

## Оптический контроль повреждений грузоподъемных канатов металлургического технологического оборудования

А.А. Кульчицкий.<sup>1</sup>, М.Ю. Николаев<sup>1</sup>, И.А. Бригаднов<sup>1</sup>, Л.А. Русинов<sup>2</sup>

<sup>1</sup>Санкт-Петербургский горный университет императрицы Екатерины II

<sup>2</sup>Санкт-Петербургский государственный технологический институт  
(технический университет)

**Аннотация:** Стальные грузоподъемные канаты играют важную роль в металлургическом оборудовании, обеспечивая надежность и эффективность подъемных операций. Одной из ключевых особенностей их эксплуатации является высокий уровень загрязнений, характерный для металлургических производств. Металлургические процессы часто сопровождаются образованием пыли, металлических стружек и прочих абразивных частиц, которые могут существенно ухудшать состояние канатов, вызывая износ и коррозию. Для поддержания эффективной работы оборудования необходимо осуществлять мониторинг состояния грузоподъемных канатов в режиме реального времени, что делает актуальной задачу совершенствования автоматических систем контроля состояния канатов. В работе проведен обзор методов оптического контроля дефектов грузоподъемных стальных канатов, рассматриваются преимущества и ограничения различных подходов. Целью работы является обоснование эффективности разработанной авторами методики анализа изображений дефектов канатов с применением нейронных сетей относительно методики, основанной на дискретном преобразовании Фурье. Выявлено, что одним из наиболее перспективных с точки зрения технико-экономической эффективности способов контроля является применение системы технического зрения с обработкой изображения на основе технологии сверточных нейронных сетей, позволяющих эффективно выявлять дефекты в условиях сложных и изменяющихся эксплуатационных условий, таких как металлургическое и горно-обогатительное производство, где фон изображения может быть неоднородным, а расстояние между камерой и канатом изменяется.

**Ключевые слова:** грузоподъемные канаты, системы технического зрения, оптические методы контроля, быстрое преобразование Фурье, скрытые марковские модели, сверточные нейронные сети.

### Введение

В ходе эксплуатации в структуре стальных канатов (СК) неизбежно возникают дефекты, вызванные механическим износом проволок, коррозией, перегрузками и усталостью на сгибах. При этом, процесс развития дефектов постепенный, что исключает мгновенное разрушение структуры, влекущее за собой вывод из строя. Разрушение проволок происходит последовательно и в случайных местах, что делает целесообразным применение методов

---

диагностики состояния канатов для предупреждения отказов (ГОСТ 33718–2015, РД РОСЭК-012–97).

Несмотря на большое разнообразие существующих средств мониторинга состояния стальных канатов, на большинстве предприятий применяется визуальный метод контроля. Отсутствие автоматизации данного процесса приводит к низкой точности выявления даже визуальных дефектов.

Скорость образования различных типов дефектов напрямую зависит от условий эксплуатации, таких, как скорость движения, нагрузка, тип каната, размер шкива, тип и ширина канавки, а также техническое обслуживание. Условия окружающей среды также важны. Повышенная влажность и испарения могут значительно увеличить скорость износа [1, 2].

Мировым стандартом для оценки состояния грузоподъемных стальных канатов является ISO 4309:2010. В соответствии с этим документом, рекомендуемые виды износа, оцениваемые при осмотре, включают:

- Количество видимых оборванных проволок
- Уменьшение диаметра каната/потеря металлической площади
- Разрушение пряди (прядей)
- Коррозия (внешняя, внутренняя)
- Деформация
- Механическое повреждение [5].

Критерии отбраковки согласно ISO 4309:2010 включают: количество обрывов проволок на определенной длине каната, локальную группировку обрывов на неподвижных участках, обрывы в долинах и при заделке, равномерное уменьшение диаметра, коррозию, а также деформации (волнистость, корзинообразные и другие искажения, выпячивания сердечника и прядей, сплюснутые или перегнутые участки, повреждения от нагрева или электрической дуги) [3-5].

---

На практике перечисленные выше виды дефектов редко встречаются в чистом виде, а чаще всего представлены синергетическим эффектом взаимодействия нескольких видов между собой (таблица 1).

Таблица № 1

Взаимное влияние дефектов стальных канатов

№ п/п	Комбинация видов дефектов	Синергетический эффект
1	Коррозия Износ	Ускорение процесса изнашивания
2	Износ Обрыв проволок	Ускорение разрушения проволок каната
3	Усталость Износ Обрыв проволок	Появление или усиленному развитию разрушения и износа проволок
4	Износ Обрыв проволок Усталость Коррозия	Ускорение разрушения проволок и усугублению обрыва каната

Одним из наиболее перспективных и распространенных направлений неразрушающего контроля дефектов СК являются оптические методы, основанные на визуальном осмотре и применении компьютерного зрения. Эта область развивалась благодаря передовым методам обработки изображений и машинному обучению. Трудности в развитии метода оптического контроля повреждений СК заключаются в отсутствии надежных методик обработки изображений, позволяющих как выявлять наличие дефектов, так и их классифицировать с последующей оценкой глубины повреждений. Помимо этого, к недостаткам метода можно отнести сравнительно низкую скорость обработки изображений, что усложняет их использование в режиме реального времени [6, 7].

### Оптические методы неразрушающего контроля

Визуальный контроль поверхностей материалов является важным применением автоматизированных систем распознавания образов, особенно

в производственных средах, где ручной осмотр связан с высоким риском для жизни человека. Проверка грузоподъемных канатов в металлургическом и горно-обогатительном производствах является примером такой сложной и опасной задачи. Ручной осмотр малоэффективен и сопряжен с высокими рисками для жизни людей, поскольку проводится без остановки агрегатов [8, 10].

Методы машинного зрения предлагают множество преимуществ, включая бесконтактность, высокую точность в реальном времени и исключение необходимости ручного вмешательства. Эти методы становятся все более востребованными в современной промышленности. Чтобы обеспечить автоматический контроль поверхностных дефектов канатов, широко применяются оптические методы дефектоскопии [11, 12].

Преимущества оптических методов заключаются в простоте, относительной легкости использования оборудования и низких трудозатратах. Однако ограниченная достоверность и чувствительность оптического контроля делают его подходящим только для обнаружения поверхностных дефектов.

Аппаратура для обнаружения дефектов с помощью компьютерного зрения имеет простую структуру и может быть адаптирована для проверки канатов различных размеров. На результат обнаружения практически не влияет высота подъема каната, что смещает акцент направления развития методов от аппаратной части к программной в сторону разработки новых алгоритмов обработки изображений [13]. Камеры проецируют изображение каната с различных ракурсов, однако зачастую поверхностные дефекты неочевидны, что делает их распознавание с использованием машинного зрения сложной задачей [14-16].

Для получения измерительной информации используется множество различных модификаций алгоритмов обработки и анализа изображений, по-

---

разному решающих проблему производительности и точности работы системы. Так, существуют методы, основанные на традиционных алгоритмах обработки изображений и автокорреляции, а также подходы, использующие современные алгоритмы и модели машинного обучения [17, 18].

Различные группы признаков, включая цветовые, яркостные и геометрические, играют ключевую роль в диагностике состояния стальных канатов, позволяя выявлять различные виды дефектов и повреждений, такие как коррозия, трещины, изломы и другие аномалии (таблица 2).

Таблица № 2

Традиционные алгоритмы анализа изображений дефектов

№ п/п	Группа	Признак	Описание
1	Цветовы признаки	Гистограммы цветового распределения	Анализируют цветовое распределение каната, выявляя аномалии, такие как коррозия, через сравнение с эталоном.
		Цветовые моменты	Включают среднее цвета, дисперсию и асимметрию для выявления дефектов, например, обесцвечивания или посторонних веществ.
2	Яркостные признаки	Гистограмма яркости	Представляет распределение яркости изображения, где аномалии, такие как затемнения или высветления, указывают на повреждения каната.
		Средняя яркость и контраст	Высокий контраст и отклонения от средней яркости могут указывать на износ, трещины или другие повреждения.
3	Геометрически е признаки	Выделение краев	Используются алгоритмы Собеля, Канни для обнаружения краев прядей каната и выявления разрывов или изломов.
		Гистограмма направлений градиентов	Анализирует направления градиентов на изображении, что помогает выявлять структурные изменения и деформации.
		Форма и размеры прядей	Геометрические параметры, такие как длина, ширина и форма прядей, используются для выявления разрывов, утолщений или других аномалий.

К традиционным алгоритмам относится метод выделения краев каната с помощью алгоритма Собеля, после чего применяется автокорреляция для создания сигнала, который помогает определить наличие повреждений.

Другой метод предусматривает определение ориентации текстуры с использованием нечеткого преобразования Хафа, что позволяет установить направление стального каната. Текстурные признаки, такие как гистограмма плотности направления краев, а также сегментация текстуры изображения с помощью алгоритма кластеризации нечеткого С-среднего (Fuzzy C-Means – FCM), способствуют выделению краевых линий каната и улучшению точности анализа [19, 20].

Предварительная обработка изображений также может включать методы повышения резкости и выравнивания, после чего оператор Канни используется для выделения краев. Показатели гладкости и энтропии краев затем применяются для различения нормальных и поврежденных канатов, обеспечивая дополнительный уровень анализа и точности.

Скрытые марковские модели (Hidden Markov Models – HMM) широко используются для учета временного контекста при классификации временных рядов. В дефектоскопии стальных канатов HMM этот метод применяется для анализа поверхности, где различные участки каната рассматриваются как последовательности наблюдений, а скрытые состояния соотносятся с конкретными положениями на канате. Определив порог вероятности для последовательности наблюдений на основе модели, можно установить принадлежность данной последовательности к определенной категории, что позволяет выявлять дефекты [21].

Применение HMM в дефектоскопии стальных канатов обусловлена способностью методики моделировать последовательности наблюдений и их вероятности, что позволяет учитывать различные факторы, влияющие на состояние каната.

Интеграция HMM с другими методами анализа, такими как использование гистограмм ориентированных градиентов и их энтропии, может повысить общую эффективность и точность дефектоскопии,

---

обеспечивая более комплексный подход к обнаружению дефектов в сложных условиях эксплуатации [22, 23].

Тем не менее, при использовании НММ возникает важная проблема: разделение сигнала на более короткие тестовые последовательности может улучшить точность локализации дефектов, но при этом теряется временной контекст, который необходим для корректного сравнения с моделью. Таким образом, для достижения наилучших результатов требуется баланс между длиной тестовых последовательностей и сохранением временного контекста [24].

Наиболее перспективными алгоритмы обработки изображений для повышения точности и эффективности диагностики являются двухмерное дискретное преобразование Фурье (ДПФ) и применение нейронных сетей.

ДПФ позволяет преобразовывать пространственные данные изображения в частотные, что существенно упрощает выявление и классификацию дефектов. Метод считается достаточно быстрым по сравнению с остальными реализациями. Также присутствует огромное число библиотек, реализующих преобразование Фурье, что делает реализацию алгоритмов сравнения изображений не очень сложной задачей для программирования [25].

Применение нейронных сетей для обработки изображений в дефектоскопии стальных канатов представляет собой инновационный подход, отличающийся прежде всего тем, что система обучается самостоятельно, а не программируется напрямую для выполнения конкретных задач. При этом программированию подлежат лишь гиперпараметры, которые контролируют процесс обучения модели [26, 27].

Для подтверждения преимуществ метода, основанного на применении нейронных сетей, было проведено сравнительное исследование трудоемкости



и результативности данной методики относительно преобразования Фурье [28].

Для сравнительного анализа эффективности двух основных методов обработки кадров были получены изображения двух типов стальных канатов, обладающих геометрическим сходством с реальными объектами. В качестве регистрационного устройства использовалась цифровая камера с разрешением 5 Мп (сенсор CMOS 1/2.5", разрешение 2592×1944) и объективом Lens Ricoh FL-CC1214A-2MF1.4 с фокусным расстоянием 12 мм. Для оценки визуальной идентификации трех типов дефектов (разрыв, абразивный износ и изгиб) грузоподъемных канатов были сделаны снимки под разными углами, с шагом в 45 градусов при вращении образцов.

Пример изображений различных видов дефектов представлен на рисунке 1.




Рис. 1 – Изображения дефектов стальных канатов с удаленным фоном  
а) без дефектов, б) изгиб, в) разрыв, г) абразивный износ

Предварительная обработка изображений включает удаление фона методом бинаризации:

$$I_b(x, y) = \begin{cases} 1, & \text{если } I(x, y) > T \\ 0, & \text{если } I(x, y) \leq T \end{cases} \dots\dots\dots(1)$$

где  $I(x, y)$  – интенсивность пикселя в координатах  $(x, y)$ ;



T – порог.

### Быстрое преобразование Фурье

В частотном пространстве дефекты стальных канатов могут проявляться как характерные изменения в амплитудно-частотной характеристике сигнала, что облегчает их обнаружение и анализ. Преобразование Фурье обеспечивает возможность выделения высокочастотных компонентов, связанных с мелкими и острыми дефектами, такими как трещины и разрывы проволок, а также низкочастотных компонентов, связанных с более крупными и плавными дефектами, такими как коррозионные повреждения [29-31].

Для анализа изображений дефектов стальных канатов наиболее подходящим видом рассматриваемого преобразования является двумерное дискретное преобразование Фурье.

Быстрое преобразование Фурье (БПФ), являющееся реализацией двумерного дискретного преобразования, обеспечивает высокую скорость обработки данных, что особенно важно для анализа изображений в реальном времени.

Для сигнала, представленного как функция времени,  $t$ , преобразование Фурье задается следующим уравнением:

$$f(t) = \int_{-\infty}^{+\infty} F(x) e^{-j2\pi fx} \quad (2)$$

$$F(x) = \int_{-\infty}^{+\infty} f(t) e^{-j2\pi ft} dt \quad (3)$$

Где  $F(x)$  – преобразование Фурье сигнала  $f(t)$ ;

$f$  – частота в Герцах (Гц).

Таким образом преобразование Фурье можно рассматривать как представление сигнала в частотной области, а не во временной.

---

Применение предложенной методики требует проведения процедуры калибровки для каждого отдельного изображения, что является ее ключевой особенностью. Исходя из двух важных предположений — что дифракционная картина может быть рассчитана аналитически и что дифракционные картины, смоделированные по изображениям образцов материалов, тождественны дифракционным картинам, полученным при освещении этих образцов монохроматическим светом, — можно разработать алгоритм поиска дефектов стальных канатов [32, 33].

Обработка изображений для получения необходимых измерений выполняется следующим образом: сначала записывается изображение исследуемого участка каната, затем оно сегментируется на три части. На сегментированных изображениях осуществляется поиск характерных дефектов с использованием методики, основанной на БПФ. Далее на выделенные изображения накладываются калибровочные данные, что позволяет определить размеры канатов. Для реализации поиска дефектов в программной среде используется функция захвата и анализа изображений с помощью быстрого преобразования Фурье (Image Acquisition Fast Fourier Transform – IMAQ FFT), реализующая БПФ для заданного изображения. Поскольку БПФ работает с комплексными числами, исходное изображение предварительно преобразуется в комплексную форму с помощью виртуального прибора IMAQ ImageToComplexPlane, при этом исходное изображение помещается в действительную часть комплексного изображения.

В работах, описывающих преобразование Фурье, исследования проводились на незагрязненных образцах, что позволило получить достаточно точные результаты и избежать дополнительных сложностей с обработкой.

Однако исследование загрязненных образцов, приближенных к реальным условиям металлургического производства (рисунок 2), показали недостаточную точность идентификации, что делает метод непригодным для работы в реальных условиях без применения дополнительных алгоритмов фильтрации.

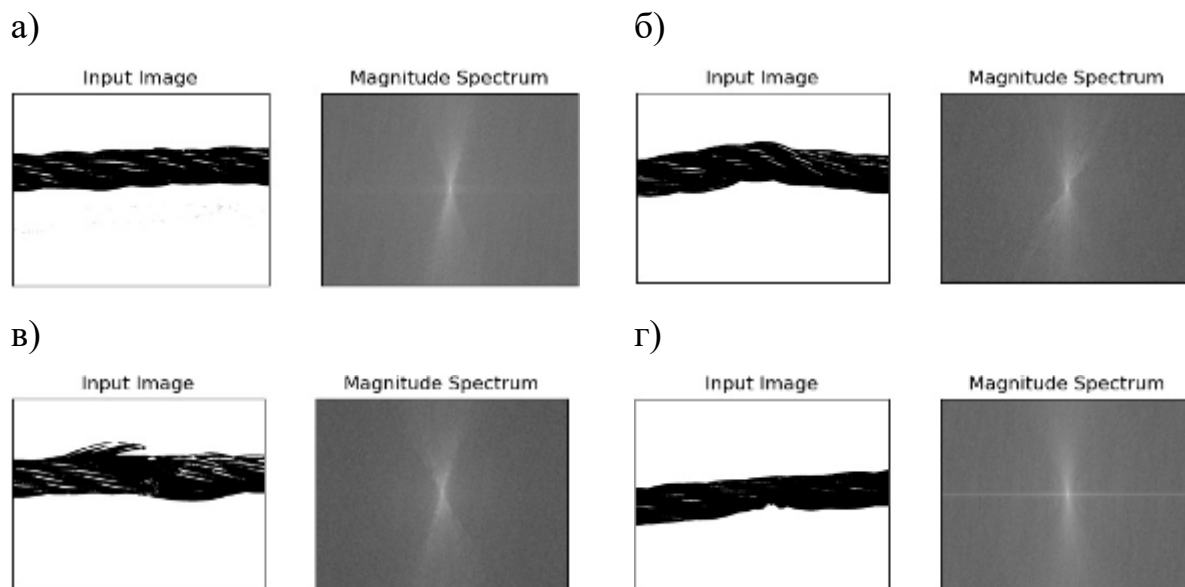


Рис. 2 – Анализ изображений дефектов стальных канатов с помощью БПФ

а) без дефектов, б) изгиб, в) разрыв, г) абразивный износ

### Сверточные нейронные сети

Для детектирования дефектов выбраны две модели сверточной нейронной сети (СНС): SSD ResNet50 V1 FPN 640×640 (RetinaNet50) и EfficientDet D2 768×768, известные своей высокой производительностью и способностью обрабатывать изображения с высоким разрешением.

Процесс обучения начинается с сбора данных: были собраны изображения двух видов стальных канатов, имитирующих реальные объекты, с разных ракурсов и расстояний при различных условиях освещенности. Эти изображения включали три типа дефектов: разрыв, абразивный износ и изгиб. Для маркировки фотографий использовался программный инструмент

Labelimg, написанный на языке Python, что позволило создать обучающую выборку с метками для каждого типа дефекта.

Обучение сети проводилось на платформе машинного обучения TensorFlow. Было собрано около 1000 изображений на каждый тип дефекта, и обучение проводилось с использованием заранее подготовленного набора данных, включающего уникальные комбинации свойств объекта. Для обучения нейросети было задано 300 тысяч итераций.

Алгоритмы обработки изображений включают предобработку, состоящую из вычитания фоновой составляющей, фильтрации и масштабирования изображения. Алгоритм обработки изображения разработан на языке Python с использованием библиотеки OpenCV, что помогает улучшить качество входных данных для нейросети и повысить точность распознавания дефектов. Модели обучаются не только на распознавании конкретных формальных признаков дефектов, но и на их комбинациях, что улучшает общую точность распознавания.

Результаты анализа изображений с применением СНС представлены на рисунке 3, где в процентном отношении определена вероятность наличия того или иного вида дефекта.




Рис. 3 – Результат обработки изображений с помощью СНС.

а) пример обработки изображения дефекта б) обнаружение дефекта

## Анализ результатов

Для оценки качества работы нейросетей использовалась метрика средней точности (mean Average Precision – mAP). Значения коэффициентов выделения дефектов рассчитывались для различных условий освещенности и расстояния до объекта контроля. Основная модель, EfficientDet D2 768×768, показала наилучшие результаты в условиях стандартного освещения и расстояния.

В результате сравнительного анализа применения нейросетевых алгоритмов и ДПФ для контроля состояния грузоподъемных канатов можно выделить следующие преимущества СНС:

- Способность к автоматическому обучению и адаптации. В отличие от БПФ, которое требует применения трудоемкой процедуры калибровки частотных характеристик дефектов, СНС обучаются на больших наборах данных, что позволяет им самостоятельно выявлять и классифицировать различные типы дефектов.

- Точность и гибкость благодаря способности СНС извлекать и анализировать сложные визуальные паттерны. Так, мелкие трещины и незначительные деформации, которые могут быть трудноразличимы при использовании БПФ из-за их слабой частотной сигнатуры, выявляются СНС с достаточной точностью.

- Высокая устойчивость к шумам и артефактам благодаря обучению на зашумленных данных, что имеет большое значение в условиях промышленного производства. В то время как ДПФ может быть чувствительным к шумам и искажениям, снижая его точность в реальных условиях эксплуатации.

- Способность СНС работать в реальном времени. Обученные нейронные сети могут быстро обрабатывать и анализировать изображения, обеспечивая непрерывный мониторинг состояния канатов, что особенно

---

важно в условиях, когда требуется быстрое реагирование на выявленные дефекты, чтобы предотвратить аварийные ситуации. БПФ, напротив, требует значительных вычислительных ресурсов и времени для обработки данных.

### Выводы

Оптические методы контроля, особенно при использовании СНС, позволяют выявлять дефекты с высокой точностью даже в сложных и изменяющихся условиях эксплуатации, характерных для металлургического и горно-обогатительного производства. СНС показали способность эффективно обрабатывать изображения канатов, выявлять и классифицировать дефекты, такие как разрывы, абразивный износ и изгибы, благодаря обучению на разнообразных наборах данных и применению передовых алгоритмов машинного обучения.

БПФ также продемонстрировало высокую эффективность в анализе изображений канатов, позволяя преобразовывать пространственные данные в частотные и выявлять скрытые дефекты на основе изменений в амплитудно-частотной характеристике сигнала.

Однако, исследования БПФ сосредоточены на обнаружении аномалий в стальных канатах в условиях, где фон изображений однороден и неизменен, а расстояние между камерой и канатом фиксировано. Однако в реальных промышленных условиях фон значительно более сложный, а расстояние между камерой и канатом изменяется, кроме того, присутствует сильная зашумленность. Более того, большинство этих исследований полагаются на традиционные методы машинного обучения и обработки изображений, не позволяя глубоким нейронным сетям всесторонне изучить визуальные особенности сцены.

Сравнительный анализ методов показал, что СНС является более эффективным по таким критериям, как точность, скорость обработки информации, устойчивость к шуму, что подтверждает целесообразность

использования СНС для автоматизированного мониторинга состояния канатов в реальных производственных условиях.

### Литература

1. Zhou P., Zhou G., Zhu Z., He Z., Ding X., Tang C. A review of non-destructive damage detection methods for steel wire ropes // Appl. Sci., 2019., Vol. 9., P. 2771.
2. Семькина И.Ю., Кипервассер М.В., Герасимук А.В. Исследование токов привода подъема мостовых кранов металлургических предприятий для раннего диагностирования превышения массы груза // Записки Горного института, 2021, Т. 247, С. 122-131. DOI: 10.31897/PMI.2021.1.13
3. Zakharov L., Martyushev D., Ponomareva I. N. Predicting dynamic formation pressure using artificial intelligence methods // Journal of Mining Institute., 2022., Vol. 253., P. 23–32. DOI: 10.31897/PMI.2022.11.
4. Mazurek P. A comprehensive review of steel wire rope degradation mechanisms and recent damage detection methods // Sustainability, 2023, Vol. 15(6), P. 5441. DOI: 10.3390/su15065441
5. Калинин Т.С. Спектрально-сигнатурная диагностика микропроцессорных информационно-управляющих систем железнодорожной автоматики и телемеханики // Инженерный вестник Дона 2012, №1. URL: ivdon.ru/ru/magazine/archive/n1y2012/687
6. Бажин В. Ю., Масько О. Н., Ануфриев А. С. Обоснование выбора платформы для создания системы управления материальными потоками в производстве металлургического кремния // Горный информационно-аналитический бюллетень, 2024, № 1-1, С. 206–219. DOI: 10.25018/0236\_1493\_2024\_011\_0\_206.
7. Ануфриев А. С., Лебедик Е. А., Бажин В. Ю. Новые подходы для повышения эффективности автоматизированных систем управления



переделами рудоподготовки // Горный информационно-аналитический бюллетень, 2024, № 2, С. 76–92. DOI: 10.25018/0236\_1493\_2024\_2\_0\_76.

8. Алёшин С.П., Бородина Е.А. Нейросетевое распознавание классов в режиме реального времени // Инженерный вестник Дона, 2013, №1, URL: ivdon.ru/ru/magazine/archive/n1y2013/1494

9. Maljaars J., Misiek T. Fatigue resistance of steel ropes: failure criterion: Background to the verification in prEN 1993-1-11: 2020 // Steel Construction, 2021, Vol. 14, Issue 3, P. 196-204. DOI: 10.1002/stco.202000058

10. Cheremisina O. V., Ponomareva M. A., Sergeev V. V., Mashukova Y. A., Balandinsky D. A. Extraction of rare earth metals by solid-phase extractants from phosphoric acid solution // Metals, 2021, Vol. 11, P. 991. DOI: 10.3390/met11060991.

11. Boikov A., Payor V., Savelev R., Kolesnikov A. Synthetic data generation for steel defect detection and classification using deep learning // Symmetry, 2021, Vol. 13(7), P. 1176. DOI: 10.3390/sym13071176

12. Huang X., Liu Z., Zhang X., Kang J. Surface damage detection for steel wire ropes using deep learning and computer vision techniques // Measurement, 2020, Vol. 161, 107843. DOI: 10.1016/j.measurement.2020.107843.

13. Zhou M., Lu W., Xia J., Wang Yu. Defect Detection in Steel Using a Hybrid Attention Network // Sensors. – 2023. – Vol. 23. – P. 6982. DOI: 10.3390/s23156982.

14. Саадун А., А. Саадун, М. Фредж, Р. Букарм, Р. Хаджи Анализ дробления с использованием цифровой обработки изображений и эмпирической модели (KuzRam): сравнительное исследование // Записки Горного института, 2022, Т. 257, С. 822—832. DOI: 10.31897/PMI.202

15. Li Z., Wei X., Hassaballah M., Li Yu., Jiang Xu. A deep learning model for steel surface defect detection // *Complex & Intelligent Systems*, 2024, Vol. 10, Issue 1, P. 885-897. DOI: 10.1007/s00542-022-07361-x.
  16. Ромашев А.О., Николаева Н.В., Гатиатуллин Б.Л. Формирование адаптивного подхода с применением технологии машинного зрения для определения параметров осаждения продуктов обогащения // *Записки Горного института*, 2022, Т. 256, С. 677-685. DOI: 10.31897/PMI.2022.77
  17. Jha S. B., Babiceanu R. F. Deep CNN-based visual defect detection: Survey of current literature // *Computers in Industry*, 2023, Vol. 148, P. 103911. DOI: 10.1016/j.measurement.2023.112611.
  18. Akhyar F., Liu Yi., Hsu Ch., Shih T.K., Lin Ch. A deep learning-based steel defect detectors // *The International Journal of Advanced Manufacturing Technology*, 2023, Vol. 126, Issue 3, P. 1093-1107. DOI: 10.1007/s00500-021-06011-x.
  19. Захаров Л.А., Мартюшев Д.А., Пономарева И.Н. Прогнозирование динамического пластового давления методами искусственного интеллекта // *Записки Горного института*, 2022, Т. 253, С. 23-32. DOI: 10.31897/PMI.2022.11
  20. Huang X., Liu Zh., Zhang Xi., Kang J., Zhang M., Guo Yu. Surface damage detection for steel wire ropes using deep learning and computer vision techniques // *Measurement*, 2020, Vol. 161, P. 107843. DOI: 10.1016/j.engappai.2023.105764.
  21. Pshenin V., Liagova A., Razin A., Skorobogatov A., Komarovskiy M. Robot crawler for surveying pipelines and metal structures of complex spatial configuration // *Infrastructures*, 2022, Vol. 7, P. 75. DOI: 10.3390/INFRASTRUCTURES7060075.
-

22. Zhou P., Zhou G., Zhu Z., He Z., Ding X., Tang C. A review of non-destructive damage detection methods for steel wire ropes // Applied Sciences, 2019, T. 9. – P. 2771. DOI: 10.3390/app9132771.
  23. Zhou G., Sun H. Defect detection method for steel based on semantic segmentation // IEEE. – 2020. – pp. 975-979.
  24. Liu S., Sun Ya., He L., Kang Yi. Weak signal processing methods based on improved HHT and filtering techniques for steel wire rope // Applied Sciences, 2022. Vol. 12(14). – P. 6969. DOI: 10.3390/app12147623.
  25. Rehab A. Ali I., Gomaa W., Fors M.N. Bearings fault detection using hidden Markov models and principal component analysis enhanced features // arXiv, 2021, pp. 1-8. DOI: 10.48550/arXiv.2104.10519.
  26. Mor B., Garhwal S., Kumar A. A systematic review of hidden Markov models and their applications // Archives of computational methods in engineering, 2021, Vol. 28, pp. 1429-1448. DOI: 10.1007/s11831-020-09422-4
  27. Zhao W., Shi T., Wang L. Fault diagnosis and prognosis of bearing based on hidden Markov model with multi-features // Applied Mathematics and Nonlinear Sciences, 2020, Vol. 5, Issue 1, pp. 71-84. DOI: 10.2478/amns.2020.1.00008
  28. Anand P., Sudharsan R.M., Ramachandran V., Prusty M.N. Steel Defect Detection Using a ResNet-Inspired Model and Fourier Transforms // IEEE, 2024, C. 1-6. DOI: 10.1109/TII.2021.3051405.
  29. Mordia R., Verma A. K. Visual techniques for defects detection in steel products: A comparative study // Engineering Failure Analysis, 2022, Vol. 134, P. 106047. DOI: 10.1016/j.engfailanal.2022.106047
  30. Simakov A. S., Trifonova M. E., Gorlenkov D. V. Virtual analyzer of the voltage and current spectrum of the electric arc in electric arc furnaces // Russian Metallurgy (Metally), 2021, Vol. 6, pp. 713–719. DOI: 10.1134/S0036029521060252
-

31. Zhang D., Zhang E., Pan S. A new signal processing method for the nondestructive testing of a steel wire rope using a small device // *NDT & E International*, 2020, Vol. 114, P. 102299. DOI: 10.1016/j.ndteint.2020.102299

32. Liu S., Shan L., Liu Yo., He Li. Wavelet structuring element-based morphological filtering method in wire rope inspection signal denoising // *Structural Health Monitoring*, 2024, pp. 5-15 DOI: 10.1177/14759217231210600.

33. Fedorova E., Pupysheva E., Morgunov V. Modelling of red-mud particle-solid distribution in the feeder cup of a thickener using the combined CFD-DPM approach // *Symmetry*, 2022, Vol. 14, P. 2314. DOI: 10.3390/SYM14112314

### References

1. Zhou P., Zhou G., Zhu Z., He Z., Ding X., Tang C. *Appl. Sci.*, 2019, Vol. 9, P. 2771.

2. Semykina I.Yu., Kipervasser M.V., Gerasimuk A.V. *Zapiski Gornogo instituta*, 2021, T. 247, pp. 122-131. DOI: 10.31897/PMI.2021.1.13

3. Zakharov L., Martyushev D., Ponomareva I. N. Predicting dynamic formation pressure using artificial intelligence methods // *Journal of Mining Institute*, 2022, Vol. 253. pp. 23–32. DOI: 10.31897/PMI.2022.11.

4. Mazurek P. *Sustainability*, 2023, Vol. 15(6), P. 5441. DOI: 10.3390/su15065441

5. Kalinin T.S. *Inzhenernyj vestnik Dona*, 2012, № 1. URL: ivdon.ru/ru/magazine/archive/n1y2012/687

6. Bazhin V.Yu., Mas'ko O.N., Anufriev A.S. *Gornyj informacionno-analiticheskij byulleten'*, 2024, no. 1-1, pp. 206–219. DOI: 10.25018/0236\_1493\_2024\_011\_0\_206.

7. Anufriev A.S., Lebedik E.A., Bazhin V.Yu. *Gornyj informacionno-analiticheskij byulleten'*, 2024, № 2, pp. 76–92. DOI: 10.25018/0236\_1493\_2024\_2\_0\_76.

---

8. Alyoshin S.P., Borodina E.A. Inzhenernyj vestnik Dona, 2013, № 1, URL: [ivdon.ru/ru/magazine/archive/n1y2013/1494](http://ivdon.ru/ru/magazine/archive/n1y2013/1494)
  9. Maljaars J., Misiek T. Steel Construction, 2021, Vol. 14, Issue 3, pp. 196-204. DOI: [10.1002/stco.202000058](https://doi.org/10.1002/stco.202000058)
  10. Cheremisina O. V., Ponomareva M. A., Sergeev V. V., Mashukova Y. A., Balandinsky D. A. Metals, 2021, Vol. 11, P. 991. DOI: [10.3390/met11060991](https://doi.org/10.3390/met11060991).
  11. Boikov A., Payor V., Savelev R., Kolesnikov A. Symmetry, 2021, Vol. 13(7), P. 1176. DOI: [10.3390/sym13071176](https://doi.org/10.3390/sym13071176)
  12. Huang X., Liu Z., Zhang X., Kang J. Measurement, 2020, Vol. 161, 107843. DOI: [10.1016/j.measurement.2020.107843](https://doi.org/10.1016/j.measurement.2020.107843).
  13. Zhou M., Lu W., Xia J., Wang Yu. Sensors. 2023. Vol. 23. P. 6982. DOI: [10.3390/s23156982](https://doi.org/10.3390/s23156982).
  14. Saadun A., A. Saadun, M. Fredzh, R. Bukarm, R. Zapiski Gornogo instituta, 2022, T. 257, pp. 822—832. DOI: [10.31897/PMI.202](https://doi.org/10.31897/PMI.202)
  15. Li Z., Wei X., Hassaballah M., Li Yu., Jiang Xu. Complex & Intelligent Systems, 2024, Vol. 10, Issue 1, pp. 885-897. DOI: [10.1007/s00542-022-07361-x](https://doi.org/10.1007/s00542-022-07361-x).
  16. Romashev A.O., Nikolaeva N.V., Gatiatullin B.L. Zapiski Gornogo instituta, 2022, T. 256, pp. 677-685. DOI: [10.31897/PMI.2022.77](https://doi.org/10.31897/PMI.2022.77)
  17. Jha S. B., Babiceanu R. F. Computers in Industry, 2023, Vol. 148, P. 103911. DOI: [10.1016/j.measurement.2023.112611](https://doi.org/10.1016/j.measurement.2023.112611).
  18. Akhyar F., Liu Yi., Hsu Ch., Shih T.K., Lin Ch. The International Journal of Advanced Manufacturing Technology, 2023, Vol. 126, Issue 3, pp. 1093-1107. DOI: [10.1007/s00500-021-06011-x](https://doi.org/10.1007/s00500-021-06011-x).
  19. Zaharov L.A., Martyushev D.A., Ponomareva I.N. Zapiski Gornogo instituta, 2022, T. 253, pp. 23-32. DOI: [10.31897/PMI.2022.11](https://doi.org/10.31897/PMI.2022.11)
  20. Huang X., Liu Zh, Zhang Xi., Kang J., Zhang M., Guo Yu. Measurement, 2020, Vol. 161, P. 107843. DOI: [10.1016/j.engappai.2023.105764](https://doi.org/10.1016/j.engappai.2023.105764).
-



21. Pshenin V., Liagova A., Razin A., Skorobogatov A., Komarovskiy M. Infrastructures, 2022, Vol. 7, P. 75. DOI: 10.3390/INFRASTRUCTURES7060075.
22. Zhou P., Zhou G., Zhu Z., He Z., Ding X., Tang C. Applied Sciences, 2019, T. 9. P. 2771. DOI: 10.3390/app9132771.
23. Zhou G., Sun H. IEEE. 2020. pp. 975-979.
24. Liu S., Sun Ya., He L., Kang Yi. Applied Sciences, 2022. Vol. 12(14). P. 6969. DOI: 10.3390/app12147623.
25. Rehab A. Ali I., Gomaa W., Fors M.N. arXiv, 2021, pp. 1-8. DOI: 10.48550/arXiv.2104.10519.
26. Mor B., Garhwal S., Kumar A. Archives of computational methods in engineering, 2021, Vol. 28, pp. 1429-1448. DOI: 10.1007/s11831-020-09422-4
27. Zhao W., Shi T., Wang L. Applied Mathematics and Nonlinear Sciences, 2020, Vol. 5, Issue 1, pp. 71-84. DOI: 10.2478/amns.2020.1.00008
28. Anand P., Sudharsan R.M., Ramachandran V., Prusty M.N. IEEE, 2024, pp. 1-6. DOI: 10.1109/TII.2021.3051405.
29. Mordia R., Verma A. K. Engineering Failure Analysis, 2022, Vol. 134, P. 106047. DOI: 10.1016/j.engfailanal.2022.106047
30. Simakov A. S., Trifonova M. E., Gorlenkov D. V. Russian Metallurgy (Metally), 2021, Vol. 6, P. 713–719. DOI: 10.1134/S0036029521060252
31. Zhang D., Zhang E., Pan S. NDT & E International, 2020, Vol. 114, P. 102299. DOI: 10.1016/j.ndteint.2020.102299
32. Liu S., Shan L., Liu Yo., He Li. Structural Health Monitoring, 2024, pp. 5-15 DOI: 10.1177/14759217231210600.
33. Fedorova E., Pupysheva E., Morgunov V. Symmetry, 2022, Vol. 14, P. 2314. DOI: 10.3390/SYM14112314

**Дата поступления: 20.12.2024**

**Дата публикации: 25.02.2025**

---