

# Мультиагентный алгоритм глубокого обучения с подкреплением для формирования микроэлектрических сетей

С. П. Ковалёв, А. И. Полюхович

*Институт проблем управления им. В.А.Трапезникова, Российская академия наук, Москва, Россия*

Поступила в редколлегию 29.09.2025 г. Принята 10.10.2025 г.

**Аннотация**—В автономных энергосистемах необходимо формировать микроэлектрические сети так, чтобы обеспечить максимально возможную суммарную мощность запитанных потребителей с учетом их приоритетов и ограниченной мощности источников. Поэтому предложено использовать современную технологию мультиагентного глубокого обучения с подкреплением. Идея представленного алгоритма в максимизации количества агентов, принимающих решения о запитывании узлов электросети, с одновременным сокращением продолжительности их функционирования. В отличие от подхода, предполагающего длительный жизненный цикл агентов, данный подход демонстрирует повышенную эффективность в электрических сетях, имеющих сложную топологию. Удастся автоматически удовлетворить топологические ограничения микросетей без итерационного перерасчета, что существенно снижает вычислительную нагрузку и ускоряет процесс обучения нейросети. Алгоритм апробирован на тестовых системах IEEE-33 и IEEE-300.

**КЛЮЧЕВЫЕ СЛОВА:** микроэлектрическая сеть, автономная электроэнергетическая система, мультиагентное глубокое обучение с подкреплением, Q-сеть, коэффициент использования установленной мощности.

**DOI:** 10.53921/18195822\_2025\_25\_3\_413

## 1. ВВЕДЕНИЕ

Энергосистема представляет собой сеть, состоящую из компонентов трех видов: генерации, распределения и передачи. Источники энергии в системе (такие как уголь, солнечный свет, ветер, ядерные реакции и дизельное топливо) производят электрическую энергию. Микросетевые энергосистемы, также известные как гибридные системы возобновляемой энергии или системы, использующие несколько источников энергии, набирают популярность в настоящее время. Самыми часто используемыми во всем мире среди возобновляемых источников энергии являются солнечные панели и ветряные турбины. С их помощью для районов, обслуживаемых традиционными централизованными сетями, обеспечивается максимальная мощность генерации электроэнергии с минимальными издержками, а для отдалённых автономных районов производится гибридизация различных источников для обеспечения устойчивого и стабильного электроснабжения.

Микроэлектрические сети – это локализованные электроэнергетические сети небольшого масштаба, которые могут работать автономно или в режиме питания от централизованной магистральной сети. Они состоят из распределенных энергетических ресурсов, таких как возобновляемые источники, системы преобразования энергии, устройства хранения энергии и резервные генераторы. Микросети гарантируют эффективное устойчивое энергоснабжение изолированных объектов благодаря динамическому управлению источниками энергии и оптимизации зон их влияния.

Чтобы иметь возможность активно использовать микроэлектрические сети, необходимы передовые технологии. Эти технологии в применении к энергетическим ресурсам позволяют создавать системы управления электроснабжением – интеллектуальные автоматизированные системы, которые способствуют снижению или изменению потребления энергии в критические моменты, а также снижению затрат на содержание микроэлектрической сети. Хотя микросети имеют много преимуществ, им присущи различные проблемы в управлении из-за факторов, обусловленных переменной выработкой возобновляемых источников энергии, не согласованной с колебаниями нагрузки. Для преодоления этих проблем технологии искусственного интеллекта анонсируются как многообещающий подход к реализации и оптимизации управления электроснабжением в микросетях.

При этом для поддержания стабильности и управляемости энергосистемы решающее значение имеет обработка данных и принятие решений в реальном времени. Традиционные методы регулирования и автоматического управления генерацией основаны на предопределённых правилах и параметрах, которые могут недостаточно быстро адаптироваться к изменениям в таком режиме. Методы искусственного интеллекта, включая глубокое обучение и обучение с подкреплением, позволяют очень быстро обрабатывать данные и принимать адаптивные решения, отвечающие фактически складывающимся условиям [1]. Алгоритмы искусственного интеллекта, особенно использующие обучение с подкреплением, могут постоянно совершенствоваться, обучаясь на новых данных и приспосабливаясь к изменяющимся условиям функционирования системы.

Именно поэтому онлайн-системы управления энергообеспечением так выгодны: они могут управлять неопределенностями, анализируя данные в реальном времени, что важно ввиду прерывистого характера выработки возобновляемых источников энергии и высокой стохастичности рыночных цен и нагрузок. Например, еще в 2018 году была разработана модель управления генерацией и нагрузкой, основанная на обучении с подкреплением и применяемая к каждому распределенному источнику энергии и потребителю [2]. Модель была предназначена для оценки потребления и выработки энергии с учетом изменчивости стохастических параметров. Поставщики и клиенты здесь считались рациональными, независимыми субъектами, способными подстраиваться под действия друг друга.

Однако методы обучения с подкреплением часто сталкиваются с медленным обучением, сложными ограничениями и «проклятием размерности» пространств состояний и действий. В частности, глубокое обучение с подкреплением не используется повсеместно для формирования микросетей во многом ввиду сложности целевой топологии и большого числа возможных реконфигураций (переключений), требуемых в крупных энергосистемах [3]. Предложенный в настоящей работе мультиагентный метод способен преодолеть эти трудности: он гарантирует, что при любой схеме электроснабжения микросети будут питать максимально большое по мощности количество потребителей (с учетом их приоритетов), будучи изолированными друг от друга и имея радиальную топологию с центром в точке подключения соответствующего генератора. Для этого виртуальные агенты обучения с подкреплением назначаются коммутационным аппаратам (переключателям) – элементарным исполнительным механизмам реконфигурирования энергосистемы.

## 2. ОБЗОР МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В УПРАВЛЕНИИ ЭНЕРГОСИСТЕМАМИ

В литературе активно обсуждается применение различных алгоритмов на основе искусственного интеллекта в микросетях для решения задач управления энергообеспечением, предиктивной аналитики, прогнозирования и оптимизации нагрузки, обнаружения и классификации неисправностей оборудования, а также обнаружения и предотвращения кибератак. Техно-

логии искусственного интеллекта с начала текущего периода его расцвета также используются для задач прогнозирования цен на электроэнергию, обнаружения и диагностики аварий и катастроф [4].

Одним из основных трендов на данный момент является интеграция технологий искусственного интеллекта и блокчейн, которые могут обеспечить безопасный и прозрачный обмен энергией и данными как между несколькими микросетями, так и между конкретной микросетью и магистральной сетью [5]. Этот подход также позволяет осуществлять торговлю энергией и предоставить владельцам микросетей возможность монетизировать их избыток энергии. Еще одной тенденцией является использование объяснимого искусственного интеллекта, который может улучшить интерпретируемость и прозрачность систем на основе искусственного интеллекта и повысить их надежность и доверие к ним. Так, использование объяснимого искусственного интеллекта совместно с обучением с подкреплением может обеспечить снижение затрат на электроэнергию за счёт оптимизации процесса зарядки электромобилей, тем самым уменьшая износ аккумуляторов зарядных станций по сравнению с традиционными методами [6]. Предложенный подход позволяет оценивать надежность многошаговых сценариев электроснабжения зарядок с учетом деградации аккумуляторов вследствие старения.

Предиктивная аналитика может использоваться для прогнозирования выработки возобновляемых источников энергии, таких как солнечная и ветровая энергия, на основе прогнозов погоды, географического положения, сезонности и других факторов. Эта информация затем может быть использована для оптимизации работы микросети и минимизации использования резервных генераторов и других невозобновляемых источников [7].

Задача оптимизации в микросетях формулируется как поиск наилучшего решения проблем электроснабжения с учетом конкретных ограничений и целей. Оптимизация может быть направлена на уменьшение затрат на электроэнергию, снижение выбросов углерода, повышение надежности и долговечности энергосистем. Алгоритмы оптимизации также могут быть использованы для балансировки спроса и предложения энергии в реальном времени, что имеет решающее значение для работы микросети [8].

Основные типовые цели управления энергопотреблением — обеспечить безопасность и эффективность энергоснабжения, увеличить диверсификацию энергетических ресурсов и коэффициент использования установленной мощности (КИУМ), а также снизить потери при генерации, передаче, распределении и использовании электроэнергии. Задачи управления энергопотреблением обычно направлены на рациональное планирование функционирования управляемых нагрузок и систем накопления энергии, а также на снижение общих эксплуатационных расходов компонентов микросети и сокращение выбросов [9]. Ставится также задача обнаружения и реагирования на чрезвычайные ситуации, такие как отключения электроэнергии, отказы оборудования и стихийные бедствия [10]. В [11] предлагается стохастическое управление энергопотреблением на основе данных, основанное на искусственном интеллекте, для изолированных микросетей, с учетом реактивной мощности распределенных источников энергии. В этом исследовании неопределенности выходной мощности возобновляемых источников энергии моделируются с использованием генеративно-состязательной сети (Generative Adversarial Networks, GAN) для генерации сценариев.

Мониторинг в данной предметной области представляет собой процесс отслеживания и анализа производительности и состояния микросети и ее компонентов. Системы мониторинга на основе искусственного интеллекта способны обнаруживать аномалии, такие как отказы оборудования, кибератаки и системные сбои, и инициировать ответные меры, такие как профилактическое обслуживание, отключения и переход на аварийный резерв [12]. Использование инструментов искусственного интеллекта для поддержки эксплуатационного персонала в мониторинге и принятии решений минимизирует нагрузку на персонал и повышает эффектив-

ность реагирования на инциденты [13]. Нейронные сети, такие как сверточные (Convolutional Neural Networks, CNN) и рекуррентные (Recurrent Neural Networks, RNN), играют важную роль в мониторинге и управлении в реальном времени, позволяя обучаться на основе шаблонов данных и быстро принимать обоснованные решения [14].

Очень востребованы комплексные инструменты формирования рациональных планов и диспетчеризации процессов восстановления энергосистем после аварий на основе технологий глубокого обучения с подкреплением. Так, была разработана мультиагентная программная платформа на основе глубокого обучения с подкреплением для повышения устойчивости электроэнергетических систем в аварийных ситуациях, в том числе вызванных штормовыми ветрами [15]. Мультиагентная платформа использует метод актора-критика и обучается на прошлом опыте для определения оптимальных мест размещения и уставок шунтов, позволяющих уменьшить перепады напряжения во время сбоев и обрывов линий.

Обучение с подкреплением также используется для эффективного восстановления распределительных электроэнергетических систем после крупных сбоев [16]. Модель на основе поиска по дереву Монте-Карло (Monte-Carlo Tree Search, MCTS) отрабатывает процедуры восстановления, такие как определение приоритетности потребителей, распределение ресурсов для проведения ремонтных работ, оценка прироста производительности энергосистемы по мере выполнения работ.

Важной задачей также является оперативная диспетчеризация ремонтных бригад в случае каких-либо инцидентов в электрических сетях. Координация действий бригад является сложной задачей, особенно в мультиэнергетических микросетях с динамической неопределенностью. Известен подход к решению этой задачи в рамках восстановления интегрированной сети транспортировки электроэнергии и газа [17]. Этот подход основан на иерархическом алгоритме мультиагентного обучения с подкреплением, где каждой бригаде сопоставлен отдельный агент. В развитие этого подхода был предложен инструмент для совместного планирования работ ремонтных бригад и расстановки мобильных источников электроэнергии [18]. Аналогичным образом мультиагентное обучение с подкреплением на основе параметризованных двойных глубоких Q-сетей используется для оптимальной расстановки и оперативного управления мобильными системами хранения электроэнергии в ходе совместного восстановления энергетических и транспортных сетей в реальном времени [19]. Разработки на такой же основе известны для оптимизации расстановки мобильных ветровых турбин [20].

Активное внедрение киберфизических систем управления привело к появлению уязвимостей, которые могут быть использованы злоумышленниками для нарушения ресурсоснабжения. В [21] представлена комплексная стратегия минимизации ущерба от кибератак на основе определения оптимального времени повторного включения каналов ресурсоснабжения, отключенных в ходе атаки. Исследование базировалось на алгоритме градиента детерминированной политики (Deep Deterministic Policy Gradient, DDPG) для глубокого обучения с подкреплением. На основе этого же метода искусственного интеллекта был разработан инструмент для защиты микросетей от атак на системы управления спросом на электроэнергию, основанных на вводе вредоносных данных [22]. Чтобы достоверно и оперативно отличать воздействия атак от естественных изменений состояния инфраструктуры и целенаправленных реконфигураций, предложено использовать рекуррентные сети нейронов с долгой кратковременной памятью (Long Short-Term Memory, LSTM) [23].

Особое место среди приложений искусственного интеллекта занимают большие языковые модели (Large Language Models, LLM), которые способны обрабатывать и генерировать различные тексты на естественных и искусственных языках и изображения [24]. На стадии планирования работ по строительству, модернизации, ремонту и реконфигурации энергосистем большие языковые модели способны анализировать альтернативные варианты стратегии выполнения

работ. Появляется возможность автоматически выбирать наиболее предпочтительный состав работ и график их выполнения по критериям, сформулированным экспертами на естественном языке. Например, искусственный интеллект может помочь найти наилучший баланс между скоростью восстановления поврежденной энергосистемы и связанными с ним финансовыми затратами. Для эффективного решения подобных задач предложен типовой цикл внедрения большой языковой модели в интеллектуальную систему управления [25].

Таким образом, данный обзор иллюстрирует, что использование машинного обучения, глубокого обучения и других алгоритмов искусственного интеллекта может улучшить прогнозную аналитику, оптимизацию, управление и мониторинг микросетей, а также обеспечить принятие решений в реальном времени и способствовать более эффективному использованию доступных ресурсов. Этот тезис обоснован, поскольку методы искусственного интеллекта доказали свою эффективность в решении многочисленных задач в энергосистемах, и их эффективность еще больше возрастает в сочетании с традиционными математическими подходами [26]. Поскольку традиционные методы наталкиваются на ограничения при работе с огромными объемами данных и сложными взаимозависимостями в современных энергосетях, методы искусственного интеллекта, такие как нейронные сети и машинное обучение, нивелируют этот недостаток, эффективно обрабатывая большие наборы данных и выявляя скрытые закономерности [27].

### 3. ОПИСАНИЕ МУЛЬТИАГЕНТНОГО АЛГОРИТМА ОБУЧЕНИЯ С ПОДКРЕПЛЕНИЕМ

Глубокое обучение с подкреплением в рассматриваемом контексте реализовано через имитационную модель, состоящую из агентов и среды, в которой агенты совершают действия [28]. Среда характеризует текущее состояние сети электроснабжения (мощности генераторов, состав запитанных узлов), в то время как агенты пошагово принимают решения о запитывании или не запитывании новых узлов. За каждое решение агент получает вознаграждение, пропорциональное вызванному решением приросту мощности и относительному приоритету узла за вычетом штрафов за нарушение эксплуатационных и топологических ограничений.

Действия в среде математически описываются как марковский процесс принятия решений – набор  $(S, A, p, r)$ , где на каждом временном шаге  $t$  агент наблюдает за состоянием среды  $s_t \in S$  и выполняет действие  $a_t \in A$ . Среда возвращает агенту следующее состояние  $s_{t+1} \in S$  с вероятностью  $p(s_{t+1}|s_t, a_t)$  и агент получает немедленное вознаграждение  $r_t = r(s_t, a_t)$ . В процессе обучения агенты исследуют различные стратегии запитывания энергосистемы, что позволяет нейронной сети обучаться максимально точной оценке совокупной полезности принимаемых агентами решений путем вычисления так называемой Q-функции:

$$Q^\pi(s, a) = E_{\tau \sim \pi} \left[ \sum_{t=0}^T \gamma^t r_t \right],$$

где  $\gamma \in [0, 1]$  – коэффициент дисконтирования. Q-функция удовлетворяет известному рекуррентному уравнению Беллмана:

$$Q^\pi(s, a) = E_{s' \sim p(s'|s, a), r \sim r(s, a)} \left[ r + \gamma E_{a' \sim \pi(s')} [Q^\pi(s', a')] \right],$$

где переменные без штриха обозначают значения на очередном шаге, а переменные со штрихом – на следующем. При такой формулировке обучение с подкреплением используется для нахождения стохастической политики  $\pi(a_t|s_t)$ , которая максимизирует ожидаемое интегральное вознаграждение:

$$R(\tau) = r_0 + \gamma^1 r_1 + \gamma^2 r_2 + \dots + \gamma^T r_T = \sum_{t=0}^T \gamma^t r_t.$$

Для накопления информации о среде агент следует  $\varepsilon$ -жадной стратегии, которая позволяет ему балансировать между исследованием новых действий и приложением уже полученных знаний. С вероятностью  $\varepsilon \in [0, 1]$  агент выбирает случайное действие (исследование), а с вероятностью  $1 - \varepsilon$  — действие с максимальной оценкой ценности на основе Q-функции (приложение). В начале обучения, когда знания о среде минимальны, значение  $\varepsilon$  устанавливается близким к 1, что соответствует активной фазе исследования. По мере обучения параметр  $\varepsilon$  итеративно уменьшается, позволяя агенту все чаще принимать решения не случайным образом, а с опорой на уже имеющийся опыт.

Известен метод формирования микросетей на основе глубокого обучения с подкреплением, в котором число агентов соответствует числу генераторов [29]. Агенты шаг за шагом виртуально перемещаются по системе вдоль линий электропередачи начиная от генераторов, до тех пор, пока мощность генераторов не исчерпается либо все потребители не получают питание. Этот метод был апробирован на модифицированной тестовой модели 33-узловой сети IEEE. Недостаток данного подхода заключается в том, что на каждом шаге необходимо вычислять топологические ограничения для обеспечения радиальной топологии каждой микросети.

Предлагаемый в настоящей работе метод, напротив, позволяет без явных сложных вычислений учитывать ограничения радиальной топологии и взаимной изолированности микросетей. В нем число агентов увеличивается: каждый агент сопоставляется переключателю в электросети, как показано на примере на рис. 1.




Рис. 1. Расположение агентов обучения с подкреплением в модифицированной сети IEEE-33

До начала обучения все переключатели разомкнуты, а агенты не активированы и готовы к помещению в очередь, чтобы выполнять действия в среде. Каждый шаг эпизода формирования микросетей состоит в извлечении одного агента из очереди ожидающих активации, принятии им решения о замыкании соответствующего переключателя исходя из текущего состояния энергосистемы, и последующей деактивации. При помощи нейронной сети ищется такой порядок активации агентов, который приводит к максимизации запитанной мощности. Эпизод завершается, когда очередь становится пустой. При этом в начале эпизода в очередь помещаются агенты, соответствующие всем переключателям, ближайшим к генераторам. Эти агенты получают информацию о мощности соответствующего источника энергии. По мере обу-

чения агенты выбираются из очереди сначала случайно (следуя  $\varepsilon$ -жадной стратегии), а позже – целенаправленно максимизируя Q-функцию.

Рассмотрим условия принятия активированным агентом решения о замыкании «своего» переключателя. А именно, переключатель остаётся разомкнутым и не приводит к активации каких-либо других агентов в следующих случаях:

- 1) на обоих концах линии, коммутируемой переключателем, отсутствует питание (так что замыкание переключателя не приведет к запитыванию каких-либо энергоприемников);
- 2) оба конца коммутируемой линии уже запитаны (так что замыкание переключателя вызовет появление кольца в микросети либо соединение двух микросетей, т.е. нарушение топологических ограничений);
- 3) суммарная мощность энергоприемников, непосредственно (через неотключаемые линии) подключенных к незапитанному концу коммутируемой линии, превышает текущую свободную мощность генератора, питающего второй конец.

Если ни один из этих случаев не имеет места, то агент замыкает переключатель. При этом энергоприемники, непосредственно подключенные к нему с незапитанного конца, получают питание, и их суммарная мощность вычитается из свободной мощности генератора, питающего второй конец. После этого агенты переключателей на линиях, непосредственно связанных с только что запитанным концом линии, помещаются в очередь на активацию. За замыкание переключателя агент получает вознаграждение

$$r = \sum_i w_i P_i,$$

где индекс  $i$  пробегает множество всех только что запитанных энергоприемников,  $P_i$  – мощность  $i$ -го энергоприемника,  $w_i$  – его относительный приоритет (вещественное число в диапазоне  $[0, 1]$ ).

При таком подходе, состав активируемых агентов по итогам очередного шага зависит от того, с какой стороны к замыкаемому на этом шаге переключателю поступает питание. Например, на рис. 1 переключатель А7 может получить мощность либо слева (если ранее был замкнут переключатель А6), либо справа (если ранее был замкнут переключатель А8). В первом случае будут запитаны узлы 28-30 и помещен в очередь на активацию агент переключателя А8, а во втором – запитаны узлы 26-27 и помещен в очередь агент А6. Здесь возможна ситуация, в которой переключатель, не замкнутый при получении его агентом мощности от одного генератора, становится замкнутым при получении мощности от другого генератора. Однако, если переключатель уже был замкнут, то он ни при каких обстоятельствах не может быть разомкнут в ходе эпизода.

Таким образом, радиальная топология микросетей соблюдается благодаря тому, что агенты связаны с переключателями, а правила принятия решений агентами позволяют гарантировать изолированность микросетей друг от друга внутри электроэнергетической системы. Это позволяет оптимизировать работу алгоритма, увеличивая скорость вычислений за счёт априорно корректной логики принятия решений.

#### 4. РЕЗУЛЬТАТЫ ТЕСТИРОВАНИЯ МУЛЬТИАГЕНТНОГО АЛГОРИТМА

Реализация алгоритма основана на нейронной сети вычисления функции полезности (Q-сети), имеющей для электросети, изображённой на рис. 1, три полносвязных скрытых слоя с функцией активации ReLU. Входной слой имеет такую же размерность, как список параметров состояния сети электроснабжения, так что он состоит из 13 нейронов (имеется 3 генератора и 10 агентов переключателей). Скрытые слои для электросети такого масштаба содержат по

50 нейронов, а размерность выходного слоя соответствует размерности пространства действий (10 нейронов, по числу агентов). Коэффициенту дисконтирования  $\gamma$  присвоено значение 0.99. Процедуры обучения и применения такой Q-сети реализованы с использованием библиотеки Tianshou [30]. Даже для системы, изображённой на рис. 1, предложенный алгоритм выигрывает у упоминавшегося выше известного алгоритма обучения с подкреплением, в котором агенты соответствуют генераторам, по объёму запитанной мощности. Например, для генератора G1 известный алгоритм строит микросеть из узлов 1-6 и 23-25, обеспечивая питанием 84.2% от суммарной мощности энергосистемы, а новый алгоритм обеспечивает 89.1% мощности, включая в эту микросеть узлы 1-3, 19-22 и 23-25.

Однако, как упоминалось ранее, существенным испытанием для методов обучения с подкреплением является рост вычислительной нагрузки при кратном увеличении размерности энергосистемы. Говоря конкретнее, например, для сети, изображённой на рис. 1, время, затраченное на процесс обучения нейронной сети при фиксированных значениях мощностей генераторов, составило 20.68 секунд. Вычисления производились в облачной среде Google Colaboratory, имеющей следующие характеристики: виртуальный процессор Intel Xeon с эффективной тактовой частотой 2.3 ГГц и графическим ускорителем серии NVIDIA Tesla K80 с объёмом оперативной памяти 12 Гб.

Целесообразно проверить адекватность предложенного мультиагентного подхода для сети большей размерности. Для этого рассмотрим тестовую сеть IEEE, состоящую из 300 узлов и 69 генераторов, имеющих различный уровень мощности [31]. Количество выключателей обычно соответствует числу ветвей (линий электропередачи, трансформаторов), так как каждый элемент сети должен быть оснащён коммутационной аппаратурой для управления режимами и защиты. В тестовой сети 411 ветвей, значит, выключателей будет 411. Приоритеты всех подключенных к сети потребителей электроэнергии полагаются равными 1. Схема сети представлена на рис. 2.

Для этой энергосистемы предложенный алгоритм сформировал 69 микросетей, информация о которых представлена в табл. 1.

Таблица 1: Характеристики сформированных микросетей

| Узел генератора | Список узлов микросети               | Мощность генератора, кВт | КИУМ, % |
|-----------------|--------------------------------------|--------------------------|---------|
| 8               | 2, 8, 14                             | 300                      | 97.3    |
| 10              | 7, 10, 12, 131                       | 200                      | 78      |
| 20              | 13, 20, 27                           | 750                      | 99.3    |
| 63              | 45, 60, 62-64, 74, 88                | 100                      | 76      |
| 76              | 35, 36, 72, 76, 531                  | 350                      | 88.1    |
| 84              | 73, 78, 79, 84                       | 375                      | 86.4    |
| 91              | 89, 91, 97                           | 155                      | 65.8    |
| 92              | 92, 94, 103, 105, 109, 110, 112, 114 | 290                      | 98.6    |
| 98              | 98, 100                              | 68                       | 98.5    |
| 108             | 104, 108                             | 117                      | 95.7    |
| 119             | 116-121, 115, 158, 1201              | 1930                     | 100     |
| 124             | 123, 124, 160                        | 240                      | 97.8    |
| 125             | 125, 126                             | 250                      | 96.5    |
| 138             | 137, 138, 181                        | 215                      | 99.6    |
| 141             | 141                                  | 281                      | 55.5    |
| 143             | 140, 142-144, 148                    | 696                      | 90.5    |
| 146             | 146, 172, 174                        | 84                       | 31      |

Таблица 1 (продолжение)

| Узел генератора | Список узлов микросети                                                  | Мощность генератора, кВт | КИУМ, % |
|-----------------|-------------------------------------------------------------------------|--------------------------|---------|
| 147             | 147                                                                     | 217                      | 10      |
| 149             | 145, 149, 180                                                           | 103                      | 100     |
| 152             | 136, 152                                                                | 372                      | 21      |
| 153             | 153, 183                                                                | 216                      | 18.5    |
| 156             | 154, 156                                                                | 186                      | 100     |
| 170             | 132, 170                                                                | 205                      | 100     |
| 171             | 171                                                                     | 90                       | 99.6    |
| 176             | 175, 176                                                                | 228                      | 88.2    |
| 177             | 177                                                                     | 84                       | 40      |
| 185             | 134, 184, 185                                                           | 200                      | 69      |
| 186             | 186, 188                                                                | 1200                     | 21      |
| 187             | 187                                                                     | 1200                     | 10.2    |
| 190             | 190, 240, 231, 281                                                      | 475                      | 49.7    |
| 191             | 192, 223-226                                                            | 1973                     | 96.4    |
| 198             | 69, 189, 193, 195-197, 198, 202, 203-205, 209-212, 2040                 | 424                      | 98.4    |
| 213             | 213-216                                                                 | 272                      | 100     |
| 220             | 220                                                                     | 302                      | 100     |
| 221             | 221                                                                     | 450                      | 41.1    |
| 222             | 222                                                                     | 378                      | 100     |
| 227             | 227                                                                     | 652                      | 100     |
| 230             | 228-230                                                                 | 345                      | 100     |
| 233             | 233                                                                     | 456                      | 100     |
| 236             | 234, 236                                                                | 600                      | 98.7    |
| 238             | 238                                                                     | 250                      | 100     |
| 239             | 239                                                                     | 550                      | 100     |
| 241             | 194, 217-219, 237, 241                                                  | 575.43                   | 50      |
| 242             | 242, 245, 247, 248                                                      | 170                      | 98.8    |
| 243             | 243, 244, 246                                                           | 84                       | 100     |
| 7001            | 1, 5, 7001                                                              | 467                      | 100     |
| 7002            | 6, 7002                                                                 | 623                      | 20.2    |
| 7003            | 3, 4, 15, 16, 19, 33, 37, 38, 40, 41, 48, 52, 85-87, 90, 107, 150, 7003 | 1210                     | 69.2    |
| 7011            | 9, 11, 7011                                                             | 234                      | 81.2    |
| 7012            | 7012                                                                    | 372                      | 10      |
| 7017            | 7017                                                                    | 330                      | 10      |
| 7023            | 22, 23, 25, 7023                                                        | 185                      | 82.7    |
| 7024            | 24, 7024                                                                | 410                      | 28.7    |
| 7039            | 34, 39, 42, 46, 81, 7039                                                | 500                      | 31.2    |
| 7044            | 7044                                                                    | 37                       | 92.3    |
| 7049            | 49, 7049                                                                | 100                      | 96      |
| 7055            | 54, 55, 7055                                                            | 45                       | 75.5    |
| 7057            | 57, 58, 7057                                                            | 165                      | 69.1    |
| 7061            | 61, 7061                                                                | 400                      | 63      |
| 7062            | 7062                                                                    | 400                      | 10      |
| 7071            | 71, 7071                                                                | 116                      | 100     |
| 7130            | 127, 129, 130, 133, 134, 151, 167, 168, 169, 7130                       | 1292                     | 54      |
| 7139            | 139, 7139                                                               | 700                      | 85.6    |

Таблица 1 (продолжение)

| Узел генератора   | Список узлов микросети                                                                                                                                                                             | Мощность генератора, кВт | КИУМ, % |
|-------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------|---------|
| 7166              | 155, 161-166, 7166                                                                                                                                                                                 | 553                      | 60      |
| 9002              | 9001-9007, 9012, 9021-9026, 9031-9038, 9041-9044, 9052, 9071, 9072, 9121                                                                                                                           | 68                       | 100     |
| 9051              | 9005, 9051                                                                                                                                                                                         | 36                       | 100     |
| 9053              | 9053, 9533                                                                                                                                                                                         | 29                       | 100     |
| 9054              | 9054                                                                                                                                                                                               | 50                       | 100     |
| 9055              | 9055                                                                                                                                                                                               | 8                        | 100     |
| Незапитанные узлы | 1, 17, 21, 26, 43, 44, 47, 53, 59, 70, 77, 80, 99, 102, 113, 122, 157, 159, 173, 178, 179, 182, 191, 199-201, 206-209, 232, 235, 249, 250, 319, 320, 322-324, 526, 528, 552, 562, 609, 1190, 1200. | -                        | 81.1    |
| Итого:            |                                                                                                                                                                                                    |                          | 77.1    |

Поскольку важным показателем эффективности микросетей является КИУМ генераторов, его значения приведены в таблице. В строках с 1 по 69 КИУМ вычисляется как отношение суммарной мощности потребления узлов сформированной микросети к мощности генератора. Предпоследняя строка описывает все узлы, не получившие питания ни от одного генератора. В ней КИУМ вычисляется как отношение суммарной запитанной мощности (т.е. суммарной мощности всех узлов энергосистемы, получивших питание) к суммарной мощности потребления всей энергосистемы. В последней строке КИУМ вычисляется как отношение суммарной запитанной мощности к суммарной мощности всех генераторов.

Время вычислений, необходимое для обучения нейронной сети при фиксированных значениях мощности генераторов, составило 57.6 минут, в результате чего запитанная мощность оказалась равной 81.1% от общей мощности сети. Расчёт проводился с использованием того же аппаратного обеспечения, что и приведённый ранее расчёт для сети IEEE-33. Таким образом, предположение об эффективности алгоритма, предложенного в настоящей работе, для достаточно больших сетей оказалось верно.

Естественно, что увеличение числа узлов и, как следствие, коммутационных аппаратов в электросети приводит к необходимости скорректировать архитектуру нейронной сети. С учётом отличий топологии данной электросети от топологии сети IEEE-33, число скрытых слоёв Q-сети увеличилось с трёх до пяти, а количество нейронов в них – с 50 до 256. Во входном слое находится 480 нейронов (имеется 69 генераторов и 411 переключателей), а в выходном – 411 (согласно числу переключателей). График изменения функции потерь в зависимости от номера эпизода, представленный на рис. 3, демонстрирует корректность проведённого обучения с подкреплением и соответствие выбранной архитектуры решаемой задаче. После прохождения последнего эпизода обучения значение функции потерь составило 0.0012.

Также целесообразно исследовать зависимость КИУМ от мощности генераторов по мере её увеличения. Такая зависимость позволяет убедиться в корректности работы предложенного алгоритма и помогает инженерам в выборе и обосновании мощности генераторов при строительстве и модернизации энергосистемы. Чтобы получить такую зависимость для некоторого генератора, проводится серия циклов обучения Q-сети с варьированием его мощности от ма-

лых значений до суммарной мощности узлов, которые он может запитать, при фиксированных (номинальных) значениях мощности всех остальных генераторов. Например, для генератора, подключенного к узлу 10, такой график имеет вид, представленный на рис. 4.

## 5. ЗАКЛЮЧЕНИЕ

Результаты вычислительного эксперимента показали, что предложенный алгоритм может быть эффективен для формирования микросетей в топологически нетривиальных автономных энергосистемах, содержащих многолучевые разветвления и достаточно большое количество узлов и коммутационных аппаратов. В ходе дальнейших исследований планируется для электрических сетей, имеющих нестандартную топологию, исследовать и апробировать другие подходы глубокого обучения с подкреплением. Например, целесообразно будет рассмотреть методы типа актора-критика [28], комбинацию обучения с подкреплением и графовых нейронных сетей для оперативного анализа топологии [32], а также способы явного учета физических законов в алгоритмах обучения (Physics-Informed Reinforcement Learning [33]).

## СПИСОК ЛИТЕРАТУРЫ

1. Kishore P.S.V., Rajesh J., Jayaram N., Halder S. A Survey of Machine Learning Applications in Renewable Energy Sources. *IETE Journal of Research*, 2024, vol. 70, pp. 1389–1406.
2. Foruzan E., Soh L.K., Asgarpour S. Reinforcement learning approach for optimal distributed energy management in a microgrid. *IEEE Transactions on Power Systems*, 2018, vol. 33, pp. 5749–5758.
3. Altin N., Eyimaya S.E. Artificial Intelligence Applications for Energy Management in Microgrid. *11th International Conference on Smart Grid*, 2023, pp. 1–6.
4. Ковалёв С.П. Применение нейронных сетей глубокого обучения в математическом обеспечении цифровых двойников электроэнергетических систем. *Системы и средства информатики*, 2021, Т. 31, № 1, стр. 133–144.
5. Singh P., Lather J.S. Artificial neural network-based dynamic power management of a DC microgrid: A hardware-in-loop real-time verification. *International Journal of Ambient Energy*, 2022, vol. 43, pp. 1730–1738.
6. Li S., Zhao A.P., Gu C., Bu S., Chung E., Tian Z., Li J., Cheng S. Interpretable Deep Reinforcement Learning with Imitative Expert Experience for Smart Charging of Electric Vehicles. *IEEE Transactions on Power Systems*, 2025, vol. 40, pp. 1228–1240.
7. Elmouatamid A., Ouladsine R., Bakhouya M., Kamoun N.El, Zine-dine K., Khaidar M. MAPCAST: An adaptive control approach using predictive analytics for energy balance in microgrid systems. *International Journal of Renewable Energy Research*, 2020, vol.10, pp. 945–954.
8. Lin S.Y., Chen J.F. Distributed optimal power flow for smart grid transmission system with renewable energy sources. *Energy*, 2013, vol. 56, pp. 184–192.
9. Marzband M., Azarinejadian F., Savaghebi M., Guerrero J.M. An optimal energy management system for islanded microgrids based on multiperiod artificial bee colony combined with Markov chain. *IEEE systems journal*, 2017, vol. 11, pp. 1712–1722.
10. Shafiullah M., Abido M.A., Al-Mohammed A.H. Power system fault diagnosis: a wide area measurement based intelligent approach. *Elsevier*, 2022.
11. Sadek S.M., Omran W.A., Hassan M.M., Talaat H.E. Data driven stochastic energy management for isolated microgrids based on generative adversarial networks considering reactive power capabilities of distributed energy resources and reactive power costs. *IEEE Access*, 2020, vol. 9, pp. 5397–5411.
12. Esmalifalak M., Liu L., Nguyen N., Zheng R., Han Z. Detecting stealthy false data injection using machine learning in smart grid. *IEEE Systems Journal*, 2014, vol. 11, pp. 1644–1652.




Рис. 2. Схема тестовой сети IEEE-300




Рис. 3. График изменения функции потерь в зависимости от эпизода обучения




Рис. 4. Зависимость КИУМ от мощности генератора в узле 10

13. Haque M., Shaheed M.N., Choi S. Deep learning based micro-grid fault detection and classification in future smart vehicle. *2018 IEEE Transportation Electrification Conference and Expo*. 2018, pp. 1082—107.
14. Lu R., Bai R., Ding Y., Wei M., Jiang J., Sun M., Zhang H.T. A hybrid deep learning-based online energy management scheme for industrial microgrid. *Applied Energy*, 2021, vol.304, p. 117857.
15. Kamruzzaman M., Duan J., Shi D., Ben-Idris M. A deep reinforcement learning-based multi-agent framework to enhance power system resilience using shunt resources. *IEEE Transactions on Power Systems*, 2021, vol. 36, pp. 5525—5536.
16. Bedoya J.C., Wang Y., Liu C.C. Distribution system resilience under asynchronous information using deep reinforcement learning. *IEEE Transactions on Power Systems*, 2021, vol. 36, pp. 4235—4245.
17. Qiu D., Wang Y., Zhang T., Sun M., Strbac G. Hierarchical multi-agent reinforcement learning for repair crews dispatch control towards multi-energy microgrid resilience. *Applied Energy*, 2023, vol. 336, p. 120826.
18. Wang Y., Qiu D., Teng F., Strbac G. Towards microgrid resilience enhancement via mobile power sources and repair crews: A multi-agent reinforcement learning approach. *IEEE Transactions on Power Systems*, 2024, vol. 39, pp. 1329—1345.
19. Wang Y., Qiu D., Strbac G. Multi-agent deep reinforcement learning for resilience-driven routing and scheduling of mobile energy storage systems. *Applied Energy*, 2022, vol. 310, p. 118575.
20. Zhang R., Su J., Dehghanian P., Alhazmi M. Deep Reinforcement Learning-Aided Pre-Positioning of Mobile Wind Turbines to Enhance Power Distribution System Resilience. *Proc. 56th North American Power Symposium (NAPS)*. 2024, pp. 1—6.

21. Wei F., Wan Z. Cyber-attack recovery strategy for smart grid based on deep reinforcement learning. *IEEE Transactions on Smart Grid*, 2020, vol. 11, pp. 2476–2486.
22. Zhang H., Yue D., Dou C., Xie X., Li K., Hancke G.P. Resilient Optimal Defensive Strategy of TSK Fuzzy-Model-Based Microgrids' System via a Novel Reinforcement Learning Approach. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, vol. 34, pp. 1921–1931.
23. Mohammadpourfard M., Khalili A., Genc I., Konstantinou C. Cyber-Resilient Smart Cities: Detection of Malicious Attacks in Smart Grids. *Sustainable Cities and Society*, 2021, vol. 75, p. 103116.
24. Liu Y., Han T., Ma S., Zhang J., Yang Y., Tian J., He H., Li A., He M., Liu Z., Wu Z., Zhao L., Zhu D., Li X., Qiang N., Shen D., Liu T., Ge B. Summary of ChatGPT-related research and perspective towards the future of large language models. *Meta-Radiology*, 2023, vol. 1, p. 100017.
25. Yigit Y., Ferrag M.A., Sarker I.H., Maglaras L.A., Chrysoulas C, Moradpoor N., Janicke H. Critical Infrastructure Protection: Generative AI, Challenges, and Opportunities. *IEEE Transactions and journals*, 2016, vol. 4, pp. 1–14.
26. Alimi O.A., Ouahada K., Abu-Mahfouz A.M. A review of machine learning approaches to power system security and stability. *IEEE Access*, 2020, vol. 8, pp. 113512–113531.
27. Zheng Z., Shafique M., Luo X., Wang S. A systematic review towards integrative energy management of smart grids and urban energy systems. *Renewable and Sustainable Energy Reviews*, 2024, vol. 189, p. 114023.
28. Л. Грессер, В. Л. Кенг. *Глубокое обучение с подкреплением: теория и практика на языке Python*. СПб.: Питер, 2022.
29. Igder M.A., Liang X. Service Restoration Using Deep Reinforcement Learning and Dynamic Microgrid Formation in Distribution Networks. *IEEE Transactions on Industry Applications*, 2023, vol. 59, pp. 5453–5472.
30. Mnih V., Kavukcuoglu K., Silver D. Human-level control through deep reinforcement learning. *Nature*, 2015, vol. 518, pp. 529–533.
31. CASE300 Power flow data for IEEE 300 bus test case. <https://matpower.org/docs/ref/matpower5.0/case300.html> (дата последнего обращения: 18.07.2025).
32. Fan B., Liu X., Xiao G., Kang Y., Wang D., Wang P. Attention-Based Multiagent Graph Reinforcement Learning for Service Restoration. *IEEE Transactions on Artificial Intelligence*, 2024, vol. 5, pp. 2163–2178.
33. Banerjee C., Nguyen K., Fookes C., Raissi M. A Survey on Physics Informed Reinforcement Learning: Review and Open Problems. *Expert Systems with Applications*, 2025, vol. 287, p. 128166.

## Multi-Agent Deep Learning Reinforcement Algorithm for the Formation of Microelectric Networks

S. P. Kovalyov, A. I. Poliuchovich

In autonomous power systems, it is necessary to form microelectric networks in such a way as to ensure the maximum possible total capacity of powered consumers, taking into account their priorities and limited power sources. Therefore, it is proposed to use modern technology of multi-agent deep learning with reinforcement. The key idea of the algorithm is to maximize the number of agents making decisions about supplying network nodes while reducing their uptime. In contrast to the approach that assumes with a long agent lifecycle, this approach demonstrates increased efficiency in electrical networks with complex topologies. The proposed solution automatically accounts for topological constraints of microgrids without iterative recalculation, which significantly reduces the computational load and speeds up the learning process of the neural network. The algorithm has been tested on IEEE-33 and IEEE-300 test systems.

**KEYWORDS:** microelectric grid, autonomous electric power system, multi-agent deep reinforcement learning, Q-network, installed capacity utilization factor.