

УДК 621.385.73 (088.8)
EDN: RQOHPEPACS: 79.40. + z, 68.37. – d,
84.47.+w, 81.15.-z**Нейросетевая оптимизация параметров ионно-плазменного осаждения термоэмиссионных покрытий**

© Г. А. Жабин

*АО «НПП «ИСТОК» им. Шокина», Московская обл., г. Фрязино, 141190 Россия
E-mail: zhabingennady@yandex.ru**Статья поступила в редакцию 19.01.2026; после доработки 2.02.2026; принята к публикации 5.06.2026
Шифр научной специальности: 2.2.9*

Предложен способ оптимизации параметров процесса ионно-плазменного распыления мишеней тройных карбонатов щелочноземельных металлов Ba, Sr, Ca. Для построения прогнозной модели использована искусственная нейронная сеть (ИНС) с генетическим алгоритмом. Определены параметры напыления для получения тока эмиссии в диапазоне 70–120 мкА тонкопленочных термоэмиссионных микрокатодов. Выполнено сравнение результатов прогнозирования с экспериментальными данными по эмиссии изготовленных микрокатодов, а также с расчетами, полученными с помощью других моделей машинного обучения. Это сравнение показало, что ИНС позволяет найти более точную комбинацию параметров осаждения покрытий для создания эффективных термоэмиссионных микрокатодов.

Ключевые слова: молекулярно-напыленный оксидный микрокатод (МНОК), ионно-плазменное напыление, машинное обучение, прогнозирование, искусственная нейронная сеть, генетический алгоритм.

DOI: 10.51368/1996-0948-2026-3-61-67

Введение

Технологии ионно-плазменного (магнетронного) распыления (ИПР) позволяют контролировать толщину и состав напыляемой пленки. В этих процессах для распыления с мишени вещества, осаждаемого на подложку и формирующего тонкую пленку, используют плазменную среду. Сложные физико-химические явления, происходящие при осаждении покрытий, требуют точного контроля важнейших технологических параметров – таких, как давление, скорость потока рабочего газа, температура подложки и мощность распыления. Изучение этих процессов помогает управлять стехиометрией и структурой пленок, что, в свою очередь, влияет на их функциональные характеристики [1].

Авторы работы [2] разработали гибридную методику машинного обучения (МО), объединившую соответствующие модели

классификации и регрессии для решения проблемы, связанной с получением высокоподвижных аморфных плёнок $\text{In}_2\text{O}_3\text{Sn}$, которые были изготовлены методом радиочастотного магнетронного распыления.

В работе [3] рассмотрены различные характеристики низкотемпературной плазмы и их сложность, обусловленная разнообразием параметров состава газовой фазы, давлением рабочего газа, плотностью подаваемой энергии и пространственными границами. В этих условиях прямое применение методов машинного обучения не всегда возможно. Для преодоления трудностей необходим прогресс в области диагностики плазмы и систем сбора данных. Обработка большого количества данных является одной из ключевых задач для достижения этой цели.

Авторы работы [4] путем моделирования переноса ионов аргона, бомбардирующего композит Ti-Al, получили ряд репрезентатив-

ных функций распределения энергии падающих частиц. Затем на этом наборе входных и выходных распределений обучили и проверили многослойную искусственную нейронную сеть (ИНС). После получения результатов обучения проведен анализ ошибок и сравнение их качества для двух наборов гиперпараметров. Показано, что обученная ИНС способна прогнозировать распределение расплывшихся частиц для неизвестных распределений энергии падающих ионов произвольной формы.

В работе [5] предложили эффективную систему проектирования процессов, которая позволяет искать оптимальные условия процесса за счёт сочетания глубокого обучения с моделированием плазмы. Для создания модели обучения был создан набор данных с использованием двумерного (2D) кода модели гибридного плазменного оборудования для системы с аргоновой плазмой с индуктивной связью. Модель была реализована и обучена с использованием набора данных для изучения функциональной взаимосвязи между технологическими условиями и вытекающими из них состояниями плазмы.

В исследовании [6] прогнозировались показатели преломления пленок SiN_x , выращенных на кремниевых подложках методом осаждения магнетронного распыления с использованием ИНС. Для обучения ИНС в качестве входных параметров использовались значения длины волны и температуры из экспериментальных данных, а в качестве выходного параметра – показатель преломления. Результаты моделирования и прогноза, полученные с помощью модели, сравнивались с экспериментальными данными. Сделан вывод, что подход с ИНС применим для моделирования и прогнозирования показателя преломления.

Методы мягких вычислений – такие, как генетический алгоритм (ГА) и ИНС – активно применяются в решении многих нелинейных задач благодаря хорошей производительности данных моделей [7, 8]. Используя ИНС, можно получать из данных сложные закономерности.

В настоящей работе предметом исследования являются тонкопленочные молекулярно-напыленные оксидные катоды (МНОК), при-

меняемые в циклотронных защитных устройствах (ЦЗУ), которые получают с использованием ИПР катод-мишеней из карбонатов щелочно-земельных металлов (ЩЗМ). Они обеспечивают плотность тока $1\text{--}2\text{ А/см}^2$ в течение $5\text{--}10$ тысяч часов. Толщина напыляемой эмиссионной пленки на микрокатодах составляет $\approx 1\text{ мкм}$ [1, 9].

Целью данного исследования являлось построение и оптимизация модели для предсказания значения целевой переменной тока микрокатада (I_{cat}) на основе набора технологических параметров напыления.

Объекты исследований и методика эксперимента

Напыление покрытий на микрокатоды проводилось на установке вакуумного ионно-плазменного напыления «УРМ3279011», производство России. Геометрические размеры, принцип работы и основные электрические параметры КПУ и рабочей камеры данной установки описанные в работах [10,11] одинаковы. Катод-мишени (Ba , Sr , Ca) CO_3 для ИПР изготавливали методом пульверизации из порошкообразных карбонатов ЩЗМ марки КТА-1-6-сп. Соотношение активных элементов ЩЗМ в мишени составляло 47:45:8, толщина – 130–135 мкм. Турбомолекулярный насос имел скорость откачки 500 л/с. Предельный уровень вакуума – 1×10^{-6} Па. После разложения карбонатов мишени постоянное напряжение, подаваемое между мишенью и подложкой, дает энергию, необходимую для ионизации атомов аргона и диссоциации газа CO_2 , что приводит к состоянию плазмы. Под действием приложенного электрического поля ионы аргона бомбардируют мишень и распыляют ее. Распыленные атомы и молекулы в процессе движения к подложкодержателю реагируют с газом и, осаждаясь на керны микрокатодов, создают пленки оксидов и карбонатов ЩЗМ. Процесс распыления контролируется путем изменения технологических параметров установки.

Используемый набор данных получен при осаждении покрытий на МНОК и последующем измерении тока эмиссии микрокатодов в вакуумных приборах. Набор данных по-

лучен из процессов, которые были проведены в различных условиях с изменяющимися параметрами осаждения покрытий. Целевая переменная I_{cat} была отделена от признаков. Набор данных был разделен на обучающую (80 %) и тестовую (20 %) выборки. Все признаки были масштабированы на обучающей выборке, а затем применены к тестовой выборке. Исходные данные содержали 253 строки и 13 столбцов.

Исследование состояло из следующих этапов: сбора и обработки данных, разработки и прогнозирования модели с помощью ИНС, оптимизации с помощью ГА. Столбцы с полностью пропущенными значениями были удалены. Осуществлена проверка и обработка пропусков. Были выбраны 12 параметрах осаждения: Напряжение разряда U_{dis} , В; ток разряда I_{dis} , мА; напряжение накала мишени при напылении U_{nm} , В; ток накала мишени при напылении I_{nm} , А; напряжение отражателя U_{otr} , В; ток отражателя I_{otr} , А; ток соленоида I_{sol} , А; давление напыления P , Па; температура подложки T_{sub} , °С; время разложения карбонатов мишени t_{dec} , мин; максимальный ток при разложении мишени I_{dec} , А; время напыления t_{sup} , мин. ГА был адаптирован для поиска оптимальной комбинации настроек параметров. В этом исследовании целевая функция состояла в максимизации тока эмиссии катодов I_{cat} . Полученный результат с использованием ГА проверялся с помощью ИНС и сравнивался с экспериментальными результатами и результатами полученными другими методами машинного обучения (МО) – такими, как метод опорных векторов (SVR), «случайный лес» (RF) [12], градиентный бустинг (GB) [13, 14], XGBoost (высокопроизводительный градиентный бустинг) [12–14, 15]. ГА основан на естественном отборе и включает четыре основных этапа. Это создание популяции решений, оценка приспособленности для каждого решения, отбор особей и создание новой популяции на основе трех генетических операций: репродукции, кроссовера и мутации [7, 8]. Репродукция происходит, когда каждая особь дублируется на основе ее значений приспособленности [16]. В данном исследовании выбрана мутация, при которой ток катода заменяется равномерно случайным значением, выбранным между заданными верхней и ниж-

ней границами 60–120 мкА в низкотемпературной области (480–490 °С) эмиссионных характеристик МНОК [1, 11]. Данная низкотемпературная область выбрана потому, что она характеризует и определяет эмиссионную активность и качество микроатома на всей эмиссионной кривой. Целевая функция исследования – максимизировать ток эмиссии напыленных катодов в определенной низкотемпературной области не локальных характеристик. Входами для модели являлись параметры напыления, а выходом – ток микроатома. Была определена архитектура нейронной сети с использованием библиотеки Keras. Базовая модель состояла из 4 полносвязных слоев с функциями активации LeakyReLU с параметром 0,01 и слоями пакетной нормализации. L2-регуляризация применена для контроля переобучения и повышения обобщающей способности модели. Входной слой состоял из 12 нейронов. Скрытые слои имели 128, 128, 64 и 32 нейрона. Выходной слой имел один нейрон с линейной активацией для задачи регрессии. Обучение модели проводилось на 100 эпохах с ранней остановкой. Модель была скомпилирована с оптимизатором Adam (скорость обучения 0,001) и функцией потерь MSE (среднеквадратическая ошибка), а также метриками MAE (средняя абсолютная ошибка) и R^2 . Метрики базовой модели на тестовых данных с 4 скрытыми слоями: MSE – 431,9; MAE – 15,5; показатель R^2 – 0,47. R^2 показывает, какой процент изменчивости в зависимой переменной может быть объяснен вариациями в независимых переменных, используемых в модели. Целевой метрикой для оптимизации была R^2 с направлением максимизации. Было выполнено 30 испытаний, каждая конфигурация модели обучалась 2 раза для повышения стабильности оценки.

Обучение оптимизированной модели с найденными гиперпараметрами показало значительное улучшение. Модель обучалась в течение 250 эпох. Использовались библиотеки Keras и метод `keras_tuner`, алгоритм `RandomSearch`. Случайным образом выбраны различные комбинации гиперпараметров. Для каждой выбранной комбинации гиперпараметров алгоритм обучил модель на тренировочных данных. Оптимизированные гиперпараметры

привели к созданию модели ИНС со следующей архитектурой и конфигурацией обучения: 4 скрытых слоя. Первый слой – с 480 нейронами и функцией активации «relu», второй слой – с 160 нейронами, «tanh». Третий слой – 96 нейрона, четвертый – 128, функции активации «leaky_relu» и «relu», соответственно.

После обучения оптимизированной ИНС ее метрики производительности на тестовой выборке изменились: MSE – 229,68; MAE – 12,17; R^2 – 0,72. Процесс настройки существенно улучшил предсказательную способность модели. Графики обучения оптимизированной модели представлены на рис. 1 (а, б).

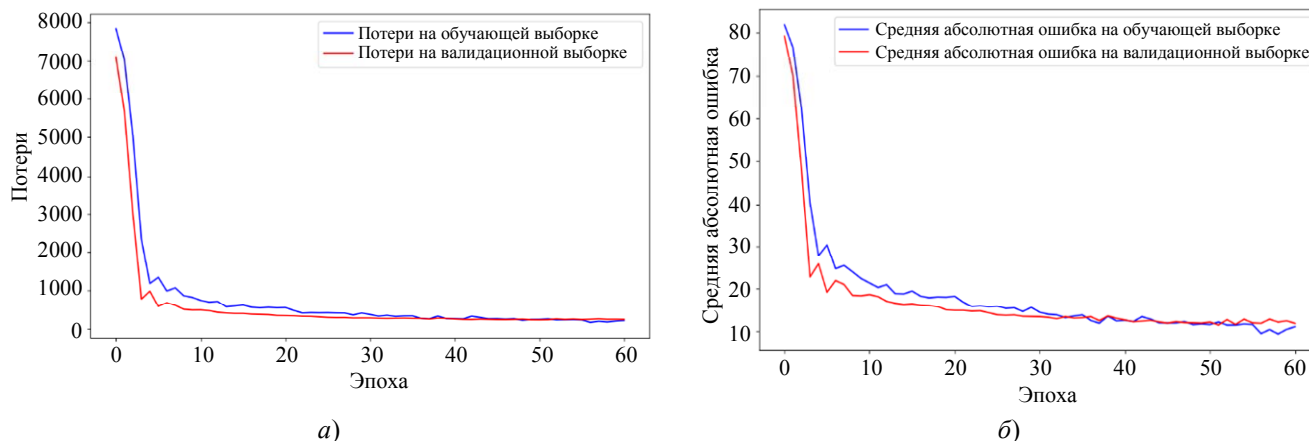


Рис. 1. Обучение модели на тестовой и валидационной выборках: а) – потери, б) – MAE

Результаты экспериментов и их обсуждение

В работе использовались технологические данные, связанные с нагревом и разложением карбонатов мишени, осаждением покрытия в установке ИПР, измерением эмиссии. Значения, записанные на других этапах, косвенно связанных с током эмиссии, например – откачка вакуума или монтаж и сборка напыленных катодов – не рассматривались. Добавление этих этапов потребовало бы создания гораздо большего набора данных и увеличения сложности задачи.

На графиках истории обучения (рис. 1) видно, что на тренировочных и валидационных данных ошибки со временем уменьшаются. Кривые показывают, что модель успешно обучается. Показаны две ключевые метрики: потери (Loss) и средняя абсолютная ошибка (MAE). Для каждой метрики отображены две линии: синяя линия показывает значения метрики на обучающей выборке (данные, на которых модель училась). Красная линия – значения метрики на валидационной выборке (данные, которые модель никогда не видела во время обучения, используются для оценки ее обобщающей способности). График потерь

демонстрирует, как менялась ошибка модели на протяжении эпох обучения. Показано, что валидационные потери не сильно расходятся с тренировочной – это указывает на то, что модель не переобучилась и способна хорошо работать на новых данных. Модель эффективно учится и при этом сохраняет обобщающую способность. MAE показывает среднее абсолютное отклонение предсказанных значений от фактических. Меньшее значение MAE означает, что предсказания модели в среднем ближе к истинным значениям. Аналогично потерям, обе линии MAE также снижаются, а затем стабилизируются. Низкие значения MAE на валидационной выборке подтверждают, что модель делает точные предсказания. Сходство между тренировочной и валидационной MAE свидетельствует об отсутствии значительного переобучения.

На основе усредненных абсолютных весов связей первого слоя оптимизированной модели проведен анализ важности признаков. Важность признаков оптимизированной модели ИНС была рассчитана и отсортирована по возрастанию. Визуализация с помощью вертикальной столбчатой диаграммы (рис. 2а) показала численную важность каждого признака.




Рис. 2. Диаграмма важности признаков оптимизированной модели (а). Эмиссионные характеристики двух экспериментальных МНОК, полученные после напыления покрытий с применением ГА (б)

Согласно проведенному анализу (рис. 2а) наиболее важными признаками (с наибольшими средними абсолютными весами в первом слое) являются параметры напыления: I_{dec} , U_{dis} , I_{nm} , I_{dis} , а наименее важными – I_{otr} , U_{nm} , P . I_{dec} имеет наибольшую важность. Изменяя этот параметр случайным образом, мы значительно ухудшаем качество предсказания модели. От того, насколько правильно произойдет термическое разложение карбонатов катод-мишени в вакууме, до начала непосредственного процесса напыления покрытия на керны микрокатодов, зависит последующая ее эмиссионная способность для испускания термоэлектронов и ионизация газа для ее распыления при нанесении эмиссионного покрытия. Это связано с температурой разложения карбонатов ЦЗМ, продолжительностью данного технологического этапа, давлением остаточных газов в камере. При термическом разложении мишени происходят важные физико-химические процессы в объеме и на ее поверхности, формирующие оксидный слой соответствующего состава, с которого идет напыление на микрокатоды. U_{dis}

определяет ускоряющее напряжение, необходимое для распыления катод-мишени. I_{nm} вместе с U_{nm} определяют мощность накала, имеющую значение для температурного разогрева и диффузии атомов активных веществ на поверхность мишени во время осаждения покрытия.

В результате работы ГА был найден набор входных признаков (лучшее решение), который при подаче в оптимизированную ИНС определил предсказанное значение $I_{cat} = 90$ мкА, что соответствует центру целевого диапазона и максимизирует функцию приспособленности (таблица).

При проведении исследования также получены зависимости прогнозируемого тока катодов от технологических параметров напыления. Прогнозируемый ток МНОК растет с увеличением ускоряющего напряжения разряда, тока разложения карбонатов мишени и тока разряда. Уменьшение давления рабочего газа с 0,13 до 0,11 Па влияет на увеличение прогнозируемого I_{cat} . Полученные результаты согласуются с ранее проведенными исследованиями в экспериментальных работах [1, 9–11].

Таблица

Оптимизация параметров процесса с применением ГА

U_{dis} , В	I_{dis} , мА	U_{nm} , В	I_{nm} , А	U_{otr} , В	I_{otr} , А	I_{sol} , А	P , Па	T_{sup} , °C	t_{dec} , мин.	I_{dec} , А	t_{sup} , мин.	I_{cat} , мкА
821	226	23	9,5	24	36	0,38	0,12	228	86	9,7	177	90

После проведенного экспериментально-го процесса напыления на микрокатоды с использованием технологических параметров, близких к полученному ГА в таблице, были измерены значения I_{cat} двух МНОК, смонтированных в макеты вакуумных приборов. Полученные недокальные характеристики микрокатодов показаны на рис. 2б. В низкотемпературной области эмиссионных кривых (480–490 °С) прогнозируемый I_{cat} имеет значения 108 мкА (№ 1) и 77 мкА (№ 2), что входит в диапазон целевой функции.

Проведено обучение и оценка производительности других моделей машинного обучения (RF, GB, SVR, XGBoost). Критерием оценки перечисленных моделей была R^2 -метрика. Результаты сравнения для всех моделей: ИНС – 0,72; RF – 0,61; GB – 0,62; XGBoost – 0,42; SVR – 0,25. Точность прогнозирования ИНС выше, чем у других традиционных методов МО. Модели ИНС, GB и RF являются наиболее подходящими для прогнозирования I_{cat} на основе текущего набора данных, но ИНС превзошла все остальные модели, демонстрируя наибольшую предсказательную способность.

Заключение

Разработана архитектура и проведено обучение модели ИНС для предсказания последующего значения тока термоэмиссионных микрокатодов на основе экспериментальных данных процесса вакуумного ионно-плазменного напыления эмиссионных покрытий. Предложен способ оптимизации параметров процесса ИПР для изготовления эффективных тонкопленочных эмиттеров. С использованием генетического алгоритма найден лучший набор параметров напыления, обеспечивающий ток микрокатодов в низкотемпературной области эмиссионных характеристик в диапазоне 60–120 мкА. ИНС показала приемлемую точность предсказаний на тестовых данных с

метрикой R^2 , равной 0,72, и лучшие результаты по сравнению с традиционными регрессионными моделями МО. Результаты моделирования можно использовать для масштабирования процессов напыления в промышленности.

СПИСОК ЛИТЕРАТУРЫ

1. Жабин Г. А., Пелунец О. В., Шапанов Н. А. / Письма в Журнал технической физики. 2024. Т. 50. № 11. С. 38–41. <https://doi.org/10.61011/PJTF.2024.11.57909.19827>.
2. Kamataki K. et al. / Journal of Applied Physics. 2023. Vol. 134. № 16. <https://doi.org/10.1063/5.0160228>.
3. Sakai O., Kawaguchi S., Murakami T. / Japanese Journal of Applied Physics. 2022. Vol. 61. № 7. P. 070101. <https://doi.org/10.35848/1347-4065/ac76fa>.
4. Krüger F., Gergs T., Trieschmann J. / Plasma Sources Science and Technology. 2019. Vol. 28. № 3. P. 035002.
5. Ko J. et al. / Journal of Physics D: Applied Physics. 2023. Vol. 56. № 34. P. 344001. <https://doi.org/10.1088/1361-6463/acd1fd>.
6. Yükses A. G. et al. / Physica B: Condensed Matter. 2024. Vol. 695. P. 416581. <https://doi.org/10.1016/j.physb.2024.416581>.
7. Mohd Sabri N. et al. / Advanced Materials Research. 2015. Vol. 1109. P. 481–485. <https://doi.org/10.4028/www.scientific.net/AMR.1109.48>.
8. Ko Y. D. et al. / Expert Systems with Applications. 2009. Vol. 36. № 2. P. 4061–4066. <https://doi.org/10.1016/j.eswa.2008.03.010>.
9. Жабин Г. А., Архипов Д. Ю., Темирязева М. П. / Прикладная физика. 2019. № 5. С. 54.
10. Жабин Г. А., Логинов Б. А., Логинов А. Б., Шичалин К. В. / Журнал радиоэлектроники. 2025. № 6. <https://doi.org/10.30898/1684-1719.2025.6.5>.
11. Жабин Г. А., Архипов Д. Ю., Седловец Д. М., Темирязева М. П. / Электронная техника. Сер. 1. СВЧ – техника. 2020. Вып. 1 (544). С. 46–55.
12. Khan A. A., Chaudhari O., Chandra R. / Expert Systems with Applications. 2024. Vol. 244. P. 122778. <https://doi.org/10.1016/j.eswa.2023.122778>.
13. Vijayaraghavan V., Garg A., Gao L. / Journal of Energy Storage. 2025. Vol. 135. P. 118374.
14. Chen T. / Cornell University. 2016. <https://doi.org/10.1145/2939672.2939785>.
15. Клюковкин Г. К. / Актуальные исследования. 2024. № 37 (219). <https://doi.org/10.5281/zenodo.16131539>.
16. Katoch S., Chauhan S. S., Kumar V. / Multimedia tools and applications. 2021. Vol. 80. № 5. P. 8091–8126. <https://doi.org/10.1007/s11042-020-10139-6>.

Application of artificial neural networks to optimization the parameters of ion-plasma deposition of thermionic coatings

G. A. Zhabin

JSC «RPC «Istok» named after Shokin», Fryazino, Moscow Region, 141190 Russia

E-mail: zhabingennady@yandex.ru

Received 19.01.2026; revised 2.02.2026; accepted 5.06.2026

A method for optimizing the parameters of the ion-plasma sputtering process of triple carbonates of alkaline-earth metals Ba, Sr, Ca is proposed. An artificial neural network (ANN) with a genetic algorithm is used to build a predictive model. The sputtering parameters are determined to obtain an emission current in the range of 70–120 μA for thin-film thermionic microcathodes. The prediction results are compared with the actual emission data of the manufactured microcathodes and those calculated by other machine learning models. Based on the comparison, it was shown that the ANN allowed for finding a more accurate combination of coating deposition parameters to obtain efficient thermionic microcathodes.

Keywords: molecular sputter-deposited oxide microcathode (MSOC), ion-plasma deposition, machine learning, forecasting, artificial neural network, genetic algorithm.

REFERENCES

1. Zhabin G. A., Pelipets O. V., and Sharapov N. A., Technical Physics Letters **50** (11), 38–41 (2024). <https://doi.org/10.61011/PJTF.2024.11.57909.19827>.
2. Kamataki K. et al., Journal of Applied Physics **134** (16), (2023). <https://doi.org/10.1063/5.0160228>.
3. Sakai O., Kawaguchi S., and Murakami T., Japanese Journal of Applied Physics **61** (7), 070101 (2022). <https://doi.org/10.35848/1347-4065/ac76fa>.
4. Kruger F., Gerges T., and Trishman J., Science and technology of plasma sources **28** (3), 035002 (2019).
5. Ko J. et al., Physics Journal D: Applied Physics **56** (34), 344001 (2023). <https://doi.org/10.1088/1361-6463/acd1fd>.
6. Yuksek A. G. et al., Physics in: Condensed media **695**, 416581 (2024). <https://doi.org/10.1016/j.physb.2024.416581>.
7. Mohd Sabri et al., Modern Materials Research **1109**, 481–485 (2015). <https://doi.org/10.4028/www.scientific.net/AMR.1109.48>.
8. Ko Yu. D. et al., Expert systems with applications, **36** (2), 4061–4066 (2009). <https://doi.org/10.1016/j.eswa.2008.03.010>.
9. Zhabin G. A., Arkhipov D. Yu., and Temiryazeva M. P., Applied Physics, № 5, 54 (2019) [in Russian].
10. Zhabin G. A., Loginov B. A., Loginov A. B., and Chichalin K. V., Journal of Radio Electronics, № 6, (2025). <https://doi.org/10.30898/1684-1719.2025.6.5>.
11. Zhabin G. A., Arkhipov D. Yu., Sedlovetz D. M., and Temiryazeva M. P., Electronnaya tekhnika. Ser. 1. Svch-tekhnika, № 1 (544), 46–55 (2020) [in Russian].
12. Khan A. A., Chaudhary O., and Chandra R., Expert systems with applications **244**, 122778 (2024). <https://doi.org/10.1016/j.eswa.2023.122778>.
13. Vijayaraghavan V., Garg A., and Gao L., Journal of Energy Storage **135**, 118374 (2025).
14. Chen T., Cornell University, (2016). <https://doi.org/10.1145/2939672.2939785>.
15. Klyukovkin G. K., Aktual'nyye issledovaniya, № 37 (219), (2024). <https://doi.org/10.5281/zenodo.16131539>.
16. Katoch S., Chauhan S. S., and Kumar V., Multimedia tools and applications **80** (5), 8091 (2021). <https://doi.org/10.1007/s11042-020-10139-6>.

Об авторе

Жабин Геннадий Анатольевич, начальник сектора, АО «НПП «ИСТОК» им. Шокина» (141190, Россия, Московская обл., г. Фрязино, ул. Вокзальная, 2 А). E-mail: zhabingennady@yandex.ru SPIN-код: 1554-0437, AuthorID: 991720