

Приложения компьютерного зрения в горнодобывающей промышленности

В.А. Калашников¹, В.И. Соловьев^{2,3*}

¹Финансовый университет при Правительстве Российской Федерации, Москва, Россия

²ООО «ЦИАРС», Москва, Россия

³Московский технический университет связи и информатики, Москва, Россия

*vs@ciars.ai

Аннотация. В последнее десятилетие происходит активная цифровизация промышленного производства на основе бурно развивающихся информационных технологий, в том числе технологий искусственного интеллекта. Во многом это связано с развитием методов глубокого обучения и их применения в компьютерном зрении. С середины 2010-х сверточные нейронные сети демонстрируют исключительную эффективность при решении таких задач, как обнаружение, классификация и сегментация различных объектов. В результате методы компьютерного зрения начинают активно использоваться в задачах контроля качества сырья и готовой продукции. Все это относится к горнодобывающей промышленности. Однако в отечественной научной литературе практически отсутствуют систематические обзоры приложений компьютерного зрения в этой области. Настоящее исследование призвано восполнить этот пробел. В данной работе дается систематический обзор истории развития и современного состояния методов и технологий машинного зрения, применяемых в горнодобывающей промышленности для анализа твердых материалов, демонстрируются последние достижения в этой области и примеры их применения в горном деле. Авторы проанализировали 29 научных работ в области применения компьютерного зрения в горнодобывающей промышленности и классифицировали этапы развития технологий, начиная с середины 1980-х гг., когда компьютерное зрение использовалось без применения машинного обучения, и заканчивая современными исследованиями на основе использования глубоких сверточных нейронных сетей для решения задач классификации и сегментации. Приводится сравнение эффективности применяемых методов, обсуждаются их достоинства и недостатки, даются прогнозы развития методов компьютерного зрения в горнодобывающей промышленности на ближайшее будущее. Приведены примеры, показывающие, что использование сверточных нейронных сетей позволило перейти на качественно более высокий уровень в решении задач классификации и сегментации применительно к анализу объемов выпуска продукции горнодобывающей промышленности, гранулометрического состава, в том числе лещадности, угловатости и шероховатости, содержания пыли и глины, насыпной плотности и пустотности и др.

Ключевые слова: глубокое обучение, компьютерное зрение, сверточные нейронные сети, сегментация, классификация, горнодобывающая промышленность, цифровая обработка изображений

Для цитирования: Калашников В.А., Соловьев В.И. Приложения компьютерного зрения в горнодобывающей промышленности // Прикладная информатика. 2023. Т. 18. № 1. С. 4–21. DOI: 10.37791/2687-0649-2023-18-1-4-21

Applications of computer vision in the mining industry

V. Kalashnikov¹, V. Soloviev^{2,3*}

¹Financial University under the Government of the Russian Federation, Moscow, Russia

²CIARS Llc, Moscow, Russia

³Moscow State University of Communications and Informatics, Moscow, Russia

*vs@ciars.ai

Abstract. In the last decade, there has been an active digitalization of industrial production based on rapidly developing information technologies, including artificial intelligence technologies. This is largely due to the development of deep learning methods and their applications in computer vision. Since the mid 2010s convolutional neural networks demonstrate exceptional efficiency in solving problems such as the detection, classification and segmentation of various objects. As a result, computer vision methods are beginning to be actively used in the problems of quality control of raw materials and finished products. All this applies to the mining industry. However, in the Russian scientific literature there are practically no systematic reviews of computer vision applications in this area. The present study aims to fill this gap. The paper provides a systematic review of the history of development and the current state of the methods and technologies of machine vision used in the mining industry for the analysis of solid materials, demonstrates the latest achievements in this area and examples of their application in the mining industry. The authors have analyzed 29 research papers in the field of application of computer vision in the mining industry and classified the stages of technology development from the mid-1980s, when computer vision was used without the use of machine learning, and ending with modern research based on the use of deep convolutional neural networks for solving problems of classification and segmentation. The effectiveness of the methods used is compared, their advantages and disadvantages are discussed, and forecasts are made for the development of computer vision methods in the mining industry in the near future. Examples are given showing that the use of convolutional neural networks made it possible to move to a qualitatively higher level of quality in solving problems of classification and segmentation as applied to the analysis of output volume, particle size distribution, including flakiness, angularity and roughness, dust and clay content, bulk density and emptiness, etc.

Keywords: deep learning, computer vision, convolutional neural networks, segmentation, classification, mining, digital image processing

For citation: Kalashnikov V., Soloviev V. Applications of computer vision in the mining industry. *Prikladnaya informatika=Journal of Applied Informatics*, 2023, vol.18, no.1, pp.4-21 (in Russian). DOI: 10.37791/2687-0649-2023-18-1-4-21

Введение

В последнее десятилетие идет активная цифровизация промышленного производства на основе быстро развивающихся информационных технологий, в том числе технологий искусственного интеллекта. Это во многом связано с бурным развитием методов глубокого обучения и их приложений в компьютерном зрении. Начиная

с середины 2010-х гг. сверточные нейронные сети демонстрируют исключительную эффективность в решении таких задач, как обнаружение, классификация и сегментация различных объектов.

Раньше интеллектуальные технологии активно внедрялись в процессы, где можно обеспечить идеальную повторяемость условий внешней среды. В частности, системы ком-

пьютерного зрения внедрялись в чистых цехах с идеальным освещением, стандартными расстояниями от камер до анализируемых объектов и т. д.

С развитием технологий компьютерного зрения и появлением сверточных нейронных сетей у исследователей появилась уникальная возможность качественно имитировать когнитивные функции человека, а иногда и существенно превосходить их. Это приводит к возможности замены людей на интеллектуальные системы в самых разных областях.

Использование интеллектуальных систем компьютерного зрения в промышленности позволяет более надежно и информативно сопровождать производственные процессы, значительно сократить долю брака, защитить оборудование от поломок, сэкономить трудовые ресурсы.

Горнодобывающая промышленность в России является одной из крупнейших сфер производства, динамично развивающейся в последние десятилетия. По данным Росстата, в России имеется более 20 тыс. месторождений, из которых примерно треть активно используется для добычи полезных ископаемых, при этом в отрасли занято более 990 тыс. человек, а общий объем рынка в 2018 г. составлял более 18 трлн руб. Несмотря на сокращение производства на 6,6% в 2020 г., вызванное пандемией COVID-19, отрасль сохраняет высокий уровень рентабельности. По данным Росстата [1], при том что индекс промышленного производства (по всем видам экономической деятельности) в январе–ноябре 2022 г. составил 99,9% от соответствующего периода 2021 г., добыча полезных ископаемых за январь–ноябрь 2022 г. выросла на 4,2% по сравнению с январем–ноябрем 2021 г., а добыча прочих полезных ископаемых (т. е. всех, за исключением угля, нефти, природного газа и металлических руд) за 11 месяцев 2022 г. оказалась на 5,3% больше, чем за аналогичный период 2021 г.

Внедрение интеллектуальных систем для проведения разведки, контроля качества сырья и продукции в этой сфере обладает значи-

тельным потенциалом и уже активно ведется в последние годы. Однако в российской научной литературе практически отсутствуют сведения о применении систем машинного зрения в данной области.

Наибольший потенциал внедрение систем компьютерного зрения имеет в задачах сплошного контроля качества и объемов продукции. Качество продукции при этом определяется стандартами. Например, щебень и гравий из горных пород со средней плотностью зерен от 2,0 до 3,0 г/см, применяемые в качестве заполнителей для тяжелого бетона, а также для дорожных и других видов строительных работ, должны соответствовать требованиям, определенным межгосударственным стандартом ГОСТ 8267–93 «Щебень и гравий из плотных горных пород для строительных работ. Технические условия».

Так, щебень и гравий могут производиться в виде следующих основных фракций: 3–10, 5–10, 10–15, 10–20, 5–20, 15–20, 20–40, 40–70, 40–80 мм. ГОСТ 8267–93 определяет, что не более 10% по массе производимого щебня может выходить за верхнюю границу фракции и не более 10% – за нижнюю.

При этом, помимо соответствия размера производимого щебня заданной фракции, важна форма зерен: они не должны быть пластинчатыми (в профессиональной терминологии – лещадными, т. е. похожими не на кубики, а на лещадь). В зависимости от доли содержания пластинчатых и игольчатых зерен щебень делится на пять групп по качеству: в первой группе доля лещадных и игольчатых зерен не может превышать 10% по массе, в 5-й группе она может находиться в диапазоне 35–50%.

Также важно контролировать содержание в щебне пылевидных и глинистых частиц (размером менее 0,05 мм) – доля таких частиц в зависимости от породы не может превышать 1–3% по массе.

Методы контроля качества, применяемые на практике, определяются межгосударственным стандартом ГОСТ 8269.0–97 «Щебень и гравий из плотных горных пород

и отходов промышленного производства для строительных работ. Методы физико-механических испытаний» и предполагают выборочный контроль с отбором проб и проведением лабораторных измерений. Так, зерновой состав щебня и гравия определяют путем рассыпь пробы на стандартном наборе, состоящем из двух сит – нижнего, имеющего размер ячеек, равный нижней границе фракции, и верхнего, в котором размер ячеек равен верхней границе фракции.

Системы компьютерного зрения способны трансформировать процесс выборочного контроля качества в процесс непрерывного контроля в реальном времени с одновременным контролем объемов выпускаемой продукции.

Таким образом, система компьютерного зрения должна быть способна определять общий объем (по массе) продукции, выпущенной с конвейера за смену, а также массовую долю продукции заданной фракции и заданной группы качества в общем объеме выпущенной продукции.

В данной статье приводится краткий обзор истории развития применения компьютерного зрения в горнодобывающей промышленности, а также обсуждаются результаты, полученные в данной области. В первом разделе рассматриваются различные подходы к решению задач классификации изображений: по гранулометрическому составу и типу породы без использования методов глубокого обучения. Во втором разделе описаны методы сегментации и классификации различных объектов на изображениях (в основном, элементов некоторого материала) с применением сверточных нейронных сетей. Показаны также приложения описанных методов в задачах геологической разведки и контроля качества продукции.

Компьютерное зрение до появления глубокого обучения

В данном разделе рассмотрены классические методы и алгоритмы машинного зрения, а также применение полно связанных нейронных

сетей и методов цифровой обработки изображений в горнодобывающей промышленности.

Компьютерное зрение до появления машинного обучения

В начале 1990-х гг. развитие оптических и вычислительных устройств достигло уровня, достаточного для внедрения в промышленность. У специалистов по искусственному интеллекту уже в то время имелось значительное количество эффективных алгоритмов обработки изображений и получения их количественных характеристик. Применяемые методы можно отнести к сфере компьютерного зрения – совокупности технологий и методик обработки данных, полученных с камер и сканеров различного типа. Далее рассмотрены работы, в которых применялись классические методы цифровой обработки изображений, а также разрабатывались специальные устройства для применения в сфере горнодобывающей промышленности.

До появления современных алгоритмов машинного обучения для решения задач компьютерного зрения в горнодобывающей промышленности применялись самые разные техники.

Одна из первых попыток использования методов анализа изображений была предпринята в 1985 г. Мананой и соавторами [19]. Авторы рассматривали задачу сортировки угля на ленте конвейера с помощью сегментации пикселей (разделения пикселей изображения на классы, где каждый класс соответствует некоторому объекту). Применяемая специалистами методика подразумевала несколько этапов. Первым из них являлась дискретизация черно-белого изображения, полученного с камеры. Далее проводились необходимые вычисления, затем с помощью полученных характеристик изображения моделировалась проекция видимой поверхности камня. Основным параметром, применяемым для сегментации кусков угля, был уровень черного цвета на изображении, что позволяло быстро проводить вычисления даже на про-

цессорах 1980-х гг. Однако авторы статьи констатируют, что применение числовых характеристик не обеспечивает требуемого уровня точности и ведет к большому количеству ошибок даже в простых условиях (когда куски угля уложены в один слой и разделены).

В статье 1992 г. Ланге и соавторами определялось распределение золотоносной руды по массе с помощью морфологических преобразований [17].

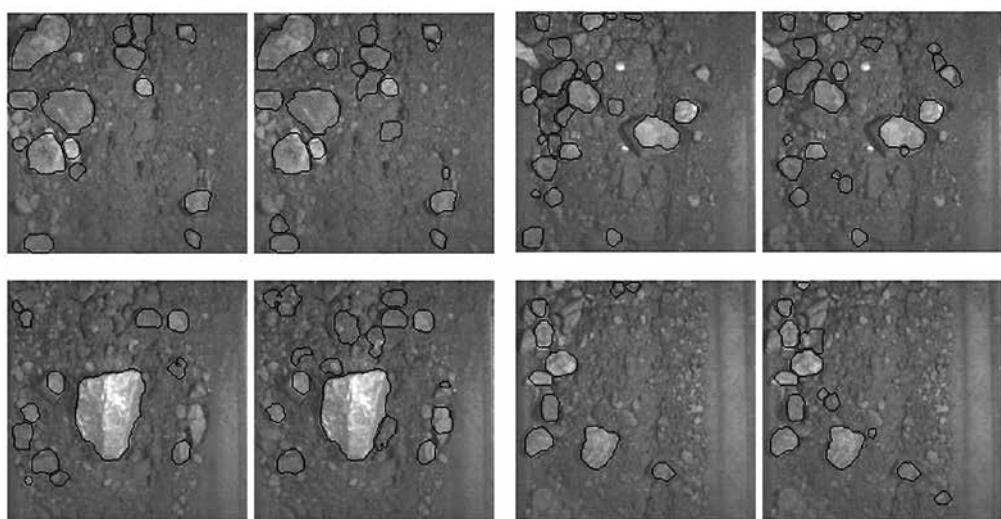
В работе 1997 г. [13] Хислип и соавторы для исследования гранулометрического состава пород вычисляли фрактальную размерность контуров изображений. Они обнаружили положительную корреляцию фрактальной размерности с долей мелких фракций. Однако для практического применения только обнаруженной корреляционной связи недостаточно.

Кроме методов обработки изображений, исследователями применялись и более сложные технологии. В частности, в статье 1992 г. [9] Чеунг и соавторы использовали промышленное лазерное сканирование. Из полученных данных реконструировалась трехмерная модель камня. Данный метод в совокупности с математическими вычислениями обладает довольно высоким уровнем эффективности.

Однако в связи с дороговизной и некоторыми существенными затруднениями в эксплуатации лазерных сканеров (сложность калибровки и перемещения, запыленность производственных помещений и др.) его практическое использование оказалось довольно затруднительным.

Наиболее простым и эффективным решением в задаче автоматической сегментации кусков породы на изображении оказался алгоритм сегментации по водоразделам (Watershed algorithm). Например, в статье [20], опубликованной в 2005 г., Маквело и соавторам удалось добиться качества сегментации, сравнимого с человеческим зрением. Тем не менее, использование этого метода сопряжено с рядом сложностей, поскольку алгоритм эффективен лишь в определенных, достаточно частных условиях. Изменение освещенности, окружающей камни среды или цветовой гаммы самих элементов породы с высокой вероятностью ведет к существенному падению эффективности.

Пример применения данного алгоритма иллюстрирует рисунок 1. В каждой паре изображений слева выделен результат работы алгоритма, а справа – реальное расположение камней.



Источник: [20].

Рис. 1. Пример использования алгоритма сегментации по водоразделам

Fig. 1. Example of watershed algorithm usage

Машинное обучение до появления нейронных сетей

Кроме базового анализа характеристик изображения простейшими статистическими методами, исследователи применяли комбинированный подход, сущность которого заключалась в экстракции некоторых характеристических признаков из изображения и их дальнейшей обработке методами машинного обучения.

Например, в уже упомянутой работе Маквело и соавторов [20] после применения алгоритма сегментации по водоразделам возникает необходимость выделить на изображении ленты конвейера области, в которых отсутствует порода. Для этого авторы проводят расчет 11 различных числовых характеристик, полученных методом цифровой обработки изображений, и используют несколько различных алгоритмов классификации (KNN, SVM, RLSC) для решения поставленной задачи. Доля корректно сегментированных пикселей на изображении достигает 90%. Аналогичный метод с некоторыми модификациями используется и в работе Бай и соавторов [2], вышедшей в 2021 г.

Помимо задачи сегментации камней на конвейере, методами машинного обучения решаются и некоторые другие задачи горного дела. Например, в 2007 г. в работе [26] Тессиер и соавторы предложили следующую технологию классификации породы на изображении. Методом главных компонент (PCA) из изображения извлекаются ключевые признаки, а затем строятся регрессионные модели с помощью модифицированного метода наименьших квадратов (PLS-DA) и метода опорных векторов (SVM). Использование данной технологии позволяет получить информацию о видах камней, имеющихся на изображении ленты конвейера, однако авторы не ставили перед собой цель их сегментации.

Таким образом, методы машинного обучения могут быть успешно применены к обработке изображения классическими методами,

однако поставленные задачи имеют частный характер и требуют неэффективного процесса рассмотрения отдельных параметров, что существенно усложняет их разработку и ограничивает практическую применимость.

Нейронные сети до появления сверточных нейронных сетей

В научной литературе можно также найти примеры использования полносвязных нейронных сетей для решения задач компьютерного зрения в горнодобывающей промышленности. В 1994 г. Бэррон и соавторы предложили использовать преобразование Фурье и методы снижения размерности данных для обучения нейронной сети в задаче гранулометрии образовавшихся в результате взрыва осколков [5]. Используемая авторами нейронная сеть довольно проста (содержит три слоя с 5, 20 и 1 нейроном), что объясняется отсутствием эффективных вычислительных устройств на момент проведения исследования. Выходной нейрон относит изображение к определенному классу распределений. В результате авторы добиваются доли корректных ответов (accuracy) в задаче классификации на уровне 97%.

Петэл и соавторы в 2016 г. предложили использовать полносвязные нейронные сети для классификации типов известняка по цветовым параметрам изображений [21]. Кроме того, для определения распределения размеров камней на изображениях используются вейвлет-преобразование и преобразование Габора.

В работе Ко и соавторов [16] вначале по изображению неупорядоченного рудного материала вычисляется однородность как отношение числа темных (по порогу 130) пикселей в центральном квадранте изображения, разделенного на три части по горизонтали и три части по вертикали, к числу темных пикселей в остальных квадрантах, а далее для прогнозирования доли зерен, удовлетворяющих заданным критериям по размеру, обучена нейронная сеть LM, объясняющая

более 90% вариации доли соответствующих критериям зерен.

Описанные в данном разделе методы несколько эффективнее классических методов компьютерного зрения, так как действуют известные математические операции над массивами информации и добиваются приемлемых результатов классификации изображений. Однако горнодобывающая промышленность не ограничивается лишь задачами этого типа. Зачастую требуется не просто разделить изображения на несколько классов, а получить более детальную информацию об объектах, присутствующих на изображении (например, о размерах камней, о степени их лещадности, т. е. вытянутости в продольном направлении, и др.). Это требует использования более продвинутых методов работы с визуальной информацией, речь о которых пойдет далее.

Компьютерное зрение с применением глубокого обучения

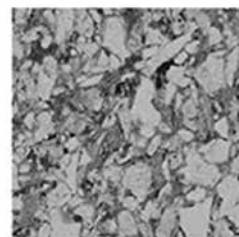
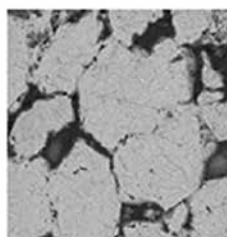
На современном этапе развития технологий компьютерного зрения технологии, рассмотренные в предыдущем разделе, являются несколько устаревшими и существенно проигрывают в качестве и универсальности сверточным нейронным сетям. Использование нейросетей такого типа возможно практически в любых современных задачах машинного зрения, но в горнодобывающей промышленности они в основном применяются для классификации внутри некоторых заранее заданных групп и для сегментации каких-

либо объектов (обычно элементов породы) на изображении. Такой подход довольно прост в применении и позволяет использовать информацию, имеющуюся на изображении гораздо полно.

Использование сверточных нейронных сетей для классификации

Одной из наиболее простых задач, с достаточной точностью решаемой современными нейронными сетями, является классификация по гранулометрическому составу. При этом предполагается не его оценка, а лишь отнесение к некоторой группе. В отличие от приведенных ранее методов, использование сверточных нейронных сетей позволяет исследователям не выделять некоторые характеристические параметры изображения, а использовать имеющиеся в визуальной информации паттерны неявно. Например, для решения задачи классификации необходимо лишь предварительно собрать данные и вручную разделить их на группы. После этого часть размеченных изображений используется для обучения нейронной сети, затем алгоритм должен быть проверен на тестовой выборке, что позволяет исследовать влияние различных параметров алгоритма на точность классификации. Заключительным этапом является дополнительное исследование точности предсказания на валидационной выборке.

Например, в работе [9] Чеунг и др. разделили имеющиеся фотографии песка на три группы (рис. 2): к первой группе они отнесли фотографии, на которых изображены



Источник: [9].

Рис. 2. Примеры классов для классификации

Fig. 2. Example classes for classification

крупнозернистые песчинки, ко второй – песчинки среднего размера, а к третьей – мелкие песчинки. Все используемые для обучения и тестирования фотографии были выполнены с одного и того же расстояния, что позволило исследовать их в одинаковом масштабе. Авторы самостоятельно разработали несколько архитектур сверточных нейронных сетей для решения поставленной задачи и получили наилучший результат, используя вариант с четырьмя слоями (доля верных ответов в задаче классификации 98,5%). При этом в процессе обучения было использовано 3600 изображений (по 1200 из каждого класса), а тренировочный набор состоял из 1200 изображений, что обеспечивает результатам достаточно высокий уровень статистической устойчивости.

Описанный метод имеет одно очень важное достоинство – он легко может быть обобщен и использован в других задачах классификации, если имеется достаточное количество предварительно размеченных (отнесенных к некоторому классу) данных.

Сверточные нейронные сети также были успешно использованы и в задаче определения типов породы на изображениях, полученных с помощью дронов. В частности, в работе [23] Ран и др. использовали более 24 000 размеченных изображений для обучения собственной нейронной сети. Набор данных состоял из фотографий шести различных видов изображений породы: милонита, гранита, песчаника, сланца, известняка и комбинированных изображений (сразу несколько типов камней на фотографии). Доля верно классифицированных изображений составила примерно 98%, что говорит о высокой прикладной значимости результата. В своем исследовании специалисты также сравнивали свою разработку с другими известными архитектурами нейронных сетей: AlexNet, GoogleLeNet и VGG-16, однако получили лучшие предсказания на валидационных данных с помощью собственной архитектуры.

Описаны также разработки мобильных приложений для классификации камней на изображении, получаемом с камеры смартфона. Фан и др. в работе [11] используют архитектуру ShuffleNet, предварительно обученную на классическом наборе ImageNet. Используя суммарно более 3600 изображений 30 классов для обучения и проверки своей модели, исследователи достигают доли верных ответов более 97%. При этом время, необходимое для определения типа породы с помощью смартфона, составляет в среднем около 0,6 секунды, что обеспечивает довольно удобное применение на практике.

Описаны также случаи применения сверточных нейронных сетей для контроля качества в горнодобывающей промышленности. В работе [12] Ферейрой и др. исследуется возможность классификации гранитных плит, используя фотографии поверхности. В результате авторы получают 100%-ную точность классификации на требуемые группы.

Сравнение способов использования сверточных нейронных сетей для решения задачи классификации приведено в таблице 1.

Приведенные исследования показывают, что сверточные нейронные сети различной архитектуры могут быть успешно применены для решения множества задач, возникающих в горнодобывающей промышленности. При этом для получения сравнимых с человеком результатов не требуется проведения каких-либо сложных предварительных этапов, достаточно лишь собрать набор данных, разметить его и обучить несколько алгоритмов, чтобы затем выбрать из них наиболее эффективный в конкретной задаче. Разработчикам не требуется какого-либо дорогостоящего оборудования – на современном этапе развития техники можно использовать облачные вычислительные платформы, предоставляющие свои вычислительные мощности бесплатно либо за небольшую плату. Для дальнейшего использования обученного алгоритма достаточно иметь существенно меньшие мощности, возможно даже

Таблица 1. Сравнительный анализ применения сверточных нейронных сетей для классификации
Table 1. Comparative analysis of the application of convolutional neural networks for classification

Статья <i>Paper</i>	Нейронная сеть <i>Neural network</i>	Задача <i>Task</i>	Доля верных ответов в задаче классификации, % <i>Classification accuracy, %</i>
Cheng, 2017 [8]	Разработана Cheng и со-авторами	Классификация зернистости песчаника	98,5
Fan, 2020 [9]	ShuffleNet	Классификация камней по составу	97,6
Ferreira, 2017 [12]	Matlab(CIFAR) Matlab(MNIST)	Классификация гранита по качеству	100,0 96,5
Ran, 2019 [23]	AlexNet GoogLeNet VGG-16 Разработана Ran и со-авторами	Классификация камней по составу	92,8 97,1 94,2 98,0

использование смартфонов. Все это открывает большие возможности для использования современных методов компьютерного зрения даже на небольших производствах.

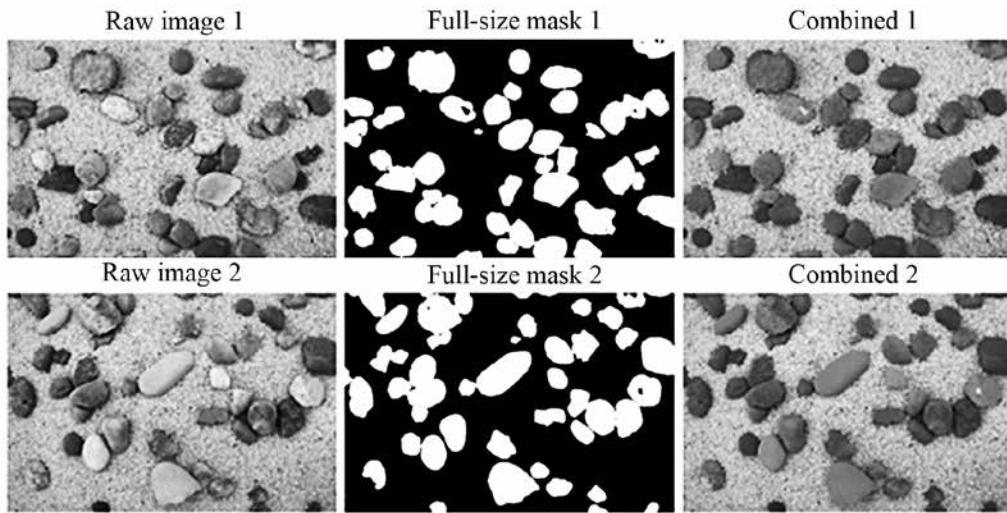
Использование сверточных нейронных сетей для сегментации

Сверточные нейронные сети позволяют не только провести классификацию на группы, но и извлечь из изображения некоторые количественные параметры, что успешно применяется различными исследователями в последние годы. Таким образом, например, может с высокой степенью точности решаться задача определения гранулометрического состава или сортировки объектов по размерам. Для этого нейронную сеть тренируют для решения задачи сегментации камней на изображении, а затем рассчитывают требуемые характеристики, используя результаты, полученные на предыдущем шаге.

При этом можно выделить два принципиально различных подхода к решению данной задачи. В первом из них нейронная сеть решает задачу сегментации, выделяя камни на изображении, но не проводя их разделение на отдельные элементы породы. Полученная таким образом карта сегментации (*segmenta-*

tion map) обрабатывается с использованием методов цифровой обработки изображений (отдельные камни выделяются, их форма аппроксимируется различными математическими функциями). Во втором случае нейронная сеть решает задачу поэлементной сегментации (*instance segmentation*), т. е. разбивка камней на изображении производится самой нейронной сетью (одному камню сопоставляется одно множество пикселей).

Примером успешного применения первого из этих подходов может служить работа Лианга и др. [18]. В ней исследователи использовали одну из самых современных и эффективных архитектур для сегментации – U-Net. Для ее обучения были использованы четыре изображения камней разрешением 3648×2432 . Авторы создали маски для каждого из изображений, разметив их вручную и разрезав на отдельные изображения. Затем были использованы некоторые методы аугментации (дополнения) данных: повороты, отражения, зашумление и изменения яркости. В результате обучения авторы получают точность классификации пикселей более 98%. Затем, используя алгоритм заполнения отверстий (*fill hole algorithm*), выделяются отдельные камни, после чего их форма сглаживается с помощью B-сплайнов (рис. 3).



Источник: [18].

Рис. 3. Пример сегментации

Fig. 3. An example of segmentation

Похожим образом действуют и Дан и др. [10]. В своей работе они исследуют задачу контроля качества асфальто-бетонной смеси. Для осуществления оценки такого рода необходимо оценить размеры частиц асфальта и вычислить их распределение. Исследователи применили для решения данной задачи модифицированную версию алгоритма U-Net (T-U-Net++) и получили итоговый результат сегментации более 96,5%. В описанной работе используется оригинальный метод улучшения качества – полученные во время первичной обработки сверточной нейронной сетью изображения дополняются ручной разметкой данных, после чего модель снова обучается на доработанных данных. Данная методика позволяет достичь роста качества сегментации на несколько процентов, избегая полностью ручной разметки изображений, что позволяет существенно экономить время в процессе предварительной подготовки данных.

Еще один важный пример такого подхода можно обнаружить в работе [29], выполненной Чжоу и др. Авторы рассмотрели задачу сегментации породы на ленте конвейера, применив различные модификации алгоритма

U-Net, в результате было обнаружено, что наибольшей эффективностью обладает вариант MSD-U-Net. С помощью данной архитектуры была получена доля корректно сегментированных пикселей более 93%.

Как было отмечено ранее, некоторым исследователям удалось использовать методы глубокого обучения для сегментации отдельных камней на изображении. Важным примером применения данного метода является работа [24]. Шенком и соавторами была применена архитектура сверточной нейронной сети Mask R-CNN, способная эффективно находить на изображении отдельные экземпляры объектов. Обучение алгоритма было проведено на наборе, состоящем из 1000 размеченных авторами вручную изображений. Отдельные камни на изображении были разделены на два класса – круглые и эллипсоидные, за счет чего впоследствии было вычислено распределение камней по размерам.

Похожим методом действовали Ченг и др. В своей работе [7] они исследовали довольно сложную задачу сегментации кусков цемента на изображении. По мнению авторов, задача похожа на задачу сегментации камней на изображении, однако куски цемента, как пра-

вило, более однородны, чем камни, что может осложнять сегментацию. Для обучения нейронной сети авторы использовали набор из 150 изображений, дополненный методами аугментации данных. Для сегментации была выбрана архитектура HCN, демонстрирующая высокую эффективность в задачах определения границ объектов на изображениях. Полученная в результате доля корректно сегментированных пикселей была оценена более чем в 90%.

Статью [22] Вейдунга и др. можно считать оригинальным подходом к решению задачи сегментации отдельных камней на изображении. В ней авторы использовали сразу две сверточные нейронные сети для сегментации камней на изображении: первая из них была использована для детекции положения камня, т. е. камень выделялся прямоугольной рамкой вдоль своих границ; вторая сеть сегментировала пиксели, относящиеся к камню на каждом отдельном изображении. Далее по полученным данным был вычислен гранулометрический состав имеющейся породы. В результате была получена доля, равная 88,8%.

Янг и соавторы в 2021 г. с помощью сети Mask R-CNN детектировали положение зерен щебня, обводя их прямоугольной рамкой, затем использовали Фурье-анализ для определения границ каждого камня и далее вычисляли коэффициенты лещадности, угловатости и шероховатости. Средняя точность распознавания камней (*AP50*, *AP75*) в данной работе составила 98,9%, однако следует отметить, что обучение нейронной сети проводилось на 20 изображениях с 1030 зернами, а тестирование – всего на 10 изображениях с 451 зерном [28].

Кроме задачи бинарной сегментации, исследователи рассматривают задачу сегментации на несколько классов. Вангом и др. [27] рассмотрен процесс сегментации различных видов минералов на изображениях, полученных методом компьютерной томографии. Авторы использовали для тренировки 7200 изображений и исследовали метрики не-

скольких популярных архитектур сверточных нейронных сетей: SegNet, ResNet и U-Net. Используя SegNet, авторам удалось достичь качества сегментации более 98%.

Каримпоули и др. [15] решали задачу, аналогичную описанной выше, и добились доли верных ответов более 96% в задаче много-классовой сегментации. Примечательно, что для обучения нейронной сети (использована архитектура SegNet) был использован набор данных, состоящий всего из 20 изображений. Используя методы аугментации данных, исследователи сгенерировали датасет из 22 000 изображений, распределенных в отношении 16 000/4000/2000 для обучения, тестирования и валидации соответственно.

Сравнение способов применения сверточных нейронных сетей для решения задачи сегментации приведено в таблице 2.

Помимо измерения доли верно сегментированных пикселей, авторы зачастую использовали и другие метрики, такие как *IoU* и *F1*. Первая из них применяется для измерения качества детекции объектов, а вторая позволяет оценить точность работы классификатора. Данные метрики вычисляются следующим образом:

$$IoU = \frac{AoI}{AoU},$$

где *AoI* – площадь пересечения полученной рамки детекции с реальной;

AoU – площадь объединения полученной рамки детекции с реальной;

$$F1 = \frac{2TP}{2TP + FP + FN},$$

где *TP* – истинно положительные ответы алгоритма;

FP – ложноположительные ответы алгоритма;

FN – ложноотрицательные ответы алгоритма.

Как можно видеть, спектр решаемых сверточными нейронными сетями задач достаточно велик, а достигаемая точность является удовлетворительной для большинства прикладных задач.

Таблица 2. Сравнительный анализ применения сверточных нейронных сетей для сегментации
Table 2. Comparative analysis of the application of convolutional neural networks for segmentation

Статья <i>Paper</i>	Нейронная сеть <i>Neural network</i>	Задача <i>Task</i>	Количество изображений <i>Number of images</i>	Доля верных ответов в задаче сегментации, % <i>Segmentation accuracy, %</i>	Иные метрики <i>Other metrics</i>
Liang, 2019 [18]	U-Net	Определение распределения камней по размерам путем сегментации камней на изображении	170	98	—
Dan, 2021 [10]	T-U-Net++	Определение распределения частиц в асфальто-бетонной смеси	2250	96,5	<i>IoU</i> 0,918
Zhou, 2021 [29]	MSD-U-Net	Определение распределения камней по размерам путем сегментации камней на изображении ленты конвейера	150	93	<i>F1</i> 0,867
Schenk, 2019 [24]	Mask R-CNN	Определение гранулометрического состава по фотографиям взрыва, полученным с дрона	400	97	<i>IoU</i> 0,913
Chen, 2018 [7]	HCN	Сегментация кусков цемента на изображении	150	95	<i>F1</i> 0,949
Qiao, 2021 [22]	U-Net	Определение гранулометрического состава мрамора, гранита и гнейса по изображению	4743	88,8	<i>IoU</i> 0,893
Wang, 2021 [27]	SegNet	Сегментация минералов по 3D-томографии элемента породы	7200	98,7	—
	RezNet			88,4	—
	U-Net			71,9	—
Karimpouli, 2019 [15]	SegNet	Сегментация минералов по 3D-томографии элемента породы	20	96,0	—
Bihani, 2022 [6]	DeepLab-v3+	Сегментация зерен глинистых пород, зерен ила и пор по изображениям с глубины более 1 км, полученным с помощью электронного микроскопа	49	92,0 (зерна глинистых пород); 94,4 (зерна ила); 95,1 (поры)	<i>IoU</i> 0,780 (зерна глинистых пород); 0,944 (зерна ила); 0,951 (поры)
Bai, 2021 [3]	U-Net	Определение гранулометрического состава щебня по изображению	400	96,0	—
Bamford, 2021 [4]	ResNet50	Определение гранулометрического состава	443	—	—
Shu, 2018 [25]	VGG-19	Определение гранулометрического состава	420	89,4	—
Yang, 2021 [28]	Mask R-CNN	Определение гранулометрического состава, в том числе лещадности, угловатости и шероховатости	20	—	<i>AP50</i> 0,989;
					<i>AP75</i> 0,989

Выводы

Развитие технологий компьютерного зрения в горнодобывающей промышленности можно рассматривать как четыре последовательных этапа, на каждом из которых воз-

растала роль применения методов машинного и глубокого обучения.

На первом этапе исследователи применяли методы цифровой обработки изображений вместе с вычислением некоторых численных характеристик.

Среди достоинств данного метода можно выделить следующие:

- простота интерпретации применяемых численных характеристик;
- использование небольших вычислительных мощностей.

К недостаткам данной технологии относятся:

- необходимость вручную задавать требуемые для вычисления характеристики;
- сильная зависимость применяемых методов от условий окружающей среды.

На *втором этапе* к вычислению характеристик изображения стали активно применяться методы машинного обучения, что позволило существенно увеличить точность классификации пикселей. Однако данная технология во многом наследует преимущества и недостатки, изложенные выше.

Третий этап, выделенный в статье, отличается от предыдущих использованием нейронных сетей в комбинации с различными классическими преобразованиями из сферы цифровой обработки сигналов.

Выделим следующие существенные преимущества:

- отсутствие необходимости подбирать вычисляемые признаки вручную;
- высокое качество при небольшом потреблении вычислительных мощностей.

Но технология обладает и существенными недостатками:

- необходимость аккуратной подготовки данных для обучения классификатора;
- необходимость проведения полного цикла подготовки данных и обучения классификатора при каждом незначительном изменении постановки задачи.

Последний – *четвертый этап* характеризуется активным внедрением глубокого обучения. Исследователи и разработчики активно используют сверточные нейронные сети для решения задач машинного зрения. Это открывает принципиально новые возможности для применения искусственного интеллекта, а также дает возможность исправить боль-

шинство отмеченных ранее недостатков. При использовании современных архитектур специалистам не требуется самостоятельно задавать вычисляемые по изображению параметры и проводить глубокий анализ для решения каждой конкретной задачи. Сверточные нейронные сети способны самостоятельно извлекать информацию из предоставленных данных и с высоким уровнем точности решать широкий класс задач, возникающих в горнодобывающей промышленности.

Используемые сети глубокого обучения можно условно разделить на следующие *три группы*.

В первую из них можно включить нейронные сети, решающие задачу классификации. Принцип их работы состоит в автоматическом извлечении некоторых паттернов из изображения на основе заранее известной совокупности правильных ответов. От исследователя требуется лишь обучить веса сверточной нейронной сети, используя для обучения некоторый набор размеченных данных, в котором каждому изображению соответствует определенный класс. Далее обученная модель будет автоматически относить исследуемое изображение к некоторому классу. Принципиальное отличие архитектуры данной группы нейронных сетей состоит в присутствии на выходе специального слоя, который называется *softmax* и осуществляет подсчет вероятности принадлежности изображения к некоторому классу.

Во вторую группу можно отнести нейронные сети, решающие задачу семантической сегментации. Для их обучения исследователю необходимо уже определить принадлежность каждого пикселя на изображении к интересующему классу. Обученная нейронная сеть, в свою очередь, будет определять, к какому классу принадлежит каждый пиксель входного изображения, и возвращать соответствующую маску сегментации. Особенность архитектур данного типа сверточных сетей состоит в использовании большого количества слоев и широкой вариативности размеров входных и выходных данных каждого

слоя. Это позволяет работать на различных масштабах, выделяя один и тот же объект вне зависимости от того, на каком расстоянии он был снят изначально.

К третьей группе нейронных сетей можно отнести сети для сегментации по сущностям (*instance segmentation*). Они способны не только относить пиксели на изображении к определенному классу, но и успешно разделять однотипные объекты между собой. Для этого, как правило, используется комбинированное решение сразу двух задач. Во-первых, нейронной сети, детектирующей объект, т. е. определяющей, в какой области изображения он находится, во-вторых, нейронной сети, решющей задачу сегментации в его области детекции.

Тем не менее, на практике исследователи обычно самостоятельно модифицируют нейронные сети под решаемые задачи и могут использовать различные комбинации нейронных сетей и других методов. Поэтому приведенная классификация имеет весьма условный характер.

Применение методов глубокого обучения имеет следующие существенные достоинства:

- отсутствие необходимости глубокого анализа конкретной задачи – необходимо лишь продемонстрировать алгоритму правильное решение некоторого количества примеров;
- возможность достигать хороших результатов, используя относительно небольшой набор данных, – имеется возможность использовать методы аугментации данных;
- большая устойчивость алгоритма к изменению условий окружающей среды, что опять же может быть достигнуто корректной аугментацией данных;
- простота использования – существует множество готовых архитектур, которые нужно дообучить для решения конкретной задачи на конкретном датасете;
- для развертывания обученного алгоритма не требуется больших вычислительных

мощностей – достаточно аппаратного обеспечения современного домашнего компьютера;

- для обучения алгоритма можно использовать аппаратное обеспечение крупных облачных платформ, и, следовательно, отсутствует необходимость в наличии собственного мощного вычислительного оборудования;
- легкость адаптации алгоритма к конкретному оборудованию;
- простота в переносе алгоритма на другие устройства – достаточно лишь выбрать архитектуру и передать файл, содержащий веса модели.

Однако присутствуют и некоторые недостатки, самые существенные из них заключаются в следующем:

- для обучения алгоритма в некоторых случаях требуется большое количество времени;
- результат работы алгоритма практически невозможно интерпретировать, можно лишь убедиться в его работоспособности;
- нейронная сеть должна быть обучена на всех возможных в жизни случаях, в противном случае в нестандартных условиях она будет неработоспособна.

Как следствие, применение сверточных нейронных сетей лишено основных недостатков технологий компьютерного зрения, отнесенных в данной работе к первым трем этапам. Кроме того, они дают массу преимуществ, которые отсутствовали у систем, основанных на цифровой обработке изображений и применении полно связных нейронных сетей.

Хотя очевидно, что глубокие нейронные сети позволили перейти на качественно более высокий уровень решения задач классификации и сегментации, классические методы машинного обучения применяются в задачах горнодобывающей промышленности до настоящего времени. Так, в работе 2021 г. [14] Иващенко и соавторы вначале по изображению камней анализируют их текстуру, выделяя признаки Харалика, а затем применяют

к этим признакам машины опорных векторов деревья с бустингом AdaBoost и XGBoost, многослойный персепtron и случайный лес для решения задачи классификации. При этом авторы декларируют долю верных ответов (Accuracy), полноту (Recall), точность (Precision) и F1-метрику на уровне более 90%, однако вряд ли можно считать результаты презентативными, поскольку обучение велось на 24 фотографиях, а случайный лес состоял из 10 деревьев. Судя по приведенным рисункам, границы камней достаточно хорошо определяются при помощи признаков Харалика, и из работы не ясно, какой прирост качества дает применение случайного леса.

Среди приложений сверточных нейронных сетей можно выделить множество содержательных задач из сферы горнодобывающей промышленности, таких как определение объемов выпуска продукции, определение зернового состава, содержания нестандартных (например, для щебня – пластинчатых и игловатых) зерен, содержания пыли и глины, насыпной плотности и пустотности и др.

Заключение

Развитие методов компьютерного зрения предоставляет производителям товаров новое поле возможностей, правильное использование которых является необходимым условием конкуренции в современной экономике. Руководителям предприятий и научным сотруд-

никам необходимо координировать свои действия для скорейшего внедрения передовых методов контроля качества сырья и готовой продукции. Важной современной технологией является компьютерное зрение, которое и стало предметом рассмотрения данной статьи.

В работе рассмотрена история развития применения машинного зрения в горнодобывающей промышленности. На базе имеющихся статей по данной тематике проведено разбиение методов на четыре этапа. При этом особый акцент делается на наиболее передовой технологии – сверточных нейронных сетях, способных успешно имитировать некоторые когнитивные функции человека, а иногда и существенно превосходить их. В статье обсуждаются преимущества и недостатки методов, использованных исследователями на различных этапах, демонстрируется существенное превосходство глубокого обучения над традиционными методами и даются прогнозы на будущее исследуемой сферы. Проводится табличное сравнение эффективности сверточных нейронных сетей в широком наборе задач, возникающих в процессе горнодобывающего производства.

Полученные выводы могут быть использованы исследователями для проведения собственных экспериментов на базе изложенных в статье, а также для разработки систем компьютерного зрения, способных качественно решать задачи горнодобывающей промышленности.

Список литературы

1. О промышленном производстве в январе–ноябре 2022 года // Федеральная служба государственной статистики. 28.12.2022. URL: https://rosstat.gov.ru/storage/mediabank/219_28-12-2022.html (дата обращения: 29.01.2023).
2. Bai F., Fan M., Yang H., Dong L. Image segmentation method for coal particle size distribution analysis // Particuology. 2021. Vol. 56. P. 163–170. DOI: 10.1016/j.partic.2020.10.002.
3. Bai H., Li R., Hu X., Chen F., Liao Z. Automated shape analysis and DEM study on graded crushed stone // Advances in Materials Science and Engineering. 2021. Vol. 2021. Article 3463363. DOI: 10.1155/2021/3463363.
4. Bamford T., Esmaeili K., Schoellig A. P. A deep learning approach for rock fragmentation analysis // International Journal of Rock Mechanics and Mining Sciences. 2021. Vol. 145. Article 104839. DOI: 10.1016/j.ijrmms.2021.104839.
5. Barron L., Smith M. L., Prisbrey K. Neural network pattern recognition of blast fragment size distributions // Particulate Science and Technology. 1994. Vol. 12. No. 3. P. 235–242. DOI: 10.1080/02726359408906653.
6. Bihani A., Daigle H., Santos J. E., Landry Ch., Prodanović M., Milliken K. MudrockNet: Semantic segmentation of mudrock SEM images through deep learning // Computers & Geosciences. 2022. Vol. 158. Article 104952. DOI: 10.1016/j.cageo.2021.104952.

7. Chen H., Jin Y., Li G., Chu B. Automated cement fragment image segmentation and distribution estimation via a holistically-nested convolutional network and morphological analysis // Powder Technology. 2018. Vol. 339. P. 306–313. DOI: 10.1016/j.powtec.2018.08.015.
8. Cheng C., Guo W. Rock images classification by using deep convolution neural network // Journal of Physics: Conference Series. 2017. Vol. 887. Article 012089. DOI: 10.1088/1742-6596/887/1/012089.
9. Cheung W., Ferrie F.P., Dimitrakopoulos R., Carayannidis G. Computer vision-based rock modelling // Computing Systems in Engineering. 1992. Vol. 3. No. 5. P. 601–608. DOI: 10.1016/0956-0521(92)90028-H.
10. Dan H.-Ch., Bai G.-W., Zhu Zh.-H. Application of deep learning-based image recognition technology to asphalt-aggregate mixtures: Methodology // Construction and Building Materials. 2021. Vol. 297. Article 123770. DOI: 10.1016/j.conbuildmat.2021.123770.
11. Fan G., Chen, F., Chen D., Li Y., Dong Y. A deep learning model for quick and accurate rock recognition with smartphones // Mobile Information Systems. 2020. Vol. 2020. Article 7462524. DOI: 10.1155/2020/7462524.
12. Ferreira A., Gilson G. Convolutional neural network approaches to granite tiles classification // Expert Systems with Applications. 2017. Vol. 84. P. 1–11. DOI: 10.1016/j.eswa.2017.04.053.
13. Hyslip J., Vallejo L. Fractal analysis of the roughness and size distribution of granular materials // Engineering Geology. 1997. Vol. 48. No. 3–4. P. 231–244. DOI: 10.1016/S0013-7952(97)00046-X.
14. Iwaszenko S., Smoliński A. Texture features for bulk rock material grain boundary segmentation // Journal of King Saud University – Engineering Sciences. 2021. Vol. 33. No. 2. P. 95–103. DOI: 10.1016/j.jksues.2020.03.001.
15. Karimouli S., Tahmasebi P. Segmentation of digital rock images using deep convolutional autoencoder networks // Computers & Geosciences. 2019. Vol. 126. P. 142–150. DOI: 10.1016/j.cageo.2019.02.003.
16. Ko Y.-D., Shang H. A neural network-based soft sensor for particle size distribution using image analysis // Powder Technology. 2011. Vol. 212. No. 2. P. 359–366. DOI: 10.1016/j.powtec.2011.06.013.
17. Lange T. B. Application of machine vision in mining and metallurgical processes // IFAC Proceedings Volumes. 1992. Vol. 25. No. 19. P. 229–233. DOI: 10.1016/S1474-6670(17)49926-5.
18. Liang Z., Nie Zh., An A., Gong J., Wang X. A particle shape extraction and evaluation method using a deep convolutional neural network and digital image processing // Powder Technology. 2019. Vol. 353. P. 156–170. DOI: 10.1016/j.powtec.2019.05.025.
19. Manana R., Artieda J., Catalina J. Ore sorting and artificial vision // IFAC Proceedings Volumes. 1985. Vol. 18. No. 6. P. 235–240. DOI: 10.1016/S1474-6670(17)60515-9.
20. Mkwelo S., Nicolls F., de Jager G. Watershed-based segmentation of rock scenes and proximity-based classification of watershed regions under uncontrolled lighting // SAIEE Africa Research Journal. 2005. Vol. 96. No. 1. P. 28–34. DOI: 10.23919/SAIEE.2005.9488146.
21. Patel A.K., Chatterjee S. Computer vision-based limestone rock-type classification using probabilistic neural network // Geoscience Frontiers. 2016. Vol. 7. No. 1. P. 53–60. DOI: 10.1016/j.gsf.2014.10.005.
22. Qiao W., Zhao Y., Xu Y., Lei Y., Wang Y., Yu Sh., Li H. Deep learning-based pixel-level rock fragment recognition during tunnel excavation using instance segmentation model // Tunnelling and Underground Space Technology. 2021. Vol. 115. Article 104072. DOI: 10.1016/j.tust.2021.104072.
23. Ran X., Xue L., Zhang Y., Liu Z., Sang X., He J. Rock classification from field image patches analyzed using a deep convolutional neural network // Mathematics. 2019. Vol. 7. No. 8. Article 755. DOI: 10.3390/math7080755.
24. Schenck F., Tscharf A., Mayer G., Fraundorfer F. Automatic muck pile characterization from UAV images // ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences. 2019. Vol. IV-2/W5. P. 163–170. DOI: 10.5194/isprs-annals-IV-2-W5-163-2019.
25. Shu L., Osinski G. R., McIsaac K., Wang D. An automatic methodology for analyzing sorting level of rock particles // Computers & Geosciences. 2018. Vol. 120. P. 97–104. DOI: 10.1016/j.cageo.2018.08.001.
26. Tessier J., Duchesne C., Bartolacci G. A machine vision approach to on-line estimation of run-of-mine ore composition on conveyor belts // Minerals Engineering. 2007. Vol. 20. No. 12. P. 1129–1144. DOI: 10.1016/j.mineng.2007.04.009.
27. Wang Y.D., Shabaninejad M., Armstrong R. T., Mostaghimi P. Deep neural networks for improving physical accuracy of 2D and 3D multi-mineral segmentation of rock micro-CT images // Applied Soft Computing. 2021. Vol. 104. Article 107185. DOI: 10.1016/j.asoc.2021.107185.
28. Yang D., Wang X., Zhang H., Yin Zh.-Y., Su D., Xu J. A Mask R-CNN based particle identification for quantitative shape evaluation of granular materials // Powder Technology. 2021. Vol. 392. P. 296–305. DOI: 10.1016/j.powtec.2021.07.005.
29. Zhou X., Gong Q., Liu Y., Yin L. Automatic segmentation of TBM muck images via a deep-learning approach to estimate the size and shape of rock chips // Automation in Construction. 2021. Vol. 126. Article 103685. DOI: 10.1016/j.autcon.2021.103685.

Сведения об авторах

Калашников Владимир Андреевич, ORCID 0000-0001-9701-9872, ассистент, департамент анализа данных и машинного обучения, Финансовый университет при Правительстве Российской Федерации, Москва, Россия, vakalashnikov@fa.ru

Соловьев Владимир Игоревич, ORCID 0000-0003-0338-1227, докт. наук, профессор, генеральный директор, ООО «ЦИАРС»; заведующий кафедрой прикладного искусственного интеллекта, Московский технический университет связи и информатики, Москва, Россия, vs@ciars.ai

Статья поступила 28.10.2022, рассмотрена 06.11.2022, принята 26.11.2022

References

1. *O promyshlennom proizvodstve v yanvare–noyabre 2022 goda* [On industrial production in January–November 2022]. Federal State Statistics Service. 28.12.2022. Available at: https://rosstat.gov.ru/storage/mediabank/219_28-12-2022.html (accessed 29.01.2023).
2. Bai F., Fan M., Yang H., Dong L. Image segmentation method for coal particle size distribution analysis. *Particuology*, 2021, vol.56, pp.163-170. DOI: 10.1016/j.partic.2020.10.002.
3. Bai H., Li R., Hu X., Chen F., Liao Z. Automated shape analysis and DEM study on graded crushed stone. *Advances in Materials Science and Engineering*, 2021, vol.2021, article 3463363. DOI: 10.1155/2021/3463363.
4. Bamford T., Esmaeili K., Schoellig A.P. A deep learning approach for rock fragmentation analysis. *International Journal of Rock Mechanics and Mining Sciences*, 2021, vol.145, article 104839. DOI: 10.1016/j.ijrmms.2021.104839.
5. Barron L., Smith M.L., Prisbrey K. Neural network pattern recognition of blast fragment size distributions. *Particulate Science and Technology*, 1994, vol.12, no.3, pp.235-242. DOI: 10.1080/02726359408906653.
6. Bihani A., Daigle H., Santos J.E., Landry Ch., Prodanović M., Milliken K. MudrockNet: Semantic segmentation of mudrock SEM images through deep learning. *Computers & Geosciences*, 2022, vol.158, article 104952. DOI: 10.1016/j.cageo.2021.104952.
7. Chen H., Jin Y., Li G., Chu B. Automated cement fragment image segmentation and distribution estimation via a holistically-nested convolutional network and morphological analysis. *Powder Technology*, 2018, vol.339, pp.306-313. DOI: 10.1016/j.powtec.2018.08.015.
8. Cheng C., Guo W. Rock images classification by using deep convolution neural network. *Journal of Physics: Conference Series*, 2017, vol.887, article 012089. DOI: 10.1088/1742-6596/887/1/012089.
9. Cheung W., Ferrie F. P., Dimitrakopoulos R., Carayannis G. Computer vision-based rock modelling. *Computing Systems in Engineering*, 1992, vol.3, no.5, pp.601-608. DOI: 10.1016/0956-0521(92)90028-H.
10. Dan H.-Ch., Bai G.-W., Zhu Zh.-H. Application of deep learning-based image recognition technology to asphalt-aggregate mixtures: Methodology. *Construction and Building Materials*, 2021, vol.297, article 123770. DOI: 10.1016/j.conbuildmat.2021.123770.
11. Fan G., Chen, F., Chen D., Li Y., Dong Y. A deep learning model for quick and accurate rock recognition with smartphones. *Mobile Information Systems*, 2020, vol.2020, article 7462524. DOI: 10.1155/2020/7462524.
12. Ferreira A., Gilson G. Convolutional neural network approaches to granite tiles classification. *Expert Systems with Applications*, 2017, vol.84, pp.1-11. DOI: 10.1016/j.eswa.2017.04.053.
13. Hyslip J., Vallejo L. Fractal analysis of the roughness and size distribution of granular materials. *Engineering Geology*, 1997, vol.48, no.3-4, pp.231-244. DOI: 10.1016/S0013-7952(97)00046-X.
14. Iwaszenko S., Smoliński A. Texture features for bulk rock material grain boundary segmentation. *Journal of King Saud University – Engineering Sciences*, 2020, vol.33, no.2, pp.95-103. DOI: 10.1016/j.jksues.2020.03.001.
15. Karimpouli S., Tahmasebi P. Segmentation of digital rock images using deep convolutional autoencoder networks. *Computers & Geosciences*, 2019, vol.126, pp.142-150. DOI: 10.1016/j.cageo.2019.02.003.
16. Ko Y.-D., Shang H. A neural network-based soft sensor for particle size distribution using image analysis. *Powder Technology*, 2011, vol.212, no.2, pp.359-366. DOI: 10.1016/j.powtec.2011.06.013.
17. Lange T. B. Application of machine vision in mining and metallurgical processes. *IFAC Proceedings Volumes*, 1992, vol.25, no.19, pp.229-233. DOI: 10.1016/S1474-6670(17)49926-5.
18. Liang Z., Nie Zh., An A., Gong J., Wang X. A particle shape extraction and evaluation method using a deep convolutional neural network and digital image processing. *Powder Technology*, 2019, vol.353, pp.156-170. DOI: 10.1016/j.powtec.2019.05.025.

19. Manana R., Artieda J., Catalina J. Ore sorting and artificial vision. IFAC Proceedings Volumes, 1985, vol.18, no.6, pp.235-240. DOI: 10.1016/S1474-6670(17)60515-9.
20. Mkwelo S., Nicolls F., Jager G. Watershed-based segmentation of rock scenes and proximity-based classification of watershed regions under uncontrolled lighting. SAIEE Africa Research Journal, 2005, vol.96, no.1, pp.28-34. DOI: 10.23919/SAIEE.2005.9488146.
21. Patel A. K., Chatterjee S. Computer vision-based limestone rock-type classification using probabilistic neural network. Geoscience Frontiers, 2016, vol.7, no.1, pp.53-60. DOI: 10.1016/j.gsf.2014.10.005.
22. Qiao W., Zhao Y., Xu Y., Lei Y., Wang Y., Yu Sh., Li H. Deep learning-based pixel-level rock fragment recognition during tunnel excavation using instance segmentation model. Tunnelling and Underground Space Technology, 2021, vol.115, article 104072. DOI: 10.1016/j.tust.2021.104072.
23. Ran X., Xue L., Zhang Y., Liu Z., Sang X., He J. Rock classification from field image patches analyzed using a deep convolutional neural network. Mathematics, 2019, vol.7, no.8, article 755. DOI: 10.3390/math7080755.
24. Schenk F., Tscharf A., Mayer G., Fraundorfer F. Automatic muck pile characterization from UAV images. ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2019, vol.IV-2/W5, pp.163-170. DOI: 10.5194/isprs-annals-IV-2-W5-163-2019.
25. Shu L., Osinski G.R., McIsaac K., Wang D. An automatic methodology for analyzing sorting level of rock particles. Computers & Geosciences, 2018, vol.120, pp.97-104. DOI: 10.1016/j.cageo.2018.08.001.
26. Tessier J., Duchesne C., Bartolacci G. A machine vision approach to on-line estimation of run-of-mine ore composition on conveyor belts. Minerals Engineering, 2007, vol.20, no.12, pp.1129-1144. DOI: 10.1016/j.mineng.2007.04.009.
27. Wang Y.D., Shabaninejad M., Armstrong R. T., Mostaghimi P. Deep neural networks for improving physical accuracy of 2D and 3D multi-mineral segmentation of rock micro-CT images. Applied Soft Computing, 2021, vol.104, article 107185. DOI: 10.1016/j.asoc.2021.107185.
28. Yang D., Wang X., Zhang H., Yin Zh.-Y., Su D., Xu J. A Mask R-CNN based particle identification for quantitative shape evaluation of granular materials. Powder Technology, 2021, vol.392, pp.296-305. DOI: 10.1016/j.powtec.2021.07.005.
29. Zhou X., Gong Q., Liu Y., Yin L. Automatic segmentation of TBM muck images via a deep-learning approach to estimate the size and shape of rock chips. Automation in Construction, 2021, vol.126, article 103685. DOI: 10.1016/j.autcon.2021.103685.

About the authors

Vladimir A. Kalashnikov, ORCID 0000-0001-9701-9872, Assistant, Data Analysis and Machine Learning Department, Financial University under the Government of the Russian Federation, Moscow, Russia, vakalashnikov@fa.ru
Vladimir I. Soloviev, ORCID 0000-0003-0338-1227, Dr. Sci. (Econ.), Professor, CEO, CIARS LLC; Chair of Applied Artificial Intelligence Department, Moscow Technical University of Communications and Informatics, Moscow, Russia, vs@ciars.ai

Received 28.10.2022, reviewed 06.11.2022, accepted 26.11.2022