

УДК 621.313.13+004.94

EDN ORLANH

СРАВНИТЕЛЬНЫЙ АНАЛИЗ АНСАМБЛЕВЫХ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОБНАРУЖЕНИЯ РЕЖИМА ЗАПУСКА ЭЛЕКТРОДВИГАТЕЛЯ

С.С. АверьяновORCID: 0009-0001-8468-1098 e-mail: sergey.s.averianov@gmail.comНовосибирский государственный технический университет
Новосибирск, Россия**А.С. Трофимов**ORCID: 0000-0002-1557-9380 e-mail: a.trofimov@corp.nstu.ruНовосибирский государственный технический университет
Новосибирск, Россия

Исследуется применение ансамблевых алгоритмов машинного обучения для классификации переходных процессов в системах релейной защиты с целью повышения их эффективности. Рассматриваются методы «*bagging*», «*boosting*» и «*stacking*» для решения задачи классификации данных, полученных из SCADA-систем и терминалов РЗ. Оценка точности классификации осуществляется с использованием метрик *Precision*, *Recall* и *F1-score*. Результаты экспериментов демонстрируют высокую точность работы ансамблевых алгоритмов при классификации переходных процессов, таких как пуск и самозапуск электродвигателей, на основе данных, полученных из моделей *Power Factory* и *Matlab Simulink*. Для дальнейших исследований предполагается анализ более сложных режимов пуска электродвигателей с целью улучшения точности классификации.

Ключевые слова: ансамблевые алгоритмы, классификация, машинное обучение, переходные процессы, релейная защита.

Для цитирования: Аверьянов С.С., Трофимов А.С. Сравнительный анализ ансамблевых алгоритмов машинного обучения для обнаружения режима запуска электродвигателя // Интеллектуальная Электротехника. 2025. № 4. С. 77-90. EDN ORLANH

COMPARATIVE ANALYSIS OF ENSEMBLE MACHINE LEARNING ALGORITHMS FOR DETECTING THE STARTING MODE OF ELECTRIC MOTOR

S.S. Averyanov

ORCID: 0009-0001-8468-1098 e-mail: sergey.s.averianov@gmail.com

Novosibirsk State Technical University

Novosibirsk, Russia

A.S. Trofimov

ORCID: 0000-0002-1557-9380 e-mail: a.trofimov@corp.nstu.ru

Novosibirsk State Technical University

Novosibirsk, Russia

Abstract. The article explores the application of ensemble machine learning algorithms for classifying transients in relay protection systems in order to increase their efficiency. The methods of bagging, boosting and stacking for solving the problem of classifying data obtained from SCADA systems and RS terminals are considered. Classification accuracy is assessed using the Precision, Recall, and F1-score metrics. The experimental results demonstrate the high accuracy of the ensemble algorithms in classifying transient processes, such as starting and self-starting electric motors, based on data obtained from the Power Factory and Matlab Simulink models. For further research, it is planned to analyze more complex starting modes of electric motors in order to improve the classification accuracy.

Keywords: ensemble algorithms, classification, machine learning, transients, relay protection.

For citation: S.S. Averyanov and A.S. Trofimov, “Comparative analysis of ensemble machine learning algorithms for detecting the starting mode of electric motor”, *Smart Electrical Engineering*, no. 4, pp. 77-90, 2025. EDN ORLAHH

I. Введение

В настоящее время прослеживается тенденция на развитие и применение технологий обработки больших данных и машинного обучения (МО) в различных отраслях науки и техники. Благодаря возможности анализа и обобщения больших объемов информации, появляется возможность усовершенствовать процесс принятия решений в различных отраслях на основе имеющихся статистических данных. Большие объемы статистических данных обрабатываются, в том числе в энергетических комплексах и системах, в частности в системах *Supervisory Control And Data Acquisition (SCADA)* в связке с терминалами релейной защиты (РЗ) и противоаварийной автома-

тики (ПА). Современные SCADA серверы обладают достаточной производительностью для реализации на их основе новых подходов с использованием алгоритмов МО для организации логических органов РЗ. В качестве инновационного подхода может рассматриваться алгоритм классификации переходных процессов на основе МО, который позволит распознавать режим пуска двигателя, для снижения значения коэффициента отстройки от пуска (самозапуска) электродвигателей для максимальной токовой защиты за счет логического блокирующего органа, работающего в этом режиме.

Анализ современных отечественных и зарубежных исследований позволил выявить значительный научный интерес к применению методов МО в задачах релейной защиты. Проведенный обзор свидетельствует о перспективности данного направления.

В [1] демонстрируется эффективность ансамблевых алгоритмов МО для решения задачи селективного выявления коротких замыканий за трансформатором. Исследование [2] посвящено вопросам классификации режимов энергосистемы с применением алгоритма «случайный лес», где решалась задача определения оптимальных управляющих воздействий для предотвращения развития аварийных ситуаций. В [3] представлены результаты успешного применения ансамблевых методов для раннего обнаружения аварийных режимов на оборудовании электростанций. Особого внимания заслуживает исследование [4], в котором раздел посвящен классификации повреждений с использованием ансамблевых алгоритмов на модели, реализованной в *Matlab Simulink*, показавшей высокую точность классификации.

Вместе с тем, практическая реализация алгоритмов МО в контексте релейной защиты порождает комплекс актуальных вопросов, требующих дополнительного изучения. Среди них:

- 1) методология сбора и подготовки эксплуатационных данных для работы моделей после обучения;
- 2) организация информационного обмена между вычислительной системой и устройствами релейной защиты;
- 3) определение минимально достаточной частоты дискретизации измерительных устройств, обеспечивающей требуемое качество работы алгоритмов МО;
- 4) исследование возможности и разработка требований к алгоритмам для классификации переходных процессов в режиме реального времени.

Решение указанных задач представляется необходимым условием для успешной интеграции перспективных методов МО в практику релейной защиты.

Настоящая работа представляет собой развитие исследований алгоритмов МО для реализации логического органа классификации переходных

процессов с целью выявления процессов пуска и самозапуска электродвигателей для улучшения характеристик срабатывания максимальной токовой защиты. По результатам предыдущих исследований [5, 6] было установлено, что простейшие алгоритмы МО, представленные «деревом решений», «*k*-ближайших соседей» и «логистической регрессией» не обеспечивают требуемого уровня точности классификации. В этой связи актуальность представленной работы определяется необходимостью анализа и применения более совершенных алгоритмов МО для решения задачи классификации переходных процессов в электрических сетях. Целями данного исследования являются: разработка и реализация ансамблевых алгоритмов МО для классификации переходных процессов, оценка их точностных характеристик, а также выявление факторов, оказывающих влияние на качество классификации. Для достижения поставленных целей требуется решение следующего комплекса задач:

- подготовить математические модели участков электрической сети, включающих электродвигатели переменного тока, защита линии питания которых осуществляется благодаря максимальной токовой защите;
- сформировать выборки данных признаков для обучения алгоритмов МО;
- реализовать различные типы ансамблевых алгоритмов МО для решения задачи классификации переходных процессов и оценить их точность;
- изменив место и тип замыкания, оценить эффективность классификации в различных вариация аварийных режимов.

II. Структурная схема обмена информацией

Согласно современным стандартам, современные устройства релейной защиты и автоматики должны иметь интерфейсы связи. Одним из распространенных интерфейсов является МЭК 61850, который обеспечивает мгновенный обмен данными с сервером. Для реализации логического органа релейной защиты в основе которого лежат алгоритмы МО возможно рассмотреть использование существующей связи терминалов РЗ и SCADA систем для реализации вычислений на их базе (рис. 1). При проектировании цифровых подстанций для передачи сигналов мгновенных значений токов и напряжений применяется протокол МЭК 61850-9-2 (*Sampled Values, SV*). В соответствии с требованиями стандарта МЭК 61869-9 [7], частота дискретизации *SV*-потока может принимать следующие значения:

- 4800 Гц с числом выборок в кадре 2, номинальной частотой сообщений цифрового выхода 2400 кадр/секунд;
- 12800 Гц в формате «*Format 2 (FT2)*», используемом в дифференциальной защите трансформаторов и при оценке качества электроэнергии.

В случае наличия в составе ячейки электромеханических устройств релейной защиты для сбора данных требуется установка блока слияния

(*Merging Unit, MU*). Данное устройство подключается к вторичным цепям трансформаторов тока и напряжения, а также синхронизируется от источника точного времени (*GPS/GLONASS*). Функциональным назначением *MU* является формирование и *multicast*-ретрансляция *SV*-потока в соответствии со стандартом МЭК 61850-9-2 с частотами дискретизации, регламентированными стандартом МЭК 61869-9.

Ансамблевые алгоритмы МО представляют собой класс статистических методов. В процессе своего функционирования они оперируют статистическими метриками, такими как среднее значение, стандартное отклонение, экстремумы и медиана, а также частотными характеристиками, получаемыми посредством быстрого преобразования Фурье (БПФ).

В рамках данной исследовательской методологии рассматривается поток данных с частотой дискретизации 4800 Гц. Данные передаются структурированными кадрами, каждый из которых содержит по два последовательных отсчета измеряемого сигнала. Таким образом, частота обновления информационных кадров составляет 2400 Гц.

Такая схема передачи и упаковки данных обеспечивает репрезентативность выборки и сохранение необходимых частотных характеристик сигнала вплоть до 2400 Гц (в соответствии с теоремой Котельникова [8]), что является достаточным для последующего эффективного обучения моделей МО и решения задач классификации, регрессии или обнаружения аномалий в электроэнергетических системах.




Рис. 1. Структурная схема обмена информацией между SCADA сервером и терминалом РЗ

Fig. 1. Structural diagram of information exchange between the SCADA server and the protection terminal

Алгоритмы МО, решающие задачу классификации переходных процессов, являются расчетными, т.е. для их реализации не требуется использование графического процессора. Сравнительный анализ системных требований производителей SCADA систем [9, 10] показал, что мощностные характеристики современных SCADA серверов полностью удовлетворяют системным требованиям для реализации алгоритмов обработки больших данных и МО.

Дообучение алгоритмов классификации в процессе работы требует корректной идентификации режимов эксплуатации электрооборудования, при формировании размеченных датасетов необходима интеграции объективных источников телеметрии, верифицирующих классифицируемые события. К числу таких источников относятся:

- сигналы состояния коммутационных аппаратов (включено/отключено) с временными метками;
- триггеры срабатывания защитных устройств с фиксацией времени и типа повреждения.

Указанные данные позволяют установить однозначное соответствие между наблюдаемыми переходными процессами и эксплуатационными режимами, что является критически важным для построения репрезентативных моделей МО.

III. Методология ансамблевых алгоритмов машинного обучения

Ансамблевые алгоритмы (*bagging*, *boosting*, *stacking* и др.) представляют собой методологию построения метамоделей, основанную на агрегировании решений множества базовых классификаторов. Их ключевое преимущество заключается в том, что они позволяют компенсировать слабые стороны отдельных алгоритмов, таких как деревья решений, логистическая регрессия и метод k -ближайших соседей (k -NN). Преимуществами ансамблевых алгоритмов являются:

1. Снижение обобщающей ошибки.

Метод «*Bagging*» (например, «Случайный лес») уменьшает дисперсию модели за счет усреднения прогнозов множества независимых классификаторов, обученных на бутстрапированных выборках. Это повышает устойчивость алгоритма к переобучению, которое характерно для отдельных деревьев решений.

Метод *Boosting* (например, *Gradient Boosting*, *XGBoost*, *LightGBM*) снижает смещение путем итеративного построения последовательности слабых моделей, каждая из которых обучается на ошибках предшествующих. Такой подход особенно эффективен в задачах, где логистическая регрессия оказывается слишком «жесткой» в предположениях о линейности границы раздела.

2. Робастность к шуму и выбросам.

В отличие от метода k -NN, который чувствителен к локальным шумам в данных, ансамблевые методы (особенно «*Boosting*») способны смещать внимание модели в сторону более сложных областей пространства признаков, тем самым обеспечивая большую устойчивость.

3. Использование гетерогенных моделей.

Стратегия «*Stacking*» позволяет комбинировать алгоритмы разной природы (например, деревья решений, логистическую регрессию и k -NN), что повышает аппроксимирующую способность системы и позволяет моделировать более сложные закономерности, чем отдельные классификаторы.

4. Улучшение баланса между смещением и дисперсией.

Отдельные модели, как правило, обладают либо высоким смещением (логистическая регрессия), либо высокой дисперсией (деревья решений). Ансамбли позволяют более эффективно находить компромисс между этими характеристиками, что обеспечивает лучшие результаты классификации на разнообразных наборах данных.

Ансамблевые алгоритмы МО в сравнении с технологией искусственных нейронных сетей обладают более простой интерпретируемостью, что снижает требования к наладчику программного обеспечения. Исходя из вышесказанного, ансамблевые алгоритмы требуют рассмотрения для решения задачи классификации переходных процессов с целью выделения режима пуска двигателя из выборки данных мгновенных значений токов и напряжений.

Описанные выше методы ансамблевых алгоритмов МО реализовываются на базе языка программирования *Python* с использованием специализированной библиотеки «*Scikit learn*». Ознакомится с математическим аппаратом и функциями, реализованными в библиотеке каждого из методов можно в [11, 12]. Структурные схемы алгоритмов подробно описаны в [13].

Оценка точности результатов классификации полученных в результате работы ансамблевых алгоритмов реализуется с помощью метрик «*Accuracy*», «*Precision*», «*Recall*». Дополнительно следует рассмотреть метрику «*f1-score*»:

$$f1-score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}. \quad (1)$$

Метрика *Precision* необходима для оценки вероятности ошибки второго рода «излишнее срабатывание». Метрика *Recall* служит для выявления ошибок первого рода «отказ в срабатывании». С точки зрения РЗ обе ошибки являются критическими, влияющими на надежность системы. С этой целью рассматривается дополнительная метрика «*f1-score*», которая показывает степень баланса по двум вышеописанным метрикам.

V. Исходные данные

Для получения выборки данных мгновенных значений токов и напряжений использовались две модели сформированных с помощью программного комплекса математического моделирования: *Matlab Simulink* и *Power Factory* согласно однолинейной схеме (рис. 2).




Рис. 2. Однолинейная схема ячейки 10 кВ ввода на секцию 0,4 кВ

Fig. 2. Single-line diagram of a 10 kV input cell for a 0.4 kV section

Разработана математическая модель системы электроснабжения, включающая ячейку ввода 10 кВ и присоединенную секцию 0,4 кВ. Структура нагрузки секции комбинированная: постоянная активная составляющая дополнена двигательной нагрузкой в виде асинхронного электродвигателя номинальной мощностью 40 кВт.

Локализация двигательной нагрузки на стороне 0,4 кВ обусловлена необходимостью корректного моделирования трансформации токовых характеристик через силовой трансформатор. Такой подход служит методологической основой для дальнейшего экстраполирования алгоритмов классификации переходных процессов на электроустановки более высоких классов напряжений.

Номинальная мощность двигательной нагрузки была выбрана таким образом, чтобы минимизировать амплитуду пускового тока. Токи короткого замыкания (в том числе замыкания на землю) были снижены на два порядка для минимизации разницы амплитудных значений с процессом пуска двигателя. Мощность электродвигателя выбрана с учетом минимизации разницы амплитудных значений с постоянной нагрузкой.

Для регистрации мгновенных значений токов и напряжений переходных процессов в моделировании используется измерительный орган, интегрированный в цепь трансформаторов тока ячейки 10 кВ.

Моделирование предусматривает последовательную коммутацию двигательной нагрузки и создание точки короткого замыкания с целью возбуждения переходных процессов. Параметры сбора данных установлены

следующим образом: частота дискретизации – 2,4 кГц, длительность реализации – 2,4 с. Ограничение указанных параметров введено для оптимизации вычислительных затрат на этапе постобработки данных. Выбор объема выборки обоснован в работе [4].

Формирование выборки данных осуществляется в последовательности, заданной в табл. 1. Полученная выборка соответствует осциллограмме (рис. 3). Сама выборка представляет собой массив мгновенных значений токов и напряжений по трем фазам. Для использования набора данных в задачах обучения с учителем ему присвоены метки классов. В отдельном столбце «*Target*» осуществляется категоризация типа переходного процесса для каждого временного отсчета, согласно следующей кодировке: 1 – Нормальный режим (НР); 2 – Пуск двигательной нагрузки (П); 3 – Короткое замыкание (на землю) (КЗ).




Рис. 3. Осциллограмма порядка коммутаций при рассмотрении двухфазного КЗ в точке 2

Fig. 3. An oscillogram of the switching order when considering a two-phase short circuit at point 2

Таблица 1.

Таблица порядка коммутаций

Table 1.
Switching order table

Время, с	0-0,2	0,2-0,4	0,4-0,6	0,6-0,8	0,8-1	1-1,2	1,2-1,4
Процесс	НР	П	НР	КЗ	НР	П	НР
Время, с	1,4-1,6	1,6-1,8	1,8-2	2-2,2	2,2-2,4		
Процесс	КЗ	НР	П	НР	КЗ		

V. Результаты

При реализации описанных методов возникла проблема низкого качества классификации без учета структуры данных выборки. Оно обосновано методами деления данных для обучения. Зачастую алгоритмы используют процессы кросс-валидации, где происходит перемешивание выборки для исключения ложных закономерностей. Однако «сырые» мгновенные значения ($I_A, I_B, I_C, U_A, U_B, U_C$) малоинформативны. На один момент времени приходится всего 6 чисел – этого недостаточно, чтобы точно определить режим («нормальный», «запуск», «аварийный»). В то же время классы отличаются по динамике сигналов. В «нормальном режиме» токи и напряжения стабильные. В «запуске двигателя» появляются характерные всплески токов. В «аварии» могут быть сильные выбросы, перекосы фаз и т.д. Эти особенности проявляются только на отрезке времени, а не в одной точке. Для решения задачи классификации временных рядов следует применить метод «Скользящего окна» [14]. Метод позволяет использовать в качестве признаков последовательности, выбранные из временного ряда. Для данного метода необходимо задать два параметра: число точек и шаг. Число точек связано с частотой дискретизации и особенностью входных данных, а шаг «окна» равен половине от количества точек. Таким образом, рассматриваемое окно должно охватить один период промышленной частоты, т.е. при частоте дискретизации равной 2,4 кГц число точек составит 48, а шаг окна составит 24 точки. Результаты классификации с использованием метода «Скользящего окна» над выборкой, полученной при двухфазном коротком замыкании в точке К2 представлены в табл. 2, где указаны безразмерные величины метрик оценки точности модели для искомых классов. Целевым классом для выявления является класс 1 – пуск двигателя.

Согласно результатам моделирования, наибольшую точность классификации показывают ансамблевые алгоритмы с использованием данных, полученных в *Power Factory*. Все алгоритмы ансамблевой классификации обучались и опробовались на выборке полученных в точках К3 указанных на рис. 2. Причиной высокой точности алгоритма могла стать переобученность модели, так как рассматривался один тип К3 в одной выборке данных. Для подтверждения или опровержения точности работы ансамблевых алгоритмов классификации необходимо объединить выборки с К3 К2⁽²⁾, К2⁽¹⁾ и К1⁽²⁾, К1⁽¹⁾. Результаты моделирования представлены в табл. 3.

Таблица 2.
Результаты классификации с использованием метода «Скользящего окна»

Table 2.
Classification results using the Sliding Window method

K2 ⁽²⁾	Matlab Simulink			Power Factory		
	Bagging	Boosting	Stacking	Bagging	Boosting	Stacking
Precision (класс 0)	0,832	0,893	0,830	0,994	0,975	0,991
Precision (класс 1)	0,823	0,878	0,830	0,991	0,947	0,991
Precision (класс 2)	0,887	0,806	0,991	0,997	0,994	0,988
Recall (класс 0)	0,901	0,806	0,900	0,989	0,975	0,985
Recall (класс 1)	0,695	0,837	0,873	0,984	0,947	0,992
Recall (класс 2)	0,884	0,923	0,885	0,992	0,994	0,995
F1-score (класс 0)	0,865	0,847	0,865	0,991	0,975	0,986
F1-score (класс 1)	0,853	0,857	0,903	0,986	0,947	0,990
F1-score (класс 2)	0,882	0,800	0,932	0,993	0,994	0,991
K2 ⁽¹⁾						
F1-score (класс 1)	0,833	0,842	0,873	0,995	0,947	0,993
F1-score (класс 2)	0,892	0,828	0,997	0,996	0,998	0,999
K1 ⁽²⁾						
F1-score (класс 1)	0,801	0,927	0,855	0,992	0,975	0,991
F1-score (класс 2)	0,842	0,867	0,995	0,985	0,989	0,983
K1 ⁽¹⁾						
F1-score (класс 1)	0,812	0,924	0,899	0,987	0,954	0,982
F1-score (класс 2)	0,878	0,786	0,872	0,992	0,989	0,988

Таблица 3.
Результаты классификации для объединенных выборок

Table 3.
Classification results for combined samples

K2 ⁽²⁾ и K2 ⁽¹⁾	Matlab Simulink			Power Factory		
	Bagging	Boosting	Stacking	Bagging	Boosting	Stacking
F1-score (класс 1)	0,853	0,857	0,908	0,994	0,973	0,992
F1-score (класс 2)	0,892	0,901	0,932	0,984	0,960	0,981
K1 ⁽²⁾ и K1 ⁽¹⁾						
F1-score (класс 1)	0,851	0,962	0,874	0,989	0,969	0,994
F1-score (класс 2)	0,881	0,875	0,992	0,995	0,986	0,991

VI. Заключение

Ансамблевые алгоритмы для решения задачи классификации с последующим выделением режима пуска двигателя показали достаточно высокую точность. При этом время, затраченное на алгоритм классификации,

составляет не более 0,004 секунды в расчете использования вычислительной мощности сравнимой со SCADA сервером. Ансамблевые алгоритмы демонстрируют высокую эффективность при условии, что модель не предполагается дообучать в процессе эксплуатации. Однако расширение ансамблевых методов механизмами инкрементального обучения сопровождается рядом существенных рисков. В частности, при длительном поступлении данных, относящихся преимущественно к одному классу, возникает эффект дрейфа: модель адаптируется к текущему распределению и утрачивает способность корректно распознавать ранее встречавшиеся сценарии. Дополнительной проблемой является повышенная чувствительность к шумовым компонентам входных сигналов, особенно при отсутствии предварительной фильтрации, что требует применения инкрементальных методов нормализации и стабилизации параметров. Совокупность указанных мер приводит к увеличению вычислительных затрат и времени обработки данных. В связи с этим, дальнейшие исследования методов классификации переходных процессов целесообразно ориентировать на изучение нейросетевых архитектур с механизмами долговременной памяти.

© Аверьянов С.С., 2025

© Трофимов А.С., 2025

Поступила в редакцию 22.10.2025

Принята к публикации 24.11.2025

Received 22.10.2025

Accepted 24.11.2025

Библиографический список

- [1] Куликов А.Л., Лоскутов А.А., Бездушный Д.И. Повышение распознаваемости аварийных режимов релейной защиты методами деревьев решений // Электричество. 2023. № 7. С. 20-34. DOI: 10.24160/0013-5380-2023-7-20-34
- [2] Осак А.Б., Ефимов Д.Н., Жуков А.В., Панасецкий Д.А., Курбацкий В.Г., Сидоров Д.Н., Томин Н.В., Воропай Н.И. Комплекс интеллектуальных средств раннего выявления и предотвращения возникновения системных аварий в энергообъединениях // Автоматика и телемеханика. 2018. № 10. С. 6-25. DOI: 10.31857/S000523100001845-3
- [3] Коршикова А.А., Трофимов А.Г. Модель раннего обнаружения аварийных ситуаций на оборудовании электростанций на основе методов машинного обучения // Теплоэнергетика. 2019. № 3. С. 49-56. DOI: 10.1134/S0040363619030044
- [4] Najafzadeh M., Pouladi J., Daghigh A, Beiza J., Abedinzade T. Fault detection, classification and localization along the power grid line using optimized machine learning algorithms // International Journal of Computational Intelligence Systems. 2024. Vol. 17. Art. no. 49. DOI: 10.1007/s44196-024-00434-7

- [5] Averyanov S., Trofimov A. Analysing non-ensemble machine learning methods for solving the transient classification problem // 2025 IEEE 26th International Conference of Young Professionals in Electron Devices and Materials (EDM), Altai, Russian Federation, 2025. Pp. 1100-1105. DOI: 10.1109/EDM65517.2025.11096849.
- [6] Аверьянов С.С., Трофимов А.С. Анализ факторов, влияющих на интеллектуальный алгоритм классификации переходных процессов и надежность устройств релейной защиты // Методические вопросы исследования надежности больших систем энергетики: материалы конференции. Иркутск. 2025. №. 76. С. 794-803.
- [7] ГОСТ Р МЭК 61869-9-2025. Трансформаторы измерительные. Часть 9. Цифровой интерфейс для измерительных трансформаторов (преобразователей). Введ. 2025-12-01. М.: Российский институт стандартизации, 2025.
- [8] Котельников В.А. О пропускной способности эфира и проволоки в электросвязи // Успехи физических наук. 2006. Т. 176. № 7. С. 762-770.
- [9] ОИК «Систел». Сервер «SCADA». Программа для ЭВМ «ОИК «СИСТЕЛ». Сервер «SCADA». Руководство администратора. 2024. – 11 с.
- [10] Выбор сервера для искусственного интеллекта: основные критерии и рекомендации // Serverflow. [Электронный ресурс]. URL: <https://www.serverflow.ru> (дата обращения: 18.09.2025).
- [11] Елистратова Е., Губко П. Ансамбли в машинном обучении // Yandex Education. [Электронный ресурс]. URL: <https://www.education.yandex.ru> (дата обращения: 23.09.2025).
- [12] Ensemble-based methods for classification, regression and anomaly detection // scikit-learn. [Электронный ресурс]. URL: <https://www.scikit-learn.org> (дата обращения: 23.09.2025).
- [13] Hastie T., Tibshirani R., Friedman J. The elements of statistical learning: Data mining, inference, and prediction. New York: Springer, 2009. – p. 745.
- [14] McKinney W. Python for data analysis. Sebastopol: O'Reilly Media, 2013. – p. 450.

References

- [1] A.L. Kulikov, A.A. Loskutov and D.I. Bezdushnyj, "Improving the recognizability of emergency modes by relay protection using decision tree methods", *Elektrichestvo*, pp. 20-34, np. 7, 2023. DOI: 10.24160/0013-5380-2023-7-20-34
- [2] A.B. Osak, D.N. Efimov, A.V. Zhukov, D.A. Panasetskij, V.G. Kurbatskij, D.N. Sidorov, N.V. Tomin and N.I. Voropai, "A suite of intelligent tools for early detection and prevention of blackouts in power interconnections", *Avtomatika i telemekhanika*, no. 8, pp. 6-25, 2018. DOI: 10.31857/S000523100001845-3
- [3] A.A. Korshikova and A.G. Trofimov, "Model for early detection of emergency conditions in power plant equipment based on machine learning methods", *Teploenergetika*, no. 3, pp. 49-56, 2019. DOI: 10.1134/S0040363619030044).
- [4] M. Najafzadeh, J. Pouladi, A. Daghigh, J. Beiza and T. Abedinzade, "Fault detection, classification and localization along the power grid line using optimized machine learning algorithms", *International Journal of Computational Intelligence Systems*, vol. 17, art. no. 49, 2024. DOI: 10.1007/s44196-024-00434-7.

- [5] S. Averyanov and A. Trofimov, "Analysing non-ensemble machine learning methods for solving the transient classification problem", in *proc. 2025 IEEE 26th International Conference of Young Professionals in Electron Devices and Materials (EDM)*, Altai, Russia, 2025, pp. 1100-1105. DOI: 10.1109/EDM65517.2025.11096849
- [6] S.S. Averyanov and A.S. Trofimov, "Analiz faktorov, vliyayushchikh na intellektual'nyj algoritm klassifikatsii perekhodnykh processov i nadezhnost' ustroystv relejnoj zashchity [Analysis of factors affecting the intelligent algorithm for transient classification and reliability of relay protection devices]", in *proc. Metodicheskie voprosy issledovaniya nadezhnosti bol'shikh sistem energetiki*, Irkutsk, no. 76, pp. 794-803, 2025 (in Russian).
- [7] Instrument transformers. Part 9. Digital interface for instrument transformers, GOST R IEC 61869-9—2025, Jan. 2025.
- [8] V.A. Kotelnikov, "O propuskoy sposobе efira i provoloki v elektrosvyazi [On the transmission capacity of "ether" and wire in telecommunications]", *Uspekhi Fizicheskikh Nauk*, vol. 176, no. 7, pp. 762-770, 2006 (in Russian).
- [9] OIK "Sistel". Server "SCADA". Programma dlya EVM "OIK "SISTEL". Server "SCADA". Rukovodstvo administratora [OIC "Sistel". SCADA Server. Computer program "OIC "SISTEL". SCADA Server. Administrator's guide], 2024 (in Russian).
- [10] Vybor servera dlya iskusstvennogo intellekta: osnovnye kriterii i rekomendatsii [Choosing a server for artificial intelligence: main criteria and recommendations], Serverflow. [Online]. Available at: <https://www.serverflow.ru> [Accessed: Sept. 18, 2025] (in Russian).
- [11] E. Elistratova and P. Gubko, "Ansambli v mashinnom obuchenii [Ensembles in machine learning]", Yandex Education. [Online]. Available at: <https://www.education.yandex.ru> [Accessed: Sept. 23, 2025] (in Russian).
- [12] Ensemble-based methods for classification, regression and anomaly detection scikit-learn. [Online]. Available at: <https://www.scikit-learn.org> [Accessed: Sept. 23, 2025]
- [13] T. Hastie, R. Tibshirani and J. Friedman, *New The elements of statistical learning: Data mining, inference, and prediction*. New York: Springer, 2009.
- [14] W. McKinney, *Python for data analysis*. Sebastopol: O'Reilly Media, 2013.

ИНФОРМАЦИЯ ОБ АВТОРАХ INFORMATION ABOUT THE AUTHORS

Аверьянов Сергей Сергеевич, аспирант Новосибирского государственного технического университета, г. Новосибирск, Российская Федерация.

Sergey S. Averyanov, postgraduate student of the Novosibirsk State Technical University, Novosibirsk, Russian Federation.

Трофимов Андрей Сергеевич, кандидат технических наук, доцент Новосибирского государственного технического университета, г. Новосибирск, Российская Федерация.

Andrey S. Trofimov, Cand. Sci. (Eng.), associate professor of the Novosibirsk State Technical University, Novosibirsk, Russian Federation.