



УДК 621.311.22

DOI: 10.53083/1996-4277-2026-256-2-79-85

Ш.З. Зиниев, В.А. Каргин,
И.В. Кротов, Т.Б. Эзирбаев
Sh.Z. Ziniev, V.A. Kargin,
I.V. Krotov, T.B. Ezirbaev

ПРОГНОЗИРОВАНИЕ ОТКАЗОВ ВОЗДУШНЫХ ЛИНИЙ 35 кВ НА ОСНОВЕ НЕЙРОСЕТИ ДЛЯ ОБЕСПЕЧЕНИЯ НАДЕЖНОСТИ ЭЛЕКТРОСНАБЖЕНИЯ АГРОПРОМЫШЛЕННОГО КОМПЛЕКСА

FORECASTING FAILURES OF 35-KV OVERHEAD POWER LINES USING A NEURAL NETWORK TO ENHANCE POWER SUPPLY RELIABILITY IN THE AGRO-INDUSTRIAL COMPLEX

Ключевые слова: нейронные сети, прогнозирование отказов, воздушные линии электропередачи, ВЛ 35 кВ, машинное обучение, электрические сети, надежность электроснабжения, техническое обслуживание, климатические факторы.

Представлены разработка, обучение и верификация интеллектуальной модели прогнозирования количества и типов технологических нарушений на воздушных линиях электропередачи напряжением 35 кВ. Основная цель работы заключается в повышении надежности электроснабжения объектов агропромышленного комплекса в условиях специфических и динамично меняющихся климатических факторов Шалинского района Чеченской Республики. Актуальность обусловлена критической зависимостью современного АПК от стабильного энергоснабжения и ограничениями традиционных подходов к диагностике состояния ВЛ 35 кВ, не способных учитывать сложные, нелинейные взаимосвязи множества факторов. В качестве методологической основы использована полносвязная нейронная сеть, обученная на обширном временном ряду данных за период 2018-2023 гг. Исходная информация была агрегирована из оперативных журналов, систем SCADA и локальных метеорологических станций, что позволило учесть влияние таких деструктивных факторов, как температурные перепады, ветровые нагрузки и гололедно-изморозевые отложения. Оптимизация архитектуры нейронной сети проводилась с использованием байесовского подхода, а её прогностиче-

ская способность оценивалась метрикой средней абсолютной ошибки (MAE). Эмпирические эксперименты показали, что оптимальной является трехслойная архитектура нейронной сети с конфигурацией 16×64×64 нейронов, которая обеспечила минимальное значение MAE $\approx 0,17$ по каждому классу прогнозируемых повреждений. Было установлено, что дальнейшее увеличение глубины или ширины сети не приводило к существенному улучшению результатов, подтверждая оптимальный баланс между сложностью модели и объемом обучающих данных. Разработанная модель демонстрирует высокую перспективность для своевременного планирования превентивных ремонтных мероприятий, что значительно повышает операционную надежность электроснабжения критически важных объектов АПК.

Keywords: neural networks, failure prediction, overhead power lines, 35 kV overhead lines, machine learning, electrical grids, power supply reliability, maintenance, climatic factors.

The development, training, and verification of an intelligent model for forecasting the quantity and types of technological failures in 35 kV overhead power lines are discussed. The research goal was to enhance the reliability of power supply to agro-industrial complex facilities under the specific and dynamically changing climatic conditions of the Shali District of the Chechen Republic. The relevance of the research is determined by the critical dependence of modern agro-industrial complex on

stable energy supply and the limitations of traditional overhead power line diagnostic approaches which are unable to account for complex, non-linear interdependencies among numerous factors. A fully connected neural network was employed as the methodological basis, trained on an extensive time series dataset from 2018 through 2023. Data aggregation involved information from operational logs, SCADA systems, and local meteorological stations facilitating the incorporation of destructive factors such as temperature fluctuations, wind loads, and ice-frost depositions. Neural network architecture optimization utilized the Bayesian approach, and its predictive capability was evaluated using the Mean

Absolute Error (MAE) metric. Empirical experiments revealed that the optimal neural network architecture was a three-layer configuration with $16 \times 64 \times 64$ neurons achieving a minimum MAE of approximately 0.17 across all classes of predicted failures. Further increases in network depth or width did not yield significant improvements, thereby confirming an optimal balance between model complexity and training data volume. The developed model demonstrates significant potential for the timely planning of preventive maintenance which may substantially enhance the operational reliability of power supply to critical agro-industrial complex facilities.

Зиниев Шамсудин Зелимович, к.т.н., доцент, Грозненский государственный нефтяной технический университет имени академика М.Д. Миллионщикова, г. Грозный, Российская Федерация, e-mail: injenemi-klub@mail.ru.

Каргин Виталий Александрович, д.т.н., профессор, ФГБОУ ВО «Российский биотехнологический университет (РОСБИОТЕХ)», г. Москва, Российская Федерация, e-mail: vakargin@mail.ru.

Кротов Игорь Владимирович, аспирант, ФГБОУ ВО «Российский биотехнологический университет (РОСБИОТЕХ)», г. Москва, Российская Федерация, e-mail: gor_@bk.ru.

Эзирбаев Тимур Борисович, к.т.н., доцент, зав. кафедрой «Теплотехника и гидравлика», директор института энергетика, Грозненский государственный нефтяной технический университет имени академика М.Д. Миллионщикова, г. Грозный, Российская Федерация, e-mail: timersno@mail.ru.

Zinieva Shamsudin Zelimovich, Cand. Tech. Sci., Assoc. Prof., Millionshchikov Grozny State Oil Technical University, Grozny, Russian Federation, e-mail: injenemi-klub@mail.ru.

Kargin Vitaliy Aleksandrovich, Dr. Tech. Sci., Prof., Russian Biotechnological University, Moscow, Russian Federation, e-mail: vakargin@mail.ru.

Krotov Igor Vladimirovich, post-graduate student, Russian Biotechnological University, Moscow, Russian Federation, e-mail: gor_@bk.ru.

Ezirbaev Timur Borisovich, Cand. Tech. Sci, Assoc. Prof., Director, Power Industry Institute, Millionshchikov Grozny State Oil Technical University, Grozny, Russian Federation, e-mail: timersno@mail.ru.

Введение

Обеспечение стабильного и бесперебойного электроснабжения является критически важным условием для устойчивого развития экономики, в особенности для функционирования агропромышленного комплекса (АПК). В частности, современное сельскохозяйственное производство, включая системы орошения, животноводческие комплексы, зернохранилища и перерабатывающие предприятия, характеризуется высокой степенью автоматизации и прямой зависимостью от качества и непрерывности подачи электрической энергии [1, 2]. Воздушные линии электропередачи (ВЛ) напряжением 35 кВ составляют основу распределительной сети, связывая питающие центры с крупными сельскохозяйственными потребителями [3, 4]. Технологические нарушения на этих линиях приводят к значительным перерывам в подаче энергии, что влечет за собой экономические потери, порчу продукции и нарушение производственных циклов АПК.

Так, территория Шалинского района Чеченской Республики, как и многие другие регионы с горным или предгорным ландшафтом, подвержена воздействию сложных и динамичных климатических условий. К числу факторов, оказывающих наиболее деструктивное влияние на надежность эксплуатации ВЛ 35 кВ, относятся резкие температурные перепады, сильные ветровые нагрузки, интенсивные гололедно-изморозевые отложения, а также повышенная грозовая активность. Учет этих специфических климатических факторов при разработке предиктивных моделей является фундаментальной задачей для повышения устойчивости энергосистемы [5].

Традиционные подходы к оценке технического состояния и прогнозированию отказов ВЛ, базирующиеся на периодических инспекциях, статистическом анализе частоты аварий и экспертных оценках, обладают существенными ограничениями [6, 7]. Они, как правило, не позволяют оперативно идентифицировать скрытые

дефекты, не способны точно прогнозировать возникновение аварийных ситуаций в краткосрочной перспективе и слабо учитывают сложные, нелинейные взаимосвязи между множеством факторов, определяющих надежность электропередачи.

В последние годы наблюдается активное внедрение методов машинного обучения в электроэнергетике [8-10]. Нейронные сети продемонстрировали высокую эффективность в решении задач классификации, регрессии и прогнозирования благодаря своей способности к самообучению на основе эмпирических данных и выявлению неочевидных закономерностей [11-13].

Целью исследования является разработка, обучение и верификация интеллектуальной модели прогнозирования количества и типов технологических нарушений, возникающих на ВЛ 35 кВ, эксплуатируемых в Шалинском районе Чеченской Республики.

Объекты и методы

Объектом исследования выступают воздушные линии электропередачи классом напряжения 35 кВ, находящиеся в эксплуатации на территории Шалинского района. Для обучения и последующей верификации прогностической модели был использован временной ряд данных за шестилетний период с 2018 по 2023 гг. Исходная информация была получена из несколь-

```
def model_regression():
    inputs = keras.Input(shape=(6, 8))
    x = keras.layers.Reshape((6 * 8,))(inputs)
    x = keras.layers.Dense(16, activation="relu")(x)
    x = keras.layers.Dense(64, activation="relu")(x)
    x = keras.layers.Dense(64, activation="relu")(x)
    outputs = keras.layers.Dense(7)(x)
    model = keras.Model(inputs, outputs)

    model.compile(optimizer="rmsprop", loss="mse", metrics=["mae"])

    return model
```

Рис. 1. Модель нейронной сети

Взвешенный вектор затем проходит через третий полносвязный слой из 64 нейронов, после чего выходной блок, состоящий из семи нейронов, формирует количественные оценки для каждого из предопределённых типов повреждений ВЛ 35 кВ.

Настройка гиперпараметров (количество слоев l , количество нейронов n в слое) осуществлялась с применением байесовской опти-

ких источников, в том числе оперативных журналов и актов расследования технологических нарушений районных электрических сетей, архивов системы телемеханики и SCADA, а также данных локальных метеорологических станций.

Для обеспечения целостности и структурированности данных был разработан специализированный программный интерфейс, обеспечивающий автоматизированное извлечение и консолидацию информации в единую реляционную базу данных. Это позволило минимизировать ошибки и значительно сократить время на подготовку обучающих выборок. В качестве архитектурного решения для прогнозирования отказов была выбрана модель полносвязной нейронной сети [14].

Архитектура разработанной сети (рис. 1) представлена последовательно соединенными полносвязными слоями. Входной слой принимает двумерный тензор, описывающий последовательность нормализованных признаков за заданный интервал времени. За входным блоком следуют два полносвязных слоя с 16 и 64 нейронами, которые обеспечивают извлечение временных закономерностей и формирование информативного представления последовательности. Это позволяет фокусировать модель на наиболее значимых событиях, например, на резких изменениях температуры или пиковых значениях скорости ветра.

мизации, что позволило эффективно исследовать пространство параметров и найти наиболее производительную конфигурацию.

Оценка прогностической способности модели проводилась с использованием стандартного набора метрик [14]. Качество обучения оценивалось абсолютным значением разности между предсказанными и целевыми значениями – функцией MAE [14].

Результаты и обсуждение

Анализ производительности нейронных сетей с различным количеством нейронов в одном скрытом слое продемонстрировал следующую зависимость. При использовании однослойной конфигурации с шестнадцатью скрытыми элементами зафиксирована средняя абсолютная ошибка на уровне $MAE \approx 0,22$ (рис. 2 а), что свидетельствует о приемлемом, но не оптимальном уровне аппроксимации. Последующее увеличение числа нейронов до тридцати двух в этом же слое привело к некоторому росту ошибки до $MAE \approx 0,24$ (рис. 2 б). Данная тенденция указывает на то, что в условиях ограниченной глубины модель может испытывать трудности с адекватным представлением сложной нелиней-

ной зависимости между входными параметрами и вероятностью возникновения дефекта, а избыточное расширение ширины одного слоя не компенсирует недостаток структурной сложности.

Введение дополнительного скрытого уровня позволило существенно повысить прогностическую способность системы. При конфигурации из двух скрытых слоев, содержащих по шестнадцать нейронов в каждом, отмечено снижение ошибки до $MAE \approx 0,19$ (рис. 3 а). Дальнейшее увеличение n во втором слое до тридцати двух при сохранении шестнадцати в первом привело к незначительному ухудшению – $MAE \approx 0,20$ (рис. 3 б).

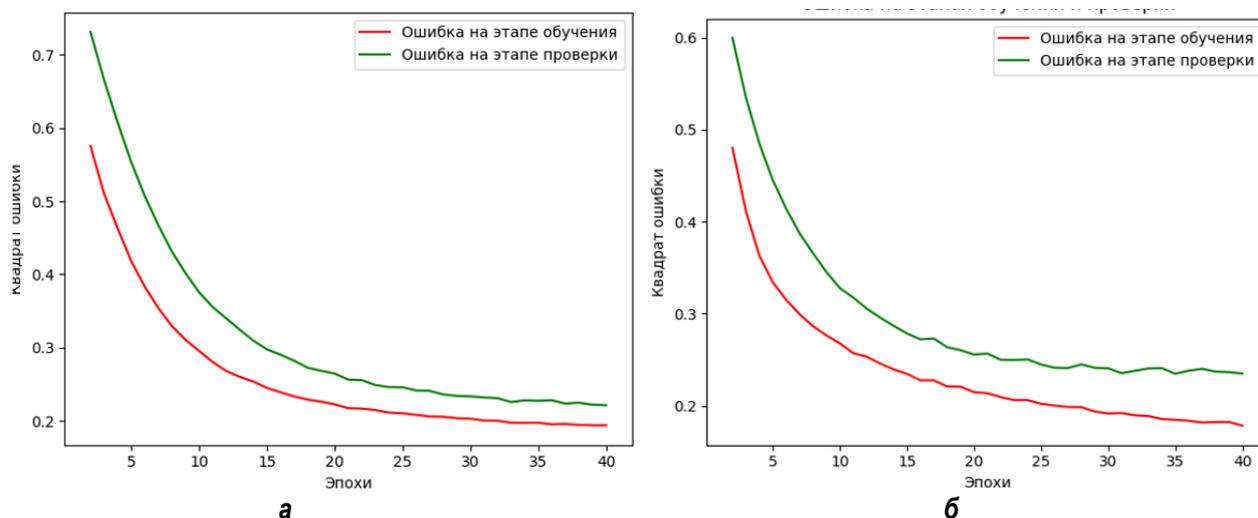


Рис. 2. Результаты обучения нейронной сети с параметрами:
 а – $l = 1, n = 16, MAE \approx 0,22$; б – $l = 1, n = 32, MAE \approx 0,24$

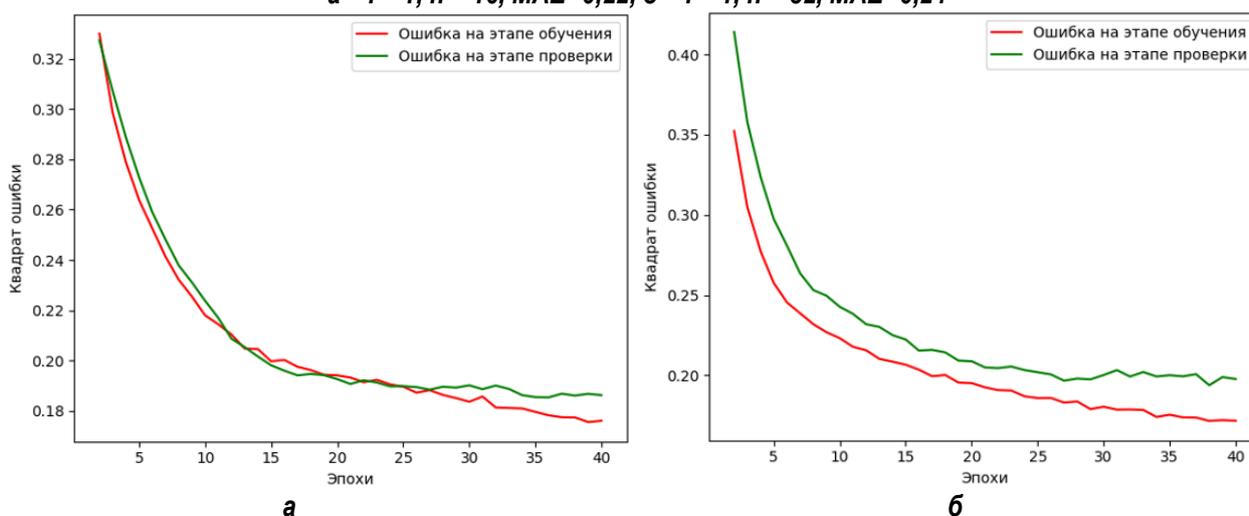


Рис. 3. Результаты обучения нейронной сети с параметрами:
 а – $l = 2, n_1 = 16, n_2 = 16, MAE \approx 0,19$; б – $l = 2, n_1 = 16, n_2 = 32, MAE \approx 0,20$

Переход к трехслойным архитектурам продемонстрировал наиболее выраженный положительный эффект в контексте минимизации

прогностической неточности. Конфигурация с количеством нейронов $16 \times 32 \times 32$ обеспечила $MAE \approx 0,18$ (рис. 4 а). Дальнейшая оптимизация

архитектуры привела к достижению наилучших результатов. Модель с параметрами $16 \times 64 \times 64$ (рис. 4 б) зафиксировала минимальное значение ошибки – $MAE \approx 0,17$. Вариация с более асимметричным распределением ($16 \times 64 \times 128$) показала незначительное увеличение ошибки до $MAE \approx 0,18$, что может быть связано с увеличением числа настраиваемых весовых коэффициентов без соответствующего прироста информативности в самом глубоком слое.

Исследование влияния увеличения глубины до четырех скрытых слоев ($16 \times 64 \times 128 \times 128$) подтвердило, что дальнейшее наращивание сложности не приводит к существенной оптимизации ошибки, сохраняя ее на уровне $MAE \approx 0,17$. Это подтверждает принцип, согласно которому чрезмерное увеличение количества слоев и параметров в моделях для прикладных задач, особенно при ограниченном объеме данных о редких, но критических событиях, таких

как аварии на ВЛ, ведет к потере эффективности из-за усложнения процесса обучения и повышенного риска чрезмерной подгонки к обучающей выборке.

Таким образом, эмпирически установлено, что оптимальная структура гибридной нейронной сети для прогнозирования отказов ВЛ 35 кВ в условиях АПК характеризуется наличием трех скрытых слоев с конфигурацией, близкой к $16 \times 64 \times 64$. Данная архитектура продемонстрировала наивысшее качество прогнозирования с усредненной абсолютной ошибкой $MAE \approx 0,17$ по каждому классу прогнозируемых повреждений. Полученный результат позволяет утверждать о перспективности применения данной модели для своевременного планирования превентивных ремонтных мероприятий, что является ключевым фактором повышения операционной надежности электроснабжения аграрного сектора.

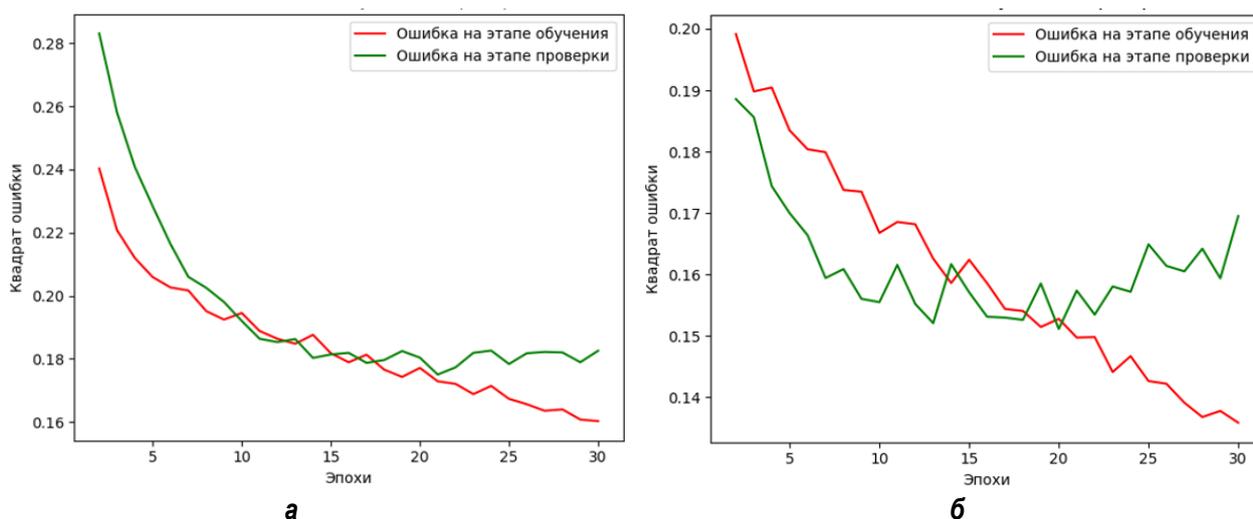


Рис. 4. Результаты обучения нейронной сети с параметрами:
 а – $l = 3, n_1 = 16, n_2 = 32, n_3 = 32, MAE \approx 0,18$; б – $l = 3, n_1 = 16, n_2 = 64, n_3 = 64, MAE \approx 0,17$

Заключение

В рамках настоящего исследования была успешно разработана, обучена и верифицирована интеллектуальная прогностическая модель для оценки вероятности возникновения, а также прогнозирования количества и типов технологических нарушений на воздушных линиях электропередачи классом напряжения 35 кВ. Модель ориентирована на эксплуатацию в специфических, динамично меняющихся климатических условиях Шалинского района Чеченской Республики, что имеет ключевое значение для устойчивого энергоснабжения объектов агропромышленного комплекса.

Библиографический список

1. Королёв, Д. С. Обзор состояния и перспективных направлений развития сельских электрических сетей 0,4 кВ / Д. С. Королёв. – Текст: непосредственный // Агротехника и энергообеспечение. – 2025. – № 1 (46). – С. 47-58. – EDN: NPLYSB.
2. Масенко, А. В. Инновационная структура сельской электрической сети с пониженным уровнем потерь / А. В. Масенко, В. В. Жестков. – Текст: непосредственный // Уральский научный вестник. – 2023. – Т. 1, № 3. – С. 67-70. – EDN: CWAZXJ.

3. Якупова, М. А. Вопросы энергосбережения в сельских низковольтных электрических сетях при несбалансированном электропотреблении / М. А. Якупова. – DOI 10.53083/1996-4277-2023-226-8-89-97. – Текст: непосредственный // Вестник Алтайского государственного аграрного университета. – 2023. – № 8 (226). – С. 89-97. – EDN: GRKNSY.

4. Наумов, И. В. Прогнозирование отказов сельских распределительных сетей напряжением 10 кВ (на примере филиала восточных электрических сетей ОАО «ИЭСК») / И. В. Наумов, А. В. Ланин. – Текст: непосредственный // Вестник Алтайского государственного аграрного университета. – 2011. – № 1 (75). – С. 86-90. – EDN: NBXBTR.

5. Nurulin, Y., Skvortsova, I., Konovalova, O. (2023). Innovation Management Models in the Energy Sector. *International Journal of Technology*. 14. 1759. DOI: 10.14716/ijtech.v14i8.6846.

6. Рысин, А. В. Использование математических моделей элементов воздушных линий электропередачи для диагностики оборудования / А. В. Рысин. – DOI 10.17586/0021-3454-2025-68-6-557-561. – Текст: непосредственный // Известия высших учебных заведений. Серия: Приборостроение. – 2025. – Т. 68, № 6. – С. 557-561. – EDN: CMGWYM.

7. Зиниев, Ш. З. Методологические основы обеспечения надежности в сельской электроэнергетике / Ш. З. Зиниев, В. А. Каргин, К. М. Усанов. – Текст: электронный // Аграрный научный журнал. – 2025. – № 12. – С. 164171. – URL: <https://doi.org/10.28983/asj.y2025i12pp164-171>.

8. Liao, W., Ruan, J., Xie, Y., et al. (2023). Deep learning time pattern attention mechanism-based short-term load forecasting method. *Frontiers in Energy Research*. 11. DOI: 10.3389/fenrg.2023.1227979.

9. Lin, G., Zhang, H., Chen, L., Chen, X. (2025). Deep Learning Based Fault Detection and Diagnosis Method for Power Systems. *Applied Mathematics and Nonlinear Sciences*. 10. DOI: 10.2478/amns-2025-0200.

10. Мисерханов, Л. Х. Повышение энергостойчивости субъекта Российской Федерации для обеспечения энергетической безопасности и экономического развития / Л. Х. Мисерханов, Т. Б. Эзирбаев, Р. А. В. Турлуев. – DOI 10.18572/1999-4788-2024-4-44-51. – Текст: непосредственный // Предпринимательское право. – 2024. – № 4. – С. 44-51.

11. Fristiana, A., Alfarozi, S., Permanasari, A., et al. (2024). A Survey on Hyperparameters Optimization of Deep Learning for Time Series Classification. *IEEE Access*. 12. 191162-191198. DOI: 10.1109/ACCESS.2024.3516198.

12. Isaeva A. S., Denisenko M. A., Kots I. N., Testing the layout of the rail condition monitoring system using LSTM recurrent neural networks, *St. Petersburg State Polytechnical University Journal. Physics and Mathematics*. 15 (3.2) (2022) 51–55. DOI: <https://doi.org/10.18721/JPM.153.209>.

13. Горшенин, А. Ю. Прогнозирование выработки электроэнергии ветроэлектростанцией с применением рекуррентной нейронной сети / А. Ю. Горшенин, Л. А. Денисова. – DOI 10.24412/2071-6168-2023-4-39-45. – Текст: непосредственный // Известия Тульского государственного университета. Серия: Технические науки. – 2023. – № 4. – С. 39-45. – EDN: ZDOIGJ.

14. Каширина, И. Л. Исследование и сравнительный анализ методов оптимизации, используемых при обучении нейронных сетей / И. Л. Каширина, М. В. Демченко. – Текст: непосредственный // Вестник Воронежского государственного университета. Серия: Системный анализ и информационные технологии. – 2018. – № 4. – С. 123-132. – EDN: YTRTOP.

References

1. Korolev D.S. Obzor sostoyaniya i perspektivnykh napravleniy razvitiya selskikh elektricheskikh setey 0,4 KV // *Agrotehnika i energoobespechenie*. 2025. No. 1 (46). S. 47-58.

2. Masenko A.V., Zhestkov V.V. Innovatsionnaya struktura selskoy elektricheskoy seti s ponizhennym urovnem poter // *Uralskiy nauchnyy vestnik*. 2023. T. 1. No. 3. S. 67-70.

3. Yakupova M.A. Voprosy energosberezheniya v selskikh nizkovoltnykh elektricheskikh setyakh pri nesbalansirovannom elektropotreblenii // *Vestnik Altayskogo gosudarstvennogo agrarnogo universiteta*. 2023. No. 8 (226). S. 89-97. DOI: 10.53083/1996-4277-2023-226-8-89-97.

4. Naumov I.V., Lanin A.V. Prognozirovanie otkazov selskikh raspredelitelnykh setey napryazheniem 10 KV (na primere filiala Vostochnykh elektricheskikh setey ОАО "IESK") // *Vestnik Altayskogo gosudarstvennogo agrarnogo universiteta*. 2011. No. 1 (75). S. 86-90.

5. Nurulin, Y., Skvortsova, I., Konovalova, O. (2023). Innovation Management Models in the Energy Sector. *International Journal of Technology*. 14. 1759. DOI: 10.14716/ijtech.v14i8.6846.

6. Rysin A.V. Ispolzovanie matematicheskikh modeley elementov vozdushnykh liniy elektropredachi dlya diagnostiki oborudovaniya // Izvestiya vysshikh uchebnykh zavedeniy. Priborostroenie. 2025. T. 68. No. 6. S. 557-561. DOI: 10.17586/0021-3454-2025-68-6-557-561.

7. Ziniev Sh.Z., Kargin V.A., Usanov K.M. Metodologicheskie osnovy obespecheniya nadezhnosti v selskoy elektroenergetike // Agrarnyy nauchnyy zhurnal. 2025. No. 12. S. 164–171. <https://doi.org/10.28983/asj.y2025i12pp164-171>.

8. Liao, W., Ruan, J., Xie, Y., et al. (2023). Deep learning time pattern attention mechanism-based short-term load forecasting method. *Frontiers in Energy Research*. 11. DOI: 10.3389/fenrg.2023.1227979.

9. Lin, G., Zhang, H., Chen, L., Chen, X. (2025). Deep Learning Based Fault Detection and Diagnosis Method for Power Systems. *Applied Mathematics and Nonlinear Sciences*. 10. DOI: 10.2478/amns-2025-0200.

10. Miserkhanov, L. Kh., Ezirbaev T. B., Turlyev R. A. V. Povyshenie energoustoychivosti subekta Rossiyskoy Federatsii dlya obespecheniya energeticheskoy bezopasnosti i ekonomicheskogo

razvitiya // Predprinimatelskoe pravo. 2024. No. 4. S. 44-51. DOI 10.18572/1999-4788-2024-4-44-51.

11. Fristiana, A., Alfarozi, S., Permanasari, A., et al. (2024). A Survey on Hyperparameters Optimization of Deep Learning for Time Series Classification. *IEEE Access*. 12. 191162-191198. DOI: 10.1109/ACCESS.2024.3516198.

12. Isaeva A. S., Denisenko M. A., Kots I. N., Testing the layout of the rail condition monitoring system using LSTM recurrent neural networks, *St. Petersburg State Polytechnical University Journal. Physics and Mathematics*. 15 (3.2) (2022) 51–55. DOI: <https://doi.org/10.18721/JPM.153.209>.

13. Gorshenin A.Yu., Denisova L.A. Prognozirovaniye vyrabotki elektroenergii vetroelektrostantsiy s primeneniem rekurrentnoy neyronnoy seti // Izvestiya Tul'skogo gosudarstvennogo universiteta. Tekhnicheskie nauki. 2023. No. 4. S. 39-45. DOI: 10.24412/2071-6168-2023-4-39-45.

14. Kashirina I.L., Demchenko M.V. Issledovanie i sravnitelnyy analiz metodov optimizatsii, ispolzuemykh pri obuchenii neyronnykh setey // Vestnik Voronezhskogo gosudarstvennogo universiteta. Seriya: Sistemnyy analiz i informatsionnye tekhnologii. 2018. No. 4. S. 123-132.



УДК 631.371:621.31

DOI: 10.53083/1996-4277-2026-256-2-85-92

О.Г. Бельчикова, А.А. Болтенков,
М.В. Селивёрстов, В.П. Шерышев
O.G. Belchikova, A.A. Boltenkov,
M.V. Seliverstov, V.P. Sheryshev

ОПРЕДЕЛЕНИЕ ВРЕМЕНИ ЗАВЕРШЕНИЯ СТАДИИ ТЕРМИЧЕСКОЙ ПОДГОТОВКИ ВОССТАНАВЛИВАЕМОГО ЭЛЕКТРОКОНТАКТНЫМ НАГРЕВОМ ДИСКА СОШНИКА

DETERMINATION OF COMPLETION TIME OF THERMAL PREPARATION STAGE OF A FURROW OPENER DISC BEING RECONDITIONED BY ELECTROCONTACT HEATING

Ключевые слова: восстановление, диск сошника, электроконтактный нагрев, адиабатический режим, максимально допустимая температура, стадия термической подготовки, время завершения, стержневая модель, расчётная формула.

Keywords: reconditioning, furrow opener disc, electrocontact heating, adiabatic mode, maximum permissible temperature, thermal preparation stage, completion time, rod model, calculation formula.