

Программные системы и вычислительные методы

Правильная ссылка на статью:

Черепенин В.А., Кацупеев А.А. Анализ подходов к созданию системы «Умная теплица» на основе нейронной сети // Программные системы и вычислительные методы. 2024. № 1. DOI: 10.7256/2454-0714.2024.1.69794

EDN: XAZVOW URL: https://nbpublish.com/library_read_article.php?id=69794

Анализ подходов к созданию системы «Умная теплица» на основе нейронной сети

Черепенин Валентин Анатольевич

ORCID: 0000-0002-6310-1939

аспирант, кафедра Информационные и измерительные системы и технологии, Южно-Российский государственный политехнический университет (НПИ) имени М.И. Платова

346428, Россия, Ростовская область, г. Новочеркасск, ул. Просвещения, 132

✉ cherept2@gmail.com



Кацупеев Андрей Александрович

кандидат технических наук

доцент, кафедра Информационные и измерительные системы и технологии, Южно-Российский государственный политехнический университет (НПИ) имени М.И. Платова

346428, Россия, Ростовская область, г. Новочеркасск, ул. Просвещения, 132

✉ andreykatsupееv@gmail.com



[Статья из рубрики "Системный анализ, поиск, анализ и фильтрация информации"](#)

DOI:

10.7256/2454-0714.2024.1.69794

EDN:

XAZVOW

Дата направления статьи в редакцию:

08-02-2024

Аннотация: Исследование затрагивает важную тему разработки и внедрения интеллектуальных систем в агропромышленном производстве, фокусируясь на создании "Умной теплицы" с применением нейронных сетей. В работе детально анализируются ключевые технологические инновации и их роль в устойчивом сельском хозяйстве. Особое внимание уделяется изучению методов сбора, обработки и анализа данных для оптимизации условий выращивания растений. Рассматриваются вопросы эффективности

использования ресурсов, контроля влажности, температуры, уровня углекислого газа и освещённости, а также автоматизация полива и подачи удобрений. Особое внимание уделяется созданию адаптивных алгоритмов для прогнозирования оптимальных условий, повышающих урожайность и качество сельскохозяйственной продукции, при одновременном снижении экологического воздействия и затрат. Это открывает новые перспективы для устойчивого развития аграрного сектора, способствуя более эффективному и экологически чистому сельскому хозяйству. Исследование реализовано с использованием аналитического обзора литературы, сравнительного анализа существующих решений и моделирования работы нейронных сетей для предсказания оптимальных условий выращивания. Исследование представляет собой значительный вклад в область применения искусственного интеллекта для управления микроклиматом в теплицах, демонстрируя возможности нейронных сетей в автоматизации агропромышленных процессов. Анализируются перспективы использования ИИ для предсказания и оптимизации условий выращивания, что может привести к революционным изменениям в сельском хозяйстве. Выявленные научные новизны включают разработку и тестирование алгоритмов прогнозирования, способных адаптироваться к меняющимся внешним условиям, и обеспечивать максимальную продуктивность при минимальных затратах ресурсов. Выводы исследования подчеркивают важность дальнейшего изучения и внедрения интеллектуальных систем в агропромышленности, указывая на их потенциал в увеличении урожайности и улучшении качества продукции при одновременном снижении экологического воздействия. В заключении, авторы оценивают перспективы применения нейронных сетей в агропромышленном секторе и рассматривают возможные пути дальнейшего развития "Умных теплиц".

Ключевые слова:

интернет вещей, теплица, биотехнология, глубокое обучение, гибридная нейронная сеть, микроклимат, алгоритм оптимизации, нейронные сети, Умная теплица, Анализ подходов

Введение

С развитием технологий интернета вещей (далее *IoT*) и искусственного интеллекта (ИИ) системы «Умная теплица» становятся важным направлением в современном сельском хозяйстве. Эффективное использование ресурсов, оптимальный контроль климата и автоматизация процессов выращивания растений предоставляют сельскохозяйственным предприятиям новые возможности для повышения урожайности и снижения затрат. В данной статье проводится обзор существующих подходов к созданию системы «Умная теплица», с акцентом на использование нейронных сетей. Исследование направлено на выявление ключевых аспектов и преимуществ, которые предоставляют нейронные сети в контексте управления тепличным климатом. Рассматриваются методы сбора и анализа данных, внедрение сенсорных технологий, а также алгоритмы обработки информации с применением нейронных сетей для оптимизации условий роста растений. Этот обзор предоставляет комплексное понимание современного состояния технологий «Умной теплицы» и выделяет перспективы дальнейших исследований в данной области.

Исследование и сравнение методов климат-контроля в теплицах

Климат в теплице основан на условиях окружающей среды, необходимых растениям для

жизни. Микроклимат теплицы очень сложный, нелинейный, многопараметрический, и зависит от набора внутренних и внешних факторов, включая метеорологические факторы, такие как влажность и температура окружающей среды, интенсивность солнечного излучения, скорость и направление ветра.

Составляющие теплицы — это внутренние факторы, различные сельскохозяйственные культуры, компоненты теплицы и такие элементы, как запотевание, отопление, вентиляционные системы, типы почвы и т.д. Различное описание тепличного климата объясняется в двух подходах: один основан на уравнениях массового расхода энергии, которые описывают процесс. Другой использует подход системной идентификации, состоящий из исследования как входных, так и выходных данных процесс [\[1\]](#). Таким образом, данные подходы созданы для решения всех проблем микроклимата на основе современных методов адаптивных и нелинейных систем. Для достижения заранее определенных и оптимальных результатов климат-контроль в теплицах создает благоприятную среду для выращивания. Для управления окружающей средой теплицы было предложено несколько стратегий и методов управления, таких как адаптивное управление, прогнозирующее управление, нечеткая логика управления, надежное управление, нелинейное управление с обратной связью и оптимальное управление. Было проведено множество исследований, в которых ведется поиск экономии энергии, где применяются методы оптимизации сбора энергии, физические модели и методы вычислительной гидродинамики для прогнозирования микроклимата теплиц [\[2, 3\]](#).

Эти методы прогнозирования делятся на две группы:

1. Физический метод.
2. Метод черного ящика.

Первый метод основан на математической теории, которая необходима для регулирования огромного количества параметров, и расчет этих параметров затруднен. Метод черного ящика основан на современных вычислительных технологиях, которые не всегда обеспечивают сходимость к оптимальному решению и даже легко проходят частичную оптимизацию.

С другой стороны, нейронные сети, в отличие от запрограммированных, учатся реализовывать все закономерности. Эти тепличные системы очень уместны для отражения знаний, которые нельзя запрограммировать для представления нелинейных явлений [\[4\]](#).

Обучение и применение нейронных сетей в сельском хозяйстве

Поскольку теплицы неизменны во времени, нелинейны и имеют сильную связь, проводится множество исследований, чтобы выбрать искусственные нейронные сети (далее *ANN*) для моделирования, оптимизации, прогнозирования и управления всеми этими процессами. В этом разделе рассматриваются все различные приложения и исследования *ANN* в области тепличных технологий. Разработка модели этого типа, в будущем расширит возможности ее применения и объединится с технологиями, которые востребованы в интеллектуальном сельском хозяйстве. На рис. 1 показывается классификация моделей различных теплиц.



Рис. 1. – Классификация моделей теплицы

ANN — это алгоритм машинного обучения, основанный на анализе и понимании человеческого нейрона. Это вычислительная модель с биологическим влиянием, состоящая из обрабатывающих элементов (нейронов) и взаимосвязей между ними с коэффициентами, обычно называемыми весами [5].

Нейроны получают входные данные в виде импульса. Некоторыми мерами, используемыми для описания активности нейронов, являются пиковая скорость, создаваемая с течением времени, и средняя пиковая генерация в нескольких прогонах. Нейрон распознается по скорости, с которой он производит пики. С помощью адаптивных синаптических весов нейроны связаны с другими нейронами предыдущего слоя. В наборе весов соединения обычно хранятся знания. Процесс обучения выявляет подходящий метод обучения, когда эти веса соединений изменяются соответствующим образом. Эти методы обучения содержат входные данные для сети и генерируют желаемый результат путем изменения весов для получения идеального результата. По мере обучения методы веса будут иметь соответствующую информацию по сравнению с предыдущим обучением, поскольку он содержит всю избыточную и бессмысленную информацию [6].

В нейронных сетях обучение является важной частью. Обучение модели нейронной сети — это процесс настройки весов и смещений сети таким образом, чтобы она могла точно предсказать выходные данные для заданных входных данных. Это делается путем многократного представления сети примеров входных и выходных данных, а затем корректировки весов и смещений таким образом, чтобы прогнозы сети становились более точными. Процесс обучения повторяется много раз до тех пор, пока модель не сойдется, что означает, что ошибка больше не уменьшается значительно. Количество повторений процесса обучения называется количеством эпох. Этот процесс определит связь ввода и вывода, поскольку для этого требуется наиболее точный прогнозирующий расчет. Этот процесс обучения подразделяется на две категории:

1. Под наблюдением;
2. Без присмотра.

Обучение под наблюдением воспринимает ожидаемые результаты и маркирует данные. При неконтролируемом обучении не обязательно воспринимать данные, так как обучение осуществляется посредством определения местоположения представления данных и

внутренних структур.

Структура сети зависит от типа описываемой задачи, сложности системы и процесса обучения. В таблице №1 показаны различные виды нейронных моделей, подробно описаны входные и выходные переменные, которые использовались, архитектура сети, функции активации, которые использовались сетью или каждым уровнем сети, и алгоритм, используемый в тренировочный процесс [\[7\]](#).

Таблица №1. Типы нейросетевых моделей для прогнозирования

№ Модели	Входные переменные	Выходные переменные	Тип	Функции активации	Метод обучения	% оц
1	Наружная температура; Наружная влажность; Скорость ветра; Солнечная радиация;	Внутренняя температура; Внутренняя влажность	<i>FFNN</i>	Передаточная функция Гаусса для скрытого слоя	Обратное распространение градиентного спуска (далее <i>BP</i>)	5.0
2	Температура наружного воздуха; Наружная влажность; Скорость ветра; Солнечная радиация; Температура воздуха внутри	Внутренняя влажность	<i>FFNN</i>	Сигмовидная передаточная функция для скрытого слоя	<i>BP</i>	15
3	Температура наружного воздуха; Солнечное излучение; Влажность внутри помещения	Внутренняя температура	<i>FFNN</i>	Сигмовидная передаточная функция для скрытого слоя	Ортогональный метод наименьших квадратов	20
4	Внешняя температура; Внешняя гигрометрия; Глобальный радиант;	Внутренняя температура; Внутренняя гигрометрия	<i>RNN</i>	Сигмовидная функция для скрытого слоя	Метод обучения с учителем	20

	Скорость ветра					
5	Внешняя температура; Внешняя гигрометрия; Обогрев; Сдвижной затвор в градусах; Опрыскиватель	Внутренняя температура; Внутренняя гигрометрия	<i>RNN</i>	Сигмовидная функция для скрытого и выходного слоев	Глубокое обучение, где использовался алгоритм <i>BP</i>	30
6	Внешняя температура; Внешняя влажность; Внутренняя температура; Внутренняя влажность	Внутренняя температура; Внутренняя влажность	<i>NNARX</i>	Функция гиперболического тангенса для скрытого слоя	Левенберг-Марквардт	25

Обучение нейронной сети сводится к минимизации функции ошибки, путем корректировки весовых коэффициентов синоптических связей между нейронами. Под функцией ошибки понимается разность между полученным ответом и желаемым. Для нейронов выходного слоя известны их фактические и желаемые значения выходов. Поэтому настройка весов связей для таких нейронов является относительно простой [8]. Однако для нейронов предыдущих слоев настройка не столь очевидна. Долгое время не было известно алгоритма распространения ошибки по скрытым слоям. Величина ошибки определяется по следующей формуле:

$$E_p = \frac{1}{2} \sum_j (t_{pj} - y_{pj})^2,$$

где E_p – величина функции ошибки для образа p ; t_{pj} – желаемый выход нейрона j для образа p ; y_{pj} – активированный выход нейрона j для образа p .

Метод обучения с учителем включает в себя сокращение функции стоимости, которая собирает ошибки между желаемыми выходными данными и фактическими выходными данными для заданных входных данных. Чтобы уменьшить эту функцию стоимости, используется несколько методов. Алгоритм *BP* является одним из наиболее часто используемых для получения результатов в однослойных и многослойных сетях. Алгоритм предназначен для самоорганизации *ANN* и получен по закону Хебба. Выявленные методы обучения позволили разработать продвинутые алгоритмы, такие как самоорганизующиеся карты (далее *S.O.M.*) и самоорганизующийся древовидный алгоритм (далее *SOTA*). Основанные на неконтролируемых данных, это алгоритмы кластеризации временных рядов. Для визуализации и кластеризации данных используется инструмент *S.O.M.* Основным недостатком этого инструмента является то, что пользователю необходимо выбирать размер карты, что приводит к многочисленным экспериментам с картами разного размера в попытке получить оптимальный результат.

Этот процесс может быть довольно медленным. Более точная классификация паттернов в последнем слое *SOTA* позволит классифицировать на начальных этапах группу паттернов, отделенных друг от друга. Используя методы *SOTA*, нейронные сети могут быть построены автоматически из доступных обучающих данных.

Согласно этим методам применения и обработки инструментов, переменные, связанные с климатом для теплицы, имеют решающее значение. Некоторые параметры, такие как расчет скорости, прогнозирование поведения точности и управление переменными различными элементами, остаются огромной проблемой. Используя некоторые нелинейные методы, искусственные нейронные сети в значительной степени решают эти задачи.

Оптимизация микроклимата в теплицах с использованием нейронных сетей

Для достижения контролируемого сельскохозяйственного производства, теплицы представляют собой нелинейные и сложные системы. Эти системы имеют внутренние факторы, составной динамический импульс внешних факторов и механизмы управления. Основанный на микроклимате и управлении тепличными культурами, он выступает центральным элементом и важнейшей частью системы. Эта система, как правило, учитывает некоторые общие вопросы, которые являются более важными реакциями микроклимата, поскольку он представляет собой комплекс и разнообразие культур в теплице. Тепличная система в основном фокусируется на наборе окружающей среды, которая влияет на развитие и рост сельскохозяйственных культур. Система микроклимата в теплицах в последние годы привлекла к себе пристальное внимание из-за значительного вклада в улучшение урожайности. Для прогнозирования различных элементов, таких как количество CO_2 , температуры и относительной влажности воздуха, в систему внедрили статистику, инженерию и искусственный интеллект.

В тепличной системе используется обычный контроль, чтобы гарантировать желаемую производительность, но этот контроль может быть неудовлетворительным. В последнее время интерес вызывает тема применения нейронных сетей для управления микроклиматом. Чтобы отразить нелинейные характеристики, нейросеть предоставляет все надежные модели для теплицы, поскольку с помощью традиционных методов трудно решить, поскольку надежные модели не требуют каких-либо предварительных знаний о системе, в режиме реального времени модель вполне удовлетворительно работает для динамических систем [\[9\]](#).

Наиболее важными атрибутами в системе микроклимата теплицы являются влажность и температура. В окружающей среде может происходить сложный газообмен, а также взаимодействие между массой, теплом и внутренним воздухом, а также некоторыми элементами теплицы с внешней стороны. Построение надежной модели — очень сложная задача, поскольку она должна выполнять все параметры, математические функции и функции преобразования [\[10\]](#). Когда мы строим модель с помощью *ANN*, видим большие возможности для отображения всех нелинейных функций для создания многочисленных систем производственных процессов. Чтобы построить модель, нужно спроектировать сеть системы, такую как влажность и температура воздуха в теплицах, которые рассматриваются как выходные данные; это вызвано некоторыми фактами. Для модели самое сложное — установить входные данные, чтобы лучше понять систему. Для рассмотрения входной переменной в системе необходимо следовать следующим соображениям:

1. Характер физической зависимости входа и выхода.

2. Корреляция между входами и выходами.

3. Диапазон переменных входа.

Входными переменными системы являются внутренняя относительная влажность воздуха, внутренняя температура, внутреннее атмосферное давление, внешняя температура, внешнее атмосферное давление, внешняя температура, скорость и направление ветра. Выходной переменной системы является CO_2 . Во всех слоях используется передаточная функция. 0,97 коэффициента получено с использованием прогноза концентрации CO_2 . Искусственная нейронная сеть должна быть обучена в соответствии со всеми возможными ситуациями и измеримыми объектами, чтобы получить уникальный результат с ограниченными данными [11].

Для правильного функционирования нейронной сети требуется база данных. В данном разделе описано множество моделей, в которых эти искусственные нейронные сети используются для прогнозирования микроклимата тепличной системы, а оптимизация сети связана с ее структурой и типом. Поскольку для модели требуются обучающие данные, сбор данных является одним из ключевых моментов, который имеет одинаковое значение для системы для эффективного вывода. В каждой базе данных будет три общих этапа, таких как тестирование, обучение и проверка. Эти фазы необходимо учитывать в каждой нейронной сети. Модель Бэкбокса требует огромного количества данных в *ANN* [12, 13]. Необязательная сумма в модели черного ящика — это метод проб и ошибок, который выбирает скрытый слой и нейроны. Поскольку рассматриваем огромный объем данных для получения точного вывода, это приводит к снижению эффективности процесса. Некоторые методы применяются к модели с огромными данными, которые можно упростить и оптимизировать процесс обучения *N.N.* База данных за 12 месяцев является идеальной для *ANN* для прогнозирования нейронной сети теплицы, которая имеет огромное количество данных. Была выбрана модель в течение 29 дней: 22 дня фазы обучения и 7 дней фазы тестирования. Модель считалась фазами, разделенными на 15% для проверки, 15% для тестирования и 70% для обучения сети. На основе модели и требований считается, что период дает точный результат. Рис. 2 показывает прогноз микроклимата теплицы в искусственной нейронной сети.

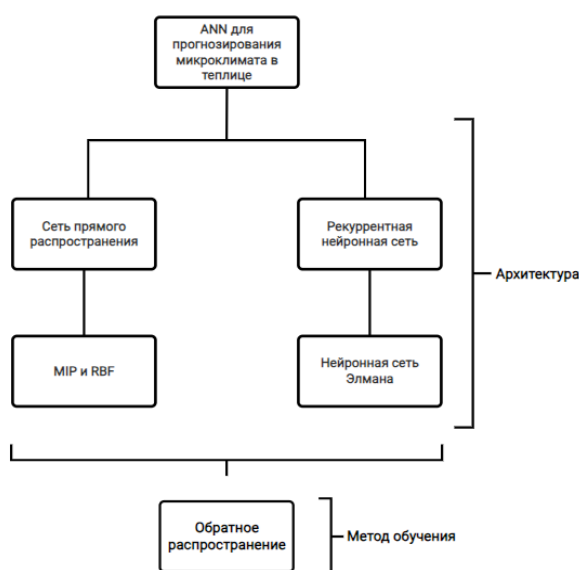


Рис. 2. - Прогноз микроклимата теплицы в искусственной нейронной сети

Заключение

В отличие от физических моделей, *ANN* требуется всего несколько минут, чтобы завершить прогноз климата в помещении, учитывая, что задействовано много неизвестных факторов, которые невозможно изучить с помощью физических моделей. Комбинация *ANN* и физических моделей позволила бы лучше прогнозировать микроклимат, однако конструкция этой гибридной сети мало изучена и, следовательно, эта сеть должна быть изучена. В рамках других приложений нейронных сетей в теплицах оценка и прогнозирование эпидемий и болезней сельскохозяйственных культур может осуществляться с помощью таких технологий, как анализ изображений в сочетании с моделями глубокого обучения, такими как *CNN*. Точно так же с помощью этих методов может быть осуществимо прогнозирование микроклимата, поскольку эти методы могут обрабатывать больший объем информации по сравнению с традиционными моделями *ANN*. Роль *ANN* заключается в разработке прогностических моделей, использующих преимущества генерируемой информации и управления ею.

Библиография

1. Taki, M. "Solar thermal modeling and application in greenhouses" / M. Taki, A. Rohani, M. Rahmati-Joneidabad // Info Proc Agri, 5 (2018), pp. 83-113.
DOI:10.1016/J.inpa.2017.10.003.
2. Huihui, Yu "Temperature prediction in a Chinese solar greenhouse based on LS-SVM optimized with improved PSO" / Huihui Yu, Yinyi Chen, Shahbaz Gul Hassan, Daoliang Li // Comput Electron Agric, 122 (2016), pp. 94-102.
DOI:10.1016/J.compag.2016.01.019.
3. Taki, M. "The relationship of energy and yield costs and sensitivity analysis for growing tomatoes in greenhouses in Iran" / M.Taki, R.Abdi, M.Akbarpour, H.Ghasemi-Mobtaker // Agric Eng Int: CIGR J, 15 (2013), pp. 59-67. ISSN:16821130.
4. Abdel Ghani, A.M. "The use of solar energy by greenhouses: general relations" / A.M. Abdel Ghani, I.M. Helal // Renewable Energy, 36 (2011), pp. 189-196.
DOI:10.1016/j.renene.2010.06.020.
5. Nielsen, H. "Identification of transfer functions for regulating air temperature in a greenhouse" / H.Nielsen, P.Madsen // J Agric Eng Res, 60 (1995), pp. 25-34.
DOI:10.1006/jaer.1995.1093.
6. Dariushi, E. "Labyrinth prediction of internal parameters of a tomato greenhouse in a semi-arid zone using a time series model of artificial neural networks" / E. Dariushi, K. Aassif, L. Lekush, G. Buirden // Measurement, 42 (2009), pp. 456-463.
DOI:10.1016/J.measurement.2008.08.013
7. Кацупеев, А. А. Постановка и формализация задачи формирования информационной защиты распределённых систем / А. А. Кацупеев, Е. А. Щербакова, С. П. Воробьев // Инженерный вестник Дона. – 2015, 34, с. 21. – EDNTXTMHJ.
8. Abdi, R. "Analysis of energy consumption and greenhouse gas emissions from agricultural production" / R. Abdi, M. Taki, M. Akbarpour // Int J Nat Eng Sci, 6 (2012), pp. 73-79. ISSN: 026322410.
9. Ruano, A.E. "Forecasting building temperature using neural network models" / A.E. Ruano, E.M. Crispim, E.Z.E. Conceicao, M.Lucio // Energy Build, 38 (2006), pp. 682-694.
DOI:10.1016/J.enbuild.
10. He, F. "Modeling of air humidity in a greenhouse using an artificial neural network and analysis of the main components" / F. He, S. Ma // Prog Electron-X. Sciences, 71 (2010), pp. 19-23. DOI: 10.1016/J.compag.2009.07 0.011.
11. Taki, M. "Models of heat transfer and MLP neural networks for predicting internal

- environmental variables and energy losses in a semi – solar greenhouse" / M. Taki, Yu. Ajabshirchi, S. F. Ranjbar, A. Rohani, M. Matlub // Energy Build, 110 (2016), pp. 314-329. DOI:10.1016/j.enbuild.2015.11.010.
12. Ilyas, S.A. "Neural network logic sensor RBF for monitoring technological emissions" / Ilyas S.A., Elshafey M., Habib M.A. // Control Eng Practice, 21 (2013), pp. 962-970. DOI:10.1016/J.conengprac.2013.01.007.
13. Воробьев, С. П. Исследование модели транзакционной системы с репликацией фрагментов базы данных, построенной по принципам облачной среды / С. П. Воробьев, В. В. Горобец // Инженерный вестник Дона, 2012, 22, с. 49. – EDNPRXKMН

Результаты процедуры рецензирования статьи

В связи с политикой двойного слепого рецензирования личность рецензента не раскрывается.

Со списком рецензентов издательства можно ознакомиться [здесь](#).

Статья посвящена анализу разработки систем "Умная теплица" с применением нейронных сетей в контексте современного сельского хозяйства. Авторы сосредотачиваются на важности интеграции технологий IoT и ИИ для повышения эффективности агропредприятий через оптимизацию ресурсов и автоматизацию процессов. Исследование базируется на анализе существующих моделей и подходов, с акцентом на использование нейронных сетей для управления микроклиматом теплиц и оптимизации условий роста растений. Особое внимание уделено методам обучения нейронных сетей, включая обучение под наблюдением и без присмотра, а также различным архитектурам и функциям активации, используемым в нейросетевых моделях. Актуальность работы подчеркивается растущей потребностью в инновационных технологиях для сельского хозяйства, способствующих повышению урожайности и снижению затрат. Научная новизна заключается в комбинировании нейронных сетей и физических моделей для более точного прогнозирования микроклимата, что позволяет более эффективно управлять агропроцессами. Статья имеет логичную структуру и ясное изложение, начиная с введения и заканчивая выводами и предложениями по дальнейшим исследованиям. В заключении авторы подчеркивают необходимость дальнейшего изучения интеграции ANN в системы управления теплицами и предлагают перспективные направления для будущих исследований, включая применение глубокого обучения для анализа изображений в целях диагностики заболеваний культур. Следует особо отметить упоминание о Модели Бэкбокса, которая представляет собой значимый аспект в контексте исследования. Модель Бэкбокса описывается как метод, требующий значительного объема данных для эффективного обучения искусственных нейронных сетей, используемых в прогнозировании микроклимата теплиц. Этот метод основывается на пробах и ошибках для выбора подходящего скрытого слоя и нейронов, что, как указывается, может привести к снижению эффективности из-за необходимости работы с большими объемами данных. Упоминание Модели Бэкбокса важно для понимания методологических трудностей, с которыми сталкиваются исследователи при работе с нейронными сетями в сельскохозяйственной сфере, а также подчеркивает потребность в оптимизации процесса обучения для повышения эффективности и точности прогнозирования. Это подчеркивает важность выбора и адаптации методов обучения в зависимости от специфики задачи и доступных данных. В целом, статья представляет интерес для широкого круга читателей, включая специалистов в области агрономии, искусственного интеллекта и разработчиков сельскохозяйственных технологий.

Предложенные авторами идеи и методы могут способствовать развитию устойчивого и эффективного сельского хозяйства. В качестве рекомендации для дальнейшего исследования предлагаю разработку и тестирование интегрированных моделей, сочетающих ANN и физические подходы для различных аспектов управления теплицами, а также исследование возможности применения ANN в смежных областях агротехнологий. Это может включать разработку алгоритмов для более точного контроля влажности, температуры, уровня CO₂ и других критических параметров, определяющих условия роста растений в теплицах.