DOI: 10.24892/RIJIE/20260301

Оценка состояния распределительной сети в условиях неполной наблюдаемости*

Шакиров В.А., Самаркина Е.В., Корнев В.Н., Пионкевич В.А.
Иркутский национальный исследовательский технический университет
г. Иркутск, Российская\ Федерация
shakirovva@ex.istu.edu

Аннотация. **В статье рассматривается задача оценки состояния распределительной электрической сети в условиях низкой наблюдаемости, когда измерения доступны только на части трансформаторных подстанций. Предложен гибридный подход, сочетающий нейронную сеть с физически-информированным слоем. Нейросеть предсказывает активные и реактивные нагрузки ненаблюдаемых узлов на основе данных о напряжениях и нагрузках наблюдаемых узлов, топологии сети, времени суток и года. Полученные оценки нагрузок вместе с известными нагрузками наблюдаемых узлов подаются в физический слой, где рассчитываются напряжения во всех узлах. Для тестовой распределительной сети из 16 подстанций, 4 из которых наблюдаемы, сформирован годовой датасет почасовых режимов с учётом сезонных и стохастических вариаций нагрузок, а также пяти возможных конфигураций сети. Полученные значения средней абсолютной ошибки (MAE) для активной мощности составили 12,35 кВт, для реактивной – 7,03 кВар, для напряжения – $1{,}5\cdot10^{-4}$ о.е. Результаты демонстрируют высокую точность восстановления режима, особенно уровней напряжения, и подтверждают применимость предложенного подхода.**

Ключевые слова: **распределительная сеть, наблюдаемость, режим, нейронная сеть, физически-информированный слой.**

Введение

Согласно энергетической стратегии Российской Федерации на период до 2050 года, необходимо повысить уровень технического состояния объектов распределительного сетевого комплекса, в том числе в части модернизации оборудования, внедрения цифровых технологий и автоматизированных систем управления. В соответствии с целевым сценарием планируется сокращение уровня потерь в электрических сетях до 7,3 процента. В комплекс первоочередных мер по решению задачи повышения эффективности функционирования электроэнергетики путем обеспечения взаимоувязанного регулирования в разных секторах энергетики и формирования системы долгосрочного устойчивого заказа на высокотехнологичное оборудование преимущественно отечественного производства входят: оптимизация работы распределительных электрических сетей, в том числе путем роста их пропускной способности за счет внедрения современных технологий, снижения потерь и повышения энергоэффективности; расширение использования интеллектуальных систем учета электрической энергии (мощности) и эффективное обеспечение объектов электросетевого комплекса цифровыми дистанционными устройствами управления.

Для практической реализации указанных стратегических задач и мер, таких как оптимизация режимов работы сетей, внедрение цифровых технологий и автоматизированных систем управления необходима точная и актуальная оценка состояния распределительных сетей в реальном времени. Обеспечение наблюдаемости электрических сетей является одним из первых и необходимых этапов для внедрения систем управления распределительными сетями. В наблюдаемой и управляемой распределительной сети могут быть решены задачи повышения эффективности ее функционирования: снижение потерь мощности, обеспечение допустимых уровней напряжения, оптимизация потокораспределения с учетом пропускной способности элементов сети, снижение длительности послеаварийных режимов.

Из-за большой общей протяженности и разветвленности, отсутствия средств телеизмерения распределительные сети являются фактически ненаблюдаемы. Информация об уровне напряжения, токе доступны только на питающих подстанциях. Данные о нагрузках на подстанциях 6-10 кВ собирают посредством инструментальных измерений дважды в год – в период зимнего максимума и летнего минимума нагрузки [1]. Таким образом, возникает задача оценки состояния режима сети в условиях низкой наблюдаемости.

Задача оценки состояния является одной из ключевых функций в управлении и контроле в реальном времени современных электрических распределительных сетей [2, 3]. Процесс оценки состояния распределительной сети характеризуется последовательностью нескольких шагов: сбор данных, топологический анализ, анализ наблюдаемости, оценка состояний сети и анализ некорректных данных [4]. В статье основное внимание уделяется оценке состояний сети, что включает определение векторов напряжения в узлах и/или тока, мощности в ответвлениях распределительной сети.

Из-за сложной конфигурации сети, ограниченного количества измерительных устройств, несинхронности измеряемых данных в этих сетях задача оценки состояния сталкивается со многими трудностями [2]. Хотя оценка состояния широко используется в магистральных электрических сетях, методы оценки состояния не могут быть прямо адаптированы в распределительные сети из-за специфики последних: радиальная структура, большое количество узлов, высокое отношение R/X линий электропередачи, плохая наблюдаемость и неточность параметров сети [2]. Кроме того, методы оценки состояния магистральных сетей могут

* Статья публикуется по рекомендации программного комитета Всероссийской научно-технической конференции "Пром-Инжиниринг", https://icie-rus.org

иметь проблемы сходимости или не обеспечивать высокоточные результаты оценки в распределительных сетях [3, 4]. Так, например, в исследовании [1] показана недопустимость оценки перетоков мощности по участкам линии при использовании предположения о пропорциональности нагрузки установленной мощности распределительных трансформаторов. Одним из основных факторов, усложняющих задачу оценки состояния, является низкая оснащенность измерительными приборами распределительных сетей и ограниченные финансовые возможности для масштабного внедрения таких приборов [5]. Поэтому в мире проводятся исследования, направленные на повышение точности оценки состояния в условиях ограниченной наблюдаемости сети. Важной задачей в этой области является оптимизация размещения измерительных приборов, позволяющих передавать информацию о режиме [5, 6].

В последние десятилетия многие исследователи развивали классические подходы, такие как метод Ньютона [7], линейное программирование [8] или градиентный спуск [9]. В основе подходов лежит итеративный поиск, основанный на оценке методом взвешенных наименьших квадратов [2, 4]. Были также предложены некоторые другие методы, основанные на фильтре Калмана [2, 4]. Однако эти методы имеют некоторые недостатки. Эти недостатки связаны с использованием допущений о непрерывности и дифференцируемости уравнений, с неспособностью преодолеть локальные минимумы, проблемы несходимости решения [4]. Алгоритмы искусственного интеллекта, эвристические алгоритмы оптимизации позволяют преодолеть отмеченные проблемы [2, 4]. Высокую эффективность показывают физически-информированные нейронные сети, которые учитывают физические законы потокораспределения в электрических сетях [10]. В целом, исследования по оценке состояния направлены на снижение вычислительных ресурсов, поиск оптимального решения с учетом локальных оптимумов, возможность использования с неполными и неточными данными.

Для решения задачи оценки состояния исходные данные могут быть получены следующим образом. Центры питания распределительных сетей обычно имеют телеизмерения: напряжение на шинах, суммарную активную и реактивную нагрузку, токовую нагрузку фидеров. При наличии реклоузеров дополнительно можно иметь информацию о токе участка и напряжении узла по месту его установки. Трансформаторные подстанции 6-10/0,4 кВ могут быть оснащены интеллектуальными приборами учета, позволяющими передать данные о мощности нагрузки и напряжении на стороне 0,4 кВ. Анализ данных интеллектуальных приборов учета позволяет сформировать статистику по закономерностям электропотребления. При отсутствии данных интеллектуальных приборов учета могут формироваться синтетические графики электропотребления на основе методов расчета нагрузок, учета стохастики и закономерностей электропотребления характерных потребителей. Исследования показывают допустимость и эффективность такого подхода [11].

В статье рассматривается подход к оценке режима участка городской распределительной сети с неполной наблюдаемостью с использованием нейронных сетей и учетом физических законов потокораспределения.

Модель оценки состояния участка сети в условиях низкой наблюдаемости

На рис. 1 представлена схема подхода к оценке состояния сети в условиях низкой наблюдаемости.

Для реализации предлагаемого подхода необходима информация о конфигурации и параметрах сети.

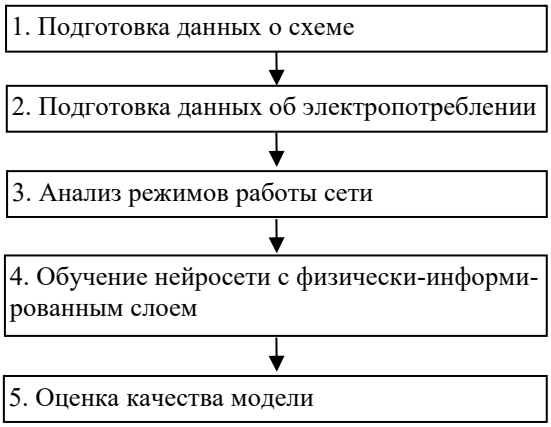

Рис. 1. Схема подхода к оценке состояния сети в условиях низкой наблюдаемости

Топология сети задаётся перечнем узлов, включая питающие шины с известными напряжениями, и линий, соединяющих узлы. Для каждой линии указывается номинальное напряжение, протяженность, а также удельные активные и реактивные сопротивления. Для участков сетей с двухсторонним питанием дополнительно определяются возможные точки разрыва сети. Для постановки задачи оценки состояния в условиях низкой наблюдаемости задается подмножество узлов, на которых доступны измерения напряжений и нагрузок.

На этапе 2 проводится формирование почасовых профилей активной и реактивной нагрузки для всех трансформаторных подстанций рассматриваемого участка сети с использованием разработанной программы на языке Python. Используется информация о номинальной мощности трансформаторов, о типе подключенных потребителей (жилая застройка, коммерческие объекты, промышленные предприятия с различными режимами работы, социальные учреждения и др.). Суточные профили формируются на основе данных измерений, а при их отсутствии используются характерные для преобладающих потребителей профили нагрузок. На основе сформированных суточных профилей проводится формирование годового графика электропотребления активной мощности с часовой детализацией. При формировании учитывается сезонные изменения нагрузок, стохастические вариации (случайные всплески и сдвиги пиковых нагрузок). Реактивная нагрузка определяется путём генерации фактического коэффициента мощности в заданных пределах для каждого часа, что позволило учесть естественную вариабельность коэффициента мощности.

Далее проводится обучение модели по схеме, представленной на рис. 2.

На этапе 3 для каждого часа из сформированного годового профиля нагрузок и каждого возможного положения точки разрыва в среде pandapower выполняется расчёт установившегося режима. Входными данными служат активные

и реактивные нагрузки всех узлов, параметры линий и напряжения на питающих шинах. В результате расчёта определяются напряжения во всех узлах сети. Полученные данные образуют обучающий датасет: для каждого сочетания часа и точки разрыва сохраняются напряжения и нагрузки на заданном подмножестве наблюдаемых узлов, информация о текущей топологии, а также истинные нагрузки всех узлов и рассчитанные напряжения, которые используются в дальнейшем при обучении и оценке модели.

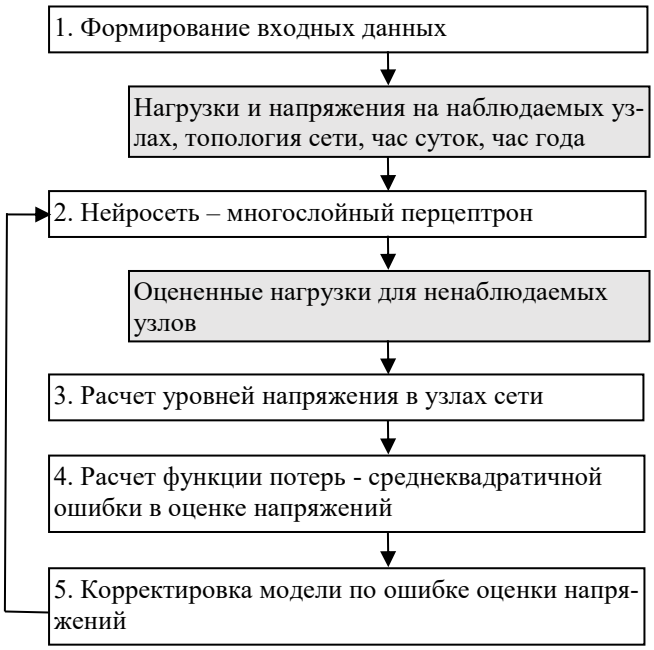

Рис. 2. Структура обучения нейросети с физически информированным слоем

На рис. 2 представлена структура обучения модели. Нейросеть оценивает активные и реактивные нагрузки для ненаблюдаемых узлов. Эти оценки объединяются с реальными нагрузками наблюдаемых узлов, и полный вектор нагрузок всех узлов подаётся в блок «Расчёт уровней напряжения в узлах сети», где на основе параметров сети и текущей топологии рассчитываются напряжения во всех узлах. Далее в блоке «Расчёт функции потерь» определяется среднеквадратическая ошибка между рассчитанными напряжениями на наблюдаемых узлах и их измеренными значениями. Полученная невязка передаётся в блок «Корректировка модели по ошибке оценки напряжений», где градиент ошибки распространяется через физический слой и обновляет веса нейросети. Функция потерь имеет вид:

$$L = MSE\left(U_{calc}^{obs}; U_{true}^{obs}\right) + \lambda \cdot MSE\left(P_{calc}^{obs}; P_{true}^{obs}\right) \quad (1)$$

где MSE – среднеквадратичная ошибка; $U_{calc}^{obs}; U_{true}^{obs}$ – модельное и истинное значение напряжение на наблюдаемых подстанциях; λ – весовой коэффициент; $P_{calc}^{obs}; P_{true}^{obs}$ – модельное и истинное значение активной нагрузки на наблюдаемых подстанциях.

Первое слагаемое обеспечивает соответствие расчётных напряжений на наблюдаемых узлах их измеренным значениям, второе – помогает нейросети быстрее обучаться предсказывать нагрузки в нормализованном пространстве.

Обновлённая нейросеть снова обрабатывает входные данные – процесс повторяется итерационно. Обучение завершается по достижении заданного числа эпох или при стабилизации значения функции потерь.

Оценка качества модели проводится с использованием показателей средней абсолютной ошибки MAE, корень среднеквадратичной ошибки RMSE

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i|, \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}, \quad (2)$$

где n – количество сопоставлений; y_i – фактическое значение; $\hat{y}_i$ – предсказанное значение.

Применение модели и оценка ее точности

Для анализа точности модели была сформирована распределительная сеть с 16 подстанциями, 4 из которых – 4, 7, 13 и 15 были приняты наблюдаемыми (рис. 3). Подстанции получают питание 10 кВ от шин двух подстанций. Одна из линий 7-11 всегда находится в отключенном состоянии.

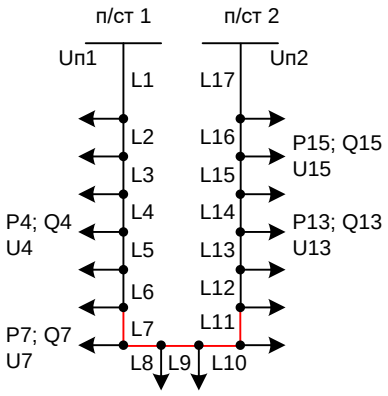

Рис. 3. Схема участка распределительной сети

В соответствии с этапом 2 (рис. 1) были сформированы суточные профили подстанций и далее годовые графики часового разрешения. На рис. 4 показаны недельные профили.

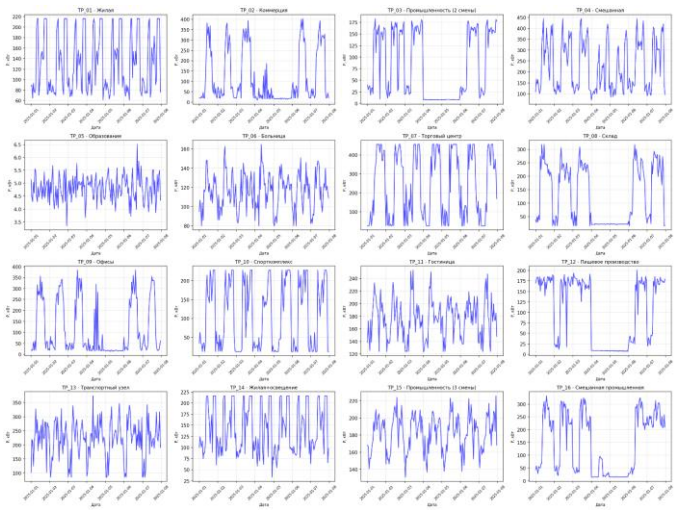

Рис. 4. Недельные профили электрических нагрузок подстанций

В табл. 1 показаны уровни нагрузки подстанций, а также преобладающий тип потребителей.

Таблица 1

Нагрузки трансформаторных подстанций, кВт

ТП	Минимальная	Максимальная	Средняя	Потребители
1	10,8	216,0	103,5	Жилой сектор
2	4,9	104,5	44,1	Коммерческий сектор
3	8,9	408,0	104,1	Промышленность (2 смены)
4	5,3	262,9	61,7	Смешанная
5	6,4	192,0	81,3	Образование
6	3,1	113,7	43,9	Больница
7	23,7	444,0	178,5	Торговый центр
8	11,1	238,7	86,3	Складские помещения
9	2,9	192,0	27,1	Офисы
10	1,9	126,6	16,8	Спорткомплекс
11	25,0	240,0	123,4	Гостиничный комплекс
12	7,9	91,1	40,3	Пищевое производство
13	5,4	456,0	172,3	Транспортный узел
14	2,8	282,6	97,8	Жилой сектор
15	8,5	324,0	119,1	Промышленность (3 смены)
16	4,5	183,5	61,1	Смешанная промышленная

Для каждого часа и каждой из пяти возможных конфигураций сети (разрыв на линиях 7, 8, 9, 10 или 11) в среде pandapower выполнялся расчёт установившегося режима. Напряжения на питающих шинах задаются с вариацией в пределах 5%. В результате расчета получены значения напряжений на всех узлах и перетоков мощности. Сформирован датасет, содержащий для каждой конфигурации сети: вектор из 21 признаков: 4 значения напряжения на наблюдаемых узлах, 8 значений активной и реактивной нагрузки в наблюдаемых узлах, 2 значения напряжения питающих шин, час суток, час года, кодировка топологии сети (код из 5 значений). Датасет разделён на три части по временному принципу: обучающий – 7000 часов (35000 сценариев); валидационный – 1000 часов (5000 сценариев); тестовый – 760 часов (3800 сценариев).

Нейросеть в модели представляет собой многослойный перцептрон со структурой: входной слой (21 признак), три скрытых слоя с 128, 256 и 128 нейронами, выходной слой. После каждого скрытого слоя использованы пакетная нормализация, активация ReLU и процедура dropout с параметром 0,2, для регуляризации.

При обучении в функции штрафа (1) параметр λ принят 0,1, что обеспечивает доминирование физической части при сохранении полезного влияния дополнительной информации о нагрузках на сходимость.

Модель предсказывала активные и реактивные нагрузки для 12 ненаблюдаемых узлов. Качество восстановления состояния сети оценивалось по следующим метрикам: MAE и RMSE для активной мощности *P*, реактивной мощности *Q*, напряжения *U*. На рис. 5-7 приведены результаты оценки метрик.

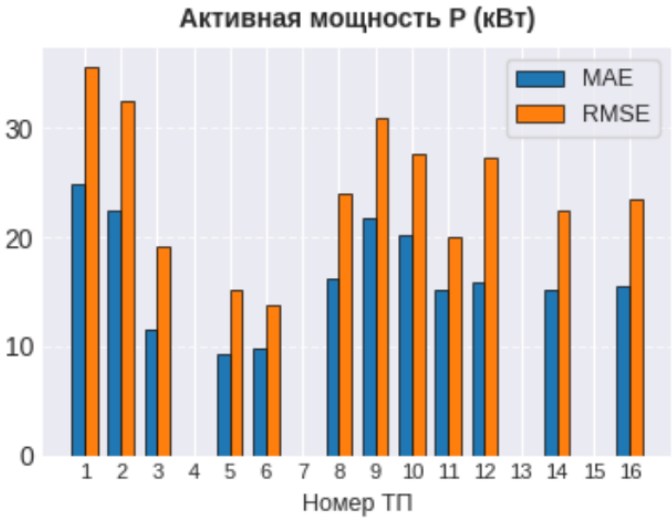

Рис. 5. Метрики оценки активной нагрузки ТП

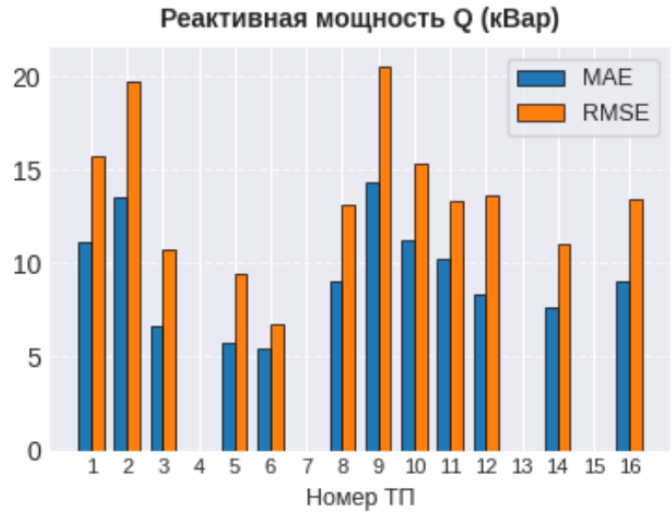

Рис. 6. Метрики оценки реактивной нагрузки ТП

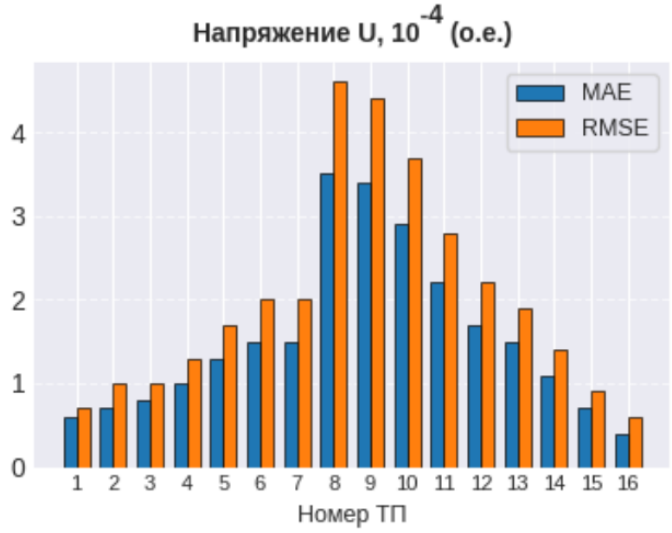

Рис. 7. Метрики оценки напряжений ТП

Полученные результаты свидетельствуют о высокой точности восстановления режима, особенно напряжений.

Заключение

Предложенный оригинальный гибридный подход сочетает физически-информированную нейронную сеть и точный расчёт установившихся режимов. В отличие от классических методов оценки состояния, требующих избыточности измерений, разработанная модель позволяет восстанавливать полный режим сети по данным измерений с части подстанций. Обучение нейросети осуществляется минимизацией ошибки между рассчитанными и измеренными напряжениями на наблюдаемых узлах. Благодаря такой архитектуре итоговое решение автоматически удовлетворяет законам Кирхгофа, а использование pandapower на этапе подготовки данных и финального применения модели гарантирует точное соблюдение баланса мощностей и позволяет получать физически непротиворечивые результаты.

Литература

1. Ванин А.С. Оценка необходимого объёма информации для решения задач управления отклонением напряжения и потерями в распределительных электрических сетях / А.С. Ванин, Ю.В. Шаров // Управление качеством электрической энергии: сб. тр. Междунар. научно-практической конференции. – 2018. – С. 42-47.

2. Zeraati M. A novel state estimation method for distribution networks with low observability based on linear AC optimal power flow model / M. Zeraati, M.R. Sheibani, F. Jabari, E. Heydarian-Forushani // Electric Power Systems Research. – 2024. – Vol. 228. – Art. 110085. – DOI: 10.1016/j.epsr.2023.110085.

3. Vanin M. A framework for constrained static state estimation in unbalanced distribution networks / M. Vanin, T. Van Acker, R. D'hulst, D. Van Hertem // 17th International Conference on Probabilistic Methods Applied to Power Systems). – 2022. – P. 1–11. – DOI: 10.1109/PMAPS53380.2022.9810582.

4. Adjerid H. Multi-agent system-based decentralized state estimation method for active distribution networks / H. Adjerid, A.R. Maouche // Computers & Electrical Engineering. – 2020. – Vol. 86. – Art. 106652. – DOI: 10.1016/j.compeleceng.2020.106652.

5. Anguswamy M.P. Optimal micro-PMU placement in distribution networks considering usable zero-injection phase strings / M.P. Anguswamy, M. Datta, L. Meegahapola, A. Vahidnia // IEEE Transactions on Smart Grid. – 2022. – Vol. 13. – P. 3662-3675. – DOI: 10.1109/TSG.2022.3174917.

6. Ferreira D.M.V.P. Optimal meter placement in low observability distribution networks with DER / D.M.V.P. Ferreira, P.M.S. Carvalho, L.A.F.M. Ferreira // Electric Power Systems Research. – 2020. – Vol. 189. – Art. 106707. – DOI: 10.1016/j.epsr.2020.106707.

7. Li K. A distributed Gauss–Newton method for distribution system state estimation / K. Li, X. Han // International Journal of Electrical Power & Energy Systems. – 2022. – Vol. 136. – Art. 107694. – DOI: 10.1016/j.ijepes.2021.107694.

8. Rana M.M. Distributed state estimation for microgrids / M.M. Rana, L. Li, S.W. Su // IFAC-PapersOnLine. – 2017. – Vol. 50. – P. 10202-10207. – DOI: 10.1016/j.ifacol.2017.08.1770.

9. Dag H. Toward improved uses of the conjugate gradient method for power system applications / H. Dag, F.L. Alvarado // IEEE Transactions on Power Systems. – 1997. – Vol. 12, no. 3. – P. 1306-1314. – DOI: 10.1109/59.630475.

10. Liang D. Bayesian state estimation for partially observable distribution networks via power flow-informed neural networks / D. Liang, G. Li, X. Liu, L. Zeng, H.-D. Chiang, S. Wang // International Journal of Electrical Power & Energy Systems. – 2025. – Vol. 170. – Art. 110886. – DOI: 10.1016/j.ijepes.2025.110886.

11. Vanin M. Distribution system state estimation for system identification and network model validation: an experience on a real low voltage network / M. Vanin, R. D'hulst, D. Van Hertem // Sustainable Energy, Grids and Networks. – 2025. – Vol. 42. – Art. 101710. – DOI: 10.1016/j.segan.2025.101710.

DOI: 10.24892/RIJIE/20260301

State Estimation of a Distribution Network under Conditions of Incomplete Observability

Shakirov V.A., Samarkina E.V., Kornev V.N., Pionkevich V.A.
Irkutsk research national technical university
Irkutsk, Russian Federation
shakirovva@ex.istu.edu

Abstract. **The paper addresses the problem of state estimation for a distribution electric power network under conditions of low observability, where measurements are available only at a subset of transformer substations. A hybrid approach combining a neural network with a physics-informed layer is proposed. The neural network predicts active and reactive loads of unobservable nodes based on data on voltages and loads at observable nodes, network topology, time of day, and time of year. The obtained load estimates, together with the known loads of the observable nodes, are fed into the physics layer, where voltages at all nodes are calculated. For a test distribution network consisting of 16 substations, 4 of which are observable, an annual dataset of hourly operating conditions was generated, taking into account seasonal and stochastic variations in loads, as well as five possible network configurations. The obtained mean absolute error (MAE) values for active power were 12.35 kW, for reactive power – 7.03 kvar, and for voltage – $1.5 \cdot 10^{-4}$ p.u. The results demonstrate high accuracy of state reconstruction, especially voltage levels, and confirm the applicability of the proposed approach.**

Keywords: **distribution network, observability, state, neural network, physics-informed layer**