

УДК 004.942

Генеративно-сопоставительная нейронная сеть для моделирования шумовых характеристик источников тока

© 2025 г. А. Г. Попов^{1,2}

¹ Московский физико-технический институт (национальный исследовательский университет), Москва, 117303, Россия

² Федеральное государственное унитарное предприятие «Центральный научно-исследовательский институт химии и механики» им. Д.И. Менделеева, Москва, 115487, Россия

В статье представлен новый подход к моделированию шумов напряжения химических источников тока с целью аугментации наборов данных. Для решения задачи моделирования шумов напряжения литий-ионных аккумуляторов впервые предложен метод на основе генеративно-сопоставительной нейронной сети с использованием слоев LSTM. Приведен краткий статистический и спектральный анализ флуктуаций реальных сигналов напряжения источников тока. На его основе проведено качественное и количественное исследование синтетических сигналов. Показано, как разметка сгенерированных данных при помощи глубокой нейронной сети позволяет проводить генерацию шумовых характеристик для заданной степени заряженности элемента. Приведены рекомендации по применению предложенного алгоритма для усовершенствования методов интерпретации флуктуаций напряжения источников тока и дана экспериментальная оценка эффективности его применения: снижение ошибки определения степени заряженности элемента с 6.8 до 4.9 %.

Ключевые слова: генеративно-сопоставительные нейронные сети, химические источники тока, спектральная плотность мощности, шум напряжения.

Введение

С увеличением приходящихся на литий-ионные химические источники тока (ХИТ) мощностей растет необходимость в их эффективной и безопасной эксплуатации. Решение данной задачи невозможно без достоверной и полной информации о состоянии элементов: степени заряженности (*State of Charge, SoC*), остаточной емкости, оставшемся числе рабочих циклов.

Последние успехи в машинном обучении ускорили развитие основанных на больших данных техник определения состояния литий-ионных аккумуляторов [1–3]. Одними из активно развивающихся в последние годы методов контроля литий-ионных источников тока, использующими как методы машинного обучения, так и модели внутреннего поведения ХИТ, являются алгоритмы расширенного фильтра Калмана [4–6]. Для их точности важна информация не только о собственных электрохимических шумах источников тока (глубоко изученных в последние годы Е.В. Астафьевым [7–10]), но и о шумах системы измерения и нелинейностях разрядных кривых ХИТ [1]. Современные алгоритмы на основе расширенного фильтра Калмана, в том числе применяющие методы машинного обучения [6], требуют информацию о виде распределения, среднем, дисперсии и ковариации шумов контролируемой системы.

Важность выделенных параметров сигнала дополнительно подтверждается попытками напрямую связать характеристики нелинейности разрядной кривой и шумы напряжения литий-ионных аккумуля-

✉ А. Г. Попов: popov.ag@phystech.edu

Поступила в редакцию: 11.07.2025

После доработки: 25.07.2025

Принята к публикации: 30.07.2025

EDN VUYXVI

торов с его зарядовым состоянием [11 – 13]. Применение методов кластеризации и глубоких нейронных сетей для анализа флуктуаций сигнала может позволить повысить точность в определении *SoC* при помощи данных подходов [12].

Как известно, эффективность применения машинного обучения напрямую зависит от количества доступных данных [22]. В случае методов контроля состояния источников тока по его электрохимическим шумам объем доступных данных ограничен высокими требованиями к точности измерительного оборудования и условиям постановки эксперимента [8 – 11].

Поскольку значимая часть информации содержится в статистических и спектральных характеристиках флуктуаций сигнала, то обычные способы увеличения обучающего набора данных (аугментации) за счет добавления случайных помех и применения аффинных преобразований неэффективны. Ставится задача создания и валидации нового метода моделирования шумов напряжения литий-ионных ХИТ.

1. Материалы и методы

Для решения поставленной задачи генерации стохастических сигналов напряжения мы предлагаем новый метод моделирования шумовых характеристик источников тока, основанный на применении генеративно-состязательной нейронной сети (так называемой GAN – generative adversarial network). Данный тип алгоритмов был впервые предложен в 2014 г. Яном Гудфеллоу и другими в работе [16]. С тех пор GAN-модели нашли широчайшее применение в задачах генерации сигналов: изображений [17, 18], текстов [19, 20], музыки [21, 22]. В последние годы в ряде работ [23, 24] была показана эффективность применения GAN для решения задач генерации данных о функционировании химических источников тока. В данной работе выбранный тип алгоритмов впервые специально применяется для получения синтетических данных о стохастических процессах в электрохимических системах.

Суть генеративно-состязательной нейронной сети (GAN) заключается в соревновании двух нейронных сетей: генератора G и дискриминатора D . Сеть-генератор обучается создавать синтетические данные, неотличимые от реальных, сеть-дискриминатор – отличать сгенерированные данные от экспериментальных. При этом в ходе обучения генератор и дискриминатор оптимизируют не только свои внутренние параметры, но и параметры друг друга при помощи обратного распространения ошибки. Таким образом, в ходе соревнования происходит обучение всей системы, позволяющее ей производить данные, все более похожие на реальные значения. Блок-схема работы генеративно-состязательной сети приведена на рис. 1.

На вход сети генератора подается случайный сигнал ξ с некоторым заранее определенным распределением $P(\xi_i)$. Для генерации сигнала источников тока типично используются нормально распределенные случайные величины с $P(\xi_i) = N(0,1) = \frac{1}{\sqrt{(2\pi)}} e^{-\frac{(\xi_i)^2}{2}}$ – гауссов шум [17]. В процессе работы

сеть-генератор решает задачу регрессии; возвращаемые значения $x_g = x_g(\xi)$ совпадают по размерности с подаваемыми на вход дискриминатора реальными данными x_r .

Получая на вход реальные и синтетические данные дискриминатор решает задачу бинарной классификации, т.е. он должен возвращать близкое к 0 значение для поступивших на вход сгенерированных данных и близкое к 1 – для реальных. В общем случае для этого используется сигмоидальная функция

$$\sigma(x) = \frac{1}{1 + e^{-(y_d(x))}}, \quad (1)$$

где $y_d(x)$ – некоторая функция отклика сети дискриминатора на сигнал x до сигмоидальной активации.

С ростом подобия сгенерированных и реальных сигналов в процессе обучения целевые функции генератора и дискриминатора D и G стремятся к $\frac{1}{2}$. Итоговая целевая функция $V(D, G)$ простой GAN-модели выглядит следующим образом:




Рис. 1. Схема работы генеративно-сопоставительной сети

$$V(D, G) = -(\log(D) + \log(1 - G)), \quad (2)$$

а функция потерь:

$$Loss = 1 - V. \quad (3)$$

В силу уже известных особенностей сигнала шумов источников тока мы предлагаем использовать в GAN комбинацию сверточных слоев и слоев с долгой краткосрочной памятью. Применение LSTM-слоев позволит снизить влияние взрывов и затуханий градиентов при работе с разреженными сигналами. Использование сверточных слоев же предположительно позволит воспроизвести частотные особенности сигналов. Архитектура, включающая в себя усреднение выходов нескольких слоев, позволит снизить ошибку дискриминатора при классификации стохастических сигналов.

После обучения GAN-сети предлагается применить разметку полученных данных по степени заряда аккумулятора при помощи предобученной сети, основанной на описанной в [20] архитектуре, и проверить эффективность применения предложенного метода для аугментации данных. При этом следует провести анализ сгенерированных данных, чтобы определить степень их сходства с реальными сигналами и между собой.

Требования используемой для разметки сети к входным данным и стремление использовать сгенерированные данные для определения SoC аккумулятора требуют разбиения разрядной кривой на небольшие (менее 5 % ΔSoC) фрагменты и предварительной обработки каждого из них.

2. Методика получения экспериментальных данных

Измерительный стенд и программное обеспечение для управления им были основаны на подробно описанных в работе [12]. Были исследованы литий-кобальт-диоксидные аккумуляторы типоразмера 18650 емкостью 2.2 А·ч («АО Энергия ICR 19/66»). Данные аккумуляторы представляют собой цилиндрические ячейки с номинальным напряжением 3.7 В. Исследования проводились в пределах 500 заряд-разрядных циклов, что составляет заявленный срок службы для данных аккумуляторов. Степень заряда аккумулятора SoC определялась при помощи интегрирования по току как

$$SoC(T) = SoC_0 - 100 \% \cdot \int_T \frac{I(t)}{Q_0} dt. \quad (4)$$

Примеры экспериментально полученных зависимостей шумов напряжения от состояния заряда (SoC , *state of charge*) исследуемых аккумуляторов при разных режимах разряда и температуре приведены на рис. 2.




Рис. 2. Пример обработки разрядной кривой: а) 100 % разрядом постоянной нагрузкой 1C; б) разрядом разрядными импульсами по 5 % SoC

Для анализа и включения в обучающий набор данных были отобраны 36 разрядных кривых с наименьшим уровнем внешних шумов и наименьшим числом выбросов значений в сигналах.

После выделения шумового сигнала при помощи методики на основе вариационной декомпозиции [12] было проведено спектральное исследование посредством быстрого преобразования Фурье. Спектральная плотность мощности (СПМ) сигналов была получена по теореме Виннера – Хинчина. Пример полученных СПМ приведен на рис. 3.

Исходя из выделенных в [15] особенностей, полученные СПМ были описаны уравнениями вида

$$U = U_{white} \cdot f^0 + U_{colored} \cdot f^\gamma. \quad (5)$$




Рис. 3. СПИ сигнала для ряда разрядных импульсов по 5 % (SoC равна 100, 75, 50 и 20 % до подачи импульса), элемент AC22, 149-й цикл заряд-разряд (см. рис. 2а)

Показатель наклона цветной составляющей шума для исследованных спектров в среднем был равен -0.96 , что при соотношении амплитуд $U_{\text{colored}} \gg U_{\text{white}}$ говорит о преимущественном вкладе фликкер-шума в шумовую характеристику источников тока.

Для проверки возможности применения для анализа шума статистических критериев, основанных на предположении о нормальности распределения флуктуаций, был проведен тест Колмогорова – Смирнова. Тест был проведен с надежностью 95 % для проверки гипотезы H_0 о подчинении выборок флуктуаций напряжения нормальному распределению. Для этого для каждого участка разрядной кривой шириной в 2 % SoC была рассчитана статистика:

$$D_n = \max |N(x) - F(x)| * n^{\frac{1}{2}}, \quad (6)$$

где $F(x)$ – выборочная функция распределения вероятности для значения x в экспериментальной выборке; $N(x)$ – нормальная функция распределения вероятности с параметрами, определенными из несмещенных выборочных оценок; n – длина участка.

Гипотеза о нормальном распределении данных была отвергнута менее чем для 5 % участков исследованных разрядных кривых, вне зависимости от уровня заряда. В силу полученных результатов можно принять нулевую гипотезу, и приблизить исследуемое распределение нормальным распределением на участках разрядных кривых с изменением SoC менее чем на 2 %.

Таким образом, обучающий набор данных был составлен из 1800 отобранных фрагментов шума напряжения, полученного из 36 разрядных кривых источников тока.

3. Архитектура генеративно-сопоставительной сети

Реализующая предлагаемый метод архитектура генеративно-сопоставительной сети состоит из двух основных блоков: блока сети-дискриминатора и сети-генератора. Блок-схема, описывающая архитектуру сети-дискриминатора приведена на рис. 4.




Рис. 4. Блок-схема архитектуры сети дискриминатора

В состав дискриминатора входит блок из двух групп параллельных слоев, выходы которых суммируются. Как показало предобучение сети-дискриминатора на подвыборке обучающего набора данных, данное решение позволяет повысить скорость падения ошибки при обучении и увеличить точность работы сети-дискриминатора на наборах данных с преобладающей составляющей шума в сигнале.

Входящие в состав дискриминатора параллельные группы слоев состоят из сверточного слоя (размер фильтра $n_{conv} = [32, 1]$, шаг 2), за которым идет рекуррентный слой (LSTM-слой с размером скрытого слоя $n_h = 32$), слой нелинейной активации с утечкой (с коэффициентом 0.05) и слой dropout (с вероятностью обнуления компоненты входа). Сочетание сверточных и рекуррентных слоев позволяет оценивать классифицируемые сигналы как данные с иерархической зависимостью и учитывать нестационарности во входных данных.

Результат суммирования выходов параллельных групп слоев подается на слой с долгой краткосрочной памятью (LSTM-слой с размером скрытого слоя $n_h = 32$). За ним следует слой нелинейной активации с утечкой (с коэффициентом 0.05) и слой dropout ($p_{dropout} = 0.2$), полносвязный слой и слой выхода классификатора.

Поскольку результаты предварительных испытаний показали превалирование сети-генератора в обучении данной архитектуры GAN при Glorot-инициализации [25], архитектура сети-дискриминатора была предварительно обучена на наборе данных, составленном из реальных сигналов из основной обучающей выборки и сгенерированных случайных гауссовых сигналов с нулевым средним и дисперсией, равной дисперсии реальных сигналов. Предобучение проходило в течение десяти эпох до достижения дискриминатором точности в 100 %.

Блок-схема, описывающая архитектуру сети-генератора, приведена на рис. 5.

На вход сети-генератора подавался случайный вектор длиной $L = 900$ из скрытого пространства z с нормальным распределением. Для генерации сигнала было решено использовать архитектуру с двумя последовательными блоками из групп параллельных слоев. Параллельная группа состоит из

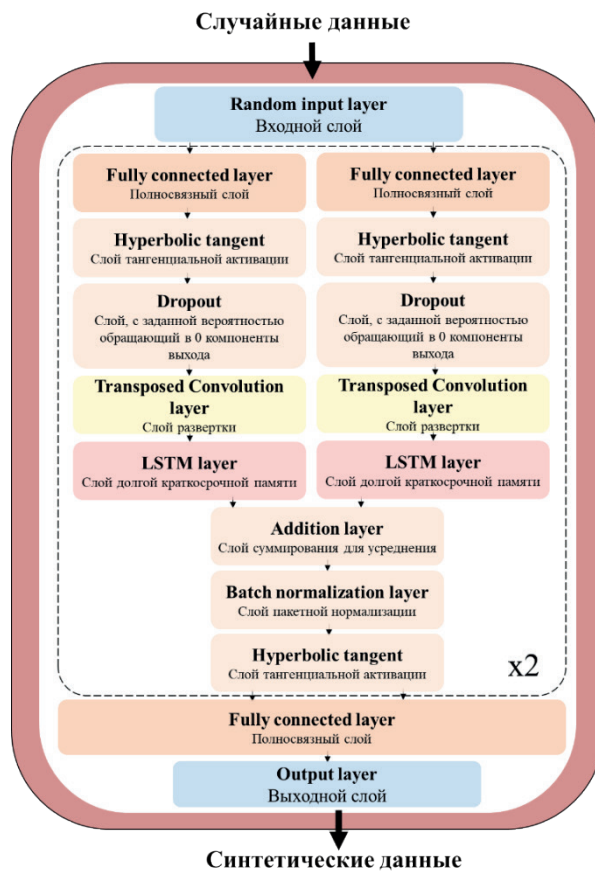


Рис. 5. Блок-схема архитектуры сети-генератора

полносвязного слоя, за которыми следует слой тангенциальной активации, слой dropout ($p_{dropout} = 0.2$), слой транспонированной свертки (ширина фильтра 16) и рекуррентный слой (LSTM-слой с размером скрытого слоя $n_h = 32$). После параллельных блоков применялся слой пакетной нормализации.

Как показали предварительные результаты обучения сети, в качестве слоя активации в данном блоке лучше использовать гиперболический тангенс, так как ReLU приводит к появлению большого числа вырожденных сигналов.

Метод, который был использован для обучения данной нейронной сети, основан на работе [12]. Для обучения архитектуры генератор-дискриминатор использовался оптимизатор adam с параметрами скорости обучения 10^{-3} , затухания градиента 0.5 и затухания квадрата градиента 0.999. Все программы для предобработки данных и инфраструктура для обучения сети были реализованы в Matlab. Обучение проводилось на рабочей станции HP Z8 на графическом процессоре NVIDIA Quadro RTX-4000. Обучение заняло 1 000 эпох, размер пакета данных был выбран равным 128. В течение каждой эпохи дискриминатор псевдослучайно обучался от 0 до 2 раз, а генератор – один раз. Коэффициент штрафа за градиент λ был установлен равным 2.

4. Результаты и обсуждение

Для качественной оценки результатов работы генератора было проведено визуальное сравнение синтетических данных с реальными во временной и частотной области. На рис. 6а приведено временное представление случайной пары из реального и синтетического сигналов. Спектральная плотность мощности шумов данных сигналов приведена на рис. 6б. Как можно увидеть, среднее значение сгенерированных данных незначительно отличается от нуля, а дисперсия синтетических данных близка к дисперсии реальных. Спектры сигналов имеют схожую форму.




Рис. 6. Сравнение сгенерированных и полученных экспериментально флуктуаций напряжения (а); спектральная характеристика сгенерированных и полученных экспериментально флуктуаций напряжения (SoC = 50 %) (б)

Известной трудностью в обучении GAN-архитектур является проблема вырождения генерируемых сигналов к обучающей выборке. Поэтому для качественной оценки влияния числа эпох обучения на вариативность данных был применен алгоритм стохастического вложения соседей с t -распределением (t -SNE).

Данный алгоритм машинного обучения определяет сходство между сигналами как расстояние между ними в многомерном пространстве и при помощи минимизации расстояния Кульбака – Лейблера проводит отображение распределенных по Гауссу многомерных данных в распределенные по Стюденту данные в пространстве меньшей размерности [26]. Это позволяет оценить вариативность и подобие данных после их отображения.

Используя t -SNE, мы смогли проследить как число итераций процесса обучения (в эпохах) влияет на качество сгенерированных синтетических данных. Распределение данных в таком виде представлено на рис. 7.




Рис. 7. Влияние числа эпох обучения на распределение данных, визуализированное при помощи метода TSNE: а) квадраты расстояния для двумерной проекции в зависимости от числа эпох обучения; цветом – сгенерированные данные; серым – область, в которой лежат значения реальных сигналов; серые рамки – области, в которых сгенерированные сигналы имеют наилучшее соотношения подобия с реальными и вариативности; б) трехмерное представление генерируемых данных при помощи TSNE

Можно заметить повторяющийся паттерн: с ростом числа эпох обучения с периодом около 200 эпох происходит увеличение уровня сходства реальных и сгенерированных сигналов. При этом наибольшую стабильность генерируемых значений имеют области в районе 400 и 1000 эпох обучения. Финальные результаты обучения генератора при этом имеют наибольшую вариативность и лежат в области значений реальных данных.

Для количественной оценки результатов работы GAN-архитектуры использовались следующие метрики:

- 1) наклон графика спектральной плотности мощности шума γ_{sint} ;
- 2) косинусное расстояние между синтетическим и реальными сигналами D_{cos} .

Для анализа при помощи последней итерации обучения сети-генератора была сгенерирована и размечена LSTM-сетью по категориям заряда выборка из 1000 синтетических сигналов.

Результаты спектрального анализа сгенерированных сигналов показали, что, исходя из предположения о нормальности распределения наклона цветной составляющей шума и применяя квантили распределения Стюдента коэффициент наклона СПМ γ_{sint} для синтетических данных, можно с надежностью 95 % оценить из выборки сгенерированных сигналов как $\gamma_{sint} = -1.04 \pm 0.09$. Поскольку значение коэффициента наклона для реальных сигналов ($\gamma_{real} = -0.96$) попадает в доверительный интервал значений синтетических, различие в среднем наклоне принимается незначимым.

Косинусное расстояние [27] позволяет попарно оценить сходство сигналов и имеет смысл косинуса между векторами в многомерном пространстве:

$$D_{cos} = \frac{\sum_{i=1}^N F'_i \cdot F''_i}{\sqrt{\sum_{i=1}^N F'^2_i \cdot \sum_{i=1}^N F''^2_i}}, \quad (7)$$

где F'_i, F''_i – i -я компонента спектральной плотности мощности для двух сравниваемых сигналов длиной N . Чем ближе D_{cos} к 1, тем выше сходство между сигналами.

Косинусные расстояния были рассчитаны по формуле (7) отдельно для спектров каждой пары реальных сигналов. Затем расстояния были усреднены по всем проведенным сравнениям. Аналогичная операция сравнения и усреднения была проведена для сгенерированных данных. Затем было проведено

сравнение между парами из сгенерированных и реальных сигналов. Результаты проведенных расчетов приведены в табл. 1.

Таблица 1. Средние косинусные расстояния $\bar{D}_{\cos}$ между спектрами сигналов в группах данных

$\bar{D}_{\cos}$	Реальные сигналы	Синтетические сигналы	Гауссов шум
Реальные сигналы	0.7921	0.8101	0.7623
Синтетические сигналы	0.8101	0.8522	0.7996
Гауссов шум	0.7623	0.7996	0.8303

Как показывают результаты расчета косинусных расстояний, синтетические сигналы имеют большее подобие с реальными (среднее расстояние $\bar{D}_{\cos} = 0.8101$), чем реальные сигналы с псевдослучайным гауссовым шумом ($\bar{D}_{\cos} = 0.7623$) и между собой ($\bar{D}_{\cos} = 0.7921$). Последнее объясняется усреднением параметров сигналов при генерации.

После проведения количественного анализа сгенерированные данные были размечены при помощи предварительно обученной нейронной сети, основанной на архитектуре [12]. Примененная архитектура показана на рис. 8. Данная сеть решает задачу регрессии, сопоставляя сигналу напряжения уровень заряда аккумулятора.




Рис. 8. Блок-схема архитектуры глубокой нейронной сети для решения задачи контроля состояния аккумулятора по шумам напряжения

Распределение присвоенных сгенерированным данным степеней заряженности аккумулятора (SoC) представлен на рис. 9. Возможный перекоп в сторону больших значений степеней заряженности может объясняться особенностями вычисления ошибки регрессии нейронной сети в области низких значений заряда.

Многokrатно повторяя генерацию сигнала и отбирая при помощи нейронной сети классификатора сигналы с требуемым SoC , возможно синтезировать шумовые характеристики источников тока на протяжении всего разряда. Пример генерации шумовой характеристики для полного разряда ХИТ приведен на рис. 10. Применение данной методики для численного моделирования значений шума затрачивает на используемом оборудовании на порядок меньше времени, чем проведение дополнительных натурных экспериментов.

Полученные синтетические данные были замешаны в обучающий набор данных, и было заново проведено обучение нейронной сети для определения SoC . Методика обучения сети была аналогична описанной в работе [12]. Благодаря увеличению объема обучающих данных удалось добиться снижения средней ошибки определения заряда элемента методом интерпретации электрохимических шумов с 6.8 до 4.9 %.




Рис. 9. Распределение сгенерированных данных по степени заряженности (SoC) среди 1000 сгенерированных сигналов




Рис. 10. Пример генерации шумовой характеристики для полного разряда ХИТ. Красным цветом указан сгенерированный сигнал, синим цветом – реальный сигнал

Закключение и выводы

Была разработан и валидирован новый метод моделирования шумовых характеристик химических источников тока, основанный на применении генеративно-состязательных нейронных сетей. Показано, как генерируемые синтетические данные о флуктуациях напряжения могут быть применены для аугментации наборов данных для машинного обучения.

В основу архитектуры сети-генератора были положены слои с долгой краткосрочной памятью (LSTM) и слои тангенциальной активации, что позволило избежать вырождения синтетических сигналов. Сеть-дискриминатор, в свою очередь, была основана на комбинации сверточных и рекуррентных слоев в параллельно-последовательном соединении. Для предотвращения доминирования генератора дискриминатор был предобучен на наборе данных из реальных сигналов и гауссова шума.

Генеративно-состязательная нейронная сеть была обучена на экспериментально полученных данных о разряде литий-ионных источников тока. Для составления обучающего набора данных экспериментально полученные сигналы напряжения были детрендированы при помощи методики на основе вариационной декомпозиции и разбиты на участки с изменением состояния заряженности элемента не более, чем на 2 %. Было показано, что вошедшие в набор данных сигналы шумов напряжения квазистационарны.

Как показывает качественный анализ результатов работы GAN, синтетические данные достаточно полно покрывают пространство реальных сигналов, не вырождаясь к отдельным его элементам. Синтетические данные имеют схожие с реальными статистические и спектральные характеристики. Сгенерированные шумы напряжения обладают большим сходством с реальными сигналами, чем простой гауссов шум.

Разметка синтетических данных при помощи глубокой нейронной сети для определения степени заряженности по шумовым характеристикам позволяет использовать предложенную методику для аугментации наборов данных для применения в методах «обучения с учителем». Результаты разметки сгенерированных сигналов показывают, что для применения методики достаточно измерения 30–40 экспериментальных кривых, при этом не менее половины экспериментальных данных должны быть получены при степенях заряженности элементов от 0 до 50 %.

Как показано на примере сети [12], применение созданной GAN-сети для аугментации обучающих наборов данных позволяет улучшить точность работы глубоких нейронных сетей, позволяя снизить ошибку до менее чем 5 %.

Финансирование

Данное исследование не получило внешнего финансирования.

Конфликт интересов

Автор заявляет, что у него нет конфликта интересов.

Список литературы

1. Li X., Jiang J., Zhang C., Wang L.Y., Zheng L. Robustness of SOC Estimation Algorithms for EV Lithium-Ion Batteries against Modeling Errors and Measurement Noise // *Mathematical Problems in Engineering*, 2015. P. 1 – 14. DOI: 10.1155/2015/719490.
2. Zhang L., Shen Z., Sajadi S.M., Prabuwno A.S., Mahmoud M.Z., Cheraghian G., ElSayed M., Tag El Din. The machine learning in lithium-ion batteries: A review // *Engineering Analysis with Boundary Elements*, 2022. V.141. P. 1 – 16. DOI: 10.1016/jenganabound.2022.04.035.
3. Eleftheriadis P., Gangi M., Leva S., Rey A.V., Groppo E., Grande L. Comparative study of machine learning techniques for the state of health estimation of Li-Ion batteries // *Electric Power Systems Research*, 2024. V. 235. Article ID: 110889. DOI: 10.1016/j.epsr.2024.110889.
4. Faragher R. Understanding the Basis of the Kalman Filter Via a Simple and Intuitive Derivation [Lecture Notes] // *IEEE signal processing magazine*, 2012. V. 29. Iss.5. P.128 – 132. DOI: 10.1109/MSP.2012.2203621.
5. Xie J., Wei X., Bo X., Zhang P., Chen P., Hao W., Yuan M. State of charge estimation of lithium-ion battery based on extended Kalman filter algorithm // *Frontiers in Energy Research*, 2023. V. 11. Article ID: 1180881. DOI: 10.3389/fenrg.2023.1180881.
6. Tian Y., Lai R., Li X., Xiang L., Tian J. A combined method for state-of-charge estimation for lithium-ion batteries using a long short-term memory network and an adaptive cubature Kalman filter // *Applied Energy*, 2020 V.265(C). Article ID: 114789. DOI: 10.1016/j.apenergy.2020.114789.
7. Астафьев Е.А. Измерение электрохимических шумов твердополимерного топливного элемента под нагрузкой // *Электрохимия*, 2018. Т. 54. № 6. С. 638 – 645.
8. Астафьев Е.А. Измерение и анализ электрохимических шумов литий-ионного аккумулятора // *Электрохимия*, 2019. Т. 55. № 6. С. 654 – 662.
9. Astafev E.A. Electrochemical noise measurement of a lithium iron(II) phosphate (LiFePO₄) rechargeable battery // *Instrumentation Science and Technology*, 2019. V.10. DOI: 10.1080/10739149.2019.1658601.
10. Астафьев Е.А. Сравнение различных подходов в анализе электрохимических шумов на примере водородно-воздушного топливного элемента // *Электрохимия*, 2020. Т. 56. № 2. С. 167 – 174. DOI: 10.1134/S0424857020020036.
11. Astafev E.A. State-of-charge determination of Li/SOCl₂ primary battery by means of electrochemical noise measurement // *Journal of Solid State Electrochemistry*, 2019. V. 23. P. 1493 – 1504.
12. Попов А.Г., Мозговой Н.А., Суцень Г.Н., Пиджаков В.А., Ульянов С.А. Применение методов глубокого обучения для анализа флуктуаций напряжения литиевых источников тока // *Труды МФТИ*, 2023. Т. 15. № 4 (60). С. 150 – 161.
13. Martemianov S., Maillard F., Thomas A., Lagonotte P., Madier L. Noise Diagnosis of Commercial Li-Ion Batteries Using High-Order Moments // *Russian Journal of Electrochemistry*, 2016. V. 52. № 12. P. 1122 – 1130.
14. Sarker I.H. Machine learning: Algorithms, real-world applications and research directions // *SN Computer Science*, 2021. № 2. P. 1 – 21.
15. Попов А.Г., Еремин Н.В., Мозговой Н.А. Спектральное исследование электрохимических шумов литиевых источников тока // *Труды МФТИ*, 2021. Т.13. № 2(50). С. 23 – 31.
16. Goodfellow I.J., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. Generative Adversarial Networks // *arXiv* 2014, arXiv:1406.2661.
17. Karras T., Aila T., Laine S., Lehtinen J. Progressive growing of GANs for improved quality, stability, and variation // *arXiv preprint*, 2017. arXiv:1710.10196.
18. Ledig C., Theis L., Huszar F., Caballero J., Cunningham A., Acosta A., Aitken A.P., Tejani A., Totz J., Wang Z. et al. Photo-realistic single image super-resolution using a generative adversarial network // *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017. DOI: 10.1109/CVPR.2017.19.
19. Fedus W., Goodfellow I., Dai A.M. MaskGAN: Better text generation via filling in the _____ // *arXiv preprint*, 2018. arXiv:1801.07736. DOI: 10.48550/arXiv.1801.07736.
20. Liang X., Hu Z., Zhang H., Gan C., Xing E.P. Recurrent topictransition GAN for visual paragraph generation // *arXiv preprint*, 2017. arXiv:1703.07022.
21. Mogren O. C-RNN-GAN: Continuous recurrent neural networks with adversarial training // *arXiv preprint*, 2016. arXiv:1611.09904.
22. Yang L.-C., Chou S.-Y., Yang Y.-H. Midinet: A convolutional generative adversarial network for symbolic-domain music generation // *arXiv preprint*, 2017. arXiv:1703.10847.

23. Yang G., Ma Q., Sun H., Zhang X. State of Health Estimation Based on GAN-LSTM-TL for Lithium-ion Batteries // International Journal of Electrochemical Science, 2022. V. 17. № 221128. DOI: 10.20964/2022.11.07.
24. Wong K.L., Chou K.S., Tse R., Tang S.-K., Pau G.A. Novel Fusion Approach Consisting of GAN and State-of-Charge Estimator for Synthetic Battery Operation Data Generation // Electronics, 2023. V. 12. № 657. DOI: 10.3390/electronics12030657.
25. Glorot X., Bengio Y. Understanding the Difficulty of Training Deep Feedforward Neural Networks // Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics, 2010. Sardinia, Italy: AISTATS, 2010. P. 249–356. <https://proceedings.mlr.press/v9/glorot10a/glorot10a.pdf>.
26. Van der Maaten L., Hinton G. Visualizing Data using *t*-SNE // Journal of Machine Learning Research, 2008. V. 9. Iss. 86. P. 2579–2605.
27. Sidorov G., Gelbukh A., Gómez-Adorno H., Pinto D. Soft Similarity and Soft Cosine Measure: Similarity of Features in Vector Space Model // Computación y Sistemas, 2014. V. 18. № 3. P. 491–504. DOI: 10.13053/CyS-18-3-2043.

Vestnik Natsional'nogo Issledovatel'skogo Yadernogo Universiteta «MIFI», 2025, vol. 14, no. 4, pp. 339–351

Generative adversarial network for power sources' noise characteristics modeling

A.G. Popov ^{1,2,✉}

¹ Moscow Institution of Physics and Technology, Moscow, 117303, Russia

² Central Scientific Research Institute of Chemistry and Mechanics, Moscow, 115487, Russia

✉ popov.ag@phystech.edu

Received July 11, 2025; revised July 25, 2025; accepted July 30, 2025

The article presents a new approach for modeling voltage noise of chemical power sources for the purpose of datasets augmentation. For the first time known machine learning methods were applied for modelling of the voltage noises of lithium-ion batteries: a generative adversarial neural network based on LSTM layers was designed for this task. A brief statistical and spectral analysis of experimental voltage fluctuations is given. A qualitative and quantitative study of synthetic noise signals is carried out based on the performed analysis of real data. It is shown how the classification of generated data by a deep neural network results in generation of noise characteristics for a given state of charge of the battery. It is recommended how to apply the proposed technique to improve precision of interpretation of voltage fluctuations in power sources. An experimental assessment of the method's effectiveness is given: a decrease in the determination error of the battery's state of charge from its noise went from 6.8% to 4.9%.

Keywords: generative adversarial networks, chemical power sources, power spectral density, voltage noise.

References

1. Li X., Jiang J., Zhang C., Wang L. Y., Zheng L. Robustness of SOC Estimation Algorithms for EV Lithium-Ion Batteries against Modeling Errors and Measurement Noise. Mathematical Problems in Engineering, 2015. Pp. 1–14. DOI: 10.1155/2015/719490.
2. Zhang L., Shen Z., Sajadi S.M., Prabuwno A.S., Mahmoud M.Z., Cheraghian G., ElSayed M., Tag El Din. The machine learning in lithium-ion batteries: A review. Engineering Analysis with Boundary Elements, 2022. Vol. 141. Pp. 1–16. DOI: 10.1016/j.enganabound.2022.04.035.
3. Eleftheriadis P., Gangi M., Leva S., Rey A.V., Groppo E., Grande L. Comparative study of machine learning techniques for the state of health estimation of Li-Ion batteries. Electric Power Systems Research, 2024. Vol. 235. Article ID: 110889. DOI: 10.1016/j.epsr.2024.110889.
4. Faragher R. Understanding the Basis of the Kalman Filter Via a Simple and Intuitive Derivation [Lecture Notes]. IEEE signal processing magazine, 2012. Vol. 29. Iss. 5. Pp. 128–132. DOI: 10.1109/MSP.20212.2203621.

5. Xie J., Wei X., Bo X., Zhang P., Chen P., Hao W., Yuan M. State of charge estimation of lithium-ion battery based on extended Kalman filter algorithm. *Frontiers in Energy Research*, 2023. Vol. 11. Article ID: 1180881. DOI: 10.3389/fenrg.2023.1180881.
6. Tian Y., Lai R., Li X., Xiang L., Tian J. A combined method for state-of-charge estimation for lithium-ion batteries using a long short-term memory network and an adaptive cubature Kalman filter. *Applied Energy*, 2020. Vol. 265. Article ID: 114789. DOI: 10.1016/j.apenergy.2020.114789.
7. Astafiev E.A. Izmerenie elektrohimijskix шумов tverdogopolimernogo toplivnogo elementa pod nagruzkoi [Measurement of electrochemical noise of a solid polymer fuel cell under load]. *Elektrokhimiya*, 2018. Vol. 54. No. 6. Pp. 638–645 (in Russian).
8. Astafiev E.A. Izmerenie i analiz elektrohimijskix шумов litij-ionnogo akkumulyatora [Measurement and analysis of electrochemical noise of a lithium-ion battery]. *Elektrokhimiya*, 2019. Vol. 55. No. 6. Pp. 654–662 (in Russian).
9. Astafiev E.A. Electrochemical noise measurement of a lithium iron(II) phosphate (LiFePO₄) rechargeable battery. *Instrumentation Science and Technology*, 2019. Vol. 10. DOI: 10.1080/10739149.2019.1658601.
10. Astafiev E.A. Sravneniye razlichnykh podhodov v analize elektrokhimicheskix шумов vodorodno-vozdushnogo toplivnogo elementa [Comparison of different approaches towards electrochemical noise analysis of air-hydrogen fuel cell]. *Electrochemistry*, 2020. Vol. 56. No. 2. Pp. 167–174 (in Russian). DOI: 10.1134/S0424857020020036.
11. Astafiev E.A. State-of-charge determination of Li/SOCl₂ primary battery by means of electrochemical noise measurement. *Journal of Solid State Electrochemistry*, 2019. Vol. 23. Pp. 1493–1504.
12. Popov A.G., Mozgovoy N.A., Sushchenya G.N., Pidzhakov V.A., Ulyanov S.A. Primeneniye metodov glubokogo obucheniya dlya analiza fluktuacij napryazheniya litievykh istochnikov toka [Application of deep learning methods for the analysis of voltage fluctuations of lithium power sources]. *Trudy MFTI*, 2023. Vol. 15. No. 4 (60). Pp. 150–161 (in Russian).
13. Martemianov S., Maillard F., Thomas A., Lagonotte P., Madier L. Noise Diagnosis of Commercial Li-Ion Batteries Using High-Order Moments. *Russian Journal of Electrochemistry*, 2016. Vol. 52. No. 12. Pp. 1122–1130.
14. Sarker I.H. Machine learning: Algorithms, real-world applications and research directions. *SN Computer Science*, 2021. No. 2. Pp. 1–21.
15. Popov A.G., Eremin N.V., Mozgovoy N.A. Spektral'noe issledovanie elektrohimijskix шумов litievykh istochnikov toka [Spectral study of electrochemical noise in lithium power sources]. *Trudy MFTI*, 2021. Vol. 13. No. 2 (50). Pp. 23–31 (in Russian).
16. Goodfellow I.J., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. Generative Adversarial Networks. *arXiv* 2014, arXiv:1406.2661
17. Karras T., Aila T., Laine S., Lehtinen J. Progressive growing of GANs for improved quality, stability, and variation. *arXiv preprint*, 2017. arXiv:1710.10196.
18. Ledig C., Theis L., Huszar F., Caballero J., Cunningham A., Acosta A., Aitken A.P., Tejani A., Totz J., Wang Z. et al. Photo-realistic single image super-resolution using a generative adversarial network. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017. DOI: 10.1109/CVPR.2017.19.
19. Fedus W., Goodfellow I., Dai A.M. MaskGAN: Better text generation via filling in the _____. *arXiv preprint*, 2018. arXiv:1801.07736. DOI: 10.48550/arXiv.1801.07736.
20. Liang X., Hu Z., Zhang H., Gan C., Xing E.P. Recurrent topictransition GAN for visual paragraph generation. *arXiv preprint*, 2017. arXiv:1703.07022.
21. Mogren O. C-RNN-GAN: Continuous recurrent neural networks with adversarial training. *arXiv preprint*, 2016. arXiv:1611.09904.
22. Yang L.-C., Chou S.-Y., Yang Y.-H. Midinet: A convolutional generative adversarial network for symbolic-domain music generation. *arXiv preprint*, 2017. arXiv:1703.10847.
23. Yang G., Ma Q., Sun H., Zhang X. State of Health Estimation Based on GAN-LSTM-TL for Lithium-ion Batteries. *International Journal of Electrochemical Science*, 2022. Vol. 17. No. 221128. DOI: 10.20964/2022.11.07.
24. Wong K.L., Chou K.S., Tse R., Tang S.-K., Pau G. A. Novel Fusion Approach Consisting of GAN and State-of-Charge Estimator for Synthetic Battery Operation Data Generation. *Electronics*, 2023. Vol. 12. No. 657. DOI: 10.3390/electronics12030657.
25. Glorot X., Bengio Y. Understanding the Difficulty of Training Deep Feedforward Neural Networks. *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics*, 2010. Sardinia, Italy, AISTATS, 2010. Pp. 249–356. <https://proceedings.mlr.press/v9/glorot10a/glorot10a.pdf>.
26. Van der Maaten L., Hinton G. Visualizing Data using t-SNE. *Journal of Machine Learning Research*, 2008. Vol. 9. Iss. 86. Pp. 2579–2605.
27. Sidorov G., Gelbukh A., Gómez-Adorno H., Pinto D. Soft Similarity and Soft Cosine Measure: Similarity of Features in Vector Space Model. *Computación y Sistemas*, 2014. Vol. 18. No. 3. Pp. 491–504. DOI: 10.13053/CyS-18-3-2043.