

И.И. Стрельников, А.З. Глухов, А.В. Николаева, С.М. Марушенко

ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ИДЕНТИФИКАЦИИ ВИДОВ РОДА *LITHOPS* N.E.Br. ПО РИСУНКУ ЛИСТА

Государственное учреждение «Донецкий ботанический сад»

Повышение объективности определения таксономической принадлежности организмов является актуальной задачей, которая может быть решена с применением методов машинного обучения. Интерес в данном направлении представляют подходы сверточных нейронных сетей, которые позволяют идентифицировать объекты по цифровым фотографиям. В работе исследована потенциальная применимость этих методов для определения видов рода *Lithops* N.E.Br. Обученная на изображениях листьев нейронная сеть продемонстрировала высокую точность (81 % верных идентификаций). Проведенный анализ подтвердил способность модели выявлять видоспецифичные фенотипические признаки. Результаты исследования подтверждают эффективность сверточных нейронных сетей в задачах идентификации растений.

Ключевые слова: искусственные нейронные сети, таксономическая идентификация, *Lithops* N.E.Br.

Введение

Точное определение таксономической принадлежности организмов является обязательным условием для широкого спектра биологических исследований. В ботанике задача идентификации исторически опиралась на морфологические и, в меньшей степени, на экологические особенности растения. Хотя указанные подходы развивались на протяжении всей обозримой истории биологии, их практическое применение все еще содержит ряд проблемных аспектов. Прежде всего, идентификация, в той или иной мере, включает элементы субъективной трактовки качественных признаков. Даже при наличии проработанных методик определения конкретной группы растений, дифференцирование уровней некоторых характеристик, например, интенсивности опушения или окраски, все равно остается на усмотрение человека. В результате задача точной идентификации, особенно в случае «сложных» таксонов, требует участия высококвалифицированного систематика. Достижение необходимого уровня навыков определения растений невозможно

без многолетней практики. В результате проведение исследования ограничивается недоступностью нужных экспертов, или его объективность снижается из-за низкого качества определения таксонов.

Обозначенная проблема может быть решена путем увеличения доли объективных источников информации для принятия решения [2]. Одним из таких источников могут выступать результаты генетического анализа, но данные подходы остаются дорогостоящими и пока не приобрели всеобщего распространения. Вторым перспективным направлением является применение методов машинного обучения [10, 13]. В общем виде машинное обучение – это задача трансфера навыков эксперта компьютеризированной системе, которую можно охарактеризовать следующим принципиальным алгоритмом:

1. Эксперт (или группа экспертов) проводят идентификацию растений.

2. Для указанных растений собирается набор релевантной информации. При этом, для повы-

шения объективности, характеристики желательного получать инструментальными методами.

3. Процедура обучения – получение статистической модели, которая сможет воспроизвести идентификацию вида по предложенному набору признаков.

4. Применение обученной модели для идентификации новых объектов по набору признаков.

Методы машинного обучения демонстрируют хорошие результаты для отдельных групп растений, но всем им свойственен один недостаток – необходимость сбора больших объемов данных. Такое ограничение препятствует как непосредственному внедрению в практику, так и разработке «глобальных» моделей для большого количества видов.

Решение проблемы недостатка данных может быть достигнуто с применением нового поколения моделей машинного обучения, в частности искусственных нейронных сетей (ИНС). Математический аппарат ИНС обеспечивает принципиально новые методы работы с данными. Например, класс сверточных ИНС позволяет классифицировать цифровые изображения путем выделения семантической информации о текстуре и форме объектов. Данная особенность делает эти методы перспективными инструментами для задач автоматической идентификации организмов, так как для их применения не требуется сбор инструментальных данных. Для обучения модели достаточно иметь подходящие изображения растений [7].

В ряде работ показана потенциальная применимость сверточных ИНС для распознавания таксономического положения растений, но к настоящему моменту этот метод остается на этапе становления и требует дополнительных работ по определению его эффективности и оптимальных процедур использования [3, 4].

Цель и задачи исследований

Целью работы стало оценить применимость искусственных нейронных сетей в практике идентификации видов растений, для которых классические подходы на основе морфологии оказываются затруднительными.

В качестве тестовых объектов выбраны виды рода *Lithops* N.E.Br. Данная систематическая группа характеризуется высокой вариабельностью габитуса, что затрудняет разграничение так-

сонов по морфологическим особенностям на практике [5, 8]. Кроме того, у систематиков отсутствует единое мнение о видовой стабильности различных фенотипических признаков, а, следовательно, и об их применимости для идентификации [6].

Для достижения поставленной цели было предусмотрено решение следующих задач:

1. Разработать и протестировать архитектуру сверточной нейронной сети, подходящей для идентификации растений по фотографическим материалам.

2. Проверить гипотезу о видовой специфичности рисунка на верхней части листьев видов рода литопс, установив возможность определения вида только лишь по рисунку.

3. Оценить, какие особенности рисунка позволяют нейронной сети идентифицировать растение.

Объекты и методики исследований

Для первичной проверки базовой гипотезы были выбраны 5 видов рода *Lithops* N.E.Br.: *L. aucampiae* L.Bolus, *L. bromfieldii* L.Bolus, *L. hallii* de Boer, *L. hookeri* Schwantes, *L. pseudo-truncatella* (A.Berger) N.E.Br. Основным критерием отбора являлось наличие достаточного количества доступных изображений этих растений.

Для указанных видов были подобраны фотографии с отчетливым отображением верхней поверхности листьев (с просматриваемым рисунком). Основным источником изображений служил сервис Flickr (<https://www.flickr.com>). Скачивали только фотографии, размещенные под разрешительными лицензиями и снабженные информацией о видовой принадлежности. Правдоподобность идентификации подтверждали визуальной оценкой.

В целях исключения влияния фона на работу модели, на изображениях выделялись только верхняя часть листа с рисунком. Остальные участки закрашивались черным цветом (значения 0 по трем каналам RGB). Таким образом было подготовлено 465 изображений (примерно по 93 изображения для каждого вида). Обучения модели проводили на выборке из 311 случайно отобранных фотографий, остальные 154 использовались для оценки качества обучения.

Для увеличения объема входных данных и исключения эффекта ориентации для каждого из

311 изображений обучающей выборки подготовили 32 варианта со случайными трансформациями: зеркальное отображение по вертикали и/или горизонтали, поворот изображения относительно центра от 0 до 45°, смещение краев изображения относительно центра (sheer) с пределами деформации от 0 до 5 %. В результате получили 9952 трансформированные изображения. Для унификации размеров использовали масштабирование с билинейным фильтром до размеров 128 на 128 пикселей. Пример исходного и трансформированных изображений представлены на рисунке 1.

Разработку и обучение искусственной нейронной сети производили в среде языка программирования Python 3.6 с применением библиотек Keras 2.3.1 и Tensorflow 1.14 [9].

О качестве обучения модели судили по ее способности верно классифицировать тестовые, не участвовавшие в обучении, изображения. При этом использовали распространенные метрики точности [4].

Классовая точность (Precision):

$$P = \frac{T_p}{T_p + F_p}, \quad (1)$$

где T_p – количество истинно положительных результатов классификации, F_p – количество ложно положительных результатов.

Отклик (Recall):

$$R = \frac{T_p}{T_p + F_n}, \quad (2)$$

где T_p – количество истинно положительных результатов, F_n – количество ложно отрицательных результатов.

F-показатель (F₁):

$$F_1 = \frac{2PR}{P + R}, \quad (3)$$

где P – классовая точность, R – отклик.

Общая точность (Accuracy):

$$A = \frac{1}{N} (\sum T_{p(i)} + \sum T_{n(i)}), \quad (4)$$

где N – размер выборки, $T_{p(i)}$ – количество истинно положительных результатов классификации i -го класса, $T_{n(i)}$ – количество истинно отрицательных результатов классификации i -го класса.

Оценку значимости отдельных участков изображений для верной классификации проводили с применением библиотеки `shap 0.35` [11].

Результаты исследований и их обсуждение

Базовой задачей обучения искусственной нейронной сети является выбор подходящей архитектуры. Для решения задачи исследования была




Рис. 1. Исходное изображение выделенного участка листа *Lithops bromfieldii* (сверху) и примеры результатов трансформации (снизу)

Fig. 1. Initial image of *Lithops bromfieldii* leaf part (top) and example results of transformations (bottom)

выбрана классическая схема сверточной сети с одним потоком. Суть модели заключается в подборе такого набора тензорных преобразований, которые трансформируют исходное изображение (массив размером $128 \times 128 \times 3$, так как использовались квадратные изображения со стороной 128 пикселей и тремя цветовыми каналами) к одномерному массиву длиной в 5 элементов. Значения в финальном массиве соответствуют одному из 5 рассматриваемых видов. Целевые преобразования должны быть такими, чтобы если на входе модели будет подано изображения *L. aucampiae*, то выходной массив должен иметь вид близкий к (1, 0, 0, 0, 0). В случае с видом *L. bromfieldii* – (0, 1, 0, 0, 0) и так далее.

Подбор точных параметров архитектуры производили в ручном режиме. В результате удовлетворительный результат продемонстрировала сеть, состоящая из четырех сверточных слоев и трех полностью связанных слоев. Визуализация архитектуры сети представлена на рисунке 2. Процедура свертки в каждом слое осуществлялась с помощью фильтров размерами 3×3 пикселя и последующей процедурой субдискретизации с шагом 2×2 пикселя. Активация проводилась на основе функции линейного выпрямителя (relu) на всех слоях кроме последнего, для которого использовали многомерную логистическую

функцию (softmax). Для предотвращения эффекта переобучения сеть включала процедуру исключений (dropout) с вероятностями 0.1 после сверточных слоев и 0.25 после полностью связанных слоев.

Нейронная сеть была успешно обучена на выборке из 9952 трансформированных изображений. Качество модели оценено по точности классификации тестовой выборки, состоящей из 154 изображений. Соотношения результатов классификации и реальной видовой принадлежности фотографий представлено в таблице 1.

Таблица 1. Матрица неопределенности результатов классификации обученной нейронной сети

	Вид	Истинные значения				
		auc	brom	hal	hook	pseud
Предсказанные значения	auc	27	0	3	1	0
	brom	2	20	5	4	0
	hal	2	0	28	5	0
	hook	0	0	1	22	1
	pseud	0	2	0	4	27

Примечание: auc – *Lithops aucampiae*; brom – *Lithops bromfieldii*; hal – *Lithops hallii*; hook – *Lithops hookeri*; pseud – *Lithops pseudotruncatella*.




Рис. 2. Визуализация архитектуры используемой искусственной нейронной сети. conv – сверточный слой, fc – полносвязанный слой

Fig 2. The artificial neural network architecture visualization. conv – convolutional layer, fc – fully connected layer

Обученная модель в большинстве случаев верно определяла вид рода литопс по предложенным изображениям листового рисунка. Вместе с тем присутствует ряд ошибок. Например, в 11 случаях фотографии были ложно идентифицированы как относящиеся к *L. bromfieldii*, что может свидетельствовать о низкой специфичности рисунка у этого вида. В 6 случаях допущена взаимно неверная идентификация видов *L. hallii* и *L. hookeri*. Правдоподобным объяснением может быть высокое сходство некоторых черт, приводящее к невозможности однозначного разделения этих таксонов.

На основе полученных данных были рассчитаны количественные показатели точности классификации. Результаты представлены в таблице 2.

Предложенная модель показала высокую общую точность идентификации видов, достигающую 81 %. В представленной задаче модель должна верно отнести изображение к одному из пяти классов (видов). Если бы в процессе обучения модель не извлекла из данных никакой полезной для идентификации информации, то ее выводы носили бы случайный, хаотичный характер. Следовательно, вероятность верной классификации изображения составляла бы 1/5 или 20 %. Основываясь на результатах точного биномиального критерия, фактически достигнутая точность статистически значимо превышает уровень в 20 % (123 верные классификации в 154 попытках при ожидаемой вероятности = 0.2, р-значение < $2.2 \cdot 10^{16}$). Следовательно, опираясь только на данные о рисунке листа, предложенная модель справляется с задачей идентификации в 4 раза лучше, чем в самом пессимистичном варианте.

Таким образом, гипотеза о видовой специфичности листового рисунка видов рода литопс может быть признана правдоподобной.

Следует отметить, что точность идентификации разных видов отличается. Например, *L. hookeri* наиболее часто классифицировался неверно с классовой точностью 61. Наилучшая точность идентификации продемонстрирована для вида *L. pseudotruncatella* с точностью 0.96. Возможно, в будущем информацию о взаимных ошибках при идентификации видов можно будет использовать для исследования связи между фенотипом и генетическим родством видов.

Искусственные нейронные сети относят к группе методов типа «черный ящик». Такие модели содержат большое количество параметров и их взаимодействий. Используемая в работе архитектура может быть условно представлена в виде уравнения с 67546629 переменными. Очевидно, что логическая интерпретация роли или функционального смысла отдельных параметров такой большой модели фактически невозможна [1]. Несмотря на это, существует ряд опосредованных методов апостериорного анализа обученных нейронных сетей. В частности, метод интегрированных градиентов позволяет определить, насколько разные участки изображения важны для правильной классификации. В контексте рассматриваемой задачи наиболее информативные участки можно интерпретировать как видоспецифичные особенности листового рисунка [12].

Графическое отображение результатов анализа интегрированных градиентов представлено на рисунке 3.

Таблица 2. Расчетные метрики точности классификации

	Классовая точность (P)	Отклик (R)	F-показатель (F ₁)	Размер выборки (N)
<i>Lithops aucampiae</i>	0.87	0.87	0.87	31
<i>Lithops bromfieldii</i>	0.91	0.65	0.75	31
<i>Lithops hallii</i>	0.76	0.8	0.78	35
<i>Lithops hookeri</i>	0.61	0.92	0.73	24
<i>Lithops pseudotruncatella</i>	0.96	0.82	0.89	33
среднее	0.82	0.81	0.80	154
взвешенное среднее	0.83	0.81	0.81	154
Общая точность (A)			0.81	154




Рис. 3. Визуализация результатов применения метода интегрированных градиентов к обученной сети. Исходные изображения (верхний ряд) и выделенные участки изображений с высокой информативностью (нижний ряд, темным обозначены наиболее значимые пиксели)

Fig 3. Visualization of the results of applying the integrated gradient method to a trained network. Initial images (top row) and selected images parts with high informativeness (bottom row, pixels with the highest importance are depicted with dark color)

Наибольшую информативность для идентификации видов имеют центральные участки и характер окантовки листа. Видоспецифичные признаки *L. aucampiae* – плотный рисунок в центре и присутствие окончаний линий на краях. Для *L. bromfieldii* наиболее вероятно характерной чертой являются крупные извилистые окна (замкнутые участки, формируемые линиями рисунка). Специфическими чертами *L. hallii* и *L. hookeri* можно назвать отсутствие рисунка на краях листа. Возможно именно это сходство вызывает высокую неуверенность нейронной сети при идентификации этих видов. В случае с *L. pseudotruncatella* отображения интегрированных градиентов не столь однозначны – информативными оказываются как отдельные окна в центральной части листа, так и крупные линии вдоль края.

Выводы

Результаты исследования подтверждают эффективность метода сверточных нейронных сетей в качестве источника дополнительной информации, подходящего для внедрения в практику идентификации растений.

Разработанная модель нейронной сети продемонстрировала высокую эффективность при

идентификации растений рода *Lithops* N.E.Br. по фотографиям рисунка листа. Фактическая достигнутая точность распознавания видов составила 81 %. Следует отметить, что в исследовании применялись изображения с низким разрешением, 128 на 128 пикселей. С одной стороны, это свидетельствует о высокой чувствительности предложенного метода, с другой – позволяет предположить направление дальнейшего улучшения качества идентификации на основе более детальных фотографий.

Помимо определения таксономической принадлежности, результаты обучения нейронной сети потенциально могут быть использованы для фенотипического анализа. В частности, перекрестные ошибки идентификации пар видов по своей сути являются следствием схожести внешних признаков. Поэтому количество подобных ошибок может рассматриваться, как мера фенотипического сходства.

Применение методов апостериорного анализа обученной модели подтвердило возможность использования нейронных сетей для выявления и формального описания видоспецифичных признаков.

1. *Bach S.*, Binder A., Montavon G., Klauschen F., Müller K. R., Samek W. On pixel-wise explanations for non-linear classifier decisions by layer-wise relevance propagation // *PloS one*. 2015. Vol. 10. N 7.
2. *Clark J. Y.* Artificial neural networks for species identification by taxonomists // *Biosystems*. 2003. Vol. 72, N 1–2. P. 131–147.
3. *Dyrmann M.*, Karstoft H., Midtiby H.S. Plant species classification using deep convolutional neural network // *Biosyst. Eng.* Elsevier Ltd, 2016. Vol. 151, N 2005. P. 72–80.
4. *Kamilaris A.*, Prenafeta-Boldú F.X. Deep learning in agriculture: A survey // *Comput. Electron. Agric.* 2018. Vol. 147, N 1. P. 70–90.
5. *Kellner A.*, Ritz C. M., Schlittenhardt P., Hellwig F. H. Genetic differentiation in the genus *Lithops* L. (Ruschioideae, Aizoaceae) reveals a high level of convergent evolution and reflects geographic distribution // *Plant Biol.* 2011. Vol. 13, N 2. P. 368–380.
6. *Korn R.W.* Window Patterns in *Lithops* // *Int. J. Plant Sci.* 2011. Vol. 172, N 9. P. 1101–1109.
7. *Lee S. H.*, Chan C. S., Mayo S. J., Remagnino P. How deep learning extracts and learns leaf features for plant classification // *Pattern Recognit.* Elsevier Ltd, 2017. Vol. 71. P. 1–13.
8. *Loots S.*, Nybom H., Schwager M., Sehic J., Ritz C. M. Genetic variation among and within *Lithops* species in Namibia // *Plant Syst. Evol.* Springer Vienna, 2019. Vol. 305, N 10. P. 985–999.
9. *Abadi M.*, Agarwal A., Barham P., Brevdo E., Chen Z., Citro C., Corrado G. S., Davis A., Dean J., Devin M., Ghemawat S., Goodfellow I., Harp A., Irving G., Isard M., Jia Y., Jozefowicz R., Kaiser L., Kudlur M., Levenberg J., Mane D., Monga R., Moore S., Murray D., Olah C., Schuster M., Shlens J., Steiner B., Sutskever I., Talwar K., Tucker P., Vanhoucke V., Vasudevan V., Viegas F., Vinyals O., Warden P., Wattenberg M., Wicke M., Yu Y., Zheng X. TensorFlow: Large-scale machine learning on heterogeneous systems, 2015. Software available from tensorflow.org. URL: <https://www.tensorflow.org/>
10. *Moshou D.*, Vrindts E., De Ketelaere B., De Baerdemaeker J., Ramon H. A neural network based plant classifier // *Comput. Electron. Agric.* 2001. Vol. 31, N 1, P. 5–16.
11. *Štrumbelj E.*, Kononenko I. Explaining prediction models and individual predictions with feature contributions // *Knowledge and information systems*. 2014. V. 4, N 3. P. 647–665.
12. *Sundararajan M.*, Taly A., Yan Q. Axiomatic attribution for deep networks // *Proceedings of the 34th International Conference on Machine Learning-Volume 70.* JMLR. Org. 2017. P. 3319–3328.
13. *Wu S. G.*, Bao F. S., Xu E. Y., Wang Y. X., Chang Y. F., Xiang Q. L. A Leaf Recognition Algorithm for plant classification using probabilistic neural network // *2007 IEEE International Symposium on Signal Processing and Information Technology.* IEEE, 2007. P. 11–16.

Поступила в редакцию: 21.05.2020

UDC 582.61+004.93'12

IDENTIFICATION OF *LITHOPS* N.E.BR. SPECIES WITH ARTIFICIAL NEURAL NETWORKS BASING ON LEAF SURFACE PATTERNS

I.I. Strelnikov, A.Z. Glukhov, A.V. Nikolaeva, S.M. Marushenko

Public Institution «Donetsk Botanical Garden»

Improving the objectivity of taxonomic identification is an urgent task that can be solved using machine learning methods. The approaches of convolutional neural networks, that allow objects identification basing on digital photographs, are of particular interest in this field. In the work, the potential applicability of these methods for determining species of the genus *Lithops* N.E.Br. was studied. The neural network trained on leaf images demonstrated high accuracy (81 % of correct identifications). Further analysis confirmed the ability of the model to detect species-specific phenotypic features. The results of the study confirm the effectiveness of convolutional neural networks in plant identification tasks.

Key words: artificial neural networks, taxonomic identification, *Lithops* N.E.Br.