

# АНАЛИЗ УРОВНЯ ОСВЕЩЕННОСТИ ПОВЕРХНОСТИ НА ОСНОВЕ КОМПЬЮТЕРНЫХ МЕТОДОВ ОБРАБОТКИ ИНФОРМАЦИИ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ

## SURFACE ILLUMINATION LEVEL ANALYSIS BASED ON COMPUTER INFORMATION PROCESSING METHODS USING MACHINE LEARNING

A. Buryi

*Summary.* The article is devoted to the analysis of the surface illumination level based on computer methods of information processing and machine learning. A convolutional neural network model has been developed that can determine illumination from images taken at fixed shooting parameters. It has been found that the use of logarithmic transformation and the error backpropagation algorithm reduces the impact of outliers and increases the accuracy of the model, while data optimization and reduction of the illumination range (no more than 600 lux, no more than 400 lux and no more than 300 lux) ensure the stability of the results. The scientific novelty lies in the adaptation of machine learning methods for analyzing illumination at the microlevel, which expands the possibilities of automated illumination control.

*Keywords:* illumination, convolutional neural network, machine learning, computer analysis, automation.

Бурый Антон Сергеевич

Калифорнийский государственный университет,  
Нортридж  
buryyantong@gmail.com

*Аннотация.* Статья посвящена анализу уровня освещенности поверхности на основе компьютерных методов обработки информации и машинного обучения. Разработана модель сверточной нейронной сети, способная определять освещенность по изображениям, снятым при фиксированных параметрах съемки. Установлено, что применение логарифмической трансформации и алгоритма обратного распространения ошибки снижает влияние выбросов и повышает точность модели, а оптимизация данных и сокращение диапазона освещенности (не более 600 лк, не более 400 лк и не более 300 лк) обеспечивают стабильность результатов. Научная новизна заключается в адаптации методов машинного обучения для анализа освещенности на микроуровне, что расширяет возможности автоматизированного контроля освещенности.

*Ключевые слова:* освещенность, сверточная нейронная сеть, машинное обучение, компьютерный анализ, автоматизация.

### Введение

Контроль уровня освещенности поверхностей имеет важное значение для обеспечения безопасности и комфорта в рабочих и производственных помещениях. Традиционные методы измерения освещенности, основанные на использовании люксметров, обеспечивают высокую точность, однако для их использования требуется непосредственный доступ к объекту и много времени. Развитие методов машинного обучения и использование сверточных нейронных сетей (далее — CNN) открывают возможность автоматического определения освещенности по фотографиям, что упрощает процесс контроля и расширяет его применение [1].

### Методология

Задача исследования заключается в разработке метода анализа уровня освещенности поверхности с применением компьютерных методов обработки информации. Основой исследования является использование изображений поверхности, снятых при фиксированных

параметрах камеры, с последующим применением методов машинного обучения. Следует отметить, что анализ уровня освещенности по фотографиям представляет собой сложную задачу, поскольку светоотражающие характеристики поверхности, угол съемки, параметры освещения и другие факторы могут существенно влиять на визуальное восприятие яркости. В этом контексте применение машинного обучения позволяет как выявлять закономерности на основе обучающих данных, так и адаптироваться к различным условиям съемки.

Методологическая основа исследования определяется выбором CNN как инструмента анализа изображений. Данный класс моделей обладает высокой способностью к распознаванию визуальных паттернов и выделению ключевых признаков, что делает его эффективным для задач классификации и регрессии на основе изображений. Применение CNN позволяет преобразовать информацию, содержащуюся в пикселях изображения, в числовые значения, отражающие уровень освещенности. Важным аспектом является подготовка данных для обучения сети, включая их нормализацию и адаптацию

к форматам, воспринимаемым нейронной сетью, что обеспечивает возможность многократного улучшения качества модели за счёт оптимизации параметров обучения.

Ожидаемым результатом исследования является создание модели, способной точно определять уровень освещенности поверхности на основе фотографии. Практическая значимость разработки заключается в расширении возможностей анализа освещения без необходимости прямого использования специализированных приборов, что открывает перспективы автоматизированного контроля освещенности в различных условиях, включая рабочие места и производственные площадки.

Ниже представлен алгоритм решения задачи, состоящий из трех основных этапов (рис. 1).

Создание базы данных для машинного обучения в задаче анализа уровня освещенности поверхности представляет собой процесс, в рамках которого основополагающим принципом стала систематизация визуальной информации с высокой точностью эталонных значений. Данные собирались таким образом, чтобы каждая запись в базе данных обладала установленным уровнем освещенности, при этом база фото была автоматически разбита на две части: 70 % было выделено под обучающую выборку, 30 % — под тестовую. В основе лежит концепция контролируемого сбора данных, которая исключает влияние таких внешних факторов, как изменение условий съемки или настройки оборудования.

Для формирования базы данных использовался метод фотографии с фиксированными параметрами. Применялся смартфон Huawei P30 lite, настройки которого включали в себя постоянные значения экспозиции и угла съемки. Такой подход обеспечивал сохранение постоянных условий фиксации изображений, что предотвращало искажения светового потока и обеспечивало сопоставимость данных. Сохранение постоянных параметров позволило исключить влияние внешних факторов на полученные изображения, а также послужило основой корректности их последующего анализа.

Контроль качества изображений был организован до их включения в базу данных. Так, в ходе работы исключались кадры с недостаточной резкостью, нарушенной геометрией объектов и другими визуальными дефектами. Такой отбор обеспечивал использование только тех данных, которые точно отражали реальные значения освещенности. Каждое изображение было связано с соответствующим значением освещенности, что создавало надёжную основу для формирования контролируемого набора данных. Процесс разметки изображений предполагал выделение областей, в которых фиксировались эталонные значения освещенности. Такой подход способствовал тому, что модель могла автономно сосредоточиться на ключевых участках, отображающих световые характеристики, и исключать влияние фоновых объектов.

На начальном этапе проводился эксперимент с выделением области на поверхности датчика, что упрощало определение ключевых участков изображения. Программное обеспечение обеспечивало точное выде-



Рис. 1. Алгоритм решения задачи

Источник: составлено автором

ление областей для формирования структурированных данных с четкой привязкой к числовым значениям освещенности. Корректная разметка исключала субъективные ошибки и обеспечивала целостность данных.

Важно отметить, что оптимизация модели машинного обучения была направлена на снижение ошибок и повышение точности предсказаний.

В условиях анализа освещенности основная сложность связана с вариативностью данных, вызванной изменениями условий съемки и характеристик поверхности [7]. Логарифмическая трансформация значений освещенности позволяет стабилизировать процесс обучения и уменьшать влияние выбросов.

Основой настройки модели стал алгоритм обратного распространения ошибки, который автоматически корректирует параметры сети, что уменьшает величину ошибки. Для повышения устойчивости модели применялась нормализация данных.

CNN выбраны вследствие способности этой сети распознавать ключевые элементы изображения. Автоматическое выделение признаков сохраняет пространственные связи между пикселями, что важно для анализа освещенности, в то время как многослойная структура модели обеспечивает высокую точность. В качестве фреймворка был выбран PyTorch вследствие гибкости и возможности динамического создания вычислительных графов. Поддержка автоматического вычисления градиентов и обширная библиотека функций ускоряют процесс разработки и настройки моделей. В задаче анализа освещенности PyTorch обеспечивает быструю адаптацию и оптимизацию моделей [7].

### Результаты и их обсуждение

Прежде всего, следует отметить, что в научной литературе отмечается, что на уровне промышленных объектов CNN позволяют выявлять дефекты на металлических поверхностях, а также обеспечивать высокую точность контроля качества в качестве объекта (табл. 1), однако в основном в работах используются промышленные рабочие места, тогда как на «микроуровне» (одном рабочем месте) практически нет исследований.

Анализ результатов обучения нейронной сети на полной базе данных выявил закономерности в точности предсказания уровня освещенности (рис. 2–3). Распределение ошибок на тестовой выборке показывает высокую точность при низких значениях освещенности и увеличение отклонений по мере роста уровня освещенности.

На графике прогнозируемых значений (Predicted Lux) по сравнению с реальными значениями (True Lux) сохраняется линейная зависимость, однако отклонения воз-

Таблица 1.

Обзор литературы CNN для определения уровня освещенности, в том числе на рабочих местах.

Источник	Методология	Основной вывод
[2]	Применение CNN для анализа дефектов на металлической поверхности	Метод CNN показывает высокую точность в обнаружении дефектов при контроле качества
[3]	Прогнозирование освещенности в офисных помещениях с помощью искусственной нейронной сети (ANN)	Автоматизация освещения улучшает качество освещенности и снижает затраты на электроэнергию
[4]	Контроль освещения офиса на основе нейронной сети с оптимизацией методом генетического алгоритма (GA-BP)	Система интеллектуального освещения повышает энергоэффективность и комфорт в офисе
[5]	Прогнозирование ежегодной освещенности и температуры с помощью ANN	Модель ANN снижает время моделирования освещения и температуры на 96 %
[6]	Реконструкция спектральной освещенности с использованием многочастотного спектрального датчика и CNN	CNN обеспечивает высокую точность реконструкции спектральной освещенности в реальных условиях.

Источник: составлено автором

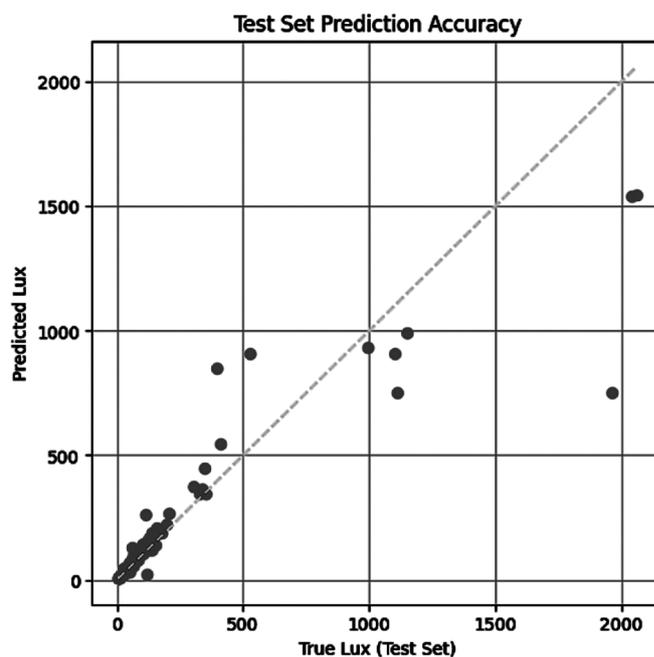


Рис. 2. Точность предсказания уровня освещенности на тестовой выборке на всей базе данных

Источник: составлено автором

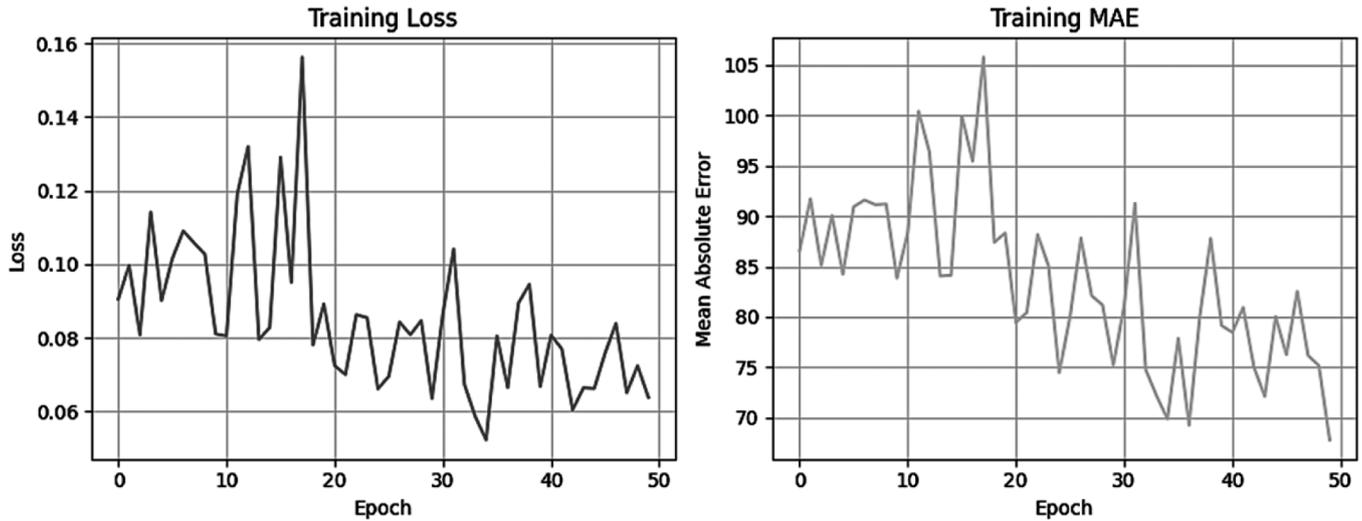


Рис. 3. Динамика ошибки обучения модели и средняя абсолютная ошибка модели на этапе обучения на всей базе данных

Источник: составлено автором

растают при превышении значений освещенности в 1000 лк. Стабилизация ошибки на этапе обучения (Training Loss) отражает постепенное снижение величины отклонений с увеличением числа эпох. Варьирование средней абсолютной ошибки (MAE) свидетельствует о колебаниях в процессе обучения, что подтверждает необходимость оптимизации модели и настройки параметров.

Однако база данных, на которой проводилось обучение, имела решающее значение, поэтому было решено убрать фото с высоким значением освещенности, т.е. меньше 700 лк (рис. 4–5).

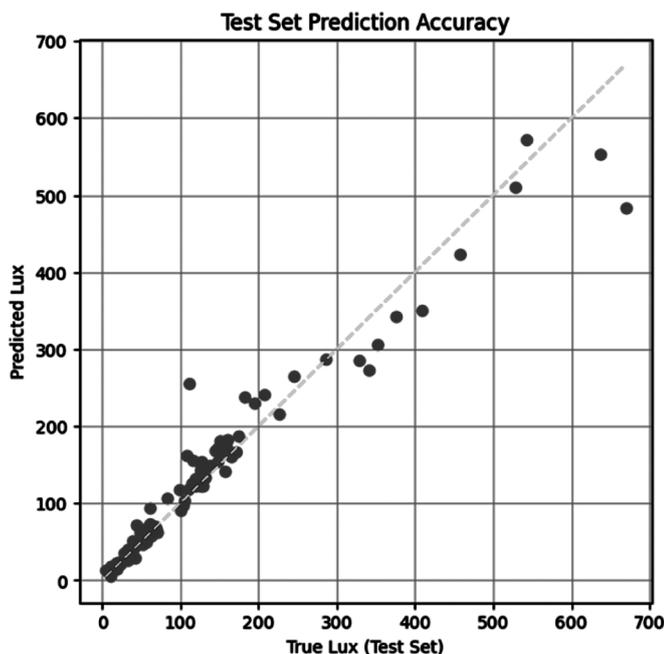


Рис. 4. Точность предсказания уровня освещенности на тестовой выборке на всей до 700 лк

Источник: составлено автором

Анализ результатов на выборке с уровнями освещенности до 700 лк показывает высокую точность модели, что подтверждается графиком, отражающим близость предсказанных значений освещенности к реальным.

Снижение диапазона данных позволило уменьшить влияние выбросов, характерных для более высоких уровней освещенности, что обеспечило улучшение общей стабильности модели.

На графике ошибки обучения и тестирования наблюдается снижение величины отклонений уже на начальных эпохах и сохранение их на стабильном уровне.

Совпадение линий ошибки на обучающей и тестовой выборках указывает на отсутствие переобучения и высокую адаптивность модели в условиях ограниченного диапазона освещенности.

Анализ результатов на выборках с ограничением уровней освещенности до 600, 400 и 300 лк соответственно (рис. 6) отражает улучшение точности модели по мере сокращения диапазона данных. Снижение верхнего предела освещенности приводит к уменьшению разброса предсказанных значений относительно реальных, что подтверждает повышение стабильности модели.

На графиках ошибки обучения и тестирования фиксируется равномерное снижение показателей с первых эпох, а схождение кривых ошибок указывает на отсутствие переобучения. Ограничение диапазона освещенности уменьшает влияние выбросов и искажений, что формирует условия для повышения точности предсказания.

Снижение диапазона значений освещенности до шестисот, четырехсот и трёхсот лк отражает зависимость точности модели от верхних пределов освещенности.

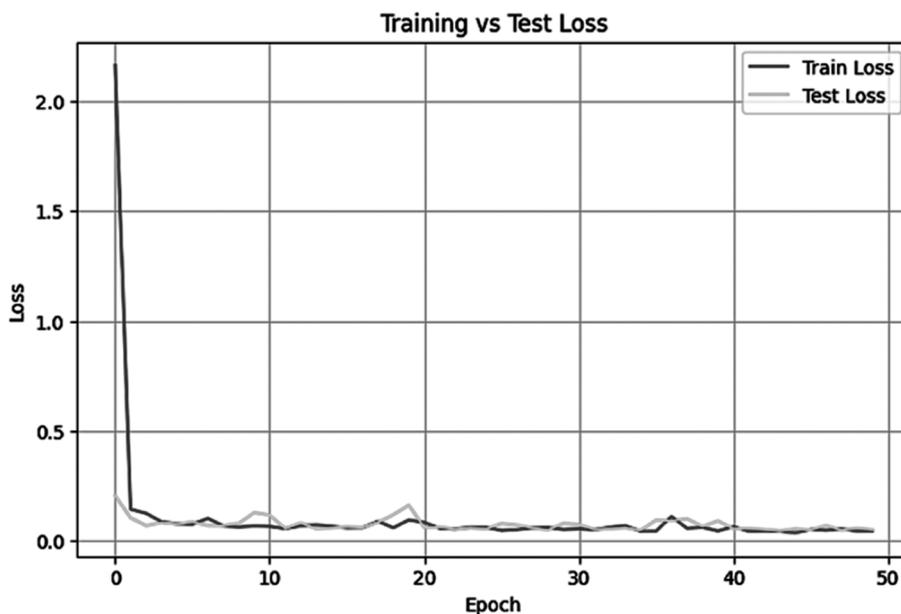


Рис. 5. Динамика ошибки обучения модели и средняя абсолютная ошибка модели на этапе обучения на выборке до 700 лк

Источник: составлено автором

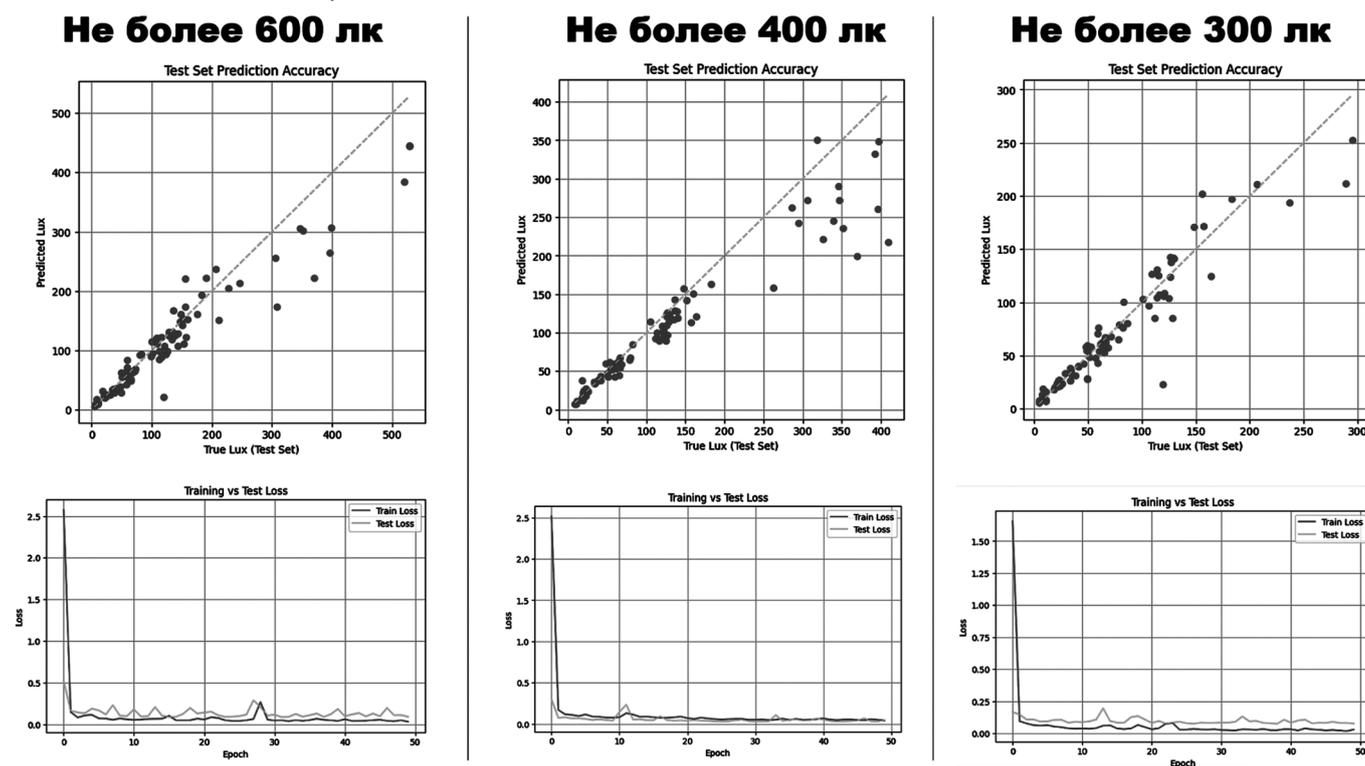


Рис. 6. Точность предсказания уровня освещенности на тестовой выборке и динамика ошибки обучения модели (выборки не более 600 лк, не более 400 лк и не более 300 лк).

Источник: составлено автором

Видно, что исключение высоких уровней уменьшает влияние выбросов и улучшает стабильность обучения нейронной сети. В условиях ограниченного диапазона корректировка данных таким образом позволяет повысить точность предсказания.

Обучение модели на основе архитектуры CNN подтверждает возможность автоматизированного определения уровня освещенности поверхности на основе анализа визуальных данных. Преобразование графической информации в числовые показатели яркости обе-

спечивает выявление закономерностей и формирование зависимостей между параметрами изображения и значениями освещенности. Функциональные возможности CNN способствуют распознаванию ключевых визуальных характеристик, что исключает необходимость ручного анализа изображений.

Высокая точность модели достигается за счёт систематизации обучающих данных и оптимизации их обработки. Фиксированные параметры съемки и предварительный контроль качества визуальных данных устраняют влияние внешних факторов, что обеспечивает стабильность результатов. Применение логарифмической трансформации уровней освещенности снижает воздействие выбросов, что упрощает процесс обучения. Нормализация данных и оптимизация параметров модели с использованием алгоритма обратного распространения ошибки способствуют повышению согласованности результатов и предотвращает переобучение.

Использование CNN в рамках анализа освещенности открывает возможности для создания систем автоматизированного контроля без применения специализированных измерительных приборов. Фиксирующие световые характеристики поверхности визуальные данные становятся основой для оценки освещенности в различных условиях. Способность модели адаптироваться к новым обучающим данным подтверждает её эффективность как средства компьютерного анализа изображений.

Научная значимость проведённого исследования связана с внедрением методов машинного обучения для анализа освещенности поверхности на основе изображений, что обеспечивает автоматизацию процесса измерения без использования люксметров или иных приборов. В отличие от традиционных подходов, когда оценка освещенности проводится вручную или с применением специализированного оборудования, модель на основе

CNN интерпретирует визуальные данные и определяет уровни освещенности с высокой точностью, что расширяет возможности контроля освещения, снижает зависимость от оборудования и облегчает мониторинг световых условий.

Применение CNN позволяет автоматизировать процесс анализа освещенности в условиях, когда использование измерительных приборов ограничено. Методы машинного обучения компенсируют недостатки традиционных способов измерения освещенности. Визуальные данные в сочетании с нейронной сетью (в данном случае — CNN) формируют гибкую систему анализа световых характеристик поверхности.

### Заключение

Проведённое исследование продемонстрировало, что применение CNN позволяет эффективно определять уровень освещенности поверхности на основе изображений, что открывает перспективы автоматизированного контроля световых условий без использования специализированных приборов. Создание базы данных с фиксированными параметрами съемки и её разметка обеспечили высокую точность модели, что подтвердилось на различных диапазонах освещенности. Применение логарифмической трансформации значений и оптимизация алгоритма обучения уменьшили влияние выбросов и повысили стабильность модели, что особенно заметно в диапазоне до 700 лк. Полученные результаты также подтвердили, что точность модели возростала при сокращении диапазона освещенности, что подтверждает её пригодность для анализа освещенности на микроуровне. Разработанная модель может применяться в системах автоматического контроля освещенности офисных и производственных помещений, обеспечивать гибкость и высокую адаптивность при изменении условий освещения.

### ЛИТЕРАТУРА

1. Zhu M. et al. Impact of lighting environment on human performance and prediction modeling of personal visual comfort in enclosed cabins // *Science of The Total Environment*. — 2024. — Vol. 927. — P. 1–13.
2. Maruschak P. et al. Surface illumination as a factor influencing the efficacy of defect recognition on a rolled metal surface using a deep neural network // *Applied Sciences*. — 2024. — Vol. 14. — No. 6. — P. 1–18.
3. Zekry O.S., Fekry A.A., Hamed R.E. D. Artificial Neural Network to Predict Curvature Light Shelf Design Related Daylighting Optimization on Office Spaces // *Journal of Daylighting*. — 2024. — Vol. 11. — No. 2. — P. 334–348.
4. Zhang R. et al. Intelligent Office Lighting Control Using Natural Light and a GA-BP Neural Network-Based System // *Applied Sciences*. — 2024. — Vol. 14. — No. 23. — P. 1–14.
5. Kristiansen T. et al. Predicting annual illuminance and operative temperature in residential buildings using artificial neural networks // *Building and Environment*. — 2022. — Vol. 217. — P. 1–14.
6. Myland P. et al. Reconstruction of spectral irradiance in a real application with a multi-channel spectral sensor using convolutional neural networks // *Optics express*. — 2023. — Vol. 31. — No. 16. — P. 25724–25746.
7. Chiew S.M. et al. Assessment and ANN model development of natural light transmittance of light-transmitting concrete // *Results in Engineering*. — 2023. — Vol. 20. — P. 1–14.