

ПРИМЕНЕНИЕ ГРАФОВЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РАСЧЕТА РЕЖИМОВ ЭЛЕКТРИЧЕСКИХ СЕТЕЙ

**В.А. Сурин, С.Э. Иванов, М.Э. Иванов, А.В. Коржов,
В.И. Сафонов, С.П. Кулик, Н.В. Малетин**

Южно-Уральский государственный университет, г. Челябинск, Российская Федерация
E-mail: surinva@susu.ru

Аннотация. Рассматривается применение графовых нейронных сетей для решения задачи расчета установившихся режимов электроэнергетических систем. Предложена математическая постановка, основанная на представлении энергосистемы в виде графа, а также разработана архитектура модели, сочетающая локальную регрессию параметров узлов и глобальную классификацию устойчивости режима. Для обучения использовались синтетические данные, сгенерированные на основе тестовой схемы. Проведенные вычислительные эксперименты продемонстрировали высокую точность аппроксимации параметров режима. Полученные результаты подтверждают перспективность применения графовых нейронных сетей для оперативного анализа режимов электроэнергетических систем.

Ключевые слова: графовые нейронные сети; задача потокораспределения; синтетические данные, область существования решения.

Введение

Анализ установившихся режимов – фундаментальный аспект проектирования и управления современными электроэнергетическими системами. С учетом энергетического перехода и массовой интеграции возобновляемых источников энергии сложность работы сетей возрастает, что требует точного контроля состояния системы в реальном времени для обеспечения надежности и предотвращения аварий.

Традиционно для расчета потокораспределения применяются итерационные численные методы, такие как метод Ньютона–Рафсона (NR), обеспечивающие высокую точность. Однако они тяжело масштабируются на крупные энергосистемы. Задача потока мощности нелинейна, и при росте числа шин метод NR требует колоссальных вычислительных ресурсов [1]. В системах из сотен или тысяч шин этот метод занимает значительное время из-за необходимости пересчета и факторизации большой матрицы Якоби на каждой итерации [2]. В качестве альтернативы активно развиваются методы машинного обучения [3], дающие быстрые аппроксимации решений. При этом предварительные эксперименты авторов с многослойными перцептронами (MLP) выявили их критические недостатки: склонность к переобучению, высокие требования к вычислительным мощностям и жесткую привязку к конкретной топологии сети [4, 5]. Любое изменение схемы делает полносвязную нейросеть непригодной без полного переобучения.

Поскольку электроэнергетические системы по своей природе имеют графовую структуру, наиболее адекватным решением становится применение графовых нейронных сетей (GNN). Они интегрируют топологическую информацию непосредственно в архитектуру через механизмы передачи сообщений между смежными узлами и ветвями [6]. GNN обладают реляционными индуктивными смещениями, обеспечивающими инвариантность к перестановкам узлов и локальную связность, что позволяет им обрабатывать графы произвольного размера и конфигурации без потери эффективности [7, 8].

Математическая постановка задачи

Математическая постановка задачи расчета установившегося режима в современных исследованиях основывается на представлении электрической сети в виде связного графа

$$G = (V, E),$$

где V – множество вершин графа, которые соответствуют вершинам (узлам) электросистемы, таким как электростанции, подстанции, крупные заводы и т. д.; E – множество ребер графа, которые отображают линии электропередачи.

Каждая вершина $v_i \in V$ характеризуется вектором физических величин, включающим действительную V_{re} и мнимую V_{im} части напряжения, а также активную P и реактивную Q мощности. Каждое ребро $e_i \in E$ также может характеризоваться вектором, включающим такие параметры, как активная проводимость g_{ij} , реактивная проводимость b_{ij} , коэффициент трансформации t_{ij} и предельная пропускная способность [6]. В рамках настоящей статьи пространство входных признаков ограничено исключительно характеристиками, заданными на вершинах графа V .

Физическая сущность задачи заключается в решении системы нелинейных алгебраических уравнений баланса мощностей, описывающих статическое состояние системы в соответствии с законами Кирхгофа и Ома. В декартовой форме уравнения баланса мощностей для активной и реактивной мощности в каждом узле i выражаются через действительные и мнимые компоненты напряжения узлов [9].

$$\begin{cases} P_i = \sum_{j \in N(i)} (V_i^{re} V_j^{re} + V_i^{im} V_j^{im}) G_{ij} + (V_i^{im} V_j^{re} - V_i^{re} V_j^{im}) B_{ij} \\ Q_i = \sum_{j \in N(i)} (V_i^{im} V_j^{re} + V_i^{re} V_j^{im}) G_{ij} + (V_i^{re} V_j^{re} - V_i^{im} V_j^{im}) B_{ij} \end{cases} \quad (1)$$

Для обеспечения корректности расчета узлы классифицируются по типам фиксируемых переменных: балансирующий узел ($V\delta$ -узел), выполняющий роль опорного с заданными действительной и мнимой частями напряжения, генераторные узлы (PV -узел), где фиксированы активная мощность и квадрат модуля напряжения; и нагрузочные узлы (PQ -узел), для которых заданы активная и реактивная мощности.

Помимо стандартной постановки задачи расчета потокораспределения дополнительно рассматривается устойчивость режима энергосистемы, а именно существование решения системы нелинейных уравнений баланса мощностей (1). Это соответствует анализу области допустимых режимов, в котором система уравнений имеет физически реализуемое решение.

На границе области существования решения наблюдается явление резкого падения напряжения, при котором малые изменения входных параметров приводят к исчезновению решения. С математической точки зрения это означает, что отображение $f_0: X \rightarrow Y$, аппроксимирующее решение уравнений (1), теряет непрерывность на границе допустимой области

$$\lim_{x \rightarrow x_0^-} f_0(x) \neq \lim_{x \rightarrow x_0^+} f_0(x).$$

Для устранения данной проблемы вводится расширенная многозадачная постановка, в которой задача декомпозируется на две взаимосвязанные подзадачи

$$f_0: X \rightarrow (Y_{reg}, Y_{cls}),$$

где Y_{reg} – действительная и мнимая части напряжения узлов; $Y_{cls} \in \{0, 1\}$ – индикатор существования реализуемого режима. В конечном итоге задача обучения сводится к совместной аппроксимации непрерывного отображения внутри области устойчивости и классификации границы существования решения.

Архитектура сети

Электроэнергетическая система моделируется в виде графа $G = (V, E)$, где каждому узлу $i \in V$ сопоставляется вектор входных признаков

$$x_i = [P_i, Q_i, t_i],$$

где P_i, Q_i – заданные значения активной и реактивной мощности в узле, положительные для генерации, отрицательные для нагрузки; V_i^{re} и V_i^{im} – действительная и мнимая части напряжения узла; t_i – one-hot вектор, кодирующий тип узла. Начальное скрытое представление узла полагается равным входному вектору $h_i^{(0)} = x_i$.

Для учета топологии сети используется стек графовых сверточных слоев. На k -м слое обновление скрытого состояния узла задается уравнением передачи сообщений

$$h_i^{(k+1)} = \sigma \left(W^{(k)} h_i^{(k)} + \sum_{j \in N(i)} W_n^{(k)} h_j^{(k)} \right),$$

где $N(i)$ – множество соседей узла; $W^{(k)}, W_n^{(k)}$ – матрицы весов сети; σ – функция активации $ReLU$. Для предотвращения переобучения применяется метод Dropout. Архитектура разделена на два функциональных модуля в соответствии с физической постановкой задачи.

Регрессионный модуль архитектуры аппроксимирует непрерывное отображение на локальном уровне, то есть на уровне узла

$$f_{reg} : h_i \rightarrow \hat{y}_i = \{V_i^{re}, V_i^{im}\}, \hat{y}_i = W_{reg} h_i + b_{reg},$$

где W_{reg} и b_{reg} – параметры линейного выходного слоя, $\hat{y}_i$ – выход модели регрессионного модуля, h_i – обрабатываемое сообщение в архитектуре сети. Функция активации отсутствует для обеспечения неограниченного диапазона предсказываемых величин.

Классификационный модуль архитектуры формирует оценку существования допустимого режима на основе агрегированного представления всей сети. Глобальный вектор вычисляется посредством усредняющего пулинга

$$h_G = \frac{1}{|V|} \sum_{i \in V} h_i.$$

Предсказание метрики класса – режим сходится или не сходится – осуществляется линейным преобразованием.

$$\hat{y}_{cls} = \sigma(W_{cls} h_G + b_{cls}),$$

где σ – сигмоидальная функция активации, ограничивающая выходное значение диапазоном от 0 до 1 включительно, $\hat{y}_{cls}$ – выход модели классификационного модуля, W_{cls} – матрица весов выходного слоя классификатора, b_{cls} – смещение выходного слоя классификатора.

Предложенная архитектура реализует естественное для задачи разделение ролей: локальная регрессия моделирует зависимость напряжения в узлах от локальных параметров режима, в то время как глобальная классификация агрегирует информацию со всех шин сети для оценки ее статической устойчивости. Такой подход служит основой для обработки разрывных отображений, возникающих на границе области существования решения.

Формирование набора данных и функция потерь

Для обучения предложенной графовой архитектуры была использована модельная схема электрической сети, состоящая из шести узлов, топология которой представлена на рис. 1. В ней первый узел – балансирующий ($P\delta$ -узел), остальные – узлы нагрузки (PQ -узлы).

Выбор данной конфигурации обусловлен её простотой формирования данных для обучения графовой архитектуры. Следует отметить, что основной проблемой при любой нейронной сети, основанной на глубоком обучении, традиционно является дефицит реальных эксплуатационных данных, которые часто недоступны исследователям из-за соображений конфиденциальности, коммерческой тайны или требований безопасности. Именно поэтому для обучения модели была использована синтетическая база данных. Как показано в работе [10], синтетические данные, генерируемые на основе физических моделей, способны эффективно воспроизводить статистические и физические характеристики реальных энергосистем без риска утечки информации.

Для формирования обучающей, валидационной и тестовой выборок было использовано программное обеспечение MathCad [11]. Программный модуль расчета реализовывал итерационное решение системы уравнений (1) для заданной топологии. Были сгенерированы данные как внутри области, так и на границе. Общий объем выборки составил около 11 000 режимов.




Рис. 1. Тестовая схема из 6 узлов

Специфика решаемой задачи требует использования составной функции потерь, поэтому итоговая функция потерь для графовой нейронной сети состоит из двух функций потерь для каждой части модели

$$\mathcal{L}_{total} = \mathcal{L}_{cls} + \mathcal{L}_{reg},$$

где $\mathcal{L}_{cls}$ – функция потерь классификационной составляющей; $\mathcal{L}_{reg}$ – функция потерь регрессионной составляющей.

Для регрессионного модуля была использована среднеквадратичная ошибка (MSE), однако ее вычисление производилось не для всех узлов графа, а лишь для тех, которые согласно сгенерированным данным находятся в активном режиме, для которых классификационная метка $y_i = 1$. Данный подход позволяет избежать смещения градиента в сторону доминирующего нормального режима и фокусирует обучение сети на предсказании значений именно в моменты отклонений. MSE для одного узла считалось по следующей формуле:

$$\ell_{mse}^{(k)} = \frac{1}{2} \left[\left(V_{re,k}^{pred} - V_{re,k}^{true} \right)^2 + \left(V_{im,k}^{pred} - V_{im,k}^{true} \right)^2 \right],$$

где $V_{re,k}^{pred}, V_{im,k}^{pred}$ – предсказанные значения действительной и мнимой частей напряжения на узле k , $V_{re,k}^{true}, V_{im,k}^{true}$ – соответствующие истинные значения на узле k . Итоговая регрессионная ошибка с учетом маскирования нормальных режимов записывается как

$$\mathcal{L}_{reg} = \frac{\sum_{i=1}^N \left(m_i \cdot \frac{1}{K} \sum_{k=1}^K \ell_{mse}^{(k)} \right)}{\sum_{i=1}^N m_i + \varepsilon},$$

где $m_i \in \{0,1\}$ – маска, соответствующая значению маски для i -го примера, $K = 6$ – количество шин в тестовой схеме, ε – малая константа для предотвращения деления на ноль в случае выборки без отклонений.

Функция потерь для классификационной составляющей определяет принадлежность среза данных к тому или иному режиму, которая была реализована на основе бинарной кросс-энтропии. Она обеспечивает численную стабильность вычислений за счет объединения сигмоидальной активации и расчета потерь в одном слое:

$$\mathcal{L}_{cls} = -\frac{1}{N} \sum_{i=1}^N \left[y_i \cdot \log(\sigma(\hat{y}_i)) + (1 - y_i) \cdot \log(1 - \sigma(\hat{y}_i)) \right],$$

где σ – сигмоидальная функция, $y_i \in \{0,1\}$ – истинная метка режима для i -го графа в одной выборке, $\hat{y}_i$ – выход классификатора.

Вычислительный эксперимент

Программная реализация нейросетевой архитектуры выполнялась на базе специализированной библиотеки для обработки графов PyTorch Geometric. В качестве базовой архитектуры была выбрана многозадачная графовая нейронная сеть пространственного типа на основе GraphConv. Обучение проводилось на компьютере с производительностью 82,6 TFLOPS.

Модель обучалась в течение 1000 эпох с использованием оптимизатора Adam с начальным значением скорости обучения $5 \cdot 10^{-5}$. Данный выбор обусловлен необходимостью обеспечения стабильной сходимости при обучении графовой нейронной сети с многозадачной функцией потерь, включающей сигмоидальную кросс-энтропию (BCE) для классификации и среднеквадратичную ошибку (MSE) для регрессии, а также предотвращения переобучения на ранних этапах.

Для дополнительной стабилизации процесса обучения использовалась L2-регуляризация с коэффициентом $\lambda = 10^{-6}$, а также адаптивное снижение скорости обучения с помощью планировщика ReduceLROnPlateau, который уменьшает скорость обучения в 2 раза при отсутствии улучшения функции потерь на валидационной выборке в течение 20 эпох. Контроль переобучения осуществлялся по динамике функции потерь на валидационной выборке. На рис. 2 представлены кривые обучения модели, которые показывают монотонное снижение функции

потерь и устойчивую сходимость модели. При этом разрыв между обучающей и валидационной выборками минимален, что свидетельствует о хорошей обобщающей способности модели.




Рис. 2. Кривая обучения графовой нейронной сети

Эффективность регрессионной части модели оценивалась с использованием метрик средне-квадратичной ошибки (MSE), средней абсолютной ошибки (MAE) и коэффициента детерминации R^2 . Классификационная часть оценивалась по метрикам Accuracy и F1-score. Итоговые значения метрик приведены в таблице.

Результаты работы модели

Тип задачи	Метрика	Обучающая выборка	Валидационная выборка
Классификация	Accuracy	0,9898	0,9912
	F1-score	0,9930	0,9939
Регрессия	MAE	0,029033	0,035787
	MSE	0,004127	0,003865
	R^2	0,9946	0,9951

Результаты экспериментов демонстрируют, что предложенная графовая нейросетевая архитектура позволяет восстанавливать параметры электрического режима с высокой точностью ($R^2 = 0,995$), сопоставимой с погрешностью исходных численных методов. Классификационная компонента модели также показывает высокую эффективность ($F_1 = 0,994$) – практически безошибочно идентифицирует границу области существования решения, что важно для нашей задачи.

Несмотря на высокие значения усредненных метрик, для практического применения в задачах диспетчеризации критической характеристикой является не средняя, а максимальная ошибка на отдельных узлах. В связи с этим был выполнен дополнительный анализ распределения абсолютной погрешности определения модуля напряжения на валидационной выборке. Установлено, что для 95 % проанализированных узлов ошибка не превышает 4,1 %, а медианное значение погрешности составляет менее 0,8 %. Абсолютный максимум ошибки зафиксирован на уровне 25,6 %, что соответствует пограничным режимам вблизи области несуществования решения, где даже классические численные методы демонстрируют вычислительную неустойчивость. Распределение ошибки (рис. 3) подтверждает надежность модели в большинстве нормальных состояний сети; значительные отклонения характерны лишь для недопустимых или аварийных режимов.



Рис. 3. Распределение абсолютной ошибки предсказания модуля напряжения по узлам сети

Сравнение с альтернативным подходом, выполненным в работе [12], показывает, что при фиксированной топологии сети простые полносвязные архитектуры демонстрируют точность, сопоставимую с графовыми сетями (MSE порядка $10^{-5} - 10^{-4}$ отн. ед.). Однако в [12] рассматривается задача внутри области устойчивости, где отображение является гладким. В настоящем исследовании основное внимание уделено наиболее сложному сегменту – границе области существования решения, что принципиально усложняет задачу аппроксимации. В связи с этим достигнутый уровень точности следует рассматривать как отправную точку для дальнейших исследований, а не как конечный результат.

Заключение

В работе исследовано применение графовых нейронных сетей для расчета установившихся режимов энергосистем. Предложенная архитектура из регрессионной и классификационной составляющих обеспечила одновременное восстановление параметров режима и оценку устойчивости системы. Эксперименты на синтетических данных подтвердили высокую точность аппроксимации в большинстве эксплуатационных состояний. Установлено, что максимальные погрешности локализуются вблизи границы области существования решения, где традиционные численные методы также нестабильны. Это подчеркивает сложную нелинейность пограничных режимов и определяет вектор доработки модели.

В отличие от полносвязных сетей, выбранная архитектура концептуально независима от размерности входа. Механизмы передачи сообщений создают фундаментальные предпосылки для работы с динамически меняющимися топологиями без полного переобучения сети и для существенного ускорения расчетов.

Дальнейшие исследования будут направлены на эмпирическое подтверждение инвариантности модели к структурным изменениям, масштабирование на крупные сети и профилирование вычислительной эффективности алгоритма в задачах оперативной диспетчеризации.

Исследование выполнено при финансовой поддержке Министерства науки и высшего образования Российской Федерации (государственное задание № FENU-2026-0004 «Классические, нейросетевые и квантовые оптимизационные алгоритмы для решения задач оперативно-диспетчерского управления объектами электроэнергетики»).

Литература

1. Fast Newton–Raphson Power Flow Analysis based on Sparse Techniques and Parallel Processing / A. Ahmadi, M. C. Smith, E. R. Collins *et al.* // IEEE Transactions on Power Systems. – 2022. – Vol. 37, no. 3. – P. 1695–1705.
2. Kulworawanichpong, T. Simplified Newton–Raphson Power-Flow Solution Method / T. Kulworawanichpong // International Journal of Electrical Power & Energy Systems. – 2010. – Vol. 32, no. 6. – P. 551–558.
3. Pham, T. Neural Network-based Power Flow Model / T. Pham, X. Li // arXiv. – 2021. <https://arxiv.org/abs/2112.08418>.
4. Boccato, T. Breaking the Structure of Multilayer Perceptrons with Complex Topologies / T. Boccato, M. Ferrante, A. Duggento, N. Toschi // Proceedings of the 2nd Annual Workshop on Topology, Algebra, and Geometry in Machine Learning (TAG-ML) at the 40th International Conference on Machine Learning, Honolulu, Hawaii, USA. – 2023.
5. Multilayer Perceptron Architecture Optimization using Parallel Computing Techniques / W. Castro, J. Oblitas, R. Santa-Cruz, J. Avila-George // PLoS ONE. – 2017. – Vol. 12, no. 12. – p. e0189369.
6. Applications of Graph Computing and Graph Neural Networks in Power Systems: A Survey / J. Lu, H. Tan, R. Zhao *et al.* // Proc. 2024 China International Conference on Electricity Distribution (CICED). – 2024. – P. 543–548.
7. Graph Neural Networks: A Review of Methods and Applications / J. Zhou, G. Cui, Z. Zhang *et al.* // arXiv preprint. – 2018. – arXiv:1812.08434.
8. A Gentle Introduction to Graph Neural Networks / B. Sanchez-Lengeling, E. Reif, A. Pearce, A.B. Wiltschko // Distill. – 2021. – Vol. 6, no. 9. – P. e33.
9. Шиманская-Семёнова, Т.А. Применение матричных моделей для расчета и анализа режимов электрических сетей / Т. А. Шиманская-Семёнова. – Минск: БНТУ, 2010. – 158 с.

10. Computationally Efficient Data Synthesis for AC-OPF: Integrating Physics-Informed Neural Network Solvers and Active Learning / J. Zhang, R. Peng, C. Lu, C. Wu // *Applied Energy*. – 2025. – Vol. 378, Part A. – P. 124714.

11. PTC Mathcad Prime 11 [Электронный ресурс] // PTC. – 2026. – What's new in PTC Mathcad Prime 11. – Режим доступа: <https://www.ptc.com/en/products/mathcad/whats-new> (дата обращения: 11.04.2026).

12. Falconer, T. Leveraging Power Grid Topology in Machine Learning Assisted Optimal Power Flow / T. Falconer, L. Mones // *IEEE Transactions on Power Systems*. – 2023. – Vol. 38, no. 3. – P. 2234–2246.

Поступила в редакцию 14 апреля 2026 г.

Сведения об авторах

Сурин Владимир Анатольевич – кандидат технических наук, доцент центра ОП топ-уровня в сфере ИИ «ВиртУм», Южно-Уральский государственный университет, г. Челябинск, Российская Федерация, e-mail: surinva@susu.ru.

Иванов Сергей Эдуардович – студент, кафедра прикладной математики и программирования, Южно-Уральский государственный университет, г. Челябинск, Российская Федерация, e-mail: ivanovse@susu.ru.

Иванов Максим Эдуардович – студент, кафедра прикладной математики и программирования, Южно-Уральский государственный университет, г. Челябинск, Российская Федерация, e-mail: ivanovme@susu.ru.

Коржов Антон Вениаминович – доктор технических наук, доцент, первый проректор – проректор по научной работе, Южно-Уральский государственный университет, г. Челябинск, Российская Федерация, e-mail: korzhovav@susu.ru.

Сафонов Валерий Иванович – кандидат физико-математических наук, доцент, кафедра электрических станций, сетей и систем электроснабжения, Южно-Уральский государственный университет, г. Челябинск, Российская Федерация, e-mail: safonovvi@susu.ru.

Кулик Сергей Павлович – доктор физико-математических наук, главный научный сотрудник управления научной и инновационной деятельности, Южно-Уральский государственный университет, г. Челябинск, Российская Федерация, e-mail: kuliksp@susu.ru.

Малетин Николай Владимирович – научный сотрудник управления научной и инновационной деятельности, Южно-Уральский государственный университет, г. Челябинск, Российская Федерация, e-mail: maletinnv@my.msu.ru.

Bulletin of the South Ural State University
Series "Mathematics. Mechanics. Physics"
2026, vol. 18, no. 2, pp. 39–46

DOI: 10.14529/mmph260205

APPLICATION OF GRAPH NEURAL NETWORKS FOR CALCULATING STEADY-STATE MODES OF ELECTRICAL POWER SYSTEMS

V.A. Surin, S.E. Ivanov, M.E. Ivanov, A.V. Korzhov, V.I. Safonov, S.P. Kulik, N.V. Maletin

South Ural State University, Chelyabinsk, Russian Federation

E-mail: surinva@susu.ru

Abstract. This paper considers the application of graph neural networks for solving the problem of calculating steady-state modes of electrical power systems. A mathematical formulation based on representing the power system as a graph is proposed, and a model architecture combining local regression of node parameters and global classification of mode stability is developed. Synthetic data generated based on a standard test scheme were used for training. The conducted computational experiments demonstrated high accuracy in approximating the mode parameters. The obtained results confirm the promising potential of applying graph neural networks for accelerated analysis of electrical power system modes.

Keywords: Graph neural networks, power flow problem, synthetic data, solution existence region.

References

1. Ahmadi A., Smith M.C., Collins E.R., Dargahi V., Jin S. Fast Newton–Raphson Power Flow Analysis based on Sparse Techniques and Parallel Processing. *IEEE Transactions on Power Systems*, 2022, Vol. 37, no. 3, pp. 1695–1705. DOI: 10.1109/TPWRS.2021.3116182.
2. Kulworawanichpong T. Simplified Newton–Raphson Power-Flow Solution Method. *International Journal of Electrical Power & Energy Systems*, 2010, vol. 32, no. 6, pp. 551–558. DOI: 10.1016/j.ijepes.2009.11.011.
3. Pham T., Li X. Neural Network-based Power Flow Model. *arXiv*, 2021. DOI: 10.48550/arXiv.2112.08418.
4. Boccato T., Ferrante M., Duggento A., Toschi N. Breaking the Structure of Multilayer Perceptrons with Complex Topologies. *Proc. 2nd Annual Workshop on Topology, Algebra, and Geometry in Machine Learning (TAG-ML) at the 40th International Conference on Machine Learning*, Honolulu, Hawaii, USA, 2023.
5. Castro W., Oblitas J., Santa-Cruz R., Avila-George H. Multilayer Perceptron Architecture Optimization using Parallel Computing Techniques. *PLoS ONE*, 2017, Vol. 12, no. 12, e0189369. DOI: 10.1371/journal.pone.0189369
6. Lu J., Tan H., Zhao R., Guo W., Zhen D., Ping L. Applications of Graph Computing and Graph Neural Networks in Power Systems: A Survey. *Proc. 2024 China International Conference on Electricity Distribution (CICED)*, 2024, pp. 543–548. DOI: 10.1109/CICED63421.2024.10754312
7. Zhou J., Cui G., Hu S., Zhang Z., Yang C., Liu Z., Wang L., Li C., Sun M. Graph Neural Networks: A Review of Methods and Applications. *arXiv preprint*, arXiv:1812.08434, 2018. DOI: 10.48550/arXiv.1812.08434
8. Sanchez-Lengeling B., Reif E., Pearce A., Wiltchko A.B. A Gentle Introduction to Graph Neural Networks. *Distill*, 2021, Vol. 6, no. 9, p. e33. DOI: 10.23915/distill.00033.
9. Shimanskaya-Semyenova T.A. *Primenenie matrichnykh modeley dlya rascheta i analiza rezhimov elektricheskikh setey* (Application of Matrix Models for Calculation and Analysis of Electric Grid Modes). Minsk, BNTU Publ., 2010, 158 p. (in Russ.).
10. Zhang J., Peng R., Lu C., Wu C. Computationally Efficient Data Synthesis for AC-OPF: Integrating Physics-Informed Neural Network Solvers and Active Learning. *Applied Energy*, 2025, Vol. 378, Part A, p. 124714. DOI: 10.1016/j.apenergy.2024.124714.
11. What's new in PTC Mathcad Prime 11. <https://www.ptc.com/en/products/mathcad/whats-new>.
12. Falconer T., Mones L. Leveraging Power Grid Topology in Machine Learning Assisted Optimal Power Flow. *IEEE Transactions on Power Systems*, 2023, Vol. 38, no. 3, pp. 2234–2246. DOI: 10.1109/TPWRS.2022.3187218.

Received April, 14, 2026

Information about the authors

Surin Vladimir Anatol'evich is Cand. Sc. (Engineering), Associate Professor at the Center of Excellence in AI, “VirtUm” – a Top-Tier Educational Program, South Ural State University, Chelyabinsk, Russian Federation, e-mail: surinva@susu.ru.

Ivanov Sergey Eduardovich is Undergraduate Student, Department of Applied Mathematics and Programming, South Ural State University, Chelyabinsk, Russian Federation, e-mail: ivanovse@susu.ru.

Ivanov Maksim Eduardovich is Undergraduate Student, Department of Applied Mathematics and Programming, South Ural State University, Chelyabinsk, Russian Federation, e-mail: ivanovme@susu.ru.

Korzhov Anton Veniaminovich is Dr. Sc. (Engineering), Vice-Rector for Research, South Ural State University, Chelyabinsk, Russian Federation, e-mail: korzhovav@susu.ru.

Safonov Valeriy Ivanovich is Cand. Sc. (Physics and Mathematics), Associate Professor of the Department Electric Power Generation Stations, Networks and Supply Systems, South Ural State University, Chelyabinsk, Russian Federation, e-mail: safonovvi@susu.ru.

Kulik Sergey Pavlovich is Dr. Sc. (Physics and Mathematics), Principal Researcher of the Research & Innovation Services, South Ural State University, Chelyabinsk, Russian Federation, e-mail: kuliksp@susu.ru.

Maletin Nikolay Vladimirovich is Researcher, Research & Innovation Services, South Ural State University, Chelyabinsk, Russian Federation, e-mail: maletinnv@my.msu.ru.