

ISSN 1999-4125 (Print)

ISSN 2949-0642 (Online)

Обзорная статья

УДК 622-1/-9

DOI: 10.26730/1999-4125-2025-4-137-144

ОБЗОР СОВРЕМЕННОГО СОСТОЯНИЯ В ОБЛАСТИ ТЕХНОЛОГИЙ МАШИННОГО ОБУЧЕНИЯ, ИСПОЛЬЗУЕМЫХ ПРИ ДОБЫЧЕ И ОБОГАЩЕНИИ ПОЛЕЗНЫХ ИСКОПАЕМЫХ

Линник Юрий Николаевич, Линник Владимир Юрьевич

Государственный университет управления

* для корреспонденции: vy_linnik@guu.ru

Информация о статье

Поступила:

14 апреля 2025 г.

Одобрена после

рецензирования:

22 июня 2025 г.

Принята к публикации:

30 июня 2025 г.

Опубликована:

28 августа 2025 г.

Ключевые слова:

полезные ископаемые,
горнодобывающая
промышленность, уголь,
бурение, добыча, транспорт,
переработка угля, машинное
обучение, глубокое обучение,
обработка сигналов,
компьютерное зрение.

Аннотация.

Целью статьи является обзор современных методов машинного обучения в процессах добычи и переработки твердых полезных ископаемых, в том числе угля. Подчеркивается возрастающая значимость технологий машинного обучения, обусловленная их интеграцией с системами компьютерного зрения и анализа изображений, широко применяемыми в угледобыче Китая и ЕС. Показано, что подобные системы демонстрируют высокую эффективность при решении задач, которые ранее оставались вне досягаемости традиционных подходов, используемых в горной промышленности. Тем не менее, следует отметить, что несмотря на активное внедрение технологий машинного и глубокого обучения горными компаниями, разработка этих технологий осуществляется преимущественно сторонними организациями. Машинное обучение предоставляет значительные возможности для увеличения продуктивности и оптимизации процессов добычи полезных ископаемых, однако доступ к данным о геологических характеристиках месторождений остается ограниченным, что препятствует дальнейшему развитию и внедрению соответствующих технологий. Авторы также акцентируют внимание на необходимости углубленного изучения потенциала машинного обучения в рамках автоматизации производственных операций, повышения уровня охраны труда и снижения экологического ущерба. Несмотря на существующие сложности, перспективы технологий машинного обучения остаются значительными, особенно учитывая рост объемов данных и улучшение алгоритмических решений по обработке информации.

Для цитирования: Линник Ю.Н., Линник В.Ю. Обзор современного состояния в области технологий машинного обучения, используемых при добыче и обогащении полезных ископаемых // Вестник Кузбасского государственного технического университета. 2025. № 4 (170). С. 137-144. DOI: 10.26730/1999-4125-2025-4-137-144, EDN: LCCUOG

Введение

Цифровизация отраслей промышленности в настоящее время стремительно развивается в рамках 4-й промышленной революции или Индустрии 4.0. В этом отношении горнодобывающая промышленность не является исключением. Большие объемы данных, генерируемые в том числе и на предприятиях угольной промышленности, являются движущей силой цифровизации. Знания, содержащиеся в

данных, становятся доступными с помощью машинного обучения, которое развивается в рамках искусственного интеллекта с середины 20-го века. Глубокое обучение, являющееся подмножеством машинного обучения, в последние годы достигло значительных успехов в виде достаточно большого количества программных приложений [1, 2]. В отличие от многих других методов машинного обучения, глубокое обучение использует преимущества

автоматического обнаружения признаков и закономерностей в данных в сочетании с моделирующими структурами, способными отражать очень сложное поведение.

В широком смысле методы глубокого обучения можно разделить на неконтролируемые, контролируемые и гибридные. Неконтролируемые методы обычно используются для извлечения признаков и могут быть объединены с контролируемыми, предназначенными для решения задач регрессии или классификации, для получения гибридных методов. В качестве примеров таких гибридных подходов можно привести предварительное обучение конволюционных нейронных сетей с глубокими автоэнкодерами (автокодировщиками) или многослойных персептронов к нейронным сетям глубокого доверия [3].

Наиболее часто в ресурсодобывающих отраслях находят применение конволюционные нейронные сети (CNN), рекуррентные нейронные сети (RNN) и сети глубокого доверия (DBN). CNN в основном используются в задачах, связанных с компьютерным зрением, таких как классификация изображений, обнаружение объектов, семантическая сегментация и сегментация экземпляров. Сети RNN, включая сети с долговременной краткосрочной памятью (LSTMa), представляют собой методы моделирования последовательности действий, при которых сеть сохраняет прошлую информацию и комбинирует ее с новыми входными данными для составления прогнозов.

Одним из основных недостатков глубокого обучения является то, что для удовлетворительной работы сети в идеале требуется наличие огромного количества обучающих данных. Однако эту проблему можно частично обойти, используя методы трансферного обучения. Было показано, что предварительно обученные сети сами по себе исключительно хорошо работают на наборах данных из новых областей [4, 5] и могут не требовать больших объемов информации для оптимизации [6]. Таким образом, учитывая широкое распространение технологий машинного и глубокого обучения, а также принимая во внимание тот факт, что Национальный проект «Цифровая экономика» в качестве одной из ключевых задач ставит развитие этих технологий в российской промышленности, рассмотрим тенденции развития технологий глубокого обучения в горнодобывающей промышленности.

2. Добыча полезных ископаемых

Последовательность технологических операций, необходимых для добычи полезных ископаемых, обычно включает в себя бурение, взрывные работы, проходческие и очистные

работы, транспортировку и переработку обогащенной продукции.

2.1. Бурение

Новейшие исследования в этой области были направлены на интерпретацию данных, полученных в результате эксплуатационного бурения, с целью получения уточненных оценок характеристик рудного тела. Например, в работе [7] описано применение CNN для оценки некондиционной прочности на сжатие и растяжение, а также угла внутреннего трения породы. В нефтегазовой отрасли был проведен ряд исследований по применению машинного обучения для анализа данных в реальном времени (измерения во время бурения, MWD). Так, в работах [8-10] продемонстрировано преимущество конволюционной глубокой нейронной сети с долговременной краткосрочной памятью по сравнению с традиционными методами при обработке сигналов. Также известны исследования в области структурированного анализа на основе методов обработки и верификации данных, полученных в процессе бурения взрывных скважин, описаны основные особенности сбора «чистых» данных с целью формирования «материнской» обучающей базы для ее последующего использования в алгоритмах машинного обучения [11].

2.2. Взрывные работы

Взрывные работы, как известно, являются основным методом разрушения горных пород при открытой разработке угольных месторождений. Недостаточно проработанный проект взрывных работ может привести к множеству негативных последствий, таких как повышенная вибрация земли, обширная взрывная волна, значительный разлет кусков породы и т. п. Эти негативные эффекты обусловлены тем, что помимо контролируемых параметров (например, расчетная линия наименьшего сопротивления при взрывании, удельный расход взрывчатого вещества, количество заряда взрывчатого вещества и т. д.) и неконтролируемых переменных, таких как свойства взрывающейся горной массы, глубина залегания угольных пластов и др. горные работы в значительной степени зависят от опыта операторов и инженеров, но развитие сенсорных технологий и анализ больших данных позволяют инженерам разрабатывать более эффективные, экономичные и безопасные планы проведения взрывных работ. В статье [12] описаны результаты сравнительных исследований трех типов нейронных сетей для прогнозирования инициированного взрывом воздушно-взрывного избыточного давления в открытом карьере.

При подземной добыче угля слабо контролируемые взрывные работы могут стать причиной серьезных аварий, таких как взрыв

метана и обрушение кровли. В процессе исследования событий, зачастую предшествующих подобным авариям, была разработана модель на основе CNN для определения местоположения источника микросейсмических событий на основе зарегистрированных сейсмических волн.

2.3. Транспортировка

В последнее время в горнодобывающей промышленности все большее распространение получают автономные (беспилотные) транспортные средства, используемые при добыче твердотопливных полезных ископаемых. Требования и правила, относящиеся к транспортным средствам для проведения горных работ, а также условия их движения значительно проще, чем для частных транспортных средств, эксплуатируемых на дорогах общего пользования. Как следствие, эксплуатация автономных грузовых автомобилей, погрузчиков, бульдозеров и экскаваторов за последние несколько лет стала широко распространенной практикой [13]. Аналогичным образом складывается ситуация и с использованием беспилотных летательных аппаратов (БПЛА).

Тем не менее, по-прежнему существует острая необходимость в совершенствовании технологий навигации, машинного зрения, зондирования, обнаружения препятствий и предотвращения столкновений. Так, в работе [14] выявляются ключевые проблемы в области автоматизации землеройных машин и обсуждается потенциальное использование технологий машинного обучения с подкреплением для интеллектуального автоматического управления. Наиболее известным методом обнаружения объектов на основе машинного зрения является метод одновременной локализации и картирования (SLAM). Однако этот алгоритм недостаточно корректно работает в подземных выработках угольных шахт, в условиях повышенной запыленности рабочего пространства, изменяющихся условий освещенности и других обстоятельств. В этой связи была разработана [15, 16] роботизированная система локализации транспортных средств, работающих в подземных условиях, которая позволяет распознавать объекты в режиме реального времени путем применения двоичного хэширования. Помимо задач локализации транспортных средств известны работы по использованию алгоритмов машинного обучения в целях повышения эффективности работы горной техники. В частности, в работе [17] описывается модель перцептрона для прогнозирования периодов работы автосамосвалов без простоя.

Несмотря на широкое использование автономных транспортных средств на шахтных

площадках, во многих случаях присутствие человека по-прежнему необходимо. Например, небольшие фрагменты породы могут стать причиной ложной тревоги и привести к остановке автономных транспортировщиков. С другой стороны, несоблюдение техники безопасности со стороны рабочего или несвоевременное обнаружение человека или транспортного средства может привести к травме или столкновению. В этой связи в работе [18] предложена система распознавания объектов на основе CNN для обнаружения легких транспортных средств и персонала в условиях подземной добычи, что позволило значительно сократить количество ложных срабатываний. Кроме того, аналогичная сетевая архитектура была использована в работе [5] для картирования местности и обнаружения объектов в условиях проведения открытых горных работ.

2.4. Переработка полезных ископаемых.

Переработка добытого сырья является одним из важнейших этапов формирования добавленной стоимости готового продукта. Именно поэтому в этой отрасли нашли свое применение технологии глубокого обучения. Рассмотрим несколько примеров.

2.4.1. Сортировка полезных ископаемых

Автоматическая идентификация свойств добываемых горных пород является важным этапом при решении задач по обогащению полезных ископаемых, в том числе их сортировки по классам крупности и удаления пустой породы. В этой связи горнообогатительные предприятия постоянно развиваются, принимая на вооружение новые технологии, в том числе и технологии глубокого обучения.

В отечественной литературе известны исследования, посвященные управлению процессами добычи и обогащения угля на основе технологий искусственного интеллекта и промышленного интернета вещей. В частности, в работе [19] изложена научно-методическая база и представлен прототип интеллектуальной системы, интегрирующей передовые подходы в области искусственного интеллекта (нейросети, машинное обучение) для повышения эффективности, безопасности и экологичности угольной отрасли России в контексте цифровой трансформации и перехода к Индустрии 4.0 в 2015-2023 гг. Глубокий анализ методов искусственного интеллекта в области обогащения угля, а также описание нейросетевых моделей оптимизации процессов добычи и переработки угля, оценка их эффективности на реальных данных, а также стратегическое планирование внедрения с учетом специфики предприятий, изложено в работе [20, 21].

Известно, что расситовка руды по классам крупности (сортировка) оказывает значительное влияние на их последующую переработку. И если на обогатительных фабриках уголь дробится преимущественно на грохотах и затем сортируется по классам крупности при помощи специальных сит, то при обогащении известняков, мрамора, кварцевого сырья обычно используется фотометрическая сепарация. При этом процесс фотометрической сепарации очень чувствителен к контрастам, например, в отношении цвета кусков руды и их размеров, что важно для осуществления процесса обогащения твердого ископаемого. Поэтому при обогащении полезного ископаемого, в том числе и угля с присутствием пустой породы, с наличием на изображениях различных пород со схожими цветами этот метод, как правило, работает неудовлетворительно. Кроме того, традиционные подходы обычно занимают много времени и требуют значительных усилий при ручной настройке параметров для регулировки контраста и шумоподавления.

Для преодоления недостатков традиционных методов, для сегментации цифровых изображений горных пород применяется конволюционная автоэнкодерная сеть SegNet [22]. При создании достаточного количества изображений для обучения сети была использована техника дополнения данных, а именно гибридное моделирование на основе паттернов и пикселей (HYPPS). При таком подходе CNN выполняет маркировку (сегментацию) попиксельно, то есть каждый пиксель исходного изображения классифицируется либо как «частица», либо как «фон».

Тем не менее, потенциальные возможности применения CNN выходят за рамки задач бинарной классификации, таких как сортировка руды, поскольку некоторые сетевые архитектуры, такие как уже упомянутая SegNet, а также UNet [23] и LinkNet [24], разработаны для семантической сегментации.

Кроме того, известны исследования в области контроля элементного состава угольной золы на основе машинного обучения. В работах [25-28] изучено влияние содержания исходных элементов в модели IPSO-FNN на зольность и обнаружено, что содержание калия является наиболее значительным фактором, влияющим на зольность, что имеет важное значение для онлайн-прогнозирования в режиме реального времени, точного и быстрого определения количества угольной золы.

Благодаря такому подходу нейронные сети могут сегментировать изображения с многокатегорийными объектами. Например, в контексте характеристики руд и пустых пород изображение может состоять из кусков

различного геологического происхождения (уголь, твердые включения, пустая порода), а сами куски обогащаемого твердого ископаемого в свою очередь могут состоять из различных минеральных зерен, отличающихся по цвету и по размеру. Наличие эффективного способа идентификации и подсчета таких частиц могло бы оказаться полезным для многих аспектов горнодобывающей и гражданской промышленности и до сих пор остается открытым исследовательским вопросом.

2.4.2. Дробление

Дробление крупных кусков угля осуществляется на обогатительных фабриках для получения на выходе сырья необходимого класса крупности. При этом неэффективная технология дробления приводит к значительным затратам энергии. Этими процессами достаточно сложно управлять, поэтому и глубокое обучение может привести к созданию более совершенных технологий. Известно [29], что алгоритмы глубокого обучения демонстрируют достаточно адекватные результаты при работе со сложными, нелинейными данными, например, при определении пропущенной или потерянной информации при получении ее от датчиков. Это позволяет использовать глубокое обучение при анализе информации, получаемой от датчиков уровня загруженности дробильных агрегатов. Кроме того, известна модель пятислойного персептрона [30] для прогнозирования уровня загруженности дробильных агрегатов в различные периоды времени. Текущее состояние дробилок отслеживается по многомерным сигналам, поступающим с датчиков, затем преобразуется в двумерные изображения с помощью матриц расстояний, после чего происходит обучение признаков с помощью CNN.

3. Обсуждение

Несмотря на то, что в настоящее время в горной промышленности используются различные архитектуры глубокого обучения, с большим отрывом от других используются конволюционные нейронные сети. Это связано с тем, что в настоящее время основное внимание уделяется анализу данных, получаемых с датчиков, в частности данных на основе изображений, используемых для определения характеристик твердых частиц, изображений, получаемых от БПЛА, а также обработке изображений и многомерных данных временных рядов.

При этом следует отметить, что далеко не все исследования в области глубокого обучения в горнодобывающей промышленности представлены в научной литературе. Большое количество весьма интересных и перспективных решений реальных задач горнодобывающей промышленности с помощью аналитики данных

реализуется в рамках интернет-сообществ для аналитиков данных. Речь идет в первую очередь о таких ресурсах, как Kaggle (<https://www.kaggle.com>) и Uearthed (<https://unearted.solutions>), являющихся площадками, где любой разработчик и специалист по анализу данных может предложить решение той или иной задачи на основе представленных на этих площадках открытых данных. Ряд горнодобывающих и нефтегазовых компаний выпустил наборы данных и разместил их в открытом виде на упомянутых ресурсах, а также сформулировал ряд задач, которые необходимо решить с помощью этих наборов. Метод решения обычно не регламентируется, однако примечательным является тот факт, что именно решения, полученные с помощью методов глубокого обучения, чаще всего занимают первые места во многих случаях. В частности, на ресурсе Uearthed в разное время ставились задачи по обнаружению отсутствующих зубьев ковша в экскаваторах и задачи сортировки руды на основе массива цифровых изображений.

4. Выводы

Резюмируя задачу, сформулированную во введении к статье и заключающуюся в необходимости рассмотрения актуальных тенденций развития технологий глубокого обучения в горнодобывающей промышленности, отметим следующее.

Технологии глубокого обучения активно внедряются в горной промышленности и при добыче полезных ископаемых, что приводит к созданию высоконадежных систем и решений. Как показано в статье, наиболее популярной архитектурой являются конволюционные нейронные сети именно благодаря своей универсальности и способности работать с данными на основе изображений.

Создание цифровых двойников технологических систем и процессов, а также внедрение технологий обработки больших данных продолжают стимулировать развитие и применение глубокого обучения.

Несмотря на то, что цифровизация горнодобывающей промышленности идет полным ходом, отрасль в силу своей специфики чаще перенимает технологии машинного и глубокого обучения, но не лидирует в их развитии, что обусловлено спецификой горнодобывающих компаний, где основной упор в первую очередь делается на исследование и разработку новых технологий добычи полезных ископаемых. Поэтому представление о будущем развитии технологий машинного обучения в добывающих отраслях можно получить лишь на основе анализа текущих тенденций. Все описанные выше рабочие решения стали возможными только благодаря сбору

достаточного количества реальных данных, полученных в реальных условиях, а не в смоделированных средах. В этой связи основной проблемой, которая и будет предметом дальнейших исследований авторов данной статьи, становится не столько решение конкретных задач, сколько процесс сбора достаточного количества реальных исторических данных, что необходимо для обучения нейронной сети. В этой связи именно доступность больших объемов данных является ключевым фактором для разработки и внедрения систем глубокого обучения в горной промышленности.

СПИСОК ЛИТЕРАТУРЫ

1. Бокарев А. И., Дианов В. А., Карташов А. Б., Арутюнян Г. А., Дубинкин Д. М., Пашков Д. А. Статистика отказов высоконагруженных узлов карьерных самосвалов грузоподъемностью 220 тонн // Вестник Кузбасского государственного технического университета. 2024. № 4 (164). С. 23–31. DOI: 10.26730/1999-4125-2024-4-23-31. EDN: BVKEVP
2. Горюнов С. В., Хорешок А. А. Оценка системы технического обслуживания и ремонта карьерных автосамосвалов на угледобывающих предприятиях Кузбасса // Технологическое оборудование для горной и нефтегазовой промышленности : Сборник трудов XXI Международной научно-технической конференции, проведенной в рамках Уральской горнопромышленной декады, Екатеринбург, 06–07 апреля 2023 года / Под общей редакцией Ю. А. Лагуновой. Оргкомитет: Лагунова Ю. А., Калянов А. Е. Екатеринбург : Уральский государственный горный университет, 2023. С. 358–362. EDN UTHNMI.
3. Кудреватых А. В., Фурман А. С., Ащеулов А. С. [и др.] Методы диагностирования фактического технического состояния редуктора мотор-колеса БелАЗ // Вестник Кузбасского государственного технического университета. 2021. № 2(144). С. 23–28. DOI: 10.26730/1999-4125-2021-2-23-28. EDN DLJVZM.
4. Хорешок А. А., Кудреватых А. В., Ащеулов А. С. [и др.] Увеличение ходимости редукторов мотор-колес карьерных самосвалов методом внедрения контроля фактического технического состояния // Горные науки и технологии. 2021. Т. 6. № 4. С. 267–276. DOI: 10.17073/2500-0632-2021-4-267-276. EDN HOKCJD.
5. Шемякин В. В., Стрижков С. А. Аспекты применения метода акустической эмиссии для мониторинга опасных промышленных объектов // В мире неразрушающего контроля. 2004. № 4. С. 16–19.
6. Иванов В. И. Актуальные проблемы АЭ диагностирования // Всероссийская конференция с международным участием «Актуальные проблемы метода акустической эмиссии» (АПМАЭ-2021) Санкт-Петербург, Россия. Сборник материалов. 2021. С. 3.
7. Иванов В. И., Барат В. А. Акустико-эмиссионная диагностика: справ. М. : Д «Спектр», 2017. 368 с.
8. Stepanova L. N., Kabanov S. I., Lebedev E. Y. Acoustic Emission Diagnostics of Freight Car Bogie Cast Pieces // Transportation Research Procedia. Irkutsk-Krasnoyarsk. 2022. Pp. 547–555. DOI: 10.1016/j.trpro.2022.01.089. EDN IFMLZT.
9. Ono K. Structural Health Monitoring of Large

Structures Using Acoustic Emission–Case Histories // Applied Sciences. 2019. № 9(21). 4602. DOI: 10.3390/app9214602.

10. Nuñez A., Kattis S. Effective approaches to remote asset monitoring with acoustic emission // EWGAE35 & ICAE10 Conference on Acoustic Emission Testing, Ljubljana, Slovenia, September 2022. e-Journal of Nondestructive Testing. 2023. Vol. 28(1). DOI: 10.58286/27600.

11. Петерсен Т. Б., Шемякин В. В., Самохвалов А. Б., Курнос Д. А. Черниговский В.Ю., АЭ как комплексный метод мониторинга объектов. Задачи и перспективы // Всероссийская конференция с международным участием «Актуальные проблемы метода акустической эмиссии» (АПМАЭ-2021) Санкт-Петербург, Россия. Сборник материалов. 2021. С. 5–6.

12. Исычко В. Е., Жантуев Р. М., Приходько М. Г. Акустико-эмиссионный контроль // Наука. Новое поколение. Успех : Материалы IV международной научно-практической конференции, Краснодар, 28 апреля 2023 года. Краснодар : Индивидуальный предприниматель Кабанов Виктор Болеславович (Издательство «Новация»), 2023. С. 246–248. EDN VPWFVZ.

13. Швыдкий С. А., Герике Б. Л. Акустико-эмиссионный мониторинг несущих элементов металлоконструкций карьерных автосамосвалов // Научные технологии разработки и использования минеральных ресурсов. 2022. № 8. С. 153–157. EDN GYVRRW.

14. Швыдкий С. А. Акустико-эмиссионный мониторинг на объектах угольной отрасли // Развитие-2023 : Сборник трудов конференции, Кемерово, 11–13 мая 2023 года. Кемерово : ФИЦ УУХ СО РАН, 2023. С. 80–85. EDN PIMCPN.

15. Менчугин А. В., Герике Б. Л., Протасов С. И., Буянкин П. В. Оценка технического состояния несущих металлоконструкций шагающих экскаваторов по параметрам акустико-эмиссионного сигнала // Горное оборудование и электромеханика. 2009. № 5. 2009. С. 25–30.

16. Менчугин А. В., Богомолов И. Д., Буянкин П. В. Применение методов неразрушающего контроля при проведении технического диагностирования металлоконструкций одноковшовых шагающих экскаваторов // Сборник лучших докладов

студентов и аспирантов Кузбасского государственного технического университета. По результатам 51-й студенческой научно-практической конференции. Кемерово : КузГТУ, 2006. С. 77–80.

17. Менчугин А. В., Протасов С. И., Стенин Г. Д. Применение акустико-эмиссионного контроля для оценки технического состояния одноковшовых шагающих экскаваторов // Энергетическая безопасность России. Новые подходы к развитию угольной промышленности: Труды VII международной научно-практической конференции Кемерово : НИЦ ГПИГД им. А. А. Скочинского, ИУУ СО РАН, КузГТУ, ЗАО КВК «ЭкспоСибирь», 2005. С. 79–82.

18. Менчугин А. В., Протасов С. И. Особенности оценки шумов при проведении АЭ контроля стрел карьерных экскаваторов типа драглайн // Безопасность труда в промышленности. 2009. № 3. С. 48–51.

19. Barat V., Marchenkov A., Bardakov V. [et al.] Structural Health Monitoring of Walking Dragline Excavator Using Acoustic Emission // Applied Sciences (Switzerland). 2021. Vol. 11. № 8. DOI: 10.3390/app11083420. EDN TFRJSC.

20. Побегайло П. А., Крицкий Д. Ю., Сазанкова Е. С. К вопросу о выборе методов контроля и оценки состояния металлоконструкций карьерных экскаваторов // Технологическое оборудование для горной и нефтегазовой промышленности : Сборник трудов XXI Международной научно-технической конференции, проведенной в рамках Уральской горнопромышленной декады, Екатеринбург, 06–07 апреля 2023 года / Под общей редакцией Лагуновой Ю. А. Оргкомитет: Лагунова Ю. А., Калянов А. Е. Екатеринбург : Уральский государственный горный университет, 2023. С. 380–387. EDN MZMIMB.

21. Bin Xu, Qi Wu. Stress fatigue crack propagation analysis of crane structure based on acoustic emission // Engineering Failure Analysis. 2020. Vol. 109. 104206. ISSN 1350-6307. DOI: 10.1016/j.engfailanal.2019.104206.

22. Серьезнов А. Н., Степанова Л. Н., Кабанов С. И. [и др.] Акустико-эмиссионный контроль дефектов зоны крепления крыла самолета в условиях полета // Контроль. Диагностика. 2024. Т. 27. № 6(312). С. 18–27. DOI: 10.14489/td.2024.06.pp.018-027. EDN KQUSNJ.

© 2025 Авторы. Эта статья доступна по лицензии Creative Commons «Attribution» («Атрибуция») 4.0 Всемирная (<https://creativecommons.org/licenses/by/4.0/>)

Авторы заявляют об отсутствии конфликта интересов.

Об авторах:

Линник Юрий Николаевич, профессор, ФГБОУ ВО «Государственный университет управления», (109542, Российская Федерация, г. Москва, ул. Рязанский проспект, 99), докт. техн. наук, профессор, ORCID: <https://orcid.org/0000-0003-3968-0026>, e-mail: yn_linnik@guu.ru

Линник Владимир Юрьевич, профессор, ФГБОУ ВО «Государственный университет управления», (109542, Российская Федерация, г. Москва, ул. Рязанский проспект, 99), докт. экон. наук, доцент, ORCID: <https://orcid.org/0000-0001-5130-8222>, e-mail: vy_linnik@mail.ru

Заявленный вклад авторов:

Линник Юрий Николаевич – постановка исследовательской задачи, концептуализация исследования, сбор и анализ данных, выводы, написание текста.

Линник Владимир Юрьевич – научный менеджмент, обзор соответствующей литературы, написание текста

Все авторы прочитали и одобрили окончательный вариант рукописи.

Review article

REVIEW OF THE CURRENT STATE OF MACHINE LEARNING TECHNOLOGIES USED IN MINING AND MINERAL PROCESSING

Yuri N. Linnik, Vladimir Yu. Linnik

State University of Management

* for correspondence: vy_linnik@guu.ru



Article info

Received:

14 April 2025

Accepted for publication:

22 June 2025

Accepted:

30 June 2025

Published:

28 August 2025

Keywords: minerals, mining, coal, drilling, mining, transportation, coal processing, machine learning, deep learning, signal processing, computer vision

Abstract.

The aim of this article is to review modern machine learning (ML) methods applied to the extraction and processing of solid minerals, including coal. The growing significance of ML technologies is emphasized, driven by their integration with computer vision and image analysis systems, which are widely used in coal mining in China and the EU. It is demonstrated that such systems exhibit high efficiency in solving tasks previously beyond the reach of traditional approaches in the mining industry. However, it should be noted that despite the active adoption of machine and deep learning technologies by mining companies, their development is primarily carried out by third-party organizations. Machine learning offers substantial opportunities for increasing productivity and optimizing mineral extraction processes. Yet, access to data on geological characteristics of deposits remains limited, hindering further advancement and implementation of these technologies. The authors also highlight the need for in-depth research into the potential of ML in automating production operations, improving occupational safety, and reducing environmental impact. Despite existing challenges, the prospects for machine learning technologies remain significant, especially given the growing volumes of data and advancements in algorithmic solutions for information processing.

For citation: Linnik Yu.N., Linnik V.Yu. Review of the current state of machine learning technologies used in mining and mineral processing. *Vestnik Kuzbasskogo gosudarstvennogo tekhnicheskogo universiteta*=Bulletin of the Kuzbass State Technical University. 2025; 4(170):137-144. (In Russ., abstract in Eng.). DOI: 10.26730/1999-4125-2025-4-137-144, EDN: LCCUOG

REFERENCES

1. Krizhevsky A., Sutskever I., Hinton Ge. Image Net classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*. 2012; 25. DOI: 10.1145/3065386.
2. Silver D., Schrittwieser J., Simonyan K. Mastering the game of Go without human knowledge. *Nature*. 2017; 550:354–359. DOI: 10.1038/nature24270.
3. Lee C., Priyadarshini P., Gopalakrishnan S., Kaushik R. Training deep spiking convolutional neural networks with STDP-based unsupervised pre-training followed by supervised finetuning. *Frontiers in Neuroscience*. 2018; 435(12). DOI: 10.3389/fnins.2018.00435.
4. Fu Y., Aldrich C. Froth image analysis by use of transfer learning and convolutional neural networks // *Minerals Engineering*. 2018; 115:68–78. DOI: 10.1016/j.mineng.2017.10.005.
5. Bewley A., Upcroft B. From ImageNet to mining: adapting visual object detection with minimal supervision. *Field and Service Robotics: Results of the 10th International Conference*. Cham: Springer International Publishing. 2016; 113:501–514.
6. Fu Y., Aldrich C. Flotation froth image recognition with convolutional neural networks. *Minerals Engineering*. 2019; 132:183–190. DOI: 10.1016/j.mineng.2018.12.011.
7. He M., Zhang Z., Ren J., Huan J., Li G., Chen Y., Li N. Deep convolutional neural network for fast determination of the rock strength parameters using drilling data. *International Journal of Rock Mechanics and Mining Sciences*. 2019; 123. DOI: 10.1016/j.ijrmms.2019.104084.
8. Flegner P., Kačur J., Durdán M., Laciak M. Processing a measured vibroacoustic signal for rock type recognition in rotary drilling technology. *Measurement*. 2019; 134:451–467. DOI: 10.1016/j.measurement.2018.10.090.
9. Bai M., Urtasun R. 2016. Deep watershed transform for instance segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017. DOI: 10.48550/arXiv.1611.08303.
10. Klyuchnikov N., Zaytsev A., Gruzdev A., Ovchinnikov G., Antipova K., Ismailova L., Muravleva E., Burnaev E., Semenikhin A., Cherepanov A., Koryabkin V., Simon I., Tsurgan A., Krasnov F., Koroteev D. Data-driven model for the identification of the rock type at a drilling bit. *Journal of Petroleum Science and Engineering*. 2019; 178:506–516. DOI: 10.1016/j.petrol.2019.03.041.

11. Panina O.V., Belyaev A.M., Zaval'ko N.A., Eremin S.G., Sagina O.A. Primenenie metodov glubokogo mashinnogo obucheniya dlya strukturnogo analiza rudnykh tel i prognozirovaniya optimal'nykh zon dobychi. *Gornaya promyshlennost'*. 2025; (1):177–183. DOI: 10.30686/1609-9192-2025-1-177-183.
12. Guo H., Zhou J., Koopialipoor M., Jahed Armaghani D., Tahir M.M. Deep neural network and whale optimization algorithm to assess flyrock induced by blasting. *Engineering with Computers*. 2021; 37:173–186. DOI: 10.1007/s00366-019-00816-y.
13. Nguyen H., Bui X.-N., Bui H.-B., Mai N.-L. A comparative study of artificial neural networks in predicting blast-induced air-blast overpressure at Deo Nai open-pit coal mine. *Neural Computing and Applications*. 2020; 32(8):3939–3955. DOI: 10.1007/s00521-018-3717-5.
14. Siau K., Hyder Z., Nah F. Use of Artificial Intelligence, Machine Learning, and Autonomous Technologies in the Mining Industry. *Journal of Database Management*. 2018; 30(2):13. DOI: 10.4018/JDM.2019040104.
15. Dadhich S., Bodin U., Andersson U. Key challenges in automation of earth-moving machines. *Automation in Construction*. 2016; 68:212–222. DOI: 10.1016/j.autcon.2016.05.009.
16. Zeng F., Jacobson A., Smith D., Boswell N., Peynot T., Milford M. Enhancing underground visual place recognition with Shannon entropy saliency. *Australasian Conference on Robotics and Automation (ACRA)*. Sydney, NSW, Australia. 2017.
17. Siebert A.O., Miroshnichenko V.V. Application of machine learning algorithms to improve the efficiency of mining equipment. *Universum: Technical Sciences: electronic scientific journal*. 2016; 2(24).
18. Zeng F., Jacobson A., Smith D., Boswell N., Peynot T., Milford M. LookUP: Vision-only real-time precise underground localization for autonomous mining vehicles. *2019 International conference on robotics and automation (ICRA)*. IEEE. 2019. Pp. 1444–1450. DOI: 10.48550/arXiv.1903.08313.
19. Meshcheryakova T.S., Arsakhanova Z.A., Brovkin A.V., Shamuhametova E.S., Bokov Yu.A. Development of an intelligent control system for coal mining and processing processes based on artificial intelligence technologies and the industrial Internet of Things. *Ugol'*. 2024; (12):89–98. (In Russ.). DOI: 10.18796/0041-5790-2024-12-89-98.
20. Krasnyukova N.L., Rozhdestvenskaya I.A., Zubets A.Zh., Bartoshevich I.A., Voronova E.I. The use of neural network technologies to optimize the processes of coal mining and processing in the coal industry. *Ugol'*. 2024; (9):101–108. (In Russ.). DOI: 10.18796/0041-5790-2024-9-101-108.
21. Krasnyukova N., Voronova E., Muravleva T.V., Imamov M., Stepanov A.A. Analysis of geological data of coal deposits using convolutional neural networks with automatic pooling. *Ugol'*. 2024; (7):68–75. (In Russ.). DOI: 10.18796/0041-5790-2024-7-68-75.
22. Badrinarayanan V., Kendall A., Cipolla R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on pattern analysis and machine intelligence*. 2017; 39(12):2481–2495. DOI: 10.1109/TPAMI.2016.2644615.
23. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation. *Medical image computing and computer-assisted intervention – MICCAI 2015: 18th international conference*. Munich, Germany, October 5-9, 2015, proceedings, part III 18. Springer International Publishing, 2015. Pp. 234–241. DOI: 10.48550/arXiv.1505.04597.
24. Chaurasia A., Culurciello E. Linknet: Exploiting encoder representations for efficient semantic segmentation //2017 IEEE visual communications and image processing (VCIP). IEEE. 2017. Pp. 1–4. DOI: 10.1109/VCIP.2017.8305148.
25. Huang J., Li Z., Chen B., Cui S., Lu Z., Dai W., Zhao Y., Duan C., Dong L. Rapid detection of coal ash based on machine learning and X-ray fluorescence. *Journal of Mining Institute*. 2022; (256):663–676. DOI: 10.31897/PMI.2022.89.
26. Wen Z., Zhou C., Pan J. [et al.] Deep learning-based ash content prediction of coal flotation concentrate using convolutional neural network. *Minerals Engineering*. 2021; 174:107251. DOI: 10.1016/j.mineng.2021.107251.
27. Chew J.W., Cocco R.A. Application of machine learning methods to understand and predict circulating fluidized bed riser flow characteristics. *Chemical Engineering Science*. 2020; 217:115503. DOI: 10.1016/j.ces.2020.115503.
28. Zhang Shengli, Tang Jiaxuan, Wang Meng. Challenges and opportunities for the development of China's coal industry under the background of carbon peak and carbon neutrality. *China Coal*. 2022; 48(05):1–5. DOI: 10.19880/j.cnki.ccm.2022.05.001.
29. McCoy J. T., Kroon S., Auret L. Variational autoencoders for missing data imputation with application to a simulated milling circuit. *IFAC-PapersOnLine*. 2018; 51(21):141–146. DOI: 10.1016/j.ifacol.2018.09.406.
30. Baek J., Choi Y. Deep neural network for ore production and crusher utilization prediction of truck haulage system in underground mine. *Applied Sciences*. 2019; 9(19). DOI: 10.3390/app9194180.

© 2025 The Authors. This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0/>). The authors declare no conflict of interest.

About the authors:

Yuriy N. Linnik, professor, State University of Management, (109542, Russian Federation, Moscow, Ryazansky prospect, 99, Ryazansky str.), Dr. Sc. in Engineering, Professor, ORCID: <https://orcid.org/0000-0003-3968-0026>, e-mail: yn_linnik@guu.ru

Vladimir Yu. Linnik, professor, State University of Management, (109542, Russian Federation, Moscow, 99, Ryazansky Prospekt St., Moscow), Dr. Sc. in Economics, Associate Professor, ORCID: <https://orcid.org/0000-0001-5130-8222>, e-mail: vy_linnik@mail.ru.

Contribution of the authors:

Yuriy N. Linnik – research problem statement; conceptualisation of research, data collection and analysis, drawing the conclusions, writing the text.

Vladimir Yu. Linnik – scientific management, reviewing relevant literature, writing the text

All authors have read and approved the final manuscript.

