

ИСПОЛЬЗОВАНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ СОЗДАНИЯ СИСТЕМЫ ПРИНЯТИЯ РЕШЕНИЙ УПРАВЛЕНИЯ МИКРОКЛИМАТОМ ТЕПЛИЧНОЙ СИСТЕМЫ

Т.В. Костеннов

аспирант, e-mail: timofey.kostenov@gmail.com

Омский государственный университет им. Ф.М. Достоевского, Омск, Россия

Аннотация. Описывается механизм использования нейронных сетей для прогнозирования показателей микроклимата в системе принятия решений тепличной системы. Рассматривается использование нескольких рекуррентных нейронных сетей внутри системы принятия решений. Внимание уделяется правильному определению места системы принятия решений в функциональной схеме тепличной системы.

Ключевые слова: тепличная система, системный анализ, прогнозирование, микроклимат, нейронная сеть, система принятия решений.

Введение

Продовольственная безопасность является одной из актуальных проблем государства, большие усилия агропромышленного комплекса направлены на её обеспечение [1]. В рамках решения данной проблемы большую значимость получают методы выращивания агрокультур в регионах с холодным климатом. Подобные методы, кроме очевидных результатов в виде повышения совокупного урожая, позволяют, например, уменьшить затраты на транспортировку продукции, что, в свою очередь, сделает её более доступной для потребителя. Одним из таких методов является метод выращивания растений в закрытых грунтах, широко применяемый тепличными хозяйствами по всему миру. Применение теплиц в промышленности позволяет максимально использовать биологический потенциал растений благодаря возможности управления многими факторами роста. Доля теплиц в сельском хозяйстве растёт, и по прогнозам специалистов данная тенденция будет сохраняться в ближайшие годы [2].

Общий курс на автоматизацию и уменьшение участия человека в базовых операциях находит всё больше поддержки. Одним из применений автоматизации в области тепличных хозяйств являются управляемые алгоритмами теплицы. Для тех тепличных систем, в которых получилось добиться высокого уровня автоматизации, участие человека сводится к минимуму, но не исчезает полностью. Человек принимает основные решения по функционированию тепличной системы. Для того чтобы минимизировать человеческий фактор в принятии таких решений, можно использовать системы принятия решений.

В рамках данной статьи рассматривается теоретическая модель системы принятия решений на основе нескольких рекуррентных нейронных сетей (RNN). Используя различные данные о функционировании тепличной системы и её микроклимате система принятия решений формирует рекомендации по основным решениям.

Для создания подобной системы принятия решений можно рассмотреть тепличную систему с точки зрения системного анализа. Это поможет унифицировать и структурировать моделируемую систему.

1. Сбор информации о среде

Рассмотрим простейшую тепличную систему, использующую следующие датчики:

- датчик освещённости внутри тепличной системы;
- датчик температуры воздуха внутри тепличной системы;
- датчик влажности воздуха внутри тепличной системы;
- датчик температуры воздуха во внешней среде;
- датчик влажности воздуха во внешней среде.

И следующие устройства регуляции среды:

- нагреватель воздуха;
- охладитель воздуха;
- увлажнитель воздуха;
- осушитель воздуха;
- устройства полива;
- устройства освещения.

На основе информации о температуре и влажности внутри тепличной системы можно вычислить меру насыщенности воздуха влагой или дефицит давления водяного пара (VPD, vapour pressure deficit). Эта мера характеризует разницу между давлением насыщенного пара (максимальным количеством влаги в воздухе) и фактическим содержанием пара в воздухе (текущего количества влаги в воздухе). Этот параметр находит всё большее применение в современном растениеводстве и экологических исследованиях [3].

С помощью аналитических методов, таких как моделирование данных, можно предсказать значения температуры и влажности. Для этого необходимо подготовить данные для реализации и обучения модели.

2. Принцип работы системы принятия решений

Для реализации моделей будет использована RNN – вид нейронных сетей, где связи между элементами образуют направленную последовательность. Использование RNN находит всё большее применение в системах интернета вещей из-за высоких темпов роста объёмов информации [4]. Однако при использовании обычных RNN можно столкнуться с проблемой исчезающих градиентов – результаты вычислений могут не учитывать долгосрочные зависимости в данных. Это происходит из-за того, что градиенты при обратном распространении экспоненциально затухают или растут при обновлении весов. Для решения проблемы долгосрочной памяти

можно использовать различные архитектуры RNN. Рассмотрим более подробно две из них: Long Short-Term Memory (LSTM) и Gated Recurrent Units (GRU).

2.1. LSTM

LSTM (долгая краткосрочная память) – архитектура RNN, предложенная в 1997 г. З. Хохрайтером и Ю. Шмидхубером (см. рис. 1). Основным нововведением архитектуры являлась невосприимчивость к длительности временных разрывов, что давало LSTM преимущество по отношению к обычным RNN. Достигалось вышеописанное с помощью ячейки состояния (cell state) и трёх «ворот», управляющих информацией.

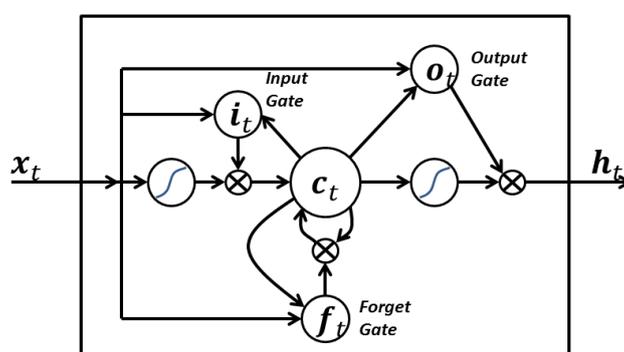


Рис. 1. Архитектура LSTM

Ключевые компоненты LSTM можно выделить следующим образом:

- Cell State – передаёт информацию через время почти без изменений, позволяет сохранять долгосрочные зависимости: C_t .
- Forget Gate – решает, какую информацию удалить из ячейки, вектор забвения: f_t .
- Input Gate – определяет, какую новую информацию добавить в ячейку, вектор входного вентиля: i_t .
- Output Gate – решает, какую информацию передать на следующий шаг, вектор выходного вентиля, кандидат на выход: o_t .

Благодаря своей архитектуре LSTM эффективно работают с длинными последовательностями, например, текстом, временными рядами, распознаванием речи, генерации музыкальных композиций, распознавании рукописного ввода.

2.2. GRU

GRU (управляемые рекуррентные блоки), представленные в 2014 г., – это упрощённая версия LSTM. Они объединяют некоторые компоненты для уменьшения вычислительной сложности. Ключевые компоненты GRU можно выделить следующим образом:

- Update Gate – определяет, какая информация сохранится из предыдущего состояния: z_t .

- Reset Gate – решает, какую часть прошлой информации игнорировать: r_t .
- Скрытое состояние: h_t .

Основным отличием от LSTM стало отсутствие ячейки состояния (C_t), осталось только скрытое состояние (h_t). Input Gate и Forget Gate объединены в Update Gate. Отсутствует Output Gate, выход формируется напрямую из обновлённого состояния. К основным преимуществам GRU относится меньшее число входных параметров, а значит более быстрое обучение.

Рассмотренные архитектуры решают проблему долгосрочных зависимостей, но выбор зависит от задачи и вычислительных ресурсов. LSTM мощнее для сложных последовательностей, в то время как GRU – эффективный компромисс между скоростью и точностью. В дальнейшем предлагается использовать GRU как более быстрый алгоритм. Для упрощения понимания внутренняя реализация GRU не будет рассматриваться совместно с входными параметрами. Обе архитектуры могут быть использованы в дальнейших предложенных схемах.

2.3. Входные и выходные данные

Рассмотрим параметры, участвующие в моделировании нейронной сети № 1:

- дата и время;
- температура воздуха внутри тепличной системы;
- влажность воздуха внутри тепличной системы;
- температура воздуха снаружи тепличной системы;
- влажность воздуха снаружи тепличной системы.

В результате набор данных содержит пять характеристик, содержит данные за две недели, с шагом в 10 минут. Таким образом, задача сводится к предсказанию временных рядов, для чего RNN часто используются и хорошо себя зарекомендовали [5].

Для обучения моделей данные следует разделить на несколько частей: 70 % – обучающие, 20 % – проверочные, 10 % – тестовые.

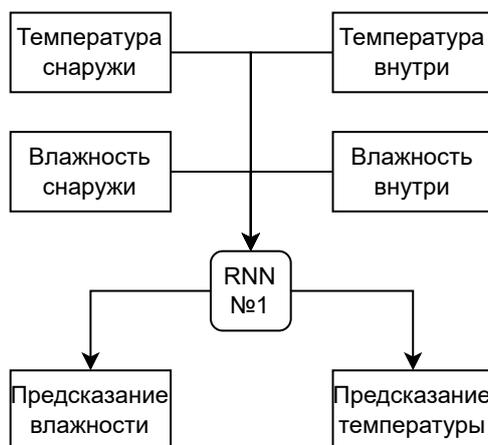


Рис. 2. Схема параметров нейронной сети № 1

Схема входных и выходных параметров нейронной сети № 1 представлена на рис. 2.

После обучения модель будет способна предсказывать влажность и температуру внутри тепличной системы. Эти данные предполагается использовать для других моделей с целью предсказания других параметров.

Рассмотрим параметры, участвующие в моделировании нейронной сети № 2:

- дата и время;
- температура воздуха внутри тепличной системы;
- влажность воздуха внутри тепличной системы;
- предсказание температуры воздуха внутри тепличной системы;
- предсказание влажности воздуха внутри тепличной системы.

В результате набор данных содержит пять характеристик, содержит данные за две недели, с шагом в 10 минут. Для обучения моделей данные следует разделить на несколько частей: 60 % – обучающие, 30 % – проверочные, 10 % – тестовые. Большой процент данных, отведённых на проверочную выборку, обусловлен использованием результатов работы другой нейронной сети.

Схема входных и выходных параметров нейронной сети № 2 представлена на рис. 3.

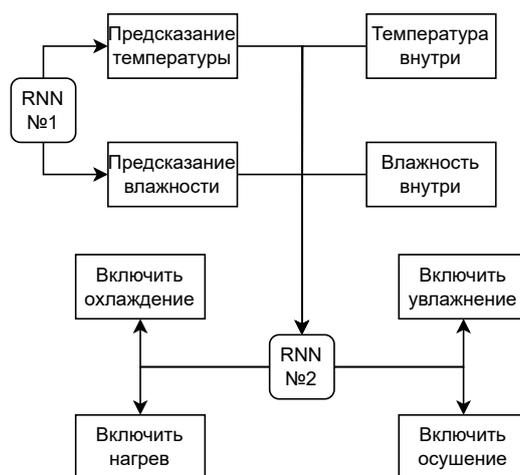


Рис. 3. Схема параметров нейронной сети № 2

После обучения модель будет способна выдавать рекомендации о включении средств регуляции среды. Стоит отметить, что при включении одних средств регуляции среды противоположные им отключаются. Например, при включении охлаждения будет автоматически отключён нагрев. Эти данные предполагается использовать для модели более высокого уровня с целью помощи в принятии решений.

Рассмотрим параметры, участвующие в моделировании нейронной сети № 3:

- дата и время;
- температура воздуха внутри тепличной системы;
- влажность воздуха внутри тепличной системы;
- предсказание температуры воздуха внутри тепличной системы;

- предсказание влажности воздуха внутри тепличной системы;
- дефицит давления пара;
- мощность, подаваемая на устройство освещения.

В результате набор данных содержит семь характеристик, содержит данные за две недели, с шагом в 10 минут. Для обучения моделей данные следует разделить на несколько частей: 60 % – обучающие, 30 % – проверочные, 10 % – тестовые. Большой процент данных, отведённых на проверочную выборку, обусловлен использованием результатов работы другой нейросети.

Схема входных и выходных параметров нейронной сети № 3 в представлена на рис. 4.

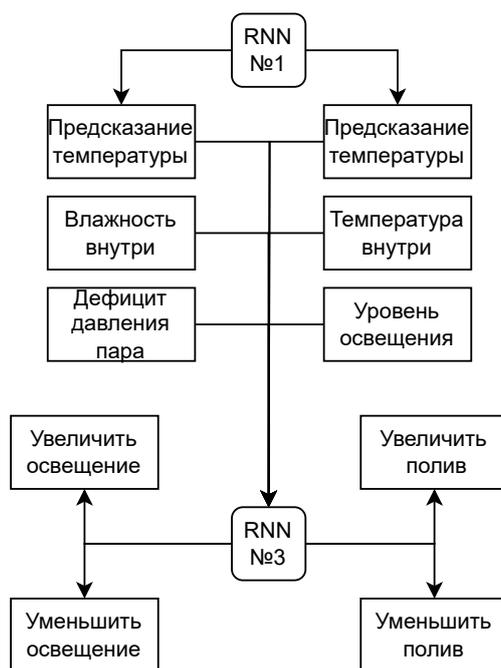


Рис. 4. Схема параметров нейронной сети № 3

После обучения модель будет способна выдавать рекомендации об изменении интенсивности работы средств регуляции среды: уровня освещения и полива в большую или меньшую сторону. Эти данные предполагается использовать для модели более высокого уровня с целью помощи в принятии решений.

Рассмотрим параметры, участвующие в моделировании нейронной сети № 4:

- дата и время;
- результаты работы нейронной сети № 1;
- результаты работы нейронной сети № 2;
- результаты работы нейронной сети № 3;
- температура воздуха внутри тепличной системы;
- влажность воздуха внутри тепличной системы;
- дефицит давления пара;
- мощность, подаваемая на устройство освещения.

После обучения нейронная сеть показывает свою оценку для решений преды-

дущих нейронных сетей на основе данных о состоянии микроклимата. Эта оценка отображается в пользовательском интерфейсе и работает как часть системы принятия решений. Поскольку на вход нейронной сети № 4 подаются те же данные что и на входы предыдущих, это приводит к двойной оценке состояния микроклимата. После проверки работоспособности концепции следует рассмотреть возможность убрать из входных данных нейронной сети № 4 данные о текущем состоянии микроклимата, и в качестве входных данных использовать только выходные данные предыдущих нейронных сетей.

Схема входных и выходных параметров нейронной сети № 4 представлена на рис. 5.

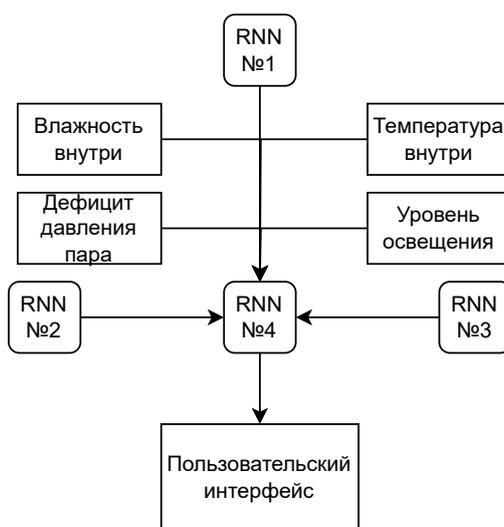


Рис. 5. Схема параметров нейронной сети № 4

3. Обработка данных внутри системы принятия решений

Данные о состоянии среды, предсказанные с помощью нейронных сетей, не стоит принимать как абсолютно истинные. Для оценки эффективности моделей стоит использовать метрики, измеряющие различия между предсказанными и фактическими значениям, такие как Mean Absolute Error (средняя абсолютная ошибка, MAE) и Root Mean Squared Error (среднеквадратичная ошибка, RMSE).

3.1. MAE

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|.$$

Результат вычисления просто интерпретируем и представляет собой среднее абсолютное отклонение между предсказанными и реальными данными. Алгоритм MAE не учитывает абсолютную величину ошибок, все ошибки имеют одинаковый вес в итоговой формуле. За счёт этого алгоритм устойчив к выбросам и случайным данным. Такие данные могут появиться в системе из-за ошибок чтения датчиков

влажности или температуры. Для значений используемых в системе, MAE должен не превышать следующих значений:

- Температура:
 - краткосрочные предсказания (1 измерение, 10 минут): 0.3–1.0 °C.
 - долгосрочные предсказания (среднее за сутки): 1.5–3.0 °C.
- Влажность:
 - краткосрочные предсказания (1 измерение, 10 минут): 1–3 %.
 - долгосрочные предсказания (среднее за сутки): 3–5 %.

Величина MAE может быть снижена с помощью увеличения объёма обучающей выборки, предобработки данных (нормализация, устранение шумов), увеличения точности датчиков.

3.2. RMSE

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}.$$

Результат вычисления представляет собой среднее квадратичное отклонение ошибок предсказаний. Из-за того, что учитывается не только величина отклонений, но и их распределение, метрика может быть менее интуитивной, чем MAE. Алгоритм RMSE более чувствителен к выбросам и случайным значениям за счёт использования квадратичного штрафа. Это делает его более строгим по сравнению с MAE. Из-за специфики вычислений факторы, позволяющие увеличить точность предсказаний и соответственно уменьшить величину метрики RMSE, совпадают с таковыми у MAE.

Из-за квадратичной природы вычислений значения метрики будут на 10–30 % выше, чем у MAE:

- Температура:
 - краткосрочные предсказания (1 измерение, 10 минут): 0.5–1.5 °C.
 - долгосрочные предсказания (среднее за сутки): 2.0–3.5 °C.
- Влажность:
 - краткосрочные предсказания (1 измерение, 10 минут): 1.5–4 %.
 - долгосрочные предсказания (среднее за сутки): 4–6%.

4. О месте системы принятия решений в функциональной схеме системы

В результате декомпозиции абстрактной тепличной системы её функциональные подсистемы были выделены следующим образом:

- Система Пользовательского Интерфейса – отвечает за предоставление пользователю актуальных данных о состоянии системы, передачу введённых пользователем данных Системе Управления.
- Система Управления – отвечает за выработку управляющих сигналов для Системы Регуляции Среды, получение данных от Системы Сбора Данных, предоставление данных для Системы Пользовательского Интерфейса.

- Система Регуляции Среды – отвечает за переключение средств регуляции среды в соответствии с управляющим сигналом от Системы Управления.
- Система Сбора Данных – отвечает за опрос датчиков с использованием различных протоколов связи низкого уровня, преобразования полученных данных и их отправку Системе Управления с использованием протоколов связи высокого уровня [6].

Декомпозицию тепличной системы, рассмотренную ранее, на первый взгляд, можно дополнить Системой Принятия Решений (см. рис. 6).

Однако при внимательном рассмотрении можно заметить, что Система Принятия Решений имеет те же связи и роль, что и Система Управления: обе системы отвечают за анализ данных среды, возможное переключение средств регуляции среды и взаимодействие с пользовательским интерфейсом. Таким образом, более корректно будет не выделять Систему Принятия Решений как отдельный функциональный компонент, а считать её частью Системы Управления (см. рис. 7).

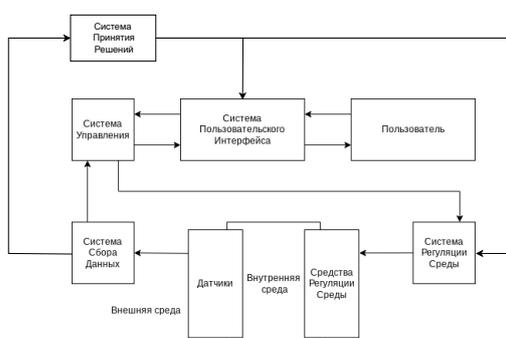


Рис. 6. Функциональная схема тепличной системы с выделением Системы Принятия Решений



Рис. 7. Функциональная схема тепличной системы с Системой Принятия Решений как частью Системы Управления

Внедрение Системы Принятия Решений на основе RNN в тепличные хозяйства открывает новые возможности для повышения их эффективности и устойчивости. Использование каскадной архитектуры, где выходы одной нейронной сети являются входами другой, усложняет алгоритм и делает его менее прозрачным, однако позволяет добиться большей степени автоматизации. Применение Системы Принятия Решений как вспомогательной для пользователя позволяет упростить внедрение в уже существующие тепличные системы и снизить влияние человеческого фактора. Увеличение автоматизации, снижение человеческого фактора и адаптивность к изменениям условий делают такие системы перспективными. Будущие исследования и разработки в этой области могут еще больше улучшить технологии и методы, используемые в тепличных хозяйствах, способствуя их дальнейшему развитию и интеграции в глобальную систему продовольственного обеспечения.

Литература

1. Бекбергенева Д.Е., Баранник В.А. Продовольственная безопасность Российской Федерации // Экономика и бизнес: теория и прак-

- тика. 2022. № 4-1. URL: <https://cyberleninka.ru/article/n/prodovolstvennaya-bezopasnost-rossiyskoy-federatsii> (дата обращения: 24.10.2023).
2. Коммерческий тепличный рынок – Статистика размеров и отрасли. URL: <https://www.mordorintelligence.com/ru/industry-reports/commercial-greenhouse-marke> (дата обращения: 01.12.2024).
 3. Domingo Sancho-Knapik, Óscar Mendoza-Herrer, David Alonso-Forn, Miguel Ángel Saz, Rubén Martín-Sánchez, José Víctor dos Santos Silva, Jerome Ogee, José Javier Peguero-Pina, Eustaquio Gil-Pelegrín, Juan Pedro Ferrio. Vapor pressure deficit constrains transpiration and photosynthesis in holm oak: A comparison of three methods during summer drought. *Agricultural and Forest Meteorology*. 2022. Vol. 327. URL: <https://doi.org/10.1016/j.agrformet.2022.109218> (дата обращения: 14.11.2024).
 4. de Brito M.S. et al. A service orchestration architecture for Fog-enabled infrastructures // Second International Conference on Fog and Mobile Edge Computing (FMEC). Valencia, Spain, 2017. P. 127–132. URL: https://www.researchgate.net/publication/317639602_A_service_orchestration_architecture_for_Fog-enabled_infrastructures (дата обращения: 14.11.2024).
 5. Губарева Е.А. Нейронные сети в анализе временных рядов // *Инновации и инвестиции*. 2020. № 10. URL: <https://cyberleninka.ru/article/n/neuronnye-seti-v-analize-vremennyh-ryadov> (дата обращения: 09.11.2024).
 6. Костеннов Т.В. Применение методов системного анализа к построению структурно-функциональной схемы тепличной системы // *Математические структуры и моделирование*. 2022. № 3 (63). С. 69–78.

USING NEURAL NETWORKS TO CREATE A DECISION-MAKING SYSTEM FOR MANAGING THE MICROCLIMATE OF A GREENHOUSE SYSTEM

T.V. Kostenov

Ph.D. Student, e-mail: timofey.kostenov@gmail.com

Dostoevsky Omsk State University, Omsk, Russia

Abstract. This article describes the mechanism of using neural networks to predict microclimate parameters in the decision-making system of a greenhouse system. The use of several recurrent neural networks within the decision-making system is considered. Attention is paid to the correct determination of the place of the decision-making system in the functional diagram of the greenhouse system.

Keywords: greenhouse system, system analysis, forecasting, microclimate, neural network, decision-making system.

Дата поступления в редакцию: 24.11.2024