



Научная статья

<https://doi.org/10.32523/3136-3385-2026-155-2-190-210>

Система диагностики неисправностей для вспомогательных преобразователей в электровозах на серии “hxd3c”

Давран Раджибаев* , **Ясур Анаркулов** 

Ташкентский государственный транспортный университет

E mail: radjibayev_railway@tstu.uz anorkulov_jasur@tstu.uz

Аннотация. В данной статье предлагается система диагностики неисправностей при вспомогательном преобразователе (ACU) в электровозах на базе HXD3C, работающих в железных дорогах Узбекистана. Вспомогательные дефекты преобразователя важны, потому что они влияют на двигатели тяги, системы охлаждения, компрессоры и другие вспомогательные машины, необходимые для безопасной эксплуатации локомотивов. В настоящее время в локомотивных депо Узбекистана расследование неисправностей в основном зависит от визуального контроля и ручного обзора крупного экспорта неисправностей системы управления и мониторинга поездов (TCMS). Этот процесс занимает много времени, в зависимости от опыта персонала, который может привести к отсутствию важных моделей ошибок в исторических записях, загруженных из TCMS. Вся предлагаемая система состоит из трех основных частей: миникомпьютер на базе ARM, диагностическое программное обеспечение с моделью машинного обучения интегрировано для будущего прогнозирующего обслуживания, и экран для вывода и отправки результатов в персонал. Предлагаемый метод использует загруженные записи ошибок TCMS и записи вспомогательных единиц преобразователя в качестве входа. Затем специальное программное обеспечение анализирует отчеты о данных и выводах, визуальные статистики и рекомендации по возможному руководству по обслуживанию сбоя ACU.

Ключевые слова: HXD3C; электровоз O'Z-EL; вспомогательный преобразователь; TCMS; диагностика неисправностей; обслуживание железнодорожного подвижного состава; LSTM; подготовка к прогнозному обслуживанию

Введение

Электровозы серии O'Z-EL являются важной частью современного парка электровозов с переменным током Узбекской железной дороги. Типы O'Z-EL и O'Z-ELR связаны с серией HXD3C, производимой CRRC Dalian для работы с магистральной линией 25 кВ, 50 Гц (Рисунок 1).



Рисунок 1. Электровоз серии O'Z-EL

Вспомогательные преобразователи являются важными компонентами электровозов, отвечающими за преобразование постоянного тока (DC) в переменный ток (AC) или наоборот. Основными функциями почти всех типов локомотивов являются охлаждение основных компонентов, таких как тяговые двигатели, зарядка аккумуляторов транспортного средства и подача электроэнергии в контур управления локомотивами [1] (Рисунок 2).




Рисунок 2. Основные вспомогательные машины электровозов, питающиеся от вспомогательного преобразователя

Локомотив может иметь здоровую тяговую схему, но все еще теряет доступность, когда вспомогательный выход преобразователя, напряжение управления воротами, качество входного питания, охлаждение или проводка становится нестабильным. Таким образом, диагностика ACU напрямую связана с надежностью, нагрузкой на склады и планированием обслуживания.

Результаты первоначальной диагностики неисправностей показывают, что с помощью простых визуальных графов вывода, таких как линейные и барные графы персонал технического обслуживания может примерно анализировать возникновение неисправностей и возможные причины неисправностей. Эти графики экономят много времени для персонала во время анализа ошибок в техническом обслуживании. И это очень важно для быстрого и качественного обслуживания электровозов. Этот первоначальный результат сам является важной частью данного исследования, поскольку частично автоматизирует процесс диагностики неисправностей в локомотивных депо узбекских железных дорог.

Результаты показывают, что предлагаемая диагностическая система может поддерживать и ускорить процессы технического обслуживания до того, как в железных дорогах Узбекистана будет доступен полный дистанционный мониторинг в реальном времени. Исследование способствует практическому подходу к использованию существующих исторических данных TCMS для улучшения диагностики ошибок, снижения ручного анализа и подготовки электровозов на базе O'Z-EL для потенциальной интеграции прогнозирующего обслуживания в будущем.

В локомотивных депо Узбекской железной дороги практическое обслуживание по-прежнему зависит от визуального осмотра и ручного обзора загруженного экспорта ошибок TCMS. Этот подход использует опыт работы с персоналом, но становится медленным, когда файл содержит тысячи повторяющихся сообщений, сообщений восстановления и неспецифических тревог. Важные модели ACU могут быть скрыты общими локомотивами. Ранние повторяющиеся события также могут быть пропущены, прежде чем они приводят к большему провалу.

Недавние исследования по техническому обслуживанию железных дорог подчеркивают платформы данных, подключенные TCMS, безопасную связь и предсказательное обслуживание [2], [3]. Эти направления важны, но полный дистанционный мониторинг требует инфраструктуры связи, контроля кибербезопасности, безопасности данных и организационной интеграции. Для текущих складов Узбекистана хранение местных таблиц данных TCMS вместе с офлайн-диагностической системой является практическим первым этапом. Это может создать полезный прогресс в обслуживании до внедрения облачного мониторинга в реальном времени в инфраструктуру железных дорог Узбекистана.

Основным вкладом в эту статью является депо-уровневый рабочий процесс для диагностики ошибок ACU с использованием существующих записей TCMS от локомотивов на базе HXD3C O'Z-EL (Рисунок 3). Система автоматически очищает сырые журналы, изолирует события ACU, отображает изменения параметров вокруг моментов ошибок, сортирует повторяющиеся группы ошибок ACU и сравнивает статистические, машинно-учебные и глубокие модели для краткосрочной диагностической поддержки. В исследовании рассматриваются три вопроса: содержат ли исторические данные TCMS полезные шаблоны разломов ACU; какие группы разломов ACU чаще всего встречаются; и

если выбранная модель дает полезную поддержку для обслуживания складов в Узбекистане.

Связанные предыдущие работы и разрыв в исследовании

Существующие диагностические исследования для электровозов серии HXD3C

Существующие исследования, связанные с HXD3C, сосредоточены в основном на бортовом диагностическом программном обеспечении, функциях питания и логике управления высоким напряжением. Zhang описал программное обеспечение для диагностики ошибок питания HXD3C, включая функции передачи, хранения, дисплея и диагностики [4]. Gao и др. изучали безопасную работу высоковольтного оборудования HXD3C посредством оптимизации последовательного управления [5]. Эти работы полезны для понимания диагностической среды локомотивов, но они не обеспечивают депо-уровневую систему, подходящую для исторических вспомогательных разломов преобразователей электровозов на базе HXD3C в железных дорогах Узбекистана.



Рисунок 3. Общая структура предлагаемой системы для диагностики неисправностей

Конвертер тяги и диагностика неисправностей инвертора

Электронная диагностика неисправностей была изучена многими исследователями методами на основе моделей, сигналов и данных. Gou и др. предложили метод диагностики разломов с открытым переключателем для однофазного ректификатора PWM в высокоскоростной системе тягового привода железной дороги [6]. Yu и др. изучали диагноз разломов напряжения и тока датчика в тяговых выпрямителях, а затем расширили работу до места разлома и идентификации типа [7], [8]. Dong и др. предложили адаптивный мультисенсорный метод для высокоскоростных преобразователей тяги поездов с использованием временного обучения [9], в то время как Deng и др. представили легкий метод ИИ для нарушений открытого цеха в однофазных PWM выпрямителях [10].

Недавние исследования также показывают растущее использование глубокого обучения и гибридных методов для диагностики инверторов и преобразователей. Примеры включают улучшенные остаточные сети для диагностики дефектов инвертора, обнаружение дефектов открытых ворот, открытых переключателей и коротких путей, гибридный электрорельсовый диагноз, детектирование дефектов электрических соединений в индукционных машинах, онлайн диагностику короткого замыкания IGBT, и прогнозирование надежности искусственно-нейро-сети для трехфазных инверторов [11]-[16]. Другие работы были сосредоточены на термоэлектрическом слиянии для IGBT модулей, мониторинге конденсаторов постоянного тока в двигательных инверторах и

обнаружении аномалий для железнодорожного оборудования с использованием данных мониторинга состояния [17]-[19].

Платформы железнодорожных данных и прогнозирующее техническое обслуживание

Исследования по техническому обслуживанию железных дорог также перешли к платформам данных и подключенному мониторингу. Ху и др. представили платформу больших данных для диагностики высокоскоростных сбоев поезда [2]. Gozali и др. описали умную концепцию TCMS с предсказывающими функциями технического обслуживания и безопасной коммуникации [3]. Эти системы показывают долгосрочное направление, но они также требуют инфраструктуры и интеграции, которые могут быть недоступны на первом этапе в железных дорогах Узбекистана. Предлагаемая локальная система, основанная на скачанных данных TCMS, может, таким образом, стать мостом с меньшим риском между ручной инспекцией и будущим прогнозирующим обслуживанием.

Исследовательский пробел

Учитывая текущие запланированные ремонтные работы в локомотивных депо Узбекистана, научно-исследовательский разрыв практичен и специфичен для данных. Литература содержит сильные методы для преобразователей тяги, инверторов, датчиков и мониторинга железных дорог, но есть ограниченные опубликованные работы по оффлайн диагностике разломов ACU с использованием низкочастотных журналов разломов TCMS от локомотивов на базе HXD3C в Узбекистане. Доступные данные депо шумны и преобладают повторяющимися численными журналами, а не подробными описаниями. Это исследование устраняет этот разрыв, создавая систему, которая работает с существующими TCMS записями и производит удобный диагностический инструмент для персонала технического обслуживания.

Методология

Объем исследования и источники данных



Рисунок 4. Детальная структура предлагаемой системы

Очистка и извлечение событий ACU

Исторические данные образца TCMS содержали 16 733 сырых записей перед очисткой данных. Первый шаг очистки удалил записи, которые не были полезны для диагностики, в

том числе “NODISP (No display - нет отображения)”, “Recovered (восстановлено)”, и другие сообщения состояния обслуживания или неспецифических сообщений. Это оставило 13 233 диагностически полезных записей. На втором шаге были выбраны записи, содержащие ключевое слово ACU, которое произвело 281 вспомогательный конвертер записей для фокусированного анализа.




Рисунок 5. Среднее сравнение параметров до и после фильтрации ACU по ошибкам

Следует отметить, что полный экспорт данных TCMS HXD3C за длительный эксплуатационный период может содержать до 27 000 строк сырых данных. Эти файлы включали инженерные значения в процентах, оборотах в минуту, км/час, амперах, вольтах, а также числовые поля без единиц измерения. Для сохранения четких параметров для визуализации был применен абсолютный порог до и после изменения на 10%. Этот порог является эмпирическим фильтром первой стадии, а не универсальным физическим пределом.

Следующие рисунки 5–7 показывают результаты применения порога 10% в разных типах визуализации. Горизонтальные столбчатые диаграммы лучше иллюстрируют значения с наибольшими изменениями с помощью абсолютного процентного изменения полей после фильтрации порога для одного и того же события ошибки ACU.

Из рисунка 7 видно, что параметр AC_DCLI (ток звена постоянного тока вспомогательного преобразователя) показал наибольшее абсолютное изменение (66,67%), что может указывать на неисправность в соответствующей цепи.

Исследовательский анализ данных и подготовка характеристик

Исследовательский анализ данных был использован перед тестированием модели, чтобы понять, как с течением времени изменялись числа ошибок. Ежедневное количество ошибок было составлено для поиска периодов с высоким дефектом и возможных кластеров (Рисунок 8).




Рисунок 6. До и после сравнения строк для выбранных полей вокруг события ошибки вспомогательного конвертера




Рисунок 7. Абсолютное процентное изменение полей после фильтрации порогов для одного и того же события ошибки АСУ

Для разделения наблюдаемой последовательности на трендные, сезонные и остаточные компоненты использовался участок разложения (Рисунок 9). Этот шаг важен, потому что нефильтрованный экспорт TCMS включает повторяющиеся тревоги со многих систем, и самые частые сообщения не всегда связаны с поведением АСУ.



Рисунок 8. Ежедневное общее число ошибок в историческом экспорте TCMS до ACU-специфического моделирования



Рисунок 9. Разложение ежедневных сбоев в наблюдаемые серии, тренды, сезонные компоненты и остатки

На рисунке 10 показаны десять наиболее частых описаний сбоев до фильтрации ACU-специфичных записей. Этот график помогает понять, какие сообщения чаще всего встречались в исходных данных TCMS. Он также показывает, почему была необходима дополнительная фильтрация, так как самые частые сообщения не всегда относятся к работе ACU.

После очистки исторические записи были преобразованы в временные индексированные количества ошибок. Дефекты были сгруппированы по дате, неделе, описанию ошибок и блоку АСУ. Повторные описания ошибок были приоритетными, потому что они предоставляют более сильные доказательства обслуживания, чем изолированные одноразовые тревоги. Этот выбор также совпадает с практикой депо: повторяющиеся преобразователи тревоги более полезны для планирования проверки, чем редкие сообщения с небольшой историей.




Рисунок 10. Десять наиболее частых описаний сбоев за время до фильтрации АСУ-специфичных

Диагностика рабочего процесса и профилактическое обслуживание

Простой рабочий процесс начинается с экспорта журнала ошибок TCMS. Неспецифичные записи удаляются, события АСУ извлечены, повторяющиеся группы ошибок АСУ ранжируются, а выбранные таблицы событий проверяются на изменения параметров до и после. Прогнозирование помещается после диагностики в систему, потому что полезное предсказание зависит от первого определения стабильных и повторяющихся моделей ошибок. Вывод представляет собой простой диагностический отчет с предложениями корневых причин, а не автоматическое решение по техническому обслуживанию.

Разработка и оценка моделей

Были протестированы четыре семейства моделей. ARIMA использовался в качестве статистической базы данных для подсчета ошибок с индексами даты [20]. Prophet использовался в качестве второй статистической базы данных, потому что он может моделировать тренд и сезонность с диапазонами неопределенности [21]. Random Forest использовался в качестве традиционной базовой базы машинного обучения для нелинейных структурированных шаблонов [22], с поддержкой внедрения стандартных инструментов машинного обучения Python [23].




Рисунок 11. Предложенный рабочий процесс на уровне депо для диагностики неисправностей вспомогательного конвертера

В качестве окна оценки использовался последний 30-дневный сегмент. На рисунках 12–17 представлены результаты протестированных моделей.




Рисунок 12. Общее количество неисправностей по времени (ежедневно)

Эти результаты показывают, насколько хорошо модели воспроизводят форму прогноза, реагируют на резкие изменения ошибок и могут использоваться для определения приоритетов обслуживания..




Рисунок 13. Прогноз ARIMA (назад, единая точка)




Рисунок 14. Прогноз ARIMA по сравнению с фактическим числом ошибок вспомогательного преобразователя в течение 30-дневного периода

Для модели также были рассчитаны MAE, MAPE и R^2 . Обратная реконструкция ARIMA использовалась только как диагностическая проверка, а не как основной показатель эффективности




Рисунок 15. Прогноз Prophet с интервалом доверия по сравнению с фактическим числом ошибок в течение 30-дневного периода




Рисунок 16. Прогноз Random Forest по сравнению с фактическим числом ошибок вспомогательного преобразователя в течение 30-дневного периода

LSTM был использован в качестве модели последовательности глубокого обучения, потому что повторяющиеся ворота памяти могут изучать временные зависимости в нерегулярных последовательностях [24].




Рисунок 17. Прогноз LSTM по сравнению с фактическим числом ошибок вспомогательного конвертера в течение 30-дневного периода оценки

Таблица 1. Модели прогнозирования, оцененные в исследовании.

Модель	Роль в исследовании	Основная причина тестирования
ARIMA	Статистическая база данных	Простой ориентир для подсчета ошибок с индексированной датой
Prophet	Статистическое прогнозирование базового уровня	Тренд, сезонность и выход в диапазоне неопределённости
Random Forest	Традиционная база машинного обучения	Нелинейное распознавание шаблонов в структурированных данных по подсчёту ошибок
LSTM	Модель последовательности глубокого обучения	Временное обучение для нелинейных и нерегулярных последовательностей ошибок

Результаты и обсуждение

Распределение неисправностей ACU

Набор данных с фильтром ACU показал повторные вспомогательные группы отказов преобразователя. Наиболее частыми рекордами были инверторные ворота низкого напряжения в ACU1 и ACU2, каждый из которых происходил более чем в 20 раз в зарегистрированном периоде. Другие повторяющиеся группы включали в себя входное напряжение переменного тока, инверторные события короткого замыкания и события перегрузки фазы вывода. Этот результат полезен для диагностики, потому что повторные события ACU более действуют, чем изолированные тревоги. Повторные сообщения низкого напряжения ворот могут направлять персонал по обслуживанию к питанию ворот-драйвера, условию преобразователя-модуля, стабильности постоянного тока, качеству

вспомогательного входного питания, охлаждению и коннектора. Рейтинг должен рассматриваться как диагностическая отправная точка, а не как автоматический вердикт причины.




Рисунок 18. Еженедельное появление верхних вспомогательных групп отказов преобразователя ACU после фильтрации

Модель сравнения

Для сравнения моделей обычно рассчитываются по результатам прогнозирования отказов и показывают точность каждой модели. MAE (средняя абсолютная ошибка) и MAPE (средняя абсолютная процентная ошибка) помогают понять, насколько сильно прогноз отличается от реальных значений в абсолютных и процентных ошибках. R^2 (коэффициент детерминации) показывает, насколько хорошо модель объясняет изменения в данных, поэтому модель с меньшими MAE и MAPE и большим R^2 считается более точной [25], [26].

Статистические базовые линии были полезны для сравнения, но были слабыми кандидатами в диагностику этого набора данных. ARIMA был чувствителен к внезапным изменениям и не хорошо следил за кластерами подсчета ошибок.

Prophet создал более гладкие прогнозы и полезные диапазоны неопределенности, но это также не очень точно на острых пиках. Эти результаты показывают, что чисто статистическое сглаживание может пропустить внезапные кластеры отказов преобразователя в логах низкочастотных депо.

Random Forest следовал общей схеме лучше, чем статистические базовые линии, но его прогнозы были менее стабильными, чем LSTM в течение выбранного 30-дневного периода.

Модель LSTM последовала за фактической тенденцией более последовательно и захватила главный период с высокой ошибкой лучше, чем другие протестированные модели. Это не означает, что модель готова к автономному прогнозирующему техническому обслуживанию. Это означает, что LSTM был самым сильным кандидатом среди протестированных моделей для дальнейшей проверки в качестве инструмента уровня депо. Как модель глубокого обучения LSTM может стать лучше и точнее по мере увеличения набора данных (Таблица 2, 3).

Таблица 2. Сравнение точности четырех моделей за 30-дневный период оценки.

Модель	MAE (меньше лучше)	MAPE (меньше лучше)	R ² (больше лучше)	Стабильность
LSTM	20.54	30.15%	0.71	Высокая
Random Forest	27.80	38.60%	0.58	Средняя
Prophet	34.70	47.10%	0.45	Низкая-средняя
ARIMA	39.25	52.40%	0.34	Ниже средней

Таблица 3. Сравнение моделей для диагностики отказов АСУ

Модель	Стабильность	Рекомендация для диагностики отказов АСУ
LSTM	Высокая	Перспективная модель для дальнейшей валидации
Random Forest	Средняя	Полезна как базовая модель; требуется дополнительная настройка и проверка по локомотивам
ARIMA	Ниже средней	Слабо справляется с резкими изменениями количества отказов в данном наборе данных
Prophet	Низкая-средняя	Подходит для визуализации трендов, но не рекомендуется как основная модель

Результаты показывают, что исторические записи TCMS и АСУ могут поддерживать диагностику неисправностей вспомогательного преобразователя в локомотивах O'Z-EL на базе HXD3C. Основное значение заключается в преобразовании шумного экспорта TCMS в меньший и более четкий набор повторяющихся групп разломов АСУ, которые обслуживающий персонал может сначала осмотреть. Этот диагностический шаг необходим, прежде чем предсказательное обслуживание может быть применено с уверенностью.

Результат LSTM технически обоснован, так как вспомогательные ошибки преобразователя нелинейны и нерегулярны. Они могут быть затронуты профилем маршрута, нагрузкой локомотивов, температурой окружающей среды, условием охлаждения, старением компонентов, качеством вспомогательного снабжения, недавней историей ремонта и управлением. Статистические базовые линии полезны для гладкой тенденции и сезонного развития, но они менее подходят, когда последовательность содержит скопления внезапных ошибок. Random Forest может изучать нелинейные шаблоны, но он, естественно, не моделирует порядок времени, если функции задержки не разработаны тщательно. LSTM лучше выравнивается с структурой последовательности повторных чисел ошибок.

Модельные и сенсорные исследования обеспечивают сильные сигнатуры ошибок, когда требуемые измерения и состояния работы доступны [6]-[10]. Недавние ИИ и гибридные методы показывают, что ошибки преобразователя, инвертора, IGBT и конденсатора могут быть обнаружены с помощью изученных шаблонов [11]-[19].

Исследования железнодорожной платформы данных показывают, как такая диагностика может быть масштабирована в более крупные системы технического обслуживания [2], [3]. Нынешнее исследование отличается тем, что фокусируется на проблеме меньшего, но практического депо: использование уже доступных данных TCMS для анализа ошибок до внедрения полной платформы мониторинга в реальном времени.

Для практики депо предлагаемая система может сократить время ручного обзора, автоматически выделяя повторяющиеся группы ошибок ACU, показывая последние тенденции ошибок с визуальными графами, чтобы сделать его легко анализировать на первый взгляд. Например, повторные инверторные сигнализации низкого напряжения в ACU1 или ACU2 могут направлять целенаправленные проверки питания ворот-драйвера, состояния IGBT/модуля, поведения постоянного тока, вспомогательного входного напряжения, охлаждения и проводки до следующего серьезного сбоя. Инженеры все еще принимают окончательное решение; модель организует только доказательства.

Исследование также поддерживает постановку цифровизации. Полная платформа дистанционного мониторинга остается долгосрочным направлением для электровозов HXD3C в Узбекистане, но она требует надежной коммуникации, безопасного обмена данными, приборных панелей и интеграции технического обслуживания.

Предложенный здесь оффлайн рабочий процесс представляет собой первый этап с меньшим риском, поскольку он использует существующий экспорт TCMS. После проверки на больших и подтвержденных ремонтом наборах данных такая же логика может быть перемещена в реальное время или в облачную среду.

Ограничения

Основные ограничения исследования связаны с данными. Набор данных не содержит непрерывных высокочастотных сигналов преобразователей. Подмножество данных, связанное с ACU, включает только 281 запись, что недостаточно для надежного применения методов глубокого обучения. Порог изменения параметров в 10% был выбран эмпирически, поэтому его необходимо проверить на большем количестве локомотивов, сезонов, маршрутов и данных технического обслуживания. В будущих исследованиях следует использовать более крупные наборы данных, учитывать сезонные эффекты и сравнивать результаты модели с реальными результатами технического обслуживания.

Заключение

В данной статье представлена локальная система диагностики неисправностей вспомогательных преобразователей в электровозах O'Z-EL на базе HXD3C. Метод очищает сырые записи TCMS, удаляет неспецифические сообщения, извлекает события, связанные с ACU, экраны до и после изменений параметров, ранжирует повторяющиеся группы ошибок ACU и сравнивает модели ARIMA, Prophet, Random Forest и LSTM для краткосрочной диагностической поддержки. Среди испытанных моделей LSTM дал наиболее последовательный 30-дневный результат, с MAE = 20,54, MAPE = 30,15%, и $R^2 = 0,71$. ARIMA и Prophet были полезными базовыми линиями, но не следовали кластерам хорошо, в то время как Random Forest предоставил полезный промежуточный ориентир.

Рабочий процесс подходит как промежуточный инструмент для железных дорог Узбекистана, так как он работает с существующими загруженными данными TCMS и не требует новых датчиков на первом этапе. Важной ценностью является частично автоматизированная диагностика ошибок. Его будущая ценность - предсказательное

обслуживание, но эта стадия должна быть реализована только после больших наборов данных и проверки локомотивов.

Доступность данных

Наборы данных по техническому обслуживанию TCMS, используемые в данном исследовании, являются внутренними операционными записями о деятельности по техническому обслуживанию железных дорог. Они не доступны публично, потому что содержат оперативную и специфическую информацию.

Список литературы

1. Ilončíak, L. Struharnanský, and J. Kuchta, "Modular Concept of Auxiliary Converters for Diesel Electric Locomotives," *Procedia Engineering*, vol. 192, pp. 359–364, 2017, doi: <https://doi.org/10.1016/j.proeng.2017.06.062>.
2. Q. Xu, P. Zhang, W. Liu, Q. Liu, C. Liu, L. Wang, A. Toprac, and S. J. Qin, "A Platform for Fault Diagnosis of High-Speed Train Based on Big Data," *IFAC-PapersOnLine*, vol. 51, no. 18, pp. 309–314, 2018, doi: <https://doi.org/10.1016/j.ifacol.2018.09.318>.
3. A. Gozali et al., "Smart Train Control and Monitoring System with Predictive Maintenance and Secure Communications Features," *Transportation Research Interdisciplinary Perspectives*, vol. 31, Art. no. 101409, 2025, doi: <https://doi.org/10.1016/j.trip.2025.101409>.
4. B.-K. Zhang, "Design and Realization of Fault Diagnosis Software for HXD3C Electric Locomotive Power Supply," *Electric Drive for Locomotives*, no. 5, pp. 93–95, 2012.
5. G. Yao-hui, W. Qian, L. Xin, Z. Shi-tao, and G. Hong-guang, "Research on the Safe Operation of HXD3C Locomotive High-Voltage Equipment Based on Sequential Control Optimization," *Electric Drive for Locomotives*, no. 4, 2013.
6. B. Gou, X. Ge, S. Wang, X. Feng, J. B. Kuo, and T. G. Habetler, "An Open-Switch Fault Diagnosis Method for Single-Phase PWM Rectifier Using a Model-Based Approach in High-Speed Railway Electrical Traction Drive System," *IEEE Transactions on Power Electronics*, vol. 31, no. 5, pp. 3816–3826, May 2016, doi: <https://doi.org/10.1109/TPEL.2015.2465299>.
7. Y. Yu, Y. Song, H. Tao, and J. Hu, "Voltage and Current Sensor Fault Diagnosis Method for Traction Rectifier in High-Speed Trains," *Electronics*, vol. 13, no. 1, Art. no. 197, Jan. 2024, doi: <https://doi.org/10.3390/electronics13010197>.
8. Y. Yu, Y. Song, and H. Tao, "Fault Location and Type Identification Method for Current and Voltage Sensors in Traction Rectifiers," *Journal of Power Electronics*, vol. 25, no. 4, pp. 666–674, 2025, doi: <https://doi.org/10.1007/s43236-024-00916-z>.
9. H. Dong, F. Chen, Z. Wang, L. Jia, Y. Qin, and J. Man, "An Adaptive Multisensor Fault Diagnosis Method for High-Speed Train Traction Converters," *IEEE Transactions on Power Electronics*, vol. 36, no. 6, pp. 6288–6302, Jun. 2021, doi: <https://doi.org/10.1109/TPEL.2020.3034190>.
10. Q. Deng, B. Gou, X. Ge, C. Lin, D. Xie, and X. Feng, "A High-Accuracy-Light-AI Data-Driven Diagnosis Method for Open-Circuit Faults in Single-Phase PWM Rectifiers," *IEEE Transactions on Transportation Electrification*, vol. 9, no. 3, pp. 4352–4365, Sep. 2023, doi: <https://doi.org/10.1109/TTE.2023.3238009>.
11. Y. Fu, Y. Ji, G. Meng, W. Chen, and X. Bai, "Three-Phase Inverter Fault Diagnosis Based on an Improved Deep Residual Network," *Electronics*, vol. 12, no. 16, Art. no. 3460, Aug. 2023, doi: <https://doi.org/10.3390/electronics12163460>.

12. M. Z. Khaneghah, M. Alzayed, and H. Chaoui, "Open Gate, Open Switch and Short Circuit Fault Detection of Three-Phase Inverter Switches in Induction Motor Drive Applications," *Actuators*, vol. 15, no. 1, Art. no. 34, Jan. 2026, doi: <https://doi.org/10.3390/act15010034>.
13. R. Sharma, "Intelligent Fault Diagnosis in Electric Railway Traction System: A Novel Hybrid Approach," *Journal of Electrical Engineering & Technology*, vol. 21, no. 3, pp. 2421–2439, 2026, doi: <https://doi.org/10.1007/s42835-026-02608-z>.
14. D. Gonzalez-Jimenez, J. del-Olmo, J. Poza, F. Garramiola, and I. Sarasola, "Machine Learning-Based Fault Detection and Diagnosis of Faulty Power Connections of Induction Machines," *Energies*, vol. 14, no. 16, Art. no. 4886, Aug. 2021, doi: <https://doi.org/10.3390/en14164886>.
15. K. Moulay, I. Merzouk, K. O. M. Touati, A. Hafaifa, and G. Alhussein, "Online IGBT Short-Circuit Fault Diagnosis in Modular Multilevel Converter Based on DWT and RBFNN," *IEEE Access*, vol. 14, pp. 22252–22273, 2026, doi: <https://doi.org/10.1109/ACCESS.2026.3662514>.
16. H.-M. Park, J.-H. Lee, H.-S. Jun, K.-B. Hwang, S.-J. Park, and J.-H. Park, "Reliability Diagnosis and Fault Prediction Technique for Three-Phase Inverters Using Artificial Neural Networks," *IEEE Access*, vol. 14, pp. 4576–4590, 2026, doi: <https://doi.org/10.1109/ACCESS.2026.3650960>.
17. M. Cui, Y. Liu, Z. Hu, and T. Shi, "Thermal-Electrical Fusion for Real-Time Condition Monitoring of IGBT Modules in Transportation Systems," *Micromachines*, vol. 17, no. 2, Art. no. 154, Jan. 2026, doi: <https://doi.org/10.3390/mi17020154>.
18. K. Hasegawa, T. Yamasoto, K. Fujimoto, Y. Oyama, and N. Iida, "Condition Monitoring of a DC-Link Capacitor Using the Instantaneous Output Power of a Propulsion Inverter with One-Pulse Modulation," *IEEJ Journal of Industry Applications*, vol. 15, no. 3, pp. 368–374, 2026, doi: <https://doi.org/10.1541/ieejia.20250328>.
19. T. Yokouchi, T. Takashige, and M. Kondo, "Anomaly Detection for Railway Vehicle Equipment Using Condition Monitoring Data," *Quarterly Report of RTRI*, vol. 63, no. 4, pp. 238–243, Nov. 2022, doi: https://doi.org/10.2219/rtriqr.63.4_238.
20. G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time Series Analysis: Forecasting and Control*, 5th ed. Hoboken, NJ, USA: Wiley, 2015.
21. S. J. Taylor and B. Letham, "Forecasting at Scale," *The American Statistician*, vol. 72, no. 1, pp. 37–45, Jan. 2018, doi: <https://doi.org/10.1080/00031305.2017.1380080>.
22. L. Breiman, "Random Forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: <https://doi.org/10.1023/A:1010933404324>.
23. F. Pedregosa et al., "Scikit-learn: Machine Learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
24. S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: <https://doi.org/10.1162/neco.1997.9.8.1735>.
25. R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," *International Journal of Forecasting*, vol. 22, no. 4, pp. 679–688, Oct. 2006, doi: <https://doi.org/10.1016/j.ijforecast.2006.03.001>.
26. D. Chicco, M. J. Warrens, and G. Jurman, "The Coefficient of Determination R-squared Is More Informative than SMAPE, MAE, MAPE, MSE and RMSE in Regression Analysis Evaluation," *PeerJ Computer Science*, vol. 7, no. 5, p. e623, 2021, doi: <https://doi.org/10.7717/peerj-cs.623>.

Davran Radjibayev*, Jasur Anarkulov*Tashkent State Transport University***Fault Diagnosis System for Auxiliary Converters in HXD3C Series Electric Locomotives**

Abstract. This paper proposes a fault diagnosis system for auxiliary converters (ACUs) in HXD3C-based electric locomotives operating on the railways of Uzbekistan. Auxiliary converter faults are critical because they affect traction motors, cooling systems, compressors, and other auxiliary equipment required for the safe operation of locomotives. Currently, fault investigation in locomotive depots of Uzbekistan mainly relies on visual inspection and manual analysis of large fault logs exported from the Train Control and Monitoring System (TCMS). This process is time-consuming and highly dependent on personnel experience, which may result in important fault patterns being overlooked in historical records downloaded from the TCMS. The proposed system consists of three main components: an ARM-based mini-computer, diagnostic software integrated with a machine learning model for future predictive maintenance applications, and a display unit for presenting and transmitting diagnostic results to maintenance personnel. The proposed approach uses TCMS fault logs and auxiliary converter records as input data. Dedicated software then analyzes the collected data and generates conclusions, visual statistics, and recommendations for possible maintenance actions related to ACU failures.

Keywords: HXD3C; O'Z-EL electric locomotive; auxiliary converter; TCMS; fault diagnosis; railway rolling stock maintenance; LSTM; predictive maintenance readiness.

References

1. Ilončíak, L. Struharnanský, and J. Kuchta, "Modular Concept of Auxiliary Converters for Diesel Electric Locomotives," *Procedia Engineering*, vol. 192, pp. 359–364, 2017, doi: <https://doi.org/10.1016/j.proeng.2017.06.062>.
2. Q. Xu, P. Zhang, W. Liu, Q. Liu, C. Liu, L. Wang, A. Toprac, and S. J. Qin, "A Platform for Fault Diagnosis of High-Speed Train Based on Big Data," *IFAC-PapersOnLine*, vol. 51, no. 18, pp. 309–314, 2018, doi: <https://doi.org/10.1016/j.ifacol.2018.09.318>.
3. A. Gozali et al., "Smart Train Control and Monitoring System with Predictive Maintenance and Secure Communications Features," *Transportation Research Interdisciplinary Perspectives*, vol. 31, Art. no. 101409, 2025, doi: <https://doi.org/10.1016/j.trip.2025.101409>.
4. B.-K. Zhang, "Design and Realization of Fault Diagnosis Software for HXD3C Electric Locomotive Power Supply," *Electric Drive for Locomotives*, no. 5, pp. 93–95, 2012.
5. G. Yao-hui, W. Qian, L. Xin, Z. Shi-tao, and G. Hong-guang, "Research on the Safe Operation of HXD3C Locomotive High-Voltage Equipment Based on Sequential Control Optimization," *Electric Drive for Locomotives*, no. 4, 2013.
6. B. Gou, X. Ge, S. Wang, X. Feng, J. B. Kuo, and T. G. Habetler, "An Open-Switch Fault Diagnosis Method for Single-Phase PWM Rectifier Using a Model-Based Approach in High-Speed Railway Electrical Traction Drive System," *IEEE Transactions on Power Electronics*, vol. 31, no. 5, pp. 3816–3826, May 2016, doi: <https://doi.org/10.1109/TPEL.2015.2465299>.
7. Y. Yu, Y. Song, H. Tao, and J. Hu, "Voltage and Current Sensor Fault Diagnosis Method for Traction Rectifier in High-Speed Trains," *Electronics*, vol. 13, no. 1, Art. no. 197, Jan. 2024, doi: <https://doi.org/10.3390/electronics13010197>.

8. Y. Yu, Y. Song, and H. Tao, "Fault Location and Type Identification Method for Current and Voltage Sensors in Traction Rectifiers," *Journal of Power Electronics*, vol. 25, no. 4, pp. 666–674, 2025, doi: <https://doi.org/10.1007/s43236-024-00916-z>.
9. H. Dong, F. Chen, Z. Wang, L. Jia, Y. Qin, and J. Man, "An Adaptive Multisensor Fault Diagnosis Method for High-Speed Train Traction Converters," *IEEE Transactions on Power Electronics*, vol. 36, no. 6, pp. 6288–6302, Jun. 2021, doi: <https://doi.org/10.1109/TPEL.2020.3034190>.
10. Q. Deng, B. Gou, X. Ge, C. Lin, D. Xie, and X. Feng, "A High-Accuracy-Light-AI Data-Driven Diagnosis Method for Open-Circuit Faults in Single-Phase PWM Rectifiers," *IEEE Transactions on Transportation Electrification*, vol. 9, no. 3, pp. 4352–4365, Sep. 2023, doi: <https://doi.org/10.1109/TTE.2023.3238009>.
11. Y. Fu, Y. Ji, G. Meng, W. Chen, and X. Bai, "Three-Phase Inverter Fault Diagnosis Based on an Improved Deep Residual Network," *Electronics*, vol. 12, no. 16, Art. no. 3460, Aug. 2023, doi: <https://doi.org/10.3390/electronics12163460>.
12. M. Z. Khaneghah, M. Alzayed, and H. Chaoui, "Open Gate, Open Switch and Short Circuit Fault Detection of Three-Phase Inverter Switches in Induction Motor Drive Applications," *Actuators*, vol. 15, no. 1, Art. no. 34, Jan. 2026, doi: <https://doi.org/10.3390/act15010034>.
13. R. Sharma, "Intelligent Fault Diagnosis in Electric Railway Traction System: A Novel Hybrid Approach," *Journal of Electrical Engineering & Technology*, vol. 21, no. 3, pp. 2421–2439, 2026, doi: <https://doi.org/10.1007/s42835-026-02608-z>.
14. D. Gonzalez-Jimenez, J. del-Olmo, J. Poza, F. Garramiola, and I. Sarasola, "Machine Learning-Based Fault Detection and Diagnosis of Faulty Power Connections of Induction Machines," *Energies*, vol. 14, no. 16, Art. no. 4886, Aug. 2021, doi: <https://doi.org/10.3390/en14164886>.
15. K. Moulay, I. Merzouk, K. O. M. Touati, A. Hafaifa, and G. Alhussein, "Online IGBT Short-Circuit Fault Diagnosis in Modular Multilevel Converter Based on DWT and RBFNN," *IEEE Access*, vol. 14, pp. 22252–22273, 2026, doi: <https://doi.org/10.1109/ACCESS.2026.3662514>.
16. H.-M. Park, J.-H. Lee, H.-S. Jun, K.-B. Hwang, S.-J. Park, and J.-H. Park, "Reliability Diagnosis and Fault Prediction Technique for Three-Phase Inverters Using Artificial Neural Networks," *IEEE Access*, vol. 14, pp. 4576–4590, 2026, doi: <https://doi.org/10.1109/ACCESS.2026.3650960>.
17. M. Cui, Y. Liu, Z. Hu, and T. Shi, "Thermal-Electrical Fusion for Real-Time Condition Monitoring of IGBT Modules in Transportation Systems," *Micromachines*, vol. 17, no. 2, Art. no. 154, Jan. 2026, doi: <https://doi.org/10.3390/mi17020154>.
18. K. Hasegawa, T. Yamasoto, K. Fujimoto, Y. Oyama, and N. Iida, "Condition Monitoring of a DC-Link Capacitor Using the Instantaneous Output Power of a Propulsion Inverter with One-Pulse Modulation," *IEEE Journal of Industry Applications*, vol. 15, no. 3, pp. 368–374, 2026, doi: <https://doi.org/10.1541/ieejia.20250328>.
19. T. Yokouchi, T. Takashige, and M. Kondo, "Anomaly Detection for Railway Vehicle Equipment Using Condition Monitoring Data," *Quarterly Report of RTRI*, vol. 63, no. 4, pp. 238–243, Nov. 2022, doi: https://doi.org/10.2219/rtriqr.63.4_238.
20. G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time Series Analysis: Forecasting and Control*, 5th ed. Hoboken, NJ, USA: Wiley, 2015.
21. S. J. Taylor and B. Letham, "Forecasting at Scale," *The American Statistician*, vol. 72, no. 1, pp. 37–45, Jan. 2018, doi: <https://doi.org/10.1080/00031305.2017.1380080>.

22. L. Breiman, "Random Forests," Machine Learning, vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: <https://doi.org/10.1023/A:1010933404324>.
23. F. Pedregosa et al., "Scikit-learn: Machine Learning in Python," Journal of Machine Learning Research, vol. 12, pp. 2825–2830, 2011.
24. S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," Neural Computation, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: <https://doi.org/10.1162/neco.1997.9.8.1735>.
25. R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," International Journal of Forecasting, vol. 22, no. 4, pp. 679–688, Oct. 2006, doi: <https://doi.org/10.1016/j.ijforecast.2006.03.001>.
26. D. Chicco, M. J. Warrens, and G. Jurman, "The Coefficient of Determination R-squared Is More Informative than SMAPE, MAE, MAPE, MSE and RMSE in Regression Analysis Evaluation," PeerJ Computer Science, vol. 7, no. 5, p. e623, 2021, doi: <https://doi.org/10.7717/peerj-cs.623>.

Информация об авторах

Давран Раджибаев – PhD, ассоциированный профессор, Ташкентский государственный транспортный университет, Ташкент, Узбекистан.

Ясур Анаркулов – докторант, Ташкентский государственный транспортный университет, Ташкент, Узбекистан.

Davran Radjibayev – PhD, Associate Professor, Tashkent State Transport University, Tashkent, Uzbekistan.

Jasur Anarkulov – Doctoral Student, Tashkent State Transport University, Tashkent, Uzbekistan.



Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY NC) license