

Новая стратегия обнаружения и классификации неисправностей в ветровых турбинах на основе двухфазных асинхронных генераторов

Боаз Вадава ^{a,*}, Жозеф Ив Эффа ^b

^a Лаборатория: электроника, приборостроение и энергетика – Кафедра физики – Факультет естественных наук – Университет Шуайба Дуккали, Эль-Джадида 24000, Марокко

^b Кафедра физики, Университет Нгаундере, а/я 454, Нгаундере 00237, Камерун

Аннотация

Предлагается новая надежная диагностическая система, основанная на представлении дробно-линейного преобразования (LFT) в сочетании со статическим резервированием, для проектирования генератора остаточных напряжений для обнаружения и локализации неисправностей в ветроэнергетической системе с двухфазным асинхронным генератором (DFIG). В результате неисправности в ветроэнергетических системах на базе DFIG, подключенных к сети, могут быть сгруппированы в три класса: неисправности, связанные с неопределенностью модели (FLMU), неисправности, связанные с возмущением заданного значения (FLDS), и неисправности, связанные с неопределенностью параметров (FLPU). На основе производства остаточных значений в пространстве четности была объединена структура искусственной нейронной сети (ANN) с классификацией, что позволило оценить скрытые, неразличимые или малоамплитудные неисправности. Обучение и проверка с использованием двух размеров данных — 1278×4 и 1278×1 соответственно на входе и выходе предложенной ANN — показали лучшие результаты по значению среднеквадратичной ошибки ($MSE = 3,0532e-9$) и хорошую корреляцию между выходными и целевыми значениями по значению регрессии ($R = 1$). Выявлено, что предложенная надежная и полная диагностическая система для оптимальной и устойчивой интеграции ветротурбин в энергосистему обладает значительными преимуществами, особенно в отношении точного и быстрого обнаружения неисправностей, а также оценки скрытых неисправностей и/или неоднозначных состояний неисправностей в ветроэнергетической системе на основе двухфазных асинхронных генераторов (DFIG). Кроме того, предложенный подход позволяет использовать меньшее количество необходимых данных, датчиков и исполнительных механизмов. Следовательно, уменьшаются трудности в обслуживании системы, ее сложность и стоимость.

Ключевые слова: классификация; диагностическая система; метод статической избыточности; дробно-линейное преобразование (LFT); Искусственная нейронная сеть (ANN)

0 Введение

1) Мотивация и побуждение

Сохранение окружающей среды и устойчивое развитие энергетических ресурсов в настоящее время находятся в центре глобальных задач [1]. В результате альтернативы усиленной эксплуатации ископаемых ресурсов все чаще заключаются в обращении к устойчивому и эффективному развитию возобновляемых источников энергии, таких как ветровая энергия. Последняя набирает обороты, в частности, благодаря своим основным преимуществам с точки зрения увеличения производства энергии, гарантированного длительного срока службы и гибкости в плане энергетического баланса и интеграции ветровых систем в электросеть [1]. Кроме того, можно сказать, что концепция устойчивости в контексте ветроэнергетических систем заключается не только в удовлетворении энергетических и экономических потребностей, но и в сохранении окружающей среды сегодня, без ущерба для возможностей, активов и задач этой чистой энергии для будущих поколений [2]. Однако найти хороший компромисс между экологическим балансом и гарантированным длительным сроком службы ветротурбин, с одной стороны, и упрощением интеграции ветротурбин в электрическую сеть, с другой стороны, совсем непросто. Главная причина заключается в том, что

использование энергии ветра сталкивается с решением очень сложных масштабных задач, которые относятся к области высокоуровневых исследований.

Nomenclature		
ANN	Artificial neural network	$\beta \in \mathbb{R}^*$ Adjustment factor of the hyperbolic tangent function
ADRC	Active disturbance rejection control	DFIG Doubly-fed induction generators
CNN	Convolutional neural network	$\Delta 1, \delta$ Transfer matrix for model and parameter uncertainties
DOS	Dedicated observer structure	FLMU Fault linked to model uncertainties
DLPC, DLIM and DLIP	Defects related to the setpoint, the model and the parameters	FLPU Fault linked to parameter uncertainties
FLDS	Fault linked to set point disturbances	FSA French Standardization Association
FKE	Extended Kalman Filter	GOS Generalized observer structure
FFT	Fast Fourier Transform	Hinf Infinty Horizon
HRC	High resistance connection	IGBT Insulated gate bipolar transistor
IEC	International Electrotechnical Commission	χ^2 Chi-square
Ξ	Diagnostic system	LPV Linear Parameter Varying
LFT	Linear fractional transformation	LM Leveuberg-Marquardt
LMI	Linear matrix inequality	MPPT Maximum Power Point Tracker
MCSA	Machine current signature analysis	$\mathbf{N}$ Set of natural numbers
MANFIS	Multiple output neurofuzzy inference	$\mathbb{R}$ Set of real numbers
RSC	Rotor side converter	TCSC Thyristor-controlled series capacitor
TS	Takagi-Sugeno	θ_j Activation threshold of neurons
TL	Transmission Lines	VMD Variational mode decomposition
UKF	Unscented Kalman Filter	
AI	Artificial intelligence	

Таким образом, можно выделить две основные группы задач, связанных с использованием энергии ветра. Первая группа касается [3-5]:

- поиск новых экологически чистых материалов, более подходящих для проектирования и производства инновационных и экологичных ветротурбин;
- планирование и размещение экологически устойчивых ветропарков на суше и в море;
- более экологичный энергетический баланс;
- анализ жизненного цикла ветровых систем;
- визуальное и шумовое загрязнение от ветряных турбин;
- обработка, сборка и обслуживание ветровой инфраструктуры и т.д.

Первая группа задач может прямо или косвенно влиять на количество и качество производимой ветровой энергии [3]. Поэтому вторая категория задач, связанных с производством качественной и количественной ветровой энергии, касается [1,3-5]:

- риски несвоевременного отключения ветряной турбины от сети;
- повышение уровня гармонии;
- мерцают провалы напряжения;
- увеличение и хранение производимой энергии;
- разделение и управление активной и реактивной мощностью ветроэнергетических систем;
- энергетическая и/или экономическая рентабельность стратегий управления и диагностики ветротурбин;
- чрезмерное повышение температуры в катушках DFIG и в статических преобразователях силовой электроники ветроэнергетической системы и т. д.

Действительно, на практике сложность задач, связанных с ветротурбинами, возрастает с увеличением требований к исследованиям, направленным на повышение количества и качества производимой энергии, с одной стороны. С другой стороны, возрастают ограничения, касающиеся выбора методов управления, стратегий технического обслуживания и выбора моделей, используемых для оптимального использования энергии ветра. Поэтому наша цель в данной работе — гарантировать автоматизированным ветроэнергетическим системам хорошую доступность и эксплуатационную безопасность. Для этого мы, как правило, используем диагностические методы, которые в основном относятся к концепции условного профилактического обслуживания, основанного на непрерывном мониторинге рассматриваемой системы. В отличие от корректирующего обслуживания, действия которого происходят после того, как рассматриваемая система вышла из строя или сломалась, подход к профилактическому обслуживанию требует предварительной диагностической системы, позволяющей заблаговременно выявлять отклонения от нормальной работы системы. Именно этому последнему подходу мы будем уделять внимание на протяжении всей статьи, чтобы внести свой вклад в разработку надежной и оптимальной диагностической системы, позволяющей нам лучше реагировать на основные сложности, связанные с производством ветровой энергии в количественном и качественном отношении.

2) Литературный обзор

Для эффективного и действенного решения задач, связанных с качеством энергии, производимой ветроэнергетическими установками, большинство исследователей посвящают себя использованию и разработке стратегий оптимального управления и надежных диагностических систем. Хотя практически невозможно отделить оптимальное управление от надежной диагностики в сложных системах, мы, тем не менее, будем заинтересованы в обзоре работ по разработке надежных диагностических систем. В целом, в диагностических системах существуют две основные группы методов: количественная диагностическая группа, использующая методы, основанные на математических моделях систем и/или сигналов. В то время как качественная диагностическая группа использует методы, основанные на искусственном интеллекте (ИИ) или на алгоритмах оптимизации численных вычислений. Действительно, эти две группы не являются взаимоисключающими; совместное использование качественных и количественных методов обеспечивает эффективное использование всех имеющихся знаний о поведении изучаемой системы или сигнала. Поэтому современное состояние дел в последних работах, представленных в данной статье, делится на две большие группы, а именно, первая группа предназначена для диагностических систем, основанных на количественных подходах, а вторая группа — для так называемых гибридных подходов, которые сочетают качественные и количественные методы.

а) Первая группа работ, основанных на количественных подходах

Мохамед-Амин и др. [6] предлагают диагностический метод, основанный на расширенном наблюдателе состояния и возмущений в сочетании с критерием хи-квадрат (χ^2). Этот подход будет экспериментально проверен на испытательном стенде мощностью 15 кВт для обеспечения обнаружения неисправностей в IGBT, датчиках тока ротора и статора, а также сбоя датчиков напряжения статора. Однако этот метод можно улучшить главным образом с точки зрения сложности, расширенного использования датчиков и исполнительных механизмов, точности идентификации и локализации характера неисправностей, стоимости и т. д. Абдельвахаб и др. [5] предлагают обзор различных методов обнаружения внутренних электрических неисправностей в DFIG для ветротурбин. Авторы рассматривают модели для точного анализа и оценки неисправностей следующим образом:

- надежные и недорогие методы, основанные на статорном токе, основным ограничением которых является высокая чувствительность к аномалиям;

- методы вейвлет-анализа для многоразрешающего обнаружения, основным недостатком которых является низкая чувствительность к незначительным дефектам;
- высокоточные методы, основанные на эквивалентных магнитных цепях, но очень сильно зависящие от параметрических изменений машины;
- быстрые методы, основанные на анализе Фурье, которые сильно подвержены влиянию колебаний скорости;
- на точность методов, основанных на комбинации сигнатурного анализа тока машины (MCSA), также влияют изменения крутящего момента или скорости;
- упрощенные методы, основанные на вибрациях, имеют ограничения с точки зрения контекста и применения;
- высокоточные методы, основанные на изучении потоков, имеют недостатки с точки зрения надежности, стоимости и сложности.

В целом, эти методы требуют усовершенствований с точки зрения чувствительности к мелким или крупным неисправностям, с одной стороны, а также с точки зрения стоимости, надежности и сложности реализации, особенно с учетом необходимости одновременного рассмотрения и объединения всех этих методов для создания более полной системы диагностики ветротурбин.

Йошра Сайхи и др. [7] используют испытательный стенд, основанный на структуре специализированного наблюдателя (DOS) и обобщенной структуре наблюдателя (GOS), для обеспечения обнаружения и локализации периодических неисправностей датчиков и короткого замыкания между обмотками DFIG. Эта работа, слишком специфичная, станет еще сложнее, когда потребуется проводить другие уведомления и манипуляции с тестами, чтобы учесть другие типы дефектов.

Вэй Дин и др. [8] сосредоточатся исключительно на диагностике неисправностей, связанных с дисбалансом сопротивления статора. Предложенный ими подход основан на блоках шунтирующих конденсаторов, на искусственной нейтральной точке и на предположении об превосходной эффективности управления. Поэтому, даже если этот подход может оказаться более сложным, он требует исследования практической осуществимости путем оценки влияния оптимальных регуляторов, с одной стороны. С другой стороны, важно связать этот подход с методом классификации, позволяющим диагностировать неисправности соединений с высоким сопротивлением (HRC) в обмотках статора и ротора DFIG.

И. Идрисси и др. [9] предлагают диагностический подход, основанный на фильтре Калмана типа линейного изменения параметров (LPV), который интегрирует параметрические изменения DFIG. Кроме того, для подавления помех и шума используются нелинейные варианты расширенного фильтра Калмана (FKE) и нелинейного фильтра Калмана (UKF). Хотя этот подход эффективен, он требует усовершенствования с точки зрения использования меньшего количества датчиков и исполнительных механизмов, которые могут заглушать определенные шумы и усложнять идентификацию, точность и локализацию других типов неисправностей DFIG.

б) Вторая группа работ, основанных на гибридных количественных и качественных подходах.

Икрам Аиссауи и др. [10] предлагают стратегию отказоустойчивого управления для датчиков тока на генераторе с двойным питанием ветряной турбины. Подход основан на оптимизированном активном управлении подавлением помех (ADRC). Генетический алгоритм связан с обнаружением, идентификацией, изоляцией и реконfigurацией сигналов датчиков тока после сбоя. Этот очень целенаправленный подход необходимо улучшить с помощью более надежной диагностической

системы, которая учитывает другие типы неисправностей для улучшения локализации и определения характера неисправностей.

Хаджира Буазза и др. [11] предлагают подход нечеткого вывода и ANFIS для обнаружения неисправностей в переключателях преобразователя со стороны ротора (RSC) DFIG ветроэнергетической установки. Этот подход основан на предварительном определении порога обнаружения на основе средних значений трехфазных токов ротора. Хотя этот подход, по-видимому, прост, эффективен и быстр в обнаружении, его можно критиковать с точки зрения проверки или практической осуществимости, точности обнаружения, интеграции, локализации и идентификации других типов дефектов DFIG.

Насреддин Лабед и др. [12] предлагают стратегию, которая включает в себя не только алгоритм быстрого преобразования Фурье (FFT) для извлечения параметров частотной характеристики, но и использование адаптивного нейро-нечеткого вывода ANFIS для обнаружения и автоматической классификации неисправностей ротора и статора DFIG. Хотя этот метод демонстрирует эффективность и надежность, тем не менее, необходимо более подробно изучить преимущества этого подхода, сравнив его с другими методами диагностики DFIG, основанными на ANN и нечеткой логике.

Эсван-Хесус Перес-Перес и др. [13] предлагают гибридный подход к обнаружению и локализации неисправностей на ветряной турбине мощностью 5 МВт. Подход состоит из ANFIS, которая идентифицирует динамическую модель ветряной турбины и приводит к квазилинейному полнотопическому ансамблю с переменным параметром (qLPV). Обнаружение неисправностей осуществляется с помощью генератора остаточных значений, состоящего из зонотических наблюдателей qLPV. Кроме того, обучение нечеткой нейронной сети ANFIS использует только исправные данные без дефектов. Надежность и удовлетворительная производительность подхода проверяются с помощью помех, связанных с аэродинамической нагрузкой и шумом измерений. Кроме того, Эсван-Хесус Перес-Перес и др. [14] предлагают еще одну систему диагностики неисправностей ветряной турбины мощностью 5 МВт, состоящую из зонотического оценщика состояния, основанного на моделях Такаги-Сугено (TS) с параметрической ассоциацией неопределенности с использованием многовыходного нейронечеткого вывода (MANFIS). Обнаружение и изоляция неисправностей с помощью матрицы сигналов неисправностей основаны на зонотическом наблюдателе TS. Ансамбль линейных матричных неравенств (LMI) с H_{∞} обеспечивает настройку параметров наблюдателя с учетом неопределенности модели. Предложенный подход, в отличие от представленного в [13], предлагает улучшение с точки зрения работоспособности, идентификации неисправностей, оценки неопределенности и времени обучения.

В том же ключе Эсван-Хесус Перес-Перес и др. [15] разрабатывают другой подход к диагностике неисправностей для ветряной турбины мощностью 5 МВт, основанный на использовании набора наблюдателей интервалов TS для обнаружения и изоляции неисправностей датчиков. Модель ANFIS позволяет получить полнотопное линейное представление и модели принадлежности для интерполяции линейных моделей выпуклого TS. Главное преимущество подхода [15] заключается в генерации доверительных интервалов для предотвращения ошибок моделирования.

Саувик Бивас и др. [16] предлагают алгоритм дистанционного реле для защиты линий электропередачи, подключенных к ветропарку, на основе DFIG. Предложенный алгоритм извлекает полезные признаки из сигналов тока линии, используя метод однополюсной фильтрации для генерации изображений красно-зелено-синих цветов классификатора ANN, чтобы улучшить обнаружение и классификацию неисправностей. Подход подтвержден численным моделированием в реальном времени с использованием данных без неисправностей и без неисправностей из двухшинных и девятишинных тестовых энергосистем для ветропарков с

тиристорно-управляемыми последовательными конденсаторами (TCSC) и DFIG. Эффективность подхода составляет 100% для точности обнаружения и около 99,50% для точности классификации неисправностей. Сауик Бивас и др. [17] также предлагают интеллектуальную схему дистанционного реле для обнаружения и классификации неисправностей в линиях электропередачи (TL), подключенных к выходным сигналам ветрогенератора с DFIG. Предложенный подход использует вариационное разложение на моды (VMD) для извлечения в реальном времени характеристик тока линии, включая извлечение частотных компонентов тока неисправности, и для различения внутренних и внешних неисправностей. Извлеченные с помощью VMD величины проходят через фильтр Винера для генерации изображений в градациях серого, которые будут использоваться классификатором глубокой сверточной нейронной сети (CNN). Эффективность предложенного алгоритма оценивается с помощью моделирования в реальном времени на двухшинной системе с использованием 12 000 случаев неисправностей и 120 случаев отсутствия неисправностей, а также путем сравнения их как минимум с 5 различными подходами. Подход демонстрирует удовлетворительные результаты со временем обнаружения неисправности 10 мс, высокой точностью обнаружения неисправности и классификации 100% и 99,86% соответственно.

Сауик Бивас и др. [18] также предлагают алгоритм релейной защиты, основанный на использовании знака наложенного на полупериод тока положительной последовательности для обнаружения неисправностей на ветропарках с тиристорно-управляемым последовательным конденсатором (TCSC) и компенсацией (TL) с DFIG. Классификация неисправностей обеспечивается классификатором случайного леса с эмпирической компенсацией. В то время как модифицированный подход с использованием импеданса обеспечивает локализацию неисправностей. Производительность предложенного алгоритма оценивается на 6750 случаях неисправностей и множестве переходных случаев без неисправностей, сгенерированных на тестовой системе в Matlab Simulink. Подход демонстрирует производительность 8 мс при обнаружении и классификации, с точностью 100% для обнаружения, 99,12% для локализации и 99,95% для классификации неисправностей. Сауик Бивас и др. [19] предлагают еще одну схему интеллектуальной релейной защиты для защиты линий электропередачи (TL), соединяющих ветропарки, на основе DFIG. Предложенная схема обнаружения и идентификации повреждений линий основана на использовании α -воздушных сигналов, наложенных на ток, измеренный на конце ЛЭ в статическом синхронном компенсаторе (STATCOM). Измеренные токи затем извлекаются на конце релейного устройства с помощью двойного временного преобразования (TT), которое используется классификатором дерева решений для классификации повреждений. Для оценки повреждений используется метод, основанный на использовании положительных волн α - и β -воздушных токов. Эффективность подхода оценивается на 6000 случаях неисправностей и множестве переходных случаев без неисправностей, смоделированных на тестовой системе в Matlab Simulink. В отличие от работ [16-18], предлагаемый подход требует меньшего количества входных данных, низкой вычислительной нагрузки и сниженных трудностей реализации. Обнаружение и классификация занимают порядка 8 мс, точность обнаружения составляет 100%, точность определения местоположения — 99,18%, а точность классификации дефектов — около 99,96%.

Хотя результаты применения подходов, предложенных во второй группе работ, удовлетворительны для диагностики неисправностей датчиков тока машины, переключателей преобразователей со стороны ротора, частот тока генератора с двойным питанием (DFIG), ветряной турбины и линий электропередачи ветропарков, предложенные гибридные подходы все же сталкиваются с некоторыми ограничениями и сложностями, которые можно суммировать следующим образом:

Предложенные подходы сосредоточены на диагностике отдельного элемента ветроэнергетической системы за раз, без учета глобального анализа ветроэнергетической системы, в частности, взаимодействия между турбиной, машиной, преобразователями и сетью.

Учитывая сложность разработки предлагаемых подходов с помощью моделирования, для их полной проверки необходимы экспериментальные оценки осуществимости. Тот факт, что используемые качественные подходы не обязательно используют математические модели систем, может привести к упущениям в получении знаний и анализе глобального и внутреннего поведения изучаемых систем. Поэтому идентификация и локализация отдельных неисправностей подвержены риску неоднозначности.

Трудности, связанные со сбором достоверных данных или использованием ошибочных данных для обучения алгоритмов ИИ, могут повлиять на эффективность диагностических результатов с точки зрения больших временных затрат и риска ошибок. Кроме того, управление или использование в этих подходах большого количества данных, датчиков и исполнительных механизмов неизбежно приводит к чрезмерному потреблению энергии, увеличению времени обучения, а также к увеличению трудностей и затрат на техническое обслуживание.

В отличие от математических подходов, обучающие данные для качественных подходов нелегко обобщить на все ветроэнергетические системы, поскольку неопределенности различаются от одного производителя к другому.

3) Организация публикаций и сбор материалов

Основная цель данной работы — предложить надежную и более полную диагностическую систему для обнаружения, локализации и классификации неисправностей ветровой системы на основе двухфазного асинхронного генератора (DFIG). Для этого предлагается новый комплексный подход, а именно:

Структурированное моделирование генератора с двойным питанием (DFIG) на основе представления в виде линейного дробного преобразования (LFT) играет роль в сопоставлении наблюдаемых выходных состояний с датчиками и/или исполнительными механизмами с целью облегчения идентификации, обнаружения и локализации неисправностей, вызванных неопределенностью параметров и модели исследуемой системы. Кроме того, структура LFT системы DFIG позволит выявлять воздействия, связанные с неисправностями, возникающими из-за инструкций или взаимодействия между различными элементами исследуемой ветроэнергетической системы. В отличие от подходов, упомянутых в литературе, LFT системы DFIG позволит внедрить надежную и более полную диагностическую систему, основанную на структурированной идентификации и локализации возможных неопределенностей и ошибок заданных значений, возникающих в результате взаимодействия между турбиной, машиной, преобразователями и сетью ветроэнергетической системы.

Использование подхода с аналитическим избыточным пространством или аналитического избыточного подхода направлено на обнаружение, идентификацию и эффективную локализацию неисправностей на выходах наблюдаемых состояний системы. В отличие от моделей наблюдения, таких как, например, фильтр Калмана, подход с аналитическим избыточным пространством предлагает преимущество использования меньшего количества датчиков и отсутствия исполнительных механизмов управления. Предложенная надежная гибридная диагностика, основанная на аналитическом избыточном подходе в сочетании со структурой ANN, также заключается в том, что структура ANN используется для оценки, локализации и классификации только скрытых неисправностей или тех, которые неотличимы от количественного метода, называемого аналитическим избыточным пространством. Предлагаемый гибридный подход позволяет сократить объем данных и время обучения, уменьшить количество необходимых

датчиков и исполнительных механизмов, а также снизить энергопотребление. Следовательно, это позволит упростить обслуживание системы, а также снизить сложность и стоимость предлагаемой диагностической системы.

Классификация неисправностей будет заключаться в сопоставлении выходных данных наблюдаемых состояний моделей по пространству четности с искусственной нейронной сетью (ANN) для более структурированного мониторинга диагностики и обеспечения оптимального вмешательства при обслуживании ветроэнергетической системы на основе DFIG.

Данная работа организована следующим образом:

Методологическая часть будет заключаться в подробном описании предлагаемого диагностического подхода, такого как структурированное моделирование DFIG с использованием LFT; обнаружение, идентификация, локализация и классификация наблюдаемых неисправностей диагностической системы на основе подхода статической избыточности, связанного с RNA.

Раздел «Результаты и обсуждение» посвящен анализу, интерпретации и подтверждению предложенных диагностических результатов.

Последняя часть посвящена заключению представленной работы.

1. Методология

Для определения контекста предполагаемой надежной диагностической системы мы будем опираться на положение и основные роли, которые играет генератор с двойным питанием (DFIG) в ветроэнергетической системе, как показано на рис. 1. Последний помещает DFIG в качестве центрального элемента ветроэнергетической системы, основная функция которого заключается в преобразовании механической энергии ветра в электрическую энергию, передаваемую в сеть. Контроллер отслеживания точки максимальной мощности (MPPT) ветряной турбины позволит максимально использовать энергию ветра и регулировать механическую энергию, передаваемую на DFIG. В то же время другие контроллеры, связанные с RSC и GSC, обеспечат обмен энергией между ротором генератора и электрической сетью. Затем, посредством магнитной индукции, будет гарантирован обмен энергией между статором DFIG и сетью. Следовательно, для обеспечения надлежащей эксплуатационной безопасности и лучшего технического обслуживания ветроэнергетических систем крайне необходима надежная система диагностики, основанная на эквивалентной модели DFIG.

1.1 Обобщенная модель DFIG

Предполагаемая диагностическая система будет использовать эквивалентную динамическую модель DFIG, определенную в рамках Парка (d,q) следующим образом [1]:

$$\begin{cases} U_{sd} = -r_s i_{sd} - L_s \frac{di_{sd}}{dt} + M \frac{di_{rd}}{dt} + \omega_{os} L_s i_{sq} - \omega_{os} M i_{rq} \\ U_{sq} = -r_s i_{sq} - L_s \frac{di_{sq}}{dt} + M \frac{di_{rq}}{dt} - \omega_{os} L_s i_{sd} - \omega_{os} M i_{rd} \\ U_{rd} = r_r i_{rd} + L_r \frac{di_{rd}}{dt} - M \frac{di_{sd}}{dt} - (\omega_{os} - \omega_r) L_r i_{rq} + (\omega_{os} - \omega_r) M i_{sq} \\ U_{rq} = r_r i_{rq} + L_r \frac{di_{rq}}{dt} - M \frac{di_{sq}}{dt} + (\omega_{os} - \omega_r) L_r i_{rd} - (\omega_{os} - \omega_r) M i_{sd} \end{cases} \quad (1)$$

где U_{sd} , U_{sq} и U_{rd} , U_{rq} - соответственно выражения для напряжений статора и ротора в точке отсчета (d, q);

M_{sr} и M_{rs} : взаимные индуктивности между обмотками статора и ротора обычно считаются одинаковыми в соответствии с соотношением; при $M_{sr} = M_{rs} = M$;

r_r , r_s : резисторы обмоток ротора и статора;

L_r, L_s : индуктивности ротора и статора;

ω_{os} и ω_r : угловые скорости вращения от возбужденного поля к статору и ротору соответственно;

i_{sd}, i_{sq} и i_{rd}, i_{rq} : токи, протекающие к статору и ротору соответственно по осям d и q.

1.2. Принцип структурированного представления с помощью LFT

В принципе, LFT представляет собой структурированное моделирование многомерной системы, включающее эталонную модель и модели неопределенности. Очевидно, что представление с помощью LFT состоит в определении расширенной модели $P(s)$ многомерной системы, либо для синтеза закона управления на рис. 2а, либо для случая синтеза надёжной диагностической системы на рис. 2б. Следовательно, описание рис. 2 может выглядеть следующим образом:

$K(s)$ и Ξ - соответственно, корректор и искомая диагностическая система;

$P(s)$ - управляемый процесс или общий процесс системы;

ω собирает рассматриваемые входные данные, такие как опорные сигналы, помехи и шум.

U - вектор управления процессом;

Z - вектор выходных сигналов, выбранный для характеристики надлежащего функционирования управляемого процесса $P(s)$;

Y - вектор выходных данных или измерений процесса;

X - вектор состояния представляет собой внутренние переменные процесса.

Этот общий процесс также называется расширенной матрицей, и её секционированное представление выглядит следующим образом:

$$P(s) = \begin{bmatrix} P_{11}(s) & P_{12}(s) \\ P_{21}(s) & P_{22}(s) \end{bmatrix} \quad (2)$$

Furthermore, the transfer function between ω and Z of the looped system of Fig. 2a can be written as:

$$F_1(P(s), K(s)) = \left(P_{11}(s) + P_{12}(s)K(s)(I - P_{22}(s)K(s))^{-1}P_{22}(s) \right) \quad (3)$$

1.3 Структурированное представление DFIG в формате LFT

Формулировка представления LFT, применяемого к DFIG для диагностики ветроэнергетической системы и включающего смешанные неопределенности (неопределенности модели и параметров), представлена структурой, показанной на рис. 3. Действительно, такая сложная и многопараметрическая система, как ветроэнергетический DFIG, должна учитывать неопределенности параметров и/или моделей. На рис. 3 неопределенность модели (W_m) представляет высокочастотную динамику в виде единой блочной матрицы переноса (Δ_1), которую можно суммировать или умножать на эталонную модель процесса. В то время как неопределенности параметров в виде матричной структуры в блоке (δ) представляют параметрические вариации динамики и/или элементарные коэффициенты процесса.

Перегруппировав (1) и используя значения параметров DFIG из таблицы A1 в приложении, мы получаем выражение матричных уравнений состояния динамической эталонной модели DFIG следующим образом:






Рис. 3. LFT-структурирование смешанных неопределенностей, включая управление и диагностику.

$$\begin{bmatrix} \dot{I}_{\text{dr}} \\ \dot{I}_{\text{qr}} \end{bmatrix} = \begin{bmatrix} -0.512 & 6.28 \\ -6.28 & -0.512 \end{bmatrix} \begin{bmatrix} I_{\text{dr}} \\ I_{\text{qr}} \end{bmatrix} + \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} V_{\text{dr}} \\ V_{\text{qr}} \end{bmatrix}$$

$$\begin{bmatrix} V_{\text{ds}} \\ V_{\text{qs}} \end{bmatrix} = \begin{bmatrix} -1.5e-3 & 0.895 \\ -0.895 & -1.5e-3 \end{bmatrix} \begin{bmatrix} I_{\text{dr}} \\ I_{\text{qr}} \end{bmatrix} + \begin{bmatrix} 0.98 & 0 \\ 0 & 0.98 \end{bmatrix} \begin{bmatrix} V_{\text{dr}} \\ V_{\text{qr}} \end{bmatrix} \quad (4)$$

1.3.1 Выбор неопределенности параметров в DFIG

На практике, независимо от влияния неисправностей, параметры системы могут быть изменены в любое время законом управления, чтобы гарантировать стабильность управляемой системы [4]. В рамках динамики ветроэнергетической системы и благодаря законам управления, DFIG может работать в четырехквadrантном режиме вокруг точки синхронизма g (скольжение). Зная, что скольжение g напрямую связано с взаимной индуктивностью M на уровне статора, мы можем напрямую выбрать параметры неопределенности, связанные со скольжением в (4), такие как [1]: $6,28 = \omega_s g$ и $0,895 = M \omega_s g$; где ω_s — пульсация статора. Следовательно, мы можем считать, что

скольжение может принадлежать диапазону скоростей $\pm 30\%$, следовательно, $g \in [0,014 \ 0,026]$ с $g = 0,02$. Мы будем записывать g в соответствии с реальной нормированной неопределенностью, обозначенной $|\delta| < 1$, следующим образом:

$$g = g_0 + g_1 \delta \quad (5)$$

где $g_0 = (0.014 + 0.026)/2$ и $g_1 = (0.026 - 0.014)/2$.

1.3.2. Выбор неопределенности модели W_m и расширенной матрицы DFIG

На практике ошибки моделирования DFIG фундаментально представляют собой источник неопределенностей модели. Поэтому, согласно принципу векторного управления, можно допустить, что передаточная функция номинальной модели $G(s)$ DFIG имеет 1-й порядок. Тогда предположим также, что приложенное управление исходит от быстрого и динамичного исполнительного механизма 1-го порядка [1]. Тогда модель $G_p(s)$ системы, включая неопределенности, возникающие из-за немоделируемой динамики, можно записать в следующей форме:

$$\tilde{G}(s) = \frac{G(s)}{1 + T_m s} \quad (6)$$

где T_m - постоянная времени актуатора (привода) (мы выбрали $T_m = 0.0001$).

Неопределенность мультипликативной модели представления рис. 3 определяется следующим выражением [1]:

$$W_m(s) = \frac{T_m s}{1 + T_m s} \geq \left| \frac{\tilde{G}(s) - G(s)}{G(s)} \right|_{\forall \omega} \quad (7)$$

$$P_a : \begin{cases} \begin{bmatrix} \dot{I}_{dr} \\ \dot{I}_{qr} \\ \dot{I}_{wm} \end{bmatrix} = \begin{bmatrix} -0.512 & 6.28 & 0 \\ -6.28 & 0.512 & 0 \\ 0 & 0 & -100 \end{bmatrix} \begin{bmatrix} I_{dr} \\ I_{qr} \\ I_{wm} \end{bmatrix} + \begin{bmatrix} 0 & 1 & 0 & 1 & 0 \\ -314 & 0 & 0 & 0 & 1 \\ 0 & 0 & 100 & 0 & 0 \end{bmatrix} \begin{bmatrix} V_1 \\ V_2 \\ V_{wm} \\ V_{dr} \\ V_{qr} \end{bmatrix} \\ \begin{bmatrix} \dot{q}_i \\ \dot{q}_m \\ \dot{V}_{ds} \\ \dot{V}_{qs} \end{bmatrix} = \begin{bmatrix} 6e^{-3} & 6e^{-3} & 0 \\ 0 & 0 & 0 \\ -1.5e^{-3} & 0.895 & -10 \\ -0.915 & -1.5e^{-3} & 0 \end{bmatrix} \begin{bmatrix} I_{dr} \\ I_{qr} \\ I_{wm} \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & -0.914 & 0 & 0.98 & 0 \\ 0.915 & 0 & 0 & 0 & 0.98 \end{bmatrix} \begin{bmatrix} V_1 \\ V_2 \\ V_{wm} \\ V_{dr} \\ V_{qr} \end{bmatrix} \end{cases} \quad (8)$$

Перегруппировав (5) и (7) в (4), мы получаем следующую расширенную систему LFT для DFIG:

$$\text{With, } V_1, 2, w_m = \Delta(\delta, \Delta_1) q_{i, m}; \quad V^T = [V_1 \ V_2 \ V_{wm}] \text{ and } q^T = [q_i \ q_m].$$

1.4. Краткое описание подхода к анализу пространства четности для диагностической системы DFIG.

Согласно определениям Французской ассоциации стандартизации (FSA) и Международной электротехнической комиссии (IEC), диагностика определяется как выявление вероятной причины сбоя с использованием логических рассуждений на основе набора информации, полученной в результате осмотра, контроля или испытаний [20]. Действительно, мы в основном сталкиваемся с двумя типами диагностических подходов, а именно количественным подходом, который не обязательно использует законы физики, и качественным подходом, который использует

математические модели для обнаружения и анализа локализации неисправностей в системе или сигналах. Количественный подход, являющийся предметом нашего диагностического исследования, в целом следует количественному представлению мониторинга, описанному шагами на рис. 4. Процесс, подлежащий мониторингу, который получает команду $U(t)$ в качестве входных данных и выдает измеренный выходной сигнал $Y(t)$, подвержен влиянию шума неизвестных входных сигналов $d(t)$ и влиянию неисправностей $f(t)$, которые мы хотим обнаружить. На этапе генерации остаточных значений используется математическая модель для определения признаков или остаточных значений на основе наблюдений исполнительного механизма управления $U(t)$ и/или измерений датчиков $Y(t)$. В то время как этап оценки остаточных значений состоит не только в обнаружении неисправностей по ненулевым остаточным значениям, но и в определении местоположения или идентификации неисправностей на основе сигнатуры неисправности или на основе классификации дефолтов.

Основная цель классификации неисправностей — разработка надёжного протокола для точного определения местоположения или идентификации неисправностей (источников, причин и/или характера неисправностей). Кроме того, классификация неисправностей включает в себя разработку хорошего протокола контроля для диагностического процесса с целью облегчения принятия решений и ввода в действие процесса технического обслуживания системы. Следовательно, последний шаг на рис. 4 посвящен исключительно контролю и/или принятию решений либо об изменении заданных значений или команд, либо о добровольной остановке, либо об аварийной остановке процесса [21].

1.4.1 Принцип статической избыточности подхода с использованием пространства четности

В целом, существует три больших группы подходов, используемых для определения диагностической системы, а именно подход с использованием пространства четности, подход с использованием наблюдателя и группа оценок параметров [21-23]. В группе с использованием пространства четности мы находим подход со статической избыточностью и подход с динамической избыточностью для случая дискретных систем. В принципе, выбор подхода может определяться не только поиском наилучшей производительности или решений, но и субъективной способностью исследователя предлагать устойчивые и эффективные решения заданных задач. В отличие от других подходов, статическое резервирование предлагает большие преимущества с точки зрения снижения сложности предполагаемой диагностической системы и облегчения оптимальной реализации диагностических систем, связанных с ANN. Кроме того, статическое резервирование позволяет использовать меньшее количество датчиков и исполнительных механизмов, что облегчает практическую осуществимость и обеспечивает работу в стационарном режиме. Принцип статического резервирования заключается в поиске существующих связей между измерениями датчиков и связанными с ними неисправностями. Для этого математическую модель предполагаемой диагностической системы можно записать следующим образом [23]:

$$y(t) = Cx(t) + f(t) \quad (9)$$

где p и n представляют собой размерность матрицы; обозначение $x(t)$ в (9) зависит от того, должна ли матрица C

$y(t) \in R_p$ — это вектор измерений;

$C \in R_{n \times p}$ — это матрица наблюдений;

$X(t) \in R_n$ — это вектор состояния;

$f(t) \in R_p$ — это вектор неисправности, связанный с датчиками.




Рис. 4. Схема процесса количественного контроля.

Выражения избыточности определяются исключением полного столбцового ранга и тем, должно ли число измерений на $y(t)$ быть больше размерности $x(t)$. С этого момента можно будет определить матрицу V такую, что $VC=0$. Для этого мы умножаем (9) на V и получаем обобщенное уравнение генератора остаточных значений, также называемого вектором пространства четности, заданное следующим выражением [23,24]:

$$r(t) = Vy(t) = VCx(t) + Vf(t) = Vf(t) = \sum_{i=1}^{ny} V_i f_i(t) \quad (10)$$

где $V_i(t)$ — номер столбцового вектора (i) проекционной матрицы V в пространстве четности; так что в отсутствие неисправности остаточное значение равно нулю, а в присутствии неисправности $f_i(t)$ остаточное значение $r(t)$ скорее ориентировно в направлении $V_i(t)$ дефектного датчика.

Кроме того, наиболее популярный подход к определению матрицы четности V состоит в том, чтобы сначала рассмотреть отсутствие дефекта. Это позволяет нам перегруппировать (9) и переписать его следующим образом:

$$y'(t) = C'x'(t) \quad (11)$$

где $y'(t) = [y_n(t) \ y_{p-n}(t)]^T$ и $C' = [C_n \ C_{p-n}]^T$.

C_n - обратимая квадратная матрица, полученная из n -й первой строки матрицы C . C_{p-n} — вторая матрица, полученная из оставшихся строк матрицы C . Тогда мы можем записать следующее соотношение:

$$y_{p-n} = C_{p-n} C_n^{-1} y_n \quad (12)$$

Уравнение (12) позволило нам отклонить неизвестное $x'(t)$, чтобы проверить согласованность измерения и вывести следующее уравнение избыточности:

$$[-C_{p-n} C_n^{-1} \ I_{p-n}] \begin{bmatrix} y_n(t) \\ y_{p-n}(t) \end{bmatrix} = 0 \quad (13)$$

где $V' = [-C_{p-n} C_n^{-1} \ I_{p-n}]$ является матрицей четности, ортогональной C' , и удовлетворяющей условию $V'C' = 0$. Мы можем вывести таблицу сигнатур ошибок из (13).

1.4.2 Краткое описание подхода статической избыточности, применяемого для надежной диагностики DFIG.

Учитывая условия формулировки (11), мы можем по аналогии извлечь и перегруппировать матрицу наблюдений (8), чтобы получить уравнение устойчивой диагностической системы DFIG следующим образом:

$$\begin{bmatrix} V_{ds} \\ V_{qs} \\ q_i \\ q_m \end{bmatrix} = \begin{bmatrix} -1.5e^{-3} & 0.895 & 0 & 0 \\ -0.915 & -1.5e^{-3} & -10 & 0 \\ 6e^{-3} & 6e^{-3} & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} I_{dr} \\ I_{qr} \\ I_{wm} \end{bmatrix} \quad (14)$$

where, $C_1 = [-1.5e^{-3} \ 0.895; -0.915 \ -1.5e^{-3}]$, $C_2 = [6e^{-3} \ 6e^{-3}; 0 \ 0]$, $C' = [C_1 \ C_2]$, $y' = [V_{ds} \ V_{qs} \ q_i \ q_m]^T$ and $x' = [I_{dr} \ I_{qr} \ I_{wm}]^T$.

где C_1 — обратимая квадратная матрица, принадлежащая первой строке матрицы C' , а C_2 — вторая матрица, полученная из оставшихся строк матрицы C' . Измеряемый выходной сигнал (y') будет содержать данные с четырех измерительных датчиков.

Исключение x' в (14) позволяет нам определить матрицу четности $V' = [-C_2 C_1^{-1} \ I]$ таким образом, чтобы выражение $V'C' = 0$ было истинным. Таким образом, мы получаем вычисление матрицы четности, ортогональной C' , следующим образом:

$$V' = \begin{bmatrix} -0.0067 & 0.00175 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (15)$$

Из (15) мы можем легко вывести следующую матрицу избыточности или выражение генератора остаточных значений:

$$\begin{cases} r_1 = -0.0067V_{ds} + 0.00175V_{qs} + q_i \\ r_2 = q_m \end{cases} \quad (16)$$

Уравнение (16) позволяет построить таблицу сигнатур дефектов, представленную в Таблице 1. Последнее означает, что остаточное значение r_1 чувствительно к неисправностям f_{vds} , f_{vqs} и f_{qi} . В то время как r_2 чувствителен к неисправности f_{qm} . Поскольку r_1 чувствителен к неисправностям f_{vds} , f_{vqs} и f_{qi} , и если неисправности возникают одновременно и с разной амплитудой, это может затруднить визуализацию похожих неисправностей или таковых с очень низкой амплитудой. Для обеспечения лучшей идентификации и хорошей локализации похожих неисправностей и/или таковых с очень низкой амплитудой мы рассматриваем автоматическую классификацию (точную и различимую) этих типов неисправностей на основе ANN.

1.5 Краткое описание классификатора неисправностей на основе ANN.

Синтез классификации неисправностей начинается с определения протокола для точного определения местоположения или идентификации неисправностей на основе анализа работы диагностической системы, созданной с использованием подхода статического резервирования. Затем, на основе анализа результатов диагностической системы, мы реализуем и связываем структуру искусственной нейронной сети (ANN) для обеспечения автоматической и структурированной классификации похожих или неразличимых неисправностей и скрытых дефектов.

1.5.1 Принцип формального нейрона

Формальное моделирование нейрона является математическим представлением в виде сумматора порогового значения, множества входов и одного выхода, как показано на рис. 5. Последний сравнивается с биологическим нейроном благодаря двум основным признакам [25]:

$$Z_j(k) = -\theta_j + \sum_{i=1}^n W_{ij}S_i(k) \quad (17)$$

$$S_j(k) = f(Z_j(k)) \quad (18)$$

где $S_i(k)$, $S_j(k)$ и $W_{ij}(k)$ — соответственно i -й вход, выход нейрона и вес связи между нейроном i и нейроном j . Пороговое значение для нейронов.

$f(\cdot)$ - это функция активации нейрона, которая может быть ступенчатой, знаковой, нелинейной и т. д.

Нейронная сеть представляет собой взаимосвязь между нейронами, предназначенную для выполнения функций прогнозирования, моделирования, управления или диагностики и т. д. Кроме того, нейронная сеть в основном имеет разомкнутую или замкнутую структуру.

1.6 Применение искусственной нейронной сети для классификации неразличимых неисправностей в диагностической системе.

На практике пока не существует единого метода определения или выбора нейронной структуры для классификации неисправностей в диагностической системе. Поэтому мы предлагаем качественный метод, основанный на ANN, для оценки, обнаружения и классификации только скрытых неисправностей или тех, что неотличимы от неисправностей, определяемых количественным методом, называемым пространством четности. Для достижения этой цели используемый в данной работе метод обучения нейронной сети осуществляется в три основных этапа:

$Z_j(k)$ — входная функция, а θ_j — смещение или активация.

- этап, предназначенный для сбора обучающих данных;
- этап, касающийся выбора конфигурации и обучения предлагаемой нейронной сети;
- этап, посвященный проверке работоспособности реализованной нейронной сети.

1.6.1 Этап сбора обучающих данных

Для сбора данных, относящихся к характеристикам скрытых или неразличимых неисправностей, мы используем данные, извлеченные из сигналов, идентифицированных на входах и на одном из выходов генератора остаточных значений, полученного на основе модели пространства четности. Затем мы можем собрать четыре выборки по 1278 точек данных на каждом из входов генератора остаточных значений, чтобы сформировать данные для четырех входов предлагаемой ANN. После этого мы также собираем выборку из 1278 данных с выхода генератора остаточных значений для обучающего выхода ANN.

Таблица 1. Таблица сигнатур неисправностей.

	f_{vds}	f_{vqs}	f_{qi}	f_{qm}
r_1	1	1	1	0
r_2	0	0	0	1

1.6.2 Этапы настройки структуры и обучения ANN

Реализация модели неразличимых неисправностей, которую мы используем, основана на контролируемом обучении, определенном в нейронной структуре утилиты Matlab «Neural Network Toolbox» [25,26]. После того, как в утилите мы выбираем вспомогательный инструмент «Fitting

Tool», который позволяет нам взять собранные данные и ввести их в обучающую базу данных для определения структуры ANN, а также ее входных и выходных данных, как показано на рис. 6.

Очевидно, что модель неисправности, реализованная на структуре ANN на рис. 6, имеет четыре входа и один выход, веса и пороги активации нейронов обозначены соответственно (w) и (b). Рис. 6 состоит из 11 нейронов, включая 10 нейронов в первом скрытом слое и 1 нейрон, расположенный в выходном слое структуры. Использование в первом скрытом слое функции активации гиперболического тангенса, изменяющейся в интервале от -1 до 1, направлено на учет и лучшую оценку сильно нелинейного поведения входных величин ANN. Выражение функции активации гиперболического тангенса можно записать следующим образом:

$$f(Z_j(k)) = \frac{1 - e^{-2\beta Z_j(k)}}{1 + e^{-2\beta Z_j(k)}} \quad (19)$$

где $Z_j(k)$ — входная функция нейрона, заданная формулой (17).

$\beta \in \mathbb{R}^*$ — это фактор или параметр для корректировки функции активации f с целью избежать сложности насыщения указанной функции.

Затем сигналы, обрабатываемые в этом первом скрытом слое, могут быть направлены на выходы ANN через функцию активации выходного слоя линейного типа, полиномиальная функция которой может быть записана следующим образом:

$$f(Z(k)) = \sum_{i=0}^n a_i Z^i(k) \quad (20)$$

где $a_i \in \mathbb{R}$ - коэффициенты многочлена степени (i) и $n \in \mathbb{N}$.




Рис. 5. Представление нейронной модели.

Обучение структуры искусственной нейронной сети (ANN) зависит от объема входных и выходных данных, которые мы вносим в ее базу данных. В нашем конкретном случае система делает оптимальный выбор для наших данных, выделяя 70% каждого образца входных и выходных данных для обучения, затем 15% каждого образца для тестирования и оставшиеся 15% образцов для валидации. Эта же система использует алгоритм обратного распространения ошибки Левенберга-Марквардта (LM) для обеспечения регрессии или минимизации нелинейных и/или многомерных функций. Кроме того, обучение на основе LM-модели корректируется в зависимости от ошибки и автоматически останавливается, когда улучшение обобщения прекращается. Таким образом, сходимость или эффективность обучения LM-модели искусственной нейронной сети будет использоваться для обеспечения локализации или классификации скрытых неисправностей или таковых с низкой амплитудой.

1.6.3 Этап валидации реализованной ANN

Метод валидации реализованной ANN основан в основном на интерпретации результатов кривых валидации, обучения и тестирования. Поэтому следует также отметить, что использование тестовых выборок не ухудшает процесс обучения, а помогает измерить производительность ANN. Кроме того, выборки, используемые для валидации, измеряют обобщающую способность сети, и

обучение прерывается, когда эта обобщающая способность перестает улучшаться и неисправность становится неустранимой.

На рисунках 7 и 8 представлены кривые валидации предложенной нейронной структуры после трех фаз обучения, валидации и тестирования. Валидация производительности, показанная на рисунке 7, ясно демонстрирует, что формы кривых валидации, обучения и тестирования хорошо сходятся вокруг наилучшей кривой; следовательно, можно сказать, что реализованная нейронная модель достигает лучших результатов после 1000 повторов со среднеквадратичной ошибкой $3,0532 \cdot 10^{-9}$. Кроме того, кривые на рисунке 8 показывают лучшую регрессию целевых выходных данных ANN, что позволяет получить коэффициент корреляции, почти равный 1, на этапах обучения предложенной структуры.

2. Обсуждение результатов

Оценка и валидация предложенной надежной диагностической системы основаны на представлении LFT и подходе статической избыточности, связанном с ANN. Это позволяет анализировать и интерпретировать результаты генерации остаточных значений, что дает возможность обнаруживать, локализовать и классифицировать неисправности в ветроэнергетической системе на основе DFIG. Параметры моделирования, используемые для DFIG и пропорционально-интегрального регулятора, представлены в таблице A1 в приложении. Все эти исследования проводились с использованием программного обеспечения Matlab/Simulink.




Рис. 6. Структура искусственных нейронных сетей (ANN), разработанных для классификации неисправностей.

2.1 Оценка и интерпретация генератора остаточных значений диагностической системы ветроэнергетики на базе генератора с двойным питанием (DFIG).

Зная, что (16) генератора остаточных значений позволил построить таблицу сигнатур неисправностей, представленную в Таблице 1, последняя будет проанализирована, а затем проверена или подтверждена моделированием в соответствии с принципом таблицы истинности. Для этого мы подвергнем диагностируемую систему различным помехам или шумам, как показано на рис. 9a,b и c, следующим образом:

На рис. 9a представлен белый шум, используемый в качестве помех неопределенности нормированных параметров (δ), который будет подаваться на входы v_i на рис. 3. Белый шум параметризован таким образом, что можно обнаружить все зашумленные сигналы, амплитуды которых меньше порогового значения 0,2 в ограниченной полосе белого шума параметров, рассмотренных на рис. 9a.

На рис. 9b представлен белый шум, используемый в качестве нормированного источника помех неопределенности модели (Δ_1), который будет подаваться на входной уровень V_{wm} на рис. 3. Белый шум параметризован таким образом, что можно обнаружить все зашумленные сигналы, амплитуда которых больше или равна 0,5 в ограниченной полосе белого шума модели на рис. 9b.

На рис. 9c в качестве помех рассматривается внезапное изменение заданного значения от 0 до 600В в момент времени $t = 10$ секунд, которое будет подаваться на входной уровень ω , показанный на рис. 3, где 600В представляет номинальное напряжение DFIG, рассмотренное в таблице A1 в приложении.

Очевидно, что проверка предложенной надежной диагностической системы заключается в подтверждении путем моделирования чувствительности и нечувствительности генератора остаточных значений к наличию помех и/или шума. Поскольку мы рассматриваем три типа помех на рис. 9, мы получаем восемь возможных этапов проверки таблицы сигнатур в таблице 2. На первом этапе предполагается, что контролируемая система не подвержена никаким помехам и шуму, следовательно, остаточные значения r_1 и r_2 не проявляют никакой чувствительности к неисправности, поэтому неисправность не обнаруживается на f_{vds} , f_{vqs} , f_{qi} и f_{qm} .




Рис. 7. Кривые производительности структуры ANN.




Рис. 8. Кривые регрессии целевых выходных значений реализованной структуры ANN.

Со второго по четвертый этап контролируемая система подвергается воздействию только одного типа помех или шума за раз. Результаты работы генератора остаточных значений для помех заданного значения, для шума параметров и для шума модели представлены на рис. 10-12 соответственно. Таким образом, рис. 10а, рис. 11а и рис. 12а наглядно показывают, что остаточное значение r_1 чувствительно соответственно к помехам заданного значения, к шуму параметров и к шуму модели. Следовательно, мы также отмечаем, что чувствительность остаточного значения r_1 на рис. 10а, рис. 11а и рис. 12а определяется через неисправности f_{vds} , f_{vqs} и f_{qi} соответственно на рис. 10b,c,d, рис. 11b,c,d и рис. 12b,c,d. В то же время, в отличие от остаточного значения r_2 на рис. 10е и рис. 11е, остаточное значение r_2 на рис. 12е чувствительно только к белому модельному шуму, что

соответственно отражает невозможность обнаружить неисправности f_{qm} на рис. 10f и рис. 11f и распознаваемость неисправности f_{qm} на рис. 12f.

На пятом этапе контролируемая система получает как помехи заданного значения, так и белый параметрический шум, чтобы получить результаты моделирования, представленные на рис. 13. Выясняется, что остаточное значение r_1 на рис. 13a полностью чувствительно к помехам заданного значения, которое немедленно обнаруживается неисправностями f_{vds} , f_{vqs} и f_{qi} соответственно на рис. 13b, 13c и 13d. В то время как на рис. 13e остаточное значение r_2 не чувствительно к помехам заданного значения и параметрическому шуму, поэтому неисправность f_{qm} на рис. 13f ничего не обнаруживает. Кроме того, этот пятый вариант моделирования также создает задачу обнаружения шума параметров, который действительно присутствует, но мы не видим его на r_1 или r_2 . Этот конкретный случай будет учтен и обработан в рассматриваемом протоколе классификации неисправностей, чтобы избежать неправильной диагностики в реальных условиях эксплуатации.




Рис. 9. Представления параметра белого шума (7a), модели белого шума (7b) и внезапных помех заданного значения (7c).

На шестом этапе контролируемая система получает как помехи заданного значения, так и шум модели, чтобы получить результаты моделирования, представленные на рис. 14. Выясняется, что остаточное значение r_1 на рис. 14a чувствительно только к помехам заданного значения и непосредственно обнаруживается неисправностями f_{vds} , f_{vqs} и f_{qi} соответственно на рис. 14b, 14c и 14d. Кроме того, остаточное значение r_2 на рис. 12e также чувствительно только к шуму модели и непосредственно обнаруживается неисправностью f_{qm} на рис. 14f. Очевидно, что на шестом этапе обнаружение помех заданного значения с помощью r_1 и обнаружение шума модели с помощью r_2 практически не сопряжено с недостатками. Однако, если возникает проблема насыщения датчика, важно знать, что r_1 будет подвергаться влиянию шума модели в дополнение к сильному влиянию помех заданного значения, которое может маскировать этот шум модели.

На седьмом этапе система, подлежащая мониторингу, подвергается воздействию как параметрического шума, так и шума модели, чтобы получить результаты моделирования, представленные на рис. 15. Оказывается, что остаточное значение r_1 на рис. 15a полностью чувствительно к шуму модели и очень слабо чувствительно к параметрическому шуму, что непосредственно обнаруживается неисправностями f_{vds} , f_{vqs} and f_{qi} соответственно на рис. 15b, c и d. В то время как остаточное значение r_2 на рис. 15e остается чувствительным только к шуму модели и непосредственно обнаруживается неисправностью f_{qm} на рис. 15f. Однако этот 7-й вариант

моделирования создает задачу неоднозначного одновременного обнаружения параметрического и модельного шума на r_1 ; этот случай будет учтен и решен в рассматриваемом протоколе классификации неисправностей. На восьмом этапе контролируемая система получает как помехи заданного значения, так и шум модели и шум параметров; однако в варианте моделирования пятого этапа, как показано на рис. 14, мы видим явные признаки неисправности. Кроме того, восьмой вариант моделирования по-прежнему создает сокрытие неисправности и неоднозначное обнаружение шума. Следовательно, этот вариант будет учтен в предусмотренном протоколе классификации неисправностей.

Таблица 2. Классификация ветровых разломов на основе DFIG.

System Status	r1 V_{ds}, V_{qs}, q_i	r2 q_m	FLDS	FLPU	FLMU	Decision
No Flaw (0)	0	0	0	0	0	No Action 1
Default (1)	1	0	1	0	0	Action 2
Default	1	0	0	1	0	Action 3
Default	1	1	0	0	1	Action 4
Default	1	0	1	1	0	Action 5
Default	1	1	1	0	1	Action 6
Default	1	1	0	1	1	Action 7
Default	1	1	1	1	1	Action 8

В целом, результаты моделирования, полученные на предыдущих восьми этапах, подтверждают точность таблицы сигнатур неисправностей в Таблице 1, полученной на основе предложенного надежного диагностического подхода, поскольку все чувствительности и/или нечувствительности r_1 были обнаружены или наблюдались в неисправностях f_{vds} , f_{vqs} и f_{qi} . То же самое справедливо, когда чувствительность и/или нечувствительность r_2 обнаруживаются или наблюдаются на неисправности f_{qm} . Кроме того, преимущество, которое можно получить от этой проверки таблицы сигнатур, заключается в том, что она предоставляет диагностической системе возможность обнаружения и локализации неисправного датчика, поскольку мы четко видим проявление неисправности r_1 одновременно на трех датчиках V_{ds} , V_{qs} и V_{qi} .




Рис. 10. r_1 чувствителен к помехам заданного значения (a), f_{vds} обнаруживает r_1 (b), f_{vqs} обнаруживает r_1 (c), f_{qi} обнаруживает r_1 (d), r_2 нечувствителен к помехам заданного значения (e), f_{qm} наблюдает r_2 (f).




Рис. 11. r_1 чувствителен к белому шуму параметра (a), f_{vds} обнаруживает r_1 (b), f_{vqs} обнаруживает r_1 (c), f_{qi} обнаруживает r_1 (d), r_2 нечувствителен к белому шуму параметра (e), f_{qm} наблюдает r_2 (f).

2.2 Классификация неисправностей для диагностики ветроэнергетической системы на основе DFIG

В целом, в ветроэнергетической системе на базе двухфазного асинхронного генератора (DFIG) можно выделить три основных типа неисправностей: неисправности, связанные с помехами заданного значения (FLDS), неисправности, связанные с неопределенностями модели (FLMU), и неисправности, связанные с неопределенностями параметров (FLPU). Кроме того, причины или источники неисправностей в ветроэнергетической системе разнообразны. Однако ниже перечислены основные вероятные причины неисправностей типа FLDS:

- резкие и внезапные колебания скорости ветра у ветряной турбины;
- ошибки в контроле и настройке заданного значения;
- снижение производительности или эффективности турбины;
- нетипичные колебания электрического заряда и т. д.

Кроме того, основные вероятные причины возникновения FLMU:

- ошибки моделирования;
- ухудшение показателей, вызванное «старением» ветроэнергетической системы;
- производственные аномалии;
- ошибки, допущенные при техническом обслуживании или установке (ненадлежащая замена запасных частей и т. д.);

Основными источниками FLPU являются:

- сбой в работе комплексной электросети;




Рис. 12. r_1 чувствителен к белому шуму модели (a), f_{vds} обнаруживает r_1 (b), f_{vqs} обнаруживает r_1 (c), f_{qi} обнаруживает r_1 (d), r_2 чувствителен к белому шуму модели (e), f_{qm} наблюдает r_2 (f).




Рис. 13. r_1 чувствителен к помехам заданного значения (a), f_{vds} обнаруживает r_1 (b), f_{vqs} обнаруживает r_1 (c), f_{qi} обнаруживает r_1 (d), r_2 нечувствителен к помехам заданного значения и белому шуму параметра (e), f_{qm} наблюдает r_2 (f).

- сбои в работе статических преобразователей силовой электроники;

- ошибка управления;

- аномальное повышение температуры в машине;

- проблемы магнитной индукции между ротором и статором и т.д.

На практике, когда одновременно возникает несколько неисправностей различной амплитуды, диагностируемая система сталкивается с двумя типами задач, связанных с обнаружением и точной локализацией указанных неисправностей, а именно:




Рис. 14. r_1 чувствителен к помехам заданного значения (a), f_{vds} обнаруживает r_1 (b), f_{vqs} обнаруживает r_1 (c), f_{qi} обнаруживает r_1 (d), r_2 чувствителен к белому шуму модели (e), f_{qm} наблюдает r_2 (f).




Рис. 15. r_1 чувствителен к белому шуму модели и слегка чувствителен к шуму параметров (a), f_{vds} обнаруживает r_1 (b), f_{vqs} обнаруживает r_1 (c), f_{qi} обнаруживает r_1 (d), r_2 чувствителен к белому шуму модели (e), f_{qm} наблюдает r_2 (f).

Первый тип задач возникает, когда обнаружение неисправностей с высокой амплитудой препятствует их визуализации с очень низкой амплитудой; именно такие этапы наблюдаются в случаях, показанных на рис. 13abcd, 14abcd, 15abcd и на восьмом этапе.

Второй тип задач, связанных с неоднозначными состояниями, возникает, когда обнаружение неисправностей с относительно одинаковой амплитудой визуализируется одновременно на разных датчиках незаметным образом; это можно наблюдать в случаях, показанных на рис. 15abcd.

Для обеспечения эффективных и комплексных решений задач обнаружения и точного определения местоположения неисправностей мы использовали результаты испытаний и последовательных проверок, представленные в шагах раздела 4.1. Соответственно, в таблице 2 мы предлагаем классификацию неисправностей ветроэнергетических систем на основе DFIG. Последняя описывается следующим образом:

В первом столбце указано состояние системы, подлежащей мониторингу, в зависимости от того, находится ли она в исправном состоянии или в состоянии, в котором присутствует неисправность;

Вторая и третья колонки посвящены различным возможным состояниям, таким как чувствительная или нечувствительная неисправность остаточных значений r_1 и r_2 , связанных соответственно с измерениями сенсора (V_{ds} , V_{qs} , q_i) и (q_m);

В столбцах с четвертого по шестой указаны возможные состояния системы при наличии или отсутствии FLDS, FLPU и/или FLMU.

В последнем столбце представлены решения о действиях, которые необходимо предпринять в случае невыполнения условий.

Результаты на рис. 10-14, соответствующие состояниям системы, связанным с действиями 2, 3, 4 и 6 в таблице 2, наглядно показывают, что обнаружение, идентификация или точная локализация неисправностей не представляют собой относительно больших сложностей. Тем не менее, мы сосредоточимся на задачах обнаружения и локализации мелких неисправностей в случаях, показанных на рис. 13-15, соответствующих состояниям системы, связанным с действиями 5, 6, 7 и 8 в таблице 2. Для этого мы будем использовать данные измеренных выходных сигналов системы, подлежащей мониторингу, для реализации классификации, связанной с ANN, чтобы решить задачи, связанные с затенением и неоднозначностью обнаружения некоторых неисправностей, указанных в действиях 5, 6, 7 и 8 в таблице 2. В частности, основная роль предлагаемого классификатора на основе ANN заключается в том, чтобы выделить только один датчик для наблюдения, обнаружения или локализации тембра или сигнатуры неисправности очень низкой амплитуды в случаях действий 5, 6, 7 и 8 в таблице 2. Дело в том, что классификатор на основе ANN использует в качестве входных данных измерения датчиков V_{ds} , V_{qs} , q_i и q_m и выдает сигнатуру или остаточное значение r_3 искомой неисправности низкой амплитуды, так что она одновременно различима, обнаруживается и локализуется, как и остаточные значения r_1 и r_2 . Результаты сигнатур или остаточных значений неисправностей, полученные в случаях действий 8, 7, 6 и 5 в таблице 2, соответственно представлены и проверены на рисунках 16-19. Как видно, рисунки 16a, 16b и 16c четко иллюстрируют остаточные значения r_1 для DLPC, r_2 для DLIM и r_3 для DLIP в случае действия 8 из Таблицы 2. Очевидно, что для получения r_3 выход нейронного датчика должен выдавать остаточное значение r_3 , соответствующий наличию неисправностей DLPC и DLIM, в то время как диагностическая система будет наблюдать остаточные значения r_1 и r_2 , соответствующие наличию всех неисправностей (DLPC, DLIM и DLIP). Классификатор на основе ANN выдаст r_3 для самой низкой неисправности на рис. 16с, выполнив следующие действия сложения и вычитания матриц:




Рис. 16. r_1 чувствителен к шуму модели и параметров (а), r_2 чувствителен к белому шуму модели (b) и r_3 чувствителен к белому шуму параметров (с).




Рис. 17. r_1 чувствителен к помехам заданного значения (а), r_2 чувствителен к белому шуму модели (b) и r_3 чувствителен к белому шуму параметров (с).

$$r_3 = (r_1 + r_2) - r'_3 \quad (21)$$

Когда в системе произойдет состояние действия 7 в Таблице 2, классификатор повторяет (21), с r_1 и r_2 для DLIM и DLIP соответственно, и r_3 для (DLIM), чтобы получить сигнатуру r_3 DLIP на рис. 17с, наряду с остаточными значениями r_1 , r_2 соответственно на рис. 17а и б.




Рис. 18. r_1 чувствителен к помехам заданного значения (а), r_2 чувствителен к моделирующему белому шуму (б) и r_3 нечувствителен к помехам заданного значения и моделирующему белому шуму (с).




Рис. 19. r_1 чувствителен к помехам заданного значения (а), r_2 нечувствителен к помехам заданного значения и белому шуму параметра (б), а r_3 чувствителен к белому шуму параметра (с).

Затем, когда в контролируемой системе произойдет состояние действия 6 из Таблицы 2, классификация повторяет операцию (21) с r_1 , r_2 и r_3 в присутствии DLPC и DLIM соответственно, чтобы получить нулевую сигнатуру r_3 (отсутствие DLIP) на рис. 18с, наряду с остаточными значениями r_1 , r_2 соответственно на рис. 18а и 18б. Наконец, когда в контролируемой системе произойдет состояние действия 5 из Таблицы 2, классификация повторяет операцию (21) с r_1 и r_2 в присутствии DLPC и DLIP, и r_3 в присутствии DLPC, чтобы получить ненулевую сигнатуру r_3 (наличие DLIP) на рис. 19с, наряду с остаточными значениями r_1 , r_2 на рис. 19а и 19б соответственно. В целом, благодаря сопоставлению ANN со статической моделью избыточности, были подтверждены все вероятные состояния классификации действий с 1 по 8 в таблице 2, чтобы прояснить любую неоднозначность, связанную с затенением и/или неоднозначными состояниями неисправностей в устойчивой диагностической системе, предложенной для ветротурбин.

3. Заключение

Эффективная, действенная и устойчивая интеграция ветровой энергии в электрическую сеть в корне обусловлена разработкой оптимальных систем управления и устойчивых стратегий диагностики. Поэтому мы предложили новую надежную систему диагностики, основанную на представлении линейного дробного преобразования (LFT) в сочетании со статическим резервированием, для проектирования генератора остаточного напряжения, позволяющего обнаруживать и локализовать неисправности в ветроэнергетических системах на основе генераторов с двойным питанием (DFIG). Более того, зная, что неисправности в ветроэнергетической системе имеют различное происхождение, мы можем тем не менее сгруппировать их в три типа, а именно: неисправности, связанные с помехами заданного значения (FLSD или DLPC), неисправности, связанные с неопределенностями моделей (DLIM или FLMU), и неисправности, связанные с неопределенностями параметров (DLIP или FLPU). Поэтому, на основе результатов генератора остаточных ошибок, было предложено связать искусственную нейронную сеть с классификацией, чтобы обеспечить обнаружение и локализацию скрытых и/или неоднозначных неисправностей. Выясняется, что предложенная устойчивая диагностическая система для оптимальной интеграции ветротурбин в сеть предлагает очень хороший компромисс с точки зрения снижения сложности, экономической рентабельности, эксплуатационной безопасности, эффективности, надежности и долговечности ветроустановок. Очевидно, что предложенная диагностика позволяет: использовать меньшее количество датчиков; обнаруживать, локализовать и классифицировать неисправности ветроэнергетической системы на основе DFIG; а также обнаруживать и локализовать неисправный датчик; эффективно решать задачи, связанные со скрытой и/или неоднозначной идентификацией неисправностей. В перспективе мы предполагаем экспериментальную реализацию предложенной в данной статье устойчивой диагностической системы.

О вкладе авторов в проект CRediT

Боаз Вадава: написание — первоначальный вариант, проверка достоверности, ресурсы, методология, формальный анализ, концептуализация. **Жозеф Ив Эффа:** проверка достоверности, научное руководство, методология, формальный анализ.

О конфликте интересов

Авторы заявляют, что у них нет известных конкурирующих финансовых интересов или личных связей, которые могли бы повлиять на результаты работы, представленной в данной статье.

Приложение А

Table A1 DFIG and PI controller simulation parameters [25].

Models DFIG		PI
Parameters	$U_s = 600 \text{ V/F} = 50 \text{ Hz}$	$K_p = 0.19891$
	$R_s = 1.69 \text{ m}\Omega$	$K_i = 3.05$
	$L_s = 2.95 \text{ mH}$	$\tau/\text{ms} = 0.5$
	$R_r = 1.52 \text{ m}\Omega$	
	$L_r = 2.97 \text{ mH/L}_m/\text{M} = 2.91 \text{ mH}$	

Список используемой литературы

[1] Б. Вадава, Й. Эррами, А. Оббади и др., Обеспечение надёжности H-контроллера в сочетании с нечеткой логикой и ПИ&ПИД-ФД для гибридного управления системой преобразования энергии ветра, подключенной к электросети на основе DFIG, Energy Rep.7 (2021) 7539-7571.

- [2] А.М. Грачик, Устойчивая энергетика — определения, сфера применения и области. Управление превосходством в образовании и инновациями. Доступно онлайн: <https://wir.ue.wroc.pl/info/article/WUT21b73bdb14d94a35a6ffb2c986f6fdcf/>.
- [3] Ц. Чен, Л. Ван, С.З. Се и др., Многомерные методы оценки и диагностики производительности ветротурбин на основе различных влияющих факторов, *IET Renew.Power Gener.* 18 (2024) 4249-4264.
- [4] Х. Шао, Р. Энрикес, Х. Мораис и др., Мониторинг качества электроэнергии в электросети с использованием морской ветроэнергетики: обзор, *Renew.Sustain.Energy Rev.*191 (2024) 114094.
- [5] Бебарс А.Д., А.А. Эладль, Г.М. Абдулсалам и др., Методы обнаружения внутренних электрических неисправностей в ветротурбинах на базе DFIG: обзор, *Prot.Control Mod.Power Syst.*7(1)(2022)18.
- [6] М.А. Яхиауи, М. Киннаерт, Дж. Гиселинк, Диагностика обрывов цепи и неисправностей датчиков в ветротурбинах DFIG на основе дополненного наблюдателя состояния, *IEEE Trans.Power Electron.* 38 (12) (2023) 16085-16099.
- [7] Ю. Саяхи, М. Аллуш, М. Гамги и др., Вклад в диагностику неисправностей датчиков ветротурбины с переменной скоростью: мультимодельный подход, в: Труды 11-й Международной конференции IEEE по системам и управлению (ICSC), IEEE, Сусс, Тунис, 2023, стр. 427-432.
- [8] В. Динг, Ю. Л. Цзинь, С. Дж. Ву и др., Диагностика высокоомных соединений двухфазных асинхронных генераторов, *Energies* 16 (22)(2023) 7516.
- [9] И. Идрисси, Р. Эль Бахтири, Х. Шафук, Банк фильтров Калмана для обнаружения и локализации неисправностей датчиков тока двухфазного асинхронного генератора для ветряной турбины, в: Труды Международной конференции по возобновляемой и устойчивой энергетике (IRSEC) 2017 года, IEEE, Танжер, Марокко, 2017, стр. 1-6.
- [10] И.Айсауи, Н.Эльмуи, А.Эсадки и др., Отказоустойчивое управление ветровой турбиной DFIG, управляемой ADRC и оптимизированной генетическим алгоритмом, *Int.J.Power Electron.Drive Syst.(IJPEDS)*14(3) (2023) 1382.
- [11] Х. Буазза, М. Л. Бендаас, Т. Аллауи и др., Применение искусственного интеллекта к ветроэнергетике: моделирование, управление и обнаружение неисправностей, *Int.J.Intell.Syst.Technol.Appl.* 19(3)(2020) 280.
- [12] Н. Лабед, И. Аттуи, С. Махлуфи и др., PSO-контроллер дробного порядка и алгоритм ANFIS для управления и диагностики ветротурбинных систем, *J.Electric.Eng.Technol.* 18(3)(2023) 2457-2468.
- [13] Э.Дж.Перес-Перес, В.Пуч, Ф.Р.Лопес-Эстрада и др., Обнаружение и локализация неисправностей в ветротурбинах на основе нейро-нечетких зонотопических наблюдателей qLPV, *Mech.Syst.Sig.Process.*191 (2023)110183.
- [14] Э.Дж.Перес-Перес, В.Пуч, Ф.Р.Лопес-Эстрада и др., Надежная диагностика неисправностей ветротурбин на основе MANFIS и зонотопических наблюдателей, *Expert Syst.Appl.*235 (2024) 121095.
- [15] Э.Дж.Перес-Перес, Д.Э.Лопес-Эстрада, В.Пуч и др., Диагностика неисправностей ветротурбин на основе ANFIS и интервальных наблюдателей Такаги-Сугено, *Expert Syst.Appl.*206 (2022) 117698.
- [16] С. Бишвас, Б.К. Паниграхи, П.К. Наяк и др., Улучшенная схема защиты с использованием однополюсного фильтра для компенсированной TCSC линии электропередачи, соединяющей крупные ветровые электростанции, *IEEEJ.Emerg.Selected Topics Ind.Electron.*5 (2) (2024) 346-358.

- [17] С. Бишвас, П.К. Наяк, Б.К. Паниграхи и др., Интеллектуальная методика обнаружения и классификации неисправностей на основе вариационного разложения на моды - CNN для линий электропередачи, установленных с UPFC и ветряной электростанцией, *Electr.Pow.Syst.Res.*223 (2023) 109526.
- [18] С. Бишвас, П.К. Наяк, Новый подход к защите компенсированных линий электропередачи TCSC, подключенных к ветряной электростанции на базе DFIG, *IEEETrans.Ind.Inf.*17 (8)(2020) 5282-5291.
- [19] С. Бишвас, П. К. Наяк, Г. Прадхан, Схема интеллектуальной релейной защиты с использованием двухвременного преобразования для линии электропередачи с компенсацией STATCOM, соединяющей ветропарк, *IEEE Syst.J.*16 (2) (2021) 2160-2171.
- [20] М. Назих, Обнаружение и локализация ошибок в статических преобразователях, в: Труды 6-й Международной конференции по электромеханическим и энергетическим системам, 2007, стр. 313-318.
- [21] В.Пуч, С.Симани, «Отказоустойчивая диагностика и управление 1: Методы и приемы диагностики на основе данных». ISTE Group, 2024. Доступно в Интернете. https://www.istegroup.com/wp-content/uploads/2019/11/058_Diagnostic-et-commande-atolerance-de-fautes-1_introduction.pdf.
- [22] Й.Дж.Парк, С.С.Фан, CYHsu, Обзор по обнаружению неисправностей и диагностике процессов в промышленных процессах, *Процессы* 8 (9) (2020) 1123.
- [23] З.Х.Ван, Ю.Шен, Диагностика неисправностей на основе моделей: методы для систем в пространстве состояний, Springer Nature, 2022.
- [24] В. Хван, К. Хан, К. Хух, Обнаружение и диагностика неисправностей электромеханического тормоза на основе наблюдателя и пространства четности, *Int.J.Automot.Technol.*13 (5) (2012) 845-851.
- [25] Б.Вадава, Й.Эррами, А.Оббади и др., Моделирование и сравнительное применение нечеткой логики и искусственных нейронных сетей в системном управлении ветряной турбиной с использованием DFIG, в: Последние достижения в теории нечетких множеств, дробном исчислении, динамических системах и оптимизации, Springer International Publishing, Cham, 2023, стр. 112-137.
- [26] А.Ядав, Й.Даш, Обзор защиты линий электропередачи с помощью искусственной нейронной сети: обнаружение неисправностей, классификация неисправностей, определение местоположения неисправности и определение направления неисправности, *Adv.Artif.Neural Syst.*1 (2014) 230382.

Получено 24 октября 2024 г.; отредактировано 10 апреля 2025 г.; принято 20 апреля 2025 г.

Экспертная оценка проводится под руководством компании Global Energy Interconnection Group Co.Ltd.

*** Ответственный автор**

Адреса электронных почт: booz_wadawa@yahoo.fr (Б. Вадава), effa.jol@yahoo.fr (Ж.И.Эффа).

Эта статья переведена из журнала <Global Energy Interconnection> (ISSN: 2096-5117), выпуск 4, 2025 г. Оригинальное название статьи:< New strategy for fault detection and classification in wind turbines

based on doubly-fed induction generators>. Перевод предоставляется исключительно для справки; преимущественную силу имеет оригинал: <https://doi.org/10.1016/j.gloi.2025.04.004>

2096-5117/© 2025 Global Energy Interconnection Group Co.Ltd. Издательские услуги предоставлены Elsevier B.V. от имени KeAi Communications Co.Ltd. Данная статья находится в открытом доступе и распространяется по лицензии CC BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).



Боаз Вадава имеет степень доктора наук (PhD) по специальности «Электротехника, автоматизация и возобновляемые источники энергии», полученную в Университете Шуаиба Дуккали в Эль-Джадиде, Марокко. Также он имеет степень магистра электротехники и автоматической электроники, полученную в Университете Нгаундере, Камерун. Автор книг, глав в книгах и научных статей высокого уровня, он является рецензентом в нескольких престижных международных журналах. Он обладает обширным опытом в областях теплотехники, энергетики, роботизации, искусственного интеллекта и телекоммуникаций.