

## О ВЫБОРЕ МЕТОДА ПОСТРОЕНИЯ НЕЧЕТКОЙ МОДЕЛИ ПРОГНОЗИРОВАНИЯ СОСТОЯНИЯ АККУМУЛЯТОРА

О.В. Яковлева  
Ю.В. Строганов  
И.В. Рудаков

oyakovleva@bmstu.ru  
stroganovyv@bmstu.ru  
irudakov@bmstu.ru

МГТУ им. Н.Э. Баумана, Москва, Российская Федерация

---

### Аннотация

В качестве альтернативы неэкологичным автомобилям с двигателями внутреннего сгорания применяются электромобили, работающие на аккумуляторных батареях. Но аккумуляторные батареи нельзя использовать без системы управления, для разработки которой требуется математическая модель прогнозирования состояния отдельного аккумулятора. Такой моделью может являться нечеткая система Такаги — Сугено (нечеткая модель). Существуют методы автоматического построения нечетких моделей по таблице наблюдений. Однако нет однозначных критериев выбора подходящего метода в каждом конкретном случае. Рассмотрена задача определения метода, позволяющего получить нечеткую модель, прогнозирующую напряжение литийионного аккумулятора по току нагрузки и состоянию заряда при разряде постоянным током с наименьшей среднеквадратической ошибкой. Выполнен обзор существующих методов и их классов, выбрано пять методов для сравнения. Ошибка прогнозирования всеми полученными моделями распределена неравномерно вдоль оси состояния заряда и принимает наибольшие значения в интервале 97...100 %. Наименьшая среднеквадратическая ошибка у модели, построенной комбинированным методом, использующим субтрактивную кластеризацию, метод наименьших квадратов и адаптивную сеть на основе системы нечеткого вывода. У такой модели ошибка изменяется скачками, что связано с особенностью алгоритма субтрактивной кластеризации — сформированные кластеры имеют одинаковый размер

### Ключевые слова

*Аккумулятор, нечеткая модель, кластеризация, субтрактивная кластеризация, ANFIS, метод наименьших квадратов, рой частиц*

Поступила 25.04.2022

Принята 17.06.2022

© Автор(ы), 2022

**Введение.** В настоящее время все большее распространение получают автомобили, использующие вместо двигателей внутреннего сгорания, производящих большое количество отработавших газов во время эксплуатации, аккумуляторные батареи [1]. Однако при неверном управлении процессами их зарядки и разрядки может произойти необратимая деградация емкости и даже возгорание батарей из-за саморазогрева [2]. Вследствие дороговизны этапа утилизации большинство производителей участвуют в разработке различных систем управления батареями для продления срока их службы. Система управления решает задачи сбора данных и прогнозирования состояний аккумуляторных батарей: напряжения на клеммах, температуры, разрядной и зарядной емкости, степени заряда, степени деградации емкости и др.

При решении задачи прогнозирования состояния аккумулятора используют следующие классы моделей: физические [3], на основе схем замещения [4], нечеткой логики [5], нейронных сетей [6], гибридных нейронно-нечетких сетей [7]. Физические модели, описывающие электрохимические процессы, протекающие в аккумуляторе, являются самыми точными, однако требуют проведения большого числа сложных экспериментов для подбора коэффициентов уравнений. В моделях на основе схем замещения аккумуляторы заменяются эквивалентной электрической цепочкой резисторов и конденсаторов, и для повышения точности необходимо полностью вручную перерабатывать модель. В настоящей работе для решения задачи прогнозирования состояния аккумулятора рассматривается применение нечеткой системы (нечеткой модели).

Наиболее широко используют следующие типы нечетких систем [8]: Такаги — Сугено [9], Мамдани [10] и сингтон. Нечеткие системы Такаги — Сугено лучше подходят для решения задач интерполяции или аппроксимации, а Мамдани — для решения задач извлечения знаний из данных в виде правил или поиска ассоциативных связей [8].

Выбрана нечеткая система Такаги — Сугено со структурой правил вида:

$$R^\theta: \text{если } x_1 \text{ есть } X_1^\theta, x_2 \text{ есть } X_2^\theta, \dots, x_N \text{ есть } X_N^\theta, \\ \text{то } y = a_0^\theta + a_1^\theta x_1 + \dots + a_N^\theta x_N, \quad (1)$$

где  $X_1^\theta, X_2^\theta, \dots, X_N^\theta$  — лингвистические значения входных переменных  $x_1, x_2, \dots, x_N$  в  $\theta$ -м правиле,  $\theta = \overline{1, \Theta}$ ;  $y$  — выходная переменная;  $a_i^\theta = \text{const}$ ,  $i = \overline{0, N}$ .

В процессе построения нечеткой системы Такаги — Сугено выделяют следующие этапы [8]:

- идентификация структуры — определение числа термов для каждой входной переменной, числа и структуры правил;
- идентификация параметров функций принадлежности для термов входных переменных;
- идентификация параметров линейных уравнений в следствиях правил (параметров консеквентов).

Итоговым методом построения нечеткой системы является комбинация методов, реализующих рассмотренные этапы.

К методам идентификации структуры, некоторые из которых могут одновременно выполнять также идентификацию параметров (как функций принадлежности, так и консеквентов), относятся: полный перебор; кластеризация; метаэвристические методы оптимизации (на основе роя частиц, генетического алгоритма и т. д.). Результаты сравнения рассматриваемых методов структурной идентификации нечетких систем приведены в табл. 1.

Таблица 1

**Методы структурной идентификации нечетких систем**

Метод	Расчет		Вычислительная сложность	Рост числа правил с ростом числа термов
	функций принадлежности	консеквентов		
Полный перебор	–	–	Низкая	Экспоненциальный
Кластеризация Густафсона — Кесселя, субтрактивная	+	–	Средняя	Линейный
Кластеризация Гата — Гевы, FCRM	+	+	»	»
На основе метаэвристик	+	+	Высокая	Зависит от данных

Метод полного перебора используется обязательно в сочетании с методами идентификации параметров, antecedentes (посылки) правил формируются как все возможные сочетания термов входных переменных, а консеквенты генерируются уникальными для каждого правила. К недостаткам метода относятся экспоненциальный рост правил с ростом числа термов входных переменных и возможность появления «лишних» правил таких,

которые не будут срабатывать ни при одной возможной комбинации значений входных переменных.

Использование методов кластеризации предполагает разбиение входного пространства (или объединения входного и выходного пространств) на кластеры и сопоставление каждому кластеру одного нечеткого правила. Для идентификации нечетких систем наиболее часто используют алгоритмы нечеткой  $c$ -регрессии (fuzzy  $c$ -regression model, FCRM) [11], Густафсона — Кесселя [12], Гага — Гевы [13, 14] и субтрактивной кластеризации [15, 16].

При использовании метаэвристических методов (роя частиц [17, 18], генетического алгоритма [19, 20]) построение нечеткой системы формулируется как задача оптимизации в многомерном пространстве, где каждая точка соответствует одной нечеткой системе, т. е. описывается вектором, содержащим закодированную базу правил и параметры функций принадлежности и консеквентов. К недостаткам метаэвристических методов относятся высокие вычислительные затраты по сравнению с алгоритмами кластеризации [14]. Кроме того, применение метаэвристик не гарантирует определения глобального минимума и, как правило, связано с эмпирической настройкой параметров используемых алгоритмов [21].

Для идентификации параметров функций принадлежности используют:

- сеточное разбиение входного пространства (СРВП) [22];
- динамическое разбиение входного пространства (ДРВП) [22];
- градиентный спуск и его модификации;
- метаэвристические методы.

В методе СРВП для каждой переменной входного пространства генерируется заданное число одинаковых термов по всему диапазону ее изменения.

Суть метода ДРВП состоит в следующем: если ошибка аппроксимации больше заданной, то на каждой итерации определяется регион входного пространства с наибольшей ошибкой; в этом регионе выбирается входная переменная с наибольшей ошибкой; для этой переменной генерируется новый терм и новая треугольная функция принадлежности, центр которой вычисляется по специальной формуле, а границами являются центры термов, между которыми будет помещен новый терм.

Для идентификации параметров консеквентов правил чаще всего используют метод наименьших квадратов (МНК) [23], рекуррентный МНК [24, 25] и метаэвристические методы.

Значения, полученные на основе кластеризации [26, 27] или методами СРВП и ДРВП [27], могут быть применены в качестве начальных для идентификации параметров как функций принадлежности, так и консеквентов в метаэвристических методах или комбинированном методе ANFIS (Adaptive Neuro-Fuzzy Inference System) [26, 28], использующем метод градиентного спуска с обратным распространением ошибки для идентификации параметров функций принадлежности и МНК для идентификации параметров консеквентов.

**Постановка задачи прогнозирования состояния аккумулятора на основе нечеткой модели.** Пусть  $I$  — множество значений тока нагрузки;  $U$  — множество значений напряжения на клеммах аккумулятора;  $Q$  — множество значений состояния заряда;  $T$  — множество значений моментов времени.

Состоянием аккумулятора назовем  $(I_j, U_j, Q_j)$ , где  $I_j \in I, U_j \in U, Q_j \in Q$  — значения тока нагрузки, напряжения на клеммах и состояния заряда (уровня заряда относительно емкости) в момент времени  $t_j \in T$  соответственно;  $j = \overline{N, M}, N < 0, M > 0$ . Это понятие состояния несколько отличается от классического понятия состояния динамической системы, введенного Калманом [29], согласно которому выходная переменная (в данном случае напряжение) не должна являться компонентой состояния. Чтобы избежать путаницы, далее внутренним состоянием будем называть состояние в классическом смысле, а полным состоянием (или просто состоянием) — приведенное ранее  $(I_j, U_j, Q_j)$ .

Пусть дана таблица наблюдений  $Z$ , в строках которой содержатся значения компонент состояния в прошлые моменты времени  $t_i, i = \overline{N, -1}$ :

$$Z = \begin{pmatrix} I_N, & U_N, & Q_N \\ I_{N+1}, & U_{N+1}, & Q_{N+1} \\ \dots & \dots & \dots \\ I_{-1}, & U_{-1}, & Q_{-1} \end{pmatrix}.$$

На основе таблицы  $Z$  для заданного набора  $P = (I_1, I_2, \dots, I_M)^T$ , содержащего значения входных воздействий (токов нагрузки)  $I_k$  в будущие моменты времени  $t_k, k = \overline{1, M}$ , и состояния  $(I_0, U_0, Q_0)$  в настоящий момент времени  $t_0 = 0$ , требуется определить состояния  $(I_k, U_k, Q_k)$  в будущие моменты времени  $t_k, k = \overline{1, M}$ .

Согласно определению динамической системы [29] и методу пространства состояний [30], для решения задачи прогнозирования требуется определить компоненты внутреннего состояния системы, выходное отображение (зависимость выходной переменной от внутреннего состояния) и переходное отображение (зависимость внутреннего состояния в следующий момент времени от входного воздействия и внутреннего состояния в текущий момент времени).

Напряжение на клеммах аккумулятора имеет нелинейную зависимость от тока нагрузки, температуры и состояния заряда. Предположим, что температура постоянна для всех моментов времени  $t_j \in T$ . Таким образом, внутреннее состояние определяется двумя компонентами: током нагрузки и состоянием заряда. Пусть  $\vec{X}_k$  — значение внутреннего состояния в момент времени  $t_k$ :  $\vec{X}_k = (I_k, Q_k) \in X$ .

Выходное отображение  $f: X \rightarrow U$  (или  $f: I \times Q \rightarrow U$ ) задается выражением

$$U_k = \text{нечеткий\_вывод}(fis, I_k, Q_k), \quad (2)$$

где  $fis$  — нечеткая система Такаги — Сугено, построенная по таблице  $Z$ .

Переходная функция для состояния заряда определяется согласно кулоновскому методу счета по формуле

$$Q_{k+1} = Q_k + I_{k+1}\Delta t, \quad (3)$$

где  $\Delta t = t_{k+1} - t_k = \text{const}$ . Переходную функцию для тока нагрузки определять не требуется, поскольку ток нагрузки одновременно является и входным воздействием  $I_k$  и компонентой внутреннего состояния  $I_k$ .

Схема решения задачи в нотации IDEF0 приведена на рис. 1.

**Сравнение методов построения нечеткой системы Такаги — Сугено.** Проведено сравнение пяти методов построения нечеткой системы, состоящих, как было указано ранее, не более чем из трех этапов каждый.

1. Генерация структуры правил методом полного перебора, затем оптимизация параметров методом роя частиц как функций принадлежности, так и консеквентов правил.

2. Оптимизация структуры правил и всех параметров методом роя частиц. При этом на структуру правил накладывается ограничение: в антецедентной части должны присутствовать все входные переменные.

3. Метод ANFIS. В качестве начальной используется система, структура правил которой сгенерирована методом полного перебора, параметры функций принадлежности идентифицированы алгоритмом сеточного разбиения, а параметры консеквентов равны нулю.

4. Идентификация структуры правил и параметров функций принадлежности с помощью субтрактивной кластеризации. Идентификация параметров консеквентов выполняется методом наименьших квадратов.

5. Метод ANFIS. В качестве начальной используется система, сгенерированная 4-м методом, приведенным в п. 4.

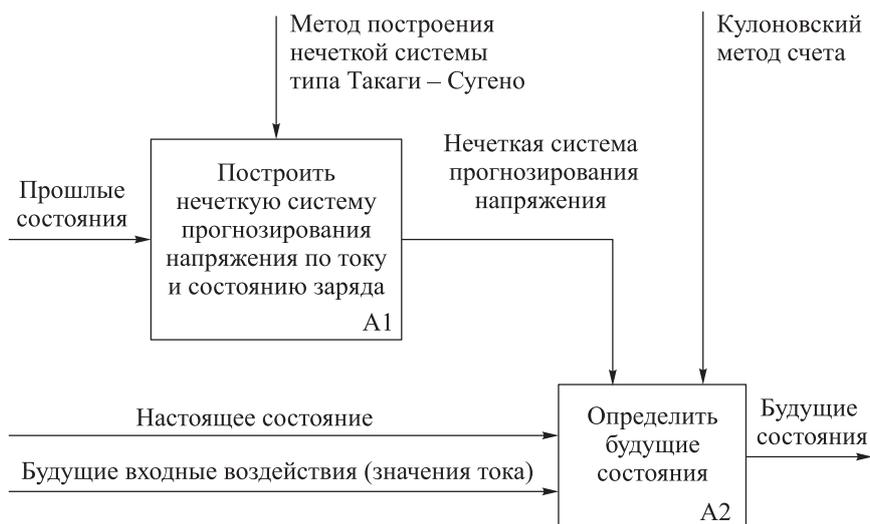


Рис. 1. Схема прогнозирования состояния аккумулятора

При использовании методов роя частиц и ANFIS значением целевой функции является среднеквадратическая ошибка прогнозирования модели (mean-squared error, MSE), вычисляемая по формуле

$$MSE = \frac{1}{L} \sum_{z=1}^L (U_z - \bar{U}_z)^2, \quad (4)$$

где  $U_z$  и  $\bar{U}_z$  — истинное и спрогнозированное значения напряжения.

При сравнении использовались пакеты MATLAB Global Optimization Toolbox и Fuzzy Logic Toolbox.

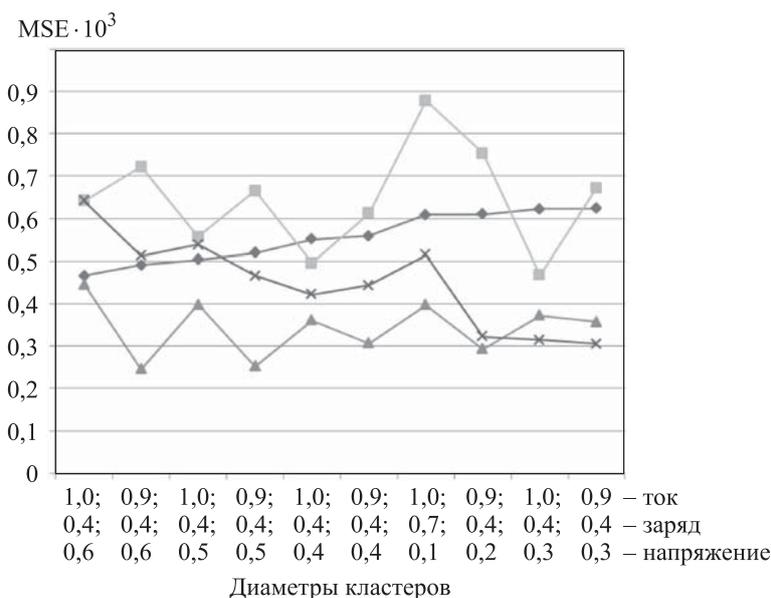
**Описание набора данных и результаты сравнения.** Исходный набор данных представляет собой пять матриц, содержащих четыре столбца: время, ток нагрузки, напряжение и состояние заряда аккумуляторной ячейки AMP20M1HD-A в течение цикла заряда-разряда постоянным током при температуре 25 °С. Каждой матрице соответствует свой постоянный ток цикла заряда-разряда — 12, 25, 37, 50 и 62 А. Значения состояния заряда рассчитаны кулоновским методом.

Для построения нечеткой системы использовались данные, собранные при разряде ячейки током 12, 25, 50 и 62 А (далее — обучающая вы-

борка). Тестирование системы проводилось на данных, полученных при разряде током 37 А (далее — тестовая выборка).

Для использования 4-го, 5-го методов требуется задать параметры субтрактивной кластеризации — диаметры кластеров по каждой размерности в диапазоне [0; 1] (в реализации MATLAB данные нормализуются так, что пространство представляет собой единичный гиперкуб; возможные значения диаметров лежат в диапазоне [0; 1]). Выбраны десять комбинаций значений диаметров кластеров, при которых число полученных кластеров не превышало 15, и среднеквадратическая ошибка прогнозирования (4) нечеткой системы, сгенерированной 4-м методом, принимала наименьшее значение из всех возможных комбинаций значений диаметров с шагом 0,1 в диапазоне [0,1; 1].

Значения среднеквадратических ошибок моделей, построенных 4-м и 5-м методами при разных параметрах субтрактивной кластеризации, приведены на рис. 2. Уменьшение среднеквадратической ошибки после применения ANFIS чувствительно к выбору параметров кластеризации.



**Рис. 2.** Зависимости среднеквадратической ошибки прогнозирования системами, полученными 4-м и 5-м методами, от параметров кластеризации: —◆— и —■— — субтрактивная кластеризация (обучающая и тестовая выборки); —▲— и —×— — субтрактивная кластеризация + ANFIS (обучающая и тестовая выборки)

Значения среднеквадратической ошибки, число термов и правил систем, полученных 1–5-м методами, приведены в табл. 2. Для 2-го метода в скобках указано заданное число термов и правил (отличается от фактиче-

ски полученного ввиду особенностей работы метода). Для 4-го метода задавались следующие диаметры кластеров:  $d_I = 1$  (для тока),  $d_Q = 0,4$  (для состояния заряда),  $d_U = 0,6$  (для напряжения); для 5-го метода —  $d_I = 0,9$  (для тока),  $d_Q = 0,4$  (для состояния заряда),  $d_U = 0,3$  (для напряжения).

Таблица 2

**Сравнение методов построения нечетких систем Такаги — Сугено по характеристикам полученных систем прогнозирования напряжения аккумуляторной ячейки по току и состоянию заряда**

Число термов		Число правил	MSE · 10 <sup>3</sup> , на выборке	
для тока	для состояния заряда		обучающей	тестовой
1. Полный перебор + рой частиц				
2	4	8	0,58	1,67
2	5	10	2,02	1,04
2	6	12	0,45	1,47
<b>2</b>	<b>7</b>	<b>14</b>	<b>0,19</b>	<b>0,44</b>
2	8	16	0,13	0,86
2	9	18	1,92	0,75
3	4	12	0,94	1,70
3	5	15	2,17	3,67
3	6	18	2,37	1,22
4	4	16	0,97	3,33
4	5	20	0,26	2,29
2. Рой частиц				
2 (2)	3 (4)	4 (4)	2,41	3,83
2 (2)	3 (4)	5 (8)	0,29	0,81
2 (2)	2 (5)	3 (5)	1,32	2,99
2 (2)	4 (5)	5 (10)	0,23	0,83
2 (2)	3 (6)	4 (6)	0,17	0,79
<b>2 (2)</b>	<b>5 (6)</b>	<b>6 (12)</b>	<b>0,15</b>	<b>0,43</b>
3 (3)	5 (5)	7 (15)	0,19	0,81
3. Полный перебор + сеточное разбиение + ANFIS				
2	2	4	0,45	1,15
2	3	6	0,39	1,23
<b>2</b>	<b>4</b>	<b>8</b>	<b>0,09</b>	<b>1,34</b>
2	5	10	0,17	1,01
2	8	16	0,03	0,93
2	10	20	0,01	0,95
3	3	9	0,18	27,39

Число термов		Число правил	MSE · 10 <sup>3</sup> , на выборке	
для тока	для состояния заряда		обучающей	тестовой
3. Полный перебор + сеточное разбиение + ANFIS				
3	4	12	0,26	58,88
3	5	15	0,02	2,78
4	4	16	0,08	546,55
4. Субтрактивная кластеризация + МНК				
5	5	5	<b>0,47</b>	<b>0,64</b>
5. Субтрактивная кластеризация + МНК + ANFIS				
<b>6</b>	<b>6</b>	<b>6</b>	<b>0,29</b>	<b>0,32</b>

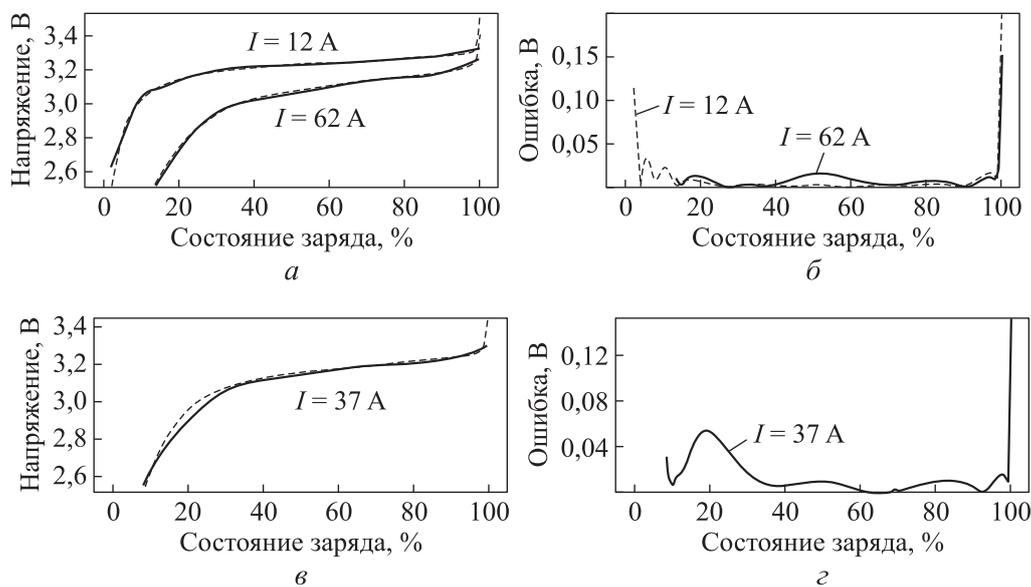
Система, полученная 1-м методом (полный перебор + рой частиц), имеет наименьшую среднеквадратическую ошибку на тестовой выборке при двух термах для тока и семи — для состояния заряда. Примерно такую же среднеквадратическую ошибку как на обучающей, так и на тестовой выборках имеет система, полученная 2-м методом (рой частиц), но число правил при этом в 2,3 раза меньше, чем в системе, полученной 1-м методом.

Система, полученная 3-м методом (полный перебор + сеточное разбиение + ANFIS), имеет наилучшие характеристики (среднеквадратическую ошибку, выходную поверхность) при двух термах для тока и от двух до четырех термов для состояния заряда. Дальнейшее увеличение числа термов как для тока, так и для состояния заряда приводит к некорректной выходной поверхности модели и ухудшению ее аппроксимирующей способности.

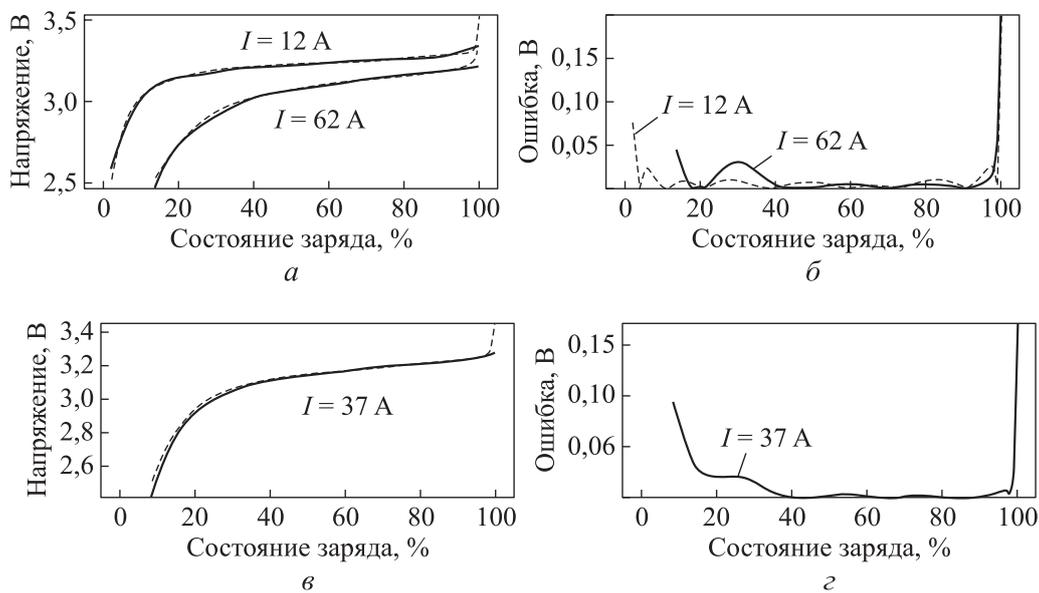
Среди всех систем наименьшую среднеквадратическую ошибку прогнозирования на тестовой выборке имеет система, полученная 5-м методом (субтрактивная кластеризация + МНК + ANFIS).

Результаты прогнозирования напряжения полученными 1–3-м методами нечеткими системами с теми характеристиками, которые выделены полужирным в табл. 2, приведены на рис. 3–5. Погрешность (абсолютная разность между реальным и спрогнозированным значениями) принимает наибольшие значения на интервалах 0...30 % и 97...100 % состояния заряда.

Результаты прогнозирования напряжения нечеткими системами, полученными 4-м и 5-м методами, приведены на рис. 6, 7. Среднеквадратическая ошибка этих систем принимает наибольшие значения на интервале 97...100 % состояния заряда, как и систем, полученных 1–3-м методами, а на интервале 0...97 % среднеквадратическая ошибка изменяется скачками.



**Рис. 3.** Результаты прогнозирования напряжения системой, полученной 1-м методом: реальное (-----) и спрогнозированное (—), на обучающей (а) и тестовой (в) выборках; ошибка на обучающей (б) и тестовой (г) выборках



**Рис. 4.** Результаты прогнозирования системой, полученной 2-м методом (а-г — см. рис. 3)

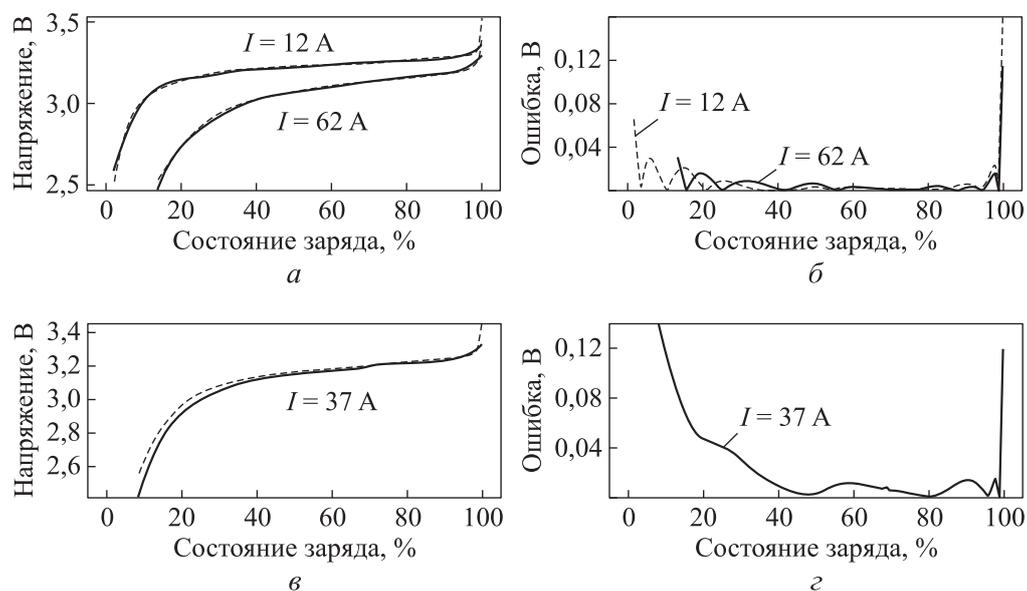


Рис. 5. Результаты прогнозирования системой, полученной 3-м методом (a-г — см. рис. 3)

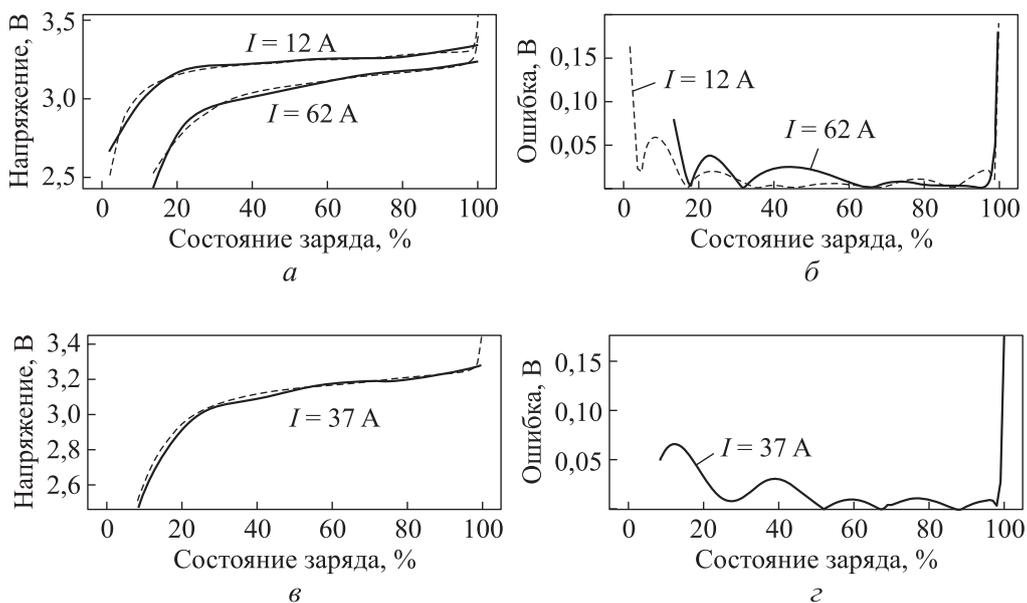


Рис. 6. Результаты прогнозирования системой, полученной 4-м методом (a-г — см. рис. 3)

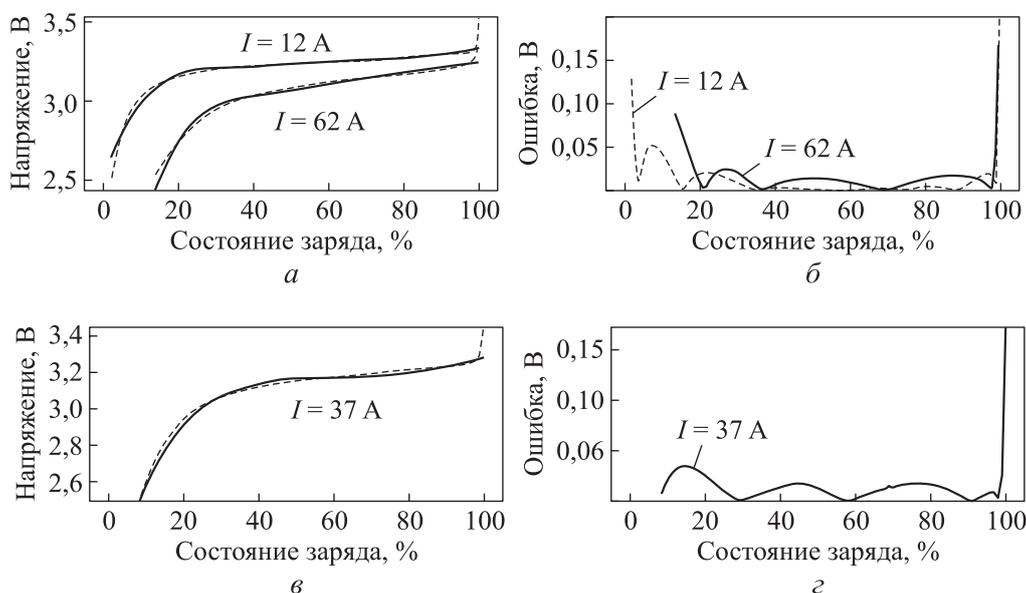


Рис. 7. Результаты прогнозирования системой, полученной 5-м методом (а-г — см. рис. 3)

**Заключение.** Проведено сравнение различных методов построения нечеткой системы Такаги — Сугено для решения задачи прогнозирования напряжения литийионного аккумулятора при разряде постоянным током. Наименьшую среднеквадратическую ошибку показала система, построенная комбинацией алгоритма субтрактивной кластеризации, метода наименьших квадратов и ANFIS. Однако уменьшение среднеквадратической ошибки после применения ANFIS зависит от параметров кластеризации.

Ошибка прогнозирования всех полученных нечетких моделей принимает наибольшие значения на интервале 97...100 % состояния заряда. У моделей, правила которых получены полным перебором, а параметры настроены различными методами оптимизации (рой частиц, ANFIS), и у модели, полностью идентифицированной методом роя частиц, ошибка увеличена на интервале 0...30 %. У моделей, основным методом идентификации которых была субтрактивная кластеризация, ошибка изменяется скачками на интервале 0...97 %.

Неравномерное распределение ошибки в случае применения методов оптимизации связано с тем, что данные методы в процессе функционирования стремятся уменьшить среднеквадратическую ошибку для всего диапазона значений и не позволяют выбрать целевые интервалы.

Причина скачков ошибки на интервале 0...97 % и увеличения ошибки на интервале 97...100 % при использовании алгоритма субтрактивной кла-

стеризации заключается, предположительно, в формировании данным алгоритмом кластеров одинакового размера. В измерении состояния заряда корректнее было бы задать маленькие диаметры кластеров на интервале 97...100 %, большие — на интервале 30...97 % и средние — на интервале 0...30 %, поскольку на этих интервалах значение напряжения меняется сильно, слабо и средне соответственно.

## ЛИТЕРАТУРА

- [1] Prajowski K., Golebiewski W., Lisowski M., et al. Road test of selected electrical parameters of the hybrid vehicle accumulation system. *IEEE Trans. Veh. Technol.*, 2021, vol. 70, no. 1, pp. 203–211. DOI: <https://doi.org/10.1109/TVT.2020.3043852>
- [2] Борисевич А.В. Моделирование литийионных аккумуляторов для систем управления батареями: обзор текущего состояния. *Современная техника и технологии*, 2014, № 5. URL: <https://technology.snauka.ru/2014/05/3542>
- [3] Moura S.J., Chaturvedi N.A., Krstic M. Adaptive partial differential equation observer for battery state-of-charge/state-of-health estimation via an electrochemical model. *J. Dyn. Sys., Meas., Control.*, 2014, vol. 136, no. 1, art. 011015. DOI: <https://doi.org/10.1115/1.4024801>
- [4] Rahmoun A., Biechl H. Modelling of Li-ion batteries using equivalent circuit diagrams. *Przegląd Elektrotechniczny*, 2012, vol. 88, no. 7B, pp. 152–156.
- [5] Soltani M., Telmoudi A.J., Belgacem Y.B., et al. Parameters identification and discharge capacity prediction of Nickel–Metal Hydride battery based on modified fuzzy *c*-regression models. *Neural Comput. & Applic.*, 2020, vol. 32, no. 15, pp. 11361–11371. DOI: <https://doi.org/10.1007/s00521-019-04631-w>
- [6] Guo Y., Yang Z., Liu K., et al. A compact and optimized neural network approach for battery state-of-charge estimation of energy storage system. *Energy*, 2021, vol. 219, no. 5, art. 119529. DOI: <https://doi.org/10.1016/j.energy.2020.119529>
- [7] Fleischer C., Waag W., Bai Z., et al. On-line self-learning time forward voltage prognosis for lithium-ion batteries using adaptive neuro-fuzzy inference system. *J. Power Sources*, 2013, vol. 243, pp. 728–749. DOI: <https://doi.org/10.1016/j.jpowsour.2013.05.114>
- [8] Ходашинский И.А. Идентификация нечетких систем: методы и алгоритмы. *Проблемы управления*, 2009, № 4, с. 15–23.
- [9] Takagi T., Sugeno M. Fuzzy identification of systems and its application to modeling and control. *IEEE Trans. Syst. Man Cybern.*, 1985, vol. 15, no. 1, pp. 116–132. DOI: <https://doi.org/10.1109/TSMC.1985.6313399>
- [10] Mamdani E.H., Assilian S. An experiment in linguistic synthesis with a fuzzy logic controller. *Int. J. Man. Mach. Stud.*, 1975, vol. 7, no. 1, pp. 1–13. DOI: [https://doi.org/10.1016/S0020-7373\(75\)80002-2](https://doi.org/10.1016/S0020-7373(75)80002-2)

- [11] Hathaway R.J., Bezdek J.C. Switching regression models and fuzzy clustering. *IEEE Trans. Fuzzy Syst.*, 1993, vol. 1, no. 3, pp. 195–204.  
DOI: <https://doi.org/10.1109/91.236552>
- [12] Gustafson D.E., Kessel W.C. Fuzzy clustering with a fuzzy covariance matrix. *Proc. IEEE CDC*, 1979, pp. 761–766. DOI: <https://doi.org/10.1109/CDC.1978.268028>
- [13] Gath I., Geva A.B. Unsupervised optimal fuzzy clustering. *IEEE Trans. Pattern Anal. Mach. Intell.*, 1989, vol. 11, no. 7, pp. 773–781. DOI: <https://doi.org/10.1109/34.192473>
- [14] Abonyi J., Babuska R., Szeifert F. Modified Gath — Geva fuzzy clustering for identification of Takagi — Sugeno fuzzy models. *IEEE Trans. Syst. Man Cybern.*, 2002, vol. 32, no. 5, pp. 612–621. DOI: <https://doi.org/10.1109/TSMCB.2002.1033180>
- [15] Yager R.R., Filev D.P. Approximate clustering via the mountain method. *IEEE Trans. Pattern Anal. Mach. Intell.*, 1994, vol. 24, no. 8, pp. 1279–1284.  
DOI: <https://doi.org/10.1109/21.299710>
- [16] Chiu S.L. Extracting fuzzy rules for pattern classification by cluster estimation. *Proc. IFSA*, 1995, vol. 95, pp. 273–276.
- [17] Kennedy J., Eberhart R. Particle swarm optimization. *Proc. IEEE ICNN*, 1995, pp. 1942–1948. DOI: <https://doi.org/10.1109/ICNN.1995.488968>
- [18] Khosla A., Kumar S., Aggarwal K.K. A framework for identification of fuzzy models through particle swarm optimization algorithm. *IEEE Indicon*, 2005, pp. 388–391.  
DOI: <https://doi.org/10.1109/INDCON.2005.1590196>
- [19] Holland J.H. *Adaptation in natural and artificial systems*. Cambridge, MIT Press, 1975.
- [20] Civelek Z. Optimization of fuzzy logic (Takagi — Sugeno) blade pitch angle controller in wind turbines by genetic algorithm. *Eng. Sc. Technol. an Int. J.*, 2020, vol. 23, no. 1, pp. 1–9. DOI: <https://doi.org/10.1016/j.jestch.2019.04.010>
- [21] Ходашинский И.А., Гнездилова В.Ю., Дудин П.А. и др. Основанные на производных и метаэвристические методы идентификации параметров нечетких моделей. *Тр. VIII Междунар. конф. SICPRO'08*. М., ИПУ РАН, 2009, с. 501–528.
- [22] Guillaume S. Designing fuzzy inference systems from data: an interpret ability-oriented review. *IEEE Trans. Fuzzy Syst.*, 2001, vol. 9, no. 3, pp. 426–443.  
DOI: <https://doi.org/10.1109/91.928739>
- [23] Shun-Hung T., Yu-Wen Ch. A novel identification method for Takagi — Sugeno fuzzy model. *Fuzzy Sets Syst.*, 2018, vol. 338, pp. 117–135.  
DOI: <https://doi.org/10.1016/j.fss.2017.10.012>
- [24] Kalman R.E. A new approach to linear filtering and prediction problems. *J. Basic Eng.*, 1960, vol. 82, no. 1, pp. 35–45. DOI: <https://doi.org/10.1115/1.3662552>
- [25] Ходашинский И.А., Сарин К.С., Черепанов С.А. Об одном методе инициализации нечетких систем типа Такаги — Сугено. *Автометрия*, 2016, т. 52, № 3, с. 61–70. DOI: <https://doi.org/10.15372/AUT20160308>

- [26] Junhong Y., Jizhen L., Xiangjie L., et al. Identification of nonlinear system based on ANFIS with subtractive clustering. *6th World Cong. on Intelligent Control and Automation*, 2006, pp. 1852–1856. DOI: <https://doi.org/10.1109/WCICA.2006.1712675>
- [27] Benmouiza K., Cheknane A. Clustered ANFIS network using fuzzy *c*-means, subtractive clustering, and grid partitioning for hourly solar radiation forecasting. *Theor. Appl. Climatol.*, 2019, vol. 137, no. 1, pp. 31–43. DOI: <https://doi.org/10.1007/s00704-018-2576-4>
- [28] Jang J.-S.R. ANFIS: adaptive network based fuzzy inference system. *IEEE Trans. Syst. Man Cybern. Syst.*, 1993, vol. 23, no. 3, pp. 665–684. DOI: <https://doi.org/10.1109/21.256541>
- [29] Калман Р., Фалб П., Арбиб М. Очерки по математической теории систем. М., Мир, 1971.
- [30] Заде Л., Дезоер Ч. Теория линейных систем. Метод пространства состояний. М., Наука, 1970.

**Яковлева Ольга Викторовна** — ассистент кафедры «Программное обеспечение ЭВМ и информационные технологии» МГТУ им. Н.Э. Баумана (Российская Федерация, 105005, Москва, 2-я Бауманская ул., д. 5, стр. 1).

**Строганов Юрий Владимирович** — старший преподаватель кафедры «Программное обеспечение ЭВМ и информационные технологии» МГТУ им. Н.Э. Баумана (Российская Федерация, 105005, Москва, 2-я Бауманская ул., д. 5, стр. 1).

**Рудаков Игорь Владимирович** — канд. техн. наук, доцент, заведующий кафедрой «Программное обеспечение ЭВМ и информационные технологии» МГТУ им. Н.Э. Баумана (Российская Федерация, 105005, Москва, 2-я Бауманская ул., д. 5, стр. 1).

**Просьба ссылаться на эту статью следующим образом:**

Яковлева О.В., Строганов Ю.В., Рудаков И.В. О выборе метода построения нечеткой модели прогнозирования состояния аккумулятора. *Вестник МГТУ им. Н.Э. Баумана. Сер. Приборостроение*, 2022, № 4 (141), с. 36–55.

DOI: <https://doi.org/10.18698/0236-3933-2022-4-36-55>

**ON SELECTING A METHOD OF CONSTRUCTING A FUZZY MODEL FOR PREDICTION OF THE BATTERY STATE**

O.V. Yakovleva

oyakovleva@bmstu.ru

Yu.V. Stroganov

stroganovyv@bmstu.ru

I.V. Rudakov

irudakov@bmstu.ru

**Bauman Moscow State Technical University, Moscow, Russian Federation**

## Abstract

Battery-powered electric vehicles are being currently considered to replace conventional non-environmental vehicles. Batteries could not be used without a control system, which development requires a mathematical model to predict the state of a separate battery. The Takagi — Sugeno fuzzy system (fuzzy model) could become such a model. There are methods for automatic construction of fuzzy models according to the table of observations. However, unambiguous criteria for selecting the appropriate method in each specific case are missing. The problem is considered of determining a method making it possible to obtain a fuzzy model that predicts the lithium-ion battery voltage from the load current and the state of charge when discharging with direct current with the lowest mean-square error. The existing methods and their classes were reviewed, and five methods were selected for comparison. Prediction error by all the models obtained was unevenly distributed along the axis of the charge state, and it took the highest values in the range of 97–100 %. The lowest mean-square error was registered in the model built by the combined method using subtractive clustering, least squares method and adaptive network based on the adaptive neuro-fuzzy inference system. The error in such model was changing step-wise, which was associated with feature of the subtractive clustering algorithm, i.e., the formed clusters were of the same size

## Keywords

*Battery, fuzzy model, clustering, subtractive clustering, ANFIS, least squares method, particle swarm*

Received 25.04.2022

Accepted 17.06.2022

© Author(s), 2022

---

## REFERENCES

- [1] Prajwowski K., Golebiewski W., Lisowski M., et al. Road test of selected electrical parameters of the hybrid vehicle accumulation system. *IEEE Trans. Veh. Technol.*, 2021, vol. 70, no. 1, pp. 203–211. DOI: <https://doi.org/10.1109/TVT.2020.3043852>
- [2] Borisevich A.V. Modeling of lithium-ion batteries for battery management systems: the survey of current state. *Sovremennaya tekhnika i tekhnologii* [Modern Technics and Technologies], 2014, no. 5 (in Russ.). Available at: <https://technology.snauka.ru/2014/05/3542>
- [3] Moura S.J., Chaturvedi N.A., Krstic M. Adaptive partial differential equation observer for battery state-of-charge/state-of-health estimation via an electrochemical model. *J. Dyn. Sys., Meas., Control.*, 2014, vol. 136, no. 1, art. 011015. DOI: <https://doi.org/10.1115/1.4024801>

- [4] Rahmoun A., Biechl H. Modelling of Li-ion batteries using equivalent circuit diagrams. *Przeгляд Elektrotechniczny*, 2012, vol. 88, no. 7B, pp. 152–156.
- [5] Soltani M., Telmoudi A.J., Belgacem Y.B., et al. Parameters identification and discharge capacity prediction of Nickel–Metal Hydride battery based on modified fuzzy *c*-regression models. *Neural Comput. & Applic.*, 2020, vol. 32, no. 15, pp. 11361–11371. DOI: <https://doi.org/10.1007/s00521-019-04631-w>
- [6] Guo Y., Yang Z., Liu K., et al. A compact and optimized neural network approach for battery state-of-charge estimation of energy storage system. *Energy*, 2021, vol. 219, no. 5, art. 119529. DOI: <https://doi.org/10.1016/j.energy.2020.119529>
- [7] Fleischer C., Waag W., Bai Z., et al. On-line self-learning time forward voltage prognosis for lithium-ion batteries using adaptive neuro-fuzzy inference system. *J. Power Sources*, 2013, vol. 243, pp. 728–749. DOI: <https://doi.org/10.1016/j.jpowsour.2013.05.114>
- [8] Khodashinskiy I.A. Identification of fuzzy systems: methods and algorithms. *Problemy upravleniya* [Control Sciences], 2009, no. 4, pp. 15–23 (in Russ.).
- [9] Takagi T., Sugeno M. Fuzzy identification of systems and its application to modeling and control. *IEEE Trans. Syst. Man Cybern.*, 1985, vol. 15, no. 1, pp. 116–132. DOI: <https://doi.org/10.1109/TSMC.1985.6313399>
- [10] Mamdani E.H., Assilian S. An experiment in linguistic synthesis with a fuzzy logic controller. *Int. J. Man. Mach. Stud.*, 1975, vol. 7, no. 1, pp. 1–13. DOI: [https://doi.org/10.1016/S0020-7373\(75\)80002-2](https://doi.org/10.1016/S0020-7373(75)80002-2)
- [11] Hathaway R.J., Bezdek J.C. Switching regression models and fuzzy clustering. *IEEE Trans. Fuzzy Syst.*, 1993, vol. 1, no. 3, pp. 195–204. DOI: <https://doi.org/10.1109/91.236552>
- [12] Gustafson D.E., Kessel W.C. Fuzzy clustering with a fuzzy covariance matrix. *Proc. IEEE CDC*, 1979, pp. 761–766. DOI: <https://doi.org/10.1109/CDC.1978.268028>
- [13] Gath I., Geva A.B. Unsupervised optimal fuzzy clustering. *IEEE Trans. Pattern Anal. Mach. Intell.*, 1989, vol. 11, no. 7, pp. 773–781. DOI: <https://doi.org/10.1109/34.192473>
- [14] Abonyi J., Babuska R., Szeifert F. Modified Gath — Geva fuzzy clustering for identification of Takagi — Sugeno fuzzy models. *IEEE Trans. Syst. Man Cybern.*, 2002, vol. 32, no. 5, pp. 612–621. DOI: <https://doi.org/10.1109/TSMCB.2002.1033180>
- [15] Yager R.R., Filev D.P. Approximate clustering via the mountain method. *IEEE Trans. Pattern Anal. Mach. Intell.*, 1994, vol. 24, no. 8, pp. 1279–1284. DOI: <https://doi.org/10.1109/21.299710>
- [16] Chiu S.L. Extracting fuzzy rules for pattern classification by cluster estimation. *Proc. IFSA*, 1995, vol. 95, pp. 273–276.
- [17] Kennedy J., Eberhart R. Particle swarm optimization. *Proc. IEEE ICNN*, 1995, pp. 1942–1948. DOI: <https://doi.org/10.1109/ICNN.1995.488968>
- [18] Khosla A., Kumar S., Aggarwal K.K. A framework for identification of fuzzy models through particle swarm optimization algorithm. *IEEE Indicon*, 2005, pp. 388–391. DOI: <https://doi.org/10.1109/INDCON.2005.1590196>

- [19] Holland J.H. *Adaptation in natural and artificial systems*. Cambridge, MIT Press, 1975.
- [20] Civelek Z. Optimization of fuzzy logic (Takagi — Sugeno) blade pitch angle controller in wind turbines by genetic algorithm. *Eng. Sc. Technol. an Int. J.*, 2020, vol. 23, no. 1, pp. 1–9. DOI: <https://doi.org/10.1016/j.jestch.2019.04.010>
- [21] Khodashinskiy I.A., Gnezdilova V.Yu., Dudin P.A., et al. [Derivative-based and metaheuristic methods for identifying parameters of fuzzy models]. *Tr. VIII Mezhdunar. konf. SICPRO'08* [Proc. VIII Int. Conf. SICPRO'08]. Moscow, IPU RAN Publ., 2009, pp. 501–528 (in Russ.).
- [22] Guillaume S. Designing fuzzy inference systems from data: an interpret ability-oriented review. *IEEE Trans. Fuzzy Syst.*, 2001, vol. 9, no. 3, pp. 426–443. DOI: <https://doi.org/10.1109/91.928739>
- [23] Shun-Hung T., Yu-Wen Ch. A novel identification method for Takagi — Sugeno fuzzy model. *Fuzzy Sets Syst.*, 2018, vol. 338, pp. 117–135. DOI: <https://doi.org/10.1016/j.fss.2017.10.012>
- [24] Kalman R.E. A new approach to linear filtering and prediction problems. *J. Basic Eng.*, 1960, vol. 82, no. 1, pp. 35–45. DOI: <https://doi.org/10.1115/1.3662552>
- [25] Khodashinskiy I.A., Sarin K.S., Cherepanov S.A. Initialization method for fuzzy Takagi — Sugeno systems. *Optoelectron. Instrument. Proc.*, 2016, vol. 52, no. 3, pp. 266–273. DOI: <https://doi.org/10.3103/S8756699016030080>
- [26] Junhong Y., Jizhen L., Xiangjie L., et al. Identification of nonlinear system based on ANFIS with subtractive clustering. *6th World Cong. on Intelligent Control and Automation*, 2006, pp. 1852–1856. DOI: <https://doi.org/10.1109/WCICA.2006.1712675>
- [27] Benmouiza K., Cheknane A. Clustered ANFIS network using fuzzy *c*-means, subtractive clustering, and grid partitioning for hourly solar radiation forecasting. *Theor. Appl. Climatol.*, 2019, vol. 137, no. 1, pp. 31–43. DOI: <https://doi.org/10.1007/s00704-018-2576-4>
- [28] Jang J.-S.R. ANFIS: adaptive network based fuzzy inference system. *IEEE Trans. Syst. Man Cybern. Syst.*, 1993, vol. 23, no. 3, pp. 665–684. DOI: <https://doi.org/10.1109/21.25654>
- [29] Kalman R.E., Falb P.L., Arbib M.A. *Topics in mathematical system theory*. New York, McGraw-Hill, 1969.
- [30] Zadeh L.A., Desoer C.A. *Linear system theory. The state space approach*. New York, McGraw-Hill, 1963.

**Yakovleva O.V.** — Assistant, Department of Computer Software and Information Technologies, Bauman Moscow State Technical University (2-ya Baumanskaya ul. 5, str. 1, Moscow, 105005 Russian Federation).

**Stroganov Yu.V.** — Senior Lecturer, Department of Computer Software and Information Technologies, Bauman Moscow State Technical University (2-ya Bauman-skaya ul. 5, str. 1, Moscow, 105005 Russian Federation).

**Rudakov I.V.** — Cand. Sc. (Eng.), Assoc. Professor, Head of the Department of Computer Software and Information Technologies, Bauman Moscow State Technical University (2-ya Baumanskaya ul. 5, str. 1, Moscow, 105005 Russian Federation).

**Please cite this article in English as:**

Yakovleva O.V., Stroganov Yu.V., Rudakov I.V. On selecting a method of constructing a fuzzy model for prediction of the battery state. *Herald of the Bauman Moscow State Technical University, Series Instrument Engineering*, 2022, no. 4 (141), pp. 36–55 (in Russ.). DOI: <https://doi.org/10.18698/0236-3933-2022-4-36-55>