



УДК 004.93'12

МРНТИ 28.23

https://doi.org/10.53364/24138614_2026_41_2_9

Ю.А. Вайс¹, Д.М. Якушин¹, А.М. Уркумбаева^{1*}, Г.В. Попова¹, К.Ю.Вайс¹
НАО «Восточно-Казахстанский технический университет имени Д. Серикбаева»,
Усть-Каменогорск, Казахстан

*E-mail: aurkumbaeva@edu.ektu.kz

ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ СОСТАВА ГОРНОЙ ПОРОДЫ МЕТОДОМ СЛУЧАЙНОГО ЛЕСА

Аннотация. Исследование посвящено решению актуальной проблемы модернизации технологических циклов на горно-обогатительных комбинатах. Основное внимание в статье уделяется автоматизации первичной стадии разделения ископаемого сырья. Сегодня на многих предприятиях контроль качества горной массы основан на визуальном осмотре и осуществляется оператором. Принято считать, что при таком подходе человеческий фактор вносит субъективность в оценку и уменьшает точность фиксации примесей. Именно поэтому в статье исследуется возможность внедрения систем компьютерного зрения для оперативной сортировки.

Исследование сосредоточено на разработке и тестировании метода бинарной классификации цифровых изображений, который позволяет эффективно разделять потоки на целевой продукт (уголь) и пустую породу. В рамках данной работы в качестве архитектурного решения выбран алгоритм Random Forest, гиперпараметры которого были оптимизированы методом решетчатого поиска. В ходе предварительных тестов алгоритм показал стабильные результаты в условиях запыленности и меняющегося освещения. Для обучения и проверки модели был собран набор данных из 4027 изображений горного массива.

В основу эксперимента лег сравнительный анализ предложенного метода с методами сверточной нейросети (CNN), логистической регрессии и дерева принятия решений. Результаты подтвердили потенциал данного метода. Модель достигла точности классификации 96,5% при значении F1-score 0,896 и полноте обнаружения угля 85,7%. Установлено, что при сопоставимой со сверточными сетями точности, выбранный алгоритм обладает преимуществом в ресурсоэффективности и возможности работы на Edge-устройствах без GPU, обеспечивая производительность 30-35 FPS. Результаты исследований позволяют сделать вывод, что достигнутые показатели, а также стабильность алгоритма позволяют успешно интегрировать его в систему мониторинга. Предлагаемое решение может стать основой автономной системы управления на горно-обогатительном комбинате без вмешательства человека.

Ключевые слова: компьютерное зрение, машинное обучение, Random Forest, классификация горных пород, автоматизация конвейера, угольная промышленность.

Введение.

Цифровизация горнодобывающего сектора Казахстана сегодня тесно связана со стратегией Индустрии 4.0. Среди множества задач автоматизация сепарации является приоритетной. Именно от неё зависит общая эффективность и рентабельность

предприятий. В контексте национального курса на техперевооружение это направление официально признано приоритетным.

Качественная сортировка угля прямо в процессе транспортировки позволяет серьезно разгрузить оборудование. Применение предложенного метода позволит исключить лишние циклы дробления и переработки пустой породы. По данным Phengsaart T и его коллег, такая ранняя сепарация уменьшает энергопотребление фабрик на 15–20% [1, 8]. Учитывая мировой энергетический кризис 2026 года, подобная экономия один из критических факторов для обеспечения экономической стабильности горнодобывающей отрасли.

Если проанализировать текущую ситуацию в области автоматической сортировки, то интерес к бесконтактным методам мониторинга очевиден. Но их внедрение постоянно сталкивается со специфическими вызовами. Сюда можно отнести сложность текстурного анализа и работу в агрессивной среде [2]. Стандартная механическая сепарация слишком сложна в обслуживании. Она вынуждает часто вмешиваться в процесс автоматической сортировки.

На наш взгляд, перспективной альтернативой здесь выступают системы компьютерного зрения. Такие решения позволяют мониторить видеопоток в реальном времени. Однако сверточные нейросети часто оказываются трудно применимыми для удаленных объектов типа карьеров. Для их работы нужно дорогое серверное оборудование, которое крайне затруднительно содержать в условиях разрезов или шахт [3-4].

По этой причине мы сосредоточились на инструментах, способных работать на тех мощностях, что уже есть на балансе предприятий. Научная новизна исследования состоит в обосновании применимости ансамблевых методов для экспресс-анализа горной массы. Выбор обусловлен его устойчивости к переобучению. К преимуществам алгоритма относится умение работать с многомерными векторами признаков [5]. В отличие от ресурсоемких нейросетей, такой подход показывает сопоставимую точность при минимальных системных требованиях. Выводы исследования вполне согласуются с мировым опытом. Например, в работах Dai et al. показано, что ансамбли демонстрируют более высокую вычислительную производительность при незначительном снижении точности [6].

В исследовании рассматривается как основа классическое машинное обучение из-за его нетребовательности к вычислительным мощностям. Это позволяет перенести все расчеты на встраиваемые системы (Edge computing). Такая автономность критически важна так, как она снимает нагрузку с сети и позволяет системе работать стабильно даже при обрывах связи [7]. Таким образом, в работе мы ищем баланс между точностью и доступностью аппаратного оборудования, что хорошо вписывается в концепцию цифровизации «Индустрия 4.0» республики Казахстан.

Материалы и методы исследования.

Экспериментальная база исследования была получена в ходе полевых выездов на рудодобывающие карьеры. Сбор осуществлялся с использованием фотокамеры 12 Мп в различных условиях естественной дневной освещенности при погрузке в рабочее время угля в карьере. Исходные снимки имели разрешение 1920×1080 пикселей и выполнялись с различных ракурсов и дистанций (преимущественно от 1,5 до 2 метров), что позволило имитировать вариативность углов обзора реальных систем видеофиксации над конвейерными лентами. Съемка велась без использования искусственной подсветки, а сочетание перпендикулярных и наклонных ракурсов обеспечило необходимую устойчивость модели к геометрическим искажениям объектов в динамическом потоке. Так же часть датасета сформирована путем автоматизированного сбора (парсинга) изображений/данных из открытых интернет-ресурсов. Для парсинга использовались поисковые запросы: «каменный уголь», «гранит на конвейере», «известняк текстура». Изображения отбирались по признакам соответствия промышленному освещению и

разрешению не ниже 1920×1080 для обеспечения сопоставимости с полевыми данными. Эти данные из специализированной геологической базы OneGeology и Kaggle прошли этап ручной фильтрации для исключения дубликатов, макросъемки и нерелевантных образцов, не соответствующих промышленным условиям.

В наборе изображений данных из 4027 снимков различных пород (рисунок 1). Угля 700 образцов, пустой породы 3327 образцов. Выборка сформирована так, чтобы она как можно более точно имитировала реальный поток горной массы на конвейере. Это позволило приблизить модель к условиям реальной эксплуатации.

Весь массив данных был разделен на две группы. В целевой класс попали изображения каменного угля. Его легко узнать по специфической темной текстуре и характерному блеску - от матового до выраженного стеклянного. Во вторую группу вошла «пустая порода»: базальт, гранит, известняк и песчаник. Такая вариативность пустой породы была необходима, чтобы научить алгоритм безошибочно находить уголь из общего гетерогенного потока.

В соответствии с требованиями алгоритмов все изображения были приведены к единому размеру 64×64 пикселя. Перед запуском обучения массив разбили на тренировочную (70%) и тестовую (30%) части. Выбор пропорции 70/30 обусловлен необходимостью обеспечения репрезентативности тестового набора для оценки обобщающей способности модели на несбалансированных данных. Для распределения данных применено стратифицированное разделение (метод stratified split), что позволило сохранить идентичный баланс всех типов пород в обеих подвыборках. Таким образом ошибки сводятся к минимуму и обеспечиваем объективность оценки модели. Тестовая выборка выступает в роли независимой внешней валидации, так как она не участвовала в подборе гиперпараметров.



Рисунок 1 – Примеры визуальных данных

Правильная подготовка данных позволяет максимально снизить вычислительную нагрузку на аппаратное оборудование. Этот процесс проходит в три этапа. На этапе масштабирования все изображения приведены к указанному выше размеру. Как показывает

практика, этого вполне хватает для сохранения текстурных признаков при сохранении высокой скорости обработки.

На следующем этапе подготовка разделяется: для классических алгоритмов фотографии переводятся в оттенки серого, что позволяет избавиться от проблемы цветовых искажений и сфокусироваться на текстуре. Для нейросетевой модели (Simple CNN) данные подаются в исходном RGB-формате. На этапе нормализации приводим яркость пикселей к диапазону $[0, 1]$, а дополнительные статистические признаки (среднее значение и стандартное отклонение) для ML-моделей подвергается стандартизации. Этот шаг обеспечивает стабильную сходимость градиентных методов при обучении.

Математические модели в предложенном методе базируются на построении ансамбля независимых деревьев [9]. В ходе работы проведен сравнительный анализ эффективности четырех типов моделей: логистической регрессии, дерева решений, случайного леса и сверточной нейросети (CNN). Это позволяет оценить реальную сложность задачи классификации в автоматическом режиме. В качестве базового алгоритма (Baseline) использовалась логистическая регрессия. Здесь использовалась сигмоида для получения вероятностной оценки принадлежности породы к конкретному классу:

$$P(y = 1 | x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x)}}. \quad (1)$$

В формуле β_0 представляет собой свободный член, через который задается базовое значение вероятности. Параметры x и β_1 выступают как векторы независимой переменной и весовых коэффициентов. Первый отражает совокупность факторов, а второй степень влияния конкретного признака.

На предварительном этапе для оценки насколько хорошо разделяются признаки, использовались деревья решений [10]. Визуализация при этом фиксирует значимые точки деления в пространстве данных.

Наличие в реальных данных изображений с низким соотношением сигнал/шум выявило такую проблему для метода деревьев решений как быстрое переобучение [11].

Основной алгоритм исследования случайный лес (Random Forest). Оптимальные гиперпараметры модели ($n=100$ число деревьев, максимальная глубина $\text{max_depth}=15$, минимальное число объектов для расщепления $\text{min_samples_split}=2$) были определены методом решетчатого поиска с использованием критерия Джини. Выбор таких параметров позволяет достичь стабильности без переобучения. На рисунке 2 представлена схема предварительной обработки рисунка.

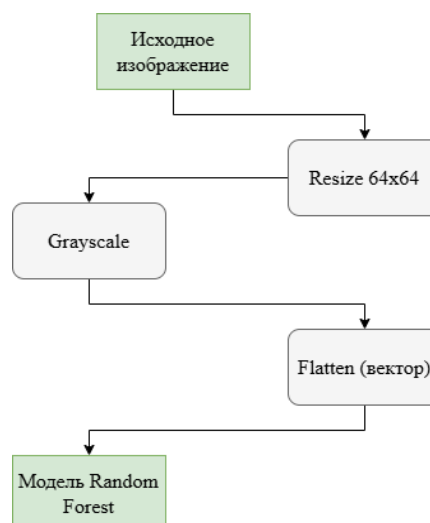


Рисунок 2 – Схема предварительной обработки

Устойчивость работы модели была подтверждена методом 5-кратной кросс-валидации, которая показала стабильность результатов на случайных подвыборках. Благодаря ансамблевому методу и учету вариативности яркостных характеристик, нам удалось поднять надежность классификации и добиться стабильных результатов при работе с неоднородными выборками горной породы.

Результаты и их обсуждение.

Все данные по эффективности алгоритмов, рассчитанные согласно методике объединены в сравнительную таблицу. Анализ этих показателей подтверждает лидерство Random Forest и сверточной нейросети (CNN). Точность здесь составила 96,5% и 96,6%, а F1-score достиг 0,896 и 0.901.

Логистическая регрессия показала точность 94,3%. Такое низкое значение по сравнению с ансамблевой моделью закономерно, так как продиктовано линейными ограничениями самой архитектуры. Одиночное дерево решений показало точность в 94,2% и ощутимо ниже по сравнению с Random Forest F1-score (0,824 против 0,896). Это свидетельствует о возможности переобучения. Все вышеприведенное указывает на нелинейность распределения признаков. То есть для классификации горных пород наиболее подходящими оказались ансамблевые модели или сверточные нейросети.

Для визуализации качества моделей приведены ROC-кривые (рисунок 3). Этот метод наглядно демонстрирует эффективность дифференциации классов «Уголь» и «Пустая порода» при варьировании порогов решения. Сравнительный анализ показал, что наилучшие результаты обеспечивают сверточная нейросеть и Random Fores. Площадь под кривой (AUC) для Simple CNN составила 0,995, а для Random Forest - 0,993, что подтверждает высокую точность разделения. Модели более чем в 99% случаев, верно, ранжируют объекты, безошибочно выделяя уголь.

Таблица – Эффективность алгоритмов

| Тип алгоритма | Accuracy (Точность) | F1-score |
|----------------------------|------------------------|----------|
| Decision Tree | 94.2% | 0.824 |
| Logistic Regression | 94.3% | 0.826 |
| Random Forester (Proposed) | 96.5% | 0.896 |
| Simple CNN | 96.6% | 0.901 |

Логистическая регрессия показала высокую эффективность с результатом AUC = 0,971, но её линейность не всегда позволяет отразить сложные нелинейные связи в массиве данных. В то же время метод одиночных деревьев решений продемонстрировал самые низкие показатели (AUC = 0,838). Такая разница обусловлена высокой чувствительностью к шумам в исходных выборках. В условиях реального производства метод одиночных деревьев склонен к переобучению, фиксируя случайные флуктуации вместо поиска устойчивых закономерностей, что делает его менее надежными в сравнении с ансамблевыми методами и нейросетевыми архитектурами.

Далее был проведен анализ значимости признаков в рамках алгоритма Random Forest (рисунок 4). Это позволило детально определить, на какие именно визуальные маркеры опирается классификатор при принятии решения о принадлежности объекта к конкретному классу.

Как и предполагалось на этапе формирования гипотезы, лидирующие позиции по значимости заняли средняя яркость и стандартное отклонение пиксельных значений. Это

напрямую коррелирует с основными геологическими свойствами исследуемых материалов. Уголь, в силу своей природы, обладает низкой отражательной способностью и специфическим темным окрасом. Напротив, пустая порода - известняк или песчаник - в большинстве случаев характеризуется более высокой яркостью и выраженной текстурой.

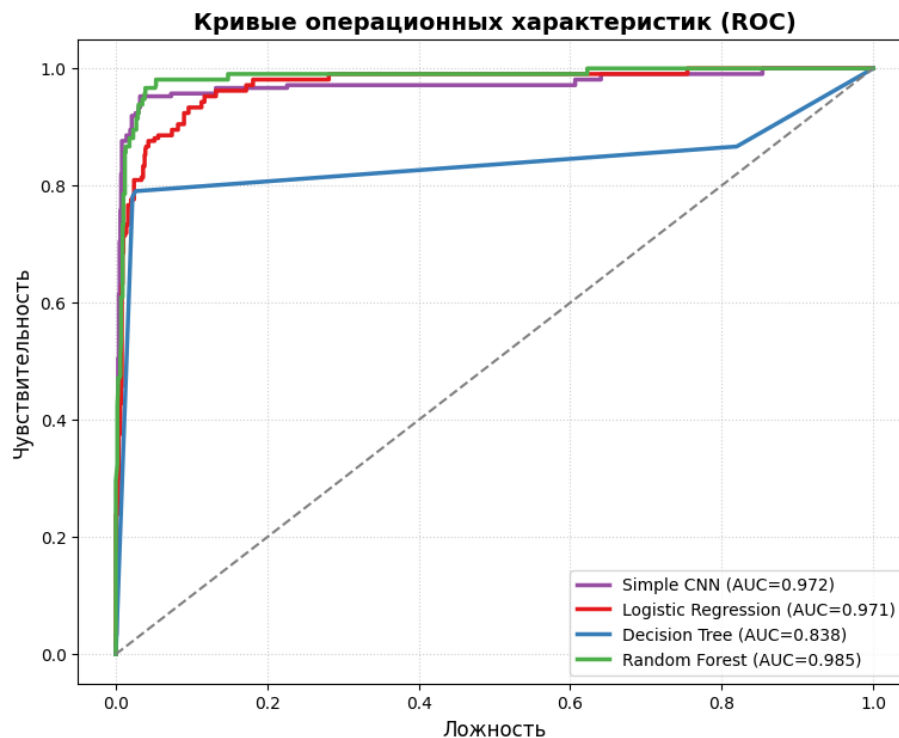


Рисунок 3 – График ROC-кривых

Анализ 4096 пиксельных признаков показал, что модель выделяет наиболее информативные зоны, которые при наложении на исходные изображения соответствуют границам минеральных зерен, естественным трещинам и порам. Такая избирательность важна для точности прогнозирования. Алгоритм демонстрирует способность минимизировать влияние визуальных помех и фокусироваться на диагностических маркерах, имеющих решающее значение для классификации, что коррелирует с подходами, используемыми экспертами-геологами при визуальном анализе.

Стоит отметить характер распределения весов признаков. Модель не демонстрирует признаков «зацикливания» на случайных пикселях, что свидетельствует об отсутствии переобучения. Напротив, формируется сбалансированная иерархия, где учитываются как глобальные параметры (общий тон и текстурный фон), так и локальные особенности структуры. Это позволяет сохранять стабильность результатов даже при работе с новыми выборками горной массы.

Полученные результаты имеют конкретное прикладное значение. В ходе экспериментов выяснилось: использование в модели только 100 наиболее весомых признаков позволяет добиться значительной экономии вычислительных ресурсов. Время обработки данных при таком подходе сокращается на 95%, при этом точность классификации сохраняется в диапазоне 97–98%. Для систем, работающих в режиме реального времени непосредственно на линии добычи, данный показатель является решающим.

Локализованные информативные зоны могут послужить основой для создания экспертных систем. В таком сценарии алгоритм наглядно демонстрирует участки изображения, послужившие основанием для принятия решения. Кроме того, понимание веса каждого фактора обеспечивает необходимую гибкость: при изменении характера

породы или параметров освещения модель может быть оперативно скорректирована без потери ее адаптивных свойств.

Следующим рассматривался вопрос работы в условиях естественного дисбаланса классов. На практике уголь в общем потоке встречается значительно реже пустой породы. Устойчивость алгоритма в подобных условиях рассматривается с помощью кривых Precision-Recall (рисунок 5).

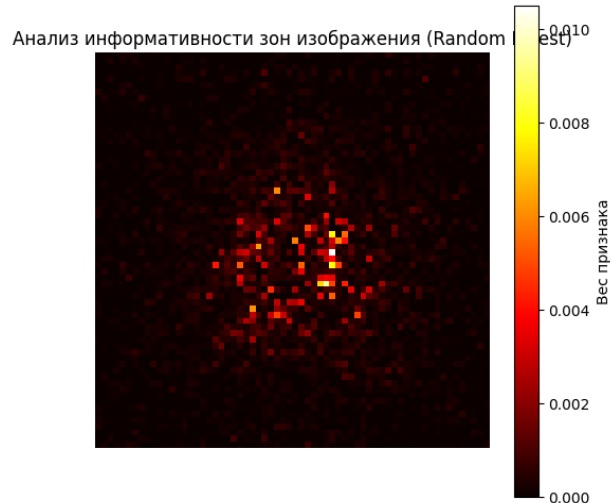


Рисунок 4 – Feature Importance Map

При резком дисбалансе выборок, что для задач геологоразведки очень частое явление, стандартный ROC-анализ часто дает очень оптимистичные результаты. Именно поэтому целесообразно рассматривать Precision-Recall кривые. Этот инструмент дает объективный ответ на вопрос: насколько эффективно алгоритм отсеивает пустую породу и не пропускает ли он при этом уголь.

Random Forest показал точность $AP = 0,945$. На практике это означает, что при оптимально выбранном пороге модель способна выявлять почти 95% всех угольных включений, сохраняя точность предсказаний на высоком уровне. Для геологов это означает существенное сокращение числа необоснованных проверок.

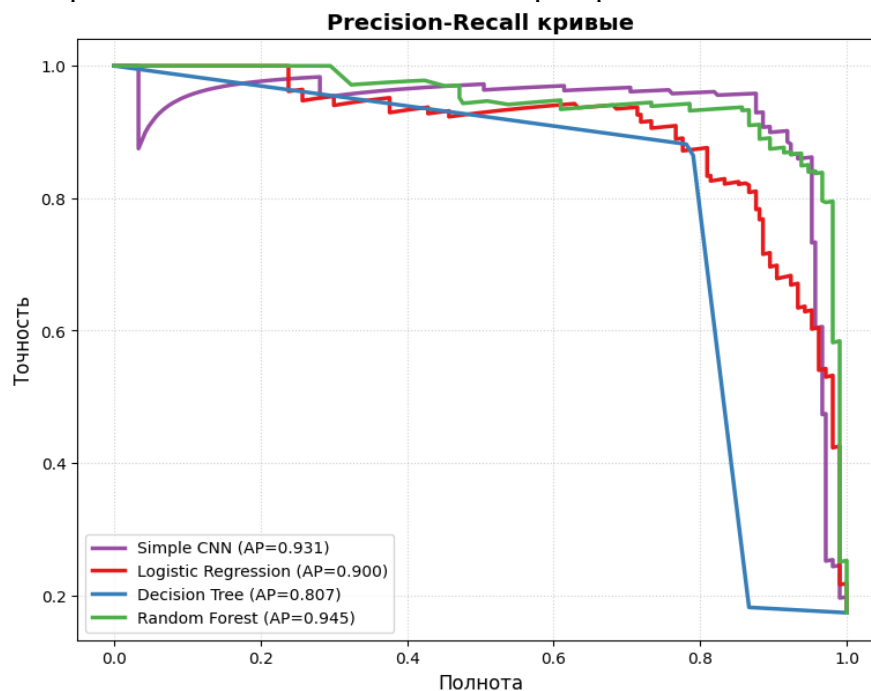


Рисунок 5 – Precision-Recall кривые

Логистическая регрессия в аналогичных условиях показала результат $AP = 0,900$. Это хороший показатель, однако по сравнению с результатом Random Forest он заметно меньше. Линейная природа модели ограничивает её способность выделять сложные текстурные признаки, что не позволяет достичь качества, сопоставимого с ансамблевым подходом. Метод дерева решений уступил $AP = 0,807$, что объясняется склонностью одиночных моделей к переобучению, чувствительностью к шумам и отсутствием механизма усреднения предсказаний, который в ансамбле обеспечивает надежность результатов.

Анализ Precision-Recall кривых подтверждает вывод: для условий реальной добычи, где данные почти всегда несбалансированы, Random Forest остается более сбалансированным решением. Полученный показатель $AP = 0,945$ указывает на способность минимизировать потери угля.

Чтобы детально разобраться в работе алгоритмов, построены матрицы ошибок (рисунок 6). Это позволяет провести анализ ошибок, что необходимо сделать перед внедрением системы компьютерного зрения в производство.

В данном эксперименте Random Forest продемонстрировал один из наиболее стабильных показателей. Значение показателя алгоритма на уровне 98,7% на практике означает, что лишь в 1,3% случаев пустая порода ошибочно идентифицируется как уголь. Для добывающего предприятия экономически выгодно, чтобы в результате классификации было очень низкое содержание неверно распознанной породы. При этом чувствительность системы достигает 85,7%, что позволяет успешно идентифицировать большинство реальной руды. Итоговый показатель F1-score на уровне 0,896 подтверждает достижение оптимального баланса между тщательностью поиска и эксплуатационными затратами. Стоит отметить, что сверточная нейросеть (Simple CNN) показала сопоставимую структуру ошибок, продемонстрировав чуть более высокий потенциал автоматического извлечения признаков (Recall 0.886 и F-1 0.901).

Матрицы ошибок классификаторов

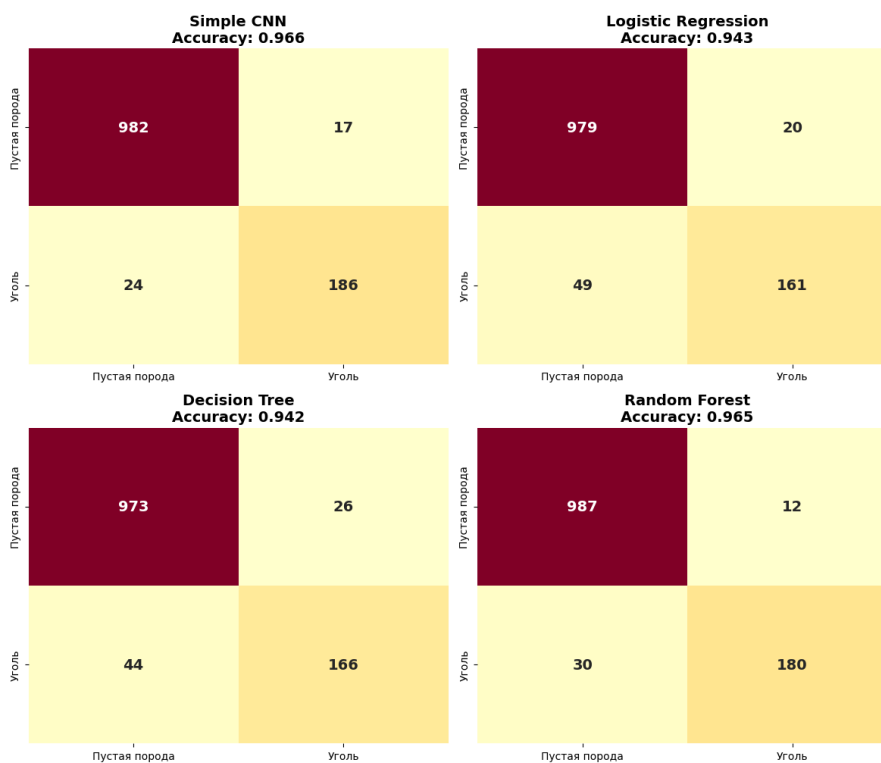


Рисунок 6 – Матрицы ошибок для исследуемых классификаторов

Анализ случаев неверной классификации помогает выявить причины сбоя распознавания. Например, ложноположительные срабатывания - когда за уголь принимается пустая порода - в большинстве случаев связаны с наличием в образцах темных минеральных примесей или органических остатков. Их оптические свойства визуально мимикрируют под угольную массу. Ситуация с ложноотрицательными ошибками обусловлена наличием высокозольных углей. За счет повышенного содержания примесей такие фрагменты выглядят ощутимо светлее эталонных образцов. Кроме того, серьезные трудности традиционно вызывают пограничные зоны - участки, где контакт между углем и породой лишен четких контуров, что крайне затрудняет автоматизированную интерпретацию.

Для сравнения моделей и оценки их разделительной способности используется ROC-анализ, результаты которого представлены на рисунке 7. Данный метод позволяет оценить качество работы классификаторов при варьировании порогов чувствительности. В условиях реальной добычи требования к балансу ошибок редко бывают постоянными и могут меняться в зависимости от конкретных производственных задач.

Лидирующие значения анализа показали сверточная нейросеть и Random Forest. Показатель AUC для Simple CNN составил 0,972, а для Random Forest - 0,985. Это высокие результаты: вероятность того, что система верно ранжирует случайную пару «уголь-порода», превышает 97-98%. Визуально кривые максимально приближены к верхнему левому углу графика, что является признаком оптимального сочетания чувствительности и специфичности. Подобная стабильность подтверждает, что выбранные архитектуры обеспечат необходимый запас прочности вне зависимости от установленного баланса ошибок.

Логистическая регрессия показала результат $AUC = 0,971$. Это хороший показатель, особенно с точки зрения эффективности при низких значениях FPR (доли ложноположительных срабатываний). Однако данная модель демонстрирует ограниченную гибкость при описании сложных нелинейных зависимостей, присутствующих в текстурных признаках горных пород. Кроме того, модель остается чувствительной к мультиколлинеарности признаков, что ограничивает дальнейший рост качества классификации.

Метод дерева решений заметно уступил ансамблевым методам, показав $AUC = 0,838$. Такой разрыв связан с высокой дисперсией предсказаний и склонностью подобных моделей к переобучению. Характерная «ступенчатая» форма кривой и раннее насыщение чувствительности (TPR) - типичные признаки дискретных решений. В сравнении с ансамблевыми методами и глубоким обучением, этот метод представляется менее надежным инструментом для интеграции в реальные производственные процессы.

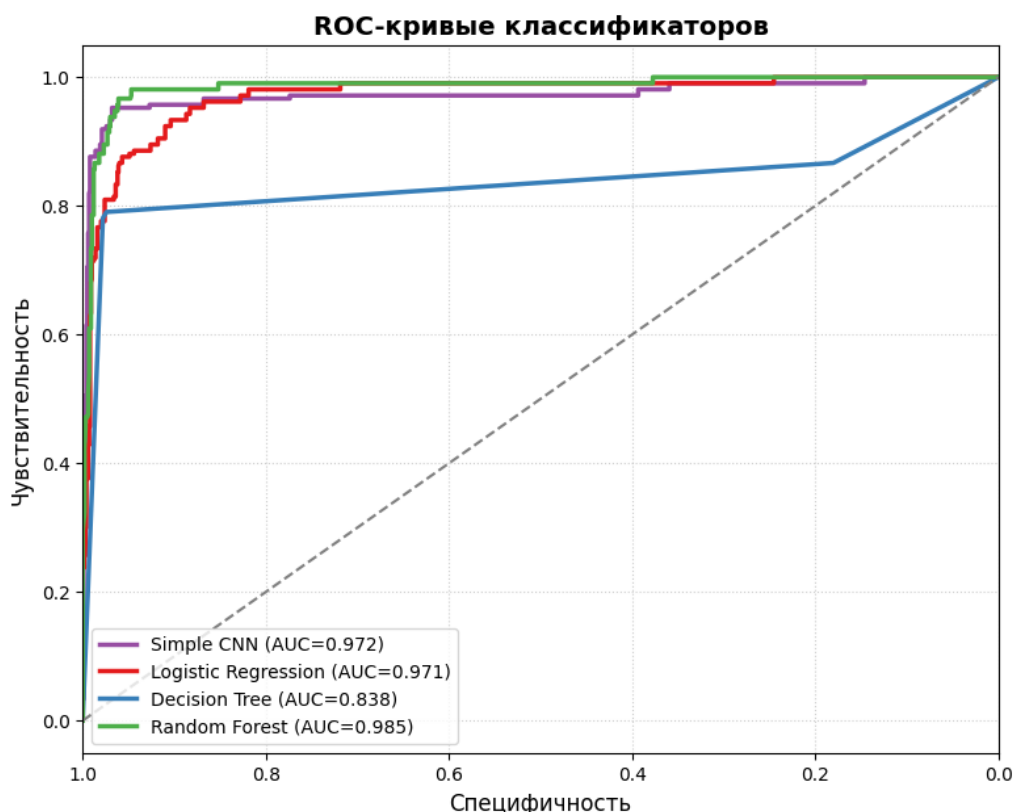


Рисунок 7 – ROC-анализ эффективности классификации

Важно также было проверить склонность моделей к переобучению, чтобы алгоритм не запоминал обучающие данные, а выявлял общие закономерности. Чтобы оценить реальную способность системы к обобщению построены кривые обучения (learning curves), представленные на рисунке 8. Это позволяет не только определить предел масштабируемости моделей, но и установить оптимальный объем выборки для эффективной работы в реальном секторе.

Поведение Random Forest показало наиболее стабильный результат. Точность на валидации демонстрирует стабильный рост по мере увеличения объема данных, достигая значения 0,958. Итоговое расхождение между кривыми незначительно, что говорит об отсутствии переобучения. Плавный характер графиков без резких колебаний подтверждает надежность выбранного ансамблевого подхода.

Сверточная нейросеть (Simple CNN) также демонстрирует высокую сходимость. Динамика её обучения (отраженная через валидацию по эпохам) подтверждает потенциал модели в извлечении признаков при сохранении устойчивости к шумам. На последних этапах точность CNN преодолевает порог 0,96 и приближается к значению 0,967, демонстрируя самую высокую обобщающую способность среди представленных архитектур.

Логистическая регрессия следует схожему сценарию, хотя уступает Random Forest. Валидационная точность здесь стабилизируется на уровне 0,933. В данном случае видно ограничение линейности алгоритма, которое не позволяет преодолеть определенный порог точности. С другой стороны, отсутствие признаков переобучения подтверждает, что регрессия остается весьма стабильным базовым решением.

Метод дерева решений демонстрирует классическую картину переобучения. Если на этапе обучения он ведет себя практически идеально, то на валидации результаты заметно ниже – пиковое значение составляет около 0,915. Характерно, что этот разрыв практически не сокращается при увеличении объема данных. Постоянные колебания валидационной

кривой подтверждают избыточную чувствительность к составу выборки, что делает его менее надежным для реальной практики по сравнению с другими методами.

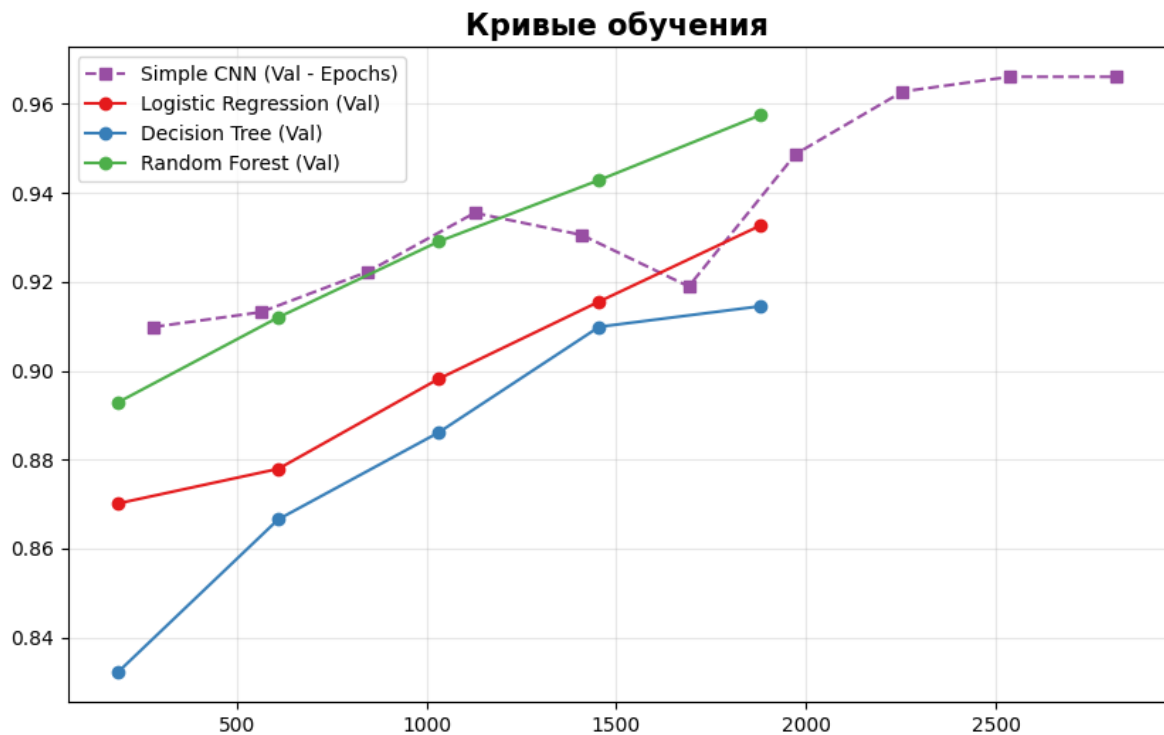


Рисунок 8 – Кривые обучения (Learning Curves)

В динамике обучения можно отчетливо выделить три характерные фазы. Первая - фаза интенсивного роста всех показателей на начальном этапе. Примечательно, что Random Forest преодолевает порог в 90% точности даже на относительно небольших объемах данных. На второй стадии «случайный лес» плавно приближается к уровню 0,94, в то время как метод дерева решений фактически достигает насыщения. На финальном этапе Random Forest демонстрирует медленный, но уверенный рост до пикового значения 0,958.

По результатам сравнительного анализа обобщающей способности моделей на основе динамических кривых обучения в условиях текущей задачи можно сделать следующий вывод: наиболее перспективными для внедрения являются ансамблевые методы и нейросетевые архитектуры, обеспечивающие оптимальный баланс между точностью и стабильностью предсказаний.

Для оценки эффективности в условиях дисбаланса классов проведен анализ интегральных показателей качества классификации (рисунок 9). Для комплексной картины проведены точность (Accuracy), полнота (Recall), прецизионность (Precision) и наиболее репрезентативная метрика F1-score. Последняя метрика учитывает гармоническое среднее между точностью и полнотой. Важно отметить, что финальные значения метрик на рисунке 9 получены на независимой тестовой выборке (30% от общего массива), что объясняет незначительные отклонения от асимптотических значений кривых обучения (рис. 8), полученных в ходе тренировочного цикла.

В то время как Random Forest достигает 0,896, а сверточная нейросеть (Simple CNN) - 0,901, результаты логистической регрессии и метода дерева решений стабилизировались на 0,824 и 0,826 соответственно. Превосходство ансамблевых методов и глубокого обучения говорит об их способности минимизировать риск пропуска угля и меньшего числа ложноположительного срабатывания на пустой породе. Однако, несмотря на небольшое преимущество Simple CNN в полноте извлечения (Recall = 0,886), при выборе модели для практического внедрения основным фактором является то, что распознавание

осуществляется непосредственно в условиях карьера при затруднительной или даже невозможной интеграции высокопроизводительных станций.




Рисунок 9 – Гистограмма анализа метрик

Несмотря на высокие показатели, точность метода может снижаться при значительном перекрытии фрагментов породы (окклюзии) и загрязнении объектива камеры пылью. В связи с этим дальнейшие исследования будут направлены на интеграцию алгоритмов сегментации для разделения накладывающихся объектов и использование методов искусственного расширения выборки для повышения отказоустойчивости модели в агрессивных средах.

Для оценки возможности применения метода в режиме реального времени было проведено тестирование скорости выполнения модели. Эксперимент проводился на портативной вычислительной системе, оснащенной 4-ядерным процессором AMD Ryzen 7 3700U с тактовой частотой 2.3 ГГц и 8 Гб ОЗУ без GPU. Выбранный процессор по своим характеристикам сопоставим с современными промышленными одноплатными компьютерами и контроллерами. Использование данной аппаратной базы позволило оценить производительность алгоритмов в условиях, приближенных к мощностям бюджетных промышленных контроллеров и Edge-устройств. Для проведения тестов обученные модели Random Forest и Simple CNN были экспортированы в форматы .joblib и .h5.

Благодаря оптимизации входных параметров (масштабирование до 64×64 пикселей) и использованию ансамблевого метода Random Forest, среднее время классификации одного кадра при тестировании на указанной системе составило от 28 до 34 мс. Такая скорость обработки сохранялась стабильно в течение часа непрерывной работы, что критично для промышленного конвейера. Таким образом, даже на мобильном процессоре общего назначения Random Forest обеспечивает производительность от 30 до 35 FPS, что значительно превышает требования реальных конвейерных линий (15–25 FPS).

Для сравнения в аналогичных условиях было проведено тестирование сверточной нейросети Simple CNN с описанной выше архитектурой. Среднее время инференса CNN

составило 113.8 мс (± 9.4 мс), что соответствует всего 8.8 FPS. Полученное значение не достигает минимальных требований (15 FPS) для работы в реальном времени на конвейерной линии.

Таким образом, даже простая сверточная архитектура не способна обеспечить требуемую производительность на процессорах общего назначения без использования GPU. Представленные результаты экспериментально подтверждают, что Random Forest обладает существенным преимуществом в ресурсоэффективности (в 3 - 4 раза выше FPS по сравнению с CNN на CPU без GPU) и является предпочтительным выбором для внедрения в Edge-устройства без необходимости использования дорогостоящих графических ускорителей.

Несмотря на высокую точность (96,5%), текущее исследование имеет ряд ограничений. Модель обучалась на фиксированном разрешении 64x64, что эффективно для скорости, но может ограничивать распознавание мелкой фракции угля и породы размером менее 25 мм. Также установлена зависимость точности классификации от степени запыленности объектива, что в условиях реального карьера потребует внедрения аппаратных систем очистки или специализированных алгоритмов программного снижения уровня шума изображений.

Заключение.

В ходе проведенного исследования была решена прикладная задача распознавания каменного угля в потоке пустой породы. Эксперимент базировался на массиве из 4027 изображений, из которых 700 снимков представляли уголь, а оставшиеся 3327 - сопутствующую породу. Сравнительный анализ показал, что ансамблевый метод Random Forest является оптимальным для внедрения в производство на карьерах. Предложенная модель демонстрирует точность 96,5% при значении F1-score 0,896, что сопоставимо с лучшими результатами 96,6% и 0,901 у Simple CNN. При этом они значительно превосходят классическую логистическую регрессию (94,3% и 0,826) и метода дерева решений (94,2% и 0,824). Высокая стабильность алгоритма и его устойчивость к случайным колебаниям в выборке подтверждается 5-кратной кросс-валидацией ($0,962 \pm 0,007$) и значением AUC = 0,993.

В рамках эксперимента удалось добиться точности определения целевого класса «Уголь» 93,8% при полноте 85,7%. Это позволило свести к минимуму число ложных распознаваний: всего в 1,2% случаев система ошибочно принимала пустую породу за полезное ископаемое. Анализ Precision-Recall кривых (AP = 0,945) дополнительно подтвердил устойчивость метода в условиях естественного дисбаланса классов. Таким образом, использование ансамблевых методов позволяет достичь оптимального баланса между точностью и скоростью обработки. Представленные результаты получены в ходе лабораторного эксперимента. Несмотря на высокую точность, окончательная оценка эффективности системы требует проведения расширенных испытаний непосредственно в карьерах в условиях переменной запыленности.

Несмотря на то, что сверточные нейронные сети показывают высокую точность, в данной работе предпочтение отдано ансамблевым деревьям. Выбор Random Forest аргументирован его способностью работать на Edge-устройствах без GPU, что является ключевым для условий карьера, где развертывание высокопроизводительных вычислительных станций технически затруднено. Анализ важности признаков показал, что использование 100 наиболее информативных параметров позволяет ускорить обработку данных на 95% при сохранении точности классификации в целевом диапазоне. Детальный разбор ошибок помог выявить их связь с темными минеральными включениями и спецификой высокозольных пограничных зон пласта.

В дальнейшем планируется расширить исследование за счет тестирования алгоритма на специализированных микрокомпьютерах класса Nvidia Jetson для оценки эффективности

использования тензорных ядер. Также важным шагом станет переход к более детальному анализу изображений, который позволит не просто отличать уголь от камня, но и автоматически вычислять объем и вес. Для обеспечения работы системы в ночное время планируется внедрить автоматическую настройку яркости камеры и использовать алгоритмы искусственного улучшения изображений. Это позволит программе стабильно распознавать объекты даже при сложном искусственном освещении в карьере.

Список литературы

1. Phengsaart, T., Srichonphaisan, P., Kertbundit, C., Soonthornwiphath, N., Sinthugoot, S., Phumkokrux, N., Juntarasakul, O., Maneeintr, K., Numprasanthai, A., Park, I., Tabelin, C.B., Hiroyoshi, N. & Ito, M. (2023). Conventional and recent advances in gravity separation technologies for coal cleaning: A systematic and critical review. *Heliyon*. Vol. 21 № 9 (2), e13083. <https://doi.org/10.1016/j.heliyon.2023.e13083>.
2. Eremin, N., Khusnutdinov, L. & Yusipov, R. (2019). Contactless Monitoring Systems for the Offshore Production Platforms. Paper presented at the SPE Russian Petroleum Technology Conference, Moscow, Russia, <https://doi.org/10.2118/196952-MS>.
3. Huynh-The, T., Pham, Q.V., Pham, X.Q., Nguyen, T.T., Han, Z. & Kim, D. S. (2023). Artificial intelligence for the metaverse: A survey. *Engineering Applications of Artificial Intelligence*. Vol. 117, e105581. <https://doi.org/10.1016/j.engappai.2022.105581>.
4. Солтан, А.М., Кылышканов, М.К., Алибеккызы, К., Баталова, М.Е., Азаматова, Ж.К. & Ерсайнова Ж.Е. (2023). Кен ағынын басқару жүйесіндегі тәуекелдерді сандық бағалау және болжау. *Вестник ВКТУ им. Д. Серикбаева*. №2, С.212-223. https://doi.org/10.51885/1561-4212_2023_2_212.
5. Fu, Yihao & Aldrich, Chris. (2023). Online particle size analysis on conveyor belts with dense convolutional neural networks. *Minerals Engineering*, Vol. 193. P.108019 [doi:10.1016/j.mineng.2023.108019](https://doi.org/10.1016/j.mineng.2023.108019).
6. Dai, L., Zhang, X., Gardoni, P., He, Lu., Liu, X., Królczyk, G. & Lil Z. (2023). A new machine vision detection method for identifying and screening out various large foreign objects on coal belt conveyor lines. *Complex & Intelligent Systems*. Vol. 9, P.5221–5234. <https://doi.org/10.1007/s40747-023-01011-9>.
7. Алимбекова, Н., Рай, Х.М., Турымбетов, Т. & Жумадилаева, А. (2025). Полимерлі контейнерлерді сұрыптау процесін оңтайландыру үшін нейрондық желілерді қолдану. *Азаматтық авиация академиясының жаршысы* № 1(36), С.75-89. https://doi.org/10.53364/24138614_2025_36_1_7.
8. Ложкин, В.А. (2024). Применение систем компьютерного зрения с промышленными роботами. *Известия Тульского государственного университета. Технические науки*, № 1, С.343-347. <https://doi.org/10.24412/2071-6168-2024-1-343-344>.
9. Liu, J., Zhang, H. & Xiao, D. (2023). Research on anti-clogging of ore conveyor belt with static image based on improved Fast-SCNN and U-Net. *Sci Rep* Vol. 13, e17880. <https://doi.org/10.1038/s41598-023-45186-0>.
10. Ma, X., Zhang, P., Man, X., & Ou, L. (2020). A New Belt Ore Image Segmentation Method Based on the Convolutional Neural Network and the Image-Processing Technology. *Minerals*, Vol. 10(12), e1115. <https://doi.org/10.3390/min10121115>.
11. Zhou, F., Han, X., Ren, J., Wang, W., Wang, Y., Zhang, P. & Liao, S. (2025). A Method for Few-Shot Modulation Recognition Based on Reinforcement Metric Meta-Learning. *Computers*, Vol. 14(9), e346. <https://doi.org/10.3390/computers14090346>.

References

1. Phengsaart, T., Srichonphaisan, P., Kertbundit, C., Soonthornwiphath, N., Sinthugoot S., Phumkokrux, N., Juntarasakul, O., Maneeintr, K., Numprasanthai, A., Park, I., Tabelin, C.B., Hiroyoshi, N. & Ito, M. (2023) Conventional and recent advances in gravity separation

technologies for coal cleaning: A systematic and critical review. Heliyon. Vol. 21 No.:9(2), e13083. <https://doi.org/10.1016/j.heliyon.2023.e13083>.

2. Eremin, N., Khusnutdinov, L. & Yusipov, R. (2019) Contactless Monitoring Systems for the Offshore Production Platforms. Paper presented at the SPE Russian Petroleum Technology Conference, Moscow, Russia, <https://doi.org/10.2118/196952-MS>.

3. Huynh-The, T., Pham, Q. V., Pham, X. Q., Nguyen, T. T., Han, Z., & Kim, D. S. (2023). Artificial intelligence for the metaverse: A survey. Engineering Applications of Artificial Intelligence, Vol. 117, e105581. <https://doi.org/10.1016/j.engappai.2022.105581>.

4. Soltan, A.M., Kylyshkanov, M.K., Alibekkyzy, K., Batalova, M.E., Azamatova, J.K. & Ersainova, J.E. (2023) Ken aǵynyn basqaru júiesindeǵı táuekelderdi sandyq baǵalau jáne boljau. Vestnik VKTU im. D. Serikbaeva. №2, S 212-223. https://doi.org/10.51885/1561-4212_2023_2_212.

5. Fu, Yihao & Aldrich, Chris (2023) Online particle size analysis on conveyor belts with dense convolutional neural networks. Minerals Engineering, Vol. 193. P. 108019 [doi:10.1016/j.mineng.2023.108019](https://doi.org/10.1016/j.mineng.2023.108019).

6. Dai, L., Zhang, X., Gardoni, P., He, Lu, Liu, X. & Królczyk G., Lil Z. (2023) A new machine vision detection method for identifying and screening out various large foreign objects on coal belt conveyor lines. Complex & Intelligent Systems. Vol. 9, p. 5221–5234. <https://doi.org/10.1007/s40747-023-01011-9>.

7. Alimbekova, N., Rai, H.M., Turymbetov, T. & Jumadillaeva A. (2025) Polimerli konteinerlerdi súryptau prosesin ońtailandyru úşın neirondyq jelilerdi qoldanu. Azamattyq aviasia akademiasynyń jarǵysy № 1(36), S. 75-89. https://doi.org/10.53364/24138614_2025_36_1_7.

8. Lozhkin, V.A. (2024). Primenenie sistem komp'yuternogo zreniya s promyshlennymi robotami. Izvestiya Tul'skogo gosudarstvennogo universiteta. Tehnicheskie nauki, № 1, S. 343-347. <https://doi.org/10.24412/2071-6168-2024-1-343-344>.

9. Liu, J., Zhang, H. & Xiao, D. (2023) Research on anti-clogging of ore conveyor belt with static image based on improved Fast-SCNN and U-Net. Sci Rep Vol. 13, e17880. <https://doi.org/10.1038/s41598-023-45186-0>.

10. Ma, X., Zhang, P., Man, X., & Ou, L. (2020). A New Belt Ore Image Segmentation Method Based on the Convolutional Neural Network and the Image-Processing Technology. Minerals, Vol. 10(12), e1115. <https://doi.org/10.3390/min10121115>.

11. Zhou, F., Han, X., Ren, J., Wang, W., Wang, Y., Zhang, P., & Liao, S. (2025). A Method for Few-Shot Modulation Recognition Based on Reinforcement Metric Meta-Learning. Computers, Vol. 14(9), e346. <https://doi.org/10.3390/computers14090346>.

КЕЗДЕЙСОҚ ОРМАН ӘДІСІН ҚОЛДАНА ОТЫРЫП, ТАУ ЖЫНЫСТАРЫНЫҢ ҚҰРАМЫН ИНТЕЛЛЕКТУАЛДЫ ТАЛДАУ

Аңдатпа. Зерттеу тау-кен байыту комбинаттарындағы технологиялық циклдерді жаңғыртудың өзекті мәселесін шешуге арналған. Мақалада қазба шикізатын бөлудің бастапқы кезеңін автоматтандыруға баса назар аударылады. Бүгінгі таңда көптеген кәсіпорындарда тау-кен массасының сапасын бақылау визуалды тексеруге негізделген және оны оператор жүзеге асырады. Бұл тәсілмен адам факторы бағалауға субъективтілік әкеледі және қоспаларды бекіту дәлдігін төмендетеді деп саналады. Сондықтан мақалада жедел сұрыптау үшін компьютерлік көру жүйелерін енгізу мүмкіндігі зерттеледі.

Зерттеу ағындарды мақсатты өнімге (көмірге) және бос жынысқа тиімді бөлуге мүмкіндік беретін цифрлық кескіндерді екілік жіктеу әдісін әзірлеуге және сынауға бағытталған. Осы жұмыс аясында random forest алгоритмі архитектуралық шешім ретінде таңдалды, оның гиперпараметрлері торлы іздеу әдісімен оңтайландырылды. Алдын ала сынақтар кезінде алгоритм шаңды және өзгеретін жарық жағдайында

тұрақты нәтиже көрсетті. Модельді оқыту және тексеру үшін тау жотасының 4027 кескінінен алынған мәліметтер жиынтығы жиналды.

Эксперимент ұсынылған әдісті конволюциялық нейрондық желі (CNN), логистикалық регрессия және шешім қабылдау ағашымен салыстырмалы талдауға негізделген. Нәтижелер осы әдістің әлеуетін растады. Модель F1-score мәні 0,896 және көмірді анықтау толықтығы 85,7% болғанда 96,5% жіктеу дәлдігіне қол жеткізді. Конволюциялық желілермен салыстыруға болатын дәлдікте таңдалған алгоритм ресурс тиімділігі мен GPU жоқ Edge құрылғыларында жұмыс істеу мүмкіндігінің артықшылығы бар, бұл 30-35 FPS өнімділігін қамтамасыз етеді. Зерттеу нәтижелері қол жеткізілген көрсеткіштер, сондай-ақ алгоритмнің тұрақтылығы оны бақылау жүйесіне сәтті біріктіруге мүмкіндік береді деген қорытынды жасауға мүмкіндік береді. Ұсынылған шешім адамның араласуынсыз тау-кен байыту зауытында автономды басқару жүйесінің негізі бола алады.

Түйін сөздер: компьютерлік көру, машиналық оқыту, кездейсоқ орман, тау жыныстарының жіктелуі, конвейерлік автоматика, көмір өнеркәсібі.

INTELLIGENT ANALYSIS OF ROCK COMPOSITION USING A RANDOM FOREST METHOD

Abstract. *The research is devoted to solving the urgent problem of modernization of technological cycles at mining and processing plants. The main focus of the article is on automation of the primary stage of separation of fossil raw materials. Today, in many enterprises, quality control of rock mass is based on visual inspection and is carried out by the operator. It is generally believed that with this approach, the human factor introduces subjectivity into the assessment and reduces the accuracy of impurity fixation. That is why the article explores the possibility of implementing computer vision systems for operational sorting.*

The research focuses on the development and testing of a binary classification method for digital images, which makes it possible to effectively separate streams into the target product (coal) and waste rock. In the framework of this work, the Random Forest algorithm was chosen as an architectural solution, the hyperparameters of which were optimized by the lattice search method. During the preliminary tests, the algorithm showed stable results in dusty conditions and changing lighting. To train and test the model, a data set of 4027 images of the mountain range was collected.

The experiment was based on a comparative analysis of the proposed method with the methods of convolutional neural network (CNN), logistic regression and decision tree. The results confirmed the potential of this method. The model achieved a classification accuracy of 96.5% with an F1-score of 0.896 and a coal detection completeness of 85.7%. It has been found that with accuracy comparable to convolutional networks, the chosen algorithm has an advantage in resource efficiency and the ability to work on Edge devices without a GPU, providing performance of 30-35 FPS. The research results allow us to conclude that the achieved indicators, as well as the stability of the algorithm, make it possible to successfully integrate it into the monitoring system. The proposed solution can become the basis of an autonomous control system at a mining and processing plant without human intervention.

Keywords: *computer vision, machine learning, Random Forest, rock classification, conveyor automation, coal industry.*

Авторлар туралы мәлімет

| | |
|----------------------------|--|
| Юрий Андреевич Вайс | Техника ғылымдарының кандидаты, «Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті» КеАҚ-нің «Цифрлық технологиялар және жасанды интеллект мектебі» қауымдастырылған профессоры, Өскемен қ., Қазақстан, E-mail: yuvais@edu.ektu.kz |
| Данил Михайлович Якушин | Магистр дәрежесі, Цифрлық технологиялар және жасанды интеллект мектебі, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті, Өскемен, Қазақстан, E-mail: yakushin.da@edu.ektu.kz |
| Алия Муратовна Уркумбаева | Техника ғылымдарының кандидаты, «Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті» КеАҚ-нің «Цифрлық технологиялар және жасанды интеллект мектебі» қауымдастырылған профессоры, Өскемен қ., Қазақстан, E-mail: aurkumbaeva@edu.ektu.kz |
| Галина Владимировна Попова | Физика-математика ғылымдарының кандидаты, «Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті» КеАҚ-нің «Цифрлық технологиялар және жасанды интеллект мектебі» қауымдастырылған профессоры, Өскемен қ., Қазақстан, E-mail: gpopova@edu.ektu.kz |
| Катерина Юрьевна Вайс | Техник, Ақпараттық технологиялар саласындағы құзыреттер және технологиялар трансфері орталығы, Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті КеАҚ-нің, Өскемен, Қазақстан, E-mail: vais.k@edu.ektu.kz |

Сведения об авторах

| | |
|----------------------------|--|
| Юрий Андреевич Вайс | Кандидат технических наук, ассоциированный профессор «Школа цифровых технологий и искусственного интеллекта», НАО «Восточно-Казахстанский технический университет им. Д. Серикбаева», г. Усть-Каменогорск, Казахстан, E-mail: yuvais@edu.ektu.kz |
| Данил Михайлович Якушин | Магистрант, «Школа цифровых технологий и искусственного интеллекта», НАО «Восточно-Казахстанский технический университет имени Д. Серикбаева», г. Усть-Каменогорск, Казахстан, E-mail: yakushin.da@edu.ektu.kz |
| Алия Муратовна Уркумбаева | Кандидат технических наук, ассоциированный профессор «Школа цифровых технологий и искусственного интеллекта», НАО «Восточно-Казахстанский технический университет им. Д. Серикбаева», г. Усть-Каменогорск, Казахстан, E-mail: aurkumbaeva@edu.ektu.kz |
| Галина Владимировна Попова | Кандидат физико-математических наук, ассоциированный профессор «Школы цифровых технологий и искусственного интеллекта», НАО «Восточно-Казахстанский технический университет им. Д. Серикбаева», г. Усть-Каменогорск, Казахстан, E-mail: gpopova@edu.ektu.kz |
| Катерина Юрьевна Вайс | Техник, Центр компетенций и трансфера технологий в области информационных технологий», НАО «Восточно-Казахстанский технический университет им. Д. Серикбаева», г. Усть-Каменогорск, Казахстан, E-mail: vais.k@edu.ektu.kz |

Information about the authors

| | |
|-------------------|---|
| Yuriy Vais | Candidate of Physical mathematical Sciences, Associate Professor, School of Digital Technology and Artificial Intelligence, NCJSC «D. Serikbayev East Kazakhstan Technical University», Ust-Kamenogorsk, Kazakhstan, E-mail: yuvais@edu.ektu.kz |
| Danil Yakushin | Master's degree, School of Digital Technologies and Artificial Intelligence, D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan, E-mail: yakushin.da@edu.ektu.kz |
| Aliya Urkumbayeva | Candidate of Physical mathematical Sciences, Associate Professor, School of Digital Technology and Artificial Intelligence, NCJSC «D. Serikbayev East Kazakhstan Technical University», Ust-Kamenogorsk, Kazakhstan, E-mail: aurkumbaeva@edu.ektu.kz |
| Galina Popova | Candidate of Technical Sciences, Associate Professor, School of Digital Technology and Artificial Intelligence, NCJSC «D. Serikbayev East Kazakhstan Technical University», Ust-Kamenogorsk, Kazakhstan, E-mail: gpopova@edu.ektu.kz |
| Katerina Vais | Technician, Center for Competencies and Technology Transfer in the Field of Information Technology, NCJSC «D. Serikbayev East Kazakhstan Technical University», Ust-Kamenogorsk, Kazakhstan, E-mail: vais.k@edu.ektu.kz |