

## **ДИАГНОСТИКА НЕИСПРАВНОСТЕЙ СИЛОВОГО ЭЛЕКТРОННОГО ПРЕОБРАЗОВАТЕЛЯ С ПРИМЕНЕНИЕМ МЕТОДА МАШИННОГО ОБУЧЕНИЯ**

**О. А. Малышева**

*к.т.н., доцент кафедры «Электротехника, электроника и электромеханика»,  
ДВГУПС, г. Хабаровск*

**Синьёй Ян**

*Магистрант группы МО622ЭИЭ(и) Электроэнергетического института,  
ДВГУПС, г. Хабаровск*

**В. А. Ковалев**

*к.т.н., доцент кафедры «Электротехника, электроника и электромеханика»,  
ДВГУПС, г. Хабаровск*

**Л. В. Бузмакова**

*к.т.н., доцент кафедры «Электротехника, электроника и электромеханика»,  
ДВГУПС, г. Хабаровск*

*Аннотация. В статье представлены результаты исследования, направленные на повышение точности диагностики неисправностей силового электронного преобразователя CRH3 EMU электропоезда Fixing с применением метода машинного обучения. Моделирование неисправностей преобразователя выполнено в MATLAB Simulink путем включения и отключения IGBT-транзисторов таким образом, чтобы имитировать рабочий режим преобразователя при возникновении одиночной неисправности. Для диагностирования неисправностей и выявления их специфики использовались в сочетании вейвлет-анализ и повышающий алгоритм ансамблевого метода машинного обучения. Рассмотрены преимущества, недостатки алгоритма машинного обучения, возможность осуществлять поиск неисправностей преобразователя CRH3 EMU на основе интеграции вейвлет-анализа и методов машинного обучения, которые могут заменить традиционные методы технического обслуживания и диагностирования неисправностей тяговых преобразователей подвижного состава.*

**Ключевые слова:** диагностика, электронный преобразователь, CRH3 EMU, вейвлет-анализ, машинное обучение, метод ансамблевого обучения.

Стремительное развитие железнодорожной отрасли Китая позволило к 2025 году высокоскоростному поезду EMU «Фусин» (Fuxing) развить скорость до 450 км/ч. Развитие высокоскоростного движения является перспективным направлением повышения объемов перевозок грузов и пассажиров. Эксплуатация высокоскоростных железных дорог предъявляет высокие требования к надежности, безопасности и стабильности работы электрооборудования электроподвижного состава.

Отличительной особенностью электротяговой нагрузки является ее непостоянство, связанное с изменением скорости, координаты поезда, профиля пути и других факторов, влияющих на величину потребляемой поездом электроэнергии и напряжение на токоприемнике. Силовое оборудование электропоезда функционирует в условиях резких изменений напряжения и тока, что является одной из причин его отказов. Разработка мероприятий, направленных на предотвращение отказов электрооборудования электропоездов является актуальной технико-экономической задачей железнодорожного транспорта Китая.

Одним из основных узлов системы электроснабжения электропоезда CRH3 является электронный преобразователь, который обеспечивает электропитание оборудования поезда (тяговые двигатели, вспомогательные машины и др.). Традиционные методы и подходы [1, 2], применяемые при анализе неисправностей электрооборудования электропоезда не позволяют с достаточной точностью получить информацию о состоянии преобразователя при возникновении отдельных неисправностей. Решение задачи повышения достоверности определения неисправностей преобразователя требует применения современных технологий интеллектуальной диагностики, которые предусматривают извлечение полезной информации о неисправностях из сигналов сложной формы и принятия на основе этого решений.

На рисунке 1 представлена структурная схема силовых цепей электропитания оборудования электропоезда «Фусин». Система тягового электроснабжения (блок 1) электрифицированной железной дороги (далее – СТЭ) выполнена по системе однофазного переменного тока напряжением 25 кВ. СТЭ содержит тяговые подстанции, предназначенные для преобразования электроэнергии по напряжению и тяговую сеть, которая обеспечивает передачу электроэнергии от тяговых подстанций до пантографа электропоезда (блок 2).

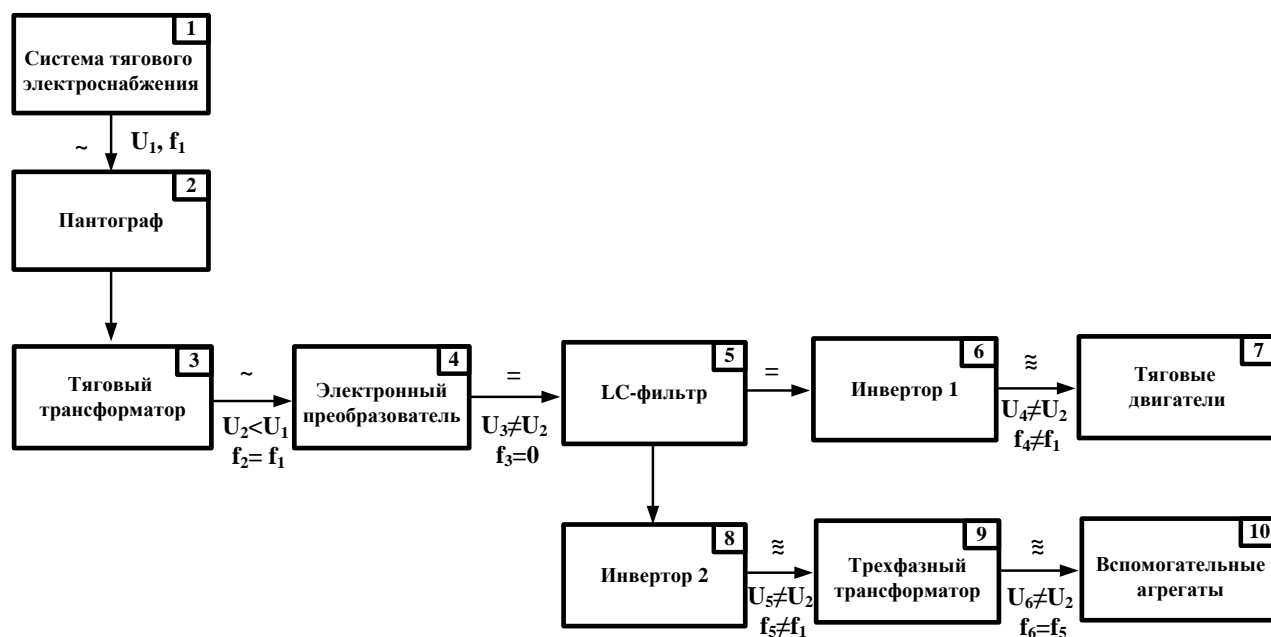


Рисунок 1 – Схема электрическая структурная силовых цепей электропитания оборудования электропоезда «Фусин» (Fixing)

Тяговый трансформатор (блок 3) размещен в высоковольтной камере локомотива и обеспечивает преобразование напряжения в тяговой сети  $U_1$  (на пантографе электровоза) в напряжение  $U_2$ , соответствующее паспортным данным тягового преобразователя (блок 4). Преобразователь обеспечивает выпрямление напряжения и, схемотехнически, представляет собой управляемый однофазный двухполупериодный выпрямитель, выполненный на биполярных транзисторах с изолированным затвором (далее – IGBT).

Индуктивно-емкостный фильтр (блок 5) содержит сглаживающий реактор и емкостные цепи и обеспечивает сглаживание пульсаций выпрямленного тока и напряжения, подаваемого на инверторы 1 и 2 (блоки 6 и 8).

Инвертор 1 (блок 6) предназначен для преобразования постоянного напряжения в трехфазное переменное для питания тяговых двигателей (блок 7) и выполнен на IGBT транзисторах, включенных по мостовой схеме. Применение трехфазного мостового управляемого инвертора обеспечивает возможность регулирования частоты и амплитуды подаваемого на двигатели напряжения и, соответственно их скорости вращения.

Инвертор 2 (блок 8) выполнен аналогично инвертору 1 и обеспечивает преобразование выпрямленного напряжения в трехфазное переменное для электропитания вспомогательного оборудования электровоза (компрессоры, вентиляторы, освещение и др.). Трансформатор (блок 9) предназначен для преобразования напряжения на выходе инвертора 2 по амплитуде до требуемого по условиям нормальной работы электрооборудования уровня.

Для моделирования возможных отказов преобразователя электропоезда в работе создана схема преобразователя CRH3 EMU в MATLAB Simulink (рисунок 2) [3], с использованием которой выполнен ряд исследований, при моделировании включения-отключения IGBT. В результате моделирования были получены кривые выходного тока преобразователя в различных рабочих условиях, которые были использованы в качестве основы для диагностики неисправностей.

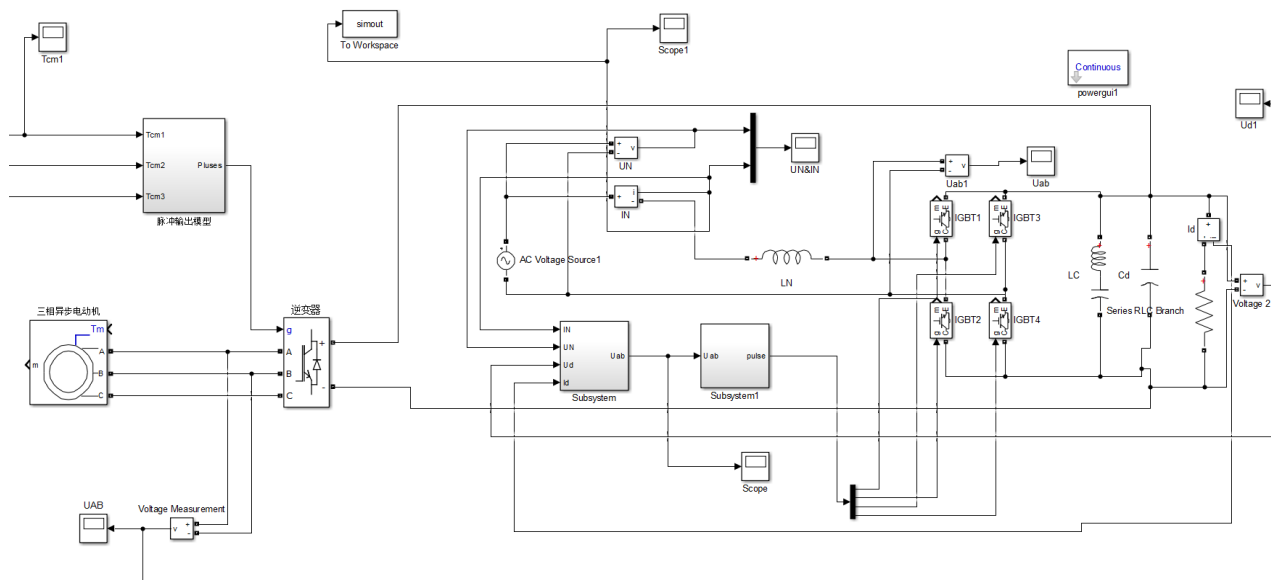


Рисунок 2 – Схема преобразователя CRH3 EMU для проведения моделирования в MATLAB Simulink

Для создания системы поддержки принятия решений по определению вида неисправности необходимо решить следующие задачи:

- 1) извлечение значимых признаков (распознавание образов);
- 2) создание модели машинного обучения;
- 3) реализация интерпретации результатов.

Извлечение значимых признаков (распознавание образов) неисправностей из сложной формы гармонического сигнала выполнено с использованием вейвлет-анализа. Вейвлет-анализ предусматривает анализ частотных компонентов данных с учетом локальных особенностей сигнала, что повышает достоверность анализа по сравнению с преобразованием Фурье.

Когда преобразователь находится в нормальных рабочих условиях, форма выходного тока представляет собой трехфазную синусоидальную волну. При возникновении отказов в преобразователе часть текущего сигнала будет потеряна в неисправной части, в результате чего форма выходного тока перестанет быть симметричной и появится множество искаженных сигналов. При возникновении различных неисправностей в преобразователе полученные выходные сигналы

различны, и существует множество детальных отличий, которые явно отличаются от форм сигналов в нормальных условиях эксплуатации.

Суть вейвлет-анализа заключается в разделении анализируемого сигнала по разным диапазонам частот. Когда преобразователь находится в разных рабочих условиях, состав каждой полосы частот также различен, поэтому необходимо выполнить анализ неисправностей на основе извлеченной информации из разных полос частот. Отличительным признаком сигнала о неисправности является то, что при возникновении неисправности в преобразователе форма сигнала тока будет иметь пиковое значение (скачок), которое отличается от нормального сигнала или «шума». Таким образом, применение вейвлет-анализа является возможным для диагностирования отдельных неисправностей электронного преобразователя.

На основании вышеизложенного можно установить, что, в дополнение к выводу о выходе из строя электронного преобразователя по выходному току, применение вейвлет-анализа позволяет определить, какая часть тягового преобразователя вышла из строя или имеет неисправность. Это можно понять, если выполнять анализ непосредственно во временной области, однако, для такого исследования необходимо извлечь информацию по многим параметрам, которые для других сигналов будут являться помехами.

С использованием технологии вейвлет-анализа в работе были проанализированы и очищены от шума 100 групп неисправностей. На основании полученных данных определены значения функций, использованные при создании модели машинного обучения [4], которая заменит традиционную ручную диагностику применением технологии искусственного интеллекта. Для этого могут быть использованы различные виды композиционных методов машинного обучения, например, ансамблевое обучение. Ансамблевое обучение представляет собой метод машинного обучения, в котором несколько моделей обучаются для решения одной и той же проблемы и объединяются в систему для получения лучших результатов, объединяя их в единое целое. При использовании данного метода машина проходит процесс обучения, преобразуя результаты вейвлет-анализа при возникновении различных неисправностей в характеристические значения, а затем сохраняет их в среде AdaBoost для дальнейшего обучения системы обеспечения функционирования электропоезда. При возникновении известной для системы неисправности алгоритм предусматривает реакцию на ее появление в виде поиска возможного решения для минимизации последствий [5].

Одной из наиболее важных идей в интегрированном обучении является классификация, позволяющая машине продолжать обучение, прежде чем она

адаптируется к классификации различных неисправностей. Фактически используется разное количество слабых классификаторов в наборе инструментов, а далее они соединяются вместе в различных комбинациях. Таким образом используются результаты классификации ансамблевого обучения нескольких слабых классификаторов, что является более точным, чем один классификатор. В процессе программирования операторов, изменяется количество слабых классификаторов для непрерывного обучения и тестирования. Использование слабых классификаторов, позволяет сбалансировать ошибки, так как, если использовать сильный классификатор, то он окажет серьезное влияние и такое отклонение приведет к тому, что другие классификаторы не смогут выполнять операции классификации, так что ансамблевое обучение потеряет свой смысл.

В исследовании для создания модели машинного обучения использован набор инструментов AdaBoost, который является алгоритмом повышения [6]. Алгоритм повышения – это алгоритм, который используется для построения функции прогнозирования различных возможностей получения ложных результатов, главной ролью которого является повышение точности слабых алгоритмов классификации. Использование слабых классификаторов ограничивает точность оценки результатов. Однако, если объединить для работы определенное количество слабых классификаторов, узнаваемость результатов будет значительно улучшена, и результаты будут определены с заданной точностью.

Построение базового классификатора происходит в процессе обучения данными, наблюдением за частотой появления неисправностей, а далее изменяя количество слабых классификаторов и переходя на следующий этап обучения, пока точность не достигнет заданного значения. Разъяснение процесса построения модели машинного обучения через ансамблевое обучение AdaBoost и алгоритм его работы приведены на рисунках 3 и 4.

AdaBoost предусматривает следующий порядок выбора параметров и формул расчета, который можно корректировать [7]:

1. Выбор слабых классификаторов.
2. Получение необходимого количества слабых классификаторов за счет ошибок.
3. Расчет веса выборки обучающих данных.
4. Объединение слабых классификаторов.
5. Определение количества итераций.
6. Определение порога выбора для формирования функции потерь.

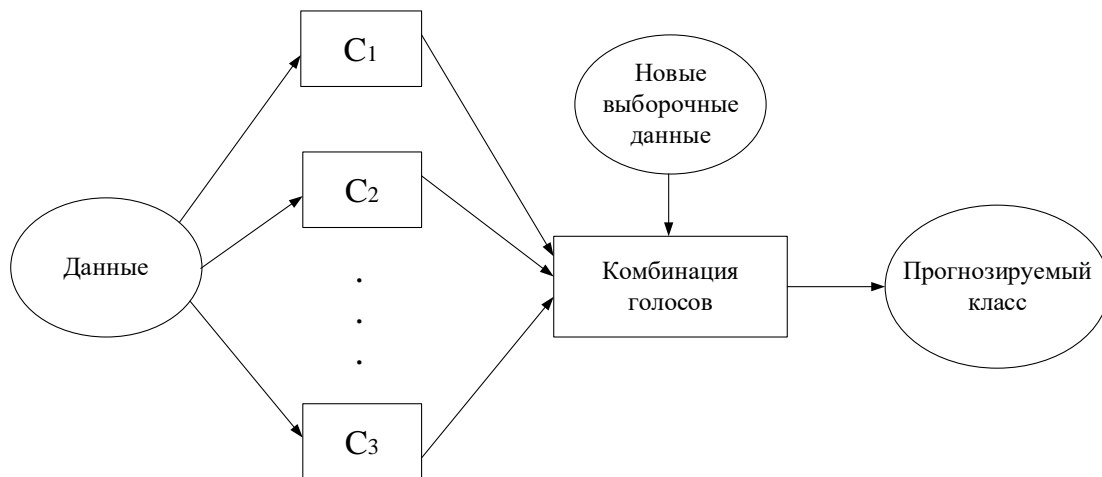


Рисунок 3 – Схема классификации ансамблевого обучения AdaBoost

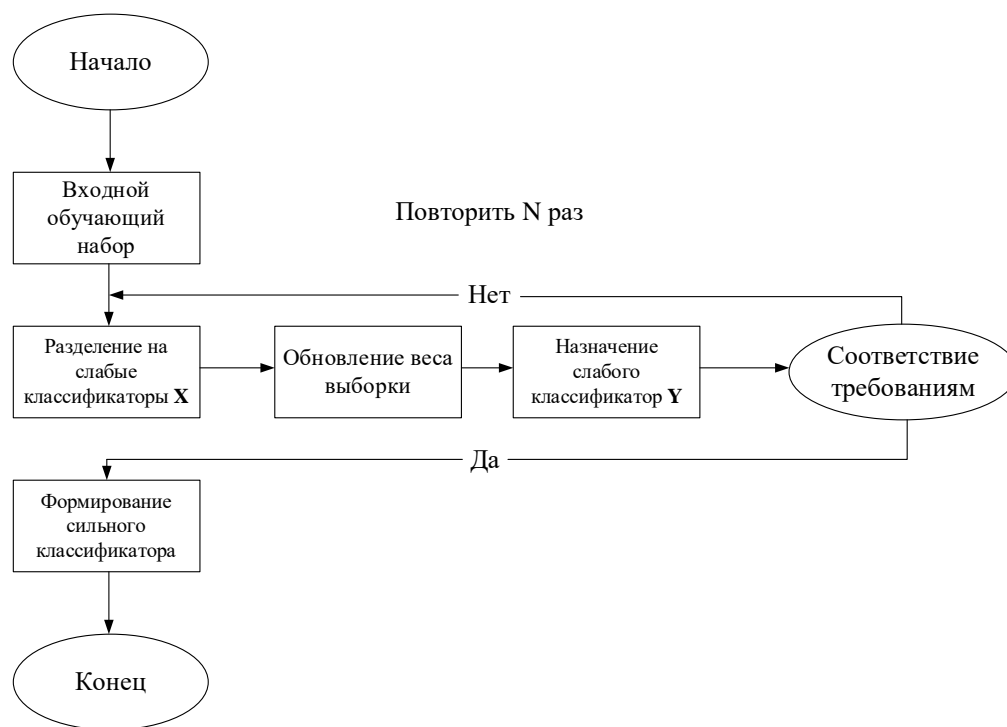


Рисунок 4 – Блок-схема алгоритма AdaBoost

Таким образом, создается новый сценарий и программирование продолжается в нем по той же схеме, а далее происходит извлечение значений функций. Затем вносятся 70 из 100 наборов данных в модуль интегрированного алгоритма обучения. Остальные 30 наборов данных переносятся в интегрированный обучающий модуль для тестирования, при достижении необходимой точности определения неисправности происходит их анализ и реализация интерпретации результатов [8].

В работе выполнен анализ точности выявления ошибок алгоритма ансамблевого обучения в зависимости от количества слабых классификаторов. Результаты анализа приведены в таблице 1.

Таблица 1 – Результаты анализа ошибок алгоритма ансамблевого обучения

Количество слабых классификаторов	10	20	50	70	100	500	<b>1000</b>	2000
Точность диагностики неисправностей, %	70	86,7	90	90	90	90	<b>93,3</b>	93,3

**Полученные результаты позволяют сделать следующие выводы:**

1. Наиболее высокий уровень точности диагностики соответствует является большему количеству слабых классификаторов (1000 и более).
2. Снижение количества классификаторов понижает точность диагностирования, что вызывает риск невыявления неисправности.
3. Повышение количества классификаторов сверх определенного значения не оказывает существенного влияния на точность диагностирования. При этом снижается скорость вычислений. Оптимальное количество слабых классификаторов следует устанавливать таким образом, чтобы функционирование разработанной модели машинного обучения соответствовало критериям достаточной точности и быстродействия.

**Список использованных источников**

1. Бузмакова Л.В., Власьевский С.В., Овсейчик С.З. Методика диагностирования выпрямительно-инверторных преобразователей электровозов переменного тока // Электротехника. 2016. № 2. С. 24-27.
2. Бузмакова Л.В., Буняева Е.В., Усенко Е.В. Алгоритм обработки признаков неисправности для автоматизированной системы диагностирования силовых преобразователей электровозов переменного тока // Научно-техническое и экономическое сотрудничество стран АТР в XXI веке. 2017. Т. 2. С. 350-352.
3. Gou, B., Ge, X., Wang, S., Feng, X., Kuo, J. B., & Habetler, T. G. 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 Trans. Power Electronics, 31, 2016. P. 3816–3826.
4. Huang, G., & Huang, G. B. Trends in extreme learning machine: A review // Neural Netw, 61, 2015. P. 32–48.
5. Xia, Y., Gou, B. & Xu, Y. A new ensemble-based classifier for IGBT open-circuit fault diagnosis in three-phase PWM converter // Prot Control Mod Power Syst 3, 2018. P. 33.
6. Ke G., et al. LightGBM: A Highly Efficient Gradient Boosting Decision Tree // Advances in Neural Information Processing Systems 30 (NIPS 2017), 2017.
7. Raschka S., Mirjalili V. Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow 2 // Packt Publishing Ltd., 2019, P. 770.
8. Ян С., Малышева О.А. Исследование неисправностей преобразователя электровоза на основе ансамблевого обучения // Наука настоящего и будущего. 2024. Т. 3. С. 257-259.