

УДК 632.08+004.8

ОБНАРУЖЕНИЕ ОСОБЕЙ ОЛЕНЕЙ НА ИЗОБРАЖЕНИЯХ МЕТОДАМИ КОМПЬЮТЕРНОГО ЗРЕНИЯ

© С. Н. Терещенко, А. Л. Осипов

*Новосибирский государственный университет экономики и управления,
630099, г. Новосибирск, ул. Каменская, 56
E-mail: alosip@mail.ru*

Исследован подход применения методов машинного обучения для автоматического обнаружения особей оленей на изображениях. Для точного подсчёта количества особей оленей по фотографиям использовалась технология нейронных сетей. Применялись методы глубокого обучения свёрточных нейронных сетей (ResNet 50, DenseNet, CenterNet, Inception V3, Xception) во взаимодействии с методикой transfer learning. На основе Faster R-CNN ResNet 50 произведено обучение нейронной сети, которая позволила с точностью 0,91 на выборке по метрике F1-score с пороговым значением 0,6 определять особей оленей по графическим изображениям.

Ключевые слова: графические изображения, оленеводство, аугментация, нейронные сети, искусственный интеллект, детекция объектов, компьютерное зрение.

DOI: 10.15372/AUT20240110

EDN: TJZCHZ

Введение. Северные олени — основной источник мяса для северных регионов, которое считается абсолютно натуральным чистым продуктом и деликатесом. С каждым годом численность оленей падает в связи с климатическими изменениями (таяние мерзлоты), браконьерством, нападением хищников, прокладкой газопроводов, вырубкой леса, добычей полезных ископаемых и др. [1]. Отсутствие достаточного финансирования не позволяет объективно оценивать численность популяции; как правило, системного контроля за состоянием и мониторингом популяции оленей как промыслового ресурса не происходит.

Система мониторинга включает в себя информацию: о хищниках, популяции, промысле оленей, домашнем оленеводстве, загрязнении пастбищ тяжёлыми металлами.

Построение системы мониторинга популяции оленей должно основываться на базе современных технических, информационных и коммуникационных средств и технологий (многоспектральная спутниковая съёмка для оценки состояния растительного покрова, спутниковые ошейники, беспилотные летательные аппараты).

Сохранение численности популяций оленей — одна из важных задач экологии и сельского хозяйства. Текущие способы учёта являются либо дорогими (использование чипов и ошейников), либо имеют невысокую точность (человеческий фактор при ручном счёте).

Для подсчёта численности популяции оленей требуется применять современные технологии свёрточных нейронных сетей, которые хорошо зарекомендовали себя в различных сферах человеческой деятельности.

В [2–4] они показали высокую эффективность к задачам стегоанализа графических изображений. Показано, что глубокая свёрточная нейронная сеть может быть обучена для классификации наличия скрытых данных в графических изображениях, достигая точности 0,928 в соответствии с взвешенной метрикой AUC.

В [5] проведены научные исследования по классификации заболеваний маниока методами компьютерного зрения на основе свёрточных нейронных сетей. С использованием сети ResNet 50 происходило обучение нейронной сети, которая позволила с точностью 0,93

по метрике F1-score классифицировать заболевания у растения маниок съедобный по графическим изображениям.

В [6–8] проведены научные изыскания по классификации внекорневых заболеваний яблоневых культур методами компьютерного зрения на основе свёрточных нейронных сетей. Нейронная сеть EfficientNet позволила с точностью 0,9842 по метрике F1-score обнаруживать некорневые заболевания яблони по изображению листьев.

В [9–10] нейронные сети и компьютерное зрение применялись для определения концентрации пропанта для гидроразрыва пласта. В указанных источниках описан опыт применения технологий компьютерного зрения для определения размера фракции расклинивающего агента по фотографии со смартфона. Модель нейронной сети была обучена с помощью фреймворка PyTorch и библиотеки TorchVision и использовала предварительно обученную сеть MobileNet V2. Результаты исследования показали, что точность классификации на тестовой выборке по показателю F1-score была равна 0,95. Разработанная модель была рекомендована для применения в нефтяной промышленности для определения фракции расклинивающего агента по фотографии со смартфона.

В [11–14] использовалась технология нейронной сети для подсчёта количества колосьев пшеницы по фотографиям пшеничных полей. С помощью архитектуры EfficientDet произведено обучение нейронной сети, которая позволила обнаруживать количество колосьев пшеницы с точностью 0,88012 по показателям F1-score с пороговым значением 0,6 (совпадение прогнозируемых и фактических областей разметки) по графическим изображениям.

Авторы статьи используют современные подходы в проблеме подсчёта численности оленей методами машинного обучения и опираются на вышеописанные методы и подходы.

Цель представленной работы состоит в применении моделей свёрточной нейронной сети для распознавания особей оленей по их графическим изображениям.

Материалы и методы исследования. Для проведения научных исследований исходным материалом послужили изображения (фотографии) оленей с размеченными координатами особей оленей, опубликованные в открытом доступе. Методы исследования включали в себя системы искусственного интеллекта, аугментацию изображений, алгоритмы настройки гиперпараметров для обучения нейронной сети, критерии проверки качества разработанных моделей.

Результаты исследования. Открытый датасет представляет собой более 11336 изображений, которые были размечены на ограничивающие области. Координаты и размеры ограничивающей области в виде прямоугольников определяют область нахождения особи оленя на изображении, на котором может находиться несколько объектов (оленей). Изображения размером 512×512 пикселей представлены в формате JPG. К датасету прилагается файл в формате CSV с разметкой вершин ограничивающих областей для каждой особи. Для обучения использовался фреймворк PyTorch. В работе решается задача детекции объектов. Пример изображений из датасета представлен на рис. 1.

Для выполнения задачи детекции объектов в работе была использована концепция Faster R-CNN, представляющая собой архитектуру детекции объектов на изображении, описанную в [15].

В данном источнике разработан новый метод локализации объекта взамен RPN (Region Proposal Networks) — алгоритма, предлагающего несколько объектов, которые можно однозначно идентифицировать на конкретном изображении. Архитектура Faster R-CNN построена следующим образом [16–17].

На вход CNN (Convolutional Neural Network) подаётся графическое изображение. С помощью слоя RPN выбираются якоря и формируется карта признаков, по которой проходит скользящее окно. Якорь — это область, имеющая три разных соотношения сторон и размера. Центр скользящего окна связан с центром якорей. На основе метрики IoU



Рис. 1. Размеченные изображения оленей

Архитектура Fast R-CNN

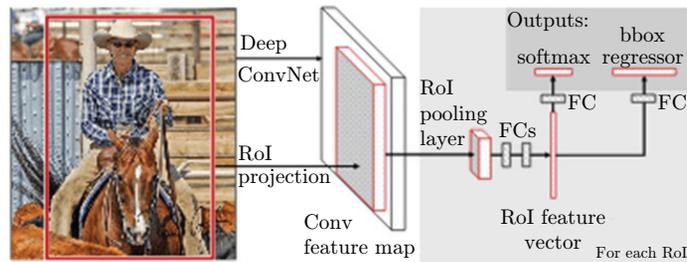


Рис. 2. Архитектура Faster R-CNN

(Intersection over Union), представляющей собой пересечение над объединением или измерение корреляции между реальным и прогнозируемым размещением (чем выше корреляция, тем выше значение [18]), принимается решение о текущем регионе — является он объектом или нет. Полученная карта признаков посредством алгоритма Faster R-CNN передаётся слою RoI (Region of Interest Pooling — объединение областей интереса, или максимальное объединение входных данных), который обрабатывает полносвязные слои и классифицирует, а также определяет смещение регионов. Архитектура Faster R-CNN представлена на рис. 2.

Была применена технология аугментации к открытому набору датасета для увеличения обучающей выборки. Изображения были отражены по нескольким осям и вращались на 90 град. Из некоторых изображений были извлечены фрагменты и добавлены как новые изображения (с сохранением размеров и разметки). Для части изображений изменена яркость и наложены блики. Аугментация позволила увеличить объём выборки в три раза.

Аугментация — это стандартный приём, который используется для обучения нейронных сетей. Он реализуется с применением библиотеки Albumentations, в которой имеется множество методов для изменения изображений. Пример использования аугментации представлен на рис. 3, на котором приведено исходное и изменённое изображения.

В работе используется предобученная модель Faster R-CNN, обученная на наборе данных COCO на базе нейронной сети ResNet 50, в свою очередь, предобученной на ImageNet.

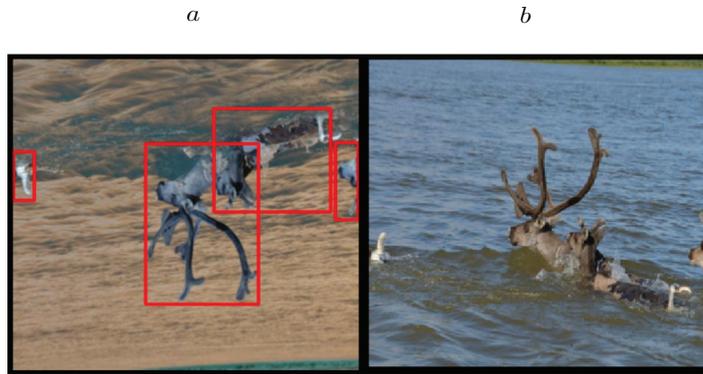


Рис. 3. Изображение с аугментацией (а), исходное изображение (b)

Классификация особей оленей по моделям

Модели	Точность классификации	
	Без аугментации	С аугментацией
DenseNet	0,781	0,909
CenterNet	0,802	0,902
Inception V3	0,766	0,895
Xception	0,797	0,89

Применяется оптимизатор SGD — стохастический градиентный спуск. Основные настройки спуска: шаг равен 0,005, коэффициент импульса — 0,9, а штраф для весов — 0,0005.

Эксперименты были связаны с разделением выборки на обучающую, которая включала 80 % элементов, и тестовую, включающую 20 % элементов. Точность обнаружения без аугментации в соответствии с показателем F1-score с пороговым значением 0,6 на обучающей выборке составила 0,82, а на тестовой выборке — 0,767. Точность обнаружения с аугментацией в соответствии с показателем F1-score с пороговым значением 0,6 на обучающей выборке составила 0,96, а на тестовой выборке — 0,91.

В результате обучения модели точность детекции на тестовой выборке с учётом аугментации по метрике F1-score с пороговым значением 0,6 (совпадения площади предсказанной разметки и фактической) составила 0,91.

Таким образом, точность определения количества особей оленей существенно повышается, если использовать процесс аугментации.

Далее для обнаружения особей оленей использовались другие модели нейронных сетей, а именно DenseNet, CenterNet, Inception V3, Xception. В таблице представлена точность обнаружения (детекции) оленей, достигнутая при применении различных моделей с аугментацией и без неё на тестовой выборке (20 %) по метрике F1-score с пороговым значением 0,6.

Из пяти представленных моделей наилучший результат показала модель Faster R-CNN на базе нейронной сети ResNet 50 с точностью классификации 0,91 с аугментацией на тестовой выборке. Близкий результат показала нейронная сеть DenseNet с точностью классификации 0,909 с аугментацией на тестовой выборке. Остальные три модели показали хорошие результаты, но несколько худшие, чем две предыдущие.

Заключение. Сохранение численности популяций оленей — одна из важных задач экологии и сельского хозяйства. Обученная нейронная сеть способна с большой точностью определять количество особей оленей, что может играть ключевую роль для решения задачи контроля популяции.

Широкое распространение смартфонов и дронов (не говоря об авиаспособе съёмки) привело к тому, что проблем со сбором данных нет, но есть проблема их обработки. Поэтому использование технологий нейронной сети для обработки собираемого массива изображений может значительно повысить эффективность учёта численности популяций оленей.

Представленная модель на основе свёрточной нейронной сети рекомендуется к практическому применению для учёта численности популяций оленей в отраслях сельского хозяйства и экологии.

В работе предложено альтернативное решение задачи оценки численности популяции оленей, основанное на использовании свёрточной нейронной сети для автоматического расчёта количества особей оленей на изображениях. Анализ открытых данных показал, что обученная соответствующим образом нейронная сеть может производить подсчёт количества особей с точностью 0,91.

СПИСОК ЛИТЕРАТУРЫ

1. Колпациков Л. А., Бондарь М. Г., Михайлов В. В. Современная история таймырской популяции дикого северного оленя: Динамика, управление, угрозы и пути сохранения // Тр. КарНЦ РАН. Сер. Экологические исследования. 2019. № 11. С. 5–20. DOI: 10.17076/eco1045.
2. Терещенко С. Н., Перов А. А., Осипов А. Л. Особенности применения предобученных свёрточных нейронных сетей к задачам стегоанализа графических изображений // Автометрия. 2021. 57, № 4. С. 98–105. DOI: 10.15372/AUT20210412.
3. Перов А. А., Пестунов А. И. О возможности применения свёрточных нейронных сетей к построению универсальных атак на итеративные блочные шифры // Прикладная дискретная математика. 2020. № 49. С. 46–56.
4. Полуниин А. А., Яндашевская Э. А. Использование аппарата свёрточных нейронных сетей для стегоанализа цифровых изображений // Тр. ИСП РАН. 2020. 32, № 4. С. 155–164.
5. Терещенко С. Н., Перов А. А., Осипов А. Л. Определение заболеваний маниока методами компьютерного зрения // Siberian Journ. Life Sci. and Agriculture. 2021. 13, № 1. С. 144–155. DOI: 10.12731/2658-6649-2021-13-1-144-155.
6. Терещенко С. Н., Перов А. А., Осипов А. Л. Классификация внекорневых заболеваний яблоневых культур методами компьютерного зрения // Siberian Journ. Life Sci. and Agriculture. 2021. 13, № 3. С. 103–118. DOI: 10.12731/2658-6649-2021-13-3-103-118.
7. Liu B., Zhang Y., He D., Li Y. Identification of apple leaf diseases based on deep convolutional neural networks // Symmetry. 2017. 10, Iss. 1. 11. DOI: 10.3390/sym10010011.
8. Sladojevic S., Arsenovic M., Anderla A., Culibrk D. Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification // Computational Intell. and Neurosci. 2016. 3289801. DOI: 10.1155/2016/3289801.
9. Tereshchenko S. N., Moiseeva E. D. Computer vision for determining the fraction of proppant for hydraulic fracturing // Proc. of the Int. Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM). Sochi, Russia, 17–21 May, 2021. P. 742–746. DOI: 10.1109/ICIEAM51226.2021.9446381.
10. Шляпкин А. С., Татосов А. В. Оценка геометрических параметров трещины гидравлического разрыва пласта при выполнении экспресс-расчета на гибридной модели // Геология, геофизика и разработка нефтяных и газовых месторождений. 2021. 10, № 358. С. 63–67.
11. Терещенко С. Н., Осипов А. Л., Моисеева Е. Д. Определение количества колосьев на изображениях пшеничных полей методами компьютерного зрения // Автометрия. 2022. 58, № 3. С. 72–78. DOI: 10.15372/AUT20220308.

12. **Бисчоков Р. М.** Анализ, моделирование и прогноз урожайности сельскохозяйственных культур средствами искусственных нейронных сетей // Вестн. РУДН. Сер. Агрономия и животноводство. 2022. **17**, № 2. С. 146–157. DOI: 10.22363/2312-797X-2022-17-2-146-157.
13. **Бисчоков Р. М.** Анализ, моделирование и прогноз урожайности сельскохозяйственных культур для Кабардино-Балкарской Республики с использованием аппарата нечёткой логики // Вестн. РУДН. Сер. Агрономия и животноводство. 2020. **15**, № 2. С. 123–133. DOI: 10.22363/2312-797X-2020-15-2-123-133.
14. **Ариничева И. В., Ариничев И. В., Волкова Г. В., Полянских С. В.** Диагностика ржавчин и пятнистостей пшеницы с помощью методов компьютерного зрения // Siberian Journ. Life Sci. and Agriculture. 2022. **14**, № 1. С. 248–261. DOI: 10.12731/2658-6649-2022-14-1-248-261.
15. **Faster RCNN** Object detection. Towards Data Science. URL: <https://towardsdatascience.com/faster-rcnn-object-detection-f865e5ed7fc4> (дата обращения: 22.03.2022).
16. **Region Proposal Network (RPN)** — Backbone of Faster R-CNN. Medium. URL: <https://medium.com/egen/region-proposal-network-rpn-backbone-of-faster-r-cnn-4a744a38d7f9> (дата обращения: 22.03.2022).
17. **Rahman C. R., Arko P. S., Ali M. E. et al.** Identification and Recognition of Rice Diseases and Pests Using Convolutional Neural Networks // Biosyst. Eng. 2020. **194**. P. 112–120. DOI: 10.1016/j.biosystemseng.2020.03.020.
18. **Понимание** концепций IU и IoU (Intersection over Union) в глубоком обучении и реализации программ на Python. Русские Блоги. URL: <https://russianblogs.com/article/4211133576/> (дата обращения: 22.03.2022).

Поступила в редакцию 30.07.2023

После доработки 18.08.2023

Принята к публикации 24.08.2023
