

Статья опубликована в открытом доступе по лицензии CC BY 4.0

Поступила в редакцию 02.04.2024 г.

Принята к публикации 06.05.2024 г.

EDN: YUQJXC

УДК 004.93:552.54(086.32):004.85

**Журавлев А.В., Груздев Д.А.**

Федеральное государственное бюджетное учреждение науки Институт геологии им. акад. Н.П. Юшкина ФИЦ Коми научного центра Уральского отделения Российской академии наук (ФГБУН ИГ Коми НЦ УрО РАН), Сыктывкар, Россия, [micropalaeontology@gmail.com](mailto:micropalaeontology@gmail.com)

## **АВТОМАТИЗИРОВАННАЯ ДИАГНОСТИКА КАРБОНАТНЫХ ПОРОД ПО МИКРОФОТОГРАФИЯМ ШЛИФОВ НА ОСНОВЕ МАШИННОГО ОБУЧЕНИЯ**

*На основе технологии машинного обучения разработана компьютерная модель диагностики карбонатных пород по изображениям шлифов. Модель использует классификацию Данхэма и определяет четыре типа карбонатов – мадстоун, вакстоун, пакстоун, грейнстоун, с достоверностью 98%. Возможности использования модели и программного обеспечения на ее основе в настоящее время ограничены заданными классами карбонатов. Любые изображения, выходящие за рамки этих классов, будут диагностированы ошибочно. К плюсам модели можно отнести высокую скорость работы и воспроизводимость результатов. Она может использоваться в качестве «консультанта» специалиста при работе с большими объемами материала.*

**Ключевые слова:** карбонаты, шлифы, машинное обучение, классификация изображений.

---

**Для цитирования:** Журавлев А.В., Груздев Д.А. Автоматизированная диагностика карбонатных пород по микрофотографиям шлифов на основе машинного обучения // Нефтегазовая геология. Теория и практика. - 2024. - Т.19. - №2. - [https://www.ngtp.ru/rub/2024/11\\_2024.html](https://www.ngtp.ru/rub/2024/11_2024.html) EDN: YUQJXC

---

Диагностика карбонатных пород в шлифах представляет собой рутинную процедуру, широко востребованную при изучении керна и естественных обнажений. Для краткой характеристики осадочных карбонатов, как правило, используется расширенная и в разной степени модифицированная классификация Р. Данхэма [Dunham, 1962]. При всей своей простоте эта классификация не является полностью формальной и допускает различные интерпретации [Lokier, Al Junaibi, 2016]. Проведенное S.W. Lokier и M. Al Junaibi исследование (2016 г.) показало, что при диагностике шлифов наибольшая согласованность экспертных оценок наблюдалась в определениях грейнстоунов и мадстоунов. При этом практически в двух третях случаев большинство экспертов не согласны с типизацией тестовых образцов, предложенной другими специалистами. Отсутствие единообразия в диагностике снижает возможности сравнения и совместного использования данных, полученных различными исследователями или одним исследователем в разное время.

Одним из путей достижения единообразия и воспроизводимости результатов диагностики карбонатов в шлифах представляется применение компьютерных систем

классификации изображений. Самым простым способом их построения выступает применение технологии машинного обучения, когда формальный образ того или иного класса карбонатов формируется на основе обучающей коллекции, составленной на базе экспертных заключений специалистов.

Системы, основанные на технологии машинного обучения, представляются перспективными инструментами для обработки больших объемов информации. В геологии существует позитивный опыт использования подобных систем для решения задач характеристики керна по фотографиям [Baraboshkin et al., 2020], петрографической диагностики [Marmo et al., 2005; Su et al., 2020; Jia et al., 2021; Ma et al., 2021; Li et al., 2022; Wu et al., 2022; Wang et al., 2023], определения фоссилий [Babenko, Telnova, 2022; Duan, 2023; Tetard et al., 2023], оценки фильтрационно-емкостных свойств пород [Wardaya et al., 2013a, 2013b], интерпретации геофизических данных и материалов аэрокосмической съемки (см. обзор [El-Omairi, El Garouani, 2023]).

Цель данной статьи заключается в описании и оценке перспектив использования созданной системы для автоматизированной диагностики карбонатных пород по оптическим микроизображениям шлифов.

Предлагаемый подход к решению задачи диагностики карбонатных пород в шлифах состоит в обучении модели классификации изображений на обучающей коллекции и интеграции полученной модели в программный (компьютерная программа, работающая с набором фотографий шлифов) или программно-аппаратный (микроскоп проходящего света, цифровая камера, компьютер) комплекс (рис. 1). Обучающая коллекция представлена микроизображениями шлифов (фрагменты 3x2 мм с формальным разрешением около 0,6 мкм/пиксел) слабо измененных карбонатных пород. Путем экспертной оценки коллекция разделена на 4 класса, отвечающих типам известняков – мадстоун, вакстоун, пакстоун, грейнстоун. Каждый класс представлен 50-75 микрофотографиями, общий размер коллекции составляет 270 изображений (табл. 1). Кроме того, размер обучающей выборки автоматически увеличен за счет трансформаций исходных изображений: добавления шума, обрезки, поворотов, отражения и фотометрических коррекций.

В качестве базовой использована предобученная модель классификации изображений Image Feature Print V2 (Apple Inc., 2017-2023). Данная модель приводит исходное изображение к размеру 360x360 пикселей и извлекает из него 768 характеристик. По сочетанию этих характеристик происходит отнесение изображения к тому или иному классу. Обучение модели проводилось на основе коллекции фотографий шлифов (изображения с разрешением 20 Мп) с использованием утилиты Create ML и фреймворка Core ML (Apple

Inc., 2017-2023), один из вариантов проекта Create ML с моделью<sup>1</sup>. Обучение осуществлялось за 275 итераций. При этом достигнутая точность модели на обучающей выборке составила 98%. Формальные характеристики полученной модели приведены в табл. 2. Последнюю версию модели можно получить для некоммерческого использования по запросу у авторов.

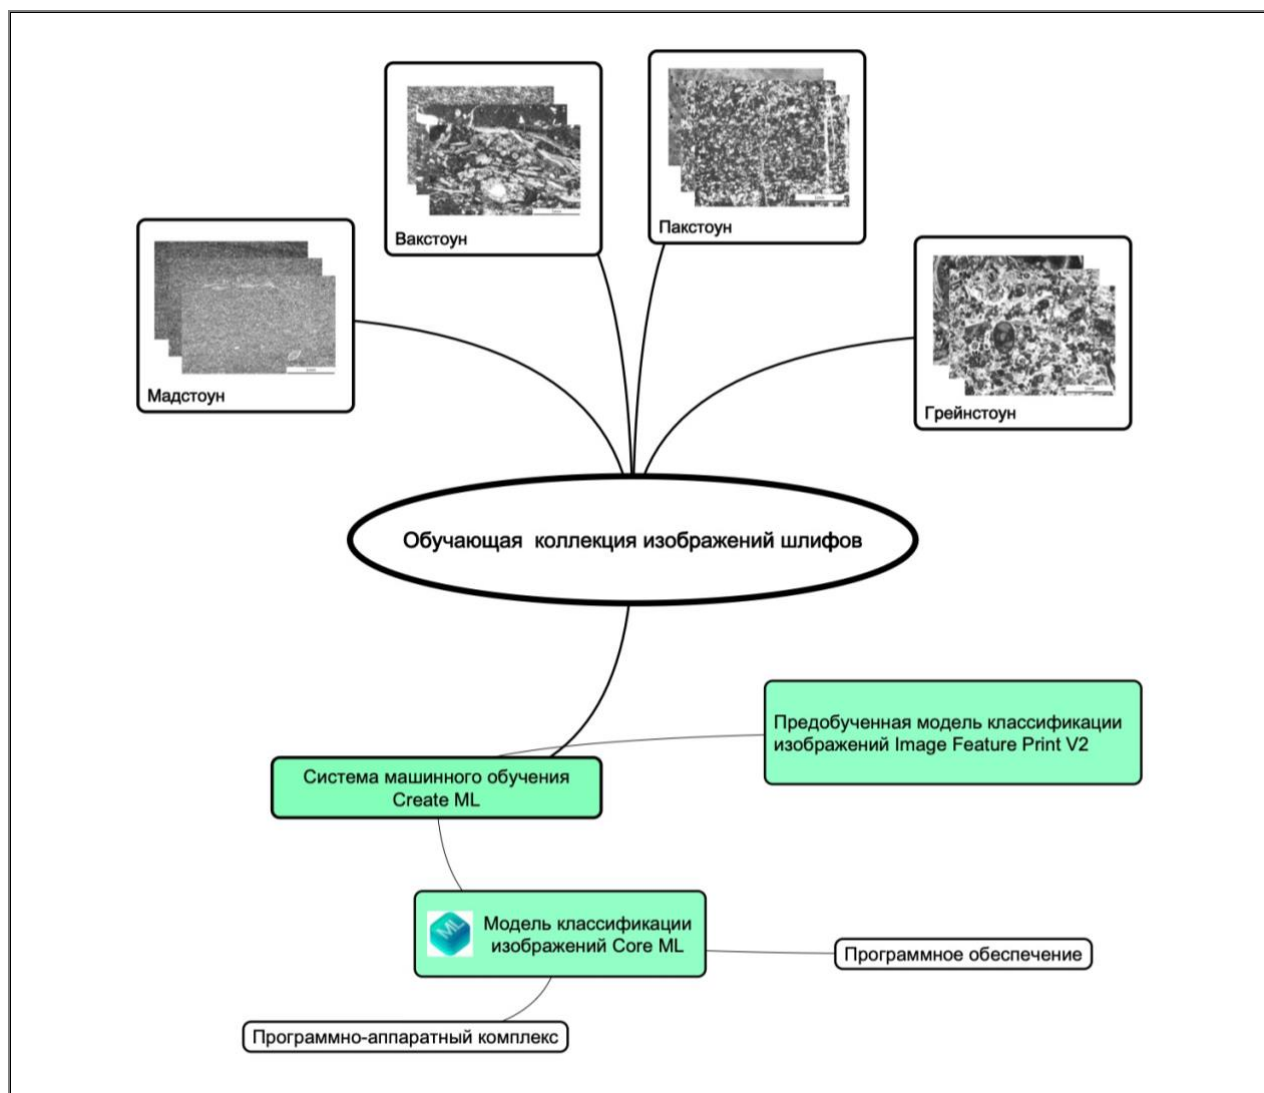


Рис. 1. Схема построения и использования модели автоматизированной диагностики карбонатных пород по микрофотографиям шлифов

Таблица 1

Характеристика обучающей коллекции микрофотографий шлифов

Тип известняка	Количество изображений
Мадстоун	54
Вакстоун	74
Пакстоун	72
Грейнстоун	70

<sup>1</sup> [https://www.researchgate.net/publication/374697646\\_Limestone\\_classification\\_ML\\_Create\\_project](https://www.researchgate.net/publication/374697646_Limestone_classification_ML_Create_project)

Таблица 2

## Характеристики модели

Тип известняка	Точность (precision)	Воспроизводимость (recall)	Сбалансированная F-оценка
Мадстоун	100%	100%	1,00
Вакстоун	100%	96%	0,98
Пакстоун	96%	97%	0,96
Грейнстоун	97%	99%	0,98


Как видно из табл. 2, ошибки модели в диагностике чаще всего связаны с пакстоунами. Наиболее распространенная ошибка – диагностика вакстоуна как пакстоуна. Следует отметить, что экспертная оценка ошибочно диагностированных моделью изображений также неоднозначна, поскольку разделение пак- и вакстоунов достаточно субъективно (см. также [Lokier, Al Junaibi, 2016]). Другой источник возможных ошибок – полная или частичная перекристаллизация карбонатов. Неравномерно перекристаллизованные разности чаще всего диагностируются моделью как вакстоуны (класс, представленный в обучающей выборке наибольшим количеством изображений) или грейнстоуны. Наиболее уверенно диагностируются мадстоуны, как и в случае использования экспертной оценки [Lokier, Al Junaibi, 2016].

Программа, реализующая применение полученной модели к микроизображениям шлифов, представляет собой консольное приложение, написанное на языке Swift 5.9 с использованием фреймворка Core ML. Исходными данными выступает набор файлов изображений в формате png и/или jpg с изображениями фрагментов шлифа размером около 2х3 мм. При существенно меньшем и большем размере изображенного фрагмента достоверность диагностики значительно снижается. Результат диагностики карбонатных пород записывается в текстовый файл (формат CSV, разделители запятые) со следующими полями: название файла изображения, результат диагностики 1, достоверность результата 1, результат диагностики 2, достоверность результата 2. Записываются два результата с наибольшей достоверностью диагностики. Обработка массива из 100 изображений (5440х3648 пикс.) занимает менее минуты.

Для реализации в виде программно-аппаратного комплекса разработанная модель устанавливается в программное обеспечение Vision Detector [Suzuki, 2022] или аналогичное, дающее возможность анализировать изображения, полученные с цифровой камеры на микроскопе, в режиме реального времени. При этом требования к аппаратной части крайне низкие – датчик изображения (цифровая камера) должен иметь разрешение не менее 360х360 пикселей, то есть 0,13 Мп. Оптимально использование камеры с разрешением 20-40 Мп, соответствующей камере, на которой проходило обучение модели. Это позволяет избежать

ошибок, связанных с качеством анализируемого изображения. Для достоверной диагностики в поле зрения камеры должен находиться фрагмент шлифа размером около 2х3 мм.

Примеры результатов применения модели к изображениям шлифов из визейско-серпуховских отложений юга поднятия Чернышева (Тимано-Печорский бассейн) показаны на рис. 2. Исходные изображения имели разрешение 5440х3648 пикселей и получены камерой МС20 на микроскопе ПОЛАМ-215 с объективом 4х (ЛОМО).




**Рис. 2. Примеры автоматизированной диагностики типа карбонатов в шлифах**  
*Под каждым изображением указаны имя файла, результат диагностики и его достоверность.*

Особенно сложными для диагностики являются шлифы, в которых присутствуют различные типы известняков. Для работы с такими шлифами разработана модификация модели, которая диагностирует карбонаты по небольшим фрагментам изображения (примерно 0,2х0,2 мм). Такая модель обладает гораздо меньшей достоверностью (70-80% на разных типах известняков) и ожидаемо плохо работает на породах с крупными форменными элементами. Однако она позволяет картировать распределение типов известняка в шлифе и, таким образом, визуализировать неоднородность породы (рис. 3). Картирование осуществляется путем разбиения изображения шлифа на фрагменты размером 0,2х0,2 мм и



определения типа известняка для каждого фрагмента.

Разработанное программное обеспечение работает на компьютерах под управлением MacOS v.14 и выше. Возможно портирование программы на мобильные устройства, работающие под управлением iOS 17.0 и выше. Выбор в качестве платформы MacOS обусловлен высокой степенью ее программно-аппаратной оптимизации для решения задач машинного обучения. При этом модель классификации изображений может быть конвертирована и для использования в приложениях Windows с помощью свободно распространяемой утилиты WinMLTools (Microsoft Corporation).



**Рис. 3. Пример картирования типов карбоната в шлифе**

*А - микроизображение шлифа, Б - карта распределения структурно-текстурных типов в шлифе (области с преобладанием спарита диагностированы как «грейнстоуны»). 1 - мадстоун, 2 - вакстоун, 3 - пакстоун, 4 - грейнстоун.*

Возможности использования модели и программного обеспечения на ее основе в настоящее время ограничены заданными классами карбонатов. Любые изображения, выходящие за рамки этих классов, будут диагностированы ошибочно. К плюсам модели можно отнести высокую скорость работы и высокую воспроизводимость результатов. Она может использоваться в качестве «консультанта» специалиста при работе с большими объемами материала.

*В настоящее время, разработанное программное обеспечение используется для анализа шлифов при выполнении работ по госзаданию в рамках темы 122040600008-5.*

### Литература

*Babenko V.V., Telnova O.P.* Problems and prospects of digital identification of Devonian spores for the stratigraphy // *Paleontological journal*. - 2022. - Vol. 56. - P. 1067-1073. DOI: [10.1134/S0031030122090040](https://doi.org/10.1134/S0031030122090040)

*Baraboshkin E.E., Ismailova L.S., Orlov D.M., Zhukovskaya E.A., Kalmykov G.A., Khotylev O.V., Baraboshkin E.Y., Koroteev D.A.* Deep convolutions for indepth automated rock typing // *Computers and Geosciences*. - 2020. - Vol. 135. - 104330. DOI: [10.1016/j.cageo.2019.104330](https://doi.org/10.1016/j.cageo.2019.104330)

*Duan X.* Automatic identification of conodont species using fine-grained convolutional neural networks // *Frontiers in Earth Science*. - 2023. - Vol. 10. - № 1. DOI: [10.3389/feart.2022.1046327](https://doi.org/10.3389/feart.2022.1046327)

*Dunham R.J.* Classification of carbonate rocks according to depositional texture // *AAPG Memoir*. - 1962. - № 1. - P. 108-121.

*El-Omairi M.A., El Garouani A.* A review on advancements in lithological mapping utilizing machine learning algorithms and remote sensing data // *Heliyon*. - 2023. - № 9. DOI: [10.1016/j.heliyon.2023.e20168](https://doi.org/10.1016/j.heliyon.2023.e20168)

*Jia L.Q., Yang M., Meng F., He M.Y., Liu H.M.* Mineral photos recognition based on feature fusion and online hard sample mining // *Minerals*. - 2021. - Vol.11. - 1354. DOI: [10.3390/min11121354](https://doi.org/10.3390/min11121354)

*Li D., Zhao J., Ma J.* Experimental studies on rock thin-section image classification by deep learning-based approaches // *Mathematics*. - 2022. - № 10. - 2317. DOI: [10.3390/math10132317](https://doi.org/10.3390/math10132317)

*Lokier S.W., Al Junaibi M.* The petrographic description of carbonate facies: are we all speaking the same language? // *Sedimentology*. - 2016. - Vol. 63. - P. 1843-1885. DOI: [10.1111/sed.12293](https://doi.org/10.1111/sed.12293)

*Ma H., Han G.Q., Peng L., Zhu L.Y., Shu J.* Rock thin sections identification based on improved squeeze-and-excitation networks model // *Computers & Geosciences*. - 2021. - Vol. 152. - 104780. DOI: [10.1016/j.cageo.2021.104780](https://doi.org/10.1016/j.cageo.2021.104780)

*Marmo R., Amodio S., Tagliaferri R., Ferreri V., Longo G.* Textural identification of carbonate rocks by image processing and neural network: methodology proposal and examples // *Computers & Geosciences*. - 2005. - Vol. 31. - Issue 5. - P. 649-659. DOI: [10.1016/j.cageo.2004.11.016](https://doi.org/10.1016/j.cageo.2004.11.016)

*Su C., Xu S.J., Zhu K.Y., Zhang X.C.* Rock classification in petrographic thin section images based on concatenated convolutional neural networks // *Earth Sci. Inform*. - 2020. - Vol. 13. - P. 1477-1484. DOI: [10.1007/s12145-020-00505-1](https://doi.org/10.1007/s12145-020-00505-1)

*Suzuki K.* Vision Detector. 2022. <https://apps.apple.com/us/app/vision-detector/id6443729650>

*Tetard M., Carlsson V., Meunier M., Danelian T.* Merging databases for CNN image recognition, increasing bias or improving results? // *Marine Micropaleontology*. - 2023. - Vol. 185. - 102296. DOI: [10.1016/j.marmicro.2023.102296](https://doi.org/10.1016/j.marmicro.2023.102296)

*Wang H., Cao W., Zhou Y., Yu P., Yang W.* Multitarget intelligent recognition of petrographic thin section images based on faster RCNN // *Minerals*. - 2023. - Vol. 13. - 872. DOI: [10.3390/min13070872](https://doi.org/10.3390/min13070872)

*Wardaya P.D., Khairy H., Chow W.S.* Extracting physical properties from thin section: another neural network contribution in rock physics // Paper presented at the International Petroleum Technology Conference, Beijing, China. - 2013a. DOI: [10.2523/IPTC-16977-MS](https://doi.org/10.2523/IPTC-16977-MS)

*Wardaya P.D., Khairy H., Chow W.S.* Integrating digital image processing and artificial neural network for estimating porosity from thin section // Paper presented at the International Petroleum Technology Conference, Beijing, China. - 2013b. DOI: [10.2523/IPTC-16959-MS](https://doi.org/10.2523/IPTC-16959-MS)

*Wu B.K., Ji X.H., He M.Y., Yang M., Zhang Z.C., Chen Y., Wang Y.Z., Zheng X.Q.* Mineral identification based on multi-label image classification // *Minerals*. - 2022. - Vol. 12. - 1338. DOI: [10.3390/min12111338](https://doi.org/10.3390/min12111338)

*This is an open access article under the CC BY 4.0 license*

Received 02.04.2024

Published 06.05.2024

**Zhuravlev A.V., Gruzdev D.A.**

Institute of Geology FRC Komi Research Center of the Ural Branch of the Russian Academy of Science (IG FRC Komi Scientific Center UB RAS), Syktyvkar, Russia, micropalaeontology@gmail.com

## **AUTOMATIC DIAGNOSTICS OF CARBONATE ROCKS FROM MICROPHOTOGRAPHS OF THIN SECTIONS BASED ON MACHINE LEARNING**

*On the basis of machine learning technology, a computer model for diagnosing carbonate rocks from thin section images has been developed. The model uses the Dunham' classification and identifies four types of carbonates - mudstone, wackestone, packstone, grainstone, with 98% accuracy. The ability to use the model and software based on it is currently limited to the given carbonate classes. Any images outside of these classes will be misdiagnosed. The pros of the model include its high speed of operation and reproducibility of results. It can be used as a human assistant when working with large volumes of material.*

**Keywords:** carbonates, thin sections, machine learning, image classification.

---

**For citation:** Zhuravlev A.V., Gruzdev D.A. Avtomatizirovannaya diagnostika karbonatnykh porod po mikrofotografiyam shlifov na osnove mashinnogo obucheniya [Automated diagnostics of carbonate rocks from microphotographs of thin sections based on machine learning]. Neftegazovaya Geologiya. Teoriya i Praktika, 2024, vol. 19, no. 2, available at: [https://www.ngtp.ru/rub/2024/11\\_2024.html](https://www.ngtp.ru/rub/2024/11_2024.html) EDN: YUQJXC

---

### **References**

Babenko V.V., Telnova O.P. Problems and prospects of digital identification of Devonian spores for the stratigraphy. Paleontological journal, 2022, vol. 56, pp. 1067-1073. DOI: [10.1134/S0031030122090040](https://doi.org/10.1134/S0031030122090040)

Baraboshkin E.E., Ismailova L.S., Orlov D.M., Zhukovskaya E.A., Kalmykov G.A., Khotylev O.V., Baraboshkin E.Y., Koroteev D.A. Deep convolutions for in-depth automated rock typing. Computers and Geosciences, 2020, vol. 135, 104330. DOI: [10.1016/j.cageo.2019.104330](https://doi.org/10.1016/j.cageo.2019.104330)

Duan X. Automatic identification of conodont species using fine-grained convolutional neural networks. Frontiers in Earth Science, 2023, vol. 10, no. 1. DOI: [10.3389/feart.2022.1046327](https://doi.org/10.3389/feart.2022.1046327)

Dunham R.J. Classification of carbonate rocks according to depositional texture. AAPG Memoir, 1962, no. 1, pp. 108-121.

El-Omairi M.A., El Garouani A. A review on advancements in lithological mapping utilizing machine learning algorithms and remote sensing data. Heliyon, 2023, no. 9. DOI: [10.1016/j.heliyon.2023.e20168](https://doi.org/10.1016/j.heliyon.2023.e20168)

Jia L.Q., Yang M., Meng F., He M.Y., Liu H.M. Mineral photos recognition based on feature fusion and online hard sample mining. Minerals, 2021, vol. 11, 1354. DOI: [10.3390/min11121354](https://doi.org/10.3390/min11121354)

Li D., Zhao J., Ma J. Experimental studies on rock thin-section image classification by deep learning-based approaches. Mathematics, 2022, no.10, 2317. DOI: [10.3390/math10132317](https://doi.org/10.3390/math10132317)

Lokier S.W., Al Junaibi M. The petrographic description of carbonate facies: are we all speaking the same language? Sedimentology, 2016, vol. 63, pp. 1843-1885. DOI: [10.1111/sed.12293](https://doi.org/10.1111/sed.12293)

Ma H., Han G.Q., Peng L., Zhu L.Y., Shu J. Rock thin sections identification based on improved squeeze-and-excitation networks model. Computers & Geosciences, 2021, vol. 152, 104780. DOI: [10.1016/j.cageo.2021.104780](https://doi.org/10.1016/j.cageo.2021.104780)

Marmo R., Amodio S., Tagliaferri R., Ferreri V., Longo G. Textural identification of carbonate rocks by image processing and neural network: methodology proposal and examples. Computers & Geosciences, 2005, vol. 31, issue 5, pp. 649-659. DOI: [10.1016/j.cageo.2004.11.016](https://doi.org/10.1016/j.cageo.2004.11.016)



Su C., Xu S.J., Zhu K.Y., Zhang X.C. Rock classification in petrographic thin section images based on concatenated convolutional neural networks. *Earth Sci. Inform.*, 2020, vol. 13, pp. 1477-1484. DOI: [10.1007/s12145-020-00505-1](https://doi.org/10.1007/s12145-020-00505-1)

Suzuki K. Vision Detector, 2022. <https://apps.apple.com/us/app/vision-detector/id64443729650>

Tetard M., Carlsson V., Meunier M., Danelian T. Merging databases for CNN image recognition, increasing bias or improving results? *Marine Micropaleontology*, 2023, vol. 185, 102296. DOI: [10.1016/j.marmicro.2023.102296](https://doi.org/10.1016/j.marmicro.2023.102296)

Wang H., Cao W., Zhou Y., Yu P., Yang W. Multitarget intelligent recognition of petrographic thin section images based on faster RCNN. *Minerals*, 2023, vol. 13, 872. DOI: [10.3390/min13070872](https://doi.org/10.3390/min13070872)

Wardaya P.D., Khairy H., Chow W.S. Extracting physical properties from thin section: another neural network contribution in rock physics. Paper presented at the International Petroleum Technology Conference, Beijing, China, 2013a. DOI: [10.2523/IPTC-16977-MS](https://doi.org/10.2523/IPTC-16977-MS)

Wardaya P.D., Khairy H., Chow W.S. Integrating digital image processing and artificial neural network for estimating porosity from thin section. Paper presented at the International Petroleum Technology Conference, Beijing, China, 2013b. DOI: [10.2523/IPTC-16959-MS](https://doi.org/10.2523/IPTC-16959-MS)

Wu B.K., Ji X.H., He M.Y., Yang M., Zhang Z.C., Chen Y., Wang Y.Z., Zheng X.Q. Mineral identification based on multi-label image classification. *Minerals*, 2022, vol. 12, 1338. DOI: [10.3390/min12111338](https://doi.org/10.3390/min12111338)