

ISSN 1995-2732 (Print), 2412-9003 (Online)
УДК 658.562
DOI: 10.18503/1995-2732-2023-21-3-155-169



МОДЕЛЬ ПРЕДИКТИВНОГО ОБСЛУЖИВАНИЯ ДЛЯ УПРАВЛЕНИЯ КАЧЕСТВОМ СЕТЕЙ СВЕТОДИОДНОГО ОСВЕЩЕНИЯ

Кузьменко В.П., Солёный С.В.

Санкт-Петербургский государственный университет аэрокосмического приборостроения,
Санкт-Петербург, Россия

Аннотация. Постановка задачи (актуальность работы). Внедрение новых технологий на базе светодиодов в сетях освещения приводит к появлению новых проблем в обеспечении и контроле качества электрической энергии и оценки надежности сетей освещения. Нелинейная природа данных осветительных приборов и сложность технического обслуживания создают значительные препятствия в получении реальной выгоды от экономии электрической энергии и затрудняют расчет реальной экономии средств. Для решения описанных проблем возникает необходимость усовершенствования процесса контроля качества и развития стратегий предиктивного обслуживания как способа повышения эффективности управления качеством сетей освещения. **Цель работы.** Целью исследований является анализ возможности и целесообразности применения стратегий предиктивного обслуживания в сетях светодиодного освещения. **Используемые методы.** В работе используются комплексный исследовательский подход, включающий анализ соответствующей литературы и конкретных практик использования предиктивного подхода в электрических сетях, методы предиктивного моделирования, аналитики и структурного анализа. **Новизна.** В работе предложена стратегия использования методов прогнозируемого обслуживания на примере предиктивной математической модели с элементами машинного обучения с учетом контекста контроля основных параметров сетей освещения. **Результат.** Представлена стратегия прогнозируемого обслуживания на примере предиктивной математической модели, разработаны рекомендации для практического применения предлагаемой стратегии прогнозируемого обслуживания в сетях освещения для прогнозирования неисправностей, оптимизации графиков технического обслуживания и интеграции процесса управления качеством в порядок эксплуатации. Результаты показывают возможность и целесообразность внедрения стратегии предиктивного обслуживания для повышения эффективности процессов контроля качества, надежности и экономии затрат в сетях светодиодного освещения. **Практическая значимость.** Результаты исследования имеют важное практическое значение для специалистов светотехнической отрасли в области управления качеством сетей освещения. Применяя разработанные модели и стратегию, организации могут оптимизировать ресурсы технического обслуживания, сократить время простоя и обеспечить повышение качества систем светодиодного освещения.

Ключевые слова: предиктивное обслуживание, сети освещения, светодиодные светильники, управление качеством, качество электроэнергии в сетях освещения, энергоэффективность сетей освещения

© Кузьменко В.П., Солёный С.В., 2023

Для цитирования

Кузьменко В.П., Солёный С.В. Модель предиктивного обслуживания для управления качеством сетей светодиодного освещения // Вестник Магнитогорского государственного технического университета им. Г.И. Носова. 2023. Т. 21. №3. С. 155-169. <https://doi.org/10.18503/1995-2732-2023-21-3-155-169>



Контент доступен под лицензией Creative Commons Attribution 4.0 License.
The content is available under Creative Commons Attribution 4.0 License.

A PREDICTIVE MAINTENANCE MODEL FOR QUALITY MANAGEMENT OF LED LIGHTING NETWORKS

Kuzmenko V.P., Solenyi S.V.

Saint Petersburg State University of Aerospace Instrumentation, Saint Petersburg, Russia

Abstract. Problem Statement (Relevance). The introduction of new LED-based technologies in lighting networks leads to new problems in ensuring and controlling the quality of electrical energy and assessing reliability of lighting networks. The non-linear nature of these lighting devices and complexity of maintenance create significant obstacles to obtaining real benefits of electricity savings and make it difficult to calculate the real cost savings. To address the problems described, there is a need to improve the quality control process and develop predictive maintenance strategies as a way to improve efficiency of lighting network quality management. **Objectives.** The research is aimed at studying and analyzing the possibility and feasibility of using predictive maintenance strategies in LED lighting networks. **Methods Applied.** The authors use a comprehensive research approach that includes an analysis of relevant literature and specific practices for using the predictive approach in electric grids, methods of predictive modeling, analytics, and a structural analysis. **Originality.** The paper proposes a strategy for using predictive maintenance methods, showing the example of a predictive mathematical model with elements of machine learning, factoring into the control context of the main parameters of lighting networks. **Result.** The paper presents the predictive maintenance strategy, using the example of a predictive mathematical model, recommendations developed for a practical application of the proposed predictive maintenance strategy in lighting networks for fault prediction, optimization of maintenance schedules and integration of a quality management process into an operation procedure. The results show the possibility and feasibility of implementing a predictive maintenance strategy to improve efficiency of quality control processes, reliability and cost savings in LED lighting networks. **Practical Relevance.** The results of the study have important practical relevance for lighting industry professionals in the field of lighting network quality management. By applying the developed models and strategy, organizations can optimize maintenance resources, reduce downtime periods and ensure the improved quality of LED lighting systems.

Keywords: predictive maintenance, lighting networks, LED lighting fixtures, quality management, quality of electricity in lighting networks, energy efficiency of lighting networks

For citation

Kuzmenko V.P., Solenyi S.V. A Predictive Maintenance Model for Quality Management of LED Lighting Networks. *Vestnik Magnitogorskogo Gosudarstvennogo Tekhnicheskogo Universiteta im. G.I. Nosova* [Vestnik of Nosov Magnitogorsk State Technical University]. 2023, vol. 21, no. 3, pp. 155-169. <https://doi.org/10.18503/1995-2732-2023-21-3-155-169>

Введение

Широкое распространение технологии светодиодного освещения произвело революцию в индустрии освещения, предлагая более энергоэффективные и более экологичные решения. Однако обеспечение качества и надежности сетей освещения сопряжено со значительными трудностями. Незапланированные отказы, сложность технического обслуживания и необходимость постоянного контроля требуют разработки эффективных стратегий управления качеством сетей освещения. В этой связи прогнозируемое техническое обслуживание становится перспективным подходом для решения этих проблем, оптимизации методов технического обслуживания и повышения общей производительности сетей светодиодного освещения.

Предиктивное техническое обслуживание – это упреждающая стратегия технического обслуживания, направленная на прогнозирование отказов оборудования или снижения производительности до того, как они произойдут. Это предполагает использование методов анализа данных, таких как статистическое моделирование, машинное обучение и мониторинг состояния, для выявления ранних признаков потенциальных проблем и обеспечения возможности своевременного вмешательства.

Предиктивное обслуживание предполагает использование передовых методов анализа данных, алгоритмов машинного обучения и мониторинга в режиме реального времени для прогнозирования отказов оборудования и соответствующего планирования работ по обслуживанию. Благодаря использованию существующих эксплуата-

ционных данных, сведений о производительности, учету факторов окружающей среды и применению методов цифрового моделирования, предиктивное обслуживание позволяет выявить закономерности деградации и потенциальные риски отказа светодиодных светильников. В результате своевременных и целенаправленных действий организации могут оптимизировать ресурсы, сократить временные издержки и обеспечить бесперебойное и высококачественное освещение.

Чтобы дать рекомендации по внедрению эффективных стратегий предиктивного обслуживания, а также для полноценного анализа и исследования возможности применения его стратегий в качестве нового подхода к управлению качеством в сетях светодиодного освещения, необходимо провести обзор основных методологий, инструментов и преимуществ предиктивного обслуживания и сделать практические выводы и рекомендации по интеграции практики предиктивного обслуживания в управлении сетью освещения и произвести обзор и анализ проблем управления качеством сетей светодиодного освещения с учетом принципов и методологии предиктивного обслуживания.

Качество и надежность сетей освещения являются важными факторами для обеспечения оптимальных характеристик освещения, энергоэффективности и удовлетворенности потребителей. Однако динамичный характер сетей освещения, меняющиеся условия окружающей среды и потенциальная деградация основных узлов, элементов и характеристик оборудования создают проблемы для поддержания постоянного качества и минимизации незапланированных отказов.

Традиционная практика технического обслуживания часто приводит к увеличению времени простоя, повышению эксплуатационных расходов и ухудшению качества освещения. Поэтому существует необходимость в проактивной и эффективной стратегии управления качеством, которая позволяет предвидеть потенциальные отказы, оптимизировать деятельность по техническому обслуживанию и обеспечить непрерывное высококачественное обслуживание освещения.

Решение проблем, связанных с управлением качеством сетей светодиодного освещения с помощью стратегий предиктивного технического обслуживания, имеет решающее значение для организаций, стремящихся оптимизировать ресурсы технического обслуживания, снизить затраты и повысить удовлетворенность клиентов. Используя

данную практику, заинтересованные стороны могут улучшить планирование технического обслуживания, оптимизировать потребление энергии, обеспечить стабильную работу сетей освещения. Более того, предиктивное техническое обслуживание способствует достижению целей устойчивого развития за счет минимизации отходов, оптимизации использования ресурсов и снижения воздействия на окружающую среду, связанного с возможными ненужными или избыточными мерами по техническому обслуживанию.

Анализ существующих актуальных исследований в данной области дает представление о применении стратегий прогностического обслуживания, моделей, основанных на данных, и методов машинного обучения в контексте сетей светодиодного освещения [1]. Они демонстрируют преимущества проактивного обслуживания, включая снижение затрат, повышение энергоэффективности и надежности. Ссылаясь на эти исследования, можно эффективно отразить ключевые выводы и достижения в области предиктивного обслуживания для сетей светодиодного освещения.

В исследованиях [2] предлагается комплексная стратегия предиктивного обслуживания систем с использованием моделей, основанных на собранных данных. Их подход включает сбор данных датчиков, использование алгоритмов машинного обучения и осуществление мониторинга в режиме реального времени для прогнозирования потенциальных отказов и оптимизации графиков технического обслуживания для оборудования.

В исследованиях [3] предлагается подход к применению иерархических нейросетевых методов для контроля качества изделий. Подход больше направлен на технологические процессы, однако может быть переориентирован и на обеспечение контроля и управления качеством сетей освещения.

Анализ существующих актуальных исследований показывает, что представленные источники дают ценную информацию о применении стратегий прогнозирования технического обслуживания, моделей, управляемых данными, и методов машинного обучения в различных областях, включая системы светодиодного освещения [4, 5]. Они подчеркивают преимущества прогнозируемого обслуживания, такие как снижение затрат, повышение энергоэффективности и надежности. Однако важно отметить, что, хотя эти источники вносят значительный вклад в область профилак-

тического обслуживания, они не охватывают в полной мере конкретный контекст сетей освещения и светодиодных осветительных приборов.

Несмотря на многообещающие результаты исследований в области машинного обучения, применение данных методов в сфере обслуживания, мониторинга и эксплуатации инженерных технических систем все еще ограничено. Управление объектами в строительстве также не в полной мере использует эффективность данных методов, особенно в порядке текущей эксплуатации и обслуживания. Отопление, вентиляция и кондиционирование воздуха, сети освещения, слаботочные инженерные системы связи и оповещения являются основой операций по управлению и техническому обслуживанию объектов, и случайные неисправности могут привести к существенным денежным потерям [5, 6].

В контексте управления качеством сетей освещения со светодиодными осветительными приборами (СОП) необходимы дальнейшие исследования для изучения уникальных проблем и возможностей, связанных с управлением ими. Будущие исследования должны быть сосредоточены на интеграции методов прогнозного технического обслуживания, адаптированных к конкретным требованиям сетей освещения, охватывающих такие параметры, как качество электроэнергии, характер износа светильников и оптимизацию энергоэффективности. Это связано со сложностью моделирования нелинейных нагрузок и искажений в электрической сети, генерируемых данными изделиями, а также оценки надежности и реального срока службы изделий [6].

Материалы и методы исследования

Целью предиктивного обслуживания является оптимизация работ, сокращение времени простоя, повышение общей надежности и производительности оборудования. Применение таких стратегий позволяет оценить вероятность выхода из строя изделия. В этом контексте техническое обслуживание можно планировать заранее, исключая незапланированные простои и максимально увеличивая срок службы оборудования.

Для реализации математической базы предиктивных моделей в случае со светодиодными осветительными приборами рекомендуется применять стандарты LM-80 и TM-21, которые используются для получения экстраполяции данных о световом потоке и могут вводиться в алгоритм, разработанный на основе модели экспоненциальной деградации [7, 8].

В целом предиктивное обслуживание основывается на анализе данных, моделировании и непрерывном мониторинге оборудования, обеспечивая значительные преимущества с точки зрения улучшения планирования технического обслуживания, повышения надежности оборудования и экономии средств.

Процесс предиктивного обслуживания обычно включает в себя этапы по сбору и анализу данных. Соответствующие данные собираются из различных источников, включая датчики, исторические записи технического обслуживания и мониторинг. Эти данные дают представление о поведении оборудования, тенденциях производительности и операционной среде. Далее производится анализ собранных данных, к которым применяются аналитические методы для выявления закономерностей, аномалий или индикаторов потенциальных сбоев.

Статистические модели и алгоритмы машинного обучения используются для анализа данных и разработки прогностических моделей. Затем производится процесс прогнозирующего моделирования и разрабатываются модели с использованием проанализированных данных для прогнозирования производительности оборудования, обнаружения ранних признаков износа или прогнозирования того, когда потребуются мероприятия по техническому обслуживанию.

Для качественного и полного применения метода предиктивного обслуживания необходимо также проведение мониторинга оборудования в режиме реального времени или хотя бы периодического мониторинга для непрерывного сбора данных и сравнения их с прогнозами, сделанными с помощью прогностических моделей. Это позволяет выявлять отклонения, аномалии или признаки раннего предупреждения, которые могут потребовать вмешательства в техническое обслуживание, так как сложность построения моделей отказов или некорректной работы устройств с нелинейными характеристиками крайне сложный процесс. Так, например, сложность моделирования параметров СОП обусловлена их нелинейным поведением в качестве нагрузки в электрической сети [9-11].

Представим математическую модель для применения стратегий прогнозного технического обслуживания в контексте сетей светодиодного освещения.

Первым этапом является сбор данных.

Пусть X – матрица, представляющая собран-

ные данные датчиков, исторические записи технического обслуживания и данные об окружающей среде, где каждая строка представляет конкретный экземпляр, а каждый столбец представляет определенную функцию или параметр, а Y – вектор, представляющий требование к техническому обслуживанию или целевую переменную, указывающую время до отказа или порог снижения производительности.

Для организации процесса предварительной обработки данных необходимо выполнить нормализацию матрицы данных X , чтобы обеспечить сопоставимые масштабы для различных параметров. Пусть X_{norm} обозначает нормализованную матрицу данных. Тогда при использовании алгоритмов машинного обучения, например регрессионной модели, для разработки прогностической модели можно представить функцию $f(X_{norm})$ как прогнозирующую модель, где f – функция, которая сопоставляет входную матрицу, нормализованную матрицу данных X_{norm} с прогнозируемым требованием к техническому обслуживанию Y_{hat} .

Вторым этапом является проверка на целостность данных.

Необходимо проверить, нет ли пропущенных значений в собранных данных. В случае, если присутствуют пропущенные значения, возможно вычисление среднего значения, чтобы заполнить пропущенные значения. В таком случае пусть X_{filled} обозначает матрицу с пропущенными значениями, заполненными путем вычисления среднего значения. Следует также обращать внимание на отклонения в данных, чтобы обеспечить их качество и достоверность. Таким образом можно ввести z -балл для каждого признака в X_{filled} путем вычитания среднего значения и деления на стандартное отклонение.

Пусть Z обозначает матрицу z -баллов. Также необходимо установить пороговое значение для определения выбросов. Тогда любая точка данных в Z с z -баллом, превышающим пороговое значение, должна будет считаться выбросом.

Далее необходимо определить новую матрицу $X_{outlier_removed}$, удалив строки, соответствующие выбросам, из X_{filled} .

Третьим этапом является выбор целевых функций.

Необходимо произвести выбор соответствующих функций из $X_{outlier_removed}$, которые с наибольшей вероятностью будут способствовать выполнению задачи прогнозного обслуживания.

Пусть $X_{selected}$ обозначает матрицу, содержащую выбранные объекты. Применяя методы проектирования объектов для создания новых, которые отражают значимые закономерности можно, например, рассчитать коэффициент энергоэффективности, разделив светоотдачу на потребляемую мощность, после чего добавить эту новую функцию в $X_{selected}$.

Далее необходимо выполнить обучение прогностической модели, сопоставив ее с нормализованной матрицей данных X_{norm} и целевой переменной Y . Это включает в себя поиск оптимальных параметров модели, которые минимизируют ошибку прогнозирования. Также необходимо нормализовать матрицу объектов $X_{selected}$, чтобы обеспечить сопоставимые масштабы для различных объектов. Целесообразно применить минимальное-максимальное масштабирование для изменения значений каждого объекта в $X_{selected}$ в пределах predetermined диапазона, такого как $(0, 1)$.

Теперь для каждого объекта в $X_{selected}$ необходимо вычислить минимальное значение (\min) и диапазон ($\max - \min$). Вычитая минимальное значение из значения каждого признака и разделив на диапазон, можно получить нормализованные значения.

Разделение данных.

Разделив предварительно обработанные данные на обучающие, валидационные и тестовые наборы данных, необходимо выделить определенный процент данных (например, 70%) для обучающего набора, меньшую часть (например, 15%) для проверочного набора и оставшуюся часть (15%) для тестового набора.

Пусть X_{train} , X_{val} и X_{test} представляют соответствующие матрицы данных.

Чтобы оценить эффективность прогностической модели, следует использовать соответствующие оценочные показатели, такие как среднеквадратичная ошибка, или коэффициент детерминации (R -квадрат), и оценить способность модели точно прогнозировать требования к техническому обслуживанию на основе заданных входных параметров.

При мониторинге в режиме реального времени необходимо собирать данные датчиков, подключенных к сети с СОП, и предварительно обрабатывать их таким же образом, как было описано на предыдущих шагах. Для этого обозначим матрицу объектов реального времени как $X_{realtime}$ и применим прогнозирующую модель $f(X_{norm})$ к

матрице характеристик реального времени $X_{realtime}$, чтобы получить прогнозируемую потребность в техническом обслуживании $Y_{hat_realtime}$.

Сравнивая прогнозируемую потребность в техническом обслуживании $Y_{hat_realtime}$ с предопределенными пороговыми значениями технического обслуживания, возможно организовать генерацию предупреждений или нотификации, когда $Y_{hat_realtime}$ превышает эти пороговые значения, указывая на необходимость упреждающих действий по техническому обслуживанию.

Также для адекватности функционирования модели необходимо включать в данные о сети мероприятия по техническому обслуживанию, периодически обновляя и переобучая прогнозную модель, используя обновленный набор данных, необходимых для фиксации новых закономерностей и повышения точности модели.

Описанные выше шаги представляют собой пример стратегии прогнозируемого технического обслуживания для сетей светодиодного освещения. Математическое описание включает в себя обработку недостающих данных путем вычисления среднего значения, обнаружение отклонений с использованием z -оценок, выбор соответствующих функций, разработку новых функций, нормализацию данных с использованием минимально-максимального масштабирования и разделение данных на обучающие, валидационные и тестовые наборы. Выполняя эти математические операции, появляется возможность подготовить данные для дальнейшего анализа и разработки моделей, что способствует эффективному профилактическому обслуживанию сетей светодиодного освещения.

Полученные результаты и их обсуждение

Рассмотрим практический пример использования модели прогнозируемого обслуживания сети светодиодного освещения.

Шаг 1: сбор данных.

Для согласования модели с реальными данными были собраны данные об измерениях активной мощности, напряжения сети, температуры светильника и светового потока в сети освещения с 21 светодиодными осветительными приборами моделями аналога ЛПО номинальной мощностью 36 Вт и номинальным световым потоком 1000 Лм.

Собранные данные необходимо представить в виде матрицы X , где каждая строка соответствует

определенному СОП, а каждый столбец представляет определенную функцию или параметр.

Примем, что X – это матрица размером 21×4 , где столбцы представляют потребляемую активную мощность (в ваттах), напряжение (в вольтах), температуру светодиода (в градусах Цельсия) и светоотдачу (в люменах) соответственно.

Данные матрицы X собраны в табл. 1.

Таблица 1. Матрица X собранных данных для практической реализации обучающей модели

Table 1. Matrix X of collected data for practical implementation of the training model

Потребляемая мощность, Вт	Напряжение сети, В	Температура светодиода, °С	Светоотдача, Лм
40	220	42	1020
44	215	46	1050
44	225	47	1050
42	210	46	1020
40	210	49	1020
40	212	43	1010
45	230	49	1070
40	211	43	1020
48	230	53	1100
40	220	43	1020
40	221	42	1020
40	215	42	1010
44	225	46	1060
45	226	49	1070
46	226	51	1080
40	215	43	1030
45	224	50	1090
40	215	42	1050
48	230	53	1110
40	215	40	1010
40	217	42	1020

Шаг 2: недостающая обработка данных.

Примем, что в собранных данных нет пропущенных значений. Таким образом, никаких дополнительных вычислений или манипуляций не требуется.

Шаг 3: обнаружение выбросов.

Необходимо вычислить z -балл для каждого признака в X , чтобы выявить все возможные выбросы.

Предположим, что пороговое значение 3 используется для обнаружения выбросов. Любая

точка данных в Z с z -баллом, превышающим 3, считается выбросом.

Тогда при X матрице с размером n строк и m столбцов

$$X = [x_{ij}], \quad (1)$$

где x_{ij} представляет собой элемент i -й строки и j -го столбца матрицы X .

Далее вычисляются среднее значение μ и стандартное отклонение σ для каждого признака.

Таким образом, z -балл для каждого элемента в матрице X вычисляется следующим образом:

$$z_{ij} = \frac{X_{ij} - \mu_j}{\sigma_j}, \quad (2)$$

$$\mu_j = \frac{1}{n} \sum_{i=1}^n X_{ij}, \quad (3)$$

$$\sigma_j = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_{ij} - \mu_j)^2}, \quad (4)$$

$$s_{ij} = \begin{cases} 1, & \text{если } |Z_{ij}| > 0 \\ 0, & \text{если } |Z_{ij}| \leq 0 \end{cases}. \quad (5)$$

где z_{ij} – z -балл для элемента в i -й строке и j -м столбце X ; μ_j – среднее значение для j -го столбца; σ_j – стандартное отклонение для j -го столбца.

Далее необходима установка порогового значения. В данном случае θ – это предопределенное пороговое значение. Выбросы выявляются путем сравнения абсолютных z -баллов с пороговым значением θ .

Далее создается двоичная матрица выбросов, где выбросы $s_{ij} = 1$, если абсолютный z -балл $|Z_{ij}|$ больше порогового значения, и выброс $s_{ij} = 0$ – в противном случае.

Результирующая матрица выбросов будет иметь те же размеры, что и матрица X , и ее элементы будут указывать, является ли каждый соответствующий элемент в матрице X выбросом или нет.

Шаг 4: выбор и введение новой функции.

Примем, что были выбраны параметры энергопотребления и температуры, соответствующие представленной модели прогнозируемого технического обслуживания.

Создадим новую функцию, рассчитывая отношение потребляемой мощности к температуре:

$$R_{P/T} = T \cdot P, \quad (6)$$

где $R_{P/T}$ – создаваемая характеристика отношения потребляемой мощности к температуре; T – параметр температуры светодиода из матрицы данных X ; P – параметр энергопотребления из матрицы данных X .

Данное соотношение представляет собой зависимость между потребляемой мощностью и температурой для каждой точки (строки) в матрице данных X .

Шаг 5 и 6: нормализация, разделение данных.

Создается матрица X_{selected} , содержащая выбранные объекты (в данном случае первый и третий столбцы матрицы X):

$$X_{\text{selected}} = \begin{bmatrix} 40 & 42 \\ 44 & 46 \\ 44 & 47 \\ 42 & 46 \\ 40 & 49 \\ 40 & 43 \\ 45 & 49 \\ 40 & 43 \\ 48 & 53 \\ 40 & 43 \\ 40 & 42 \\ 40 & 42 \\ 44 & 46 \\ 45 & 49 \\ 46 & 51 \\ 40 & 43 \\ 45 & 50 \\ 40 & 42 \\ 48 & 53 \\ 40 & 40 \\ 40 & 42 \end{bmatrix}.$$

Далее вычисляется отношение мощности к температуре путем деления первого столбца на второй столбец X_{selected}

Результатом будет новая матрица X_{selected}^* с вычисленным отношением мощности к температуре, добавленным в виде нового столбца:

$$X_{selected*} = \begin{bmatrix} 40 & 42 & 40 / 42 \\ 44 & 46 & 44 / 46 \\ 44 & 47 & 44 / 47 \\ 42 & 46 & 42 / 46 \\ 40 & 49 & 40 / 49 \\ 40 & 43 & 40 / 43 \\ 45 & 49 & 45 / 49 \\ 40 & 43 & 40 / 43 \\ 48 & 53 & 48 / 53 \\ 40 & 43 & 40 / 43 \\ 40 & 42 & 40 / 42 \\ 40 & 42 & 40 / 42 \\ 44 & 46 & 44 / 46 \\ 45 & 49 & 45 / 49 \\ 46 & 51 & 46 / 51 \\ 40 & 43 & 40 / 43 \\ 45 & 50 & 43 / 50 \\ 40 & 42 & 40 / 42 \\ 48 & 53 & 48 / 53 \\ 40 & 40 & 40 / 40 \\ 40 & 42 & 40 / 42 \end{bmatrix}.$$

Далее необходимо нормализовать выбранную матрицу объектов $X_{selected*}$, используя минимальное-максимальное масштабирование. Для каждого объекта вычисляется минимальное значение (min) и диапазон (max - min).

Далее минимальное значение вычитается из значения каждого признака и делится на диапазон, чтобы получить нормализованные значения. Создается матрица нормализованных объектов $X_{normalized}$. Общее количество данных в нормализованной матрице данных $X_{normalized}$ обозначается через n .

Разделяются предварительно обработанные данные на обучающие, валидационные и тестовые наборы данных. Примем, что 70% данных выделено для обучения, 15% – для валидации и 15% – для тестирования. Количество данных, выделенных для обучающего набора, рассчитывается как 70% от общего количества данных и обозначается как $n_{train} = [0,7 \times n]$.

Количество данных, выделенных для набора проверки, рассчитывается как 15% от общего

количества данных и обозначается как $n_{val} = [0,15 \times n]$.

Далее обучающие, валидационные и тестовые матрицы данных обозначаются как X_{train} , X_{val} и X_{test} соответственно.

После того как были определены обучающие, валидационные и тестовые матрицы данных, для обучения модели производится случайная перестановка от 1 до n . Для этого вводится результирующий массив случайных перестановок idx .

Математически это можно представить в виде $idx = \text{random} \{1, 2, \dots, n\}$, в таком случае массив idx будет хранить случайно переставленные индексы.

Если Y – это вектор, представляющий целевую переменную (в данном случае светоотдача), то необходимо извлечь значения светового потока из четвертого столбца исходной матрицы X и сохранить их в векторе Y .

Тогда для обучающего набора

$$X_{train} = X_{normalized} [idx (1 : n_{train})].$$

Для валидационного набора

$$X_{val} = X_{normalized} [idx (n_{train} + (1 : n_{train}) + n_{val})].$$

Для тестового набора

$$X_{test} = X_{normalized} [idx (n_{train} + n_{val} + 1)].$$

Аналогично создаются целевые переменные для обучающих, валидационных и тестовых наборов Y_{train} , Y_{val} , Y_{test} .

Далее должны выполняться подгонка и обучение модели.

Шаг 7: подгонка модели.

Так как наиболее распространенной и простой является модель линейной регрессии, то рассмотрим, как в данном случае будет происходить обучение с использованием отобранного обучающего набора данных из матрицы X с использованием модели линейной регрессии. Выбор модели зависит от конкретных характеристик данных, сложности взаимосвязей между переменными и требований к производительности. Выбор наилучшей модели для данной задачи прогнозного обслуживания зависит от таких факторов, как размер набора данных, характер взаимосвязей в данных, доступные вычислительные ресурсы и требования к интерпретируемости. На практике часто бывает полезно попробовать несколько моделей и сравнить их характеристики, используя подходящие оценочные показатели, чтобы определить наиболее эффективную для конкретного применения.

Целью этой модели является прогнозирование светового потока на основе других переменных. В алгебраических терминах процесс подгонки модели линейной регрессии включает в себя поиск наиболее подходящей линейной функции, которая связывает входные характеристики (X_{train}) с целевой переменной Y_{train} и будет иметь вид

$$Y_{train} = \beta_0 + \beta_1 \cdot X_{train,1} + \beta_2 \cdot X_{train,2} + \dots + \beta_p \cdot X_{train,p}, \quad (7)$$

где Y_{train} – вектор, представляющий целевую переменную для обучающего набора; $X_{train,1}$, $X_{train,2}$, ..., $X_{train,p}$ – индивидуальные характеристики в обучающем наборе; β_0 , β_1 , β_2 , ..., β_p – коэффициенты, которые необходимо оценить.

Цель подгонки модели состоит в том, чтобы найти значения β_0 , β_1 , β_2 , ..., β_p , которые минимизируют ошибку прогнозирования (обычно используется метод наименьших квадратов).

Как только модель настроена, ее можно использовать для составления прогнозов на основе новых данных.

Шаг 8: тестирование модели и оценка производительности.

Прогноз на обучающем наборе: $Y_{train_pred} = f(X_{train})$, где Y_{train_pred} – вектор, представляющий прогнозируемую целевую переменную в наборе проверки.

Прогноз по валидационному набору: $Y_{val_pred} = f(X_{val})$, где Y_{val_pred} – вектор, представляющий прогнозируемую целевую переменную в наборе проверки.

Прогноз по набору тестирования: $Y_{test_pred} = f(X_{test})$, где Y_{test_pred} – вектор, представляющий прогнозируемую целевую переменную в тестовом наборе, здесь функция f представляет модель линейной регрессии, полученную на шаге 7, благодаря ей сопоставляются входные характеристики с прогнозируемой целевой переменной, используя оцененные коэффициенты.

Выражения $Y_{train_pred} = f(X_{train})$, $Y_{val_pred} = f(X_{val})$ и $Y_{test_pred} = f(X_{test})$ представляют прогнозируемые значения целевой переменной в наборах обучения, валидации и тестирования соответственно.

Далее происходит оценка модели.

Среднеквадратичная ошибка ($RMSE$) для обучающего набора

$$RMSE_{train} = \sqrt{\frac{1}{n_{train}} \sum_{i=1}^{n_{train}} (Y_{train}[i] - Y_{train_pred}[i])^2}. \quad (8)$$

Среднеквадратичная ошибка ($RMSE$) для валидационного и тестирующего наборов определяется аналогично.

Эти ошибки представляют собой среднюю величину различий между фактическими и прогнозируемыми значениями целевых переменных в каждом наборе.

R -квадрат (коэффициент детерминации) для обучающего набора вычисляется по формуле

$$R^2_{train} = 1 - \frac{\sum_{i=1}^{n_{train}} (Y_{train}[i] - Y_{train_pred}[i])^2}{\sum_{i=1}^{n_{train}} (Y_{train}[i] - \bar{Y}_{train})^2}. \quad (9)$$

Для валидационного и тестирующего наборов вычисляется аналогично.

Для подтверждения работы стратегии на примере модели был написан код для решения примера представленной модели в среде компьютерного моделирования Matlab.

В программном обеспечении Matlab используется функция «film» для выполнения процесса подгонки модели линейной регрессии к обучающим данным X_{train} и Y_{train} . Он автоматически оценивает коэффициенты β_0 , β_1 , β_2 , ..., β_p и создает переменную LinearModel, которая представляет собой подогнанную модель.

Затем модель используется для составления прогнозов по наборам данных для обучения, валидации и тестирования.

Производительность модели оценивается с использованием среднеквадратичной ошибки ($RMSE$) и статистики в R -квадрат.

$RMSE$ дает представление о том, насколько сильно прогнозы в среднем отклоняются от фактических значений в наборе данных, в то время как R -квадрат объясняет, какую часть дисперсии в данных способна объяснить модель.

Для обучающих, валидационных и тестовых наборов данных были получены точечные графики реальных, прогнозируемых данных, а также и графики остатков (разница значений между фактическими значениями целевой переменной и прогнозируемыми значениями целевой переменной из модели).

Точечные графики отображают взаимосвязь между фактическими и прогнозируемыми значениями, в то время как остаточные графики показывают разницу между этими значениями, что помогает идентифицировать любые закономерности, которые модель, возможно, не улавливает. Следует отметить, что количество точек на графике не соответствует количеству значений матрицы X не по причине их отсутствия, а по причине совпадения значений.

Результаты оценки точности модели с использованием среднеквадратичной ошибки (*RMSE*) и статистики в *R*-квадрат представлены в табл. 2.

Таблица 2. Результаты оценки точности модели обучающей модели

Table 2. Results of estimated accuracy of the training model

Набор данных модели	<i>RMSE</i>	<i>R</i> -квадрат
Обучающий набор	7,341609	0,943203
Валидационный набор	20,507601	-0,455790
Тестирующий набор	11,135064	0,912990

Среднеквадратичная ошибка (*RMSE*) обучающего набора составляет ~ 7,34, а показатель *R*-квадрат (*R2*) ~ 0,94. Это указывает на то, что модель обладает высокой производительностью при обработке обучающих данных, поскольку меньшее значение *RMSE* означает меньшие ошибки прогнозирования, а оценка *R2*, близкая к 1, указывает на то, что модель объясняет высокую долю дисперсии в целевой переменной.

RMSE проверочного набора данных значительно больше по сравнению с обучающим набором (~20,5), а оценка *R2* отрицательна ~ (-0,46). Это говорит о том, что модель плохо обобщается на невидимые данные и, возможно, перестраивается на обучающие данные.

Переобучение происходит, когда модель слишком хорошо усваивает обучающие данные, включая их шум и выбросы, и, следовательно, плохо работает с новыми, невидимыми данными.

Тестовый набор (тестирование). На данном этапе модель показывает корректную работу, с *RMSE* (~ 11,14) и *R2* (~ 0,91), что очень похоже на результаты обучения. Однако это не согласуется с плохими результатами проверки, что может быть связано с конкретными образцами в наборе для тестирования.

Таким образом, для такого небольшого количества данных модель показывает хорошие результаты. При увеличении количества данных точность модели будет увеличиваться.

Результаты работы модели при использовании представленного кода в среде Matlab показаны на рис. 1. Данные диаграммы позволяют помочь лучше понять модель и данные. Поскольку модель прогнозирования построена по модели линейной регрессии, то точечные диаграммы фактических и прогнозируемых значений позволяют визуализировать точность модели. В идеальном случае точки должны располагаться вдоль линии под углом 45°, а графики остатков позволяют проверить предположение о постоянной дисперсии ошибок.

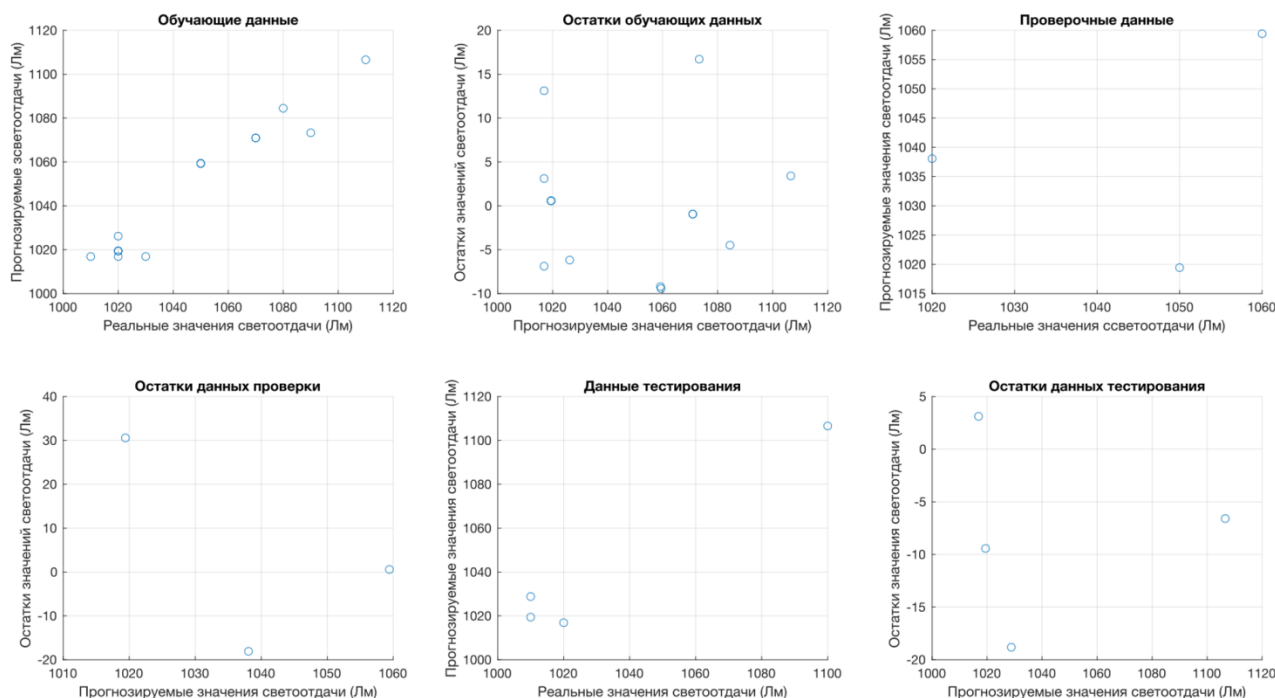


Рис. 1. Диаграммы оценки производительности модели для прогнозного обслуживания сети светодиодного освещения

Fig. 1. Model performance evaluation plots for LED lighting network predictive maintenance

Представленные на **рис. 1** диаграммы показывают сравнение фактических целевых значений из наборов данных Y_{train} , Y_{val} , Y_{test} со значениями, предсказанными моделью (Y_{train_pred} , Y_{val_pred} , Y_{test_pred}). Модель с идеальной точностью построила бы график, где все точки лежат на прямой диагональной линии, то есть вектор актуальных значений был бы равен вектору прогнозируемых значений. Отклонение от этой линии указывает на ошибки прогнозирования. Диаграммы остатков указывают на разницу значений между фактическими значениями целевой переменной и прогнозируемыми значениями целевой переменной из модели. Если значение равно нулю или близко к нулю, то на диаграмме оно не отображается. Проверочные диаграммы и диаграммы тестирования необходимы для проверки и управления моделью при внесении новых данных или изменении целевой функции прогнозирования модели. Основную информацию о предиктивной способности модели несут первые две диаграммы. Первая диаграмма показывает спрогнозированный моделью уровень светоотдачи (ось ординат) и соответствующий ему реальный уровень светоотдачи.

Основное управленческое решение в данном случае зависит от целевой функции прогнозирования и выбираемого набора данных. Рассматриваемый пример, с учетом достаточной точности, полученной в модели, позволяет принимать решения о необходимости замены осветительного прибора, при уменьшении его светоотдачи до уровня ниже требуемого (или ниже гарантийного). Основываясь на выходных параметрах модели, можно сделать несколько технических выводов. Во-первых, значение признаков функции, которые были использованы (столбец 1, столбец 2 и столбец 3 в матрице X), в данном случае являются предикторами значений светоотдачи (столбец 4). Об этом свидетельствуют высокие значения R^2 в наборе для обучения и тестирования, указывающие на то, что большая часть различий в световом потоке может быть объяснена этими особенностями. Во-вторых, несмотря на потенциальную переобучаемость, модель хорошо работает на тестовом наборе, что позволяет предположить, что она все еще может хорошо обобщаться на новые данные. Однако это требует дальнейшего изучения, учитывая низкую производительность набора для проверки. В результате возникает возможность с достаточной точностью отслеживать как изменения уровней освещенности в сети освещения, так и контролировать гарантийные обязательства поставщика и производителя осветительных приборов, что имеет высокую актуальность в протяженных се-

тях искусственного освещения, таких как уличные сети освещения дорожного полотна, городские сети освещения, железнодорожные и т.д.

Внедрение данной модели и стратегии прогнозирования в действующую сеть светодиодного освещения потребует выполнения нескольких технических шагов и развертывания дополнительных технических решений:

1. Инфраструктура сбора данных. Для непрерывного сбора данных из сети светодиодного освещения потребуется внедрить датчики и устройства сбора данных. Эти устройства должны быть способны измерять ключевые характеристики, используемые в модели, то есть первые три столбца матрицы X .

2. Хранение и управление данными. Собранные данные необходимо будет эффективно хранить и управлять ими. В зависимости от масштаба сети это может включать в себя настройку локальных серверов или использование облачных решений. Необходимо будет установить процедуры управления данными, включая очистку, обработку и регулярное резервное копирование данных.

3. Реализация модели. Сама прогностическая модель может быть реализована несколькими способами. Она может быть настроена на локальном сервере или в облаке в зависимости от масштаба и потребностей сети и эксплуатирующей организации. Модель должна быть закодирована в скрипт, который можно запускать регулярно или в режиме реального времени для получения прогнозов на основе текущих данных датчиков. Это включает в себя развертывание модели в инфраструктуре, интеграцию ее с компонентами сбора и хранения данных и настройку интерфейса для обновления модели и мониторинга.

4. Система оповещения. С моделью должна быть интегрирована система оповещения для генерации предупреждений или уведомлений о том, когда прогнозируемые требования к техническому обслуживанию превышают заранее определенные пороговые значения.

5. Планирование технического обслуживания. Прогнозная информация о техническом обслуживании, предоставляемая моделью, поможет в планировании технического обслуживания. Графики технического обслуживания могут быть оптимизированы на основе прогнозируемых требований к техническому обслуживанию, обеспечивая принятие упреждающих мер для предотвращения сбоев и простоев.

6. Непрерывное обновление и валидация модели. Со временем прогнозы модели могут становиться менее точными по мере износа эле-

ментов и изменения условий окружающей среды. Модель должна постоянно обновляться и подтверждаться новыми данными, чтобы фиксировать новые закономерности и адаптироваться к изменяющимся условиям.

7. Оценка системы. Наконец, крайне важно регулярно оценивать всю систему в целом. Это означает не только проверку точности модели, но и оценку того, эффективна ли стратегия технического обслуживания для повышения эффективности использования и улучшения качества сети освещения. Это включает в себя мониторинг ключевых показателей производительности, таких как точность прогнозов, эффективность действий по техническому обслуживанию, предпринимаемых на основе прогно-

зов, и общая надежность системы.

Следуя этим техническим шагам и интегрируя стратегию прогнозируемого технического обслуживания в сеть светодиодного освещения, организация может добиться повышения эффективности, сокращения времени простоя и экономии средств, обеспечивая при этом долговечность и оптимальную производительность инфраструктуры освещения. Структурная схема элементов системы, необходимых для выполнения описанных шагов и внедрения описанной модели, представлена на **рис. 2**.

В **табл. 3** представлен список конкретных типов устройств, которые могут понадобиться для реализации данной стратегии прогнозного обслуживания.

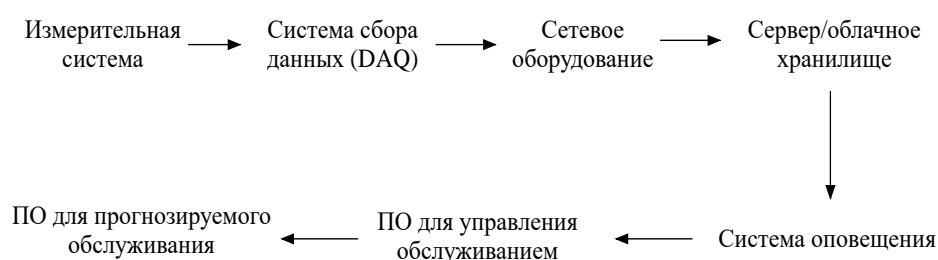


Рис. 2. Структурная схема системы прогнозирования обслуживания
Fig. 2. A block diagram of the maintenance prediction system

Таблица 3. Состав основных узлов и технических средств, необходимых для реализации стратегии системы прогнозирования обслуживания

Table 3. The composition of the main components and technical means required for implementing the strategy of the predictive maintenance system

Компонент/устройство	Функциональное назначение	Пример зарубежных продуктов и российских аналогов
Датчик энергопотребления	Измеряет энергопотребление светодиодных осветительных приборов	Multi-Loop Energy Meter, ADW210 Series
Датчик температуры	Измеряет температуру светодиодных осветительных приборов/окружающей среды	Uni-T UT320D Mini Thermometer / Терморезисторный датчик NTC Incotex
Система сбора данных	Оцифровывает и форматирует данные датчика для дальнейшей обработки	ADLINK PCIe-7300A / Система сбора данных НИИЭТ JSC
Сетевое оборудование	Обеспечивает передачу данных по сети	Huawei Networking Hardware / MikroTik сетевое оборудование
Сервер/облачное хранилище	Хранит собранные данные для дальнейшего анализа	Alibaba Cloud Services / Yandex Cloud Services
ПО для прогнозирования технического обслуживания	Анализирует собранные данные с использованием моделей прогнозирования	Alibaba Machine Learning Platform / Yandex DataSphere
ПО для управления техническим обслуживанием	Выполняет функции планирования необходимых задач на основе выходных данных ПО для прогнозирования	CMMS eWorkOrders / NOVOSOFT CMMS
Система оповещения	Уведомляет о запланированных задачах и возможных неисправностях	MNS Alibaba Cloud / Yandex Connect

Заключение

Разработанная модель прогнозного технического обслуживания сетей светодиодного освещения может оказать значительное влияние на управление качеством работы сети освещения.

Модель дает представление о прогнозируемых требованиях к техническому обслуживанию отдельных светодиодных осветительных приборов (в конкретном описанном примере в качестве основного показателя была выбрана светоотдача). Полученная информация позволяет оптимизировать планирование технического обслуживания и предпринимать упреждающие действия для устранения потенциальных проблем до того, как они приведут к сбоям. Это помогает сократить время простоя и обеспечить непрерывную и надежную работу сети освещения там, где это наиболее необходимо.

Способность модели прогнозировать светоотдачу и производительность светодиодных осветительных приборов позволяет операторам оптимизировать потребление энергии. Выявляя неэффективные устройства, можно оптимизировать энергопотребление, что приведет к экономии энергии и повышению общей энергоэффективности сети освещения.

Модель помогает определить конкретные светодиодные осветительные приборы, нуждающиеся в техническом обслуживании, позволяя операторам эффективно распределять ресурсы. Это позволяет сосредоточить усилия по техническому обслуживанию критически важных устройств, продлевая срок их службы и обеспечивая оптимальное управление активами.

Модель опирается на анализ данных и распознавание образов для составления прогнозов. Такой подход, основанный на данных, улучшает процессы принятия решений, позволяя операторам расставлять приоритеты в задачах технического обслуживания и распределять ресурсы на основе анализа данных.

Применение представленной модели в контексте прогнозируемого технического обслуживания сетей светодиодного освещения предлагает ряд новых управленческих аспектов.

Модель специально разработана для прогнозируемого технического обслуживания в индустрии светодиодного освещения. Используя данные датчиков, исторические записи технического обслуживания и данные об окружающей среде, модель позволяет прогнозировать требования к техническому использованию конкретных освети-

тельных приборов, такие как время до отказа или порог снижения производительности. Это позволяет оптимизировать операции по техническому обслуживанию и повысить общую надежность данного оборудования в используемой сети.

В модели используются методы выбора характеристик для выбора соответствующих параметров, которые способствуют выполнению задачи прогнозного технического обслуживания. Модель включает в себя обнаружение выбросов с использованием z -оценок, что помогает идентифицировать и обрабатывать точки данных, которые значительно отклоняются от нормы. Это имеет решающее значение для качества и достоверности данных, особенно в эксплуатационных решениях, где выбросы могут оказать существенное влияние на прогнозные модели. Также Модель применяет нормализацию данных и разбивает данные на обучающие, валидационные и тестовые наборы, гарантируя, что модель обучается и оценивается на независимых подмножествах данных. Правильное разделение данных имеет важное значение для надежной оценки модели и предотвращения переобучения.

Модель может применяться для мониторинга в режиме реального времени, непрерывного сбора данных с датчиков и генерации предупреждений о проактивном техническом обслуживании, когда прогнозируемые требования к техническому обслуживанию превышают заданные пороговые значения. Такого рода моделирование в режиме реального времени жизненно важно для эффективных стратегий прогнозного технического обслуживания.

Использование представленной модели и описанной стратегии позволяет производить анализ закономерностей и тенденций в нормализованных значениях энергопотребления, напряжения и температуры в каждом наборе данных. Этот анализ может помочь выявить взаимосвязи между характеристиками, а также потенциальные корреляции с другими факторами, такими как светоотдача или требования к техническому обслуживанию.

Используя предварительно обработанные данные для разработки прогнозирующих моделей, которые позволяют прогнозировать требования к техническому обслуживанию на основе нормализованных значений энергопотребления, напряжения, температуры и других параметров, можно добиться повышения эффективности процесса оптимизации производительности систем освещения и совершенствования стратегий управления качеством в данных сетях.

Представленная модель может быть масштабирована. Целесообразно расширить матрицу X и добавить в нее более сложные зависимости, а также дополнительные параметры, например срок эксплуатации, влажность и температуру окружающей среды, циклы включения и выключения, гармонический состав токов и напряжений, коэффициент мощности. После чего модель может быть использована для реализации описанной стратегии прогнозного технического обслуживания для управления качеством сетей светодиодного освещения.

В целом модель прогнозируемого технического обслуживания улучшает управление качеством сети светодиодного освещения, предлагая своевременную и точную информацию о потребностях в техническом обслуживании, оптимизируя энергоэффективность, сокращая время простоя и позволяя осуществлять упреждающее планирование технического обслуживания. Конкретные технические решения, основанные на прогнозах модели, могут привести к лучшему распределению ресурсов, экономии затрат и общему улучшению работы и надежности сети светодиодного освещения.

Список источников

1. Segovia-Muñoz D. & Serrano Guerrero, Xavier & Barragán-Escandón, Antonio. Predictive maintenance in LED street lighting controlled with telemanagement system to improve current fault detection procedures using software tools. *Renewable Energy and Power Quality Journal*, 2022, vol. 20, pp. 379-386. doi:10.24084/repqj20.318.
2. Karami, Mahdi and Madlener, Reinhard, Smart Predictive Maintenance Strategy Based on Cyber-Physical Systems for Centrifugal Pumps: A Bearing Vibration Analysis (September 1, 2019). FCN Working Paper No. 14/2019, SSRN doi.org/10.2139/ssrn.3544199
3. Прыткова Е.А., Давыдов В.М. Анализ применения иерархических нейросетевых методов в контроле качества // Вестник Магнитогорского государственного технического университета им. Г.И. Носова. 2023. Т. 21. №1. С. 74-81. doi.org/10.18503/1995-2732-2023-21-1-74-81
4. Коррекция коэффициента мощности в системах электроснабжения с многофазными нелинейными нагрузками / Егоров Д.Э., Довгун В.П., Боярская Н.П., Ян А.В., Слюсарев А.С. // Известия высших учебных заведений. Проблемы энергетики. 2020. Т. 22. №6. С. 3-15. doi:10.30724/1998-9903-2020-22-6-3-15.
5. De Luca R., Ferraro A., Galli A., Gallo M., Moscato V. and Sperli G. A deep attention-based approach for predictive maintenance applications in IoT scenarios // *Journal of Manufacturing Technology Management*, 2023, vol. 34, no. 4, pp. 535-556. doi.org/10.1108/JMTM-02-2022-0093
6. Минимизация потерь мощности в пассивных силовых фильтрах / Боярская Н.П., Довгун В.П., Егоров Д.Э., Новиков В.В., Шандрыгин Д.А. // Известия высших учебных заведений. Проблемы энергетики. 2021. Т. 23. №6. С. 42-52. doi:10.30724/1998-9903-2021-23-6-42-52.
7. Mirza Rayana Sanzana, Tomas Maul, and others, Application of deep learning in facility management and maintenance for heating, ventilation, and air conditioning, *Automation in Construction*, 2022, vol. 141, pp. 104445, ISSN 0926-5805, doi.org/10.1016/j.autcon.2022.104445.
8. Gong Chen & Xu, Haiping & Yuan, Zengquan & Liang, Jinhua. The Accelerated Life Test Investigation and Lifetime Prediction Method for LED Driver, 2022, pp. 355-359. doi:10.1109/ICPEA56363.2022.10052233.
9. Kuzmenko V. and others. Definition and approximation of the light flux degradation of a LED lamp // *IOP Conference Series: Materials Science and Engineering*. 2020, vol. 734, pp. 012197. doi:10.1088/1757-899X/734/1/012197.
10. Калечиц В.Н. Особенности моделирования режимов работы линий наружного освещения. *Энергетика* // Известия высших учебных заведений и энергетических объединений СНГ. 2022. Т. 65. №6. С. 499-510. doi:10.21122/1029-7448-2022-65-6-499-510.
11. Кузьменко В.П., Солёный С.В. Исследование влияния светодиодных прожекторов на процессы управления качеством электрической энергии и энергоэффективностью // Омский научный вестник. 2021. Т. 2. №176. С. 15-19.

References

1. Segovia-Muñoz D., Xavier Serrano Guerrero, Antonio Barragán-Escandón. Predictive maintenance in LED street lighting controlled with telemanagement system to improve current fault detection procedures using software tools. *Renewable Energy and Power Quality Journal*. 2022;20:379-386. DOI: 10.24084/repqj20.318
2. Mahdi Karami, Reinhard Madlener. Smart predictive maintenance strategy based on cyber-physical systems for centrifugal pumps: A bearing vibration analysis. FCN Working Paper No. 14/2019. DOI: 10.2139/ssrn.3544199
3. Prytkova E.A., Davydov V.M. Analysis of the use of hierarchical neural network methods in quality control. *Vestnik Magnitogorskogo gosudarstvennogo tekhnicheskogo universiteta im. G.I. Nosova* [Vestnik of Nosov Magnitogorsk State Technical University]. 2023;21(1):74-81. (In Russ.) doi.org/10.18503/1995-2732-2023-21-1-74-81
4. Egorov D.E., Dovgun V.P., Boyarskaya N.P., Yan A.V., Slyusarev A.S. Power factor correction in power delivery systems with multiphase nonlinear loads. *Izvesti-*

- ya vysshikh uchebnykh zavedeniy. *Problemy energetiki* [Power Engineering: Research, Equipment, Technology]. 2020;22(6):3-15. (In Russ.) DOI: 10.30724/1998-9903-2020-22-6-3-15
5. De Luca R., Ferraro A., Galli A., Gallo M., Moscato V., Sperli G. A deep attention-based approach for predictive maintenance applications in IoT scenarios. *Journal of Manufacturing Technology Management*. 2023;34(4):535-556. doi.org/10.1108/JMTM-02-2022-0093
 6. Boyarskaya N.P., Dovgun V.P., Egorov D.E., Novikov V.V., Shandrygin D.A. Minimization of power losses in passive power filters. *Izvestiya vysshikh uchebnykh zavedeniy i energeticheskikh obedineniy SNG* [Proceedings of the CIS Higher Education Institutions and Power Engineering Associations], 2021;23(6):42-52. (In Russ.) DOI: 10.30724/1998-9903-2021-23-6-42-52
 7. Mirza Rayana Sanzana, Tomas Maul et al. Application of deep learning in facility management and maintenance for heating, ventilation, and air conditioning. *Automation in Construction*. 2022;141:104445. ISSN 0926-5805. doi.org/10.1016/j.autcon.2022.104445
 8. Chen Gong, Haiping Xu, Zengquan Yuan, Jinhua Liang. The accelerated life test investigation and lifetime prediction method for LED driver. 2022;355-359. DOI: 10.1109/ICPEA56363.2022.10052233
 9. Kuzmenko V. et al. Definition and approximation of the light flux degradation of a LED lamp. *IOP Conference Series: Materials Science and Engineering*. 2020;734:012197. DOI: 10.1088/1757-899X/734/1/012197
 10. Kalechits V.N. Features of modeling the operating modes of outdoor lighting lines. *Energetika. Izvestiya vysshikh uchebnykh zavedeniy i energeticheskikh obedineniy SNG* [Proceedings of the CIS Higher Education Institutions and Power Engineering Associations], 2022;65(6):499-510. (In Russ.) DOI: 10.21122/1029-7448-2022-65-6-499-510
 11. Kuzmenko V.P., Solenyi S.V. Study on the influence of LED spotlights on the processes of managing the quality of electrical energy and energy efficiency. *Omskii nauchnyi vestnik* [Omsk Scientific Bulletin]. 2021;2(176):15-19. (In Russ.)

Поступила 26.05.2023; принята к публикации 07.08.2023; опубликована 25.09.2023
Submitted 26/05/2023; revised 07/08/2023; published 25/09/23

Кузьменко Владимир Павлович – кандидат технических наук, доцент кафедры электромеханики и робототехники, Санкт-Петербургский государственный университет аэрокосмического приборостроения, Санкт-Петербург, Россия.

Email: mr.konnny@gmail.com. ORCID 0000-0002-0270-4875

Солёный Сергей Валентинович – кандидат технических наук, доцент, заведующий кафедрой электромеханики и робототехники, Санкт-Петербургский государственный университет аэрокосмического приборостроения, Санкт-Петербург, Россия.

Email: ssv555sv@yandex.ru ORCID 0000-0002-7919-3890

Vladimir P. Kuzmenko – PhD (Eng.), Associate Professor of the Department of Electromechanics and Robotics, Saint Petersburg State University of Aerospace Instrumentation, Saint Petersburg, Russia.

Email: mr.konnny@gmail.com. ORCID 0000-0002-0270-4875

Sergey V. Solenyi – PhD (Eng.), Associate Professor, Head of the Department of Electromechanics and Robotics, Saint Petersburg State University of Aerospace Instrumentation, Saint Petersburg, Russia.

Email: ssv555sv@yandex.ru. ORCID 0000-0002-7919-3890