

СИСТЕМА ДИАГНОСТИКИ РЕЛЬСОВЫХ СКРЕПЛЕНИЙ НА ВЫСОКОСКОРОСТНЫХ ЖЕЛЕЗНЫХ ДОРОГАХ НА ОСНОВЕ ГЛУБОКОЙ НЕЙРОННОЙ СЕТИ

С. П. Орлов✉, Н. А. Ефимушкин, Н. В. Ефимушкина

*Кафедра вычислительной техники, orlovsp1946@gmail.com,
ФГБОУ ВО «Самарский государственный технический университет»,
Самара, Россия*

Ключевые слова: глубокое обучение; диагностика; искусственная нейронная сеть; распознавание изображений; рельсовые скрепления.

Аннотация: Представлена система диагностики состояний рельсовых скреплений железнодорожных путей по видеоматериалам, полученным вагоном-путеизмерителем. Выявлено множество классов наиболее существенных дефектов рельсовых скреплений, влияющих на надежность движения составов. Система диагностики реализована на основе предварительно обученной нейронной сети модели SSD Mobilenet v3 Small COCO. Выполнен анализ метрик при распознавании дефектов скреплений. Приведены графики основных метрик нейронной сети при распознавании рельсовых скреплений в зависимости от числа эпох обучения. Показано, что предлагаемая система диагностики обеспечивает точность определения дефектов не ниже 0,96. Высокая точность достигнута предварительной обработкой кадров датасета рельсового пути: разворота, масштабирования и разметки изображений.

Введение

Обеспечение безопасности перевозок – одна из важнейших задач Российских железных дорог. Для высокоскоростных магистралей существенную роль играет состояние элементов железнодорожных путей, в частности, рельсовых скреплений. Они предназначены для фиксации рельсов на шпалах и обеспечения электроизоляции на железнодорожных участках с электрической тягой и автоматической блокировкой [1]. Скрепления обеспечивают поддержание геометрических параметров пути: ширины колеи, уровня высоты, параллельности и вертикальности рельсов и шпал.

Автоматизация диагностики состояний рельсовых скреплений является новым направлением в оценке исправности железнодорожных элементов и конструкций. В настоящее время для мониторинга железнодорожных путей используются вагоны-путеизмерители, представляющие передвижные лаборатории с оборудованием для видеосъемки рельсов [2]. Однако контроль рельсовых скреплений в реальном времени операторами невозможен. Актуальной является задача создания средств для автоматического анализа рельсовых скреплений и обнаружения их дефектов.

В статьях [3, 4] дано описание интеллектуальных систем для анализа рельсовых стыков и контактной сети железной дороги. Предлагаемая интеллектуальная система диагностики рельсовых скреплений является прямым развитием результатов работы [5]. Формирование исходных данных осуществляется так же, как

в работах [3, 5], с использованием изображений, полученных вагоном-путеизмерителем. Однако подход, использованный в работе [4] для оценки состояний элементов контактной сети, позволяет более точно определять положение рельсовых скреплений и их элементов, а также выявлять большее число дефектов. В настоящей статье указанный подход реализован для контроля высокоскоростного железнодорожного пути.

Методика оценки технического состояния рельсовых скреплений

Диагностика рельсовых скреплений проводится по видеокадрам, получаемым с видеокамер вагона-путеизмерителя. В нижней части вагона установлены четыре видеокамеры (по две камеры на каждый рельс) для съемки элементов железнодорожного пути. Видеопоток разбивается на кадры, при этом каждое изображение в кадре содержит 500 линеек пикселей, что обеспечивает соответствие одного пикселя одному миллиметру железнодорожного пути. Изображения помещаются в специальный файл, причем каждый кадр содержит как минимум одно скрепление.

Предлагаемая методика автоматической диагностики рельсовых скреплений заключается в следующем.

1. Подсистема препроцессинга по полученным кадрам определяет путевую координату скрепления с точностью до миллиметра и формирует файл изображений с контролируруемыми скреплениями.

2. Выполняется обработка кадров с целью детекции положения рельсового скрепления на изображении и формируется датасет для обучения нейронной сети, содержащий обучающую, валидационную и тестовую выборки.

3. Проводится обучение глубокой предобученной нейронной сети на тренировочных изображениях рельсовых скреплений с размеченными типами дефектов.

4. Затем обученная нейронная сеть выявляет дефекты рельсовых скреплений при движении вагона-путеизмерителя по участку пути в реальном времени.


Основная задача при создании системы диагностики рельсовых скреплений заключается в обеспечении высокой скорости работы нейронной сети при прохождении вагона-путеизмерителя по участку железной дороги. В этом случае возможно получение результатов в реальном времени, что позволяет сразу принимать решения о мероприятиях по ремонту рельсового пути, вплоть до остановки движения поездов. Главным критерием при этом является обеспечение высокой надежности рельсового пути, особенно для высокоскоростных магистралей.

Типы рельсовых скреплений и их дефекты

В настоящее время наиболее распространенными типами скреплений на российских железных дорогах и в странах СНГ являются клеммно-болтовые (КБ), анкерные (АРС), железобетонные (ЖБР) и скрепления для деревянных шпал (ДО) [1]. Первые три вида применяются для крепления рельсов к железобетонным шпалам и отличаются способом фиксации. Так, крепление рельсов может осуществляться болтами (КБ, ЖБР), анкерами (АРС) или гвоздями (ДО). При длительном использовании в рельсовых скреплениях могут возникать различные дефекты, связанные с крепежными компонентами, подкладкой, клеммой и другими элементами. Дефекты могут выводить скрепление из строя полностью или частично, и, как результат – происходит авария. На рисунке 1 приведены примеры дефектов рельсовых скреплений.

При анализе состояния рельсовых скреплений по изображениям, полученным вагоном-путеизмерителем, выполняется оценка следующих параметров:

- 1) наличие или отсутствие рельсового скрепления в кадре;
- 2) тип скрепления (КБ, АРС, ЖБР или ДО);



а)

б)

Рис. 1. Дефекты рельсовых креплений:

а – крепление КБ с отсутствующей клеммой;

б – изображение полностью отсутствующего крепления

3) тип дефекта, если дефект имеется (у одного крепления может быть сразу несколько дефектов);

4) число крепежных элементов;

5) координаты крепления в системе кадра;

6) путевая координата крепления.

Изображения рельсовых креплений получены при прохождении вагона-путеизмерителя на нескольких российских железных дорогах: Московской, Куйбышевской, Октябрьской, Горьковской, Свердловской, Юго-Восточной и Южно-Уральской. Съемка проводилась в теплое время года (с мая по сентябрь) при сухой и солнечной погоде. Длина участков дорог, по которым сформированы данные, составляла от 5 до 20 км. В процессе съемки вагон-путеизмеритель передвигался со скоростью 90...100 км/ч.

Нейронная сеть для анализа изображений с рельсовыми креплениями

Для контроля состояния рельсовых креплений использована предварительно обученная нейронная сеть SSD Mobilenet v3 Small COCO из зоопарка моделей Tensorflow-1 [6]. Модель SSD обучена на датасете COCO и показала высокую эффективность при мониторинге контактной сети железной дороги [4].

На первом этапе необходимо определить координаты крепления на изображении в кадре. Нейросетевой детектор способен достаточно хорошо распознавать крупные объекты (площадью более 8000 пикселей) при большом количестве данных (порядка нескольких тысяч объектов на класс). Изображения, сформированные путеизмерителем, объединены в 19 классов. Каждый класс описывает элемент или один из возможных дефектов крепления.

Для обеспечения высокого качества распознавания изображения, сформированные путеизмерителем, предварительно обрабатываются. При этом выполняется разметка кадров изображений программой Labelimg [4, 7], которая позволяет выделять в кадре наиболее важные прямоугольные объекты и определять координаты этих прямоугольников. На рисунке 2 приведены примеры разметки объектов с помощью Labelimg. Именно такие области модель SSD MobileNet отыскивает на передаваемых ей изображениях.

Названия меток, а также число входящих в них объектов приведены в табл. 1. Весь датасет содержит 14 966 изображений, на которых выделены 45 763 области, при этом 4 776 кадров содержат дефекты.




Рис. 2. Пример разметки крепления КБ:
а – исправное крепление; *б* – крепление с отсутствующей клеммой

Таблица 1

Описание классов рельсовых креплений

Идентификатор класса	Классы	Число объектов
ars_mono	Монорегулятор (АРС)	1244
ars_no_mono	Отсутствующий монорегулятор (АРС)	855
bind_missing	Отсутствующее крепление	143
bolt_unscrewed	Открученная гайка (КБ)	306
do	Скрепление типа ДО	1830
hole_do	Отсутствие костыля (ДО)	616
hole_square	Отсутствие крепежного болта (КБ)	805
jbr_bracket	Скоба крепления ЖБР	1083
jbr_defect2	Отсутствие клеммы (ЖБР)	56
jbr_nut	Крепежный болт (ЖБР)	176
jbr_plate	Отсутствие крепежного болта (ЖБР)	88
kb	Скрепление типа КБ	10644
kb105	Клемма ОП-105 (КБ)	793
kb105_defect	Дефект крепежного болта клеммы ОП-105 (КБ)	526
kb_no_bracket	Отсутствие клеммы (КБ)	1240
kb_twist	Разворот подкладки крепления (КБ)	773
nail_pulled	Наддернутый костыль (ДО)	156
nut	Крепежный болт (КБ)	21895
spring	Клемма крепления (АРС, ЖБР)	2534

Используемый в предлагаемой работе подход совместного анализа выделенных на изображении объектов (элементов крепления или дефектов) позволяет получить полную информацию о состоянии крепления.

Настройка и обучение модели

Перед началом обучения осуществляется проверка корректности разметки и удаление лишних данных, сформированных программой Labeling. Изображения датасета приведены к формату «рельс в кадре справа» поворотом кадров на 180°. На рисунке 3 показан пример применения представленной операции. Для видеокамер, осуществляющих съемку рельса слева, разворот не выполняется. Поэтому такая операция проводится только для кадров, полученных видеокамерами с правой стороны.


Приведение кадров к формату «рельс справа» обеспечивает более эффективное распознавание объектов креплений. Полученные результаты детектирования интерпретируются относительно исходного положения изображения (рис. 3, а).

Для анализа корректности выделения прямоугольных областей и отнесения их к соответствующим классам построены графики зависимости параметров областей от размера выборки. Наиболее важными считаются следующие параметры размеченных рамок: площадь, отношение ширины к высоте, частота появления в одном кадре, ширина и высота. На рисунке 4 приведен пример таких графиков для класса `kb_no_bracket`. Графики демонстрируют зависимости перечисленных характеристик от номера объекта, а для частоты появления области – от номера картинки.

Характер кривой зависимости параметра областей от размера выборки должен быть относительно плавным. Наличие отклонений параметра от среднего значения, как в меньшую, так и большую сторону, может свидетельствовать о неправильно размеченной области. Кадры с такими рамками при необходимости корректируются.

Набор исходных данных разбит на обучающую и тестовую выборки. Первая содержит 90 % изображений, вторая – 10 %. В работе использовано расширение датасета генерацией дополнительных кадров. Оно применяется только для обучающей выборки. Для кадров, содержащих дефекты рельсовых креплений, получены дополнительные изображения вертикальным разворотом. При выполнении операции разворота пиксели кадра преобразуются по формуле: $x' = x$, $y' = h - y$, где x' и y' , x и y – координаты пикселя в преобразованном и исходном изображениях соответственно; h – высота изображения.

Кроме вертикального разворота кадров использована операция их масштабирования `ssd_random_crop` [8]. Масштабирование выполняется средствами TensorFlow Object Detection API и применяется для генерации новых кадров в обучающей выборке.



а) б)
Рис. 3. Изображение рельсового скрепления:
а– до разворота на 180° , *б*– после разворота




Рис. 4. Графики контролируемых параметров области для класса kb_no_bracket

Таблица 2

Скорость обучения нейронной сети

Номера шагов обучения	1 – 4999	5000 – 9999	10000 – 49999	50000 – 99999	100000 – 200000
Скорость обучения	0,001	0,0005	0,0002	0,0001	0,00005

Вначале выполняется масштабирование, при котором уменьшается размер картинки на величину, определяемую случайным образом. Результат преобразуется к размерам кадров датасета билинейной интерполяцией. Генерация нового изображения с использованием масштабирования не применяется к кадрам, полученным вертикальным разворотом.

Для обучения детектора SSD использованы средства фреймворка Tensorflow Object Detection API. Изображения обучающей выборки сжаты до размеров 300×300 пикселей и представлены в оттенках серого. Максимальное количество шагов обучения выбрано равным 200000. Изображения передаются детектору батчами, каждый из которых содержит 64 кадра. В процессе обучения модели использован оптимизатор Адам с переменной скоростью обучения (табл. 2).

При обучении архитектура нейронной сети SSD MobileNet v3 small COCO использована практически в неизменном виде: модифицированы только слои предсказания прямоугольных областей и классов. Изменения выполнены автоматически в соответствии с числом классов в наборе данных, указанным в файле конфигурации config.

Результаты обучения

Для отслеживания основных метрик качества работы модели на заданных этапах тренировки использована панель Tensorboard, на которой строились графики изменения критериев COCO detection metrics в зависимости от номера эпохи

обучения. Наиболее важной характеристикой является среднее значение точности mAP (*англ.* mean Average Precision). Оно вычисляется как среднее из значений AP, рассчитанных для каждого класса. Кроме того, используется метрика IoU (*англ.* inter section overunion), которая количественно определяет перекрытие между прогнозируемым и истинным ограничивающими прямоугольниками на изображении. При этом величина IoU изменяется в интервале [0,5; 0,95] с шагом 0,05. Метрика AP вычисляется по выражению

$$AP = \sum_{k=0}^{k=n-1} [\text{recall}(k) - \text{precision}(k+1)] \times \text{precision}(k),$$

где n – число интервалов IoU; $\text{recall}(k)$ – значение полноты для k IoU; $\text{precision}(k)$, $\text{precision}(k+1)$ – значения точности для k и $(k+1)$ IoU соответственно.

Графики, полученные для средней точности mAP в зависимости от эпохи обучения, приведены на рис. 5. Для классического mAP на момент завершения обучения получено значение 0,72, а для метрики mAP при IoU = 0,5 – точность 0,96, которая близка к идеальным результатам.

На рисунках 5 – 7 обозначение 1 соответствует графику точных значений рассматриваемой метрики, обозначение 2 – графику аппроксимированной кривой этой метрики. Аппроксимация получена методом экспоненциального скользящего среднего (*англ.* Exponential Moving Average) с параметром сглаживания $\text{smoothing} = 0,99$.

Метрика mAP не несет всю информацию о качестве распознавания нейронной сетью обучающих кадров. Дополнительно в работе проанализированы результаты, полученные для метрики полноты mAR (*англ.* mean Average Recall). Метрика mAR определяется как среднее значение AR для каждого класса. Величина IoU принимает те же значения, что и при нахождении AP. Величина AR вычисляется в этом случае по формуле

$$AR = 2 \int_{0,5}^1 \text{recall}(x) dx,$$

где x – переменная, задающая значение IoU; $\text{recall}(x)$ – значение полноты при IoU = x .




Рис. 5. Зависимости mAP от номера эпохи:
а – классическое mAR; б – mAP при IoU = 0,5

Наиболее важными являются метрики AR@10 и AR@100 (medium) для 10 самых достоверных объектов в кадре и 100 самых достоверных объектов среднего размера (см. рис. 6). Для них после завершения обучения получены значения 0,77 и 0,72 соответственно, что свидетельствует о хорошем качестве модели.

Для оценки качества обучения также построены графики функций потерь loss (см. рис. 7). Потери разделены на классификационные (classification_loss), локализационные (localization_loss) и регуляризационные (regularization_loss) компоненты.




Рис. 6. Зависимости mAR от номера эпохи:
а – AR@10; б – AR@100




Рис. 7. Графики потерь:
а – классификационные; б – локализационные; в – регуляризационные; г – общие потери

Отметим, что зависимость общих потерь (total_loss) получена суммированием всех вышеуказанных потерь. На момент завершения обучения итоговые потери составили 0,17.

В работе используется вычисление классификационных потерь фокальной функцией [9], которая обеспечивает устранение проблемы несбалансированного датасета (различное число кадров для каждого класса). Модель неявно концентрируется на проблемных объектах. При этом проводится взвешивание каждого класса с учетом его влияния на значение потерь.

Фокальная функция потерь FL вычисляется по формуле

$$FL = - \sum_{i=1}^C \alpha_i (1 - y'_i)^\gamma \log(y'_i),$$

где C – число классов; i – номер класса; y'_i – предсказанные метки классов скреплений на кадрах; α_i – весовой коэффициент; γ – параметр фокуса.

Параметр фокуса $\gamma = 2$ – модулирующий фактор, показывающий степень уменьшения влияния на потери хорошо классифицируемых объектов. Коэффициент α_i придает вес i -му классу. Он помогает выполнять балансировку между предсказаниями о наличии и отсутствии класса объекта. При обучении принималось значение $\alpha_i = 0,75$.

Для вычисления локализационных потерь использована функция Хьюбера (Smooth MAE), которая является производной от функций MAE (*англ.* Mean Absolute Error) и MSE (*англ.* Mean Square Error) и золотой серединой между ними [10]. Функция Хьюбера менее чувствительна к значительным отклонениям данных и вычисляется по формуле

$$HL = \begin{cases} (y_{act} - y_{pred})^2 / 2 & \text{для } |y_{act} - y_{pred}| \leq \delta; \\ \delta (y_{act} - y_{pred})^2 / 2 & \text{в противном случае,} \end{cases}$$

где y_{act} , y_{pred} – истинные и предсказанные значения координат объектов соответственно; δ – пороговое значение, $\delta = 1$ – стандартное для функции потерь Хьюбера.

Анализ достоверностей классов

Оценка качества работы обученной модели проводится метрикой F1 (FScore), вычисляемой по формуле

$$F1 = \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}},$$

где precision и recall – значения соответственно точности и полноты при заданных достоверности классификатора и IoU областей.

Вычисление F1 проводится для изображений в исходном разрешении (500×500). При определении метрики указывается тип выборки (валидационная или тестовая), для которой проводится оценка качества работы модели. Объект считается распознанным верно, если метрика IoU между исходной рамкой и рамкой, полученной нейросетью, больше или равна 0,5 и при этом правильно идентифицирован класс обнаруженной области.

Для каждого класса вычисляется значение метрики F1, при этом расчет precision и recall проводится для достоверностей классификатора в диапазоне от 0,1 до 0,95 с шагом 0,05. Для IoU используется постоянное пороговое значение 0,5. Таким образом, для каждого класса вычисляется несколько значений F1 при разных достоверностях.

Best f1 for class ars_mono: 1.000, reached for scores [0.5, 0.55, 0.6, 0.65, 0.7]
 Best f1 for class ars_no_mono: 1.000, reached for scores [0.55]
 Best f1 for class bind_missing: 0.929, reached for scores [0.5, 0.55, 0.6, 0.65]
 Best f1 for class bolt_unscrewed: 0.622, reached for scores [0.25]
 Best f1 for class do: 0.943, reached for scores [0.65]
 Best f1 for class hole_do: 0.909, reached for scores [0.3]
 Best f1 for class hole_square: 0.960, reached for scores [0.25]
 Best f1 for class jbr_bracket: 0.990, reached for scores [0.55]
 Best f1 for class jbr_defect2: 1.000, reached for scores [0.45, 0.5, 0.55, 0.6]
 Best f1 for class jbr_nut: 1.000, reached for scores [0.3]
 Best f1 for class jbr_plate: 0.947, reached for scores [0.3]
 Best f1 for class kb: 0.843, reached for scores [0.65]
 Best f1 for class kb105: 0.990, reached for scores [0.4, 0.45, 0.5, 0.55, 0.6]
 Best f1 for class kb105_defect: 1.000, reached for scores [0.35, 0.4, 0.45]
 Best f1 for class kb_no_bracket: 0.990, reached for scores [0.25, 0.3, 0.35]
 Best f1 for class kb_twist: 0.989, reached for scores [0.4]
 Best f1 for class nail_pulled: 0.687, reached for scores [0.35]
 Best f1 for class nut: 0.973, reached for scores [0.5]
 Best f1 for class spring: 1.000, reached for scores [0.6, 0.65, 0.7]

Рис. 8. Пороги достоверностей для классов модели

Лучшим признается порог, для которого исследуемая метрика качества имеет максимальное значение. Если таких порогов несколько, то выбирается любой из них. Результаты оценки качества работы модели сохраняются в файл `calc_thres.log`. Фрагмент полученных записей для обученного в статье детектора приведен на рис. 8, где `f1` соответствует метрике `F1`. Выбор порогов проводится по тестовой выборке изображений рельсовых креплений.

Полученные результаты показывают, что модель в целом правильно распознает различные классы креплений и их элементов. Для большинства меток метрики `F1` близки к 1. Немного хуже модель распознает класс `kb`. Средние по качеству результаты получены для дефектов `bolt_unscrewed` и `nail_pulled`. Модель распознает их хуже в связи с небольшим количеством объектов и малыми размерами областей. Также на более низкое качество детектирования этих классов указывают низкие значения достоверности – меньше 0,4 для обоих классов. Проблема может быть решена увеличением числа кадров в датасете.

Заключение

Приведены результаты использования нейросети модели `SSD MobileNet v3 Small COCO`, обученной для решения задачи оценки состояний рельсовых креплений. Исходные данные для обучения сформированы при прохождении вагономпутьеизмерителем участка железнодорожного пути. Качество распознавания областей по метрике `mAPIoU` = 0,5 достигло значения 0,96, а по метрике `AR@10` – 0,77. Модель используется для оценки состояний рельсовых креплений на железных дорогах и ориентирована в первую очередь на высокоскоростные магистрали.

Список литературы

1. Крепление рельсов: промежуточные крепления на жд пути, виды и назначение. – Текст : электрон. – URL : <https://vsp-komplekt96.ru/stati/relsovye-skrepleniya> (дата обращения: 27.12.2023).
2. Вагон-лаборатория путьеизмерительный КВЛ-П2.1 – Текст : электрон. // Инфотранс. – URL : <https://infotrans-logistic.ru/kvlp21> (дата обращения: 10.12.2023).
3. Ефимушкин, Н. А. Интеллектуальная система диагностики рельсовых стыков железнодорожного пути / Н. А. Ефимушкин, Н. В. Ефимушкина, С. П. Ор-

лов // Математические методы в технологиях и технике. – 2022. – № 1. – С. 98 – 104. doi: 10.52348/2712-8873_ММТТ_2022_1_98

4. Ефимушкин, Н. А. Интеллектуальная система контроля инфраструктуры контактной сети железной дороги / Н. А. Ефимушкин, С. П. Орлов // Системы управления и информационные технологии. – 2023. – № 3(93). – С. 60 – 65.

5. Orlov, S. Machine Learning of Diagnostic Neural Network for Railway Track Monitoring / S. Orlov, A. Piletskaya, N. Kusakina, A. Tyugashev // In: Kravets A.G., Bolshakov A.A., Shcherbakov M. (Eds.). Cyber-Physical Systems: Intelligent Models and Algorithms. Studies in Systems, Decision and Control. – Springer, Cham, 2022. – Vol 417. – P. 55 – 65. doi: 10.1007/978-3-030-95116-0_5

6. TensorFlow 1 Detection Model Zoo // Github. – URL : https://github.com/tensorflow/models/blob/master/research/object_detection/g3doc/tf1_detection_zoo.md (дата обращения: 15.12.2023).

7. Nelson, J. LabelImg for Labeling Object Detection Data // Roboflow. – URL : <https://blog.roboflow.com/labelimg/> (дата обращения: 29.12.2023).

8. SSD: Single Shot MultiBox Detector / W. Liu, D. Angelov, D. Erhan, C. Szegedy, S. Reed, C. Fu, A. Berg // European Conference on Computer Vision. Lecture Notes in Computer Science. – Springer, Cham, 2016. – Vol. 9905. – P. 21 – 37. doi: 10.1007/978-3-319-46448-0_2

9. Understanding Categorical Cross-Entropy Loss, Binary Cross-Entropy Loss, Softmax Loss, Logistic Loss, Focal Loss and all those confusing names // Raúl Gómez blog. – URL : https://gombru.github.io/2018/05/23/cross_entropy_loss/ (дата обращения: 10.02.2024).

10. Neri Van Otten. Top 8 Loss Functions Made Simple & How To Implement Them In Python // Spot Intelligence. – 2018. – URL : <https://spotintelligence.com/2023/09/25/loss-functions/> (дата обращения: 10.02.2024).

Diagnostic System for Rail Fastenings on High-Speed Railways Based on a Deep Neural Network

S. P. Orlov✉, N. A. Efimushkin, N. V. Efimushkina

*Department of Computer Technology, orlovsp1946@gmail.com;
Samara State Technical University, Samara, Russia*

Keywords: deep learning; diagnostics; artificial neural network; image recognition; rail fastening.

Abstract: The paper presents a system for diagnosing the rail fastening conditions on railway tracks based on video materials obtained using a rail measuring car. The set of classes of the most significant defects in rail fastenings affecting the reliability of the railway train movement has been identified. The diagnostic system is developed on the basis of a pre-trained neural network using the Mobilenet v3 Small COCO SSD model. The analysis of defect recognition metrics has been performed, and diagrams of the main metrics of a neural network for recognizing rail fastenings are presented depending on the number of training epochs. It is shown that the proposed diagnostic system provides an object recognition accuracy of at least 0.96. High accuracy is achieved through pre-processing of rail track dataset frames: rotation, scaling and marking.

References

1. Available at: <https://vsp-komplekt96.ru/stati/relsovye-skrepleniya> (accessed 27 December 2023).
2. Available at: <https://infotrans-logistic.ru/kvlp21> (accessed 10 December 2023).
3. Efimushkin N.A., Efimushkina N.V., Orlov S.P. [Intelligent diagnostic system for rail joints of a railway track], *Matematicheskie metody v tekhnologiiakh i tekhnike* [Mathematical methods in Technology and Engineering], 2022, no. 1, pp. 98-104. doi 10.52348/2712-8873_MMTT_2022_1_98. (In Russ., abstract in Eng.)
4. Efimushkin N.A., Orlov S.P. [Intelligent control system for railway contact network infrastructure], *Sistemy upravleniya i informatsionnyye tekhnologii* [Control systems and information technology], 2023, no. 3(93), pp. 60-65. (In Russ., abstract in Eng.)
5. Orlov S., Piletskaya A., Kusakina N., Tyugashev A. Machine Learning of Diagnostic Neural Network for Railway Track Monitoring, *Cyber-Physical Systems: Intelligent Models and Algorithms. Studies in Systems, Decision and Control*, Springer, Cham, 2022, vol. 417, pp. 55-65. doi: 10.1007/978-3-030-95116-0_5
6. Available at: https://github.com/tensorflow/models/blob/master/research/object_detection/g3doc/tf1_detection_zoo.md (accessed 15 December 2023).
7. Available at: <https://blog.roboflow.com/labelimg> (accessed 29 December 2023).
8. Liu W., Angelov D., Erhan D., Szegedy C., Reed S., Fu C., Berg A. SSD: Single Shot MultiBox Detector, *European Conference on Computer Vision. Lecture Notes in Computer Science*, Springer, Cham, 2016, vol. 9905, pp. 21-37. doi: 10.1007/978-3-319-46448-0_2
9. Available at: https://gombru.github.io/2018/05/23/cross_entropy_loss/ (accessed 10 February 2024).
10. Available at: <https://spotintelligence.com/2023/09/25/loss-functions/> (accessed 10 February 2024).

System der Diagnostik von Schienenbefestigungen auf Hochgeschwindigkeitsbahnen basierend auf dem tiefen neuronalen Netzwerk

Zusammenfassung: Es ist ein System zur Diagnose des Zustands von Schienenbefestigungen an Eisenbahngleisen anhand von Videomaterial vorgestellt, das von einem Gleismesswagen aufgenommen worden ist. Es sind viele Klassen der bedeutendsten Mängel an Schienenbefestigungen identifiziert, die die Zuverlässigkeit der Zugbewegung beeinträchtigen. Das Diagnosesystem ist auf Basis des vortrainierten neuronalen Netzwerks des SSD Mobilenet v3 Small COCO-Modells implementiert. Es ist die Analyse der Metriken zur Erkennung von Verbindungsfehlern durchgeführt. Abhängig von der Anzahl der Trainingsepochen sind Diagramme der wichtigsten Metriken des neuronalen Netzwerks zur Erkennung von Schienenbefestigungen dargestellt. Es ist gezeigt, dass das vorgeschlagene Diagnosesystem eine Fehlererkennungsgenauigkeit von mindestens 0,96 bietet. Die hohe Genauigkeit ist durch die Vorverarbeitung der Bilder des Schienendatensatzes erreicht: Drehen, Skalieren und Markieren der Bilder.

Système de diagnostic des liaisons ferroviaires à haute vitesse basé sur un réseau neuronal profond

Résumé: Est présenté un système de diagnostic des états des fixations des voies ferrées à partir de vidéos obtenues par le testeur de voie. Sont identifiées de nombreuses classes de défauts les plus importants des fixations de rail, affectant la fiabilité du mouvement des compositions. Le système de diagnostic est basé sur le réseau neuronal pré-formé du modèle SSD Mobilenet v3 Small COCO. Est réalisée l'analyse des métriques pour la reconnaissance des défauts de liaison. Sont présentés les graphiques des principales mesures du réseau neuronal lors de la reconnaissance des liaisons ferroviaires en fonction du nombre d'époques d'apprentissage. Est démontré que le système de diagnostic proposé offre une précision de détection des défauts d'au moins 0,96. Une grande précision est obtenue par le prétraitement des images du DataSet de la voie ferrée: inversion, mise à l'échelle et balisage des images.

Авторы: *Орлов Сергей Павлович* – доктор технических наук, профессор, кафедры вычислительной техники; *Ефимушкин Николай Андреевич* – аспирант кафедры вычислительной техники; *Ефимушкина Наталья Владимировна* – кандидат технических наук, доцент кафедры вычислительной техники, ФГБОУ ВО «Самарский государственный технический университет», Самара, Россия.