

К вопросу идентификации параметров полной модели литийионных аккумуляторов, полученной методом математического прототипирования энергетических процессов

С.И. Гавриленков¹

¹Московский государственный технический университет гражданской авиации,
г. Москва, Россия

Аннотация: В работе рассматривается проблема идентификации параметров полной математической модели литийионных аккумуляторов (ЛИА), построенной на основе метода математического прототипирования энергетических процессов (ММПЭП). Актуальность темы обусловлена растущим применением ЛИА в авиации, в том числе в беспилотных авиационных системах, и необходимостью обеспечения надежности и долговечности аккумуляторов за счет точного прогнозирования их характеристик. Описан подход ММПЭП, который позволяет получать модели, строго соответствующие законам сохранения энергии и законам термодинамики, а также учитывать физико-химические особенности конкретных аккумуляторов. Особое внимание уделяется этапам идентификации параметров модели – от первичного приближения на основе экспериментальных данных до дальнейшей оптимизации с помощью современных численных методов и алгоритмов машинного обучения. Проводится анализ современных инструментов для идентификации параметров, включая алгоритмы XGBoost, Random Forest и нейронные сети. Описан опыт построения и обучения инверсной нейронной сети на синтетических данных, сгенерированных на основе полной модели ЛИА, и отмечены особенности подготовки и отбора обучающих данных для улучшения качества предсказаний. Проведен анализ чувствительности модели к различным параметрам, что позволило выделить наиболее значимые параметры для последующей идентификации и повышения точности диагностики состояния аккумуляторов. Представлена архитектура нейронной сети, сочетающая обработку временных рядов и статических признаков, и показаны результаты экспериментов по предсказанию ключевых параметров ЛИА. Отмечено, что полученная нейронная сеть может быть полезна на этапе грубой идентификации параметров, а дальнейшее развитие данного направления связано с использованием более сложных архитектур и интеграции физически информированных подходов для получения более точных математических моделей, которые могут быть положены в основу создания цифровых двойников литийионных аккумуляторов.

Ключевые слова: литийионный аккумулятор, метод математического прототипирования энергетических процессов, идентификация параметров, нейронные сети, анализ чувствительности.

Для цитирования: Гавриленков С.И. К вопросу идентификации параметров полной модели литийионных аккумуляторов, полученной методом математического прототипирования энергетических процессов // Научный Вестник МГТУ ГА. 2025. Т. 28, № 6. С. 37–52. DOI: 10.26467/2079-0619-2025-28-6-37-52

On the issue of identifying the parameters of the complete model of lithium-ion batteries obtained through the method of mathematical prototyping of energy processes

S.I. Gavrilenkov¹

¹Moscow State Technical University of Civil Aviation, Moscow, Russia

Abstract: This paper examines the problem of identifying the parameters of a complete mathematical model of lithium-ion batteries (LIBs), based on the Method of Mathematical Prototyping of Energy Processes (MMPEP). The relevance of this topic is due to the increasing use of LIBs in aviation, including unmanned aerial systems, and the necessity to ensure the reliability and

durability of batteries through accurate prediction of their characteristics. The MMPEP approach is outlined, which makes it possible to obtain models that rigorously comply with the laws of energy conservation and thermodynamics, while also considering the physicochemical characteristics of specific batteries. Particular focus is given to the stages of model parameter identification – from initial approximation based on experimental data to further optimization using modern numerical methods and machine learning algorithms. The study analyzes current tools for parameter identification, including XGBoost, Random Forest, and neural networks. It describes the development and training of an inverse neural network on synthetic data generated from the complete LIB model, and highlights the features of preparing and selecting strategies to improve prediction quality. A sensitivity analysis of the model to the various parameters is conducted, thereby enabling more targeted identification and improving the accuracy of battery diagnostics. The neural network architecture combining time-series processing and static features is presented, along with the results of experiments predicting key LIB parameters. It is noted that the obtained neural network can be useful in the rough parameter identification stage, whereas further developments will involve more complex architectures and integration of physically informed approaches to achieve more accurate mathematical models that can serve as the basis for creating digital twins of lithium-ion batteries.

Key words: lithium-ion battery, method of mathematical prototyping of energy processes, parameter identification, neural networks, sensitivity analysis.

For citation: Gavrilenkov, S.I. (2025). On the issue of identifying the parameters of the complete model of lithium-ion batteries obtained through the method of mathematical prototyping of energy processes. Civil Aviation High Technologies, vol. 28, no. 6, pp. 37–52. DOI: 10.26467/2079-0619-2025-28-6-37-52

Введение

В последние годы литийионные аккумуляторы (ЛИА) получили широкое распространение в самых различных областях: от потребительской электроники до авиационной и космической промышленности. Высокие удельные энергетические показатели делают такие аккумуляторы особенно привлекательными для систем, требующих надежного и долговечного источника питания [1, 2]. Однако эффективное использование ЛИА подразумевает детальное понимание протекающих в них физических и химических процессов, а также постоянный мониторинг их текущего состояния для своевременного диагностирования и прогнозирования остаточной емкости и остаточного ресурса при разных режимах работы [3, 4].

Одним из перспективных методов диагностирования ЛИА является построение полной математической модели ЛИА, отражающей ключевые механизмы взаимодействия внутри ячейки: от кинетики электродных реакций до динамики распределения заряда на двойных слоях [5]. Такая математическая модель может быть основой цифрового двойника ЛИА [6]. Этот подход целесообразен при проектировании систем управления зарядом-разрядом, а также при реализации алгоритмов диагностирования и продления ресурса [1].

Для получения корректной математической модели ЛИА может применяться метод математического прототипирования энергетических процессов (ММПЭП) [5, 7, 8]. Он представляет собой единый формализм, основанный на законах механики, электродинамики и современной неравновесной термодинамики, позволяющий строить уравнения динамик процессов различной физической и химической природы. В рамках ММПЭП параметры аккумулятора не сводятся к абстрактным коэффициентам в эмпирических выражениях, а выводятся на основании физико-химических закономерностей и законов сохранения [7].

Вместе с тем для реальной эксплуатации важнейшей задачей является идентификация конкретных численных значений параметров полученной ММПЭП модели применительно к конкретному экземпляру ЛИА. В основу идентификации положено сопоставление результатов вычислительного эксперимента с экспериментальными данными реальных ЛИА [9]. Однако, учитывая существенную нелинейность, а нередко и высокую размерность полной модели ЛИА, наиболее целесообразным является обучение нейронной сети для параметров полной модели ЛИА. Нейросеть в этом случае имеет смысл интегрировать с полной моделью ЛИА [10].

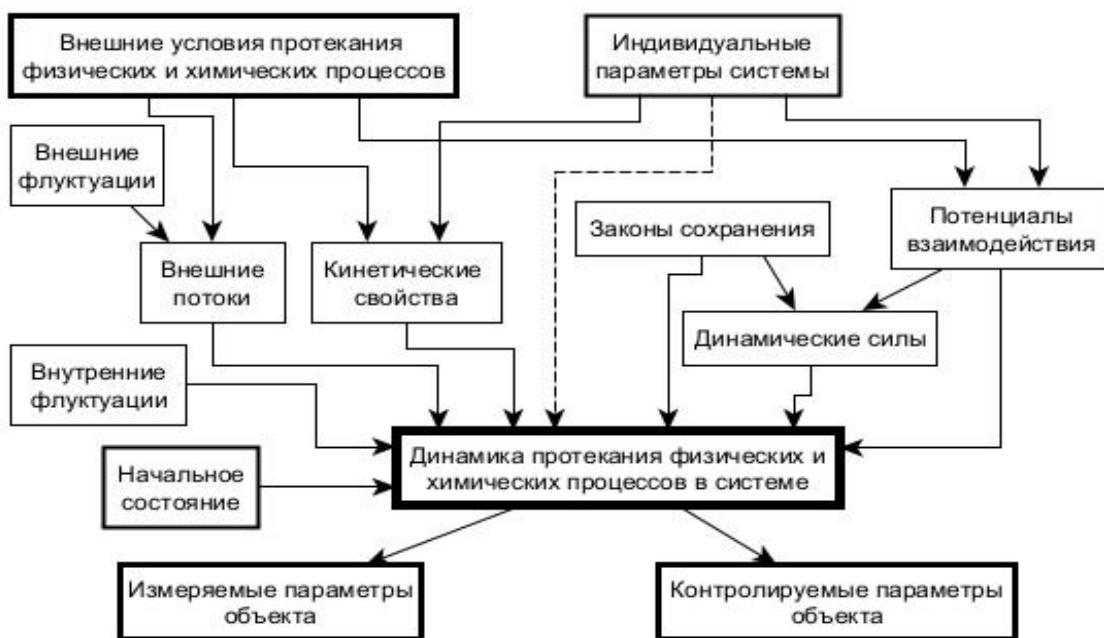


Рис. 1. Математическая модель системы для решения практических задач.

Пунктиром показаны задания аналитического решения

Fig. 1. Mathematical model of the system for solving practical problems.

The dashed line shows the tasks of the analytical solution

Целью данной статьи является анализ методов идентификации параметров полной модели ЛИА, построенной ММПЭП, в том числе и с использованием нейронных сетей. Предполагается, что результаты работы будут способствовать созданию более точных алгоритмов диагностики и прогнозирования ресурса литийионных аккумуляторов для широкого круга приложений.

Описание модели на основе метода математического прототипирования

ММПЭП представляет собой единый формализм, позволяющий строить уравнения динамики физических и химических систем, не противоречащие законам сохранения и термодинамики [5, 11]. Факторы, определяющие динамику физических и химических процессов, показаны на рис. 1. Для получения уравнений ММПЭП в численном виде задаются функциональные разложения для свойств веществ и процессов рассматриваемой системы с точностью до экспериментально исследуемых постоянных коэффициентов с учетом

соответствующих ограничений [3, 12]. Затем на основе результатов моделирования динамики строится динамика измеряемых и контролируемых параметров.

ММПЭП была построена полная модель ЛИА и выполнена ее программная реализация [4]. На вход упомянутой программной реализации подаются параметры функциональных разложений свойств веществ и процессов в ЛИА, его начальное состояние и температура окружающей среды [4]. На выходе программа возвращает динамики напряжения на клеммах, температуры внутреннего содержимого ЛИА, напряжений двойных слоев и мембранны, то есть моделирует поведение аккумулятора во времени и сохраняет результаты [4]. Полученная в [4] модель ЛИА включает более 60 независимых коэффициентов.

Каждый из упомянутых параметров полной модели ЛИА либо напрямую связывается с физическими величинами (емкости, ЭДС, сопротивления двойных слоев и мембранны), либо является поправочным множителем/дополнительным коэффициентом, уточняющим поведение системы в разных диапазонах за-

ряда, тока и температуры [4]. Предложенная в [4] полная модель ЛИА обеспечивает физическую корректность (не противоречит законам сохранения энергии и термодинамики) и требуемую точность при наличии достаточного числа экспериментальных данных.

Для численной реализации построенной в [4] полной модели ЛИА возникает задача идентификации ее параметров. На практике параметрическая идентификация может быть разбита на два этапа:

этап 1 – первичное приближение параметров. Целью этапа является получение грубых, но осмысленных стартовых значений параметров математической модели на основе анализа измеренных характеристик аккумулятора (например, $U(t)$, $I(t)$, $T(t)$);

этап 2 – оптимизация параметров. После получения стартовых значений они уточняются с использованием численных оптимизаторов, минимизирующих отклонение расчетной модели от экспериментальных данных. Например, можно использовать градиентные методы, такие как LBFGS и Adam [13, 14], или метод байесовской калибровки на основе методов MCMC/NUTS [15].

Второй задачей является получение упрощенных аналитических выражений с коэффициентами для конкретного реального аккумулятора, используя методы символьной регрессии [12]. Этот этап направлен на создание упрощенной аналитической модели, которая аппроксимирует поведение ЛИА на основе ранее идентифицированных параметров, полученных методом математического прототипирования энергетических процессов. Такие упрощенные аналитические модели строятся путем кусочно-аналитического упрощения исходных дифференциальных уравнений, полученных методом математического прототипирования, с последующей идентификацией постоянных коэффициентов модели из экспериментальных данных. Подобный подход обеспечивает минимальные вычислительные затраты и является основой для построения эффективных цифровых двойников, пригодных для задач мониторинга и управления аккумуляторами в реальном времени [16].

Для первичной оценки параметров модели по наблюдаемым данным рассмотрим следующие группы методов.

XGBoost (Extreme Gradient Boosting) представляет собой ансамблевый метод машинного обучения, основанный на градиентном бустинге деревьев решений. Он активно используется для задач регрессии и прогнозирования состояний литийионных аккумуляторов, таких как оценка состояния здоровья (State of Health, SOH) и остаточного ресурса (Remaining Useful Life, RUL). В задачах параметрической идентификации аккумуляторов XGBoost применяется для построения инверсных регрессоров, обучаемых на синтетических наборах данных формата «динамика системы → параметры аккумулятора» [17, 18]. Настоящий подход обеспечивает высокую скорость вычислений и устойчивость к шумовым данным, однако не учитывает физические ограничения модели. Это может привести к появлению физически некорректных значений параметров при экстраполяции на условия, не входящие в обучающую выборку.

Random Forest (случайный лес) также является ансамблевым методом, который основывается на построении множества случайных деревьев решений с последующим их усреднением (голосованием). Несмотря на высокую точность при небольшом объеме данных и устойчивость к переобучению, его возможности в задачах точной параметрической идентификации ограничены. Это связано с отсутствием встроенного физического описания изучаемых процессов и относительно высокими требованиями к оперативной памяти при работе с большим числом признаков [19]. XGBoost и Random Forest – универсальные табличные ансамбли: хорошо работают на статических признаках, но не умеют извлекать закономерности во времени без предварительного агрегирования или созданных вручную признаков.

Инверсные нейронные сети INN (Inverse Neural Networks) применяются для решения обратной задачи, где входом служат временные ряды (U , I , T), а выходом – параметры аккумулятора (θ). Особый интерес представ-

ляют физически информированные нейронные сети (PINNs), которые учитывают в процессе обучения физические законы, например уравнения теплопереноса и баланса заряда. PINN-архитектуры обучаются так, чтобы предсказания не только соответствовали эксперименту, но и удовлетворяли системе дифференциальных уравнений [20, 21]. Это делает их особенно подходящими для задач параметрической идентификации аккумуляторов, позволяя избежать физически некорректных решений. PINN особенно эффективны для задач, где доступны неполные данные, и они обеспечивают интерпретируемость, что важно для инженерных приложений.

Исследования показывают, что инверсные нейронные сети, особенно физически информированные нейронные сети (PINN), вероятно, наиболее подходящий выбор. Они интегрируют физические законы, такие как дифференциальные уравнения, в процесс обучения, что делает их эффективными для сложных задач параметрической оценки. Они продемонстрировали эффективность в оценке состояния заряда (SOC) и состояния здоровья (SOH), что связано с параметрами модели [20].

В сравнительных исследованиях нейронные сети с ансамблевым обучением и трансферным обучением (DCNN-ETL) показали лучшую точность и устойчивость по сравнению с Random Forest Regression, что подтверждает преимущество нейронных сетей для задач, связанных с состоянием батареи [19, 22].

Физически информированные нейронные сети довольно сложны в реализации, требуют специальных навыков в программировании, поэтому автором для решения задачи первичного приближения параметров была предпринята попытка создания более простой инверсной нейронной сети для задач параметрической идентификации. Комплекс программ, реализующих эту идею, получен с использованием LLM (большие языковые модели) Grok, ChatGPT o3, ChatGPT o4-mini-high, DeepSeek r1.

Для создания и обучения нейронных сетей критически важным является правильно подготовленные данные. Такие данные были по-

лучены из программной реализации модели литийионного аккумулятора, описанного выше.

Набор данных представляет собой разрядные характеристики, полученные при различных (случайных) параметрах модели литийионного аккумулятора. Для получения случайных параметров ЛИА была создана программа генерации параметров. Генератор параметров литийионного аккумулятора строится по принципу случайного выбора значений из заданных диапазонов с последующей фильтрацией или корректировкой тех параметров, которые нарушают физические или инженерные ограничения. Такой подход позволяет автоматизировать процесс формирования массивов данных для моделирования или обучения, исключая непригодные или противоречивые варианты. В начале каждый параметр выбирается из диапазона $p_i = [\min_i, \max_i]$ с равномерным распределением $p_i \sim U[\min_i, \max_i]$. Затем набор проверяется по ряду физических соотношений (табл. 1). В случае несоответствия значения корректируются или отклоняются, и набор параметров формируется заново. В результате сохраняется баланс между охватом пространства параметров и соответствия физико-химическим процессам.

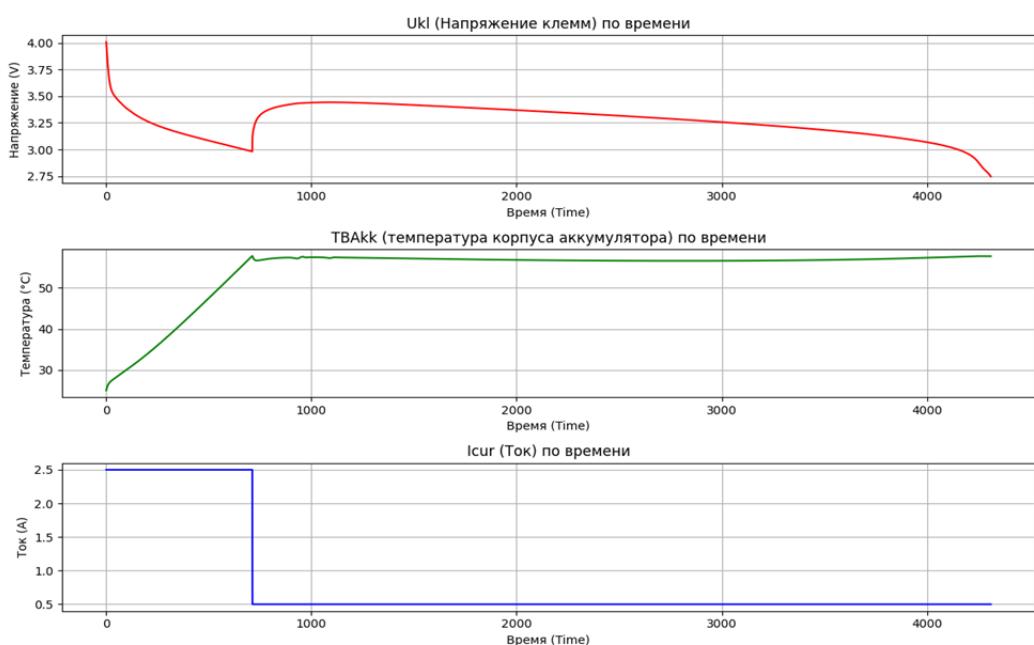
После получения разрядных характеристик каждого аккумулятора по полученным генерированным параметрам, встает вопрос оптимизации данных для обучения нейросети. С целью экономии вычислительных ресурсов производился отбор наиболее информативных сегментов данных. Для этих целей был реализован алгоритм автоматической обработки файлов, содержащих разрядные характеристики, извлекающий участки с наибольшей динамической активностью по напряжению и току. Это необходимо для формирования выборки, акцентированной на ключевых переходных процессах внутри аккумулятора.

Для каждого временного ряда выполняется извлечение трех ключевых сегментов – наблюдаемых параметров (рис. 2).

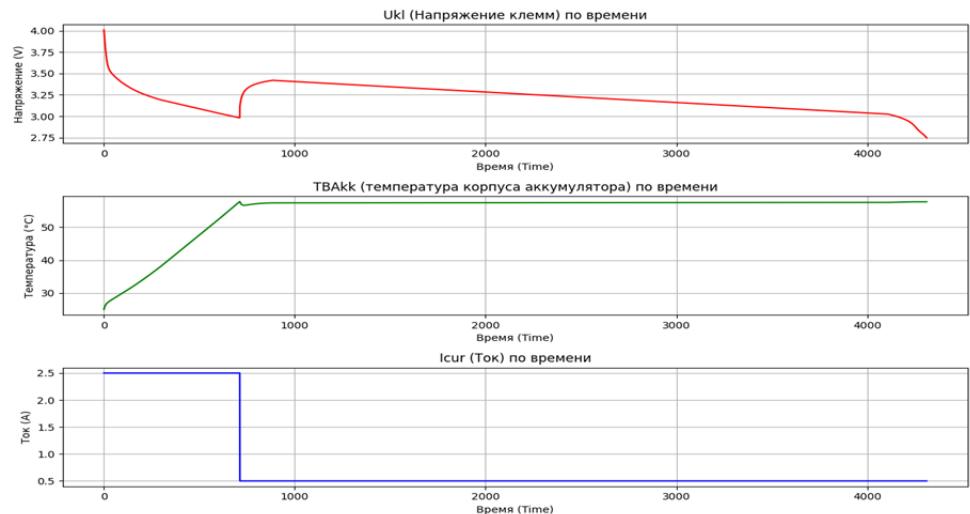
Таблица 1
Table 1

Физические ограничения генератора параметров
Physical limitations of the parameter generator

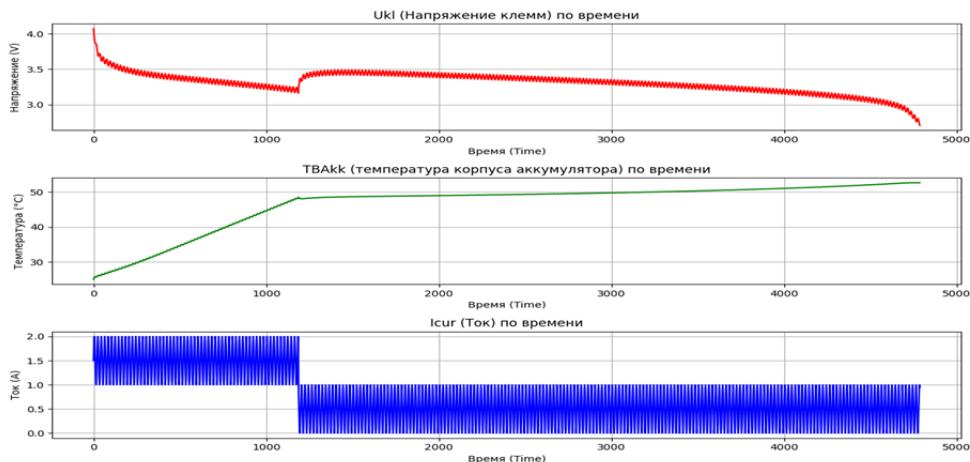
	Параметры	Формула ограничения	Физический смысл
1	EbinpC, EbinpD	$EbinpC > EbinpD + 0.05$	Заряженное состояние должно иметь большую ЭДС
2	EbinnC, EbinnD	$EbinnC > EbinnD + 0.05$	То же для отрицательного слоя
3	EbinpC, EbinnC	$EbinpC + EbinnC \geq 3.0 \text{ В}$	Минимальное напряжение заряженной ячейки
4	Rbin0p, Cbin0p	$Rbin0p \cdot Cbin0p < 100$	Ограничение на постоянную времени
5	CInAkk, CBAkk	$CInAkk \geq 5 \cdot CBAkk$	Теплоёмкость содержимого должна быть больше теплоёмкости корпуса
6	KInAkk, KBAkk	$KInAkk > KBAkk + 0.01$	Эффективная теплопередача внутри батареи
7	$\alpha_{RTp}, \alpha_{RTn}, \alpha_{RTm}$	$5\alpha_{RTm} \leq \alpha_{RTp}, \alpha_{RTn} \leq 10\alpha_{RTm}$	Электроды чувствительнее к температуре, чем мембрана
8	β_i	$ \beta_i \leq 0.1 \cdot \alpha_i$	Ограничение поправок 2–3-го порядка
9	$R_{kl}, R_{bin0p}, R_{bin0n}$	$R_{kl} < \min(R_{bin0p}, R_{bin0n}) / 10$	Клеммы почти не вносят сопротивление
10	T_{InAkk0}, T_{BAkk0}	$ T_{InAkk0} - T_{BAkk0} \leq 20^\circ\text{C}$	Реалистичное температурное распределение
11	R_{bin0n}, C_{bin0n}	$R_{bin0n} \cdot C_{bin0n} < 200$	Ограничение на время отклика отрицательного слоя



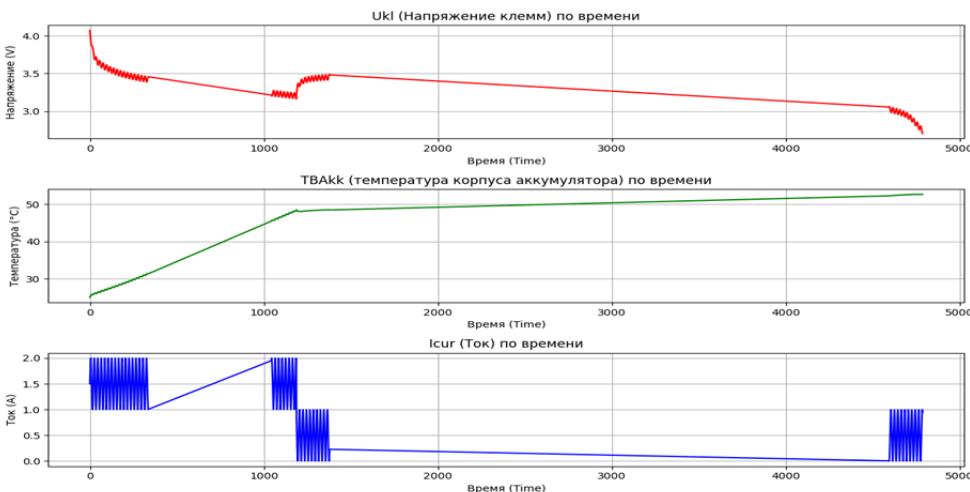
а



6



Б



Г

Рис. 2. а – данные моделирования; б – данные моделирования после обработки; в – моделирование с переменной составляющей; г – данные моделирования после обработки

Fig. 2. а – modeling data; б – modeling data after processing; в – modeling with a variable component; г – modeling data after processing

В случае несоответствия значения корректируются или отклоняются и набор параметров формируется заново. В результате сохраняется баланс между охватом пространства параметров и соответствием физико-химическим процессам.

Один сегмент по току: $d_t = |x_t - x_{t-1}|$, $d_0 = 0$ – модуль разности между соседними значениями сигнала. Поиск максимума $t^* = \operatorname{argmax} S_t$. Нахождение точки с наибольшими изменениями. Формирование отрезка $t_{\text{start}} = \max(0, t^* - \left[\frac{w}{2} \right])$, $t_{\text{end}} = t_{\text{start}} + w$. Выделение отрезка длины w вокруг максимума.

Два сегмента, соответствующих максимальному изменению напряжения (один в первой половине записи, другой – во второй):

$$S_t = \sum_{k=-[w/2]}^{w/2} d_{t+k}.$$

Суммирование изменений внутри окна длиной w . Все отобранные сегменты по времени объединяются, формируется итоговая таблица с привязкой к параметрам аккумулятора и метаданными.

$$\text{Ukl}_{\text{sum}_{\text{diff}}} = \sum_{i=1}^N (\text{Ukl}_{\text{mod}}(t_i) - \text{Ukl}_{\text{ref}}(t_i));$$

$$\text{Tbakk}_{\text{sum}_{\text{diff}}} = \int_{t_0}^{t_f} [\text{TBakk}_{\text{mod}}(t) - \text{TBakk}_{\text{ref}}(t)] dt.$$

Изменение производится поочередно для каждого параметра. Программа вычисляет участки максимального влияния каждого параметра и количественные различия между эталонной и модифицированной группами. Это позволяет определить наиболее значи-

Анализ чувствительности параметров

Одной из основных задач при анализе поведения модели литийионного аккумулятора на основе метода математического прототипирования энергетических процессов является оценка чувствительности выходных характеристик модели к изменению ее параметров. Это позволяет выявить наиболее влиятельные параметры, точность предсказания которых станет важным критерием эффективности нейросети.

Для фиксированного режима тока и эталонного аккумулятора A_{ref} с параметрами θ_{ref} моделируется временной ряд напряжения на клеммах $\text{Ukl}_{\text{ref}}(t)$ и температуры корпуса аккумулятора $\text{TBakk}_{\text{ref}}(t)$. Аналогично для аккумулятора A_{mod} , в котором один из параметров модели изменен на $\pm 10\%$, формируются временные ряды $\text{Ukl}_{\text{mod}}(t)$ и $\text{TBakk}_{\text{mod}}(t)$. На основе этих данных вычисляются интегральные разности:

мые параметры, снизить размерность задачи идентификации и повысить точность дальнейшего анализа. Таким образом был выявлен ряд параметров наибольшего влияния на изменение напряжения и температуры аккумулятора (рис. 3).

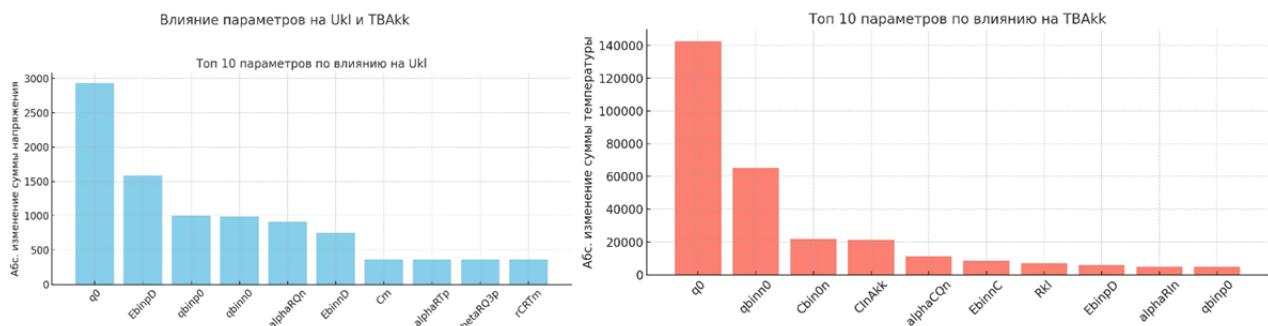


Рис. 3. Влияние параметров
Fig. 3. Impact of the parameters

Однако следует учесть, что при изменении только i -го параметра на $\pm 10\%$ оценивается только локальная чувствительность «один к одному» и игнорируется любое кроссвзаимодействие параметров. В много-параметрической среде это может привести к «скрытому раскачиванию»: два (или больше) коэффициента изменяют напряжение в противофазе, их индивидуальные интегральные эффекты велики, но совместное действие практически взаимокомпенсируется, и ранжирование по Δ_i дает неточную картину влияния. В дальнейших исследованиях планируется учесть взаимосвязь параметров при идентификации, чтобы «скрытое раскачивание» не перекочевало в нейронную сеть.

После подготовки данных были сформулированы следующие параметры нейронной сети.

На вход подаются динамические характеристики (временные ряды напряжения на клеммах аккумулятора (Ukl), температура аккумулятора (TBAkk), ток нагрузки (Icur), температура окружающей среды (Tokr). Эти временные ряды являются наблюдаемыми: они непрерывно измеряются установленными на аккумуляторе датчиками и поступают в нейронную сеть как известные входные сигналы; их значения не входят в вектор идентифицируемых параметров. Также подаются статические начальные параметры (не изменяющиеся во времени) начальная внутренняя температура аккумулятора (TInAkk0), начальная температура батареи (TBAkk0), начальный заряд аккумулятора (q0).

Для улучшения информативности входных данных были сформированы дополнительные признаки, такие как произведения напряжения и тока, разность температур, произведения времени на ток и напряжение, а также дискретные метки фрагментов временных рядов. Подготовленные данные были подвергнуты масштабированию при помощи алгоритмов стандартизации (StandardScaler), что способствует стабильности обучения и улучшению точности модели.

Архитектура нейронной сети

Используемая архитектура сочетает временные признаки (напряжение, ток, температура) с дополнительными статическими характеристиками и позволяет оценить физически осмысленные параметры батареи, такие как емкости двойных слоев, сопротивления, коэффициенты теплопередачи, параметры мембранны и др. Реализация использует сверточные, рекуррентные и attention-слои, а также стандартизацию входных данных, маскирование и смешанную точность вычислений (рис. 4).

Входные параметры:

$X^{(dyn)} = \{Ukl(t), TBakk(t), Icur(t), Tokr(t), t_{norm}(t)\}$ – временные (динамические) параметры, где Ukl – напряжение на клеммах аккумулятора, $TBakk$ – температура корпуса аккумулятора, $Icur$ – ток разряда, $Tokr(t)$ – температура окружающей среды, $t_{norm}(t)$ – нормализованное время.

Neural Network Architecture: Dynamic and Static Input Fusion

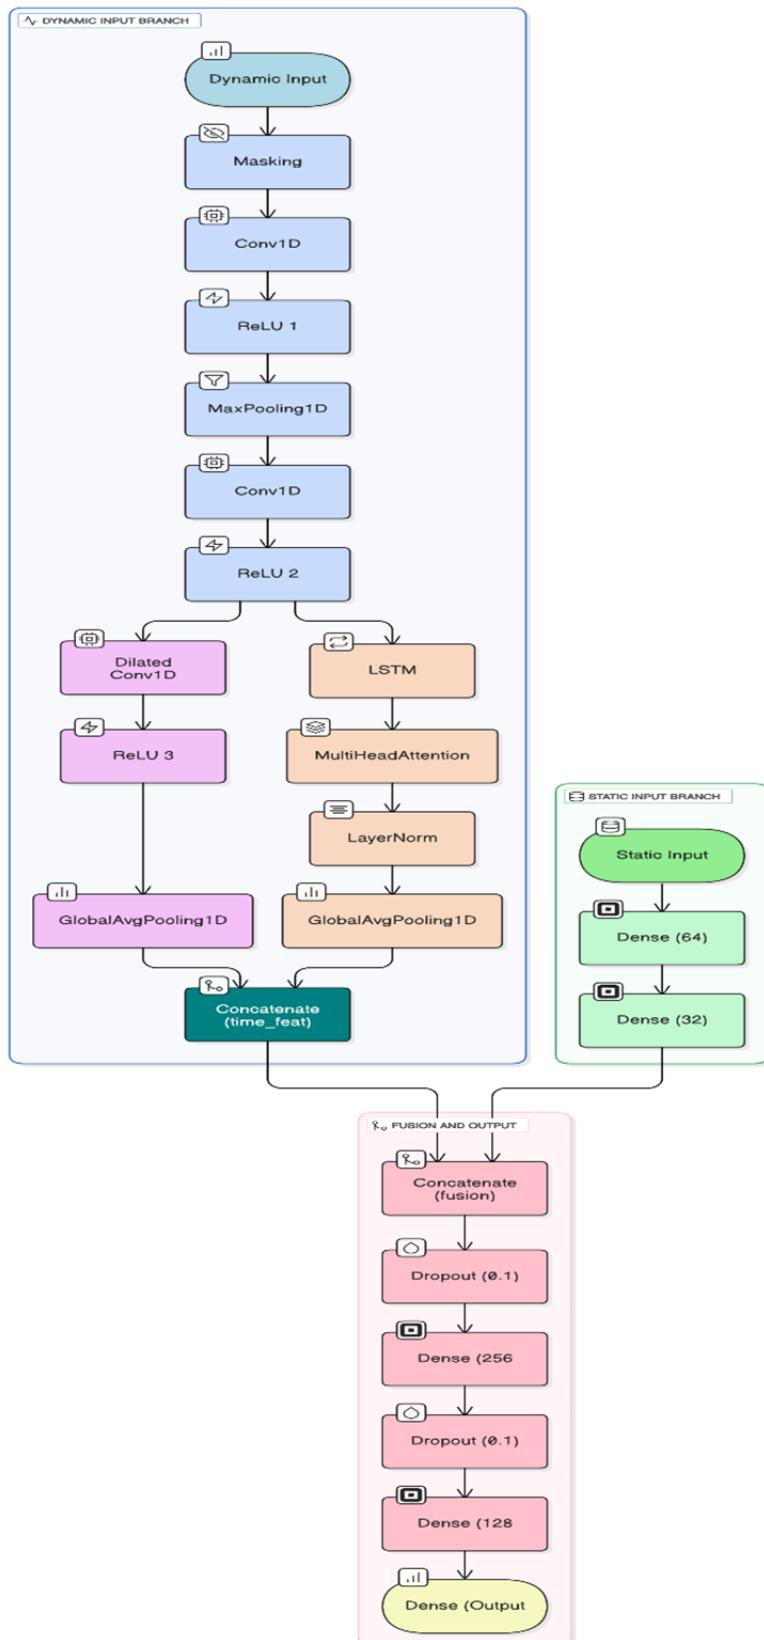


Рис. 4. Структура нейронной сети
Fig. 4. The structure of the neural network

$X^{(stat)} = \{TInAkk0,$
 $TBAkk0, q0, \int Ukl, \int Icur, \int |Icur|\}$ – статические параметры (не меняющиеся во времени), где $TBakk0$ – температура корпуса аккумулятора в начальный момент времени, $Tokr(t)$ – температура окружающей среды в начальный момент времени, $q0$ – начальный заряд.

Целевая функция: $Y = \{p_1, p_2, \dots, p_{60}\} \in R^{60}$, где p_i – параметры аккумулятора, включая ЭДС двойных слоев в заряженном и разряженном состоянии – $EbinpD, EbinpC, EbinnD, EbinnC$; электрические и тепловые емкости – $Cbin0p, Cbin0n, Cm, CBAkk, Clakk; сопротивления – Rkl, Rbin0p, Rbin0n, Rm0$; температурные и зарядовые поправки – $\alpha, \beta, rCRT, nRQ$ и др.

Перед запуском процесса обучения подготавливается и загружается csv – файл с данными динамических и статических параметров, при которых были получены первые. Далее происходит группировка по `dynamicIndex` (одна динамика разряда), заполняются пропущенные значения методом `ffill`. После этого формируется список последовательностей и стандартизация признаков по обучающей выборке.

Генератор данных производит маскирование значений до заданной длины $L = 2\ 100$, нормализует и возвращает пару $(X_{scaled}^{(dyn)}, X_{scaled}^{(stat)}), y_{scaled}$.

Модель состоит из двух ветвей.

Динамическая ветвь: `Conv1D` → `LSTM` → `MultiHeadAttention` → `GlobalAveragePooling1D`, где `Conv1D` выявляет локальные закономерности во времени, `LSTM` извлекает временные зависимости: $h_t = LSTM(x_t, h_{t-1})$, **MultiHeadAttention** – контекстное внимание: $Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V$, где Q (*Query*) – запросы, формируемые из последовательности, K (*Key*) – ключи, с которыми сравниваются запросы, V (*Value*) – значения, которые агрегируются по важности, d_k – размерность ключей (и запросов), используется для масштабирования, `softmax` нормализует скалярные произведения, превращая их в веса внимания.

Статическая ветвь: статические параметры подаются на вход плотной (dense) нейронной сети `Dense(64) → Dense(32)` с активацией `ReLU`.

Цель этих слоев – трансформировать входной вектор в более выразительное скрытое представление, которое затем будет объединено с признаками из временной ветви.

После предварительной обработки каждая ветвь формирует собственный вектор признаков. Далее они объединяются (конкатенация) в единый набор признаков, который подается на: `concat → Dropout → Dense(256) → Dropout → Dense(128)`.

`Dropout` (полносвязный слой) используется для предотвращения переобучения, увеличивая обобщающие способности модели. **Выходной слой** содержит линейную активацию и предсказывает 60 параметров аккумулятора: `Dense (60, linear)`.

Обучение модели

Обучение разработанной нейронной сети проводится с использованием двух основных метрик: среднеквадратичной ошибки (Mean Squared Error, MSE) и средней абсолютной ошибки (Mean Absolute Error, MAE). $MSE = \frac{1}{N} \sum_{i=1}^N \|y_i - \hat{y}_i\|_2^2$ и $MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|_1$, где y_i – истинный вектор параметров литийионного аккумулятора для i -го объекта обучающей выборки, включающий значения идентифицируемых параметров полной модели, \hat{y}_i – вектор параметров аккумулятора, предсказанный нейронной сетью для того же объекта, N – число объектов в обучающей выборке, $\|\cdot\|_2^2$ – квадрат евклидовой нормы. Соответствует сумме квадратов отклонений предсказанных значений параметров от их истинных значений по всем компонентам вектора. MSE эффективно отражает большие ошибки, поскольку они имеют квадратичный вес, что особенно важно для задач с высоким риском значительных отклонений. MAE вместо квадрата берется абсолютное значение ошибки. MAE менее чувствительна к выбросам и обеспечивает более равномерное штрафование всех ошибок, что делает ее полезной

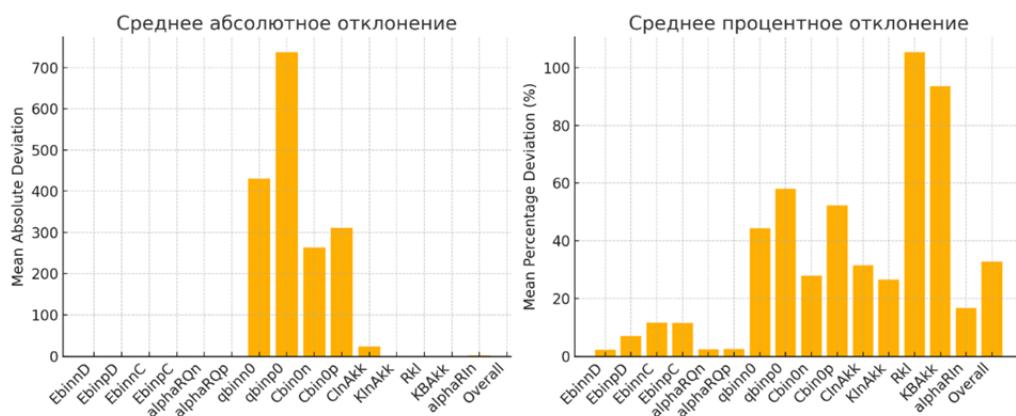


Рис. 5. Диаграмма отклонения предсказанных параметров
Fig. 5. Deviation diagram of the predicted parameters

дополнительной метрикой для оценки стабильности и общей точности модели. Таким образом, опираясь на эти значения, нейросеть обучается. Она каждый раз считает ошибку, сравнивая свои ответы с правильными. Использование MSE + MAE вместо классического алгоритма Ньютона обусловлено снижением вычислительной сложности при 60-мерном пространстве параметров, устойчивостью к шумовым выбросам, а также возможностью мини-батч-оптимизации на GPU. Быстрая локальная сходимость метода Ньютона достигается лишь при хорошем начальном приближении и полных матрицах Гессе, что для рассматриваемой модели экономически нецелесообразно.

Результаты

Для обучения был сформирован массив из 1 000 различных сочетаний статичных параметров (1 000 виртуальных аккумуляторов) и полученных по ним динамическим параметрам (разрядные характеристики). По завершении обучения средняя точность предсказания по выявленным наиболее влиятельным параметрам составила 30,6 %. Стоит отметить, что небольшое абсолютное отклонение по некоторым параметрам могло дать большое отклонение в процентном отношении, например Rkl – сопротивление клемм аккумулятора (рис. 5).

Заключение

Разработанная нейронная сеть для идентификации параметров полной модели литийионного аккумулятора продемонстрировала перспективу применения нейросетевых методов в решении задач параметрической идентификации. Несмотря на сравнительно низкую общую точность предсказаний (около 30,6 %), представленная модель может эффективно использоваться для грубой оценки и первичного приближения параметров аккумуляторов, что существенно сокращает затраты времени и ресурсов на первоначальный этап калибровки. Тем не менее для практического применения и создания цифровых двойников аккумуляторов необходима более высокая точность идентификации. Для ее достижения целесообразно продолжить работу по следующим направлениям.

1. Внедрение физически информированных нейронных сетей (PINN), которые интегрируют физические законы и ограничения непосредственно в процесс обучения, значительно снижая вероятность физически некорректных решений.

2. Использование более сложных и глубоких нейросетевых архитектур с многоуровневыми механизмами внимания (multi-head attention) и ансамблевыми подходами.

3. Оптимизация процедуры подготовки данных, включая улучшение алгоритмов автоматического отбора информативных сег-

ментов временных рядов и расширение набора дополнительных признаков.

4. Применение трансферного обучения и тонкой настройки нейронных сетей, предварительно обученных на крупных наборах синтетических данных, для повышения качества идентификации реальных аккумуляторов.

Таким образом, предложенная модель является важным промежуточным этапом на пути к созданию высокоточных цифровых двойников литийионных аккумуляторов. Дальнейшие исследования должны быть направлены на интеграцию продвинутых архитектур и физически информированных подходов, которые обеспечат необходимую точность и надежность, востребованную в высокотехнологичных отраслях, таких как авиация и космонавтика.

Список литературы

1. Иванов В.В., Мараховский И.В., Кравченко С.В. Формирование требований к авиационным литий-ионным аккумуляторным батареям // X научные чтения, посвященные памяти Н.Е. Жуковского: материалы Всероссийской научно-технической конференции. М.: ИД Академии имени Н.Е. Жуковского, 2013. С. 303–306.
2. Кедринский И.А., Яковлев В.Г. Li-ионные аккумуляторы. Красноярск: Платина, 2002. 268 с.
3. Старостин И.Е., Степанкин А.Г. Программная реализация методов современной неравновесной термодинамики и система симуляции физико-химических процессов SimulationNonEqProcSS v.0.1.0: монография. Бо Бассен, Маврикий: Lambert Academic Publishing, 2019. 127 с.
4. Старостин И.Е., Халютин С.П. Аналитическая модель динамики напряжения литийионного аккумулятора // Электричество. 2024. № 10. С. 13–22. DOI: 10.24160/0013-5380-2024-10-13-22
5. Khalyutin S.P., Starostin I.E., Agafonkina I.V. Generalized method of mathematical prototyping of energy processes for digital twins development [Электронный ресурс] // Energies. 2023. Vol. 16, iss. 4. ID: 1933. DOI: 10.3390/en16041933 (дата обращения: 10.03.2025).
6. Халютин С.П. Цифровые двойники в теории и практике авиационной электроэнергетики / С.П. Халютин, И.Е. Старостин, А.О. Давидов, В.П. Харьков, Б.В. Жмурев // Электричество. 2022. № 10. С. 4–13. DOI: 10.24160/0013-5380-2022-10-4-13
7. Старостин И.Е. Построение на основе интерполяции моделей различных физических и химических систем методом математического прототипирования энергетических процессов // Надежность и качество сложных систем. 2024. № 1 (45). С. 49–58. DOI: 10.21685/2307-4205-2024-1-6
8. Старостин И.Е., Дружинин А.А., Гавриленков С.И. Использование машинного обучения с учителем для построения математических моделей систем методом математического прототипирования энергетических процессов // Труды Международного симпозиума «Надежность и качество». 2023. Т. 1. С. 66–72.
9. Starostin I. The development of a mathematical model of lithium-ion battery discharge characteristics / I. Starostin, S. Khalyutin, A. Davidov, A. Lyovin, A. Trubachev // Proceedings – ICOECS 2019: 2019 international conference on electrotechnical complexes and systems. Ufa, 2019. Pp. 8949976. DOI: 10.1109/ICOECS46375.2019.8949976
10. Старостин И.Е., Гавриленков С.И. Архитектура математического ядра цифровых двойников различных физико-химических систем на базе метода математического прототипирования энергетических процессов // Надежность и качество сложных систем. 2024. № 4 (48). С. 160–168. DOI: 10.21685/2307-4205-2024-4-17
11. Старостин И.Е., Дружинин А.А. Аналитическое приближение решений уравнений метода математического прототипирования энергетических процессов путем качественного анализа этих уравнений // Надежность и качество сложных систем. 2023.

№ 2 (42). С. 22–31. DOI: 10.21685/2307-4205-2023-2-3

12. Старостин И.Е., Гавриленков С.И.

Задание функций состояния для потенциалов взаимодействия, приведенных теплоемкостей и приведенных тепловых эффектов, входящих в уравнения метода математического прототипирования энергетических процессов // Надежность и качество сложных систем. 2025. № 1 (49). С. 36–43. DOI: 10.21685/2307-4205-2025-1-5

13. Alshawabkeh A., Matar M., Almutairiy F.

Parameters identification for lithium-ion battery models using the levenberg–marquardt algorithm [Электронный ресурс] // World Electric Vehicle Journal. 2024. Vol. 15, iss. 9. ID: 406. DOI: 10.3390/wevj15090406 (дата обращения: 26.03.2025).

14. Lian Y., Qiao D.

A novel capacity estimation method for lithium-ion batteries based on the adam algorithm [Электронный ресурс] // Batteries. 2023. Vol. 11, iss. 3. ID: 85. DOI: 10.3390/batteries11030085 (дата обращения: 26.03.2025).

15. Pi J.

Parameter identification for electrochemical models of lithium-ion batteries using bayesian optimization / J. Pi, S.F. da Silva, M.F. Ozkan, A. Gupta, M. Canova // IFAC-PapersOnLine. 2024. Vol. 57, no. 1. Pp. 180–185. DOI: 10.1016/j.ifacol.2024.12.031

16. Starostin I.E., Druzhinin A.A.

The concept of a software and technological platform for digital twins based on energy dynamics methods // 2023 5th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE), 2023. Pp. 1–6. DOI: 10.1109/REEPE57272.2023.10086710

17. Song S., Fei C., Xia H.

Lithium-Ion Battery SOH Estimation Based on XGBoost Algorithm with Accuracy Correction [Электронный ресурс] // Energies. 2020. Vol. 13, iss. 4. ID: 812. DOI: 10.3390/en13040812 (дата обращения: 26.03.2025).

18. Naaz N., Channegowda J.

XGBoost based synthetic battery parameter generation to overcome limited battery dataset challenges // 2022 IEEE International Conference on Power Electronics, Smart Grid, and Renewable Energy

(PESGRE). India, Trivandrum, 2022. Pp. 1–4. DOI: 10.1109/PESGRE52268.2022.9715814

19. Heinrich F., Klapper P., Pruckner M.

A comprehensive study on battery electric modeling approaches based on machine learning [Электронный ресурс] // Energy Informatics. 2021. Vol. 4. ID: 17. DOI: 10.1186/s42162-021-00171-7 (дата обращения: 26.03.2025).

20. Singh S.

Hybrid modeling of lithium-ion battery: physics-informed neural network for battery state estimation / S. Singh, Y.E. Ebongue, S. Rezaei, K.P. Birke [Электронный ресурс] // Batteries. 2023. Vol. 9, iss. 6. ID: 301. DOI: 10.3390/batteries9060301 (дата обращения: 26.03.2025).

21. Wang J.

A physics-informed neural network approach to parameter estimation of lithium-ion battery electrochemical model / J. Wang, Q. Peng, J. Meng, T. Liu, J. Peng, R. Teodorescu [Электронный ресурс] // Journal of Power Sources. 2024. Vol. 621. ID: 235271. DOI: 10.1016/j.jpowsour.2024.235271 (дата обращения: 26.03.2025).

22. Shen S.

Deep convolutional neural networks with ensemble learning and transfer learning for capacity estimation of Lithium-Ion batteries / S. Shen, M. Sadoughi, M. Li, Z. Wang, C. Hu [Электронный ресурс] // Applied Energy. 2020. Vol. 260. ID: 114244. DOI: 10.1016/j.apenergy.2019.114244 (дата обращения: 26.03.2025).

References

1. Ivanov, V.V., Marakhovskiy, I.V., Kravchenko, S.V. (2013). Formulation of requirements for aviation lithium-ion batteries. In: X nauchnyye chteniya, posvyashchennyye pamyati N.Ye. Zhukovskogo: materialy Vserossiyskoy nauchno-tehnicheskoy konferentsii. Moscow: Izdatelkiy dom Akademii imeni N.E. Zhukovsky, pp. 303–306. (in Russian)

2. Kedrinskiy, I.A., Yakovlev, V.G. (2002). Lithium-ion batteries. Krasnoyarsk: Platina, 268 p. (in Russian)

3. Starostin, I.E., Stepankin, A.G. (2019). Software implementation of modern non-equilibrium thermodynamics methods and simu-

lation system of physicochemical processes SimulationNonEqProcSS v.0.1.0: Monograph. Beau Bassin, Mauritius: Lambert Academic Publishing, 127 p. (in Russian)

4. Starostin, I.E., Khalyutin, S.P. (2024). An analytical model of lithium-ion battery voltage dynamics. *Elektrichestvo*, no. 10, pp. 13–22. DOI: 10.24160/0013-5380-2024-10-13-22 (in Russian)

5. Khalyutin, S.P., Starostin, I.E., Agafonkina, I.V. (2023). Generalized method of mathematical prototyping of energy processes for digital twins development. *Energies*, vol. 16, issue 4, ID: 1933. DOI: 10.3390/en16041933 (accessed: 10.03.2025).

6. Khalyutin, S.P., Starostin, I.E., Davidov, A.O., Kharkov, V.P., Zhmurov, B.V. (2022). Digital twins in the theory and practices of aircraft electrical power systems. *Elektrichestvo*, vol. 10, pp. 4–13. DOI: 10.24160/0013-5380-2022-10-4-13 (in Russian)

7. Starostin, I.E. (2024). Building, based on interpolation, models of various physical and chemical systems by method of mathematical prototyping of energy processes. *Reliability and Quality of Complex Systems*, no. 1 (45), pp. 49–58. DOI: 10.21685/2307-4205-2024-1-6 (in Russian)

8. Starostin, I.E., Druzhinin, A.A., Gavrilenkov, S.I. (2023). Application of supervised machine learning for building mathematical models of systems by the method of mathematical prototyping of energy processes. In: *Trudy Mezhdunarodnogo simpoziuma "Nadezhnost i kachestvo"*, vol. 1, pp. 66–72. (in Russian)

9. Starostin, I.E., Khalyutin, S.P., Davidov, A.A., Levin, A.V., Trubachev, A.I. (2019). The development of a mathematical model of lithium-ion battery discharge characteristics. In: *Proceedings - ICOECS 2019: 2019 international conference on electrotechnical complexes and systems*, pp. 8949976. DOI: 10.1109/ICOECS46375.2019.8949976

10. Starostin, I.E., Gavrilenkov, S.I. (2024). Architecture of the mathematical core of digital twins of various physical and chemical systems based on the method of mathematical prototyping of energy processes. *Reliability and Quality of Complex Systems*, no. 4 (48), pp. 160–168. DOI: 10.21685/2307-4205-2024-4-17 (in Russian)

11. Starostin, I.E., Druzhinin, A.A. (2023). Analytical approximation of solutions of equations of the method of mathematical prototyping of energy processes by qualitative analysis of these equations. *Reliability and Quality of Complex Systems*, no. 2 (42), pp. 22–31. DOI: 10.21685/2307-4205-2023-2-3 (in Russian)

12. Starostin, I.E., Gavrilenkov, S.I. (2025). Assignment of state functions for interaction potentials, reduced heat capacities and reduced thermal effects included in the equations of the method of mathematical prototyping of energy processes. *Reliability and Quality of Complex Systems*, no. 1 (49), pp. 36–44. DOI: 10.21685/2307-4205-2025-1-5 (in Russian)

13. Alshawabkeh, A., Matar, M., Almutairy, F. (2024). Parameters identification for lithium-ion battery models using the Levenberg-Marquardt algorithm. *World Electric Vehicle Journal*, vol. 15, issue 9, ID: 406. DOI: 10.3390/wevj15090406 (accessed: 26.03.2025).

14. Lian, Y., Qiao, D. (2023). A novel capacity estimation method for lithium-ion batteries based on the adam algorithm. *Batteries*, vol. 11, issue 3. ID: 85. DOI: 10.3390/batteries11030085 (accessed: 26.03.2025).

15. Pi, J., da Silva, S.F., Ozkan, M.F., Gupta, A., Canova, M. (2024). Parameter identification for electrochemical models of lithium-ion batteries using Bayesian optimization. *IFAC-PapersOnLine*, vol. 57, no. 1, pp. 180–185. DOI: 10.1016/j.ifacol.2024.12.031

16. Starostin, I.E., Druzhinin, A.A. (2023). The concept of a software and technological platform for digital twins based on energy dynamics methods. In: *2023 5th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE)*, pp. 1–6. DOI: 10.1109/REEPE57272.2023.10086710

17. Song, S., Fei, C., Xia, H. (2020). Lithium-Ion Battery SOH Estimation Based on XGBoost Algorithm with Accuracy Correction. *Energies*, vol. 13, issue 4, ID: 812. DOI: 10.3390/en13040812 (accessed: 26.03.2025).

18. Naaz, N., Channegowda, J. (2022). XGBoost based synthetic battery parameter generation to overcome limited battery dataset challenges. In: *2022 IEEE International Conference on Power Electronics, Smart Grid, and*

Renewable Energy (PESGRE). India, Trivandrum, pp. 1–4. DOI: 10.1109/PESGRE52268.2022.9715814

19. Heinrich, F., Klapper, P., Pruckner, M. (2021). A comprehensive study on battery electric modeling approaches based on machine learning. *Energy Informatics*, vol. 4, ID: 17. DOI: 10.1186/s42162-021-00171-7 (accessed: 26.03.2025).

20. Singh, S., Ebongue, Y.E., Rezaei, S., Birke, K.P. (2023). Hybrid modeling of lithium-ion battery: physics-informed neural network for battery state estimation. *Batteries*, vol. 9, issue 6, ID: 301. DOI: 10.3390/batteries9060301 (accessed: 26.03.2025).

21. Wang, J., Peng, Q., Meng, J., Liu, T., Peng, J., Teodorescu, R. (2024). A physics-informed neural network approach to parameter estimation of lithium-ion battery electrochemical model. *Journal of Power Sources*, vol. 621, ID: 235271. DOI: 10.1016/j.jpowsour.2024.235271 (accessed: 26.03.2025).

22. Shen, S., Sadoughi, M., Li, M., Wang, Z., Hu, C. (2020). Deep convolutional neural networks with ensemble learning and transfer learning for capacity estimation of Lithium-Ion batteries. *Applied Energy*, vol. 260, ID: 114244. DOI: 10.1016/j.apenergy.2019.114244 (accessed: 26.03.2025).

Сведения об авторе

Гавриленков Станислав Иванович, аспирант кафедры электротехники и авиационного электрооборудования МГТУ ГА, s.gavrilenkov@mstuca.ru.

Information about the autor

Stanislav I. Gavrilenkov, Postgraduate Student, Electrical Engineering and Aviation Electrical Equipment Chair, Moscow State Technical University of Civil Aviation, s.gavrilenkov@mstuca.ru.

Поступила в редакцию	18.05.2025	Received	18.05.2025
Одобрена после рецензирования	21.07.2025	Approved after reviewing	21.07.2025
Принята в печать	20.11.2025	Accepted for publication	20.11.2025