



Применение искусственной нейронной сети при моделировании распределения освещенности в трехмерном пространстве

© 2026. С. А. Ракутько[✉], Е. Н. Ракутько

Институт агроинженерных и экологических проблем сельскохозяйственного производства – филиал ФГБНУ «Федеральный научный агроинженерный центр ВИМ», г. Санкт-Петербург, Российская Федерация

В работе рассмотрено моделирование трехмерного распределения освещенности от источников света с помощью искусственной нейронной сети (ИНС). Наиболее остро эти вопросы стоят в тепличных облучательных установках из-за конструктивных особенностей – значительных габаритов излучателей относительно малой высоты подвеса, что исключает их представление точечным источником. Цель исследования – разработка методики моделирования распределения освещенности в трехмерном пространстве, включающей получение экспериментальных данных и их обработку с помощью искусственной нейронной сети. Датасет размером 2100 записей получен экспериментально для разработанного фитооблучателя. Измеряли значения освещенности E в узлах координатной сетки с шагом 10 см в пределах от 0 до 120 см (по координате x) и от 0 до 100 см (по координате y) во всех четырех квадрантах, при различной высоте подвеса фитооблучателя h на уровнях 30, 50, 70 и 90 см. Для построения модели применены библиотеки TensorFlow и Keras языка программирования Python. Моделирование проводили в Google Colab. Результаты показали, что созданная нейросеть эффективно описывает распределение потока на облучаемой поверхности, учитывая реальную геометрию источника света. Ключевое преимущество метода – возможность расчета освещенности для любой комбинации высоты подвеса и координат точки на плоскости, что преодолевает ограничения традиционных светотехнических расчетов, основанных на законе обратных квадратов. Средняя абсолютная ошибка нейросетевой модели составляет 0,04 клк, значение коэффициента детерминации $R^2 = 0,9967$ с 95%-м доверительным интервалом [0,09953, 0,9977], что является хорошим результатом. Средняя ошибка предсказаний составляет 7,5 %, эта величина может быть улучшена путем регуляризации и аугментации данных. Показано, что метод ИНС применим для проектирования энергоэффективных осветительных систем, адаптируем к учету спектральных характеристик и отраженного света. После повторного обучения модель может быть использована для фитооблучателей произвольной конструкции, что расширяет ее практическую значимость в светоделирии.

Ключевые слова: светоделирия, фитооблучатель, нейросетевое моделирование, горизонтальная освещенность, равномерность освещения

Благодарности: работа выполнена при финансовой поддержке Минобрнауки РФ в рамках Государственного задания ФГБНУ «Федеральный научный агроинженерный центр ВИМ» (тема № FGUN-2025-0010).

Авторы благодарят рецензентов за их вклад в экспертную оценку этой работы.

Конфликт интересов: авторы заявили об отсутствии конфликта интересов.

Для цитирования: Ракутько С. А., Ракутько Е. Н. Применение искусственной нейронной сети при моделировании распределения освещенности в трехмерном пространстве. Аграрная наука Евро-Северо-Востока. 2026;27(2):493–503. DOI: <https://doi.org/10.30766/2072-9081.2026.27.2.493-503>

Поступила: 23.06.2025

Принята к публикации: 20.03.2026

Доработана после рецензирования: 08.08.2025

Опубликована онлайн: 27.04.2026

Application of artificial neural network in modeling illumination distribution in three-dimensional space

© 2026. Sergei A. Rakutko[✉], Elena N. Rakutko

Institute for Engineering and Environmental Problems in Agricultural Production – branch of Federal Scientific Agroengineering Center VIM, Saint-Petersburg, Russian Federation

The paper deals with modeling three-dimensional illumination distribution from light sources using artificial neural network (ANN). This problem is especially relevant in greenhouse irradiation systems due to the design features, namely large dimensions of the phytoirradiators relative to the small suspension height, which makes it impossible to represent them as point sources. The aim of the research is to develop a methodology for modeling illumination distribution in three-dimensional space, which includes obtaining experimental data and processing them using an artificial neural network. A dataset comprising 2,100 records was obtained experimentally for the developed phytoirradiator. The illumination values E were measured at the nodes of the coordinate grid with a step of 10 cm within the range from 0 to 120 cm (along the x coordinate) and from 0 to 100 cm (along the y coordinate) in all four quadrants, at different suspension height of the phytoirradiator h at levels of 30, 50, 70 and 90 cm. The TensorFlow and Keras libraries of the Python programming language were used to build the model. The results showed that the created neural network effectively describes the flux distribution on the irradiated surface, taking into account the real geometry of the light source. The key advantage of the method is the ability to calculate illumination for any combination of suspension height and point coordinates on the plane, which overcomes the limita-

tions of conventional lighting calculations based on the inverse square law. The mean absolute error of the neural network model is 0.04 klx, the value of the determination coefficient $R^2 = 0.9967$ with a 95 % confidence interval of [0.09953, 0.9977], which is a good result. Mean absolute prediction error is 7.5 %, this value can be improved by regularization and data augmentation. It has been established that ANN-based method is applicable to the design of energy-efficient lighting systems, adaptable to the spectral characteristics and reflected light. After retraining, the model can be used for phytoirradiators of arbitrary design, which expands its practical significance in plant lighting.

Keywords: plant lighting, phytoiradiator, neural network modeling, horizontal illumination, uniformity of illumination

Acknowledgement: the research was carried out with the financial support of the Ministry of Science and Higher Education of the Russian Federation within the state assignment of the Federal Scientific Agroengineering Center VIM (theme No. FGUN-2025-0010).

The authors thank the reviewers for their contribution to the peer review of this work.

Conflict of interest: the authors stated no conflict of interest.

For citation: Rakutko S. A., Rakutko E. N. Application of artificial neural network in modeling illumination distribution in three-dimensional space. *Agrarnaya nauka Evro-Severo-Vostoka* = Agricultural Science Euro-North-East. 2026;27(2):493–503. (In Russ.). DOI: <https://doi.org/10.30766/2072-9081.2026.27.2.493-503>

Received: 23.06.2025

Revised: 08.08.2025

Accepted for publication: 20.03.2026

Published online: 27.04.2026

На сегодняшний день в научных исследованиях, в проектной и практической деятельности все большее распространение получают искусственные нейронные сети (ИНС). Диапазон областей их применения крайне широк от инженерно-технических и проектных решений до экологических разработок [1].

В контексте светокультуры – перспективном направлении растениеводства, основанном на выращивании растений при искусственном освещении – нейросетевые технологии находят применение для: мониторинга состояния растений как биологических объектов; распознавания и классификации признаков дефицита питательных элементов по изображению листьев [2]; оптимизации микроклимата умных теплиц [3]; определения биомассы растений по визуальному состоянию [4] и выявления заболеваний растений [5].

В технических аспектах светокультуры ИНС демонстрируют высокую эффективность при решении таких задач: классификация видов искусственного освещения [6]; поиск оптимального графика освещения для выращивания растений с учетом динамического ценообразования на электроэнергию [7]; моделирование зависимости цветовой температуры освещения от источника света и оптической системы светильника [8]; прогнозирование естественной освещенности [9]; управление системами общего освещения [10] и гидропонии [11]; измерение освещенности в помещении, оценка его качества и комфортности [12]; интеллектуальное управление электрооснабжением установок освещения [13]. ИНС широко применяются в светотехнических

расчетах¹, а также при проектировании электрического освещения [14].

Особенно актуальна проблема моделирования распределения светового потока в тепличных комплексах. Тепличные облучательные установки являются неотъемлемым элементом светокультуры. Обеспечение равномерности распределения освещенности по площади выращивания является важным для повышения эффективности использования энергии и улучшения качества растений наряду с другими требованиями. Известна взаимосвязь между коэффициентом полезного использования потока и равномерностью создаваемой освещенности, что обеспечивает возможность оценки энергоэффективности по известной картине распределения освещенности на плоскости. Высказано предположение, что этот показатель может характеризовать экологичность светокультуры [15]. Также показано, что компоновочные параметры облучательной установки (высоты подвеса и расположение облучателя относительно границ участка облучения) влияет на энергоэкологичность светокультуры [16].

Особенностью компоновки фитооблучателей в светокультуре является их низкое расположение относительно растений при значительных по сравнению с этим расстоянием габаритах самого фитооблучателя. Это препятствует использованию хорошо разработанных классических методов расчета распределения облученности, таких как точечный или метод коэффициентов использования, а также современных программ моделирования освещенности типа DiaLux Evo и т. п.

¹Применение нейросетей для светотехнических расчетов. [Электронный ресурс].

URL: <https://geolighting.ru/stati-o-bytovom-primenenii/nejroseti-v-svetotekhnicheskikh-raschetah> (дата обращения: 25.07.2024).

Цель исследования – разработка методики моделирования распределения освещенности в трехмерном пространстве, включающей получение экспериментальных данных и их обработку с помощью искусственной нейронной сети.

Научная новизна – интеграция экспериментального подхода к исследованию светового поля и современных методов машинного

обучения для решения прикладной задачи в аграрной инженерии, что представляет собой шаг вперед относительно традиционных методов расчёта.

Материал и методы. Для получения экспериментальных данных использовали разработанный в лаборатории фитооблучатель² (рис. 1).



Рис. 1. Фитооблучатель / Fig. 1. Phytoirradiator



Рис. 2. Измерения горизонтальной освещенности, создаваемой фитооблучателем на плоскости / Fig. 2. Measurements of horizontal illumination created by the phytoirradiator on the plane

Светодиоды различного спектра излучения скомпонованы на прямоугольной площадке радиатора длиной 990 см и шириной 6 см. Измерения вели при включении группы белых светодиодов (45 шт., 3 Вт), поскольку диапазон их излучения наиболее соответствует спектральной чувствительности применяемого люксметра ТКА-ПКМ 31. В темной комнате люксметром измеряли значения освещенности E , клк, в узлах координатной сетки с шагом 10 см в пределах от 0 до 120 см (по координате x) и от 0 до 100 см (по координате y).

Измерения вели во всех четырех квадрантах при различной высоте подвеса фитооблучателя h на уровнях 30, 50, 70 и 90 см (рис. 2). Размер полученного датасета – 2100 записей (четыре уровня по h * 25 отсчетов по x * 21 отсчетов по y). Структура ИНС для его обработки показана на рисунке 3. Для выбора оптимальной архитектуры ИНС были проведены сравнительные эксперименты с различным числом скрытых слоёв (1–4) и числом нейронов на слой (16, 32, 64, 128),

а также с разными функциями активации ($ReLU$, $LeakyReLU$, ELU , \tanh).

Элементы матриц структуры ИНС первоначально заполняются случайными числами и при обратных проходах (*Back Propagation*), во время процедуры обучения, приходят к значениям, при которых предсказываемый выход сети максимально близок к экспериментальным данным. По известным матрицам весов, между входным слоем и первым скрытым слоем $W^{(1)}$, между первым и вторым скрытыми слоями $W^{(2)}$, между вторым скрытым и выходным слоем $W^{(3)}$ смещений (*bias*) для нейронов соответствующих слоев $B^{(1)}$, $B^{(2)}$ и $B^{(3)}$ (на структуре не показаны) и входном векторе X при прямом проходе (*Forward Propagation*) реализуются вычисления:

$$\begin{aligned} h^{(1)} &= \sigma(W^{(1)}X + B^{(1)}); \\ h^{(2)} &= \sigma(W^{(2)}h^{(1)} + B^{(2)}); \\ y &= \sigma_{out}(W^{(3)}h^{(2)} + B^{(3)}), \end{aligned} \quad (1)$$

где σ , σ_{out} – соответствующие функции активации.

²Ракутько С. А., Медведев Г. В., Ракутько Е. Н., Гулин С. В. Светодиодный фитооблучатель: пат. на полезную модель №234599 Российская Федерация. № 2025105417: заявл. 10.03.2025; опубли. 03.06.2025. Бюл. №16. 10 с. URL: <https://www1.fips.ru/ofpstorage/Doc/IZPM/RUNWU1/000/000/000/234/599/ПМ-00234599-00001/document.pdf>

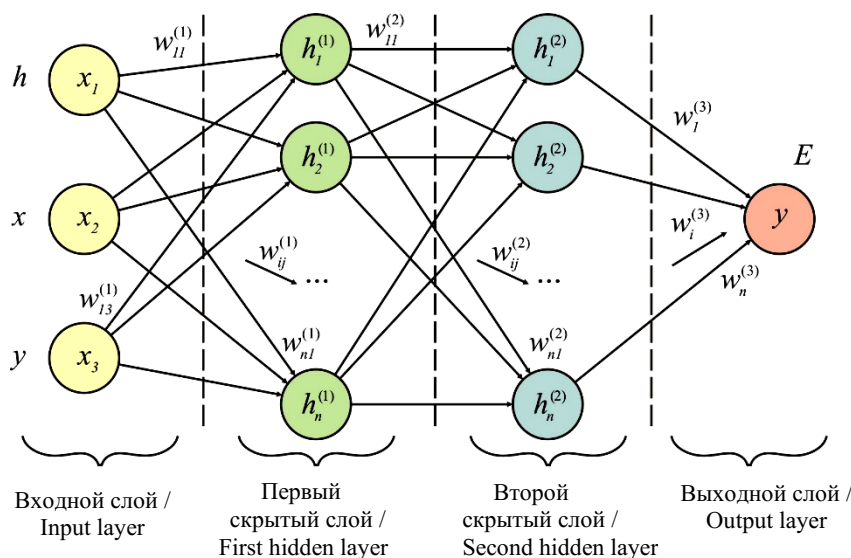


Рис. 3. Структура искусственной нейронной сети / Fig. 3. Structure of an artificial neural network

С помощью метрики средней абсолютной ошибки (*Mean Absolute Error, MAE*) определяли насколько в среднем (по n примерам в тестовом наборе) предсказания (E_i^{pred}) отличаются от реальных значений (E_i^{true}):

$$MAE = \frac{1}{n} \sum_{i=1}^n |E_i^{true} - E_i^{pred}|. \quad (2)$$

В качестве функции потерь принята средняя квадратичная ошибка (*Mean Squared Error, MSE*):

$$MSE = \frac{1}{n} \sum_{i=1}^n (E_i^{true} - E_i^{pred})^2. \quad (3)$$

Средняя ошибка предсказаний (*Mean Absolute Percentage Error, MAPE*) характеризует ошибку регрессии:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{E_i^{true} - E_i^{pred}}{E_i^{true}} \right| 100\%. \quad (4)$$

Основные фрагменты кода на языке программирования Python с применением библиотек TensorFlow и Keras рассмотрены ниже.

```
# Создание модели ИНС
model = keras.Sequential([
    layers.Dense(32, activation='relu', input_shape=(X_train_scaled.shape[1],)),
    layers.Dense(32, activation='relu'),
    layers.Dense(1) # Выходной слой (регрессия)])
```

Использован линейный стек слоёв (*Sequential*), где каждый слой имеет ровно один входной и один выходной тензор. Первый скрытый слой полносвязный (*Dense*): каждый его нейрон связан со всеми входами и всеми выходами. Количество нейронов в слое 32. Функция активации – *ReLU (Rectified Linear Unit)*, формула для вычислений – $f(x) = \max(0, x)$. Преимущества функции: устраняет проблему затухающих градиентов (по сравнению с *sigmoid/tanh*), вычислительно эффективна, придаёт нелинейность модели. Размерность входа задается для первого скрытого слоя. Последующие слои автоматически определяют свою входную размерность.

Второй скрытый слой имеет аналогичную первую архитектуру. Практика пока-

зывает, что использование одинакового количества нейронов в скрытых слоях часто работает хорошо. Выходной слой содержит один нейрон, т. к. предсказывается одно значение освещённости (E). Функция активации не используется, что позволяет модели предсказывать значения в любом диапазоне, решая задачу регрессии. Два скрытых слоя являются универсальным аппроксиматором (по теореме Цыбенко) [17] и подходят для большинства задач средней сложности. Принятые 32 нейрона на слой – разумный компромисс между скоростью обучения и мощностью модели. Функция *ReLU* является современным стандартом для скрытых слоёв и хорошо взаимодействует с оптимизатором *Adam (Adaptive Moment Estimation)*.

```
# Компиляция модели
model.compile(optimizer='adam', loss='mse', metrics=['mae'])
```

Этот метод конфигурирует модель перед обучением, задавая способ оптимизации (т. е. как обновлять веса), функцию потерь (критерий качества модели) и метрики для мониторинга (дополнительные показатели). Оптимизатор *Adam* – современный алгоритм оптимизации, учитывающий предыдущие градиенты для ускорения сходимости, адаптивно настраивающий скорости обучения (*learning rate*) для каждого параметра и эффективен при решении задач с регрессией. В коде оставлены параметры по умолчанию. Особенности принятой функции потерь *MSE*: сильно штрафует большие ошибки

(квадратичная зависимость); оптимальна для задач регрессии с нормальным распределением ошибок; чувствительна к выбросам. Метрикой принята *MAE*, особенностями которой являются линейная чувствительность к ошибкам, более легкая интерпретируемость (это средняя абсолютная ошибка в единицах целевой переменной), меньшая чувствительность к выбросам. При компиляции создаётся вычислительный граф, инициализируются весовые параметры, настраивается механизм обратного распространения ошибки, подготавливаются структуры для отслеживания метрик.

```
# Обучение модели
history = model.fit(
    X_train_scaled, y_train,
    validation_data=(X_test_scaled, y_test),
    epochs=100,
    batch_size=16,
    verbose=1)
```

Итеративное обучение модели на данных производится методом `fit()`, который возвращает объект `history` с информацией о процессе обучения. Параметры обучения следующие. Входные данные: `X_train_scaled` – нормализованные признаки обучения (масштабированные h , x , y); `y_train` – целевые значения освещённости (E). На этих данных происходит прямое распространение и вычисление градиентов. Валидационные данные: `X_test_scaled`, `y_test` – контрольный набор для объективной оценки качества, который не участвует в обучении, а используется только для оценки.

Он позволяет детектировать переобучение (когда `val_loss` растёт, а `train_loss` падает). Задано 100 эпох или итераций полного прохода по всем обучающим данным и размер `Batch size` (16), задающий количество образцов, обрабатываемых перед обновлением весов. Такое значение `Batch size` обеспечивает эффективную загрузку памяти и высокую скорость обработки без переполнения буфера в условиях обучения в среде `Google Colab`.

Задан уровень детализации вывода: прогресс-бар и метрики.

```
# Оценка модели
test_loss, test_mae = model.evaluate(X_test_scaled, y_test, verbose=0)
print(f"\nTest MAE: {test_mae:.2f}")
```

Метод `evaluate()` в ходе прямого распространения производит окончательную проверку качества модели на независимых тестовых

данных, а также возвращает значения потерь *MSE* и метрики *MAE*.

```
# Предсказания на тестовых данных
y_pred = model.predict(X_test_scaled).flatten()
```

Метод `predict()` производит получение предсказаний модели для новых данных, использует уже обученную модель (когда веса зафиксированы) и работает в режиме `inference` (только прямое распространение). Метод автоматически обрабатывает батчи (даже для больших данных), возвращает `numpy array`

с размерностью (`n_samples`, `n_outputs`) для регрессии с одним выходом – форма (`n_samples`, 1). Данные проходят через все слои сети: Нормализованные входы → `Dense(32, relu)` → `Dense(32, relu)` → `Dense(1)`. На каждом слое производится умножение на матрицу весов, добавление смещения (*bias*), применение

активации (для скрытых слоёв). Выходной слой даёт предсказание освещённости E .

Предварительную обработку и визуализацию данных проводили в Excel. Для построения и обучения ИНС использовали облачную среду Google Colab, предоставляющую бесплатный доступ к вычислительным ресурсам (GPU/TPU).

Результаты и их обсуждение. Зависимости освещенности от координат на горизонтальной поверхности при различной высоте подвеса $E(h, x, y)$ показаны на рисунке 4. Полученные трехмерные графики визуализируют пространственное распределение освещенности.

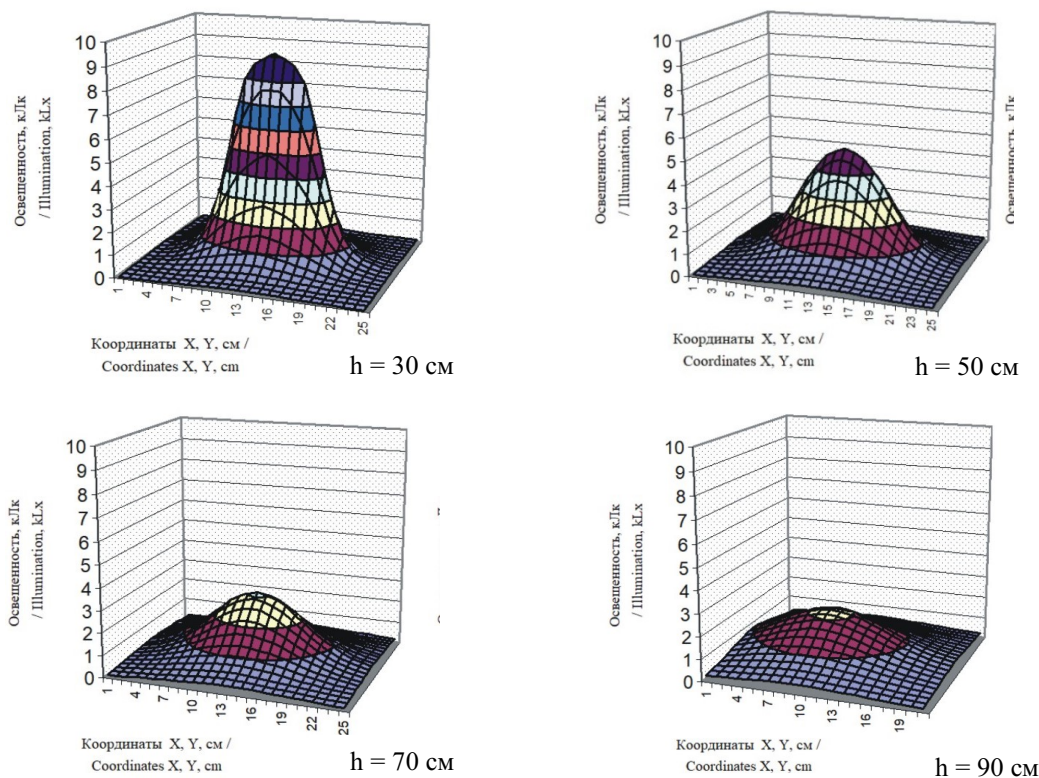


Рис. 4. Зависимость освещенности от высоты подвеса и координат / Fig. 4. Dependence of illumination on the suspension height and coordinates

Анализ трехмерных графиков зависимости освещенности от координат при различных высотах подвеса фитооблучателя позволил выявить следующие закономерности. С увеличением высоты подвеса наблюдается расширение зоны освещения, однако максимальная освещенность в центральной области снижается, что согласуется с общими принципами распределения потока по поверхности. На малых высотах подвеса формируется выраженный локальный максимум освещенности непосредственно под фитооблучателем, тогда как при больших высотах распределение более равномерно. Графики демонстрируют симметричное убывание освещенности от центра к периферии, что соответствует классической модели источника света с аксиальной симметрией. Полученные зависимости позволяют определить оптимальную высоту подвеса

фитооблучателя для заданных требований к создаваемой освещенности. Наблюдаемые минимальные значения освещенности в угловых зонах при практическом применении фитооблучателя указывают на необходимость корректировки их расположения или использования дополнительных источников света.

Зависимость максимальной освещенности от высоты подвеса фитооблучателя $E_{max}(h)$ показана на рисунке 5. Экспериментально установлено, что максимальная освещенность в точке проекции центра фитооблучателя убывает с увеличением высоты подвеса h по степенному закону.

Степенной характер убывания освещенности $E_{max} \sim h^{-1.3}$ (рис. 5) отличается от классического закона обратных квадратов $E_{max} \sim h^{-2}$, характерного для точечного источника света

в свободном пространстве, показателем степени при h . Высокое качество аппроксимации ($R^2 = 0,99$) свидетельствует о хорошем соответствии степенной модели экспериментальным данным. Различие в показателях степени указывает на отклонение от закона обратных

квадратов, вызванное тем, что на исследуемых высотах при габаритах фитооблучателя его нельзя считать точечным источником. Применение простых формул в данном случае невозможно и объясняет необходимость привлечения математического аппарата нейронных сетей.

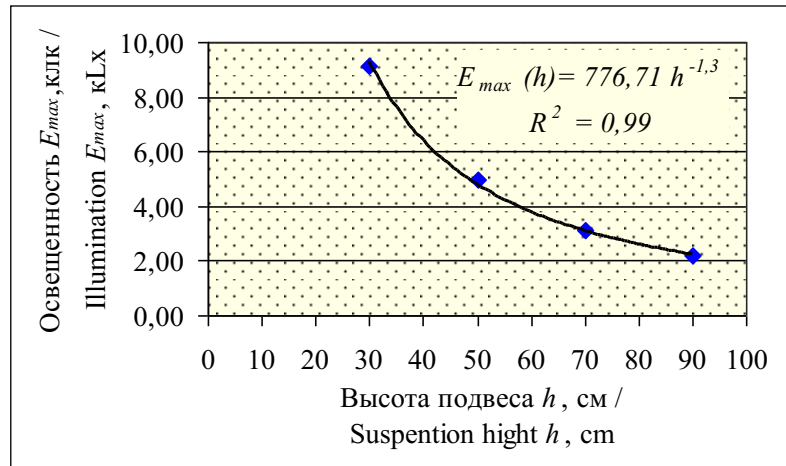


Рис. 5. Зависимость максимальной освещенности от высоты подвеса / Fig. 5. Dependence of maximum illumination on suspension height

На рисунке 6 представлены графики обучающих и валидационных потерь при работе ИНС, построенные в координатах: горизонтальная ось – номер эпохи (итерации

полного прохода по данным); вертикальная ось – значение функции потерь MSE . Графики показывают динамику изменения ошибки модели в процессе обучения.




Рис. 6. Обучающая и валидационная потери / Fig. 6. Training and validation loss




Рис. 7. Обучающая и валидационная ошибки / Fig. 7. Training and validation MAE

Форма построенных по результатам работы ИНС графиков обучающих и валидационных потерь типична для успешного обучения, когда наблюдается быстрое уменьшение потерь в начальных эпохах и далее происходит постепенное выравнивание кривых с приближением к минимуму, что указывает на сходимость. Данные графиков свидетельствуют о том, что модель не переобучается ($validation\ loss$ не начинает расти), данные хорошо разделены (нет существенной утечки

информации), принятая модель адекватна сложности задачи. Почти полное совпадение кривых говорит о том, что модель хорошо обобщает данные.

На рисунке 7 представлены графики обучающей и валидационной ошибки. Средняя абсолютная ошибка $MAE = 0,04$ клк. Форма графиков говорит о быстром улучшении точности в начальных эпохах, происходит постепенное приближение к оптимальной точности, что типично для успешно обучающейся модели.

Видны микроколебания в процессе тонкой настройки весов, что свойственно для стохастических оптимизаторов (таких, как *Adam*).

Разница в графиках обучающей и валидационной ошибок в пределах 5–15 % характерна для хорошо сбалансированных моделей. Резкий спад *MAE* в начальные эпохи говорит о том, что модель быстро усваивает основные закономерности. Совпадение кривых показывает, что модель одинаково хорошо работает




Рис. 8. Сопоставление фактических и предсказанных значений /
Fig. 8. True vs predicted values

График распределения ошибок предсказания приведен на рисунке 9. Форма распределения представляет собой узкий симметричный пик, свидетельствующий о нормальном распределении (как и ожидается для *MSE*), максимальная частота ошибок около нуля, быстрое убывание частоты при удалении от центра.

Большинство точек плотно группируется у диагональной линии, что свидетельствует о хорошей точности предсказаний модели. Концентрация точек наиболее высока в начале координат графика (небольшие значения освещенности) и постепенно уменьшается по мере удаления от него. Причина – большее количество примеров с низкими значениями освещенности в исходных данных (см. визуализацию на рис. 4). Следствием тому являются минимальные ошибки в области малых значений освещенности. Тем не менее модель успешно решает поставленную задачу, а неравномерность распределения точек скорее отражает особенности данных, чем проблемы модели.

Судя по графику распределения ошибок предсказания, большинство предсказаний достаточно точны. Диапазон ошибок ограничен интервалом от -0,2 до 0,2, что указывает на хорошую точность модели в абсолютных

на тренировочных и валидационных данных. В средней фазе модель переходит к тонкой настройке. Появляющееся различие между кривыми является естественным следствием обучения на тренировочных данных и признаком здорового баланса между обучением и обобщением.

На рисунке 8 фактические значения (*True Values*) сопоставляются с предсказанными (*Predicted Values*).




Рис. 9. График распределения ошибок предсказания /
Fig. 9. Prediction error distribution

величинах. Симметрия графика говорит об отсутствии систематического смещения (*under/over-prediction*). Это хорошо согласуется с другими метриками: низким значением *MAE* на валидационной выборке и соответствием данных на графике *True vs Predicted*. Распределение ошибок указывает на качественную модель, работающую в рамках ожиданий для задач регрессии. Узкий диапазон ошибок и симметричность распределения подтверждают адекватность выбранной архитектуры и процесса обучения.

Результаты моделирования показали, что архитектура ИНС подобрана достаточно удачно (2 слоя по 32 нейрона с *ReLU*). В условиях простой физически определенной закономерности формирования величины освещенности в трехмерной системе координат, низкого уровня шума в измерениях, применение нормализации, использование минимизирующей крупные ошибки метрики *MSE* удалось добиться *MAE* = 0,04 клк, что является неплохим результатом на уровне погрешности и воспроизводимости измерений люксметром. Набор параметров компиляции представляет собой сбалансированный выбор для большинства задач регрессии средней сложности, что подтверждается хорошими результатами

на графиках обучения. Параметры обучения модели соответствуют поставленной задаче – модель достигла сходимости без признаков переобучения, несмотря на относительно небольшой объем датасета (2100) по сравнению с количеством определяемых весов у нейронов (1217, по слоям: первый скрытый $32(3 + 1) = 128$, второй скрытый $32(32 + 1) = 1056$, выходной $1(32 + 1) = 33$). Принятый метод оценки модели даёт объективную оценку качества модели на независимых данных, что критически важно для доверия к результатам. В программном коде использованы лучшие практики, обеспечивающие четкое и эффективное выполнение поставленной задачи.

Значение коэффициента детерминации нейросетевой модели составляет $R^2 = 0,9967$ с 95%-м доверительным интервалом $[0,09953, 0,9977]$, что является хорошим результатом. Значение *MAPE* составляет 7,5 %, эта величина может быть улучшена путем регуляризации и аугментации данных. С учетом реальных условий точность модели можно считать приемлемой.

Заключение. Трехмерная визуализация освещенности подтверждает значимое влияние высоты подвеса на пространственное распределение света и предоставляет практический

инструмент для проектирования осветительных систем. Дальнейшие исследования могут быть направлены на учет многократных отражений и спектральных характеристик источников света. Полученная степенная зависимость максимальной освещенности от высоты хорошо описывает экспериментальные данные и отражает особенности реального фитооблучателя, который не может быть принят за точечный источник, распределение освещенности от которого описывается законом обратных квадратов. Указанное обстоятельство затрудняет применение традиционных методов расчета и объясняет необходимость привлечения математического аппарата ИНС.

Найденные параметры ИНС позволяют определить значение освещенности от фитооблучателя при любой комбинации высоты подвеса и координат расчетной точки на плоскости, что может быть использовано для инженерных расчетов при проектировании облучательной установки в светокультуре на базе испытываемого фитооблучателя. Разработанная методика после переобучения сети на новых данных позволяет проводить расчеты фитооблучателей произвольных размеров и конструктивных решений.

Список литературы

1. Панарин В. М., Гришаков К. В., Маслова А. А., Гришакова О. В., Архипов А. В. Применение искусственных нейронных сетей в инженерно-технических и экологических разработках. Известия Тульского государственного университета. Технические науки. 2022;(4):278–284. DOI: <https://doi.org/10.24412/2071-6168-2022-4-278-284> EDN: WDNKXE
2. Кутырёв А. И., Филиппов Р. А. Применение сверточной нейронной сети для мониторинга состояния земляники садовой. Аграрная наука Евро-Северо-Востока. 2023;24(4):685–696. DOI: <https://doi.org/10.30766/2072-9081.2023.24.4.685-696> EDN: EZQZKS
3. Черепенин В. А., Кацупеев А. А. Анализ подходов к созданию системы «Умная теплица» на основе нейронной сети. Программные системы и вычислительные методы. 2024;(1):68–78. DOI: <https://doi.org/10.7256/2454-0714.2024.1.69794> EDN: XAZVOW
4. Смирнов А. В., Тищенко И. П. Применение Сиамских нейронных сетей для классификации биомассы растений по визуальному состоянию. Программные системы: теория и приложения. 2024;15(3(62)):53–74. DOI: <https://doi.org/10.25209/2079-3316-2024-15-3-53-74> EDN: RATGTW
5. Воробьев Н. И., Лысов А. К., Корнилов Т. В., Хютти А. В. Вычислительная нейросеть для обработки светоотражательных спектров растений и дистанционного фитосанитарного мониторинга картофеля. Аграрная наука Евро-Северо-Востока. 2024;25(2):283–292. DOI: <https://doi.org/10.30766/2072-9081.2024.25.2.283-292> EDN: KUSISD
6. Сорокин М. И. Использование свёрточных нейронных сетей для классификации видов искусственного освещения. Аллея науки. 2018;3(6(22)):1008–1011. Режим доступа: <https://elibrary.ru/item.asp?id=35326748> EDN: XULOAP
7. Lork C., Cubillas M., Kiat Ng B. K., Yuen C., Tan M. Minimizing Electricity Cost through Smart Lighting Control for Indoor Plant Factories. IECON 2020 The 46th Annual Conference of the IEEE Industrial Electronics Society. 2020. DOI: <https://doi.org/10.1109/iecon43393.2020.9255061>
8. Ерсой Ыылмаз А., Розовский Е. И. Нейросетевое моделирование зависимости цветовой температуры освещения от источника света и оптической системы светильника. Светотехника. 2017;(1):49–54. Режим доступа: <https://elibrary.ru/item.asp?id=28777660> EDN: YFTNAT
9. Kazanasmaz T., Günaydin M., Binol S. Artificial neural networks to predict daylight illuminance in office buildings. Building and Environment. 2009;44(8):1751–1757. DOI: <https://doi.org/10.1016/j.buildenv.2008.11.012>

10. Dudzik M., Dechnik M., Furtak M. Application of neural networks to lighting systems. MATEC Web of Conferences. 2019;282(2):02069. DOI: <https://doi.org/10.1051/mateconf/201928>
11. Бородулин Д. М., Шафрай А. В., Максименко А. А. Применение нейронной сети для управления системой домашней гидропоники. Техника и технология пищевых производств. 2023;53(2):384–395. DOI: <https://doi.org/10.21603/2074-9414-2023-2-2440> EDN: THVKNB
12. Zhang Y., Li S. Study on Illumination Measurement Method of Lighting Environment Based on RBF Neural Network. Journal of Physics: Conference Series. 2022;2196(1):012004. DOI: <https://doi.org/10.1088/1742-6596/2196/1/012004>
13. Семенова Н. Г., Валиуллин К. Р. Интеллектуальная система энергоэффективного управления уличным освещением на основе нейросетевых технологий. Вестник Оренбургского государственного университета. 2015;(4(179)):183–188. Режим доступа: <https://elibrary.ru/item.asp?id=24097618> EDN: UHINQP
14. Егоров А. Д., Павлюченко Д. А. Применение искусственных нейронных сетей при проектировании электрического освещения. Энергетик. 2020;(11):21–25. Режим доступа: <https://elibrary.ru/item.asp?id=44236455> EDN: MGYYVH
15. Ракутько С. А., Ракутько Е. Н. Оценка равномерности поверхностного распределения потока излучения как фактора энергоэффективности светокультуры. Инженерные технологии и системы. 2021;31(3):470–486. DOI: <https://doi.org/10.15507/2658-4123.031.202103.470-486> EDN: XLLAUS
16. Ракутько С. А., Ракутько Е. Н., Васькин А. В. Влияние компоновочных параметров облучательной установки на энергоэкологичность светокультуры. АгроЭкоИнженерия. 2021;(3(108)):33–51. DOI: <https://doi.org/10.24412/2713-2641-2021-3108-33-50> EDN: RHFSXY
17. Галкин В. А., Гавриленко Т. В., Смородинов А. Д. Некоторые аспекты аппроксимации и интерполяции функций искусственными нейронными сетями. Вестник КРАУНЦ. Физико-математические науки. 2022;38(1):54–73. DOI: <https://doi.org/10.26117/2079-6641-2022-38-1-54-73> EDN: JTZQQZ

References

1. Panarin V. M., Grishakov K. V., Maslova A. A., Grishakova O. V., Arkhipov A. V. Application of artificial neural networks in engineering and environmental developments. *Izvestiya Tl'skogo gosudarstvennogo universiteta. Tekhnicheskiye nauki*. 2022;(4):278–284. (In Russ.). DOI: <https://doi.org/10.24412/2071-6168-2022-4-278-284>
2. Kutyrev A. I., Filippov R. A. Application of convolutional neural network for monitoring the condition of strawberries. *Agrarnaya nauka Evro-Severo-Vostoka = Agricultural Science Euro-North-East*. 2023;24(4):685–696. (In Russ.). DOI: <https://doi.org/10.30766/2072-9081.2023.24.4.685-696>
3. Cherepenin V. A., Katsupeyev A. A. Analysis of approaches to creating a "Smart greenhouse" system based on a neural network. *Programmniye sistemi i vichislitelniye metodi = Software Systems and Computational Methods*. 2024;(1):68–78. (In Russ.). DOI: <https://doi.org/10.7256/2454-0714.2024.1.69794>
4. Smirnov A. V., Tishchenko I. P. Application of siamese neural networks to classify plant biomass by visual state. *Programmniye sistemi: teoriya i prilozheniya = Program Systems: Theory and Applications*. 2024;15(3(62)):53–74. (In Russ.). DOI: <https://doi.org/10.25209/2079-3316-2024-15-3-53-74>
5. Vorobyov N. I., Lysov A. K., Kornilov T. V., Hyutti A. V. Computational neural network for processing light-reflective spectra of plants and remote phytosanitary monitoring of potatoes. *Agrarnaya nauka Evro-Severo-Vostoka = Agricultural Science Euro-North-East*. 2024;25(2):283–292. (In Russ.). DOI: <https://doi.org/10.30766/2072-9081.2024.25.2.283-292>
6. Sorokin M. I. Using convolutional neural networks to classify types of artificial lighting. *Alleya nauki*. 2018;3(6(22)):1008–1011. (In Russ.). URL: <https://elibrary.ru/item.asp?id=35326748>
7. Lork C., Cubillas M., Kiat Ng B. K., Yuen C., Tan M. Minimizing Electricity Cost through Smart Lighting Control for Indoor Plant Factories. IECON 2020 The 46th Annual Conference of the IEEE Industrial Electronics Society. 2020. DOI: <https://doi.org/10.1109/iecon43393.2020.9255061>
8. Yersoy Yilmaz A., Rozovsky E. I. Neural network modeling of the dependence of the color temperature of lighting on the light source and the optical system of the lamp. *Svetotekhnika = Light & Engineering*. 2017;(1):49–54. (In Russ.). URL: <https://elibrary.ru/item.asp?id=28777660>
9. Kazanasmaz T., Günaydin M., Binol S. Artificial neural networks to predict daylight illuminance in office buildings. *Building and Environment*. 2009;44(8):1751–1757. DOI: <https://doi.org/10.1016/j.buildenv.2008.11.012>
10. Dudzik M., Dechnik M., Furtak M. Application of neural networks to lighting systems. MATEC Web of Conferences. 2019;282(2):02069. DOI: <https://doi.org/10.1051/mateconf/201928>
11. Borodulin D. M., Shafray A. V., Maksimenko A. A. Neural network and home hydroponics. *Tekhnika i tekhnologiya pishchevikh proizvodstv = Food Processing: Techniques and Technology*. 2023;53(2):384–395. (In Russ.). DOI: <https://doi.org/10.21603/2074-9414-2023-2-2440>
12. Zhang Y., Li S. Study on Illumination Measurement Method of Lighting Environment Based on RBF Neural Network. Journal of Physics: Conference Series. 2022;2196(1):012004. DOI: <https://doi.org/10.1088/1742-6596/2196/1/012004>

13. Semenova N. G., Valiullin K. R. Intelligent energy-efficient street lighting control system based on neural network technology. *Vestnik Orenburgskogo gosudarstvennogo universiteta* = Vestnik of the Orenburg State University. 2015;(4(179)):183–188. (In Russ.). URL: <https://elibrary.ru/item.asp?id=24097618>

14. Egorov A. D., Pavlyuchenko D. A. Design of electric lighting using artificial neural networks. *Energetik*. 2020;(11):21–25. (In Russ.). URL: <https://elibrary.ru/item.asp?id=44236455>

15. Rakutko S. A., Rakutko E. N. Assessment of lighting uniformity as a factor of energy efficiency in greenhouse horticulture. *Inzhenerniye tekhnologii i sistemi* = Engineering Technologies and Systems. 2021;31(3):470–486. (In Russ.). DOI: <https://doi.org/10.15507/2658-4123.031.202103.470-486>

16. Rakutko S. A., Rakutko E. N., Vaskin A. V. Effect of lighting fixtures spatial arrangement on energy and ecological performance of greenhouse horticulture. *AgroEkoInzheneriya* = AgroEcoEngineering. 2021;(3(108)):33–51. (In Russ.). DOI: <https://doi.org/10.24412/2713-2641-2021-3108-33-50>

17. Galkin V. A., Gavrilenko T. V., Smorodinov A. D. Some aspects of approximation and interpolation of functions artificial neural networks. *Vestnik KRAUNTs. Fiziko-matematicheskoye nauki* = Bulletin KRASEC. Physical and Mathematical Sciences. 2022;38(1):54–73. (In Russ.). DOI: <https://doi.org/10.26117/2079-6641-2022-38-1-54-73>

Вклад авторов: Ракутько С. А. – концепция и план исследования, анализ данных. Ракутько Е.Н. – анализ данных, подготовка рукописи.

Сведения об авторах

✉ **Ракутько Сергей Анатольевич**, доктор техн. наук, доцент, главный научный сотрудник отдела агроэкологии в животноводстве, Институт агроинженерных и экологических проблем сельскохозяйственного производства – филиал ФГБНУ «Федеральный научный агроинженерный центр ВИМ», Филътровское ш., д. 3, п. Тярлево, Санкт-Петербург, Российская Федерация, 196634, e-mail: nii@sznii.ru, ORCID: <https://orcid.org/0000-0002-2454-4534>, e-mail: sergej1964@yandex.ru

Ракутько Елена Николаевна, научный сотрудник отдела агроэкологии в животноводстве, Институт агроинженерных и экологических проблем сельскохозяйственного производства – филиал ФГБНУ «Федеральный научный агроинженерный центр ВИМ», Филътровское ш., д. 3, п. Тярлево, Санкт-Петербург, Российская Федерация, 196634, e-mail: nii@sznii.ru, ORCID: <https://orcid.org/0000-0002-3536-9639>

Author contributions: Rakutko S. A. – research plan and concept, data analysis. Rakutko E. N. – data analysis, preparation of the manuscript.

Information about the authors

✉ **Sergei A. Rakutko**, DSc in Engineering, associate professor, chief researcher, the Department of Agroecology in Livestock Production, Institute for Engineering and Environmental Problems in Agricultural Production – branch of Federal Scientific Agroengineering Center VIM, 3, Filtrovskoye Shosse, Tyarlevo settlement, Saint Petersburg, Russian Federation, 196634, e-mail: nii@sznii.ru, ORCID: <https://orcid.org/0000-0002-2454-4534>, e-mail: sergej1964@yandex.ru

Yelena N. Rakutko, researcher, the Department of Agroecology in Livestock Production, Institute for Engineering and Environmental Problems in Agricultural Production (IIEP) – branch of Federal Scientific Agroengineering Center VIM, 3, Filtrovskoye Shosse, Tyarlevo settlement, Saint Petersburg, Russian Federation, 196634, e-mail: nii@sznii.ru, ORCID: <https://orcid.org/0000-0002-3536-9639>

✉ – Для контактов / Corresponding author