соответствии с его характеристиками серой шкалы. Если выбрать наилучшее пороговое значение, разница между двумя частями увеличится. Вероятность неправильной классификации сводится к минимуму, когда разница между фоном и целевым изображением имеет максимальное значение. Сегментация изображений методом Оцу осуществляется следующим образом:

1. Исходное изображение делится на $l = [0, 1, \dots, l-1]$ уровни. Количество пикселей на определенном уровне i обозначается p_i , а общее число пикселей обозначается суммой всех p_i , то есть $n = p_1 + p_2 + \dots + p_l$.
2. Пиксели изображения разделяются на классы с уровнями серого без порога и с порогом. Вычисляется вероятность серого уровня для распределения их на классы.
3. Среднее значение серого рассчитывается с помощью формулы

$$u_i = \sum_{i=0}^t \frac{iP_i}{w_i} \quad (1)$$

где P_i – вероятность серого уровня, w_i – вероятность распределения серых уровней на классы. Общее среднее обозначается u и определяется суммой всех u_i .

4. Нахождение дисперсии каждого класса, межклассовой дисперсии, общей дисперсии уровней серых является ключевым этапом метода Оцу, так как с помощью максимизации межклассовой дисперсии, выбирается оптимальный порог и реализуется идеальная сегментация изображения.

Классификация. Для классификации сорных растений использованы три классических алгоритмов машинного обучения, такие как K-Nearest Neighbors, Random Forest, Decision Tree. Поскольку классификатор должен использовать обучающий набор, сбалансированный по классам, чтобы быть эффективным [16], был реализован процесс случайной выборки, чтобы выбрать одинаковое количество объектов для каждого класса во всем изображении. Затем значения NIR/G (Near-Infrared/Green), средний красный, средний зеленый, средний NIR, яркость, стандартное отклонение NIR были извлечены для каждого объекта, составляющего обучающий набор, и использовались в качестве признаков для различения сорняков, сельскохозяйственных культур и голой почвы, используя RF. В процессе обучения было использовано 400 деревьев решений, так как это значение оказалось приемлемым при использовании RF-классификатора. Чтобы избежать какой-либо неправильной классификации крупных сорняков между рядами или внутри них, высота объекта не была включена в качестве классификационного параметра.

Оценка алгоритмов. Для оценки качества работы алгоритмов машинного обучения было разработано множество метрик. Все метрики рассчитываются с помощью комбинаций матрицы ошибок, которые предоставляют информацию о количествах истинно-положительных, истинно-отрицательных, ложно-положительных и ложно-отрицательных решений классификатора. Функции FPR, FNR, recall, precision, accuracy, индекс Жаккарда используют два или три комбинации матрицы неточностей и не дают объективной оценки результатов классификации [17]. А метрики F1, каппа Коэна, коэффициент корреляции Мэтьюса, используя все элементы матрицы ошибок, оценивают результаты классификатора при несбалансированных данных. Ниже представлены формулы нахождения этих метрик:

1. Долю ошибок, сделанных классификатором при отнесении одного или другого объекта к выбранному классу демонстрирует метрика FPR, ложно-положительный показатель. Значение данной метрики зависит от количества ложно-положительных и истинно-отрицательных решений.

$$FPR = \frac{FP}{FP+TN} \quad (2)$$

2. Ложно-отрицательный показатель демонстрирует ошибку второго рода, когда модель машинного обучения предсказывает отрицательное решение, но на самом деле он является объектом выбранного класса.

$$FNR = \frac{FN}{FN+TP} \quad (3)$$

3. Метрика recall показывает сколько примеров из положительных решений было потеряно в результате классификации. Она отвечает за способность обнаруживать объекты определенного класса, поэтому определяется с помощью истинно-положительных и ложно-отрицательных решений.

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

4. Precision демонстрирует способность алгоритма отличать выбранный класс от других классов, но в отличие от recall, учитывает ложно-положительные результаты.

$$Precision = \frac{TP}{TP+FP} \quad (5)$$

5. Accuracy рассчитывает долю правильных классификаций, и определяется как соотношение всех истинных результатов и суммы всех комбинаций матрицы ошибок.

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (6)$$

6. F1-measure является метрикой, которая сводит к одному числу две основных метрики оценки: precision и recall. Она нужна для сбалансирования, когда максимальное значение precision и recall не достижимы одновременно.

$$F1 = \frac{2*Precision*Recall}{Precision+Recall} \quad (7)$$

7. Индекс Жаккарда используется для обнаружения граней с изображения, так как он способен количественно оценить сходство между идентификацией граней компьютера с идентификацией тренировочных данных. Поэтому, этот индекс является важным при семантической сегментации изображения.

$$Jaccard\ index = \frac{TP}{TP+FN+FP} \quad (8)$$

8. Каппа Коэна, как и другие показатели оценки, рассчитывается на основе матрицы ошибок. В отличие от расчета общей точности, каппа Коэна учитывает дисбаланс в распределении классов. Поэтому, как показано в формуле, он исключает возможность совпадения классификатора и случайного предположения и измеряет количество предсказаний, который он делает.

$$Cohen's\ kappa = \frac{(TP+FP)(TP+FN)+(FN+TN)(FP+TN)}{(TP+FP+FN+TN)^2} \quad (9)$$

9. Коэффициент корреляции Мэтьюса используется в тех случаях, где размеры классов сильно различаются, и набор данных отрицательных и положительных являются несбалансированными. Показатель этой метрики зависит от произведения истинных и ложных решений классификатора по отдельности, так же от вычитания этих двух чисел.

$$MCC = \frac{(TP*TN-FP*FN)}{\sqrt{(TP+FP)(TP+FN)(TN+FP)(TN+FN)}} \quad (10)$$

10. Специфичность или истинно-отрицательный показатель отвечает за вероятность того, насколько классификатор правильно не относит объекты к выбранному классу, игнорируя ошибку второго рода, то есть количество ложно-отрицательных решений.

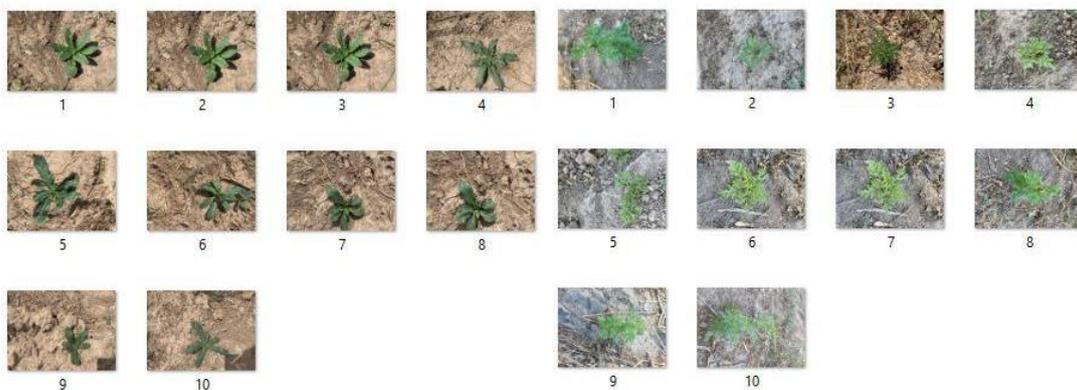
$$Spс = \frac{TN}{TN+FP} \quad (11)$$

11. Индекс Юдена определяется разницей между долей истинно-положительных результатов и долей ложноположительных решений.

$$Youden's\ index = Recall + Specificity - 1 \quad (12)$$

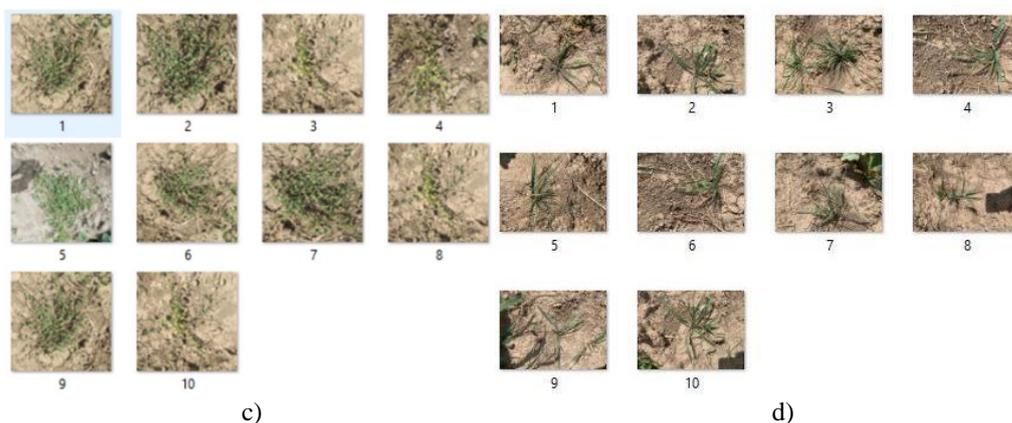
Результаты исследований

1. Формирование датасета. Как показано на рисунке 1, набор данных содержит 4 типа сорняков с 10 примерами. Каждый рассматриваемый класс был сегментирован и сохранен в наборе данных в виде массива.



a)

b)



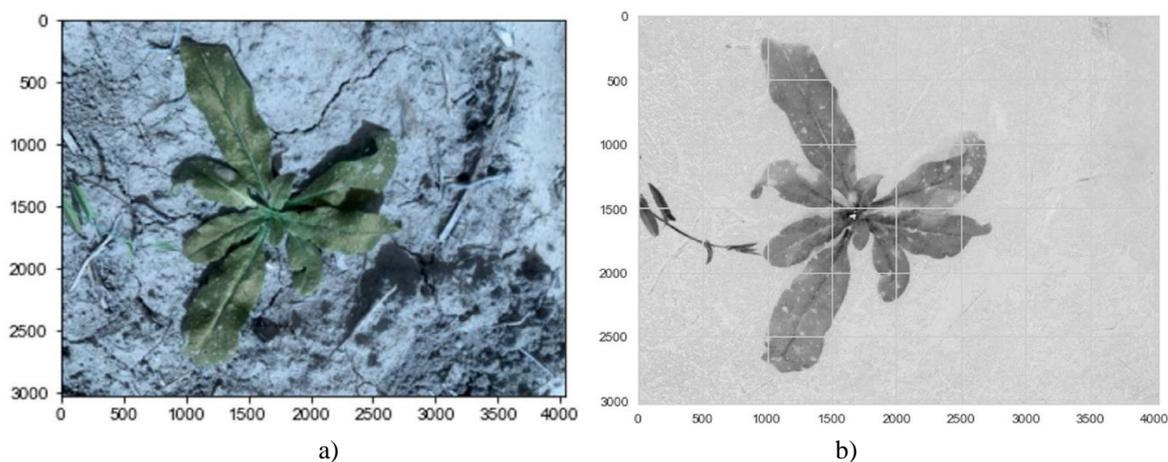
с) d)

Рисунок 1. Формирование датасета:

a) *Amaranthus* - щирица, b) *Ambrosia*- амброзия, c) *Bindweed*- вьюнок, d) *Bromus* - костер

2. Сегментация

Процесс сегментации состоит из нескольких этапов. Первый этап связан преобразованием изображения (рис. 2a) в оттенки серого, от 0 (чёрный) до 255 (белый). Изображение после обработки выглядит следующим образом (рис. 2b).

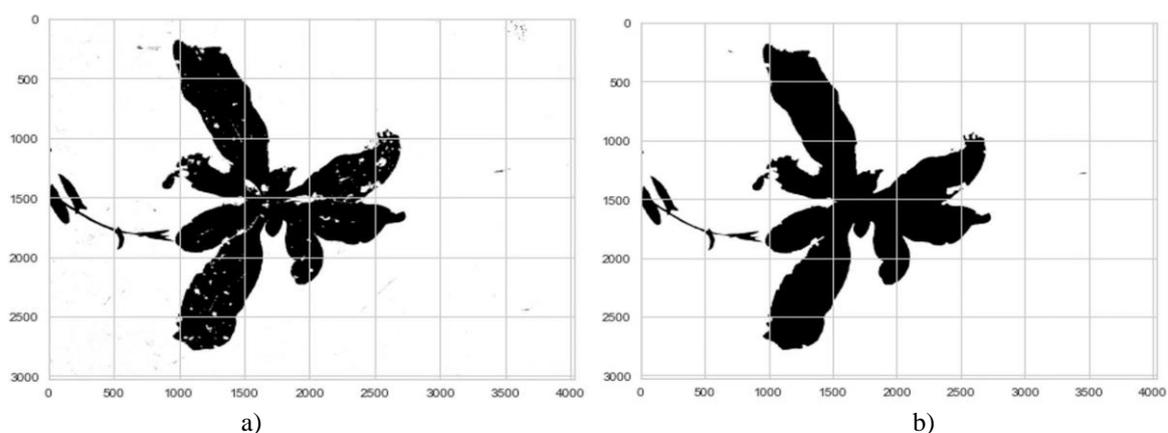


a)

b)

Рисунок 2. Изображение сорняка: a) исходное изображение, b) преобразование в оттенки серого

Следующим этапом является бинаризация. Его основная цель-уменьшить объем информации в изображении. Здесь был использован популярный метод бинаризации изображения - метод Оцу. После бинаризации методом Оцу на изображении можно увидеть небольшой шум (рис. 3a). Поэтому выполняется заключительный этап удаления шума. Обработанное изображение показано на рисунке 3b.



a)

b)

Рисунок 3. Сегментация изображения: a) фильтрация методом Оцу, b) сегментация с шумоподавлением

3. Оценка алгоритмов.

Следующий этап – оценивание качества работы классификаторов с помощью элементов матрицы неточностей.

На рисунке 4 показана общая матрица ошибок алгоритма KNN для всех классов сорных растений. Количество истинно-положительных решений (TP), предсказанных классификатором KNN – 8, а число истинно-отрицательных комбинаций (TN), которые не принадлежат к выбранному классу и были классифицированы как отрицательные правильно – 32. Ложно-отрицательная комбинация отвечает за количество ошибочно предсказанных решений, то есть классификатор предсказал их как отрицательные объекты, но в действительности они являются положительными, принадлежащими к выбранному классу объектами, количество FN - 4. С помощью этих комбинаций матрицы ошибок вычисляются метрики, которые определяют качество работы классификатора. Численные показатели оценок алгоритма для каждого класса представлены в таблице 1.

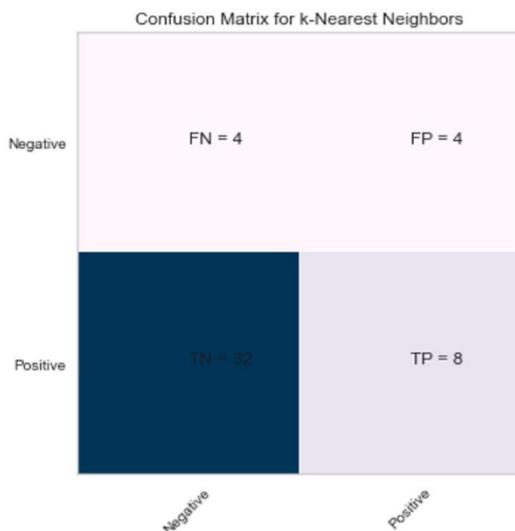


Рисунок 4. Матрица ошибок для K-Nearest Neighbors

Таблица 1. Оценки для каждого класса алгоритма K-Nearest Neighbors

Класс/Метрика	Precision	Recall	F1	Accuracy
Amaranthus	0.67	0.50	0.57	0.75
Ambrosia	1.00	0.75	0.86	0.92
Bindweed	1.00	1.00	1.00	1.00
Bromus	0.40	0.67	0.50	0.67

Согласно формуле (5), precision класса растений «Amaranthus» равна 0.67, классов «Ambrosia» и «Bindweed» равны 1, что показывают точную классификацию объектов этих классов, а для сорняков «Bromus» равна 0.4. Среднее значение precision составило 0.67, так как классификатор ошибочно предсказал объекты класса «Bromus» как объекты других классов, и это повлияло на общее качество. Следующая метрика, recall вычисляется по формуле (6). Для объектов класса «Amaranthus» значение данной метрики составляет 0.5, для сорных растений вида «Ambrosia» - 0.75, для класса «Bindweed» оценка recall достигла максимума, то есть 1, для сорняков класса «Bromus» равна 0.67. Общая оценка метрики recall тоже равна 0.67, как и precision. Поэтому, значение метрики F1, которая является гармоническим средним этих двух метрик, будет равно 0.67. По результатам проведенной оценки, можно сделать вывод о том, что алгоритм KNN неправильно классифицирует 1/3 часть от всех объектов.

Матрица неточностей классификационной модели Random Forest показана на рисунке 5. Количество корректно предсказанных объектов – 9, а количество истинно-отрицательных комбинаций составило 33. А количество ошибок, которые классификатор сделал при распознавании сорных растений равно 3. По сравнению с алгоритмом KNN, Random Forest выполнил классификацию лучше, поэтому показатели метрик оценки тоже являются выше, чем у предыдущего алгоритма (таблица 2).

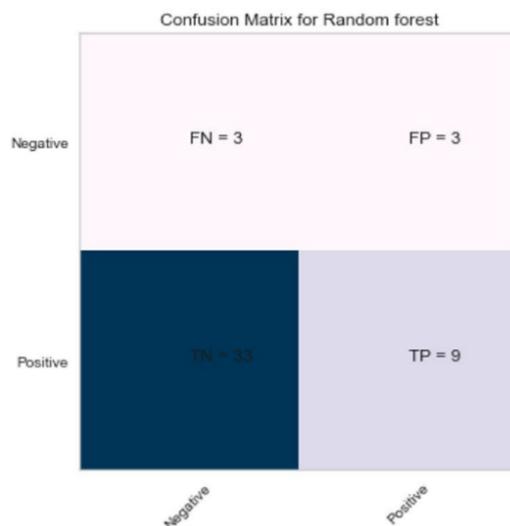


Рисунок 5. Матрица ошибок для Random Forest

Таблица 2. Оценки для каждого класса алгоритма Random Forest

Класс/Метрика	Precision	Recall	F1	Accuracy
Amaranthus	1.00	0.50	0.67	0.83
Ambrosia	1.00	0.75	0.86	0.92
Bindweed	0.33	1.00	0.50	0.83
Bromus	0.75	1.00	0.86	0.92

Значение метрики precision для объектов «Amaranthus» и «Ambrosia» равно 1, для объектов класса «Bindweed» - 0.33, для «Bromus» - 0.75, а общая оценка precision составила 0.75, это связано с тем что, множество объектов вида «Bindweed» были ошибочно классифицировано как объекты класса «Bromus» и снизило среднее значение данной метрики. А показатель recall классов «Bindweed» и «Bromus» является высоким, чем значение этой метрики класса «Amaranthus», так как при классификации объектов первого класса было потеряно больше долей правильных предсказаний. Accuracy классификатора Random Forest по двум классам, кроме «Amaranthus» и «Bindweed» составила 0.92, из-за низкой оценки recall класса «Amaranthus» и precision класса «Bindweed», их точность распознавания составила всего 0.83.

По матрице ошибок алгоритма Decision Tree (рис. 6), можно увидеть, что количество истинно-положительных решений классификатора равно 7. Число TN-комбинаций составляет 31, а количество ошибок первого и второго рода, сделанных моделью машинного обучения – 5. Так как правильно предсказанных объектов меньше чем, у KNN и RF, ассугасу имеет низкий показатель.

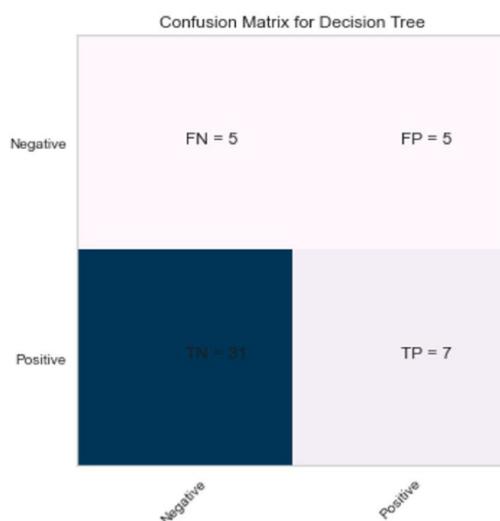


Рисунок 6. Матрица ошибок для Decision Tree

Больше всего ошибочных предсказаний сделаны при классификации сорных растений вида «Amaranthus», поэтому precision, recall и accuracy этого класса имеют значение ниже, чем остальные классы. Численные показатели представлены в таблице 3. С использованием метрики F1, уравнивается баланс между precision и recall, таким образом, для классификатора Decision Tree, их значение составило 0.8, 1.0 и 0.5 соответственно для «Ambrosia», «Bindweed» и «Bromus».

Таблица 3. Оценки для каждого класса алгоритма Decision Tree

Класс/Метрика	Precision	Recall	F1	Accuracy
Amaranthus	0.00	0.00	0.00	0.67
Ambrosia	0.67	1.00	0.80	0.83
Bindweed	1.00	1.00	1.00	1.00
Bromus	0.40	0.67	0.50	0.67

В таблице 4 представлены численные показатели всех метрик оценки алгоритмов, которые применялись для классификации сорняков.

Таблица 4. Метрики качества алгоритмов

	KNN	RF	DT
Confusion matrix	[8, 4 4, 32]	[9, 3 3, 33]	[7, 5 5, 31]
FPR	0,11	0,08	0,14
FNR	0,33	0,25	0,42
Recall	0,67	0,75	0,70
Precision	0,67	0,75	0,70
Accuracy	0,83	0,88	0,79
F1-measure	0,67	0,75	0,70
Jaccard index	0,50	0,60	0,41
Cohen's kappa	0,63	0,63	0,63
MCC	0,56	0,67	0,44
Specificity	0,89	0,92	0,86
Youden's index	0,56	0,67	0,56
Cross-validation	0,58	0,68	0,45

Доля ошибок, сделанных при отнесении объектов к определенному классу классификатором K-Nearest Neighbors – 0.11, алгоритмом Random Forest – 0.08, а Decision Tree ошибочно классифицировал 14% долю от всех объектов. Индекс Жаккарда, который является важным показателем при различении фона и целевого изображения для K-Nearest Neighbors равен 0.50, для Random Forest равен 0.60, для Decision Tree равен 0.41. Коэффициент корреляции Мэтьюса полезен при работе с несбалансированными данными, в случаях, где количество объектов каждого класса бывают разными. Количество изображений классов сорных растений в нашем датасете одинаковые, поэтому этот коэффициент имеет средний показатель. Функции индекс Юдена и AUC зависят только от суммарного процента ошибок в обоих классах и не меняются при разном распределении ошибок между классами даже в случае дисбаланса. По таблице можно увидеть, что индекс Юдена для K-Nearest Neighbors и Decision Tree имеет одинаковую оценку, а классификатор Random Forest превосходит их по этому индексу.

Оценивание качества работы классификатора проводилось в целях определения алгоритма с высокой точностью обнаружения сорных растений. По численным показателям, можно сделать вывод о том, что Random Forest лучше всех подходит для классификации объектов.

Заключение

В представленной исследовательской работе описывается процесс сегментации, различения сорных растений, так же проведена оценка алгоритмов, которые применялись для классификации. Сформирована собственная база с изображениями распространенных типов сорных растений, такие как ширица, амброзия, вьюнок и костер. Собранный датасет может быть использован другими исследователями для проведения дальнейших исследований, связанных с обнаружением вредителей сельскохозяйственных угодий. В процессе сегментации, сделана очистка изображения от шума для предоставления изображений хорошего качества. По итогам проведенной оценки, точность обнаружения сорняков классификаторами K-Nearest Neighbors, Random

Forest и Decision Tree составила 83.3%, 87.5%, и 80%. Средний показатель перекрестной валидации, являющаяся методом оценки моделей машинного обучения составила 0.68.

Количественные результаты, полученные на реальных данных, демонстрируют, что предлагаемый подход может обеспечить хорошие результаты классификации изображений сорняков с низким разрешением. В будущем планируется расширить набор данных, добавляя изображения других видов сорных растений, также улучшить результаты точности обнаружения с применением алгоритмов обучения нейронных сетей.

Благодарность

Данная работа поддержана грантом Министерства образования и науки Республики Казахстан в рамках проекта №AP08857573 «Разработка интеллектуальных информационных технологий на основе машинного зрения и распознавания образов с построением мобильного робота по обслуживанию сельхоз угодий».

Список использованной литературы

- 1 Fawakherji, M., Youssef, A., Bloisi, D., Pretto, A., & Nardi, D. (2019). *Crop and Weeds Classification for Precision Agriculture Using Context-Independent Pixel-Wise Segmentation*. 2019 Third IEEE International Conference on Robotic Computing (IRC). doi:10.1109/irc.2019.00029
- 2 Siddiqi, M. H., Ahmad, W., & Ahmad, I. (n.d.). *Weed Classification Using Erosion and Watershed Segmentation Algorithm*. *Innovations and Advanced Techniques in Systems, Computing Sciences and Software Engineering*, 366–369. doi:10.1007/978-1-4020-8735-6_69
- 3 Zhang, S., Huang, W., & Wang, Z. (2021). *Combing modified Grabcut, K-means clustering and sparse representation classification for weed recognition in wheat field*. *Neurocomputing*, 452, 665–674. doi:10.1016/j.neucom.2020.06.140
- 4 Milioto, A., Lottes, P., & Stachniss, C. (2018). *Real-Time Semantic Segmentation of Crop and Weed for Precision Agriculture Robots Leveraging Background Knowledge in CNNs*. 2018 IEEE International Conference on Robotics and Automation (ICRA). doi:10.1109/icra.2018.8460962
- 5 Dos Santos Ferreira, A., Matte Freitas, D., Gonçalves da Silva, G., Pistori, H., & Theophilo Folhes, M. (2017). *Weed detection in soybean crops using ConvNets*. *Computers and Electronics in Agriculture*, 143, 314–324. doi:10.1016/j.compag.2017.10.027
- 6 Wang, A., Zhang, W., & Wei, X. (2019). *A review on weed detection using ground-based machine vision and image processing techniques*. *Computers and Electronics in Agriculture*, 158, 226–240. doi:10.1016/j.compag.2019.02.005
- 7 Di Cicco, M., Potena, C., Grisetti, G., & Pretto, A. (2017). *Automatic model based dataset generation for fast and accurate crop and weeds detection*. 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). doi:10.1109/iros.2017.8206408
- 8 Di Cicco, M., Potena, C., Grisetti, G., & Pretto, A. (2017). *Automatic model based dataset generation for fast and accurate crop and weeds detection*. 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). doi:10.1109/iros.2017.8206408
- 9 Potena, C., Nardi, D., & Pretto, A. (2017). *Fast and Accurate Crop and Weed Identification with Summarized Train Sets for Precision Agriculture*. *Advances in Intelligent Systems and Computing*, 105–121. doi:10.1007/978-3-319-48036-7_9
- 10 Haug, S., & Ostermann, J. (2015). *A Crop/Weed Field Image Dataset for the Evaluation of Computer Vision Based Precision Agriculture Tasks*. *Lecture Notes in Computer Science*, 105–116. doi:10.1007/978-3-319-16220-1_8
- 11 Ma, X., Deng, X., Qi, L., Jiang, Y., Li, H., Wang, Y., & Xing, X. (2019). *Fully convolutional network for rice seedling and weed image segmentation at the seedling stage in paddy fields*. *PLOS ONE*, 14(4), e0215676. doi:10.1371/journal.pone.0215676
- 12 Asad, M. H., & Bais, A. (2020). *Weed detection in canola fields using maximum likelihood classification and deep convolutional neural network*. *Information Processing in Agriculture*, 7(4), 535–545. doi:10.1016/j.inpa.2019.12.002
- 13 Lavania, S., & Matey, P. S. (2015). *Novel Method for Weed Classification in Maize Field Using Otsu and PCA Implementation*. 2015 IEEE International Conference on Computational Intelligence & Communication Technology. doi:10.1109/cict.2015.71
- 14 Bosilj, P., Duckett, T., & Cielniak, G. (2018). *Analysis of Morphology-Based Features for Classification of Crop and Weeds in Precision Agriculture*. *IEEE Robotics and Automation Letters*, 3(4), 2950–2956. doi:10.1109/ra.2018.2848305
- 15 Sarvini, T., Sneha, T., Sukanya Gowthami, G. S., Sushmitha, S., Kumaraswamy, R. (2019). *Performance Comparison of Weed Detection Algorithms*. 2019 International Conference on Communication and Signal Processing (ICCSP). doi:10.1109/iccsp.2019.8698094
- 16 Belgiu, M.; Drăguț, L. *Random forest in remote sensing: A review of applications and future directions*. *ISPRS J. Photogramm. Remote Sens.* 2016, 114, 24–31

17 Старовойтов, В. В. Сравнительный анализ оценок качества бинарной классификации / В. В. Старовойтов, Ю. И. Голуб // Информатика. – 2020. – Т. 17, № 1. – С. 87–101. <https://doi.org/10.37661/1816-0301-2020-17-1-87-101>

References

- 1 Fawakherji, M., Youssef, A., Bloisi, D., Pretto, A., & Nardi, D. (2019). Crop and Weeds Classification for Precision Agriculture Using Context-Independent Pixel-Wise Segmentation. 2019 Third IEEE International Conference on Robotic Computing (IRC). doi:10.1109/irc.2019.00029
- 2 Siddiqi, M. H., Ahmad, W., & Ahmad, I. (n.d.). Weed Classification Using Erosion and Watershed Segmentation Algorithm. *Innovations and Advanced Techniques in Systems, Computing Sciences and Software Engineering*, 366–369. doi:10.1007/978-1-4020-8735-6_69
- 3 Zhang, S., Huang, W., & Wang, Z. (2021). Combing modified Grabcut, K-means clustering and sparse representation classification for weed recognition in wheat field. *Neurocomputing*, 452, 665–674. doi:10.1016/j.neucom.2020.06.140
- 4 Milioto, A., Lottes, P., & Stachniss, C. (2018). Real-Time Semantic Segmentation of Crop and Weed for Precision Agriculture Robots Leveraging Background Knowledge in CNNs. 2018 IEEE International Conference on Robotics and Automation (ICRA). doi:10.1109/icra.2018.8460962
- 5 Dos Santos Ferreira, A., Matte Freitas, D., Gonçalves da Silva, G., Pistori, H., & Theophilo Folhes, M. (2017). Weed detection in soybean crops using ConvNets. *Computers and Electronics in Agriculture*, 143, 314–324. doi:10.1016/j.compag.2017.10.027
- 6 Wang, A., Zhang, W., & Wei, X. (2019). A review on weed detection using ground-based machine vision and image processing techniques. *Computers and Electronics in Agriculture*, 158, 226–240. doi:10.1016/j.compag.2019.02.005
- 7 Di Cicco, M., Potena, C., Grisetti, G., & Pretto, A. (2017). Automatic model based dataset generation for fast and accurate crop and weeds detection. 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). doi:10.1109/iros.2017.8206408
- 8 Di Cicco, M., Potena, C., Grisetti, G., & Pretto, A. (2017). Automatic model based dataset generation for fast and accurate crop and weeds detection. 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). doi:10.1109/iros.2017.8206408
- 9 Potena, C., Nardi, D., & Pretto, A. (2017). Fast and Accurate Crop and Weed Identification with Summarized Train Sets for Precision Agriculture. *Advances in Intelligent Systems and Computing*, 105–121. doi:10.1007/978-3-319-48036-7_9
- 10 Haug, S., & Ostermann, J. (2015). A Crop/Weed Field Image Dataset for the Evaluation of Computer Vision Based Precision Agriculture Tasks. *Lecture Notes in Computer Science*, 105–116. doi:10.1007/978-3-319-16220-1_8
- 11 Ma, X., Deng, X., Qi, L., Jiang, Y., Li, H., Wang, Y., & Xing, X. (2019). Fully convolutional network for rice seedling and weed image segmentation at the seedling stage in paddy fields. *PLOS ONE*, 14(4), e0215676. doi:10.1371/journal.pone.0215676
- 12 Asad, M. H., & Bais, A. (2020). Weed detection in canola fields using maximum likelihood classification and deep convolutional neural network. *Information Processing in Agriculture*, 7(4), 535–545. doi:10.1016/j.inpa.2019.12.002
- 13 Lavania, S., & Matey, P. S. (2015). Novel Method for Weed Classification in Maize Field Using Otsu and PCA Implementation. 2015 IEEE International Conference on Computational Intelligence & Communication Technology. doi:10.1109/cict.2015.71
- 14 Bosilj, P., Duckett, T., & Cielniak, G. (2018). Analysis of Morphology-Based Features for Classification of Crop and Weeds in Precision Agriculture. *IEEE Robotics and Automation Letters*, 3(4), 2950–2956. doi:10.1109/ra.2018.2848305
- 15 Sarvini, T., Sneha, T., Sukanya Gowthami, G. S., Sushmitha, S., Kumaraswamy, R. (2019). Performance Comparison of Weed Detection Algorithms. 2019 International Conference on Communication and Signal Processing (ICCSP). doi:10.1109/iccsp.2019.8698094
- 16 Belgiu, M.; Drăguț, L. Random forest in remote sensing: A review of applications and future directions. *ISPRS J. Photogramm. Remote Sens.* 2016, 114, 24–31
- 17 Starovoitov V.V. (2020) Sravnitel'nyj analiz ocenok kachestva binarnoj klassifikacii [Comparative analysis of quality assessments of binary classification]. *Informatics. T. 17, No. 1.* 87–101. (In Russian) <https://doi.org/10.37661/1816-0301-2020-17-1-87-101>