

ОБЗОР ПРИМЕНЕНИЯ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ К ЗАДАЧЕ КЛАССИФИКАЦИИ ПЫЛЬЦЕВЫХ ЗЕРЕН

© 2022 Ю. Б. Камалова 

*Финансовый университет при Правительстве РФ,
4-й Вешняковский пр-д, 4, 109456 Москва, Российская Федерация*

Аннотация. В статье приводится аналитический обзор мирового опыта применения алгоритмов машинного обучения к задаче классификации пыльцевых зёрен, за последние несколько лет. Кратко описаны, какие характеристики используются для моделей машинного обучения относительно данной задачи. Введено понятие «Вычислительно мотивированной биологии» — области, в которой изучается биология для моделирования биологических систем с использованием компьютерных наук. Для этого исследователи анализируют поведение биологической системы, а затем создают задачи в качестве искусственной модели, чтобы облегчить задачу людям.

В настоящее время автоматическая классификация для идентификации пыльцы становится очень активной областью исследований. В статье обоснована задача автоматизации классификации пыльцевых зёрен. В работе в основном проанализированы последние исследования по применению нейронных сетей различных конфигураций для классификации пыльцевых зёрен (LeNet, AlexNet, DenseNet, DenseNet-201, ResNet-50). Проанализированы методы на основе сверточных нейронных сетей (CNN) для идентификации пыльцы на предметных стеклах микроскопа, которые дали многообещающие результаты даже при наличии грибковых спор, пузырьков, мусора и пыли. Приведены сверточные нейронные сети, которые обрабатывали сигналы рассеяния и флюорисценции от пыльцевых зёрен. Флюорисцентный спектр обрабатывался с помощью многослойного перцептрона. Рассмотрен метод автоматизированной кластеризации пыльцевых зёрен, который дал многообещающие результаты. Произведен сравнительный анализ существующих на сегодняшний день баз данных пыльцевых зёрен (Duller's Pollen Dataset, Pollen 23E, Pollen73S, Pollen 13K). Приведены и проанализированы результаты конкурса по автоматизации процесса классификации пыльцевых зёрен Pollen Grain Classification Challenge.

Ключевые слова: машинное обучение, сверточные нейронные сети, задачи распознавания пыльцевых зёрен, пыльцевые зёрна, классификация.

ВВЕДЕНИЕ

Недавние достижения в области методов машинного обучения, основанных на глубоких нейронных сетях, привели к впечатляющим результатам в решении множества за-

дач, таких как распознавание лиц, обнаружение объектов на фотографиях, медицинская диагностика и многие другие.

В настоящее время подходы машинного обучения широко используются в приложениях для классификации объектов, обеспечивая высокоточные результаты для крупномасштабных наборов данных с несколькими классами [1].

 Камалова Юлия Борисовна
e-mail: YBKamalova@fa.ru



Контент доступен под лицензией Creative Commons Attribution 4.0 License.
The content is available under Creative Commons Attribution 4.0 License.

Технологии машинного обучения разрабатываются и применяются для решения задач распознавания микроскопических изображений различных биологических объектов, в том числе, пыльцевых зерен.

Классификация видов и типов пыльцы является важной задачей во многих областях, таких как судебная палинология, археологическая палинология и мелиссопалинология [2].

Важно отметить, что автоматизация классификации пыльцевых зерен окажет большое влияние на разработку недорогих инструментов для аэробиологов.

Пчеловодство — это искусство выращивания пчел с целью добиться от этой отрасли максимальной производительности при минимальных затратах. Продаваемые продукты пчеловодства — это мед, воск, пыльца, прополис и маточное молочко. Эта деятельность способствует развитию животноводства и защите окружающей среды.

ПОСТАНОВКА ЗАДАЧИ

Задача распознавания пыльцевых зерен актуальна в настоящее время в виду отсутствия всеобщей международной базы данных пыльцевых зерен, которая могла бы пополняться. Также, данная задача представляет научный интерес в связи с развитием способов и технологий компьютерного распознавания, разработок новых видов нейронных сетей.

Пыльцевой анализ меда используется для дифференциации цветочного источника, используемого пчелами, периода сбора урожая и геоклиматических условий соответствующих регионов, палеоклиматической реконструкции [3].

Помимо этого, необходимость автоматизации классификации изображений зерен пыльцы обусловлена тем, что пыльцевой анализ мёда должен производиться по ГОСТ 31769-2012 «Мед. Метод определения частоты встречаемости пыльцевых зерен» [4], согласно которому количество пыльцевых зерен в различных видах медов регламентировано.

Данное количество пыльцевых зерен определяется в палинологической лаборатории оператором вручную. И для экономии

времени и энергии, для большей эффективности процесса классификации, необходима его автоматизация.

В таких системах довольно сложно интерпретировать принятые решения, в отличие от математических моделей и экспертных систем, они более просты в реализации и практически не имеют ограничений при увеличении сложности моделирования.

Оптический анализ изображений объектов активно изучается в современности (например, анализ структуры металла [5]).

Цель работы — информационно-теоретический обзор современных исследований в области распознавания микроскопических изображений зёрен пыльцы.

МЕТОДЫ ИССЛЕДОВАНИЯ

В 2019 году коллектив ученых из Швеции, Финляндии и др. стран [6] исследовал автоматическое распознавание пыльцы с помощью спектров рассеяния и флуоресценции, которые обрабатывались независимо при помощи искусственных нейронных сетей.

Метод рассеяния применялся для определения морфологии частиц (их формы и размера), метод флуоресценции применялся для анализа их спектра. Было выявлено, что сигналы рассеяния и флуоресценции зависят от положения пыльцевого зерна относительно лазерного луча при прохождении через него.

Было создано несколько искусственных нейронных сетей. Метод оказался перспективным, но требующим доработки (рис. 1).

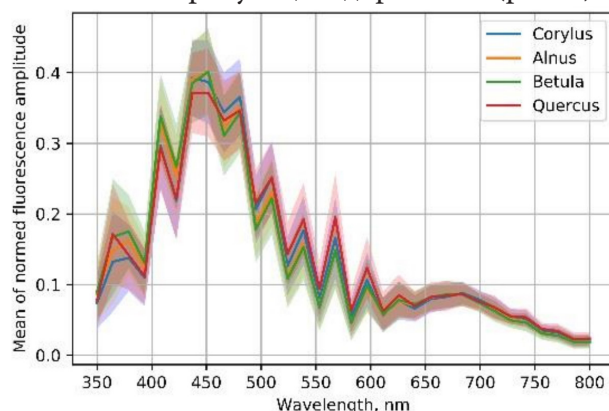


Рис. 1. Группы пыльцевых зерен с схожим флуоресцентным спектром
[Fig. 1. Groups of pollen grains with a similar fluorescent spectrum]

Исследователи [7] предложили систему, сочетающую распознавание и группировку пыльцы, основанную на использовании дерева логистической модели для классификации известной пыльцы и идентификации неизвестных видов с использованием кластерного подхода. Алгоритм содержал следующие шаги:

- 1) Выделение признаков методом локальных бинарных шаблонов (анализ текстуры изображения)
- 2) Применение логистического дерева решений
- 3) Выделение признаков с помощью метода модели набора визуальных слов
- 4) Кластеризация
- 5) Корректировка работы алгоритма человеком
- 6) Добавление новых образцов пыльцевых зерен и обучение классификатора (рис. 2).

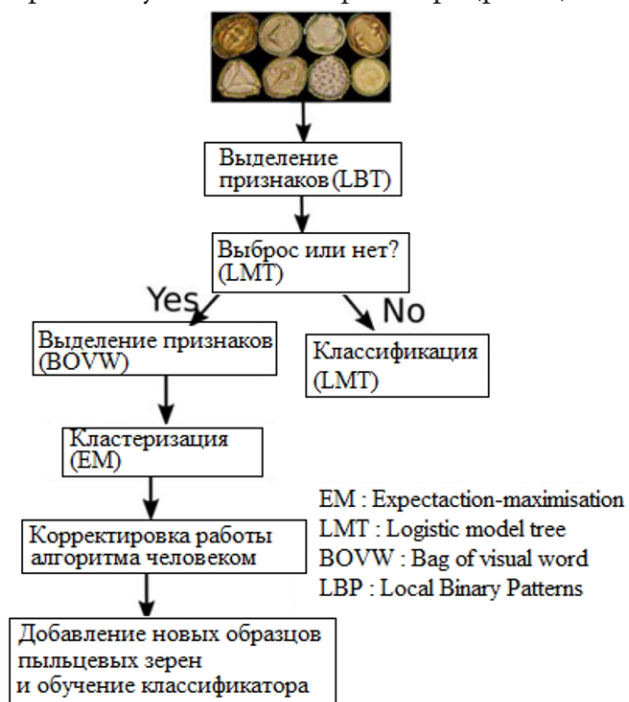


Рис. 2. Схема системы
 [Fig. 2. System Diagram]

Были достигнуты успехи в распознавании известных видов пыльцы, и автоматизированная кластеризация оказалась многообещающим подходом.

В другой статье представлено применение сверточной нейронной сети для классификации пыльцевых зерен [8]. Авторы применяли нейронную сеть из 8 скрытых слоев, где пер-

вые 5 — это сверточные нейроны, отвечающие за представление изображений, а следующие 3 — полносвязные слои для классификации изображений.

Полученные результаты подтвердили эффективность предложенного подхода к распознаванию пыльцевых зерен. Примечательно, что в данном исследовании авторы ввели такой термин, как «Вычислительно мотивированная биология» («Computationally Motivated Biology») [9].

Авторы применяли метод Deep Convolutional Activation Feature for Generic Visual Recognition (DECAF) [10], в котором реализована адаптация подхода на основе глубоких сверточных нейронных сетей для реализации только на CPU, а не на GPU.

Подход был разделен на две части. Первая часть включала извлечение признаков из изображений с использованием сверточных вычислений нелинейности ReLU, уменьшение размерности с использованием метода объединения, в результате чего образовался вектор из 2048 элементов для представления каждого изображения.

Вторая часть представляла собой 3 полносвязных слоя для классификации изображений.

Использовалась выборка Pollen23E, состоящая из 805 изображений, разделенных на 23 вида (класса). Каждый класс состоит из 35 изображений, снятых цифровым стереоскопическим микроскопом Bresser с 40-кратным увеличением под разными углами. Затем полученные изображения переносились на ноутбук и сегментировались с помощью программы CorelDRAW1.

В данном исследовании модель при 100 итерациях распознала 76,6 % тестовых изображений, а когда увеличили количество итераций до 200, было верно идентифицировано 85,1 % пыльцевых зерен (рис. 3).

Авторы исследования [11] сделали обзор методов глубокого обучения, примененных к выборке POLLEN23E (рис. 4).

Результаты показали высокую эффективность, особенно когда они использовали гибридный подход, сочетающий трансферное обучение и извлечение признаков.




Рис. 3. Исследование точности в соответствии с числом итераций
 [Fig. 3. Examination of accuracy in accordance with the number of iterations]

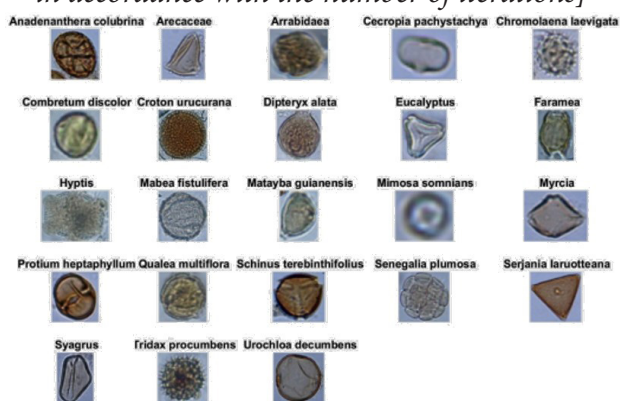


Рис. 4 Пример изображения для каждого типа пыльцы
 [Fig. 4. Example image for each type of pollen]

Полученные результаты в [9] в целом оказались лучше, чем результаты в работе [11], в которой проблема заключалась в том, что при применении множества фильтров либо для извлечения признаков, либо для классификации привело к потере большого количества информации во время этих процессов.

В рассматриваемой работе авторы использовали только технику объединения для уменьшения размерности, следовательно, минимизировали потерю информации.

Группа исследователей [12] презентовала базу данных пыльцевых зерен Бразильской Саванны POLLEN73S [13] из 2523 изображений 73 типов пыльцы. В качестве основы для автоматизации процесса классификации пыльцевых зерен они применили сверточные нейронные сети (CNN).

Эксперименты показали, что DenseNet-201 и ResNet-50 имеют более высокую производительность по сравнению с другими CNN, достигнув точности 95,7 % и 94,0 % соответственно.

Благодаря многочисленности экземпляров и наличию классификации по видовой принадлежности, POLLEN73S содержит разнообразие пыльцевых зерен, которое будет способствовать прогрессу в области компьютерного зрения для решения палинологических задач.

Сотрудники факультета информационных технологий и программирования Петербургского национального исследовательского университета информационных технологий, механики и оптики, и Пермского государственного национального исследовательского университета в своей статье провели исследования в области автоматического классификации зёрен пыльцы с использованием сверточной нейронной сети и предобработки в виде бинаризации и сегментации с использованием детектора Канни [14].

Важно отметить, что в 2020 году произошел Pollen Grain Classification Challenge [15,16], для которого была разработана база данных пыльцевых зерен Pollen 13K примерно с 13 тысячами изображений пыльцевых зерен в пяти различных категориях из аэробιологических образцов [17].

Помимо этой базы данных пыльцевых зерен, на сегодняшний день существует еще три общедоступные базы данных изображений пыльцевых зерен — Duller's Pollen Dataset [18], POLEN23E [19] и Pollen73S [20].

Первая содержит в общей сложности 630 изображений в градациях серого размером 25×25. Вторая включает 805 цветных изображений 23 видов пыльцы, по 35 изображений каждого вида. Последняя состоит из 2 523 изображений 73 типов пыльцы.

Наиболее точные результаты классификации изображений пыльцевых зерен были получены исследователями Бейханского университета (Пекин, Китай) и Университета Буффало (США), которые предложили подход, основанный на двух разных методах.

Первый метод использовал нейронную архитектуру DenseNAS с плотно связанным пространством поиска [21], представленным в виде суперсети.

Суперсеть состоит из плотно связанных блоков маршрутизации, которые выбирались

на этапе поиска, чтобы найти наилучший путь между ними и получить окончательную архитектуру.

Второй метод реализовал архитектуру обучения [22], которая сочетала в себе неглубокий классификатор сверточной нейронной сети (CNN) с сетью, совместно обученной классифицировать расширенный набор данных, который включал примеры обучающих данных, полученных путем перестановки локальных областей исходных изображений (т. е. механизма смещения областей).

Стратегия смешивания состояла из объединения выходных векторов DCL и DenseNAT, которые использовались в качестве входных данных классификатора случайного леса, который выполнял окончательную классификацию.

Авторы выполнили тесты перекрестной проверки с использованием набора поездов, достигнув точности 98,35 %. Предложенный метод получил оценку точности 97,53 % при оценке набора контрольных тестов. Это показало высокую обобщающую способность такого подхода.

Таким образом, несколько методик на основе глубоких нейронных сетей для классификации пыльцевых зерен рассматриваемой крупномасштабной эталонной базы данных были оценены и сравнены.

Было показано, что CNN достигают показателей классификации выше 90 %, где трансферное обучение использовалось как для извлечения признаков, так и для классификации.

В [23] AlexNet использовался для передачи обучения и извлечения признаков, а классификация выполнялась с помощью линейного дискриминационного анализа. Этот подход достиг среднего балла 0,967 по классификации пыльцевых зерен, содержащихся в выборке POLEN23E [24].

В другом исследовании распознавания с помощью LeNet применялась частная база данных из 1900 изображений пыльцы четырех таксонов растений, оценка составила 92,8 % [25].

Недавно различные CNN были протестированы для классификации набора дан-

ных Pollen73S, достигнув оценки 96,4 % с DenseNet-201 [26].

В ходе этого конкурса претенденты должны были разработать классификатор, способный идентифицировать отдельные экземпляры в сложных условиях, с учетом того, что, например, пыльца фундука и ольхи имеет сходные средние размеры и структуру. Кроме того, пыльца ольхи была представлена на изображениях слишком часто, что затрудняло правильную классификацию пыльцы лесного ореха даже для опытных операторов.

Таким образом, результаты, полученные лучшими участниками, были более точными, чем то, что было обнаружено в недавних исследованиях.

Кроме того, прошлые исследования никогда не включали мусор, например, пузырьки, образующиеся во время подготовки предметных стекол микроскопа, и абиотические твердые частицы, как часть проблемы классификации.

Это имеет особое значение для аэриобиологических проб, где обилие мусора может помешать правильной идентификации пыльцы.

Недавно были использованы методы на основе CNN для идентификации пыльцы на предметных стеклах микроскопа, показавшие многообещающие результаты даже при наличии грибковых спор, пузырьков, мусора и пыли [27].

В работе [28] для оценки эффективности при обнаружении пыльцевых зерен были применены подходы «two-stage» (Faster R-CNN с функциональной пирамидальной сетью (FPN) и «one-stage» детектор (RetinaNet).

Наивысшая скорость отклика была достигнута в конфигурации A RetinaNet, которая, помимо рассмотрения зерен с определенным краем, включала зерна с размытыми краями.

Однако, с другой стороны, у данного метода была самая низкая точность и высокое время вывода.

После того, как сети были обучены, было проведено распознавание изображений, входящих в тестовую выборку.

Общее время вывода для 2863 изображений в тестовом наборе составило 166,7 с для

Faster R-CNN Type A и 169,8 с для сети B той же архитектуры. Следовательно, скорость обработки на графическом процессоре составила менее 59 мс на изображение.

Таким образом, обработка 21 кадра каждого образца требовала менее 1,24 с в графическом процессоре.

Выполняя тот же анализ вариантов RetinaNet, авторы наблюдали увеличение среднего времени вывода по сравнению с тестовым набором.

Для RetinaNet типа A среднее время вывода составляло 98 мс на изображение, а для RetinaNet типа B — 103 мс, в результате чего минимальное время анализа для каждого образца составило чуть более двух секунд.

В этом исследовании общее количество пыльцевых зерен, которые должны быть обнаружены в 135 образцах (видео) тестового набора, составило 1234.

Реализации RetinaNet обеспечивала лучшую настройку положения и размера зерна.

Хотя в некоторых работах рассматривались локализация и оценка размера зерен, было невозможно провести сравнение с данными результатами, касающимися этих аспектов из-за отсутствия какой-либо метрики в этих работах.

Достоверная идентификация пыльцевых зерен в окрашенных образцах глицерина представляет собой сложную задачу.

В этой работе авторы подошли к применению двух самых последних методов искусственного интеллекта (Faster R-CNN с FPN и RetinaNet), получили многообещающие результаты с использованием недорогого оборудования как на этапе сбора образцов, так и на этапе вычислений.

Данная работа внесла важный вклад в определение местоположения пыльцевых зерен на реальных микроскопических изображениях. Прежде всего, авторы подтвердили возможность проведения успешного применения Faster R-CNN на основе FPN и RetinaNet с относительно небольшим количеством палинологических образцов.

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Типы рассмотренных подходов (статистические, нейросетевые, на основе кластеризации и т. д.) приведены в табл. 1, по каждому дана краткая характеристика и значения точности классификации/распознавания зерен пыльцы.

ЗАКЛЮЧЕНИЕ

Таким образом, на сегодняшний день существует пять основных баз данных пыльцевых зерен: Duller's содержит изображения 630 пыльцевых зерен, POLLEN23E содержит изображения 805 пыльцевых зерен, Ranzato et. al. содержит изображения 3686 пыльцевых зерен, Pollen73S содержит изображения 2523 пыльцевых зерен, Pollen13K содержит более 12 тысяч изображений пыльцевых зерен, включая примеры «помех», таких как пыль, пузырьки воздуха на подложках.

Самой перспективной для использования в целях обучения и тестирования нейронных сетей является Pollen13K.

На основе анализа просмотренных работ можно предложить методические рекомендации относительно наилучших на сегодняшний день методов для решения задачи классификации пыльцевых зерен: среди применяемых систем наибольшую актуальность имеют Многослойные Сверточные Нейронные сети (LeNet, ResNet, DenseNet). Однако модификация, цели и способы применения приложения данного инструмента могут отличаться от эксперимента к эксперименту.

Целью рассмотренных работ по распознаванию пыльцы является повышение точности классификации пыльцевых зерен.

Автоматизация анализа пыльцевых зерен зависит от создания выборок изображений, содержащих множество экземпляров разных видов, классифицированных экспертами. Эта задача требует больших усилий и должна выполняться в подходящих условиях с использованием специального оборудования, такого как оптический микроскоп и предметные стекла.

По этой причине несколько выборок изображений пыльцевых зерен создаются для

Таблица 1. Подходы к задаче классификации пыльцевых зёрен
 [Table 1. Approaches to the problem of classifying pollen grains]

	Метод	Автор	Подход	Количество зерен	Точность распознавания
1	Автоматическое распознавание пыльцы с помощью спектров рассеяния и флуоресценции	Ingrida Šaulien, LauraŠukien, Gintautas Daunys, Gediminas Valiulis, Lukas Vaitkevičius, Predrag Matavulj, Sanja Brdar, Marko Panic, Branko Sikoparija, Bernard Clot, Benoît Crouzy, Mikhail Sofiev	Нейросетевой (Rapid-E)	216 308	100 %
2	Использование обучение с учителем (дерева логистической модели) и без учителя	Endrick Barnacin, Jean-Luc Henry, Jack Molinié, Jimmy Nagau, Hélène Delatte, Gérard Lebreton	Кластерный	3761	97,21 % с учителем, 77,38 % без учителя.
3	Применение метода Deep Convolutional Activation Feature for Generic Visual Recognition (DECAF) в распознавании изображений зерен пыльцы	Hanane Menad, Farah Ben-naoum, Abdelmalek Amine	Нейросетевой (DECAF)	805	85,1 %
4	Повышение точности классификации изображений пыльцевых зерен датасета POLEN32 с помощью сверточных нейронных сетей.	Víctor Sevillano, Jose´ L. Aznarte	Нейросетевой	805	DenseNet-201 - 95,7 %, ResNet-50 - 94,0 %.
5	Применение сверточных нейронных сетей к распознаванию изображений зерен пыльцы	Natalia Khanzhina, Evgeny Putin, Andrey Filchenkov, Elena Zamyatina	Нейросетевой	2200	99,8%

автоматизации с использованием компьютерного зрения.

С другой стороны, существуют некоторые Палинотеки, представляющие собой постоянные базы данных предметных стекол ми-

кроскопии, содержащие изображения пыльцевых зерен или спор, которые вместе содержат сотни тысяч изображений пыльцевых зерен, однако для каждого типа пыльцевых зерен, как правило, существует не более деся-

ти примеров, что требует разработки крупномасштабной международной (межрегиональной) базы данных пыльцевых зерен.

КОНФЛИКТ ИНТЕРЕСОВ

Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

СПИСОК ЛИТЕРАТУРЫ

1. *Battiato S., Ortis A., Trenta F., Ascari L., Politi M., Siniscalco C.* Detection and classification of pollen grain microscope images. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. 2020. – P. 980–981.
2. *Шелехова Т. С., Слуковский З. И., Лаврова Н. Б.* Методы исследования донных отложений озер Карелии [монография] / Институт геологии КарНЦ РАН. – Петрозаводск : КарНЦ РАН, 2020. – 112 с.
3. *Чекрыга Г. П., Нициевская К. Н., Юдина О. Б.* Определение ботанического происхождения меда и бонитета медоносной растительности методом пыльцевого анализа. Известия высших учебных заведений. Пищевая технология. – 2021. – № 1(379). С. 94–97.
4. ГОСТ 31769-2012 «Мед. Метод определения частоты встречаемости пыльцевых зерен». Электронный фонд правовой и нормативно-технической документации [Электронный ресурс]. – Режим доступа: <https://docs.cntd.ru/document/1200100244>
5. *Белых В. В., Муравьев В. В., Степанов В. А.* Использование информационной энтропии структуры стали для определения качества и ресурса ее функциональных свойств. Вестник ИжГТУ имени М. Т. Калашникова. – 2020. – Т. 23, № 3. – С. 15–24.
6. *Ingrida Šaulien, Laura Šukien, Gintautas Daunys, Gediminas Valiulis, Lukas Vaitkevičius, Predrag Matavulj, Sanja Brdar, Marko Panic, Branko Sikoparija, Bernard Clot, Benoît Crouzy, Mikhail Sofiev.* Automatic pollen recognition with the Rapid-Eparticle counter: the first-level procedure, experience and next steps. Atmos. Meas. Tech. – 2019. – 12. – P. 3435–3452.
7. *Endrick Barnacin, Jean-Luc Henry, Jack Molinié, Jimmy Nagau, Hélène Delatte, Gérard Lebretton.* Logistic Model Tree and Expectation-Maximization for Pollen Recognition and Grouping. World Academy of Science, Engineering and Technology International Journal of Computer and Information Engineering. 2020. – Vol 14, No 2. P. 46–49.
8. *Hanane Menad, Farah Ben-naoum, Abdelmalek Amine.* Deep Convolutional Neural Network for Pollen Grains Classification. JERI 2019. The National Study Day on Research on Computer Sciences. 3rd edition of the National Study Day on Research on Computer Sciences (JERI 2019). Saida, Algeria, April 27. – 2019. – P. 31–41.
9. *Orobia A. G., Mali A.* Biologically Motivated Algorithms for Propagating Local Target Representations. Proceedings of the AAI Conference on Artificial Intelligence. 2019. – 33(01). – P. 4651–4658. <https://doi.org/10.1609/aaai.v33i01.33014651>
10. *Guoqiang Zhong, Shoujun Yan, Kaizhu Huang, Yajuan Cai, Junyu Dong.* Reducing and Stretching Deep Convolutional Activation Features for Accurate Image Classification. Cognitive Computation. – 2018. – V. 10. – P. 179–186.
11. *Sevillano V., Aznarte J. L.* Improving classification of pollen grain images of the POLLEN23E dataset through three different applications of deep learning convolutional neural networks. PloS one. – 2018. – 13(9). – e0201807.
12. *Astolfi, Gilberto, Gonçálves, Ariadne Barbosa, Menezes, Geazy Vilharva, Borges, Felipe Silveira Brito, Astolfi, Angelica Christina Melo Nunes, Matsubara, Edson Takashi, Alvarez, Marco, Pistori, Hemer.* POLLEN73S: An image dataset for pollen grains classification. 2020. – 11. – Vol. 60. – P. 1574–9541.
13. Pollen 73S. – URL: <https://figshare.com/articles/dataset/POLLEN73S/12536573> (дата обращения 12.05.2021)
14. *Khanzhina Natalia, Putin Evgeny, Andrey Filchenkov and Elena Zamyatina.* Pollen Grain Recognition Using Convolutional Neural Network. ESANN 2018 proceedings, European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning. Bruges (Belgium), 25–27 April 2018, i6doc.com publ. – P. 409–414.

15. Pollen classification challenge. – URL: <https://iplab.dmi.unict.it/pollenclassification-challenge/> (дата обращения 23.05.2021)
16. *Sebastiano Battiato, Francesco Guarnera, Alessandro Ortis(B), Francesca Trenta, Lorenzo Ascari, Consolata Siniscalco, Tommaso De Gregorio, Eloy Su'arez*. Pollen Grain Classification Challenge 2020 (Challenge Report). Springer Nature Switzerland AG 2021. A. Del Bimbo et al. (Eds.): ICPR 2020 Workshops, LNCS 12668. – 2021. – P. 469–479.
17. *Battiato S., Ortis A., Trenta F., Ascari L., Politi M., Siniscalco C.* Pollen13k: a large scale microscope pollen grain image dataset. In: IEEE International Conference on Image Processing (ICIP). 2020. – P. 2456–2460. IEEE
18. *Sevillano V., Aznarte J. L.* Improving classification of pollen grain images of the POLEN23E dataset through three different applications of deep learning convolutional neural networks. PLoS ONE 2018. – 13. P. 1–18. <https://doi.org/10.5194/essd-12-119-2020>
19. Pollen23E. – URL: <https://figshare.com/articles/dataset/POLEN23E/1525086> (дата обращения is 25.05.2021)
20. *Astolfi G. [et al.]* POLLEN73S: an image dataset for pollen grains classification. Ecol. Inf. 60, 101165 (2020). <https://doi.org/10.1016/j.ecoinf.2020.101165>
21. *Fang J., Sun Y., Zhang Q., Li Y., Liu W., Wang X.* Densely connected search space for more flexible neural architecture search. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. – 2020. – P. 10628–10637.
22. *Chen Y., Bai Y., Zhang W., Mei T.* Destruction and construction learning for fine-grained image recognition. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2019. – P. 5157–5166.
23. *Sevillano V., Aznarte J. L.* Improving classification of pollen grain images of the POLEN23E dataset through three different applications of deep learning convolutional neural networks. PLoS ONE 13(9), 1–18 (2018). <https://doi.org/10.1371/journal.pone.0201807>
24. *Korobeynikov A., Kamalova Y., Palabugin M., Basov I.* The use of convolutional neural network LeNet for pollen grains classification. In: “Instrumentation Engineering, Electronics and Telecommunications” Proceedings of the IV International Forum, Izhevsk, Russia. 2018. – P. 38–44. <https://doi.org/10.22213/26583658-2018-38-44>
25. *Gallardo-Caballero R., Garc'ia-Orellana C. J., Garc'ia-Manso A., Gonz'alezVelasco H. M., Tormo-Molina R., Mac'ias-Mac'ias M.* Precise pollen grain detection in bright field microscopy using deep learning techniques. Sensors (Switzerland). 2019. – 19(16). P. 1–19. <https://doi.org/10.3390/s19163583>
26. *Ramón Gallardo-Caballero, Carlos J. García-Orellana, Antonio García-Manso, Horacio M. González-Velasco, Rafael Tormo-Molina, Miguel Macías-Macías.* Precise Pollen Grain Detection in Bright Field Microscopy Using Deep Learning Techniques. Sensors 2019. – 19. – 3583. [doi:10.3390/s19163583](https://doi.org/10.3390/s19163583)

Камалова Юлия Борисовна — старший преподаватель Департамента анализа данных и машинного обучения Факультета информационных технологий и анализа больших данных Финансового университета при Правительстве Российской Федерации.

E-mail: YBKamalova@fa.ru

ORCID iD: <https://orcid.org/0000-0003-0822-2161>

REVIEW OF THE APPLICATION OF MACHINE LEARNING ALGORITHMS TO THE PROBLEM OF CLASSIFICATION OF POLLEN GRAINS

© 2022 Yu. B. Kamalova✉

*Financial University under the Government of the Russian Federation
4, 4th Veshnyakovsky proezd, Moscow 109456, Russian Federation*

Annotation. The article provides an analytical review of recent world experience in the application of machine learning algorithms to the problem of pollen grain recognition. It briefly describes what characteristics are used to train machine learning models for a given task. The concept of «Computationally motivated biology» is introduced, a field in which biology is studied to model biological systems using computer science. To do this, researchers analyze the behavior of a biological system and then create tasks as an artificial model to make it easier for humans.

Currently, automatic classification for pollen identification is becoming a very active area of research. The article substantiates the task of automating the classification of pollen grains. The paper mainly analyzes the latest research on the use of neural networks of various configurations for the classification of pollen grains. The results of applying various neural networks to the problem of classifying pollen grains (LeNet, AlexNet, DenseNet, DenseNet-201, ResNet-50) are considered. CNN-based methods for identifying pollen on microscope slides were analyzed and showed promising results even in the presence of fungal spores, bubbles, debris, and dust. Convolutional neural networks are presented that processed scattering and fluorescence signals from pollen grains. The fluorescence spectrum was processed using a multilayer perceptron. The method of automated clustering of pollen grains is considered, which gave promising results. A comparative analysis of the currently existing databases of pollen grains (Duller's Pollen Dataset, Pollen 23E, Pollen73S, Pollen 13K) was carried out. The results of the competition to automate the process of classifying pollen grains Pollen Grain Classification Challenge are presented and analyzed.

Keywords: machine learning, convolutional neural networks, pollen grain recognition problems, pollen grains, classification.

CONFLICT OF INTEREST

The authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

REFERENCES

1. Battiato S., Ortis A., Trenta F., Ascari L., Politi M., Siniscalco C. (2020) Detection and classification of pollen grain microscope images. *In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. P. 980–981.
2. Shelekhova T. S., Slukovsky Z. I., Lavrova N. B. (2020) Methods for studying the bottom sediments of lakes in Karelia [monograph]. *Institute of Geology KarRC RAS*. Petrozavodsk : KarRC RAS. 112 p.

tute of Geology KarRC RAS. Petrozavodsk : KarRC RAS. 112 p.

3. Chekryga G. P., Nitsievskaya K. N., Yudin O. B. (2021) Determination of the botanical origin of honey and the quality of honey plants by pollen analysis. *News of higher educational institutions. Food technology*. No. 1 (379). P. 94–97.

4. GOST 31769-2012 «Med. Method for determining the frequency of occurrence of pollen grains». Electronic fund of legal and normative-technical documentation [Electronic resource]. Available at: <https://docs.cntd.ru/document/1200100244>

5. Belykh V. V., Murav'ev V. V., Stepanov V. A. (2020) Using Information Entropy steel structure to determine the quality and resource of its functional properties. *Herald IzhGTU named after M. T. Kalashnikov*. V. 23, No. 3. P. 15–24.

✉ Kamalova Yuliya B.
e-mail: YBKamalova@fa.ru

6. Ingrida Šaulien, LauraŠukien, Gintautas Daunys, Gediminas Valiulis, Lukas Vaitkevičius, Predrag Matavulj, Sanja Brdar, Marko Panic, Branko Sikoparija, Bernard Clot, Benoît Crouzy, Mikhail Sofiev. (2019) Automatic pollen recognition with the Rapid-Eparticle counter: the first-level procedure, experience and next steps. *Atmos. Meas. Tech.* 12. – P. 3435–3452.
7. Endrick Barnacin, Jean-Luc Henry, Jack Molinié, Jimmy Nagau, Hélène Delatte, Gérard Lebreton. (2020) Logistic Model Tree and Expectation-Maximization for Pollen Recognition and Grouping. *World Academy of Science, Engineering and Technology International Journal of Computer and Information Engineering*. Vol 14, No 2. P. 46–49.
8. Hanane Menad, Farah Ben-naoum, Abdelmalek Amine. (2019) Deep Convolutional Neural Network for Pollen Grains Classification. *JERI 2019. The National Study Day on Research on Computer Sciences. 3rd edition of the National Study Day on Research on Computer Sciences (JERI 2019)*. Saida, Algeria, April 27. P. 31–41.
9. Ororbia A. G., Mali A. (2019) Biologically Motivated Algorithms for Propagating Local Target Representations. *Proceedings of the AAAI Conference on Artificial Intelligence*. 33(01). P. 4651–4658. <https://doi.org/10.1609/aaai.v33i01.33014651>
10. Guoqiang Zhong, Shoujun Yan, Kaizhu Huang, Yajuan Cai, Junyu Dong. (2018) Reducing and Stretching Deep Convolutional Activation Features for Accurate Image Classification. *Cognitive Computation*. V. 10. P. 179–186.
11. Sevillano V., Aznarte J. L. (2018) Improving classification of pollen grain images of the POLEN23E dataset through three different applications of deep learning convolutional neural networks. *PloS one*. 13(9). e0201807.
12. Astolfi, Gilberto, Gonçsalves, Ariadne Barbosa, Menezes, Geazy Vilharva, Borges, Felipe Silveira Brito, Astolfi, Angelica Christina Melo Nunes, Matsubara, Edson Takashi, Alvarez, Marco, Pistori, Hemer. (2020) POLLEN73S: An image dataset for pollen grains classification. 11. Vol. 60. P. 1574–9541.
13. Pollen 73S. – URL: <https://figshare.com/articles/dataset/POLLEN73S/12536573> (дата обращения 12.05.2021)
14. Khanzhina Natalia, Putin Evgeny, Andrey Filchenkov and Elena Zamyatina. (2018) Pollen Grain Recognition Using Convolutional Neural Network. *ESANN 2018 proceedings, European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*. Bruges (Belgium), 25–27 April 2018, i6doc.com publ. P. 409–414.
15. Pollen classification challenge. – URL: <https://iplab.dmi.unict.it/pollenclassification-challenge/> (дата обращения 23.05.2021)
16. Sebastiano Battiato, Francesco Guarnera, Alessandro Ortis(B), Francesca Trenta, Lorenzo Ascari, Consolata Siniscalco, Tommaso De Gregorio, Eloy Suarez. (2021) Pollen Grain Classification Challenge 2020 (Challenge Report). *Springer Nature Switzerland AG 2021. A. Del Bimbo et al. (Eds.): ICPR 2020 Workshops, LNCS 12668*. P. 469–479.
17. Battiato S., Ortis A., Trenta F., Ascari L., Politi M., Siniscalco C. (2020) Pollen13k: a large scale microscope pollen grain image dataset. In: *IEEE International Conference on Image Processing (ICIP)*. P. 2456–2460. IEEE
18. Sevillano V., Aznarte J. L. (2018) Improving classification of pollen grain images of the POLEN23E dataset through three different applications of deep learning convolutional neural networks. *PLoS ONE* 2018. 13. P. 1–18. <https://doi.org/10.5194/essd-12-119-2020>
19. Pollen23E. – URL: <https://figshare.com/articles/dataset/POLEN23E/1525086> (дата обращения is 25.05.2021)
20. Astolfi G., et al. (2020) POLLEN73S: an image dataset for pollen grains classification. *Ecol. Inf.* 60, 101165. <https://doi.org/10.1016/j.ecoinf.2020.101165>
21. Fang J., Sun Y., Zhang Q., Li Y., Liu W., Wang X. (2020) Densely connected search space for more flexible neural architecture search. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. P. 10628–10637.
22. Chen Y., Bai Y., Zhang W., Mei T. (2019) Destruction and construction learning for fine-grained image recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. P. 5157–5166.
23. Sevillano V., Aznarte J. L. (2018) Improving classification of pollen grain images of the

POLEN23E dataset through three different applications of deep learning convolutional neural networks. *PLoS ONE* 13(9), P. 1–18. <https://doi.org/10.1371/journal.pone.0201807>

24. Korobeynikov A., Kamalova Y., Palabugin M., Basov I. (2018) The use of convolutional neural network LeNet for pollen grains classification. In: “Instrumentation Engineering, Electronics and Telecommunications” *Proceedings of the IV International Forum, Izhevsk, Russia*. P. 38–44. <https://doi.org/10.22213/26583658-2018-38-44>

25. Gallardo-Caballero R., García-Orellana C. J., García-Manso A., González-Velasco H. M., Tormo-Molina R., Macías-Macías M. (2019)

Precise pollen grain detection in bright field microscopy using deep learning techniques. *Sensors (Switzerland)*. 19(16). P. 1–19. <https://doi.org/10.3390/s19163583>

26. Ramón Gallardo-Caballero, Carlos J. García-Orellana, Antonio García-Manso, Horacio M. González-Velasco, Rafael Tormo-Molina, Miguel Macías-Macías. (2019) Precise Pollen Grain Detection in Bright Field Microscopy Using Deep Learning Techniques. *Sensors* 2019. 19. 3583. doi:10.3390/s19163583

Kamalova Yuliya B. — Senior Lecturer, Department of Data Analysis and Machine Learning, Faculty of Information Technology and Big Data Analysis, Financial University under the Government of the Russian Federation.

E-mail: YBKamalova@fa.ru

ORCID iD: <https://orcid.org/0000-0003-0822-2161>