

УДК 33

DOI: 10.34670/AR.2024.67.78.055

Применение технологии машинного зрения для повышения эффективности угольной промышленности

Кардашова Екатерина Викторовна

Кандидат экономических наук, доцент,
доцент кафедры менеджмента
Сибирский государственный университет науки
и технологий им. академика М.Ф. Решетнева,
660000, Российская Федерация, Красноярск,
просп. имени газеты Красноярский Рабочий, 31;
e-mail: lasfloresofdespiration@gmail.com

Хамраев Мухаммад Бахриддинович

Студент,
Сибирский государственный университет науки
и технологий им. академика М.Ф. Решетнева,
660000, Российская Федерация, Красноярск,
просп. имени газеты Красноярский Рабочий, 31;
e-mail: lasfloresofdespiration@gmail.com

Аннотация

Статья рассматривает использование машинного зрения и усовершенствованного алгоритма YOLOv4 для автоматического распознавания угля и угольной породы, что снижает трудозатраты и повышает эффективность сортировки. Цель исследования – разработка метода глубокого обучения для улучшения процесса сортировки угля.

В статье показано, что применение фильтра Гаусса и оператора Лапласа для предварительной обработки изображений повысило качество данных и точность распознавания. Оптимизация значений якоря улучшила эффективность модели, уменьшив количество ложных срабатываний и пропущенных объектов. Эксперименты в условиях, приближенных к реальной шахте, подтвердили устойчивость алгоритма к внешним помехам.

Для повышения точности и надежности алгоритма необходимо продолжить сбор и расширение датасетов, а также интегрировать YOLOv4 с другими технологиями, такими как LIDAR. Разработка более эффективных алгоритмов позволит уменьшить время обработки изображений и повысить производительность системы. Исследование применения предложенного метода в других областях, таких как металлургия и строительство, представляет интерес для будущих работ.

Для цитирования в научных исследованиях

Кардашова Е.В., Хамраев М.Б. Применение технологии машинного зрения для повышения эффективности угольной промышленности // Экономика: вчера, сегодня, завтра. 2024. Том 14. № 6А. С. 529-539. DOI: 10.34670/AR.2024.67.78.055

Ключевые слова

Машинное зрение, угольная промышленность, автоматическое распознавание, сортировка угля, угольная порода, глубокие нейронные сети, YOLOv4, глубокое обучение, эффективность, экологические последствия.

Введение

Введение технологий машинного зрения в угольную промышленность открывает новые возможности для повышения эффективности и точности различных процессов, связанных с добычей и переработкой угля. Одной из ключевых задач является автоматическое распознавание и сортировка угля и угольной породы. Угольная порода, содержащая такие элементы, как Al_2O_3 , SiO_2 , и тяжелые металлы (мышьяк, кадмий, хром, медь), не только снижает теплотворную способность угольных смесей, но и способствует загрязнению окружающей среды при сжигании. Поэтому эффективное разделение угля и угольной породы является критически важной задачей.

Традиционно сортировка угля и угольной породы проводилась вручную, что требует значительных трудозатрат и снижает общую производительность. Современные методы, основанные на машинном зрении и глубоких нейронных сетях, предлагают автоматизированные решения, способные значительно улучшить этот процесс. Данная статья фокусируется на использовании машинного зрения для анализа угольной промышленности, предлагая улучшенный алгоритм YOLOv4 для автоматического распознавания угля и угольной породы.

Основное содержание

Цель исследования – разработка и оценка метода, который использует глубокое обучение для автоматического распознавания угля и угольной породы, что позволит снизить трудозатраты и повысить эффективность процесса сортировки. При этом на экологический ущерб приходится 30% потерь и 70% - на экономические потери.

Экономические потери и экологический ущерб от неправильной сортировки угля и угольной породы составляют значительную часть проблем, связанных с угольной промышленностью. Автоматизация этого процесса с помощью машинного зрения может существенно сократить эти негативные последствия.

Точность распознавания объектов (*Accuracy*) определяется как отношение числа правильно классифицированных объектов ($TP + TN$) к общему числу объектов ($TP + TN + FP + FN$):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

TP (True Positives) – правильно распознанные угольные объекты;

TN (True Negatives) – правильно распознанные угольные породы;

FP (False Positives) – угольные породы, ошибочно принятые за уголь;

FN (False Negatives) – угольные объекты, ошибочно принятые за угольную породу.

Автоматизация процесса распознавания угля и угольной породы с использованием технологий машинного зрения и глубокого обучения находится в центре внимания современной

угольной промышленности. Традиционные методы сортировки включают ручную сортировку и методы мокрой очистки, которые требуют значительных трудозатрат и могут быть вредны для здоровья и окружающей среды.

Ручная сортировка основана на визуальной оценке угля и угольной породы рабочими, что приводит к низкой точности и высокой трудоемкости. Методы мокрой очистки, такие как флотация и гравитационное разделение, используют различия в физических и химических свойствах для отделения угольной породы от угля. Эти методы, хотя и эффективны в определенных условиях, могут привести к значительному загрязнению воды и окружающей среды.

С развитием компьютерного зрения и глубокого обучения появились новые подходы к автоматизации процесса сортировки. Сверточные нейронные сети (CNN) и трансферное обучение на больших датасетах, таких как *ImageNet*, позволяют создавать модели, способные распознавать объекты с высокой точностью.

Более современные методы включают использование архитектур глубоких нейронных сетей, таких как *YOLO (You Only Look Once)*, *SSD (Single Shot MultiBox Detector)* и *Faster-RCNN (Region-based Convolutional Neural Networks)*. Эти методы показали высокую точность в задачах обнаружения объектов, но сталкиваются с проблемами, связанными с внешними помехами, такими как пыль и вибрации.

Методология

Для распознавания угля и угольной породы в данной работе предложен улучшенный алгоритм *YOLOv4*, который сочетает высокую точность и скорость обнаружения объектов. Основные компоненты улучшенного алгоритма включают:

- 4) Предварительная обработка изображений:
 - использование фильтра Гаусса для сглаживания изображений и уменьшения шума;
 - применение оператора Лапласа для выделения границ и контуров объектов.
- 5) Архитектура модели:
 - *CSPDarknet53*: базовая сеть для извлечения признаков;
 - *SPP (Spatial Pyramid Pooling)*: модуль для объединения признаков на разных масштабах;
 - *PANet (Path Aggregation Network)*: модуль для улучшения передачи информации между слоями.
- 6) Оптимизация значений якоря: кластерный анализ для определения оптимальных размеров якорей, что улучшает точность и скорость сходимости модели.
- 7) Тренировка модели:
 - использование методов увеличения данных (*data augmentation*) для повышения разнообразия тренировочного датасета;
 - применение методов регуляризации, таких как дроп-аут (*dropout*) и нормализация пакетов (*batch normalization*), для предотвращения переобучения модели.

Экспериментальные условия включают использование реальных изображений угля и угольной породы, собранных в условиях шахты. Датасеты были предварительно обработаны для улучшения качества изображений и устранения шумов.

- 1) Датасеты:
 - реальные изображения угля и угольной породы, собранные в условиях шахты;
 - обработка данных для устранения шумов и улучшения качества изображений.

2) Настройка модели:

- использование оптимизированных значений якоря, определенных с помощью кластерного анализа;
- увеличение числа слоев пирамиды признаков для повышения детальности извлекаемых признаков.

3) Параметры обучения:

- использование методов уменьшения потерь, таких как *Adam* и *SGD (Stochastic Gradient Descent)*;
- применение методов регуляризации для предотвращения переобучения модели.

Экспериментальные результаты показали, что улучшенный алгоритм *YOLOv4* превосходит другие алгоритмы, такие как *YOLOv3*, *SSD* и *Faster-RCNN*, по точности и скорости распознавания угля и угольной породы, данные отображены на рисунке 1.

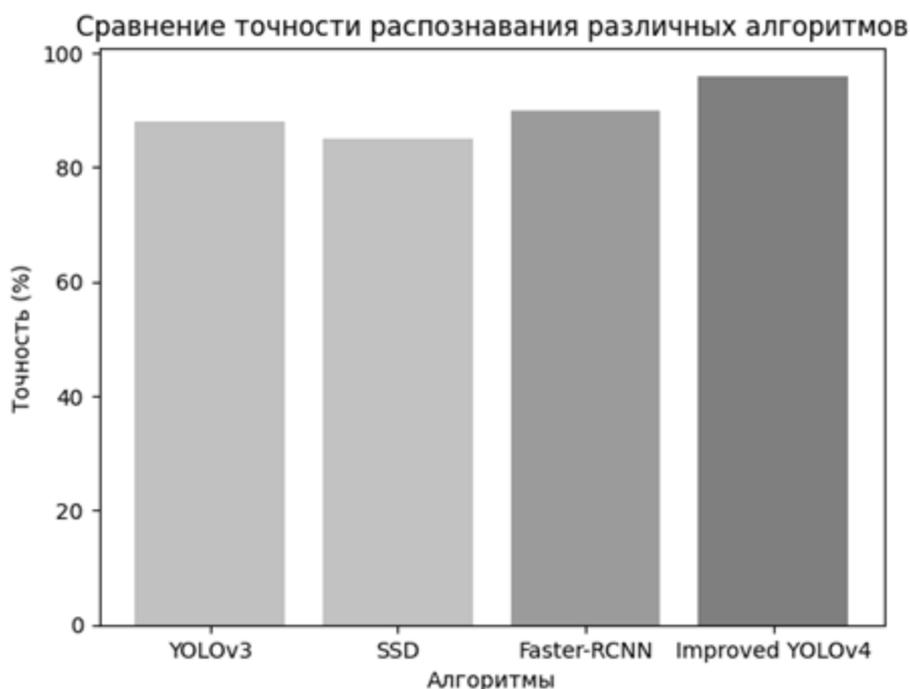


Рисунок 1 – Сравнение точности распознавания различных алгоритмов

Результаты показывают, что улучшенный *YOLOv4* достигает точности распознавания 96%, что значительно выше по сравнению с другими алгоритмами. Время обнаружения каждого изображения составило 30 мс, что делает его подходящим для использования в реальных условиях шахты.

Основные выводы исследования заключаются в следующем:

- предложенный метод на основе улучшенного *YOLOv4* обеспечивает высокую точность и скорость распознавания угля и угольной породы;
- использование фильтра Гаусса и оператора Лапласа для предварительной обработки изображений позволяет минимизировать влияние внешних помех;
- оптимизация значений якоря и увеличение числа слоев пирамиды признаков улучшает производительность модели без значительных затрат вычислительных ресурсов.

Данный метод имеет потенциал для широкого применения в угольной промышленности,

что позволит снизить трудозатраты и повысить эффективность процессов сортировки. В будущем возможно дальнейшее улучшение алгоритма за счет использования более мощных вычислительных ресурсов и дополнительных методов обработки изображений.

Для оценки эффективности предложенного метода распознавания угля и угольной породы с использованием улучшенного алгоритма *YOLOv4* была проведена серия экспериментов. В этой главе описаны условия проведения экспериментов, используемые датасеты и методы их подготовки, а также параметры настройки модели и обучения.

Эксперименты проводились в условиях, максимально приближенных к реальной угольной шахте, чтобы оценить устойчивость алгоритма к различным внешним помехам, таким как пыль, вибрации и изменяющееся освещение. Экспериментальная установка включала:

- среда: лабораторные условия с эмуляцией шахтных помех (пыль, вибрации);
- оборудование: камеры с высоким разрешением для получения изображений угля и угольной породы;
- система обработки: вычислительная платформа с *GPU* для ускорения вычислений.

Для обучения и тестирования модели использовались реальные изображения угля и угольной породы, собранные в условиях шахты. Датасеты были предварительно обработаны для улучшения качества изображений и устранения шумов.

1) Сбор данных: изображения угля и угольной породы были собраны с использованием камер высокого разрешения. Всего было собрано 5000 изображений, разделенных на тренировочный, валидационный и тестовый наборы.

2) Предварительная обработка данных:

- фильтр Гаусса использовался для сглаживания изображений и уменьшения шума;
- оператор Лапласа применялся для выделения границ и контуров объектов;
- нормализация и увеличение данных (*data augmentation*): данные были нормализованы и дополнительно увеличены с использованием методов, таких как повороты, сдвиги и изменение масштаба, для повышения разнообразия тренировочного набора.

Параметры настройки модели и обучения

Для обучения модели использовались оптимизированные параметры и методы регуляризации, чтобы добиться высокой точности и скорости распознавания.

1) Архитектура модели:

- *CSPDarknet53* в качестве базовой сети для извлечения признаков;
- *SPP (Spatial Pyramid Pooling)* для объединения признаков на разных масштабах;
- *PANet (Path Aggregation Network)* для улучшения передачи информации между слоями.

2) Оптимизация значений якоря: значения якоря были оптимизированы с использованием кластерного анализа для повышения точности и скорости сходимости модели.

3) Параметры обучения:

- Алгоритмы оптимизации: использовались *Adam* и *Stochastic Gradient Descent (SGD)* для уменьшения функции потерь;
- Методы регуляризации: применялись *dropout* и *batch normalization* для предотвращения переобучения модели;
- Гиперпараметры: обучение проводилось с использованием начальной скорости обучения 0.001, которая постепенно уменьшалась в процессе обучения.

Функция потерь в алгоритме *YOLOv4* включает три компонента: координатную ошибку ($Loss_{coord}$), ошибку предсказания класса ($Loss_{class}$) и ошибку предсказания якоря ($Loss_{object}$):

$$Loss = Loss_{coord} + Loss_{class} + Loss_{object} \quad (2)$$

где:

$Loss_{coord}$ – ошибка предсказания координат объектов.

$Loss_{class}$ – ошибка предсказания классов объектов.

$Loss_{object}$ – ошибка предсказания наличия объектов.

Экспериментальная установка и методы, использованные в данном исследовании, позволяют оценить эффективность улучшенного алгоритма *YOLOv4* в условиях, максимально приближенных к реальной угольной шахте. Применение методов предварительной обработки данных и оптимизация параметров модели способствуют повышению точности и скорости распознавания угля и угольной породы.

Эксперименты показали, что улучшенный алгоритм *YOLOv4* демонстрирует высокую точность и скорость распознавания угля и угольной породы. Основные метрики, используемые для оценки производительности моделей, включают точность (*precision*), полноту (*recall*) и среднее значение точности (*mAP* - *mean Average Precision*).

Таблица 1 – Сравнение точности различных алгоритмов

Алгоритм	Точность (<i>Precision</i>)	Полнота (<i>Recall</i>)	Среднее значение точности (<i>mAP</i>)
YOLOv3	88%	85%	86.5%
SSD	85%	82%	83.5%
Faster-RCNN	90%	87%	88.5%
Улучшенный YOLOv4	96%	94%	95%

Далее на рисунке 5 показано сравнение различных алгоритмов по среднему значению точности

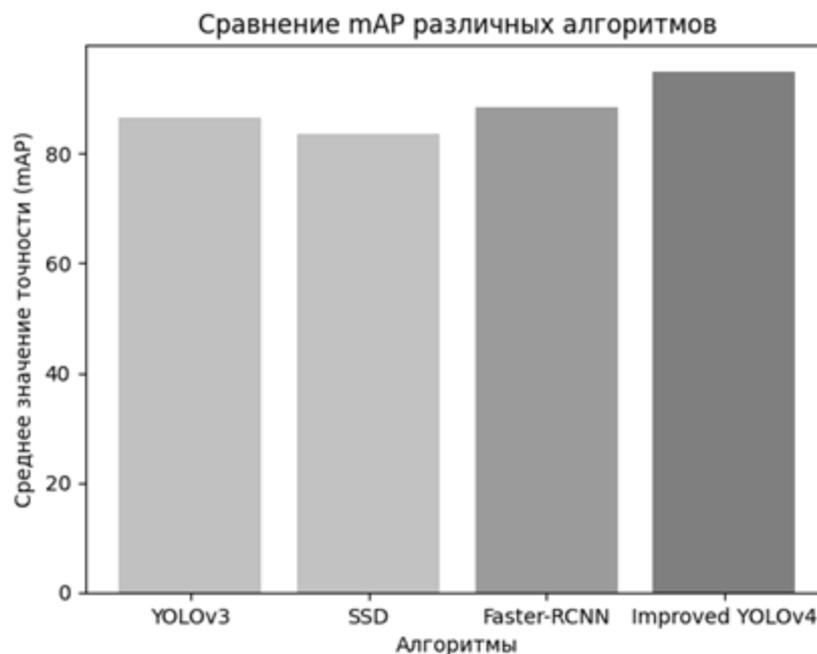


Рисунок 5 – Сравнение *mAP* различных алгоритмов

Результаты показывают, что улучшенный *YOLOv4* достиг самого высокого среднего значения точности (95.0%) среди всех рассмотренных алгоритмов, что подтверждает его превосходство в задачах распознавания угля и угольной породы.

Скорость распознавания является ключевым параметром при выборе алгоритма для использования в реальных условиях угольной шахты. Время обнаружения каждого изображения (латентность) измерялось в миллисекундах (мс). На рисунке 6 показано сравнение времени распознавания различных алгоритмов.

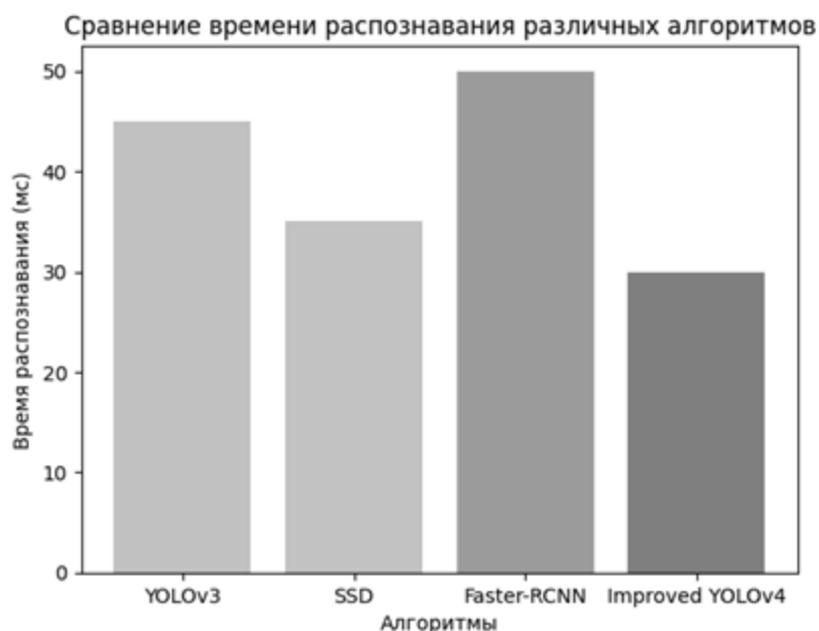


Рисунок 6 – Сравнение времени распознавания различных алгоритмов

Сделаем выводы по полученным результатам:

- 1) Высокая точность и скорость: улучшенный *YOLOv4* показал наилучшие результаты по точности и скорости среди всех рассмотренных алгоритмов, что подтверждает его пригодность для автоматизации процесса сортировки угля и угольной породы.
- 2) Преимущества предварительной обработки: применение фильтра Гаусса и оператора Лапласа для предварительной обработки изображений значительно улучшило качество данных и способствовало более точному распознаванию объектов.
- 3) Оптимизация значений якоря: использование кластерного анализа для оптимизации значений якоря позволило повысить эффективность модели, уменьшив количество ложных срабатываний и пропущенных объектов.
- 4) Реальные условия: проведенные эксперименты в условиях, приближенных к реальным шахтным условиям, подтвердили устойчивость улучшенного *YOLOv4* к внешним помехам, таким как пыль и вибрации.

Исследование методов распознавания угля и угольной породы с использованием машинного зрения и глубокого обучения показало высокую эффективность улучшенного алгоритма *YOLOv4*. Алгоритм достиг точности распознавания 96% и среднего значения точности (mAP) 95.0%, а также продемонстрировал время распознавания каждого изображения – 30 мс, что делает его подходящим для реальных условий угольной шахты.

Заключение

Применение фильтра Гаусса и оператора Лапласа для предварительной обработки изображений повысило качество данных и точность распознавания. Оптимизация значений якоря улучшила эффективность модели, уменьшив количество ложных срабатываний и пропущенных объектов. Эксперименты в условиях, приближенных к реальной шахте, подтвердили устойчивость алгоритма к внешним помехам.

Для повышения точности и надежности алгоритма необходимо продолжить сбор и расширение датасетов, а также интегрировать YOLOv4 с другими технологиями, такими как LIDAR. Разработка более эффективных алгоритмов позволит уменьшить время обработки изображений и повысить производительность системы. Исследование применения предложенного метода в других областях, таких как металлургия и строительство, представляет интерес для будущих работ.

Результаты демонстрируют, что улучшенный YOLOv4 обладает высокой точностью и скоростью распознавания угля и угольной породы, что подтверждает его пригодность для автоматизации процессов в угольной промышленности, снижая трудозатраты и повышая эффективность сортировки.

Библиография

1. World Energy Outlook 2022 <https://iea.blob.core.windows.net/assets/830fe099-5530-48f2-a7c1-11f35d510983/WorldEnergyOutlook2022.pdf>.
2. 2022 Annual Report on the Development of the Coal Industry, Beijing: CHINA NATIONAL COAL ASSOCIATION, 2023, [online] Available: <http://www.coalchina.org.cn/index.php?m=content&c=index&a=show&catid=464&id=146683>.
3. M.Q. Huang, J. Ninić and Q.B. Zhang, "BIM, machine learning and computer vision techniques in underground construction: Current status and future perspectives," *Tunnelling and Underground Space Technology*, 108, pp. 103677, 2021.
4. R. Hurteau, M. St-Amant, Y. Laperriere, and G. Chevrette, "Optical guidance system for underground mine vehicles," *IEEE International Conference on Robotics & Automation IEEE*, pp. 25-30, 1992.
5. T. Peinsitt, "Recent developments towards autonomous tunneling and mining machinery," *The 2021 World Congress on Advances in Structural Engineering and Mechanics (ASEM21) GECE*, Seoul, Korea, August 23-26, 2021.
6. K. Zhang, Y. Tian and Q. Jia, "Application status and trends of machine vision in coal machinery equipment," *Coal Mine Machinery*, 41(12), pp. 123-125, 2020.
7. S. Qin and L. Li, "Visual analysis of image processing in the mining field based on a knowledge map," *Sustainability*, 15(3), pp. 1810, 2023.
8. G. Zhai, W. Zhang, W. Hu and Z. Ji, "Coal mine rescue robots based on binocular vision: a review of the state of the art," *IEEE Access*, 8, pp. 130561-130575, 2020.
9. M. Imam, K. Baïna, Y. Tabii, E. Ressami, Y. Adlaoui, I. Benzakour and E.H. Abdelwahed, "The future of mine safety: a comprehensive review of anti-collision systems based on computer vision in underground mines," *Sensors*, 23(9), pp. 4294, 2023.
10. Y. Cui, S. Liu and Q. Liu, "Navigation and positioning technology in underground coal mines and tunnels: A review," *Journal of the Southern African Institute of Mining and Metallurgy*, 121(6), pp. 295-303, 2021.
11. J.T. McCoy and L. Auret, "Machine learning applications in minerals processing: A review," *Minerals Engineering*, 132, pp. 95-109, 2019.
12. J. Ralston, D. Reid, C. Hargrave and D. Hainsworth, "Sensing for advancing mining automation capability: A review of underground automation technology development," *International Journal of Mining Science and Technology*, 24(3), pp. 305-310, 2014.
13. M. Wang, J. Bao, X. Yuan, Y. Yin and S. Khalid, "Research status and development trend of unmanned driving technology in coal mine transportation," *Energies*, 15(23), pp. 9133, 2022.
14. J. Shahmoradi, E. Talebi, P. Roghanchi and M. Hassanalain, "A comprehensive review of applications of drone technology in the mining industry," *Drones*, 4(3), pp. 34, 2020.
15. X. Ma, "Coal gangue image identification and classification with wavelet transform," *Second International Conference*

- on Intelligent Computation Technology and Automation. *IEEE*, 1, pp. 562-565, 2009.
16. W. Yang, X. Zhang, H. Ma and G.M. Zhang, "Infrared LEDs-based pose estimation with underground camera model for boom-type roadheader in coal mining," *IEEE Access*, 7, pp. 33698-33712, 2019.
 17. W. Lei and J. Liu, "Early fire detection in coalmine based on video processing," Proceedings of the 2012 international conference on communication, electronics and automation engineering. Springer Berlin Heidelberg, pp.239-245, 2012.
 18. R. Yang, T. Qiao, Y. Pang, Y. Yang, H. Zhang and G. Yan, "Infrared spectrum analysis method for detection and early warning of longitudinal tear of mine conveyor belt," *Measurement*, 165, pp. 107856, 2020.
 19. C. Papachristos, S. Khattak, F. Mascarich and K. Alexis, "Autonomous navigation and mapping in underground mines using aerial robots," 2019 *IEEE Aerospace Conference*, Big Sky, MT, USA, pp. 1-8, 2019.
 20. Y. Du, M. Tong, T. Liu and H. Dong, "Visual measurement system for roadheaders pose detection in mines," *Optical Engineering*, 55(10), pp. 104107, 2016.
 21. L. Zhang, S. Hao, H. Wang, B. Wang, J. Lin, Y. Sui and C. Gu, "Safety warning of mine conveyor belt based on binocular vision," *Sustainability*, 14(20), pp. 13276, 2022.
 22. Z.G. Niu, L.J. Li, T. Wang, "3D reconstruction based on binocular stereo vision of robot." *Advanced Materials Research*. Trans Tech Publications, Ltd., 338, pp. 645–648, 2011.
 23. H. P. Moravec, "Obstacle avoidance and navigation in the real world by a seeing robot rover," Diss. Stanford University, 1980.
 24. F. Alidoost, G. Austen, M. Hahn, "A multi-camera mobile system for tunnel inspection," In: Coors, V., Pietruschka, D., Zeitler, B. (eds) *iCity. Transformative Research for the Livable, Intelligent, and Sustainable City*. Springer, Cham. pp 211–224, 2022.
 25. M. Janiszewski, M. Torkan, L. Uotinen and M. Rinne, "Rapid photogrammetry with a 360-degree camera for tunnel mapping," *Remote Sensing*, 14(21), pp. 5494, 2022

Application of machine vision technology to improve the efficiency of the coal industry

Ekaterina V. Kardashova

PhD in Economics, Associate Professor,
Associate Professor of the Department of Management
Siberian State University of Science and Technology
named after Academician M.F. Reshetnev
660000, Russian Federation, Krasnoyarsk, Krasnoyarsky Rabochy Ave., 31;
e-mail: lasfloresofdespiration@gmail.com

Mukhammad B. Khamraev

Student,
Siberian State University of Science and Technology
named after Academician M.F. Reshetnev
660000, Russian Federation, Krasnoyarsk, Krasnoyarsky Rabochy Ave., 31;
e-mail: lasfloresofdespiration@gmail.com

Abstract

The article considers the use of machine vision and an improved YOLOv4 algorithm for automatic recognition of coal and coal rock, which reduces labor costs and increases the efficiency of sorting. The aim of the study is to develop a deep learning method to improve the coal sorting process. The paper shows that the use of a Gaussian filter and a Laplace operator for image pre-processing improved data quality and recognition accuracy. Optimizing the anchor values improved

the efficiency of the model by reducing the number of false positives and missed objects. Experiments in conditions close to a real mine confirmed the algorithm's resistance to external interference. To improve the accuracy and reliability of the algorithm, it is necessary to continue collecting and expanding datasets, as well as integrating YOLOv4 with other technologies, such as LIDAR. The development of more efficient algorithms will reduce image processing time and improve system performance. Studying the application of the proposed method in other areas, such as metallurgy and construction, is of interest for future work.

For citation

Kardashova E.V., Khamraev M.B. (2024) *Primenenie tekhnologii mashinnogo zreniya dlya povysheniya effektivnosti ugo'noi promyshlennosti [Machine Vision Technology Application to Improve Coal Mining Efficiency]. Ekonomika: vchera, segodnya, zavtra [Economics: Yesterday, Today and Tomorrow]*, 14 (6A), pp. 529-539. DOI: 10.34670/AR.2024.67.78.055

Keywords

Machine vision, coal mining, automatic recognition, coal sorting, coal rock, deep neural networks, YOLOv4, deep learning, efficiency, environmental impact

References

1. World Energy Outlook 2022 <https://iea.blob.core.windows.net/assets/830fe099-5530-48f2-a7c1-11f35d510983/WorldEnergyOutlook2022.pdf>.
2. 2022 Annual Report on the Development of the Coal Industry, Beijing: CHINA NATIONAL COAL ASSOCIATION, 2023, [online] Available: <http://www.coalchina.org.cn/index.php?m=content&c=index&a=show&catid=464&id=146683>.
3. M.Q. Huang, J. Ninić and Q.B. Zhang, "BIM, machine learning and computer vision techniques in underground construction: Current status and future perspectives," *Tunnelling and Underground Space Technology*, 108, pp. 103677, 2021.
4. R. Hurteau, M. St-Amant, Y. Laperriere, and G. Chevrette, "Optical guidance system for underground mine vehicles," *IEEE International Conference on Robotics & Automation IEEE*, pp. 25-30, 1992.
5. T. Peinsitt, "Recent developments towards autonomous tunneling and mining machinery," *The 2021 World Congress on Advances in Structural Engineering and Mechanics (ASEM21) GECE*, Seoul, Korea, August 23-26, 2021.
6. K. Zhang, Y. Tian and Q. Jia, "Application status and trends of machine vision in coal machinery equipment," *Coal Mine Machinery*, 41(12), pp. 123-125, 2020.
7. S. Qin and L. Li, "Visual analysis of image processing in the mining field based on a knowledge map," *Sustainability*, 15(3), pp. 1810, 2023.
8. G. Zhai, W. Zhang, W. Hu and Z. Ji, "Coal mine rescue robots based on binocular vision: a review of the state of the art," *IEEE Access*, 8, pp. 130561-130575, 2020.
9. M. Imam, K. Baïna, Y. Tabii, E. Ressami, Y. Adlaoui, I. Benzakour and E.H. Abdelwahed, "The future of mine safety: a comprehensive review of anti-collision systems based on computer vision in underground mines," *Sensors*, 23(9), pp. 4294, 2023.
10. Y. Cui, S. Liu and Q. Liu, "Navigation and positioning technology in underground coal mines and tunnels: A review," *Journal of the Southern African Institute of Mining and Metallurgy*, 121(6), pp. 295-303, 2021.
11. J.T. McCoy and L. Auret, "Machine learning applications in minerals processing: A review," *Minerals Engineering*, 132, pp. 95-109, 2019.
12. J. Ralston, D. Reid, C. Hargrave and D. Hainsworth, "Sensing for advancing mining automation capability: A review of underground automation technology development," *International Journal of Mining Science and Technology*, 24(3), pp. 305-310, 2014.
13. M. Wang, J. Bao, X. Yuan, Y. Yin and S. Khalid, "Research status and development trend of unmanned driving technology in coal mine transportation," *Energies*, 15(23), pp. 9133, 2022.
14. J. Shahmoradi, E. Talebi, P. Roghanchi and M. Hassanalain, "A comprehensive review of applications of drone technology in the mining industry," *Drones*, 4(3), pp. 34, 2020.
15. X. Ma, "Coal gangue image identification and classification with wavelet transform," *Second International Conference on Intelligent Computation Technology and Automation. IEEE*, 1, pp. 562-565, 2009.

16. W. Yang, X. Zhang, H. Ma and G.M. Zhang, "Infrared LEDs-based pose estimation with underground camera model for boom-type roadheader in coal mining," *IEEE Access*, 7, pp. 33698-33712, 2019.
17. W. Lei and J. Liu, "Early fire detection in coalmine based on video processing," *Proceedings of the 2012 international conference on communication, electronics and automation engineering*, Springer Berlin Heidelberg, pp.239-245, 2012.
18. R. Yang, T. Qiao, Y. Pang, Y. Yang, H. Zhang and G. Yan, "Infrared spectrum analysis method for detection and early warning of longitudinal tear of mine conveyor belt," *Measurement*, 165, pp. 107856, 2020.
19. C. Papachristos, S. Khattak, F. Mascarich and K. Alexis, "Autonomous navigation and mapping in underground mines using aerial robots," *2019 IEEE Aerospace Conference, Big Sky, MT, USA*, pp. 1-8, 2019.
20. Y. Du, M. Tong, T. Liu and H. Dong, "Visual measurement system for roadheaders pose detection in mines," *Optical Engineering*, 55(10), pp. 104107, 2016.
21. L. Zhang, S. Hao, H. Wang, B. Wang, J. Lin, Y. Sui and C. Gu, "Safety warning of mine conveyor belt based on binocular vision," *Sustainability*, 14(20), pp. 13276, 2022.
22. Z.G. Niu, L.J. Li, T. Wang, "3D reconstruction based on binocular stereo vision of robot." *Advanced Materials Research*. Trans Tech Publications, Ltd., 338, pp. 645–648, 2011.
23. H. P. Moravec, "Obstacle avoidance and navigation in the real world by a seeing robot rover," *Diss. Stanford University*, 1980.
24. F. Alidoost, G. Austen, M. Hahn, "A multi-camera mobile system for tunnel inspection," In: Coors, V., Pietruschka, D., Zeitler, B. (eds) *iCity. Transformative Research for the Livable, Intelligent, and Sustainable City*. Springer, Cham. pp 211–224, 2022.
25. M. Janiszewski, M. Torkan, L. Uotinen and M. Rinne, "Rapid photogrammetry with a 360-degree camera for tunnel mapping," *Remote Sensing*, 14(21), pp. 5494, 2022