

Научная статья

УДК 004.8:517.4:58

DOI 10.35266/1999-7604-2024-1-3

КЛАССИФИКАЦИЯ СОСТОЯНИЯ РАСТЕНИЙ СРЕДСТВАМИ ТЕКСТУРНОГО ВЕЙВЛЕТ-АНАЛИЗА И МАШИННОГО ОБУЧЕНИЯ

**Валентин Валерьевич Брыкин¹✉, Михаил Яковлевич Брагинский²,
Дмитрий Викторович Тараканов³, Ирина Олеговна Тараканова⁴**

^{1, 2, 3, 4}Сургутский государственный университет, Сургут, Россия

¹valentin.brykin@mail.ru ✉, <https://orcid.org/0000-0002-6143-8992>

²braginskiy_my@surgu.ru, <https://orcid.org/0000-0003-1332-463X>

³sprtdv@mail.ru, <https://orcid.org/0000-0003-1851-1039>

⁴tarakanova_io@surgu.ru, <https://orcid.org/0000-0002-7707-5890>

Аннотация. В данной работе предложен метод, комбинирующий вейвлет-преобразования и методы машинного обучения, для классификации состояния растительных культур по цветным цифровым изображениям. Входными данными для классификации являлся сформированный вектор текстурных признаков Харалика.

Реализована программа на высокоуровневом языке программирования Python для классификации цифровых изображений с использованием многоуровневого дискретного вейвлет-преобразования Добеши и классификационных методов машинного обучения – классической логистической регрессии и перцептрона. Показана эффективность предложенного метода в решении задачи многоклассовой классификации изображений, сделаны соответствующие выводы, оценены перспективы метода.

Ключевые слова: вейвлет-преобразование Добеши, текстурные признаки Харалика, нейронная сеть, логистическая регрессия, классификация цифровых изображений

Для цитирования: Брыкин В. В., Брагинский М. Я., Тараканов Д. В., Тараканова И. О. Классификация состояния растений средствами текстурного вейвлет-анализа и машинного обучения // Вестник кибернетики. 2024. Т. 23, № 1. С. 23–30. DOI 10.35266/1999-7604-2024-1-3.

Original article

CLASSIFICATION OF PLANTS HEALTH VIA TEXTURE WAVELET ANALYSIS AND MACHINE LEARNING

Valentin V. Brykin¹✉, Mikhail Ya. Braginsky², Dmitry V. Tarakanov³, Irina O. Tarakanova⁴

^{1, 2, 3, 4}Surgut State University, Surgut, Russia

¹valentin.brykin@mail.ru ✉, <https://orcid.org/0000-0002-6143-8992>

²braginskiy_my@surgu.ru, <https://orcid.org/0000-0003-1332-463X>

³sprtdv@mail.ru, <https://orcid.org/0000-0003-1851-1039>

⁴tarakanova_io@surgu.ru, <https://orcid.org/0000-0002-7707-5890>

Abstract. The article demonstrates a method that combines the wavelet transform and machine learning methods to classify plants health using colored digital images. The input data for classification is comprised of a built vector of Haralick texture features.

The software was developed via the Python programming language to classify digital images with the multilevel discrete Daubechies wavelet transform and methods of classification for machine learning, particularly classic logistic regression and perceptron. The efficiency of this method for solving the problem of multiclass image classification is demonstrated. The study concludes and assesses the prospects of the method.

Keywords: Daubechies wavelet transform, Haralick texture features, neural network, logistical regression, digital images classification

For citation: Brykin V. V., Braginsky M. Ya., Tarakanov D. V., Tarakanova I. O. Classification of plants health via texture wavelet analysis and machine learning. *Proceedings in Cybernetics*. 2024;23(1):23–30. DOI 10.35266/1999-7604-2024-1-3.

ВВЕДЕНИЕ

Сегодня цифровизация сельского хозяйства, где полевые условия контролируются с помощью автономных систем, набирает все большие обороты. При создании систем подобного рода необходимо решать задачи идентификации болезни растений, анализировать динамику их роста.

Выявление болезней растений на ранней стадии и их своевременное предотвращение позволяет избежать больших потерь с точки зрения качества, количества и финансов. Таким образом, для укрепления экономики и сельского хозяйства государство нуждается в системах, способных выявлять болезни растений с высокой точностью и скоростью.

Имеется большая потребность в новых технологиях, отслеживающих рост растений и прогнозирующих воздействие на него различных факторов. В большинстве случаев болезни можно проследить по состоянию побегов растения (стебля, листьев). Значит, идентификация растений, выявление болезней, анализ роста играют существенную роль в успешном выращивании агрономических культур.

Все операции, связанные с обработкой изображений, выполняются в цветовом пространстве RGB, являющемся одним из основных способов представления изображений.

МАТЕРИАЛЫ И МЕТОДЫ

Вейвлет-преобразование

Вейвлет-преобразование представляет собой многомасштабное и многоразрешающее преобразование, позволяющее извлекать из изображения высокочастотные и низкочастотные компоненты. В данной работе используется дискретное двумерное вейвлет-преобразование Добеши (DWT2, вейвлет ‘db2’). Это означает, что квадратное изображение будет передано в качестве входных данных для вейвлет-функции, которая разделит все изображение на 4 компоненты (рис. 1).

Компоненты на рис. 1 – квадранты поддиапазонов частот, где L – низкая частота, H – высокая частота. Разложение может быть многоуровневым, где n – число уровней разложения. LL-квадрант представляет собой аппроксимацию исходного изображения (cA_n), HL – его вертикальные детали (cV_n), LH – горизонтальные детали (cH_n), HH – диагональные составляющие (cD_n) [1–4].

Текстура наряду с цветом является самой важной особенностью, если необходимо обнаружить какой-либо объект. Это относится и к классификации состояния растений – любое заболевание отличается характерным распространением по организму и цветом. На основе расположения пикселей на изображении




Рис. 1. Принцип одноуровневого двумерного вейвлет-разложения исходного изображения

Примечание: составлено по [1].

появляется возможность идентифицировать любой объект.

Существует множество способов текстурного анализа. Здесь используется метод текстурных признаков Харалика. Эти признаки рассчитываются на основе матрицы совпадения уровней серого (gray-level co-occurrence matrix, GLCM), являющейся оценкой плотности распределения вероятностей второго порядка $p_2(P, Q, Z, Y)$, полученной по одному изображению в предположении, что плотность вероятности p_2 зависит лишь от взаимного расположения P и Q . При этом Z является числом, обозначающим учет соседних пикселей, в том числе их расстояния от пикселя интереса. Y – значение ориентации пикселя интереса и соседних пикселей (в градусах) в интервале $[0; 2\pi)$ с шагом $\pi/4$.

Проще говоря, GLCM-матрица строится на основе вычислений частоты встречаемости пикселя с интенсивностью i с пикселем интенсивности j . Каждый элемент (i, j) в матрице смежности описывает число случаев, когда пиксель со значением i встречается с пикселем со значением j [5].

Хотя GLCM-матрица и представляет собой текстурные свойства, но она неудобна при непосредственном анализе изображения. Признаки Харалика, вычисляемые на ее основе, зарекомендовали себя куда лучше. В данной работе использовались 4 информативных признака, дающих наибольшую итоговую точность, из 14 возможных:

- **Контраст.** Измеряет пространственную частоту изображения:

$$con = \sum_{i=1}^N \sum_{j=1}^N p_{i,j} (i - j)^2. \quad (1)$$

- **Несходство.** Мера расстояния между парами пикселей в интересующей области:

$$dis = \sum_{i=1}^N \sum_{j=1}^N |i - j| \cdot p(i, j)^2. \quad (2)$$

- **Энергия** (второй угловой момент). Измеряет текстурную однородность изображения:

$$enr = \sum_{i=1}^N \sum_{j=1}^N p(i, j)^2. \quad (3)$$

- **Однородность** (обратный разностный момент). Измеряет однородность изображения, которая возрастает при уменьшении тона серого:

$$hom = \sum_{i=1}^N \sum_{j=1}^N \frac{p_{i,j}}{1 + (i - j)^2}. \quad (4)$$

Алгоритм классификации

Целью данной работы является классификация большого числа цифровых изображений растений на основе информации об их текстуре и цвете. Алгоритм классификации основан на совместном применении текстурных признаков Харалика, вейвлет-преобразования Добеши и многослойной нейронной сети.

Общий порядок действий алгоритма представлен в схеме на рис. 2.

Как можно увидеть из рис. 2, после инициализации набора данных и его предварительной обработки к каждому изображению применяется дискретное двумерное вейвлет-преобразование Добеши. Полученные коэффициенты затем группируются по квадрантам поддиапазонов частот, помогая извлекать текстурные признаки, которые пе-




Рис. 2. Схема предлагаемого алгоритма классификации

Примечание: составлено авторами.

редаются в качестве входных данных для классификационных методов.

Загрузка и подготовка данных

Исходные данные приведены на рис. 3 и представляют собой набор цветных цифровых изображений, распределенных по директориям, имена которых соответствуют названиям классов. Изображения были предварительно подготовлены – приведены к единому размеру 256×256 пикселей и распределены поровну на каждый класс (сбалансированы по 2200 единиц в каждом классе, суммарно 17600 фотографий). Таким образом, количество директорий совпадает с числом классов, т. е. 8.

Датасет на рис. 3 был загружен с общедоступного ресурса по исследованию данных Kaggle.

Получение значений признаков

Результат вейвлет-преобразования, описанного выше, приведен на рис. 4 на примере исходных данных.

Так как каждый из 4-х квадрантов представляет собой RGB-область размером 128×128 пикселей исходного изображения, для каждого из 3-х его каналов (красная, зеленая и синяя компонента) строится симметричная нормированная GLCM-матрица в 256 оттенках серого. Значит, для целого изображения будет вычислено 12 GLCM-матриц оттенков серого. В свою очередь, каждая такая матрица порождает 4 значения призна-

ков Харалика, описанных ранее. Таким образом, при одноуровневом вейвлет-преобразовании одно цветное изображение будет описано вектором-строкой из 48 коэффициентов-признаков Харалика. Вообще длина вектора может быть рассчитана по следующей формуле:

$$F = Q \cdot C \cdot H \cdot n, \quad (5)$$

где $Q = 4$ – количество областей (квадрантов), на которые разбивается изображение;

$C = 3$ – количество каналов цветного изображения (в данном случае RGB);

H – количество признаков Харалика, порождаемых GLCM-матрицей (здесь $H = 4$);

n – число уровней вейвлет-преобразования.

Формула (5) представляет расчет итогового числа текстурных признаков на единицу исходных данных.

Логично, что с увеличением количества n уровней вейвлет-разложения будет пропорционально расти и размерность F вектора признаков. В текущей работе число уровней разложения n было определено эмпирически. Для восьми классов оптимально значение $n = 3$. Отсюда итоговое число признаков $F = 4 \cdot 3 \cdot 4 \cdot 3 = 144$. Для удобства восприятия и дальнейших расчетов все коэффициенты – это массив размером $m \times k$ (где $m = 17600$ – общее число изображений в наборе данных, $k = F + 1 = 145$ – итоговое количество признаков Харалика и метка класса, закодированная способом «label encoding») – были записаны



Рис. 3. Классы исходных данных

Примечание: составлено авторами.




Рис. 4. Пример одноуровневого двумерного вейвлет-разложения исходного изображения
Примечание: составлено авторами.

в CSV-файл средствами библиотеки Pandas языка Python (рис. 5).

Стоит также упомянуть другие модули и библиотеки Python, задействованные в данной работе:

Os – для работы с операционной и файловой системами (загрузка и инициализация набора данных);

OpenCV – для анализа изображений;

NumPy – для работы с многомерными массивами;

Matplotlib – для визуализации данных и вычислений;

PyWt – для вейвлет-вычислений;

Scikit-learn – для операций машинного обучения.

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Фактически датафрейм из рис. 5 представляет собой готовую для дальнейших вычислений и решения основной задачи базу данных признаков изображений. Входными данными для обучения нейронной сети будут являться значения признаков Харалика (все столбцы датафрейма, кроме последнего), выходными – последний столбец

features_db													
	0	1	2	3	4	5	6	7	8	9	...	135	
0	4910.661102	5415.794556	4273.397919	29048.449310	29122.806091	29106.444092	1553.198120	2060.362946	1171.758636	1393.249298	...	0.020375	
1	7303.758423	8427.883728	6236.064575	23997.235077	24021.615082	24051.146210	1490.319397	1115.246582	1598.354919	2341.404175	...	0.021991	
2	4430.062317	4523.639435	3207.685944	31342.150543	31424.312653	31187.380554	2588.799622	5389.672791	2168.333527	1171.598816	...	0.031454	
3	2486.059052	3068.871552	1756.565704	29658.216309	29714.896667	29592.967621	1630.973450	1723.165375	1520.119598	2698.978638	...	0.022097	
4	2495.887024	3002.724609	1748.883606	29889.781281	29849.687653	29692.824524	1620.140015	1768.595612	1494.767761	2675.156372	...	0.022522	
...	...	...	...	...	...	...	...	...	...	...	...	...	...
17595	1535.361542	1275.335602	1669.307983	32816.403412	33203.055695	33404.653168	3346.186890	3439.760468	693.740204	844.401672	...	0.023542	
17596	2938.391448	3469.871307	1427.089050	20699.824158	21046.329041	22294.390381	1638.140228	2546.195953	436.153076	1110.063110	...	0.041534	
17597	2976.249786	3380.340973	1314.810059	33047.073792	33249.885498	33173.229004	811.761047	2261.653107	458.613220	1446.747620	...	0.029648	
17598	7692.713287	10451.721527	10453.655701	28285.653687	28356.335419	28304.653381	1385.866791	1878.329651	1318.927338	1372.675537	...	0.016805	
17599	4373.335419	4887.719177	2555.983002	27060.069489	27138.666473	28001.021484	1659.912781	3139.970367	585.401855	717.408020	...	0.033401	

17600 rows × 145 columns

Рис. 5. Текстуальные признаки Харалика для исходного датасета
Примечание: составлено авторами.

датафрейма с закодированными метками классов.

Следующим шагом является предварительная обработка данных.

Во-первых, это разделение на обучающую и тестовую выборки в оптимальном соотношении 70 к 30.

Во-вторых, стандартизация: некоторые характеристики имеют широкий диапазон значений и в процессе классификации могут создать систематическую ошибку. Вспомогательный класс **StandardScaler** масштабирует данные так, чтобы они имели нулевое среднее значение и единичную дисперсию ($\mu = 0$, $\sigma = 1$). Важно то, что здесь выполняется стандартизация лишь входных данных, поскольку выходные содержат только закодированные метки [6, 7].

В-третьих, уменьшение размерности, являющееся самым важным шагом предобработки. Оно улучшает скорость работы методов машинного обучения, снижает требования к памяти при минимальных информационных потерях. Одним из распространенных методов уменьшения размерности данных является метод главных компонент (principal component analysis, PCA). В библио-

теку Scikit-learn этот метод уже встроен, поэтому главной задачей становится правильный выбор количества главных компонент набора данных. Чтобы ее решить, нужно построить график зависимости параметра «Variance explained» от количества главных компонент (рис. 6).

Параметр «Variance explained» характеризует степень потери полезной информации о данных. Чем ближе он к 1, тем больше информации сохраняется для анализа [8].

Как можно заметить из рис. 6, уже при числе $N = 40$ компонент значение вариативности практически достигает единицы, так что именно этот показатель будет взят для дальнейших расчетов. Таким образом, с минимальными потерями удалось снизить размерность данных более чем в три раза (со 144 до 40 признаков).

Непосредственно классификация выполнялась двумя способами:

- классическим алгоритмом машинного обучения – логистической регрессией;
- базовой моделью искусственной нейронной сети – персептроном.

Результаты приведены в сравнительной таблице.




Рис. 6. График зависимости параметра «Variance explained» от числа главных компонент
Примечание: составлено авторами.

Таблица

Результаты нейросетевой классификации

Метод классификации	Метрика			
	accuracy	precision	recall	f-score
Логистическая регрессия	88 %	0.88	0.87	0.87
Перцептрон	84 %	0.84	0.83	0.84

Примечание: составлено авторами.

Как можно видеть из таблицы, благодаря комбинированию методов текстурного анализа и машинного обучения удалось достичь высоких показателей точности – до 88 %.

ЗАКЛЮЧЕНИЕ

В статье предложен алгоритм многоклассовой классификации состояния растений с использованием текстуры изображений, от-

личающийся совокупным применением методов вейвлет-анализа и машинного обучения, что позволило достичь хороших результатов (до 88 % точности).

Перспективы совершенствования предложенного метода могут включать выбор наиболее оптимального типа вейвлет-преобразования и классификационного метода машинного обучения.

Список источников

1. Vyas A., Paik J. Review of the application of wavelet theory to image processing. *IEIE Transactions on Smart Processing & Computing*. 2016;5(6):403–417.
2. Балаганский А. Ю., Гребеньков А. А. Вейвлет-преобразование для обработки изображений системы управления отоплением с применением методов машинного обучения // Информатика и образование: границы коммуникаций. 2022. № 14. С. 147–150.
3. Мельникова Ю. С. Анализ и обработка медицинских изображений с помощью метода вейвлет-анализа в ветеринарии // Фундаментальные и прикладные исследования в информатике и цифровизации : материалы симпозиума XVIII (L) Международ. науч. конф. студентов, аспирантов и молодых ученых, приуроченной к 50-летию КемГУ, 26 апреля 2023 г., г. Кемерово. Кемерово : Кемеровский государственный университет, 2023. С. 138–141.
4. Alekseev V. V., Kaliakin I. V. The role of sampling rate in wavelet transform decomposition. In: *Proceedings of the XIX IEEE International Conference on Soft Computing and Measurements SCM 2016*, May 25–27, 2016, Saint Petersburg. St. Petersburg; 2016. p. 392–394.
5. Ковалева И. Л. Текстуры признаки изображений. Минск : Белорусский национальный технический университет, 2010. 26 с.
6. Предварительная обработка данных. URL: <https://scikit-learn.ru/6-3-preprocessing-data/> (дата обращения: 25.12.2023).
7. Как писать преобразователи данных в Sklearn. URL: <https://habr.com/ru/companies/skillfactory/articles/675876/> (дата обращения: 25.12.2023).
8. Kumar A. PCA Explained Variance Concepts with Python Example. 2023. URL: <https://vitalflux.com/pca-explained-variance-concept-python-example/> (дата обращения: 27.12.2023).

References

1. Vyas A., Paik J. Review of the application of wavelet theory to image processing. *IEIE Transactions on Smart Processing & Computing*. 2016;5(6):403–417.
2. Balagansky A. Yu., Grebenkov A. A. Wavelet transformation for image processing of a heating control system using machine learning methods. *Informatsiia i obrazovanie: granitsy kommunikatsii*. 2022;(14):147–150. (In Russian).
3. Melnikova Yu. S. Analiz i obrabotka meditsinskikh izobrazhenii s pomoshchiu metoda veivlet-analiza v veterinarii. In: *Proceedings of the Symposium of the XVIII (L) International Scientific Conference for Students, Post-graduates and Young Scientists devoted to the 50th Anniversary of Kemerovo State University "Fundamentalnye i prikladnye issledovaniia v informatike i tsifrovizatsii"*, April 26, 2023, Kemerovo. Kemerovo: Kemerovo State University; 2023. p. 138–141. (In Russian).
4. Alekseev V. V., Kaliakin I. V. The role of sampling rate in wavelet transform decomposition. In: *Proceedings of the XIX IEEE International Conference on Soft Computing and Measurements SCM 2016*, May 25–27, 2016, Saint Petersburg. St. Petersburg; 2016. p. 392–394.
5. Kovaleva I. L. Teksturnye priznaki izobrazhenii. Minsk: Belarusian National University of Technology; 2010. 26 p. (In Russian).
6. Predvaritelnaia obrabotka dannykh. URL: <https://scikit-learn.ru/6-3-preprocessing-data/> (accessed: 25.12.2023). (In Russian).
7. Kak pisat preobrazovateli dannykh v Sklearn. URL: <https://habr.com/ru/companies/skillfactory/articles/675876/> (accessed: 25.12.2023). (In Russian).
8. Kumar A. PCA Explained Variance Concepts with Python Example. 2023. URL: <https://vitalflux.com/pca-explained-variance-concept-python-example/> (accessed: 27.12.2023).

Информация об авторах

В. В. Брыкин – аспирант.

М. Я. Брагинский – кандидат технических наук,
доцент.

Д. В. Тараканов – кандидат технических наук, до-
цент.

И. О. Тараканова – аспирант, ассистент.

Information about the authors

V. V. Brykin – Postgraduate.

M. Ya. Braginsky – Candidate of Sciences (Engineer-
ing), Docent.

D. V. Tarakanov – Candidate of Sciences (Engineer-
ing), Docent.

I. O. Tarakanova – Postgraduate, Assistant Professor.