

Сенюк М.Д., Дмитриева А.А.

Уральский федеральный университет имени первого Президента России Б.Н. Ельцина, Екатеринбург

РАЗРАБОТКА МЕТОДА ОЦЕНКИ ДИНАМИЧЕСКОЙ УСТОЙЧИВОСТИ ЭНЕРГОСИСТЕМ НА ОСНОВЕ ПРИМЕНЕНИЯ ТЕОРИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА С УЧЁТОМ ТОПОЛОГИЧЕСКОЙ СВЯЗАННОСТИ СЕТИ

Развитие современных электроэнергетических систем связано с цифровизацией и увеличением потока данных от объектов электроэнергетики к центрам управления. С другой стороны, увеличение доли возобновляемых источников энергии приводит к увеличению неопределенности электрических режимов и снижению суммарной инерции, что накладывает новые требования к быстродействию процедуры оценки динамической устойчивости и противоаварийного управления. Применение традиционных детерминированных алгоритмов к анализу динамической устойчивости энергосистем в условиях ужесточающихся требований к быстродействию могут оказаться неэффективными. Для преодоления недостатков традиционных методов оценки динамической устойчивости энергосистем могут быть использованы методы искусственного интеллекта. Данный класс методов обладает значительным быстродействием обученных моделей и возможностью поиска закономерностей в данных, что делает его эффективным в условиях современных энергосистем. В работе представлены результаты разработки метода оценки динамической устойчивости энергосистемы на основе методов искусственного интеллекта с учетом топологической связанности электрической сети. Методика основана на применении алгоритма градиентного бустинга деревьев решений. Численное моделирование выполнено на модели IEEE39, реализованной в Matlab/Simulink, для реализации алгоритмов машинного обучения использована библиотека Scikit-learn языка программирования Python3. Для обучения алгоритма машинного обучения использовались углы нагрузок синхронных генераторов, уровни напряжения в узлах подключения синхронных генераторов к электрической сети, топология электрической сети, продолжительность и сопротивление короткого замыкания. В результате применения обученного алгоритма с учетом топологии электрической сети на тестовой выборке была получена точность в 91,5%. Точность работы на тестовой выборке без учета топологической связанности элементов энергосистемы составила 81,6%.

Ключевые слова: динамическая устойчивость, искусственный интеллект, машинное обучение, математическое моделирование

ВВЕДЕНИЕ

Использование алгоритмов искусственного интеллекта (ИИ) для решения задач проектирования, эксплуатации и управления электроэнергетическими системами (ЭЭС) стало возможным благодаря цифровизации отрасли и накоплению достаточных объемов данных. На сегодняшний день алгоритмы ИИ находят для решения следующего спектра научных задач:

1. Оценка технического состояния оборудования [1].
2. Прогнозирование электропотребления [2].
3. Прогнозирование выработки мощности возобновляемых источников электроэнергии (ВИЭ) [3].
4. Настройка устройств управления режимом ЭЭС [4].
5. Оценивание состояния [5].
6. Идентификация возмущения в ЭЭС [6].

Однако на сегодняшний день при эксплуатации и управлении ЭЭС отдаётся предпочтение традиционным методам, в основе которых лежат детерминированные методы. С другой стороны, развитие методов ИИ с точки зрения быстродействия, точности и масштабируемости способно предоставить качественно новый инструмент для анализа и управления электроэнергетическими режимами. Кроме того, активное внедрение синхронизированных векторных измерений (СВИ) [7] существенно увеличит поток информации от объектов электроэнергетики к центрам управления, что способствует увеличению времени работы традиционных подходов [8] к анализу электрических режимов.

В условиях цифровизации, увеличения потока данных в центры управления, а также возможных ограничений быстродействия традиционных алгоритмов анализа и управления режимами ЭЭС методы ИИ могут предоставить новые инструменты и возможности. В частности, одним из возможных применений методов ИИ является оценка динамической устойчивости (ДУ) ЭЭС. Традиционными подходами к решению данной задачи являются:

1. Численное игнорирование дифференциально-алгебраической системы уравнений, описывающей динамическую модель ЭЭС.
2. Применение качественного метода анализа полной энергии ЭЭС (правило площадей) [9].

Данные подходы обладают недостатками, связанными со значительными временными затратами, необходимыми для численного дифференцирования математических моделей ЭЭС высокой размерности, и возможным снижением точности анализа ДУ качественным методом. Для преодоления недостатков традиционных подходов к оценке ДУ ЭЭС возможно применение методов ИИ, позволяющих значительно сократить время решения задачи при обеспечении заданной точности.

Целью данной статьи является разработка метода оценки ДУ ЭЭС на основе методов ИИ с учетом топологической связанности электрической сети.

ОБЗОР ЛИТЕРАТУРЫ

В качестве исходных данных для задачи оценки ДУ ЭЭС могут применяться измерения, получаемые с трансформаторов тока (ТТ) и напряжения (ТН),

установленных на объектах электроэнергетики, и измерения, получаемые в ходе численного моделирования процессов, протекающих в имитационной модели исследуемого фрагмента электрической сети. Рассмотренные выше источники информации о состоянии ЭЭС имеют определённые достоинства и недостатки. Данные, поступающие с измерительных систем, обладают лучшей репрезентативностью фактического электрического режима ЭЭС с учётом влияния различных систем управления с их фактическими настройками. Цифровое моделирование ЭЭС позволяет рассмотреть совокупность электрических режимов, необходимых для противоаварийного и режимного управления. Оба вида исходных данных активно используются для формирования обучающих и тестовых выборок при решении задачи оценки ДУ на основе алгоритмов искусственного интеллекта (ИИ).

С точки зрения теории искусственного интеллекта, задача оценки ДУ может быть приведена к задаче бинарной классификации [10] с двумя классами: потеря ДУ и сохранение ДУ. Так как явление потери ДУ является на порядок более редким событием по сравнению с сохранением ДУ, то данные в выборках становятся несбалансированными, что имеет значительное влияние на процесс обучения и использование модели ИИ. В данных обучающей и тестовой выборок могут присутствовать шумы, выбросы и пропуски.

Важным этапом формирования обучающей и тестовой выборок является определение значимых признаков, оказывающих влияние на состояние класса (потеря ДУ или сохранение ДУ). В качестве признаков для задачи оценки ДУ могут применяться различные сигналы параметров электрического режима во временной области: скорость вращения ротора синхронного генератора (СГ), угол нагрузки, активная и реактивная мощности и т.д.

Также могут учитываться признаки в частотной области. Многие традиционные методы ИИ не рассчитаны на работу с сигналами во временной области. Для преодоления данной проблемы используется выделение из временной области двух характерных точек – до и после возмущения. Данная процедура уменьшает временной ряд до двух точек [11], что снижает общую размерность решаемой задачи и увеличивает скорость обучения и использования выбранной модели ИИ. Дальнейшее уменьшение размерности задачи может быть выполнено за счёт применения метода анализа главных компонент [12], разложения по сингулярным составляющим или линейного дискриминантного анализа. В исследовании [13] предложен метод для случайного перебора признаков с целью минимизации времени обучения выбранного алгоритма ИИ.

Общая схема подготовки данных выборки для обучения и тестирования алгоритма оценки ДУ на основе ИИ приведена на **рис. 1**.

Данные, полученные путём математического моделирования или с устройств регистрации параметров электрического режима работы реальной ЭЭС, содержат значительное число временных рядов, описывающих установившиеся или переходные процессы. Такая информация обозначена на **рис. 1** в качестве исходных данных.



Рис. 1. Процесс формирования обучающей и тестовой выборок для оценки ДУ

Первый этап обработки данных состоит в устранении шумов, выбросов и пропусков за счёт применения процедуры статистического анализа. Следующий этап заключается в разбиении всего объёма данных на тестовую и обучающую выборки. Далее выполняется центрирование и масштабирование данных. Заключительный этап подготовки данных связан с проверкой значимости признаков с помощью корреляционного анализа. Так как потеря ДУ является довольно редким событием в современных ЭЭС, то важной задачей при использовании алгоритма ИИ для анализа ДУ является подготовка синтетического набора данных за счёт проведения серии расчётов электромеханических переходных процессов на моделях ЭЭС. Серия расчетов выполняется при варьировании уровней нагрузок и генераций в узлах ЭЭС, а также мест, типов и длительности коротких замыканий (КЗ) [14]. Из полученных результатов выполняется выбор следующих данных: 10% – трёхфазные КЗ, 20% – двухфазные КЗ и 70% – однофазные КЗ [15]. Чаще всего в процессе моделирования может быть получена несбалансированная выборка с превалированием режимов с сохранением ДУ. В рамках разделения выборки на обучающую и тестовую выполняется стратифицированное случайное разделение с обеспечением сбалансированности данных.

Задача оценки ДУ ЭЭС может быть решена за счёт применения традиционных алгоритмов ИИ:

1. Метод опорных векторов.
2. Случайный лес.
3. Градиентный бустинг (ГБ).
4. Многослойный персептрон.
5. Ансамблевые алгоритмы.
6. Алгоритмы глубокого обучения.
7. Алгоритмы обучения с подкреплением.

На сегодняшний день наиболее распространённым алгоритмом, используемым для оценки ДУ ЭЭС, является метод опорных векторов [16, 17]. В работе [18] были использованы модернизированные версии метода опорных векторов.

Алгоритм случайного леса (Random Forest) основан на использовании совокупности элементарных алгоритмов классификации, называемых деревьями

решений. Результат классификации каждого отдельного дерева берётся с заранее определённым в процессе обучения весом. Использование алгоритма случайного леса в задачах оценки ДУ описано в работах [19-21].

Другие алгоритмы ИИ также находят применение для оценки ДУ. В работе [22] был использован ГБ, авторы исследования [23] использовали ядерную регрессию, исследование [24] посвящено разработке алгоритма оценки ДУ на основе байесовского классификатора.

Ансамблевый алгоритм представляет собой совокупность элементарных (базовых) алгоритмов, общее решение алгоритма получается путём анализа решений каждого из базовых подалгоритмов. В ансамблевых алгоритмах выделяют следующие подмножества: алгоритмы бэггинга (bagging), бустинга (boosting) и стекирование. Алгоритмы бэггинга и бустинга используют результаты базовых алгоритмов, работающих независимо, а в алгоритме стекирования применяется модель второго уровня, которая обучается на данных базовых моделей. Ансамблевые алгоритмы нашли широкое применение в работах, направленных на оценку ДУ за счёт применения ИИ [25-27].

Глубокое обучение основано на разработке искусственных нейронных сетей (ИНС) с множеством слоёв различного типа. Основная сложность при использовании глубокого обучения связана с инициализацией слоёв, выбором функции активации, определением оптимальной скорости обучения и т.д. Использование глубокого обучения для оценки ДУ не предполагает решение задачи выбора признаков в отличие от других алгоритмов ИИ. В работах [28-30] для оценки ДУ ЭЭС предлагается использование ИНС.

На сегодняшний день существует значительное количество подходов к оценке ДУ ЭЭС на основе ИИ. Рассмотренные подходы реализуются с использованием различных алгоритмов ИИ и различных наборов признаков в обучающих выборках.

В общем случае ДУ СГ определяется:

1. Доаварийной активной мощностью, выдаваемой в ЭЭС.
2. Значением напряжения в точке присоединения к ЭЭС.
3. Импедансом от точки КЗ до точки присоединения к ЭЭС.
4. Законом автоматического регулятора активной мощности (APB).

В рассмотренных исследованиях для анализа ДУ использовались электрические и механические параметры режима работы СГ и не учитывалась топология ЭЭС, которая влияет не только на доаварийные параметры режима работы СГ, но и на характер развития послеаварийного переходного процесса.

ИСПОЛЬЗОВАНИЕ АЛГОРИТМОВ XGBoost и RANDOM FOREST ДЛЯ ОЦЕНКИ ДУ ЭЭС

Для решения задачи оценки ДУ СГ с учётом топологической связанности сети выбраны алгоритмы классификации XGBoost [31] и Random Forest [32] по следующим причинам:

1. Высокое быстродействие обученных алгоритмов.
2. Формализованная процедура обучения.
3. Устойчивость алгоритмов к пропускам данных и выбросам.

Алгоритм XGBoost основан на технике комбинации базовых классификаторов. В ходе работы алгоритма создаётся аддитивная композиция, в которой каждый последующий классификатор минимизирует общую ошибку модели. Классификаторы добавляются итеративно до достижения требуемой точности. При работе алгоритма результат классификации определяется суммой результатов базовых алгоритмов:

$$Y = \sum_{i=1}^K f_i(x_i), \quad (1)$$

где Y – результат классификации алгоритма XGBoost; $f_i(x_i)$ – результат работы каждого базового классификатора; K – количество базовых классификаторов.

Для обучения каждого базового классификатора внутри композиции выполняется поиск минимума регуляризованной функции потерь [10], которая обеспечивает отсутствие переобучения алгоритма.

Алгоритм Random Forest использует ансамбль деревьев решений, итоговый результат классификации является усреднением решений всех деревьев в ансамбле:

$$A = \frac{1}{m} \sum_{i=1}^m a_i(x_i), \quad (2)$$

где A – результат классификации алгоритма Random Forest; $a_i(x_i)$ – результат работы каждого дерева решений; m – количество деревьев решений в ансамбле.

ЧИСЛЕННЫЙ ЭКСПЕРИМЕНТ

Численный эксперимент выполнен с использованием математического моделирования серии электромеханических переходных процессов в Matlab/Simulink, для реализации алгоритмов машинного обучения использована библиотека Scikit-learn языка программирования Python3.

ФОРМИРОВАНИЕ ВЫБОРКИ ДАННЫХ

Для формирования исходных данных для обучения и тестирования алгоритмов XGBoost и RandomForest использованы результаты численного моделирования, выполненные для тестовой схемы IEEE39, графика которой приведена на рис. 2. Подробное описание модели приведено в исследовании [33].

Для формирования выборки данных был смоделирован набор электромеханических переходных процессов при варьировании следующих переменных:

1. Мощности СГ (всего 9 СГ, СГ 1 моделирует внешнюю энергосистему и его устойчивость не анализируется) изменялись в диапазоне: 60, 80 и 100% от номинальных активных мощностей;
2. В каждом узле (всего 39 узлов) рассматривались однофазные, двухфазные и трёхфазные КЗ длительностью 0,15 секунд.
3. Рассматривались единичные ремонты каждой линии электропередачи (всего 37 линий).

Таким образом, общее количество электромеханических переходных процессов N составляет:

$$N = N_1 N_2 N_3 N_4 = 3 \cdot 3 \cdot 38 \cdot 37 = 12\,654, \quad (3)$$

где N_1 – количество вариантов загрузки СГ; N_2 – количество типов КЗ; N_3 – количество узлов, в которых моделируется КЗ (в узле 39 КЗ не моделируется); N_4 – количество единичных ремонтов линий электропередачи.

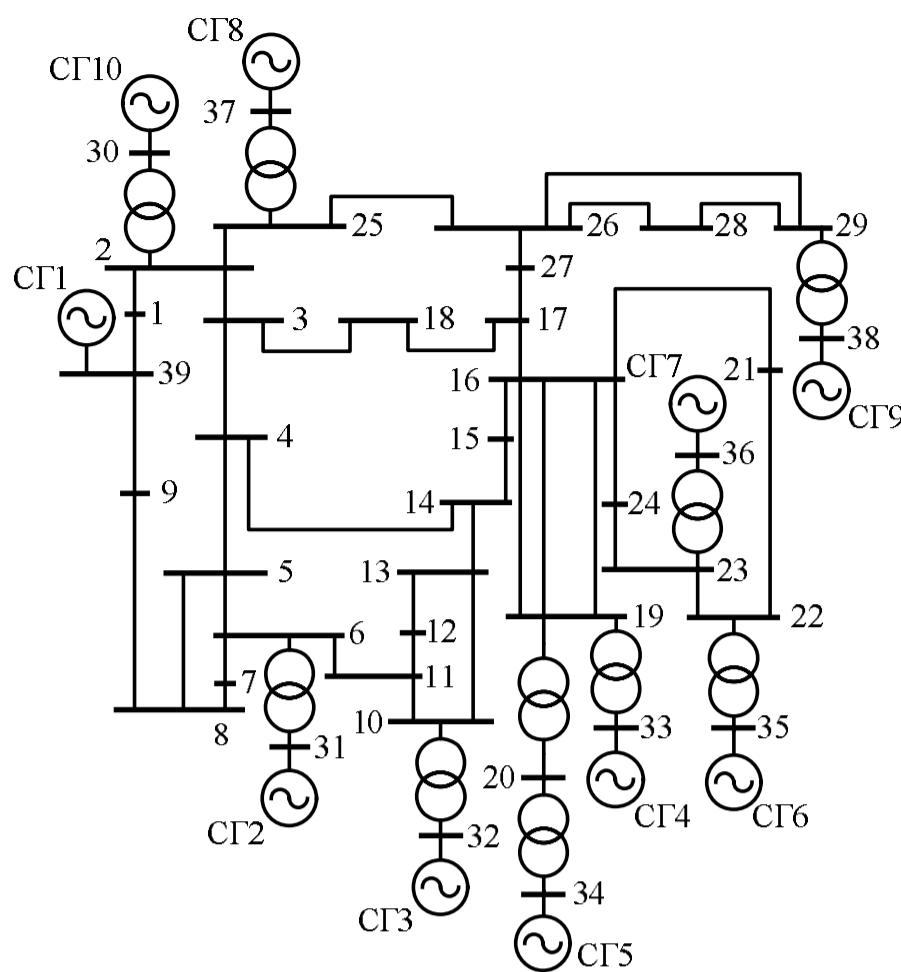


Рис. 2. Графика тестовой модели ЭЭС IEEE39

В результате выполнения серии электромеханических переходных процессов получена выборка данных, структура которой приведена в табл. 1.

Для выполнения расчётов 12 654-х электромеханических переходных процессов был использован компьютер с процессором Intel(R) Core(TM) i7-7700T CPU @ 2,90GHz. Вычисления выполнялись на видеокарте NVIDIA GeForce 940MX с использованием средства параллельных вычислений Parallel Computing Toolbox, входящих в Matlab.

Для анализа влияния каждого признака на результаты классификации выполнен анализ корреляции Спирмена. Результаты признаков с корреляцией к результату классификации по модулю менее 10% представлены на рис. 3. Так как для приведённых на рис. 3 признаков значение корреляции является незначительным, то они исключаются из выборки данных.

Таблица 1

Структура выборки данных

Атрибут выборки	
Признак. Ремонт линии	
Признак. Загрузки СГ (принимаются одинаковыми для всех СГ)	
Признак. Узел КЗ	
Признак. Сопротивление КЗ	
Признак. Угол нагрузки СГ 2	
...	
Признак. Угол нагрузки СГ 10	
Признак. Напряжение в точке подключения СГ2	
...	
Признак. Напряжение в точке подключения СГ10	
Результат классификации. СГ с потерей ДУ	

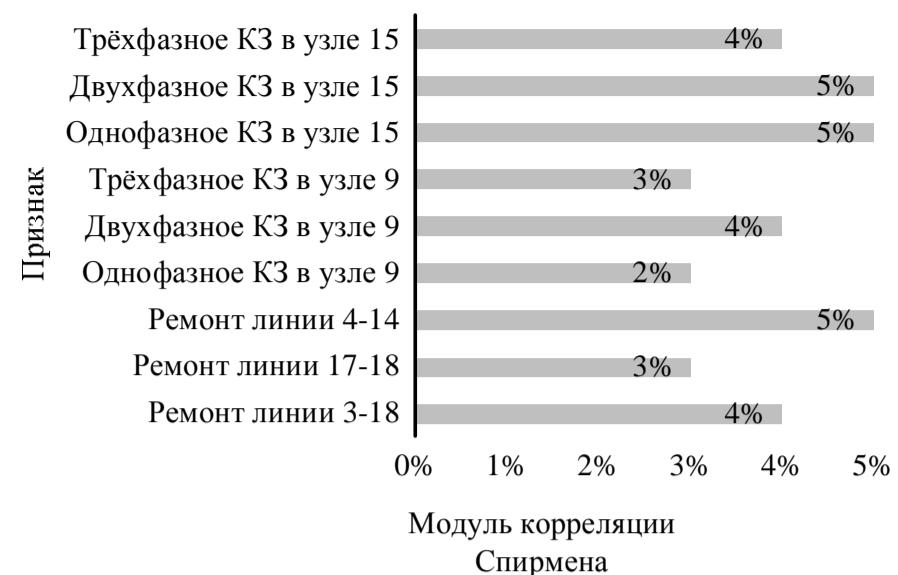


Рис. 3. Результаты корреляционного анализа данных

Для получения тестовой и обучающей выборок данных применялась процедура разделения общей выборки в соотношении 80%:20% (80% – обучающая выборка, 20% – тестовая выборка).

РЕЗУЛЬТАТЫ ОБУЧЕНИЯ АЛГОРИТМА XGBOOST

При обучении алгоритма XGBoost были получены следующие параметры модели:

1. L_1 регуляризация, штраф на величины весовых функций [31] (базовое значение 0): 0,1.
2. L_2 регуляризация, штраф на величины весовых функций [31] (базовое значение 0): 0,2.
3. Минимально требуемое уменьшение функции потерь при создании нового листа (базовое значение 0): 0,5.
4. Глубина дерева базового классификатора, определяет сложность модели и степень переобучения (базовое значение 3): 5.
5. Базовое значение вероятности отнесения строки данных к классу для бинарного случая, позволяет скорректировать падение точности вследствие несбалансированности классов (базовое значение 0,5): 0,8.
6. Число базовых классификаторов композиции, контролирует сложность модели: 50.
7. Темп градиентного спуска, контролирует возможность упустить локальные минимумы: 1.
8. Доля тренировочной выборки, случайно выбранная для обучения одного дерева (базовое значение 1): 0,8.

Значимость признаков для обученной модели приведена на рис. 4.

Наибольшую значимость для оценки ДУ тестовой ЭЭС с помощью алгоритма XGBoost имеет признак трёхфазного КЗ в узле 16, что объясняется наличием значительного числа связей узла 16 с другими узлами.

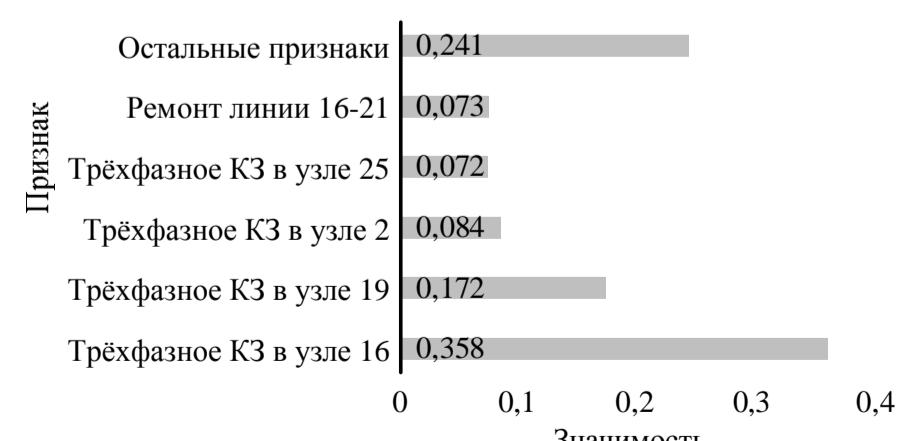


Рис. 4. Значимость признаков для алгоритма XGBoost

РЕЗУЛЬТАТЫ ОБУЧЕНИЯ АЛГОРИТМА RANDOM FOREST

При обучении алгоритма Random Forest были получены следующие параметры модели:

1. Число базовых классификаторов (базовое значение 100): 150.
2. Глубина дерева базового классификатора (базовое значение 1): 5.
3. Минимальная доля экземпляров данных для проведения расщепления (базовое значение 2 строки): 0,005.
4. Минимальная доля экземпляров данных, попадающая в лист (базовое значение 1 строка): 0,002.
5. Доля признаков тренировочной выборки, случайно выбранная для обучения одного дерева: 0,6.
6. Веса классов; в графе значения описаны веса для класса 0, вес класса 1 неизменен (базовое значение 1 для каждого класса): 6.

Значимость признаков для обученной модели приведена на **рис. 5**. Для алгоритма Random Forest наибольшая значимость для классификации потери ДУ имеет признак трёхфазного КЗ в узле 16.

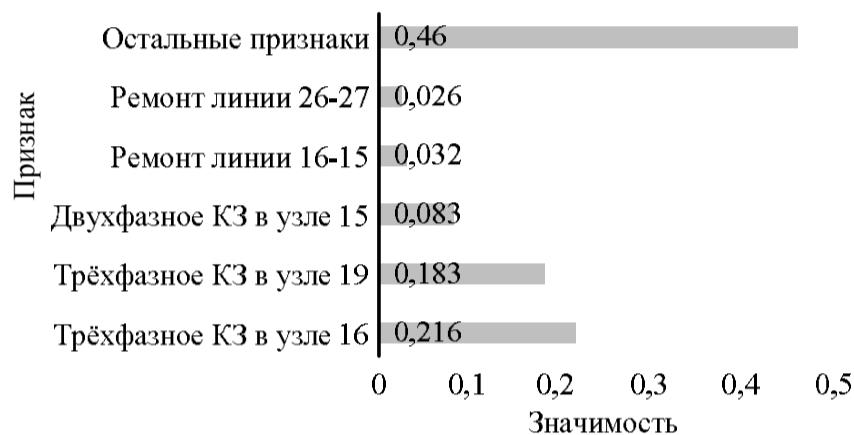


Рис. 5. Значимость признаков для алгоритма Random Forest

СРАВНЕНИЕ АЛГОРИТМОВ

В **табл. 2** приведено сравнение результатов тестирования алгоритмов XGBoost и Random Forest.

Для оценки точности работы алгоритма использованы параметры «точность» (precision) и «полнота» (recall), которые определяются по следующим выражениям:

$$\text{precision} = \frac{tp}{tp + fp}, \quad (4)$$

$$\text{recall} = \frac{tp}{tp + fn}, \quad (5)$$

где tp – истинно-положительное решение; tn – истинно-отрицательное решение; fp – ложно-положительное решение; fn – ложно-отрицательное решение.

Таблица 2
Сравнение результатов тестирования обученных алгоритмов

Параметр	XGBoost	Random Forest
С учётом топологической связности сети		
Точность	0,915	0,816
Точность средняя по классам	0,864	0,744
precision	0,898	0,847
recall	0,858	0,851
Без учёта топологической связности сети		
Точность	0,806	0,801
Точность средняя по классам	0,817	0,711
precision	0,815	0,816

recall	0,824	0,801
--------	-------	-------

Для проверки гипотезы о влиянии топологической связности электрической сети на результат работы используемых алгоритмов машинного обучения было проведено две серии численных экспериментов. В первой серии численных экспериментов обучение и тестиирование алгоритмов выполнялось без добавления признака, описывающего топологию электрической сети. В этом случае была получена точность 80,6 и 80,1 % для алгоритмов XGBoost и Random Forest соответственно. Для второй серии опытов в набор данных был добавлен признак, описывающий топологию электрической сети. На тестовой выборке данных были получены значения точности в 91,5 и 81,6% для алгоритмов XGBoost и Random Forest соответственно. Увеличение точности оценки ДУ объяснимо физической природой влияния суммарного сопротивления от точки КЗ до исследуемого СГ [9].

Таким образом, в ходе численного эксперимента было доказано влияние топологической связности электрической сети на точность работы рассматриваемых ИИ. Также было показано, что использование алгоритма XGBoost увеличивает точность классификации потери ДУ ЭЭС на 9,9% по сравнению с алгоритмом Random Forest.

ЗАКЛЮЧЕНИЕ

В работе представлен алгоритм оценки ДУ ЭЭС на основе алгоритмов XGBoost и Random Forest с учётом топологической связности электрической сети. Выполнен обзор существующих исследований, направленных на оценку ДУ ЭЭС с помощью методов машинного обучения.

Апробация выполнена на модели IEEE39. Для вычисления серии электромеханических процессов использован компьютер с процессором Intel(R) Core(TM) i7-7700T CPU @ 2,90GHz. Вычисления выполнялись на видеокарте NVIDIA GeForce 940MX с использованием средства параллельных вычислений Parallel Computing Toolbox, входящих в Matlab. В результате моделирования получена выборка данных из 12 654-х электромеханических переходных процессов.

В результате обучения были получены параметры алгоритмов XGBoost и Random Forest. Для тестовой выборки точность классификации потери ДУ для алгоритма XGBoost с учётом топологической связности сети составляет 91,5%, для алгоритма Random Forest точность составила 81,6%. Учёт топологической связности электрической сети позволяет увеличить точность алгоритмов.

Список источников

1. Khalyasmaa A.I., Senyuk M.D., Eroshenko S.A. High-Voltage Circuit Breakers Technical State Patterns Recognition Based on Machine Learning Methods // IEEE Transactions on Power Delivery. 2019. No. 4(34). Pp. 1747-1756. doi: 10.1109/TPWRD.2019.2921095
2. Electric vehicle charging load clustering and load forecasting based on long short term memory neural network / H. Wang, X. Huang, S. Gao, Z. Yang, T. Gao, Q. Zhao, H. Ding // 5th International Electrical and Energy Conference (CIEEC). IEEE, 2022. Pp. 3196-3200. doi: 10.1109/CIEEC54735.2022.9846570
3. Improved PV Forecasts for Capacity Firming / C. Keerthisinghe, E. Mickelson, D.S. Kirschen, N. Shih, S. Gibson // IEEE Access. 2020. Vol. 8. Pp. 152173-152182.

- doi: 10.1109/ACCESS.2020.3016956
4. Gelli R., Manimaran G. Anomaly Detection and Mitigation for Wide-Area Damping Control using Machine Learning // Power & Energy Society General Meeting (PESGM). IEEE, 2020. doi: 10.1109/PESGM41954.2020.9281615
 5. Hong G., Kim Y.-S. Supervised Learning Approach for State Estimation of Unmeasured Points of Distribution Network // IEEE Access. 2020. Vol. 8. Pp. 113918-113931. doi: 10.1109/ACCESS.2020.3003049
 6. Reduced Kernel Random Forest Technique for Fault Detection and Classification in Grid-Tied PV Systems / K. Dhibi, R. Fezai, M. Mansouri, M. Trabelsi, A. Kouadri, K. Bouzara, H. Nounou, M. Nounou // IEEE Journal of Photovoltaics. 2020. No. 6(10). Pp. 1864-1871. doi: 10.1109/JPHOTOV.2020.3011068
 7. The Accelerate Estimation Method of Power System Parameters in Static and Dynamic Processes / S. Beryozkina, M. Senyuk, A. Berdin, A. Dmitrieva, S. Dmitriev, P. Erokhin // IEEE Access. 2022. Vol. 10. Pp. 61522-61529. doi: 10.1109/ACCESS.2022.3181196
 8. Guest Editorial Big Data Analytics for Grid Modernization / T. Hong, C. Chen, J. Huang, N. Lu, L. Xie, H. Zareipour // IEEE Transactions on Smart Grid. 2016. No. 5(7). Pp. 2395-2396. doi: 10.1109/TSG.2016.2593358
 9. Kundur P. Power System Stability and Control. McGraw-Hill, Inc., New York, 1994.
 10. Алексеева В.А. Использование методов машинного обучения в задачах бинарной классификации // Автоматизация процессов управления. 2015. №. 3. С. 58-63.
 11. Time Series-Analysis Based Engineering of High-Dimensional Wide-Area Stability Indices for Machine Learning / R.T. Dabou, I. Kamwa, C.Y. Chung, C.F. Mugombozi // IEEE Access. 2021. Vol. 9. Pp. 104927-104939. doi:10.1109/ACCESS.2021.3099459
 12. Chen K. Indirect PCA Dimensionality Reduction Based Machine Learning Algorithms for Power System Transient Stability Assessment // Innovative Smart Grid Technologies - Asia (ISGT Asia). IEEE, 2019. Pp. 4175-4179. doi: 10.1109/ISGT-Asia.2019.8881370
 13. Online transient stability margin prediction of power systems with wind farms using ensemble regression trees / D. Mi, T. Wang, M. Gao, C. Li, Z. Wang // International Transactions on Electrical Energy Systems. 2021. No. 11(31). doi: 10.1002/2050-7038.13057
 14. Non-parametric statistics-based predictor enabling online transient stability assessment / T. Liu, Y. Liu, L. Xu, J. Liu, J. Mitra, Y. Tian // IET Gener. Transm. Distrib. 2018. Vol. 12(21). Pp. 5761-5769. doi: 10.1049/iet-gtd.2018.5802.
 15. Power System Transient Stability Assessment Using Stacked Autoencoder and Voting Ensemble / P. Sarajcev, A. Kunac, G. Petrovic, M. Despalatovic // Energies. 2021. No. 14(11). 3148. doi: 10.3390/en14113148
 16. Transient Stability Assessment Method for Power System Based on SVM with Adaptive Parameters Adjustment / D. Shao, Y. Xu, S. Ma, Y. Jing, W. Sun, T. Zhou, J. Yang // 4th International Electrical and Energy Conference (CIEEC). IEEE, 2021. Pp. 1-6. doi: 10.1109/CIEEC50170.2021.9510574
 17. Support vector machines for transient stability analysis of large-scale power systems / L.S. Moulin, A.P.A. da Silva, M.A. El-Sharkawi, R.J. Marks // IEEE Transactions on Power Systems. 2004. No. 2(19). Pp. 818-825. doi: 10.1109/TPWRS.2004.826018
 18. Power System Transient Stability Assessment Based on Big Data and the Core Vector Machine / B. Wang, B. Fang, Y. Wang, H. Liu and Y. Liu // IEEE Transactions on Smart Grid. 2016. No. 5(7). Pp. 2561-2570. doi: 10.1109/TSG.2016.2549063
 19. Mukherjee R., De A. Development of an Ensemble Decision Tree-Based Power System Dynamic Security State Predictor // IEEE Systems Journal. 2020. No. 3(14). Pp. 3836-3843. doi: 10.1109/JSYST.2020.2978504
 20. A Comparative Analysis of Decision Trees, Support Vector Machines and Artificial Neural Networks for On-line Transient Stability Assessment / N.G. Baltas, P. Mazidi, J. Ma, F. de Asis Fernandez, P. Rodriguez // International Conference on Smart Energy Systems and Technologies (SEST). IEEE, 2018. Pp. 1-6. doi: 10.1109/SEST.2018.8495872
 21. Amraee T., Ranjbar S. Transient Instability Prediction Using Decision Tree Technique // IEEE Transactions on Power Systems. 2013. No. 3(28). Pp. 3028-3037. doi: 10.1109/TPWRS.2013.2238684
 22. Li N., Li B., Gao L. Transient Stability Assessment of Power System Based on XGBoost and Factorization Machine // IEEE Access. 2020. Vol. 8. Pp. 28403-28414. doi: 10.1109/ACCESS.2020.2969446
 23. Data-driven Transient Stability Assessment Based on Kernel Regression and Distance Metric Learning / X. Liu, Y. Min, L. Chen, X. Zhang and C. Feng // Journal of Modern Power Systems and Clean Energy. 2021. No. 1(9). Pp. 27-36. doi: 10.35833/MPCE.2019.000581
 24. Pannell Z., Ramachandran B., Snider D. Machine learning approach to solving the transient stability assessment problem // Texas Power and Energy Conference (TPEC). IEEE, 2018. Pp. 1-6. doi: 0.1109/TPEC.2018.8312089.
 25. A Unified Online Deep Learning Prediction Model for Small Signal and Transient Stability / S.K. Azman, Y.J. Isbeih, M.S.E. Moursi, K. Elbassioni // IEEE Transactions on Power Systems. 2020. No. 6(35). Pp. 4585-4598. doi: 10.1109/TPWRS.2020.2999102
 26. Power system transient stability assessment based on dimension reduction and cost-sensitive ensemble learning / F. Hang, S. Huang, Y. Chen, S. Mei // Conference on Energy Internet and Energy System Integration (EI2). IEEE, 2017. Pp. 1-6. doi: 10.1109/EI2.2017.8245698.
 27. Li N., Li B., Gao L. Transient Stability Assessment of Power System Based on XGBoost and Factorization Machine // IEEE Access. 2020. Vol. 8. Pp. 28403-28414. doi: 10.1109/ACCESS.2020.2969446
 28. Power System Transient Stability Assessment Based on Voltage Phasor and Convolution Neural Network / J. Hou, C. Xie, T. Wang, Z. Yu, Y. Lü, H. Dai // International Conference on Energy Internet (ICEI). IEEE, 2018. Pp. 247-251. doi: 10.1109/ICEI.2018.00052
 29. Transient Stability Assessment of Power Systems Using Cost-sensitive Deep Learning Approach / Y. Zhou, W. Zhao, Q. Guo, H. Sun, L. Hao // 2nd Conference on Energy Internet and Energy System Integration (EI2). IEEE, 2018. Pp. 1-6, doi: 10.1109/EI2.2018.8582047
 30. Real- Time Detection of Critical Generators in Power Systems: A Deep Learning HCP Approach / B. Shinde, S. Wang, P. Dehghanian, M. Babakmehr // Texas Power and Energy Conference (TPEC). IEEE, 2020. Pp. 1-6. doi: 10.1109/TPEC48276.2020.9042552
 31. Preventive control for power system transient security based on XGBoost and DCOPF with consideration of model interpretability / S. Zhang, D. Zhang, J. Qiao, X. Wang, Z. Zhang // CSEE Journal of Power and Energy Systems. 2021. No. 2(7). Pp. 279-294. doi: 10.17775/CSEEJPES.2020.04780
 32. Sizing Optimization and Energy Management Strategy for Hybrid Energy Storage System Using Multiobjective Optimization and Random Forests / M. Li, L. Wang, Y. Wang, Z. Chen // IEEE Transactions on Power Electronics. 2021. No. 10(36). Pp. 11421-11430. doi: 10.1109/TPEL.2021.3070393
 33. Subrahmanyam S.V, Jain S.K., Narayanan G. Real-time Simulation of IEEE 10-Generator 39-Bus System with Power System Stabilizers on Miniature Full Spectrum Simulator // International Conference on Sustainable Energy Technologies and Systems (ICSETS). IEEE, 2019. Pp. 161-166. doi: 0.1109/ICSETS.2019.8745001

Поступила в редакцию 30 сентября 2022 г.

Принята к печати 17 ноября 2022 г.

INFORMATION IN ENGLISH

DEVELOPMENT OF A METHOD FOR ASSESSMENT THE DYNAMIC STABILITY OF POWER SYSTEMS ON THE BASIS OF THE THEORY OF ARTIFICIAL INTELLIGENCE APPLICATION TAKING INTO ACCOUNT THE TOPOLOGICAL CONNECTIVITY OF THE NETWORK

Mikhail D. Senyuk

Leading engineer, Department of Automated Electrical Systems, Ural Federal University, Ural Power Engineering Institute, Yekaterinburg, Russia. E-mail: mdsenuk@gmail.com. ORCID: <https://orcid.org/0000-0002-5589-7922>

Anna A. Dmitrieva

Postgraduate Student, Department of Automated Electrical Systems, Ural Federal University, Ural Power Engineering Institute, Yekaterinburg, Russia. E-mail: anyaprox@gmail.com.

The development of modern electric power systems is associated with digitalization and an increase in the data flow from electric power facilities to the control centers. On the other hand, an increase in the renewable energy sources share leads to an increase in electrical modes uncertainty and a decrease in total inertia, which imposes new requirements on the speed of the procedure for assessing dynamic stability and emergency control. The application of traditional deterministic algorithms to the analysis of the dynamic stability of power systems in the presence of increased requirements for performance may turn out to be inefficient. To overcome the shortcomings of traditional methods for assessing the dynamic stability of power systems, artificial intelligence methods can be used. This class of methods has a significant speed of trained models and the ability to search for patterns in the data, which makes it effective in modern power systems. The paper presents the results of developing a method for assessing the dynamic stability of a power system based on artificial intelligence methods, taking into account the topological connectivity of the electrical network. The technique is based on the application of the gradient boosting algorithm for decision trees. Numerical simulation was performed on the IEEE39 model implemented in Matlab/Simulink; the Scikit-learn library of the Python3 programming language was used to implement machine learning algorithms. To train the machine learning algorithm the load angles of synchronous generators, voltage levels at the nodes connecting synchronous generators to the electrical network, the topology of the electrical network, the duration and resistance of the short circuit were used. As a result of applying the trained algorithm, taking into account the topology of the electrical network, an accuracy of 91.5% was obtained on the test sample. The accuracy on the test sample without taking into account the topological connectivity of the elements of the power system was 81.6%.

Keywords: transient stability, artificial intelligence, machine learning, mathematical modeling

REFERENCES

1. Khalyasmaa A.I., Senyuk M.D., Eroshenko S.A. High-Voltage Circuit Breakers Technical State Patterns Recognition Based on Machine Learning Methods. *IEEE Transactions on Power Delivery* 2019, no. 4(34), pp. 1747-1756. doi: [10.1109/TPWRD.2019.2921095](https://doi.org/10.1109/TPWRD.2019.2921095)
2. Wang H., Huang X., Gao S., Yang Z., Gao T., Zhao Q., Ding H. Electric vehicle charging load clustering and load forecasting based on long short term memory neural network. *5th International Electrical and Energy Conference (CIEEC)*. IEEE, 2022, pp. 3196-3200. doi: [10.1109/CIEEC54735.2022.9846570](https://doi.org/10.1109/CIEEC54735.2022.9846570)
3. Keerthisinghe C., Mickelson E., Kirschen D.S., Shih N., Gibson S. Improved PV Forecasts for Capacity Firming. *IEEE Access*. 2020, vol. 8, pp. 152173-152182. doi: [10.1109/ACCESS.2020.3016956](https://doi.org/10.1109/ACCESS.2020.3016956)
4. Gelli R., Manimaran G. Anomaly Detection and Mitigation for Wide-Area Damping Control using Machine Learning. *Power& Energy Society General Meeting (PESGM)*. IEEE, 2020. doi: [10.1109/PESGM41954.2020.9281615](https://doi.org/10.1109/PESGM41954.2020.9281615)
5. Hong G., Kim Y.-S. Supervised Learning Approach for State Estimation of Unmeasured Points of Distribution Network. *in IEEE Access*, vol. 8, pp. 113918-113931, 2020.
6. Dhibi K., Fezai R., Mansouri M., Trabelsi M., Kouadri A., Bouzara K., Nounou H., Nounou M. Reduced Kernel Random Forest Technique for Fault Detection and Classification in Grid-Tied PV Systems. *IEEE Access*. 2020, no. 6(10), pp. 1864-1871. doi: [10.1109/JPHOTOV.2020.3011068](https://doi.org/10.1109/JPHOTOV.2020.3011068)
7. Beryozkina S., Senyuk M., Berdin A., Dmitrieva A., Dmitriev S., Erokhin P. The Accelerate Estimation Method of Power System Parameters in Static and Dynamic Processes. *IEEE Access*. 2022, vol. 10, pp. 61522-61529. doi: [10.1109/ACCESS.2022.3181196](https://doi.org/10.1109/ACCESS.2022.3181196)
8. Hong T., Chen C., Huang J., Lu N., Xie L., Zareipour H. Guest Editorial Big Data Analytics for Grid Modernization. *IEEE Transactions on Smart Grid*. 2016, no. 5(7), pp. 2395-2396. doi: [10.1109/TSG.2016.2593358](https://doi.org/10.1109/TSG.2016.2593358)
9. Kundur P. *Power System Stability and Control*. McGraw-Hill, Inc., New York, 1994.
10. Alekseeva V. A. Use of machine learning methods in binary classification problems. *Avtomatizatsiya protsessov upravleniya* [Automation of control processes]. 2015, no. 3, pp. 58-63. (In Russian)
11. Dabou R.T., Kamwa I., Chung C.Y., Mugombozi C.F. Time Series-Analysis Based Engineering of High-Dimensional Wide-Area Stability Indices for Machine Learning. *IEEE Access*. 2021, vol. 9, pp. 104927-104939. doi: [10.1109/ACCESS.2021.3099459](https://doi.org/10.1109/ACCESS.2021.3099459)
12. Chen K. Indirect PCA Dimensionality Reduction Based Machine Learning Algorithms for Power System Transient Stability Assessment. *Innovative Smart Grid Technologies - Asia (ISGT Asia)*. IEEE, 2019, pp. 4175-4179. doi: [10.1109/ISGT-Asia.2019.8881370](https://doi.org/10.1109/ISGT-Asia.2019.8881370)
13. Mi D., Wang T., Gao M., Li C., Wang Z. Online transient stability margin prediction of power systems with wind farms using ensemble regression trees. *International Transactions on Electrical Energy Systems*. 2021, no. 11(31). doi: [10.1002/2050-7038.13057](https://doi.org/10.1002/2050-7038.13057)
14. Liu T., Liu Y., Xu L., Liu J., Mitra J., Tian, Y. Non-parametric statistics-based predictor enabling online transient stability assessment. *IET Gener. Transm. Distrib.* 2018, vol. 12(21), pp. 5761-5769. doi: [10.1049/iet-gtd.2018.5802](https://doi.org/10.1049/iet-gtd.2018.5802)
15. Sarajcev P., Kunac A., Petrovic G., Despalatovic M. Power System Transient Stability Assessment Using Stacked Auto-encoder and Voting Ensemble. *Energies*. 2021, no. 14(11), 3148. doi: [10.3390/en14113148](https://doi.org/10.3390/en14113148)
16. Shao D., Xu Y., Ma S., Jing Y., Sun W., Zhou T., Yang J. Transient Stability Assessment Method for Power System Based on SVM with Adaptive Parameters Adjustment. *4th International Electrical and Energy Conference (CIEEC)*. IEEE,

- 2021, pp. 1-6. doi: 10.1109/CIEEC50170.2021.9510574
17. Moulin L.S., da Silva A.P.A., El-Sharkawi M.A., Marks R.J. Support vector machines for transient stability analysis of large-scale power systems. *IEEE Transactions on Power Systems*. 2004, no. 2(19), pp. 818-825. doi: 10.1109/TPWRS.2004.826018
 18. Wang B., Fang B., Wang Y., Liu H., Liu Y. Power System Transient Stability Assessment Based on Big Data and the Core Vector Machine. *IEEE Transactions on Smart Grid*. 2016, no. 5(7), pp. 2561-2570. doi: 10.1109/TSG.2016.2549063
 19. Mukherjee R., De A. Development of an Ensemble Decision Tree-Based Power System Dynamic Security State Predictor. *IEEE Systems Journal*. 2020, no. 3(14), pp. 3836-3843. doi: 10.1109/JSYST.2020.2978504
 20. Baltas N.G., Mazidi P., Ma J., de Asis Fernandez F., Rodriguez P. A Comparative Analysis of Decision Trees, Support Vector Machines and Artificial Neural Networks for On-line Transient Stability Assessment. International Conference on Smart Energy Systems and Technologies (SEST). IEEE, 2018, pp. 1-6. doi: 10.1109/SEST.2018.8495872
 21. Amraee T., Ranjbar S. Transient Instability Prediction Using Decision Tree Technique," in *IEEE Transactions on Power Systems*. 2013, no. 3(28), pp. 3028-3037. doi: 10.1109/TPWRS.2013.2238684
 22. Li N., Li B., Gao L. Transient Stability Assessment of Power System Based on XGBoost and Factorization Machine. *IEEE Access*. 2020, vol. 8, pp. 28403-28414. doi: 10.1109/ACCESS.2020.2969446
 23. Liu X., Min Y., Chen L., Zhang X., Feng C. Data-driven Transient Stability Assessment Based on Kernel Regression and Distance Metric Learning. *Journal of Modern Power Systems and Clean Energy*. 2021, no. 1(9), pp. 27-36. doi: 10.35833/MPCE.2019.000581
 24. Pannell Z., Ramachandran B., Snider D. Machine learning approach to solving the transient stability assessment problem. *Texas Power and Energy Conference (TPEC)*. IEEE, 2018, pp. 1-6. doi: 10.1109/TPEC.2018.8312089
 25. Azman S.K., Isbeih Y.J., Moursi M.S.E., Elbassioni K. A Unified Online Deep Learning Prediction Model for Small Signal and Transient Stability. *IEEE Transactions on Power Systems*. 2020, no. 6(35), pp. 4585-4598. doi: 10.1109/TPWRS.2020.2999102
 26. Hang F., Huang S., Chen Y., Mei S. Power system transient stability assessment based on dimension reduction and cost-sensitive ensemble learning. Conference on Energy Internet and Energy System Integration (EI2). IEEE, 2017, pp. 1-6. doi: 10.1109/EI2.2017.8245698
 27. Li N., Li B., Gao L. Transient Stability Assessment of Power System Based on XGBoost and Factorization Machine. *IEEE Access*. 2020, vol. 8, pp. 28403-28414. doi: 10.1109/ACCESS.2020.2969446
 28. Hou J., Xie C., Wang T., Yu Z., Lü Y., Dai H. Power System Transient Stability Assessment Based on Voltage Phasor and Convolution Neural Network. International Conference on Energy Internet (ICEI). IEEE, 2018, pp. 247-251. doi: 10.1109/ICEI.2018.00052
 29. Zhou Y., Zhao W., Guo Q., Sun H., Hao L. Transient Stability Assessment of Power Systems Using Cost-sensitive Deep Learning Approach. 2nd Conference on Energy Internet and Energy System Integration (EI2). IEEE, 2018, pp. 1-6, doi: 10.1109/EI2.2018.8582047
 30. Shinde B., Wang S., Dehghanian P., Babakmehr M. Real-Time Detection of Critical Generators in Power Systems: A Deep Learning HCP Approach. *Texas Power and Energy Conference (TPEC)*. IEEE, 2020, pp. 1-6. doi: 10.1109/TPEC48276.2020.9042552
 31. Zhang S., Zhang D., Qiao J., Wang X., Zhang Z. Preventive control for power system transient security based on XGBoost and DCOPF with consideration of model interpretability. *CSEE Journal of Power and Energy Systems*. 2021, no. 2(7), pp. 279-294. doi: 10.17775/CSEEPES.2020.04780
 32. Li M., Wang L., Wang Y., Chen Z. Sizing Optimization and Energy Management Strategy for Hybrid Energy Storage System Using Multiobjective Optimization and Random Forests. *IEEE Transactions on Power Electronics*. 2021, no. 10(36), pp. 11421-11430. doi: 10.1109/TPEL.2021.3070393
 33. Subrahmanyam S.V., Jain S.K., Narayanan G. Real-time Simulation of IEEE 10-Generator 39-Bus System with Power System Stabilizers on Miniature Full Spectrum Simulator. International Conference on Sustainable Energy Technologies and Systems (ICSETS). IEEE, 2019, pp. 161-166. doi: 10.1109/ICSETS.2019.8745001

Сенюк М.Д., Дмитриева А.А. Разработка метода оценки динамической устойчивости энергосистем на основе применения теории искусственного интеллекта с учётом топологической связности сети // Электротехнические системы и комплексы. 2022. № 4(57). С. 12-19. [https://doi.org/10.18503/2311-8318-2022-4\(57\)-12-19](https://doi.org/10.18503/2311-8318-2022-4(57)-12-19)

Senyuk M.D., Dmitrieva A.A. Development of a Method for Assessing the Dynamic Stability of Power Systems on the Basis of the Theory of Artificial Intelligence Application Taking into Account the Topological Connectivity of the Network. *Elektrotekhnicheskie sistemy i kompleksy* [Electrotechnical Systems and Complexes], 2022, no. 4(57), pp. 12-19. (In Russian). [https://doi.org/10.18503/2311-8318-2022-4\(57\)-12-19](https://doi.org/10.18503/2311-8318-2022-4(57)-12-19)