

Система комплексного контроля состояния грузоподъемных стальных канатов на основе машинного обучения и синхронизированной обработки сигналов оптического и магнитного каналов

А.А. Кульчицкий, М.Ю. Николаев

Санкт-Петербургский горный университет императрицы Екатерины II

Аннотация: Предложен комплексный подход к решению задачи автоматизированного контроля технического состояния стальных грузоподъемных канатов, реализованный через объединение двух независимых методов — оптического и магнитометрического, в единую синхронизированную систему контроля. В оптическом канале реализованы два механизма анализа: классификация дефектов на основе оценки характерных паттернов изменений размеров поперечного сечения, а также классификация на основе сверточной нейронной сети, обученной на размеченных изображениях реальных повреждений. Магнитометрический канал использует принцип утечки магнитного потока, фиксируя внутренние аномалии с помощью набора датчиков, сигнал с которых преобразуется в числовой вектор признаков. Временная и пространственная синхронизация данных с использованием алгоритмов корреляции обеспечивает унифицированное отображение дефектов и минимизирует ложные срабатывания. Проведена экспериментальная верификация системы на канатах с дефектами типа изгиб, залом, разрыв и без повреждений в условиях, приближенных к реальной эксплуатации. Полученные результаты подтверждают высокую чувствительность, устойчивость к шумам и потенциальную пригодность разработанного решения для непрерывного промышленного мониторинга.

Ключевые слова: автоматизация контроля, стальные канаты, неразрушающий контроль, комплексный контроль, техническое зрение, классификация дефектов, нейросети, градиентный бустинг, сверточные нейронные сети.

Введение

Стальные канаты широко применяются в подъемно-транспортных системах, шахтном оборудовании, канатных дорогах и других объектах критической инфраструктуры, где они подвергаются интенсивным механическим и климатическим нагрузкам. Постепенное накопление повреждений — таких как локальные изгибы, износ, коррозия, обрывы отдельных проволок или деформация сердечника — приводит к утрате прочности и может стать причиной аварий, производственных простоев и угрозы безопасности персонала. Своевременное выявление таких дефектов

является необходимым условием для оценки остаточного ресурса каната и планирования технического обслуживания [1-3].

На практике оценка состояния канатов чаще всего осуществляется с помощью визуального контроля или магнитных дефектоскопов. Однако визуальный осмотр подвержен влиянию человеческого фактора, чувствителен к условиям освещения и загрязнению поверхности, а также не позволяет выявлять скрытые внутренние дефекты. Магнитные методы, в частности метод утечки магнитного потока, напротив, чувствительны к изменениям внутренней структуры, но обладают ограниченным пространственным разрешением и могут давать неоднозначные сигналы в случае сложной геометрии дефекта [4, 5].

В существующих разработках систем контроля, как правило, применяется только один канал контроля — либо оптический, либо магнитный. Это ограничивает надёжность классификации и снижает эффективность в условиях промышленной эксплуатации. Проблема объединения оптического анализа и магнитометрического контроля остаётся актуальной задачей в области интеллектуальной диагностики и технического зрения [6-8].

Материалы и методы

Предлагаемая система автоматизированного контроля состояния стальных канатов построена на принципе параллельной обработки данных из двух независимых каналов — оптического и магнитометрического. Каждый канал работает с сигналами своей физической природы, отражающими разные аспекты технического состояния объекта. Интеграция каналов осуществляется с использованием механизмов временной и пространственной синхронизации, что обеспечивает высокую точность локализации дефектов и снижает вероятность ложных классификаций.

Принципы работы оптического канала

Оптический канал предназначен для выявления геометрических отклонений и обнаружения поверхностных дефектов стального каната. В рамках предлагаемой архитектуры оптический канал решает две взаимодополняющие задачи: оценку изменений толщины поперечного сечения и классификацию изображений поверхности. В его основе лежит использование технического зрения и алгоритмов машинного обучения, обеспечивающих автоматизированную интерпретацию визуальных данных [9, 10].

Получение изображения осуществляется с помощью камеры высокого разрешения, совмещённой с зеркальным преобразователем, обеспечивающим получение изображения внешней поверхности каната с трёх сторон. Такая конструкция позволяет получать развернутую картину сечения и учитывать сложную геометрию укладки проволок [11]. Первичная обработка изображения включает коррекцию перспективных искажений, нормализацию яркости и выделение границ объекта.

В первом подходе к обработке информации, полученной с оптического канала — анализе формы поперечного сечения — изображение преобразуется в одномерную последовательность значений толщины (в пикселях), получаемую по каждой горизонтальной координате. Эта последовательность отражает локальные геометрические характеристики и позволяет идентифицировать деформации, вызванные такими дефектами, как изгиб, залом, разрыв и пр. Из извлечённого массива толщины рассчитываются агрегированные статистики: среднее значение, минимум, максимум, стандартное отклонение, сумма и произведение. Эти признаки подаются на вход модели градиентного бустинга CatBoost, которая классифицирует каждое сечение по типу дефекта. Подход обеспечивает устойчивость к шумам, высокую интерпретируемость и возможность

быстрой дообучаемости на новых примерах без необходимости изменения архитектуры [12, 13].

Во втором подходе используется прямой анализ изображений поверхности каната. Здесь применяется сверточная нейросетевая модель с несколькими уровнями свёртки, активацией и классификационным слоем. Модель обучена на размеченном датасете, включающем примеры типичных дефектов (разрывы, истончения, поверхностные трещины, смятия, загрязнения и др.). Для повышения устойчивости к изменениям освещенности, масштаба и ориентации изображений используются методы аугментации и нормализации входных данных. В качестве перспективного расширения применялись архитектуры типа EfficientDet, обеспечивающие более глубокое представление текстурных признаков и улучшенную сходимость при обучении [14-16].

Результаты от обеих ветвей оптической обработки (анализ размеров сечения и анализ текстуры поверхности) объединяются на этапе принятия решений. Это позволяет уточнить локализацию повреждения, классифицировать его характер и выделить участки, требующие дополнительной проверки со стороны магнитного канала (таблица 1).

Таблица № 1

Сравнение направлений оптического анализа

Характеристика	Анализ поперечного сечения	Классификация изображений
Тип входных данных	Одномерный массив толщин	2D изображение поверхности
Тип извлекаемых признаков	Агрегированные статистики	Визуальные паттерны
Алгоритм классификации	CatBoost	EfficientDet
Чувствительность к локальным дефектам	Средняя	Высокая
Объяснимость модели	Высокая	Низкая
Требования к вычислениям	Низкие	Средние–высокие
Скорость обработки (на CPU)	< 10 мс	60–80 мс
Устойчивость к шумам	Высокая	Средняя–высокая

Принципы работы магнитометрического канала

Магнитометрический канал позволяет контролировать состояние каната на основе анализа локальных искажений магнитного поля в стальном канате, возникающих вследствие дефектов, нарушающих непрерывность ферромагнитной среды. В основе метода лежит принцип утечки магнитного потока, позволяющий выявлять повреждения внутренней структуры, недоступные визуальному контролю. Такая форма диагностики эффективна для обнаружения обрывов внутренних проволок, усталостных трещин, локальных потерь металлического сечения и глубинной коррозии [17, 18].

Сигнал регистрируется с помощью массива магнитных сенсоров, равномерно распределённых по периметру диагностической головки. В качестве сенсорных элементов применяются датчики Холла, индукционные катушки и магниторезистивные элементы. Конфигурация сенсоров подбирается в соответствии с диаметром каната, необходимой чувствительностью и дискретностью сканирования. Частота оцифровки и пространственный шаг привязаны к скорости движения каната и обеспечивают синхронизацию с данными оптической подсистемы [20, 21].

Необработанная информация, поступающая с датчиков, проходят этап предварительной обработки, включающий подавление низкочастотных дрейфов, фильтрацию шумов, нормализацию амплитуды и устранение искажений, вызванных вибрацией и нестабильной подачей каната. Затем для каждого зарегистрированного сигнала извлекаются диагностически значимые признаки, отражающие форму, амплитуду и пространственные характеристики: максимальная индукция, ширина пика, симметрия сигнала, протяжённость аномалии, а также вовлечение соседних сенсоров. Все признаки формируют вектор фиксированной длины, подаваемый на вход модели машинного обучения [22].

Для классификации магнитных аномалий также используется алгоритм градиентного бустинга на решающих деревьях. Такой выбор обусловлен его устойчивостью к шуму, возможностью обработки слабо структурированных числовых признаков, интерпретируемостью и высокой точностью на малых обучающих выборках. Для каждого события классификатор возвращает вероятность принадлежности к одному из типов дефектов. Алгоритмическая часть магнитометрического канала также включает блок постобработки, исключающий ложноположительные срабатывания путём анализа временной стабильности сигнала и его корреляции с соседними каналами. При необходимости задействуется модуль «неопределённой классификации», в котором событие сохраняется в отдельный буфер для последующего экспертного анализа и возможного дообучения модели [23].

Интеграция каналов и алгоритм принятия решений

Согласованная работа оптического и магнитометрического каналов реализована через механизм временной и пространственной синхронизации. Каждый канал формирует результаты анализа в виде набора событий с привязкой к координате вдоль каната и метке времени, что позволяет проводить сопоставление сигналов и их объединение в рамках

унифицированной диагностической логики. При обнаружении аномалий данные классификации дополняются вероятностными оценками, отражающими степень уверенности моделей в принадлежности события к определённому типу дефекта [24, 25].

Пространственная привязка данных оптического и магнитометрического каналов осуществляется по сигналам инкрементального энкодера, измеряющего линейное перемещение каната. Каждому измерению/кадру обоих каналов присваивается единая координата вдоль каната x , вычисляемая по числу импульсов энкодера, что переводит разнородные потоки данных в общие координаты по длине от точки старта. При этом измерительные устройства каналов конструктивно разнесены вдоль установки на 0,30 м, поэтому при объединении данных вводится постоянная поправка по координате $\Delta x = 0,30$ м (сдвиг одного из рядов относительно другого). На практике исходные данные представляют собой два одномерных ряда с различной точкой старта (разные моменты начала регистрации), поэтому перед слиянием выполняется выравнивание начальных индексов по нулевой отметке энкодера и последующая коррекция фиксированного сдвига, после чего значения обоих каналов относятся к одному и тому же участку каната.

На рисунке 1 приведён алгоритм функционирования системы контроля, отражающий основные этапы работы: от регистрации сигнала до построения карты состояния каната.

Для оценки согласованности между каналами и повышения надёжности классификации используется сопоставление координат и дефектных меток. При совпадении типа и местоположения дефекта, событие получает статус подтверждённого. В случае расхождений — формируется событие с пониженной уверенностью, требующее последующего анализа или повторного контроля [26, 27].

В задачах анализа сигналов, представленных в пространственной области (например, вдоль протяжённых объектов, таких как канаты, трубы или транспортные магистрали), возникает необходимость синхронизации двух одномерных дискретных последовательностей, заданных на различных пространственных сетках. В отличие от временных рядов, синхронизация в данном случае осуществляется не по шкале времени, а по координате расстояния. Ниже приводится обобщённый алгоритм синхронизации таких рядов [28].

1. Нормализация пространственной шкалы

Пусть заданы два ряда:

$A = \{a_i\}_{i=1}^n$, соответствующий координатам $X^A = \{x_i^A\}_{i=1}^n$;

$B = \{b_j\}_{j=1}^m$, соответствующий координатам $X^B = \{x_j^B\}_{j=1}^m$.

Поскольку ряды определены на различных неравномерных сетках, в первую очередь производится нормализация шкалы расстояний путём линейной или сплайн-интерполяции сигналов на единую пространственную сетку $X = \{x_k\}_{k=1}^K$, равномерно покрывающую объединённый диапазон исходных координат:

$$X = [\min(x_1^A, x_1^B), \max(x_n^A, x_m^B)], \quad (1)$$

где $\min(x_1^A, x_1^B)$ – минимальная координата;

$\max(x_n^A, x_m^B)$ – максимальная координата;

x_k – значение k -й точки новой координатной сетки, $k=1..K$;

k – общее число узлов новой сетки.

По данной сетке выполняется интерполяция сигналов A и B , в результате чего формируются непрерывные аппроксимации $\hat{A}(x)$ и $\hat{B}(x)$, пригодные для последующего анализа.

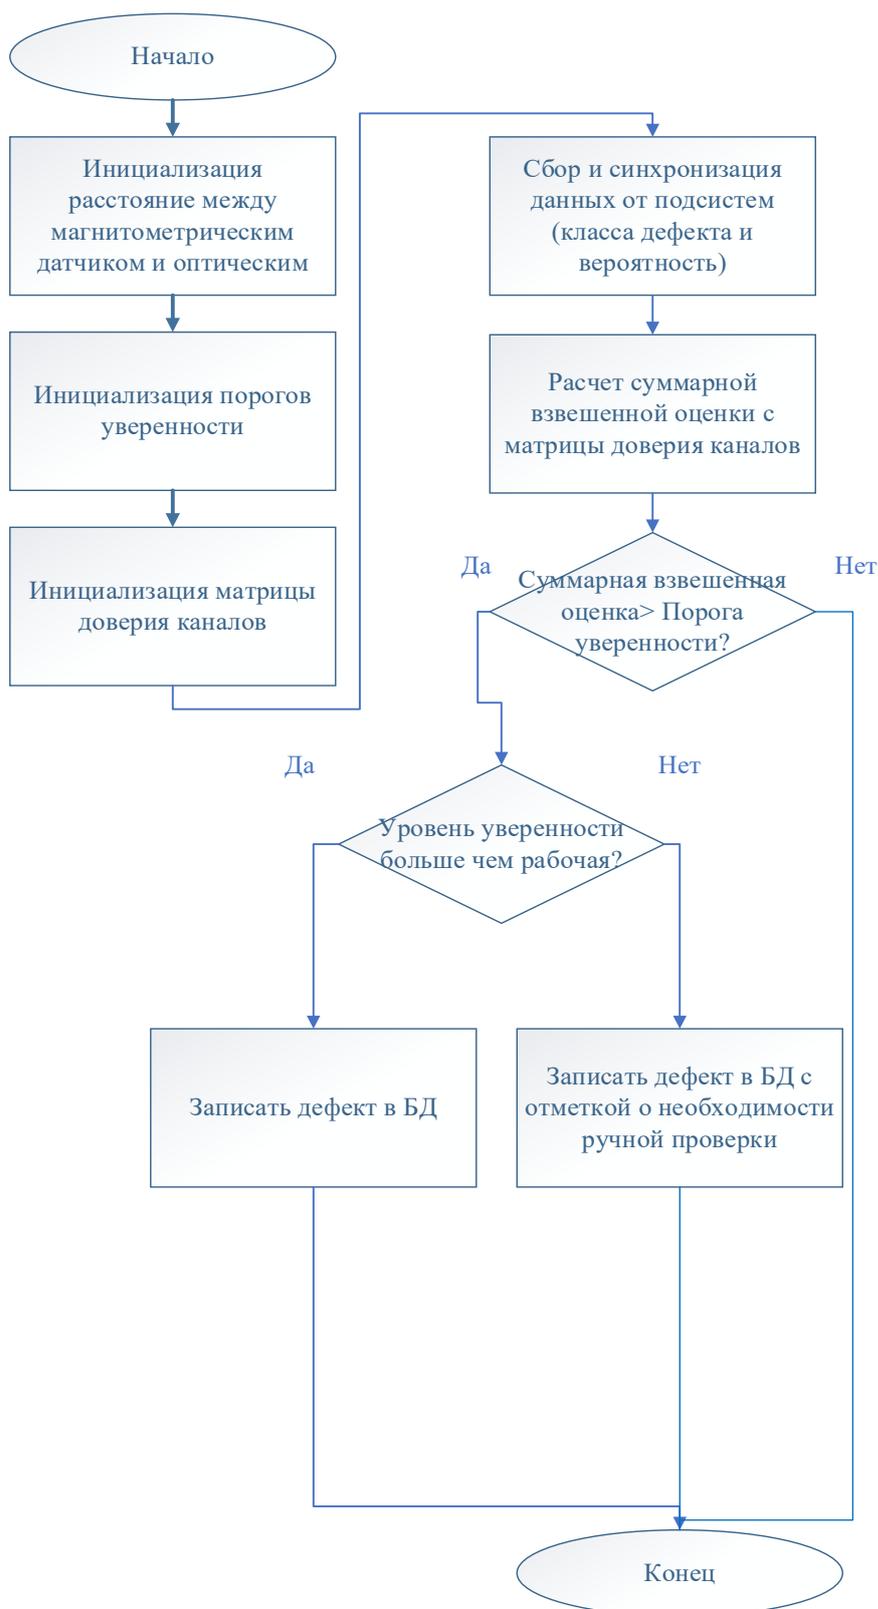


Рис. 1. – Алгоритм работы комплексной системы автоматизированного контроля дефектов стальных грузоподъемных канатов

2. Оценка сдвига методом кросс-корреляции

Для предварительной оценки сдвига между сигналами может применяться метод кросс-корреляции:

$$R_{AB}(\delta) = \sum_{k=1}^K \hat{A}(x_k) \cdot \hat{B}(x_k + \delta) \quad (2)$$

где $R_{AB}(\delta)$ – значение корреляции при сдвиге δ ;

$\hat{A}(x_k)$ – значение интерполированного сигнала А в узле x_k ;

$\hat{B}(x_k + \delta)$ – значение сигнала В, смещенного по координате на величину δ ;

$\delta \in R$ – параметр пространственного смещения;

K – количество узлов интерполяционной сетки.

Максимум функции $R_{AB}(\delta)$ соответствует оптимальному сдвигу δ^* , при котором достигается наибольшее взаимное сходство. Полученное значение может использоваться как предварительная оценка смещения пространственных осей двух сигналов.

3. Выравнивание с использованием динамического преобразования времени.

Для более точного и нелинейного согласования двух сигналов применяется метод динамического преобразования времени, адаптированный для пространственной области. Рассматривается матрица локальных расстояний:

$$D(i, j) = |a_i - b_j| + \alpha \cdot |x_i^A - x_j^B| \quad (3)$$

где $D(i, j)$ – локальное расстояние между i -й точкой сигнала А и j -й точкой сигнала В;

a_i – значение сигнала А в точке i ($i=1..n$);

b_j – значение сигнала В в точке j ($j=1..m$);

x_i^A, x_j^B – координаты, соответствующие a_i, b_j ;

α – весовой коэффициент, учитывающий пространственное расхождение координат.

Оптимальный путь выравнивания определяется путём минимизации накопленной стоимости перехода:

$$DTW(i, j) = D(i, j) + \min \begin{cases} DTW(i-1, j) \\ DTW(i, j-1) \\ DTW(i-1, j-1) \end{cases} \quad (4)$$

где $DTW(i, j)$ – минимальная суммарная «стоимость» выравнивания префиксов сигналов А и В до точек i и j соответственно;

Результатом является функция соответствия индексов $i \leftrightarrow j$, отражающая наиболее вероятное соответствие между элементами сигналов А и В с учётом как амплитудного, так и пространственного расстояния.

Применение описанного алгоритма позволяет выравнивать сигналы, обладающие различной пространственной дискретизацией и нелинейными искажениями координатной шкалы, что особенно актуально при обработке сигналов в инженерной диагностике, метрологии и задачах технического зрения [29, 30].

Обнаруженные отклонения фиксируются в диагностической карте каната. Каждому событию присваивается координата (с точностью до 15 см), временная метка, классификация дефекта и уровень достоверности. Последний определяется в зависимости от совпадения результатов двух каналов: при согласии решения классифицируется как подтверждённое, в случае расхождения — как дефект с пониженной уверенностью и требует последующего анализа.

Кроме идентификации конкретных дефектов, система позволяет формировать интегральный показатель состояния каната — локальную плотность дефектов (количество подтверждённых аномалий на 100 метров).

Этот параметр используется в качестве критерия для оценки остаточного ресурса и принятия решений о допустимости дальнейшей эксплуатации каната.

Для единообразного принятия решений вводятся три порога уверенности: Высокая уверенность, где рассчитанная уверенность больше 0.8, рабочий, в пределах от 0.6 до 0.8 и минимальный, где в дальнейшем требуется ручное подтверждение дефекта оператором.

Объединённая оценка вероятности принадлежности события к дефекту D_i рассчитывается по формуле:

$$P_{\text{fusion}}(D_i) = w_{\text{CNN}} \cdot P_{\text{CNN}}(D_i) + w_{\text{Catboats}} \cdot P_{\text{Catboats}}(D_i) + w_M \cdot P_M(D_i), \quad (5)$$

где: $P_{\text{CNN}}(D_i)$, $P_{\text{Catboats}}(D_i)$ и $P_M(D_i)$ — вероятности, полученные соответственно от подсистемы на основе сверточной нейронной сети, подсистемы на основе профиля толщины каната и магнитного классификаторов,

w_{CNN} , w_{Catboats} и w_M — весовые коэффициенты, определяемые эмпирически на основе чувствительности каждого канала к различным видам дефектов.

Для данного исследования их значения представлены в таблице 2. Кроме классификации отдельных дефектов, система формирует интегральный показатель состояния каната — плотность дефектов на 100 метров. Этот параметр используется для оценки остаточного ресурса и принятия решений о возможности дальнейшей эксплуатации. Также учитывается глубина и масштаб повреждения, поскольку один критический дефект может сигнализировать о необходимости замены каната.

Таблица № 2

Матрица доверия.

Тип дефекта	Оптический канал	Магнитометрический
-------------	------------------	--------------------

	Анализ 2D изображения сверточной нейронной сетью	Анализ размеров сечения градиентным бустингом	канал
Внутренний дефект	0,1	0,1	0,8
Изгиб	0,45	0,45	0,1
Залом	0,45	0,45	0,1
Разрыв	0,4	0,4	0,2

Результаты и обсуждение

Разработанная система обеспечивает комплексный контроль технического состояния стального каната путём интеграции двух синхронизированных каналов диагностики — оптического и магнитометрического. Такая архитектура позволяет выявлять как внешние, так и внутренние повреждения, в том числе дефекты, недоступные для традиционных методов визуального осмотра [31-33].

Для оценки эффективности предложенной комплексной системы контроля технического состояния стальных канатов была проведена верификация на стандартной выборке участков с известными дефектами. Анализу подвергались одни и те же фрагменты канатов, содержащие дефекты типа изгиб, залом, разрыв проволок, а также участки без повреждений. Диагностика выполнялась одновременно тремя каналами: нейросетевым оптическим, геометрическим по сечению и магнитометрическим. Это позволило сопоставить результаты, выявить зоны согласованности и установить границы применимости каждого из подходов.

Нейросетевой канал реализован на базе сверточной архитектуры и ориентирован на визуальный анализ поверхности каната. Выделение дефектов производилось по изображениям в различных условиях — при изменении расстояния до объекта и освещённости. Величины коэффициентов выделения дефектов усреднялись по пяти режимам. Средняя точность классификации составила 0,85 для разрывов, 0,79 для заломов (по аналогии с

«абразивным износом» в представленных данных) и 0,76 для изгибов. Для участков без дефектов, по совокупным данным валидации, модель не демонстрировала ложных срабатываний, что позволяет оценить точность на уровне 0,91.

Второй канал основан на анализе формы поперечного сечения. Изображения, полученные в ортогональной проекции, обрабатывались с извлечением профиля толщины. Далее производилось построение агрегированных числовых признаков (среднее, стандартное отклонение, экстремумы и др.), которые подавались в классификационную модель CatBoost. По результатам верификации, отражённым в [11], точность модели достигла: 0,97 для разрывов, 0,96 для заломов, 0,94 для изгибов и 0,93 для участков без дефектов. Высокие значения метрик обусловлены стабильностью геометрических паттернов и малой чувствительностью к шумам, вибрациям и искажениям фона.

Третий канал анализировал изменение магнитного поля вдоль каната. Первичная проверка чувствительности проводилась вручную с использованием магнитометра ICM-20948. При разрывах наблюдалось увеличение напряжённости магнитного поля до 31%, при заломов — до 23%, при изгибах — до 18% относительно фонового уровня. Эти данные легли в основу формирования обучающей выборки для модели CatBoost, использующей сигналы от магнитного датчика. Классификатор, построенный на базе признаков формы сигнала (амплитуда, ширина, асимметрия и др.), показал следующие метрики F1-score: 0,94 для разрывов, 0,91 для заломов, 0,87 для изгибов, 0,96 для фоновых участков. Совпадение координат между данными ручного прибора и моделью составило 100% для заломов и разрывов, 87% — для изгибов.

Результаты обобщены в таблице 3.

Для повышения достоверности интерпретации результатов контроля в предлагаемой системе реализован механизм перекрёстного подтверждения. Диагностическое событие фиксировалось как достоверное только в случае его обнаружения двумя или более независимыми методами в пределах одного координатного окна с согласованием по типу дефекта. Такой подход позволяет минимизировать влияние ложных срабатываний, вызванных шумами, нестабильными условиями наблюдения или локальными артефактами сигнала [33-35].

Таблица № 3

Метрики точности классификации дефектов каната по каналам

Тип дефекта	Оптический канал		Магнитометрический канал	Точность комбинированной подсистемы
	Анализ 2D изображения сверточной нейронной сетью	Анализ размеров сечения градиентным бустингом		
Внутренний дефект	0,03	0,15	0,86	0,87
Изгиб	0,76	0,94	-	0,96
Залом	0,79	0,96	0,13	0,96
Разрыв	0,85	0,97	0,76	0,98
Без дефекта	0,93	0,95	0,96	0,96

По результатам совмещённого анализа, 97% всех дефектов были подтверждены мультиканальной идентификацией, а в 78 % случаев совпадение обнаружения и классификации наблюдалось по всем доступным каналам одновременно. Такая избыточность существенно повышает устойчивость системы к эксплуатационным помехам, включая нестабильное освещение, вибрации, загрязнение поверхности и электромагнитные воздействия. Это обеспечивает более надёжную интерпретацию сигналов и снижает риск пропуска критических повреждений при контроле канатов в реальном времени [36, 37].

Заключение

В настоящей работе разработана и верифицирована автоматизированная система комплексного контроля состояния стальных канатов, основанная на интеграции визуального и магнитного диагностических каналов. Предложенная архитектура объединяет методы машинного обучения, включая градиентный бустинг и сверточные нейронные сети, с механизмами временной и пространственной синхронизации данных, что обеспечивает высокую достоверность выявления как поверхностных, так и внутренних дефектов.

Экспериментальные испытания проводились на дефектах трёх типов — изгиб, залом и разрыв, а также на эталонных (бездефектных) участках. Выбор именно этих нарушений обусловлен их высокой распространённостью в условиях эксплуатации, а также возможностью их достоверного воссоздания в контролируемых лабораторных условиях. Эти дефекты вызывают выраженные изменения геометрии и структуры каната, что позволяет надёжно регистрировать их средствами оптической и магнитометрической диагностики. На основании анализа синхронизированных данных установлено, что до 97% всех дефектов были подтверждены более чем одним каналом, из них 78% — всеми тремя, что свидетельствует о высокой чувствительности и устойчивости системы при комбинированной обработке сигналов.

В то же время остальные типы повреждений, такие как локальный и комбинированный износ, выдавливание сердечника, утрата металлической площади, коррозионные очаги, перекручивание, нестабильность укладки и волнообразные искажения, пока не подвергались целенаправленной верификации в рамках данной работы. Их диагностика требует создания расширенного размеченного датасета и проведения натурных испытаний на различных типах канатов.

В дальнейшем планируется проведение полноформатной экспериментальной оценки эффективности системы на расширенном множестве дефектов, а также реализация механизмов инкрементального обучения, позволяющих адаптировать классификаторы под новые условия эксплуатации. Предлагаемая архитектура показала технологическую состоятельность и потенциальную применимость в составе промышленных систем мониторинга технического состояния канатов в реальном времени.

Литература (References)

1. Zhang, G.; Tang, Z.; Fan, Y.; Liu, J.; Jahanshahi, H.; Aly, A.A. Steel Wire Rope Surface Defect Detection Based on Segmentation Template and Spatiotemporal Gray Sample Set. *Sensors* 2021, 21, 5401. DOI: 10.3390/s21165401
2. Zhao, G.; Han, C.; Yu, Z.; et al. Technical Code Analysis of Geomagnetic Flaw Detection of Suppression Rigging Defect Signal Based on Convolutional Neural Network. *Appl. Sci.* 2024, 14, 11852. DOI: 10.3390/app141811852
3. Posphehov G. B., Savón Yu., Moseykin V. V. Landslide susceptibility zonation using the analytical hierarchy process. A case study of Guantanamo Province. *MIAB. Mining Inf. Anal. Bull.* 2024;(1):125-145. DOI: 10.25018/0236_1493_2024_1_0_125.
4. Jalonen, T.; Al-Sa'd, M.; Mellanen, R.; et al. Real-Time Damage Detection in Fiber Lifting Ropes Using Lightweight Convolutional Neural Networks. *arXiv2023*, arXiv: 2302.11947. DOI: 10.48550/arXiv.2302.11947
5. You, S.; Yang, L.; Kuang, Z.; et al. A Signal Matrix-Based Local Flaw Detection Framework for Steel Wire Ropes Using CNN. *arXiv2025*, arXiv: 2504.10952. DOI: 10.48550/arXiv.2504.10952

6. Bolobov, V.I.; Plaschinskiy, V.A. On the Assessment of Energy Consumption When Splitting Rock Fragments. *Obogashch. Rud* 2023, 2, 3–8. rudmet.ru/journal/2208/article/36606/
7. Bao, Y.; Hu, B. Optical Nondestructive Damage Detection Method for Steel Wire Ropes in Plateau Environment. *arXiv2024*, arXiv: 2402.03843. DOI: 10.48550/arXiv.2402.03843
8. Quiroz, V.E.; Calvopiña, D. Training of Highly Qualified Specialists in the Field of Software Development: Problems and Solutions in Higher Educational Institutions of Ecuador. *ITM Web Conf.* 2024, 59, 04008. DOI: 10.1051/itmconf/20245904008
9. Zhang, Y.; Han, J.; Jing, L.; Liu, F. Intelligent Fault Diagnosis of Broken Wires for Steel Wire Ropes Using GAN. *Appl. Sci.* 2022, 12, 11552. DOI: 10.3390/app122211552
10. Peng, Y.; Liu, J.; He, J.; Ma, Q. Damage Width Identification Using Residual Networks and Feature Fusion. *Machines* 2024, 12, 744. DOI: 10.3390/machines12110744
11. Kulchitskiy, A.A.; Mansurova, O.K.; Nikolaev, M.Y. Recognition of Defects in Hoisting Ropes of Metallurgical Equipment by an Optical Method Using Neural Networks. *Chernye Metally* 2023, 3, 81–88. DOI: 10.17580/chm.2023.03.13
12. Semykina, I.Y.; Kipervasser, M.V.; Gerasimuk, A.V. Study of Drive Currents for Lifting Bridge Cranes of Metallurgical Enterprises for Early Diagnosis of Load Excess Weight. *J. Min. Inst.* 2021, 247, 122–131. DOI: 10.31897/PMI.2021.1.13
13. Zhang, X.; Wang, Z.; Liu, G. Wire Rope Defect Recognition Based on Attention-Enhanced CNN. *Sensors* 2023, 23, 3158. DOI: 10.3390/s23063158

14. Wang, Y.; Jiang, X.; Hu, J. Lightweight Neural Network Model for Real-Time Wire Rope Defect Detection. *Electronics* 2021, 10, 2948. DOI: 10.3390/electronics10232948
15. Fedorova, E.R.; Morgunov, V.V.; Pupysheva, E.A. Effect of Variation of Internal Diameter Along the Length of a Rotary Kiln on Material Movement. *Non-ferrous Metals* 2024, 1, 28–34. DOI: 10.17580/nfm.2024.01.05
16. Li, J.; Wang, M.; Zhao, H. Comparison of Classical and Deep Learning Methods for Steel Rope Fault Detection. *Sensors* 2021, 21, 7634. DOI: 10.3390/s21227634
17. Liu, S.; Sun, Y.; Jiang, X.; Kang, Y. Signal Processing Methods in Wire Rope Defect Detection Using Hall Sensors. *Measurement* 2021, 171, 108768. DOI: 10.1016/j.measurement.2020.108768
18. Zhang, J.; Tan, X.; Zheng, P. Wire Rope Discontinuity Detection Using MFL and Hilbert-Huang Transform. *Sensors* 2021, 21, 6612. DOI: 10.3390/s21196612
19. Liu, Y.; Cheng, Y.; Wang, C. Feature Fusion for Magnetic Flux Leakage Defect Detection Based on Multi-Channel Analysis. *IEEE Trans. Ind. Electron.* 2022, 69, 11972–11981. DOI: 10.1109/TIE.2021.3073953
20. Skamyin, A.; Shklyarskiy, Y.; Lobko, K.; Dobush, V.; Sutikno, T.; Hatta, M.J. Impedance Analysis of Squirrel-Cage Induction Motor at High Harmonics Condition. *Indones. J. Electr. Eng. Comput. Sci.* 2024, 33, 31–41. DOI: 10.11591/ijeecs.v33.i1
21. Shklyarskiy, Y.E.; Lobko, K.K.; Kuznetsova, Y.N.; Vorobyev, M.S. Study of Combined Motor Load in the Presence of High Harmonics in Electrical Networks. *Energetika (CIS)* 2024, 67(4), 285–299. DOI: 10.21122/1029-7448-2024-67-4-285-299

22. Wang, Z.; Zhu, W.; Liang, Z. Intelligent Magnetic Signal Analysis for Internal Wire Rope Defects Using CatBoost. *IEEE Sens. J.* 2023, 23, 11691–11700. DOI: 10.1109/JSEN.2023.3272413
 23. He, Y.; Li, Z.; Wang, Y. Multi-Sensor Fusion in Wire Rope Internal Damage Detection. *IEEE Access* 2022, 10, 103011–103020. DOI: 10.1109/ACCESS.2022.3201236
 24. Zhou, P.; Zhou, G.; He, Z.; Li, X. Automatic Detection of Wire Rope Damage Using Deep Learning-Based Visual Perception. *IEEE Trans. Instrum. Meas.* 2020, 70, 1–11. DOI: 10.1109/TIM.2020.2992523
 25. Jin, Y.; Tang, W.; Huang, M. Comparative Study of Detection Algorithms under Varying Illumination. *Measurement* 2022, 187, 110272. DOI: 10.1016/j.measurement.2021.110272
 26. Bratskikh, D.S.; Romasheva, N.V.; Konopelko, A.Y.; Nikolaychuk, L.A. Model of Supply Chain Management in the Oil and Gas Industry Using Digital Technologies. *Oil Industry* 2024, 7, 120–125. DOI: 10.24887/0028-2448-2024-7-120-125
 27. Xu, Z.; Liu, Q.; Chen, D. 2D-FFT Based Defect Detection in Wire Ropes with Neural Network Fusion. *IEEE Access* 2021, 9, 143612–143620. DOI: 10.1109/ACCESS.2021.3119264
 28. Bazhin, V.Yu.; Tran Duc Hieu; Makushin, D.V.; Krylov, K.A. Influence of Temperature Regime of the Combined Process of Casting and Rolling of Strips from High-Alloy Aluminium Alloys. *Non-ferrous Metals* 2024, 2, 45–51. DOI: 10.17580/nfm.2024.02.07
 29. Zhang, F.; Gao, W.; Li, Y. Evaluation of CNN-Based and Classical Methods in Multichannel Signal Fusion. *IEEE Access* 2023, 11, 80112–80124. DOI: 10.1109/ACCESS.2023.3274110
-

30. Xu, C.; Li, H.; Zhang, H. Signal Fusion for Synchronized Magnetic and Optical Defect Recognition. *Sensors* 2022, 22, 10325. DOI: 10.3390/s222410325
31. Zhou, P.; Zhou, G.; He, Z.; Huang, M. Visual Detection Method for Mine Hoisting Wire Ropes. *Meas. Sci. Technol.* 2024, 35, 115018. DOI: 10.1088/1361-6501/ad2dbe
32. Chen, Q.; Zhang, J.; Ye, Q. Detection of Wire Rope Damage Based on Magnetic Flux and Vision. *J. Fail. Anal. Prev.* 2023, 23, 1275–1287. DOI: 10.1007/s11668-023-01596-w
33. Bolshunov, A.V.; Ignatev, S.A.; Gorelik, G.D.; et al. Comprehensive Studies of the Snow-Firn Layer in the Area of the Russian Antarctic Vostok Station. *J. Min. Inst.* 2025, 1–13. (DOI появится после выхода номера)
34. Bolshunov, A.V.; Vasilev, D.A.; Dmitriev, A.N.; et al. Results of Complex Experimental Studies at Vostok Station in Antarctica. *J. Min. Inst.* 2023, 263, pp. 724–741. DOI: 10.31897/PMI.2023.6.07
35. Peng, Y.; Liu, J.; He, J.; Ma, Q. Neural Classification of Wire Rope Damage with Residual Architectures. *Machines* 2024, 12, 744. DOI: 10.3390/machines12110744
36. Zhang, X.; Wang, Z.; Liu, G. Attention-Enhanced CNN for Rope Defect Recognition. *Sensors* 2023, 23, 3158. DOI: 10.3390/s23063158
37. Wang, Y.; Jiang, X.; Hu, J. Real-Time Defect Detection in Wire Ropes with Lightweight Models. *Electronics* 2021, 10, 2948. DOI: 10.3390/electronics10232948

Авторы согласны на обработку и хранение персональных данных.

Дата поступления: 5.01.2026

Дата публикации: 3.03.2026