

Нейросетевая модель для идентификации пыльцевых зёрен в микропрепарате мёда

М.А. Овчинникова, Д.Ю. Романюта, А.В. Коваленко

Кубанский государственный университет, Краснодар

Аннотация: В данной работе рассматривается разработка и обучение нейросетевой модели для идентификации видового и количественного состава пыльцы, которая впоследствии будет использоваться для определения ботанического происхождения мёдов и количественных подсчётов зёрен пыльцы, содержащихся в определённой массе мёда. Основной целью исследования является создание модели, способной эффективно различать морфологию пыльцевых зёрен, присутствующих в мёде, определять их количественный и качественный состав, что позволит улучшить контроль качества продукта, а также выявлять его ботаническое и географическое происхождение. Для этого были проанализированы похожие работы по классификации пыльцы. В качестве фреймворка для создания нейросетевой модели был выбран Pytorch, обеспечивающий возможность детальной настройки модели. Результатом работы является обученная модель, способная классифицировать пыльцевые зерна.

Ключевые слова: Нейронные сети, задача классификации, классификации пыльцы, сверточные нейронные сети, PyTorch.

Введение

Пыльцевые зерна имеют различный размер, вид и строение. Зрелое пыльцевое зерно состоит из двух клеток - вегетативной и генеративной [1]. Эти клетки окружены тонкой стенкой из неизменной целлюлозы называемой интиной (внутренний слой), и жесткой - называемой экзиной (наружный слой). Экзина часто имеет углубления, шипы, бородавки, различные скульптуры и характер отметин – апертуры. Апертуры бывают простые (бороздки, щели, поры и т.д.) и сложные, у которых в строении присутствуют дополнительные апертуры – оры. Строение апертур, их число и расположение на поверхности пыльцевого зерна является важнейшими признаками для идентификации рода, вида, сорта пыльцы, а также для создания и обучения нейросетевой модели.

В работе представлены этапы сбора и подготовки данных, архитектура используемой нейросети, методология обучения и тестирования модели, а также результаты экспериментов.

Идентификация пыльцы является важной задачей в области пчеловодства и производства мёда, так как позволяет определить ботаническое и географическое происхождение продукта, а также его подлинность и качество. Традиционные методы анализа пыльцы требуют значительных временных и трудовых затрат, а также участия высококвалифицированных специалистов. В связи с этим актуальность применения методов машинного обучения, в частности нейросетевых моделей, значительно возрастает.

Задача распознавания пыльцевых зерен актуальна в настоящее время ввиду отсутствия всеобщей международной базы данных пыльцевых зерен, которая могла бы в дальнейшем 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 (пыльцы), используемого пчелами, с целью определения ботанического происхождения меда.

На сегодняшний день пыльцевой анализ мёда проводится в соответствии с ГОСТ 31769-2012 «Мед. Метод определения частоты встречаемости пыльцевых зерен». Количественный и видовой состав пыльцевых зерен определяется специалистом вручную под микроскопом, что является очень трудоемкой и ресурсно-затратной задачей. Просмотр и подсчет пыльцевых зерен под микроскопом проводят при увеличении 100х. Идентифицируют пыльцевые зерна под микроскопом при увеличении 400 и 600х.

При подсчете пыльцевых зерен под микроскопом с увеличением 100х счетное поле, попадающее в поле зрения оператора на панели, составляет 2 мм как по горизонтали, так и по вертикали. В объеме меда 100 мкл под покровным стеклом площадью 18x18 мм счетных полей 81 - 9 по

горизонтали и 9 по вертикали. (18 мм - длину покровного стекла надо разделить на 2 мм - поле зрения оператора, получается 9 счетных полей.). Всего специалист должен насчитать вручную минимум 500 и более пыльцевых зерен.

При идентификации пыльцевых зерен подсчитывают их количество в каждом счетном поле при увеличении 100х, затем 400х, а при необходимости и 600х. В настоящее время, благодаря возможностям нейронных сетей, можно значительно сократить работу оператора, если распознавание известных видов пыльцевых зерен на пробе будет проходить автоматически. Для начало можно идентифицировать 5 таксонов, установленных в ГОСТ 31766-2022 «Меды монофлорные. Технические условия»: липовый, подсолнечниковый, акациевый, гречишный, каштановый, а в дальнейшем расширить базу по медам России.

Данная программа была бы полезна для сотрудников ветеринарных лабораторий, научно-исследовательских институтов, университетов, палинологов.

Использование нейронных сетей для решения задачи классификации становится наиболее удобным выходом. Например, с помощью нейросетей была успешно решена задача классификации состояния объектов городской инфраструктуры [2]. Также их успешно использовали в сельском хозяйстве для сегментации проблемных участков на полях [3]. В последние годы задачу классификации пыльцы успешно решали для проблем, связанных с аллергенной пыльцой. Одной из первых работ по автоматизации распознавания пыльцы реализовали модель с помощью сверточных нейронных сетей [4]. В работе [5] осуществляется попытка построения сверточной нейронной сети для классификации пыльцы, которая будет использоваться в пчеловодстве. В работе [6] успешно обучили сверточную нейронную сеть для классификации вредной пыльцы, используя технологии

специальной стратегии обучения и детектор Rapid-E. В работе [7] также построили нейросетевой классификатор для пыльцы в рамках борьбы с аллергией.

Попытка создать базу данных, которую можно использовать для классификации аллергенной пыльцы была успешно предпринята в работе [8]. В ней была собрана база, насчитывающая более 10000 изображений. С помощью такого датасета была успешно обучена нейросетевая модель для классификации на базе модели ResNetSt-110.

Для создания нейросетевой модели классификации пыльцы использовался фреймворк Pytorch для языка программирования Python. PyTorch — это библиотека с открытым исходным кодом для машинного обучения на языке Python, разработанная на базе Torch [9]. Она широко используется для решения разнообразных задач, включая компьютерное зрение, обработку естественного языка и другие области искусственного интеллекта. Благодаря гибкости и удобству PyTorch, разработчики могут легко создавать и тренировать сложные модели. В данном случае, с использованием PyTorch была разработана и обучена модель, сохраненная в формате PTN, которая готова к интеграции и применению в реальном приложении для классификации пыльцевых зёрен. В данной работе была проведена попытка реализации собственной модели для классификации пыльцы с учетом собранного датасета.

В качестве датасета для обучения были собраны изображения пыльцы под микроскопом для следующих видов растений, которые участвуют в производстве меда: акация, гречиха, каштан, липа, подсолнечник (рис.1). Всего было собрано около 500 изображений по 100 на каждое растение.

Прежде чем обучать модель, необходимо применить некоторую предварительную обработку к обрезанным изображениям. Каждое изображение пыльцы встроено в центр черной фоновой рамки размером

128×128 пикселей. Набор данных преобразуется в dataloader и разбивается на три набора: обучающий набор, содержащий 80% всех выборок каждого класса и тестовый набор, содержащий оставшиеся 20%.

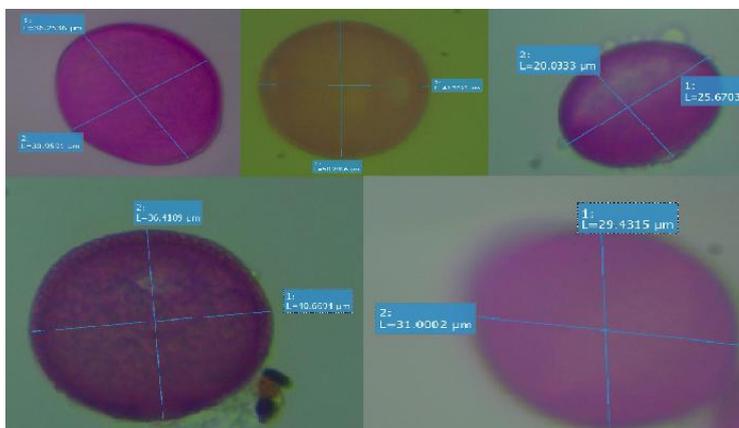


Рис. 1. – Примеры изображений пыльцы из датасета

Архитектура сверточной нейронной сети для классификации пыльцевых зёрен, показанная на рис. 2, включает в себя следующие элементы: входной слой, который принимает изображение размером 128x128, затем два сверточных слоя и два нормализующих слоя, используемых на этапе обучения модели. Далее идет один объединяющий слой, за которым следуют еще два сверточных и два нормализующих слоя. На этапе классификации применяются три полносвязных слоя для оптимизации оценки классов. Заключительный слой softmax отвечает за окончательную классификацию.

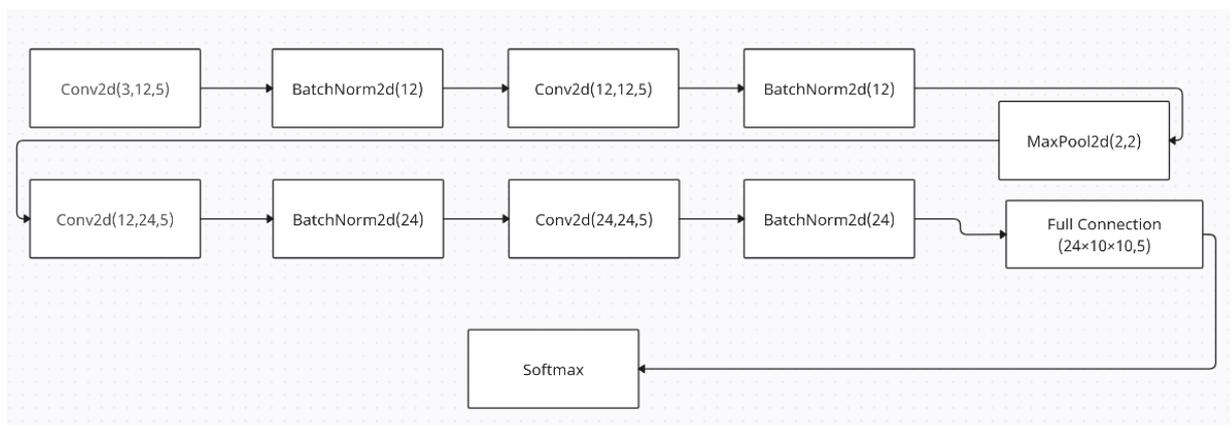


Рис. 2. – Архитектура сверточной нейронной сети для классификации

Прежде чем обучать модель, необходимо применить некоторую предварительную обработку к обрезанным изображениям. Каждое изображение пыльцы встроено в центр черной фоновой рамки размером 128×128 пикселей. Набор данных преобразуется в `dataloader` и разбивается на три набора: обучающий набор, содержащий 80 % всех выборок каждого класса и тестовый набор, содержащий оставшиеся 20 %. Класс `Dataset` позволяет удобно работать с обучающими и тестовыми данными, а загрузчик данных эффективно разбивает эти данные на пакеты (батчи) для использования в процессе обучения. [10].

Для построения модели классификации с использованием библиотеки `Pytorch` использовались следующие классы: вышеуказанный `Dataset`, `Module`, `CrossEntropyLoss`. Архитектура модели определяется с помощью класса `Module`. Реализуя данный класс, необходимо определить слои, функции активации и нормализации. Класс `CrossEntropyLoss` используется для реализации функции потерь.

```
C:\Users\Dmitry\anaconda3\python.exe
For epoch 30 the test accuracy over the whole test set is 93 %
For epoch 31 the test accuracy over the whole test set is 93 %
For epoch 32 the test accuracy over the whole test set is 93 %
For epoch 33 the test accuracy over the whole test set is 93 %
For epoch 34 the test accuracy over the whole test set is 93 %
For epoch 35 the test accuracy over the whole test set is 93 %
For epoch 36 the test accuracy over the whole test set is 93 %
For epoch 37 the test accuracy over the whole test set is 93 %
For epoch 38 the test accuracy over the whole test set is 93 %
For epoch 39 the test accuracy over the whole test set is 93 %
For epoch 40 the test accuracy over the whole test set is 93 %
For epoch 41 the test accuracy over the whole test set is 93 %
For epoch 42 the test accuracy over the whole test set is 93 %
For epoch 43 the test accuracy over the whole test set is 92 %
For epoch 44 the test accuracy over the whole test set is 93 %
For epoch 45 the test accuracy over the whole test set is 93 %
For epoch 46 the test accuracy over the whole test set is 93 %
For epoch 47 the test accuracy over the whole test set is 93 %
For epoch 48 the test accuracy over the whole test set is 92 %
For epoch 49 the test accuracy over the whole test set is 93 %
For epoch 50 the test accuracy over the whole test set is 93 %
Finished Training
Real labels: Sunflower Sunflower Chestnut Chestnut Sunflower acacia linden linden linden linden
Predicted: Sunflower Sunflower Chestnut Sunflower Sunflower acacia linden linden linden linden
Accuracy of acacia : 100 %
Accuracy of buckwheat : 100 %
Accuracy of Chestnut : 70 %
Accuracy of linden : 100 %
Accuracy of Sunflower : 95 %
Press any key to continue . . .
```

Рис. 3. – Результаты обучения классификатора для пыльцы

Процесс обучения модели состоит из двух основных этапов: первоначального и тестового обучения, каждый из которых включает по 50 эпох. В ходе первого этапа обучение завершилось с точностью 0.8037, что

показывает хорошие начальные результаты. По мере продолжения обучения и в ходе тестового этапа, точность модели продолжала улучшаться и в итоге достигла около 93.9%. Эти показатели свидетельствуют о том, что параметры модели были удачно подобраны, обеспечивая высокую эффективность и точность предсказаний. Итоговые результаты обучения вместе с точностью определения каждого вида пыльцы показаны на рис. 3.

В данной работе была успешно разработана и обучена нейросетевая модель для классификации пыльцы, достигающая точности 93%. Данный результат демонстрирует высокую эффективность предложенного подхода, основанного на использовании сверточных нейронных сетей, для автоматической идентификации различных видов пыльцы, присутствующих в мёде. Результаты исследования открывают перспективы для дальнейшего улучшения модели и расширения её применения. Возможные направления будущих исследований включают увеличение объема данных для обучения, использование более сложных архитектур нейронных сетей и интеграцию дополнительных методов обработки и анализа данных. Изображения, которые будут добавляться в датасет, будут также содержать различные побочные элементы. Такие элементы важно разметить при обучении, для повышения точности работы модели. Необходимыми направлениями работы в будущем станут проектирование и реализация приложения, которое будет использовать обученную модель.

Литература

1. Овчинникова, М.А., Морева, Л.Я. Монофлорные мёды фитоценозов Северо-Западного Кавказа и Предкавказья: монография. Краснодар: Кубанский гос. ун-т, 2022. — 155 с.
2. Глухин И.Н., Карякин Ю.Е., Березовский А.К., Дудина А.А. Классификация состояний объектов городской инфраструктуры с

использованием нейронных сетей // Инженерный вестник Дона, 2021, №8.
URL: ivdon.ru/ru/magazine/archive/n1y2023/8151/.

3. Белоусов И.С., Рогачев А.Ф. Разработка глубокой нейронной сети для сегментации проблемных участков сельскохозяйственных полей // Инженерный вестник Дона, 2022, №8. URL: ivdon.ru/ru/magazine/archive/n8y2022/7864/.

4. Khanzhina, N., E. Putin, A. Filchenkov and E. Zamyatina, 2018. Pollen Grain Recognition Using Convolutional Neural Network. Proceedings of European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, 25-27 April 2018, ESANN, pp: 409-414.

5. Deep Convolutional Neural Network for Pollen Grains Classification. URL: semanticscholar.org/paper/Deep-Convolutional-Neural-Network-for-Pollen-Grains-Menad-Ben-Naoum/10a3102ce3923ec83bc298de3b19211d4329eb3a, Date accessed 12.05.2024.

6. Panića, M., B. Šikoparija, D. Tešendić, M. Radovanović and S. Brdar, 2022. Advanced CNN Architectures for Pollen Classification: Design and Comprehensive Evaluation. Applied Artificial Intelligence, 37. URL: tandfonline.com/doi/full/10.1080/08839514.2022.2157593. Date accessed 12.05.2024.

7. Automated Classification of Airborne Pollen using Neural Networks. URL: ieeexplore.ieee.org/document/8856910, Date accessed 15.05.2024.

8. Rostami, M.A., B. Balmaki, L.A. Dyer, J.M. Allen and M.F. Sallam, 2023. Efficient pollen grain classification using pre-trained Convolutional Neural Networks: a comprehensive study. Journal of Big Data, 151. URL: journalofbigdata.springeropen.com/articles/10.1186/s40537-023-00815-3, Date accessed 16.05.2024.

9. Пойтер, Я. Программируем с PyTorch: создание приложений глубокого обучения. – Санкт-Петербург: ПИТЕР, 2020. – 256с.

10. Елисеев А.И., Минин Ю.В., Кулаков Ю.В. Решение задач глубокого обучения с использованием фреймворков Pytorch и Pytorch Lightning. Тамбов: Издательский центр ФГБОУ ВО "ТГТУ", 2022. 160 с.

References

1. Ovchinnikova, M.A. and L.Ya. Moreva, Monoflornyye mëdy fitotsenozov Severo-Zapadnogo Kavkaza i Predkavkaz'ya: monografiya [Monoflora honey of phytocenoses of the Northwestern Caucasus and the Caucasus: a monograph]. Krasnodar: Kuban State University, 2022. 155p.

2. Glukhikh I.N., Karyakin Yu.E., Berezovsky A.K., Dudina A.A. Inzhenernyj vestnik Dona, 2021, №8. URL: ivdon.ru/ru/magazine/archive/n1y2023/8151/

3. E Belousov I.S., Rogachev A.F. Inzhenernyj vestnik Dona, 2022, №8. URL: ivdon.ru/ru/magazine/archive/n8y2022/7864/.

4. Khanzhina, N., E. Putin, A. Filchenkov and E. Zamyatina, 2018. Pollen Grain Recognition Using Convolutional Neural Network. Proceedings of European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, 25-27 April 2018, ESANN, pp. 409-414.

5. Deep Convolutional Neural Network for Pollen Grains Classification. URL: [semanticscholar.org/paper/Deep-Convolutional-Neural-Network-for-Pollen-Grains-Menad-Ben-Naoum/10a3102ce3923ec83bc298de3b19211d4329eb3a](https://www.semanticscholar.org/paper/Deep-Convolutional-Neural-Network-for-Pollen-Grains-Menad-Ben-Naoum/10a3102ce3923ec83bc298de3b19211d4329eb3a), Date accessed 12.05.2024.

6. Panića, M., B. Šikoparija, D. Tešendić, M. Radovanović and S. Brdar, 2022. Advanced CNN Architectures for Pollen Classification: Design and Comprehensive Evaluation. Applied Artificial Intelligence, 37. URL: [tandfonline.com/doi/full/10.1080/08839514.2022.2157593](https://doi.org/10.1080/08839514.2022.2157593). Date accessed 12.05.2024.

7. Automated Classification of Airborne Pollen using Neural Networks. URL: ieeexplore.ieee.org/document/8856910. Date accessed 15.05.2024.



8. Rostami, M.A., B. Balmaki, L.A. Dyer, J.M. Allen and M.F. Sallam, 2023. Efficient pollen grain classification using pre-trained Convolutional Neural Networks: a comprehensive study. *Jornal of Big Data*, 151. URL: journalofbigdata.springeropen.com/articles/10.1186/s40537-023-00815-3. Date accessed 16.05.2024.

9. Појтер, Ја. Программируем с PyTorch: создание приложений глубокого обучения [Programming with PyTorch: Creating Deep Learning applications]. Санкт-Петербург: ПИТЕР, 2020. 256p.

10. Eliseev A.I., Minin Ju.V, Kulakov Ju.V. Reshenie zadach glubokogo obucheniya s ispol'zovaniem frejmvorkov Pytorch i Pytorch Lightning [Solving deep learning problems using the Pytorch and Pytorch Lightning frameworks]. Tambov: Izdatel'skij centr FGBOU VO "TGTU", 2022. 160p.

Дата поступления: 13.05.2024
Дата публикации: 22.06.2024