

**Архипов Андрей Евгеньевич** – Государственный научный центр РФ – Федеральное государственное автономное научное учреждение «Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики»; e-mail: a.arkhipov@rtc.ru; г. Санкт-Петербург, Россия; тел.: +78125523351; м.н.с.

**Fomin Ivan Sergeevich** – Russian State Scientific Center for Robotics and Technical Cybernetics; e-mail: i.fomin@rtc.ru; Saint-Petersburg, Russia; phone: +78125523351; researcher.

**Matveev Victor Dmitrievich** – Russian State Scientific Center for Robotics and Technical Cybernetics; e-mail: v.matveev@rtc.ru; Saint-Petersburg, Russia; phone: +78125523351; engineer.

**Arkhipov Andrey Evgenievich** – Russian State Scientific Center for Robotics and Technical Cybernetics; e-mail: a.arkhipov@rtc.ru; Saint-Petersburg, Russia; phone: +78125523351; junior researcher.

УДК 004.8

DOI 10.18522/2311-3103-2025-4-284-297

**С.С. Обаид, В.А. Погонин, И.Б. Кирина****ИНТЕГРАЦИЯ РЕКУРРЕНТНОЙ НЕЙРОННОЙ СЕТИ ДЛЯ ПОВЫШЕНИЯ ОТКАЗОУСТОЙЧИВОСТИ МОДЕЛИ ВЛАГОПЕРЕНОСА В СИСТЕМЕ «УМНЫЙ САД»**

*Представлено исследование по разработке и интеграции рекуррентной нейронной сети (RNN) для повышения точности и отказоустойчивости модели влагопереноса в системе «Умный сад». Проблема контроля влажности почвы становится особенно актуальной в современных условиях сельского хозяйства и экологического мониторинга, где требуется высокая точность для управления водными ресурсами, прогнозирования урожайности и предотвращения засушливых периодов. Традиционные методы, такие как дистанционное зондирование и модели влагопереноса, имеют существенные ограничения: низкая точность, сложность вычислений, зависимость от точных данных сенсоров и сложность применения в реальных полевых условиях. Для решения этих проблем в исследовании предлагается использование RNN, способной эффективно обрабатывать временные ряды данных и прогнозировать влажность почвы даже при наличии неполных, неточных или искажённых входных данных. В качестве исходных данных использованы глобальный датасет влажности почвы GSSM и погодные данные платформы Meteostat, что позволило учесть климатические особенности регионов с разными типами почвы. Модель включает слой долговременной краткосрочной памяти (LSTM) и полносвязный слой для финального прогнозирования. Особое внимание уделено предобработке данных, включая расчёт среднесуточных, среднемесячных и среднегодовых значений, а также коррекцию данных с учётом характеристик различных типов почв. Проведённое исследование показало, что разработанная модель RNN обладает высокой устойчивостью к сбоям в работе сенсоров, минимальной зависимостью от объёма входных данных и способностью адаптироваться к разным климатическим и почвенным условиям. Предлагаемое решение позволяет улучшить точность мониторинга влажности почвы в системе «Умный сад», оптимизировать использование водных ресурсов и повысить стабильность работы системы в условиях изменяющихся внешних факторов. Таким образом, интеграция RNN открывает новые возможности для развития сельского хозяйства и экологии, обеспечивая более эффективное управление водными ресурсами и повышение производительности агросистем.*

*Рекуррентная нейронная сеть; влагоперенос в почве; «Умный сад»; отказоустойчивость; прогнозирование.*

**S.S. Obaid, V.A. Pogonin, I.B. Kirina****INTEGRATION OF A RECURRENT NEURAL NETWORK TO INCREASE THE FAILURE TOLERANCE OF THE MOISTURE TRANSFER MODEL IN THE SMART GARDEN SYSTEM**

*The paper presents a study on the development and integration of a recurrent neural network (RNN) to improve the accuracy and fault tolerance of a moisture transfer model in a smart garden system. The problem of soil moisture control is becoming especially relevant in modern agricultural and environmental monitoring, where high accuracy is required to manage water resources, forecast crop yields and prevent drought periods. Traditional methods, such as remote sensing and moisture transfer models, have significant limitations: low accuracy, computational complexity, dependence on accurate sensor data and difficulty in applying in real field conditions. To solve these problems, the study proposes the use of RNN,*

which is able to effectively process time series data and predict soil moisture even in the presence of incomplete, inaccurate or distorted input data. The global soil moisture dataset GSSM and weather data from the Meteostat platform were used as initial data, which made it possible to take into account the climatic features of regions with different soil types. The model includes a long short-term memory (LSTM) layer and a fully connected layer for the final forecast. Particular attention is paid to data pre-processing, including calculating average daily, average monthly and average annual values, as well as data correction taking into account the characteristics of different soil types. The study showed that the developed RNN model is highly resistant to sensor failures, has minimal dependence on the volume of input data and is able to adapt to different climatic and soil conditions. The proposed solution improves the accuracy of soil moisture monitoring in the Smart Garden system, optimizes the use of water resources and increases the stability of the system in the face of changing external factors. Thus, the integration of RNN opens up new opportunities for the development of agriculture and ecology, ensuring more efficient water resource management and increasing the productivity of agrosystems.

*Recurrent neural network; soil moisture transfer; "Smart Garden"; fault tolerance; forecasting.*

**Введение.** Актуальность разработки и применения систем мониторинга влажности почвы значительно возросла в условиях современных требований к сельскохозяйственным и экологическим исследованиям. Влажность почвы является важным фактором, влияющим на обмен веществ и энергии между почвой и атмосферой, а также на глобальную циркуляцию водяного пара, развитие экосистем и энергетические процессы [1]. В сельском хозяйстве контроль влажности почвы позволяет оценивать рост растений, прогнозировать урожайность и следить за засушливыми периодами.

Существующие методы оценки влажности почвы, как дистанционное зондирование, так и полевые наблюдения, ограничены в ресурсах и показывают недостаточную точность результатов. Микроволновые и оптические технологии дистанционного зондирования, которые применяются для мониторинга влажности на больших территориях, также имеют ограничения, связанные с низким пространственным разрешением и чувствительностью к внешним факторам. На основе моделей оценки влажности почвы создаются более сложные модели влагопереноса в почве.

В современных условиях садоводства система «Умный сад» становится всё более востребованной благодаря оптимизации использования ресурсов и увеличению урожайности. Одним из ключевых элементов системы является контроль влажности почвы, для чего широко применяются модели влагопереноса. Такие модели имеют ряд ограничений: сложность вычислений, зависимость от точных данных о параметрах почвы и низкая точность в полевых условиях.

При сбоях в работе датчиков или неточных показателях существующих моделей, критически важной становится задача повышения точности и устойчивости системы к отказам. Перспективное решение представляет применение методов глубокого обучения, в частности рекуррентных нейронных сетей (RNN), поскольку они способны предсказывать значения временных рядов с высокой точностью. В данном исследовании предложена интеграция RNN для достижения высокого уровня отказоустойчивости системы «Умный сад» и повышения точности модели влагопереноса, с целью эффективного преодоления недостатков применяемых существующих решений.

**1. Постановка задачи.** Цель исследования заключается в разработке и интеграции модели RNN для обеспечения отказоустойчивости системы «Умный сад» и повышения точности модели влагопереноса. В рамках исследования поставлены задачи анализа существующих моделей оценки влажности и влагопереноса в почве, выявления их недостатков, а также выбора и предобработки данных для обучения и тестирования модели. После чего, разработка архитектуры модели, её обучение и тестирование.

Основной задачей исследования является создание RNN, способной адаптироваться к неполным или неточным данным, обеспечивая высокую точность моделирования влагопереноса даже при отказе датчиков.

**2. Материал и методы исследования.** Модели влагопереноса в почве часто базируются на моделях оценки влажности, поскольку корректная оценка влажности верхних и корневых слоев почвы является ключевым компонентом для моделирования процессов инфильтрации, испарения и перемещения влаги. Модели оценки обеспечивают входные

данные, используемые в более сложных моделях для прогнозирования влагообмена в различных слоях почвы, что делает их неотъемлемой частью моделирования влагопереноса. Учитывая вышесказанное, важно сперва исследовать модели оценки влажности почвы, в частности модели зондирования влажности почвы.

**2.1. Модели оценки влажности почвы.** Множество исследований посвящено дистанционному зондированию влажности почвы [2], в рамках которых были разработаны четыре основных типа моделей: эмпирические, полуэмпирические, физические модели на основе математической статистики и модели с физическим смыслом. Эти модели глубоко изучены, и на их основе созданы различные продукты для мониторинга влажности почвы. С развитием компьютерных технологий и искусственного интеллекта быстро прогрессируют методы машинного обучения, такие как нейронные сети, которые показали хорошие результаты в оценке влажности почвы и привлекли большое внимание.

Эмпирическая модель оценки влажности почвы основывается на параметрах, таких как температура поверхности, коэффициент обратного рассеяния радара и оптические индексы (например, *normalized vegetation index*, NDVI). Микроволновые методы разделяются на активные и пассивные, где влажность почвы оценивается с помощью коэффициента обратного рассеяния, температуры яркости и содержания воды в растительности. Эти модели показывают высокую корреляцию между отражательной способностью почвы и её влажностью. Методы, основанные на инфракрасном излучении, часто используются, но их точность может снижаться из-за растительности. Для устранения влияния растительности были разработаны более сложные индексы, такие как NMDI (*normalized multi-band drought index*) и MPDI (*modified perpendicular drought index*). Современная модель OPTRAM (*Optical Trapezoid Model*) использует данные спутников Sentinel-2 и Landsat-8 для построения модели, что позволяет достигать высокой точности в оценке влажности почвы [3].

Полуэмпирические модели обрабатывают одновременно эмпирические и физические данные с целью снижения влияния растительности, а также шероховатости поверхности, и повышения точности оценки влажности почвы. Модели, подобные модели ОН и Дюбуа, для оценки влажности почвы используют радарные данные, опираясь на взаимосвязь между шероховатостью поверхности, влажностью почвы и коэффициентами рассеяния [4, 5]. Для улучшения точности в областях с растительностью применяется модель водяного облака (*water-cloud model*), которая использует данные радаров, таких как Sentinel-1 [6]. Эта модель позволяет эффективно оценивать влажность почвы под покровом растительности. Кроме того, разработаны методы, объединяющие оптические и радарные данные, что позволяет ещё точнее оценивать влажность в сложных условиях, например, на сельскохозяйственных или лесных территориях.

Физические модели для оценки влажности почвы были впервые предложены в 1950-х годах. Наиболее распространённые из них включают метод малых возмущений (*small perturbation method*, SPM) [7], приближение Кирхгофа (*Kirchhoff Approximation*, KA) [8] и интегральную модель уравнений (*integral equation model*, IEM) [9]. IEM и её улучшенная версия AIEM (*advanced integral equation model*) являются наиболее популярными моделями для оценки влажности почвы. Эти модели используют уравнение переноса микроволнового излучения и учитывают шероховатость поверхности. Модель AIEM улучшает расчёт коэффициентов рассеяния и автокорреляционных функций, что повышает точность моделирования. Также были разработаны модели для исправления ошибок, связанных с растительностью и шероховатостью, что позволило значительно улучшить точность оценки влажности почвы. Модель Qp [10], основанная на данных спутников, позволяет устранить влияние шероховатости, а алгоритмы, такие как AMSR-E [11], используют методы наименьших квадратов для минимизации различий между наблюдаемыми и моделируемыми значениями температуры яркости. Эти физические модели применяются для глобального мониторинга влажности почвы с помощью спутников, таких как AMSR и FY-3.

Методы машинного обучения, такие как нейронные сети, случайные леса (*random forest*, RF), опорные векторные машины (*support vector machine*, SVM) и глубокое обучение, активно используются для оценки влажности почвы на основе данных дистанцион-

ного зондирования. Эти методы демонстрируют высокую точность в моделировании влажности почвы и позволяют избегать сложных процессов, связанных с учётом растительности и шероховатости поверхности. Например, метод улучшенной сверточной нейронной сети (Improved Convolutional Neural Network, ICNN) с использованием радарных и мультиспектральных данных [12] позволил достичь корреляции между оценками и измерениями влажности почвы до 0,934 и RMSE 0,0145. Другие исследования [13] показывают, что комбинация данных Sentinel-1 и нейронных сетей может дать RMSE до 0,045. В машинном обучении также используется 10-кратная перекрестная проверка для выбора лучших моделей, что помогает улучшить пространственное разрешение продуктов влажности почвы. Например, метод уменьшения масштаба данных AMSR-E с использованием случайного леса привел к получению данных с разрешением 1 км [14, 15].

Для дальнейшего развития моделей оценки влажности почвы необходимо объединение данных из различных источников, например таких как оптическое и радиолокационное зондирование, повышение пространственно-временного разрешения для точного мониторинга, особенно в корневой зоне, и продление временных рядов наблюдений для климатических исследований. Также требуется повышение точности и интерпретируемости моделей с минимальной зависимостью от дополнительных данных, что создает основу для аналогичных задач в моделях влагопереноса, которые сталкиваются с теми же проблемами точности, разрешения и интерпретируемости. Рассмотрим существующие модели влагопереноса в почве.

**2.2. Модели влагопереноса в почве.** Уравнение Ричардса описывает движение воды в ненасыщенных почвах и было предложено Лоренцо А. Ричардсом в 1931 году [16]. Оно основано на законе Дарси-Бекингема для течения в пористых средах при изменяющейся степени насыщенности. Уравнение представляет собой квазилинейное дифференциальное уравнение и решается при определенных начальных и граничных условиях (1):

$$\frac{\partial \theta}{\partial t} = \nabla \cdot (K(\theta) \nabla \Psi) + S. \quad (1)$$

где  $\theta$  – влажность почвы (% объема воды),  
 $t$  – время,  
 $K(\theta)$  – гидравлическая проводимость почвы,  
 $\Psi$  – матричный потенциал,  
 $S$  – сток или источник влаги в почве,  
 $\nabla$  – оператор набла (пространственный градиент).

Основные проблемы при решении включают сложные вычисления и зависимость от гидравлических параметров почвы, таких как водоудерживающая способность, насыщенность и гидравлическая проводимость. Существуют разные формы уравнения: основанная на давлении и на насыщенности, каждая из которых имеет свои вычислительные сложности. Численное решение уравнения Ричардса требует точной настройки параметров почвы и сложных вычислительных методов для обеспечения устойчивого и точного результата.

Модель Ван Генухтена-Муалема описывает зависимость матричного потенциала и водопроницаемости от влажности почвы [17]. Уравнение удержания воды является основой уравнения, где влажность определяется насыщенной и остаточной влажностью, а также учитывает параметрами почвы полученные эмпирически (2):

$$\theta(\Psi) = \theta_r + \frac{\theta_s - \theta_r}{[1 + (\alpha |\Psi|)^n]^m}, \quad (2)$$

где  $\theta(\Psi)$  – влажность почвы (при матричном потенциале  $\Psi$ ),  
 $\theta_r$  и  $\theta_s$  – остаточная и насыщенная влажность почвы,  
 $\alpha$ ,  $n$  и  $m$  – характеризующие почву эмпирические параметры,  
 $m = 1 - 1/n$ , предполагая, что  $n > 1$ .

Гидравлическая проводимость рассчитывается по формуле Муалема (3):

$$K(\Psi) = K_s \sqrt{\theta(\Psi)} \left[ 1 - \left( 1 - \theta(\Psi)^{\frac{1}{m}} \right)^2 \right], \quad (3)$$

где  $K_s$  – насыщенная гидравлическая проводимость почвы.

Модель оценивает проводимость и водопоглощение ненасыщенных почв с высокой точностью, что значимо для управления водными ресурсами и ирригации. Однако применение данной модели требует полевых или лабораторных измерений для точного определения параметров. Важно также отметить, что модель может отражать поведение гетерогенных почв не в полной мере.

Модель Дарси-Бакингема, опираясь на потенциал влажности Бакингема и закон Дарси, описывает перемещение воды в ненасыщенных почвах [18] (4).

$$q = -K(\theta) \left( \frac{\partial \Psi}{\partial z} + 1 \right), \quad (4)$$

где  $q$  – скорость водного потока в почве (м/с),

$K(\theta)$  – гидравлическая проводимость от функции влажности почвы  $\theta$ ,

$\Psi$  – матричный потенциал (м),

$z$  – вертикальная координата, направленная вверх,

$\frac{\partial \Psi}{\partial z} + 1$  – градиент общего потенциала воды (включая матричный потенциал и гравитационный компонент).

Прогнозирование движения воды через почву и прочие пористые среды, учитывая изменение насыщенности – основная задача данной модели. Модель широко применяется для решения вопросов водного хозяйства, дренажа и ирригации, поскольку помогает проанализировать движение водяных масс в почве и оценить потребность в поливе. Сложность точного определения матричного потенциала и параметров гидравлической проводимости – основная проблема модели. Также необходимо наличие точных данных и учет возможной неоднородности почвы для определения и введения граничных условий, что повышает уровень сложности моделирования и требует для получения корректных параметров проведения полевых или лабораторных испытаний.

Модель Грина-Ампта описывает процесс инфильтрации воды в почву, принимая допущение о наличии резкой границы влажности (фронт увлажнения) между насыщенной и ненасыщенной зонами почвы [19]. В основе этой модели лежит применение закона Дарси для описания скорости фильтрации воды через увлажненный слой почвы (5):

$$Z = K(t - t_p) + \left( \frac{\psi m}{K} \right) \ln \left( \frac{Kt}{\psi m} + 1 \right), \quad (5)$$

где

$Z$  – глубина влажного фронта,

$t$  – время,

$t_p$  – время начала насыщения,

$K$  – гидравлическая проводимость почвы,

$\psi m$  – потенциал матрицы почвы на границе влажной зоны.

Главным преимуществом модели является ее относительная простота и возможность использования для моделирования процессов инфильтрации на различных почвенных типах, особенно для задач, связанных с ирригацией, моделированием стока, а также при проектировании дренажных систем. Однако у модели есть и недостатки. Во-первых, она предполагает, что почва является однородной и ее свойства не изменяются с глубиной, что не всегда соответствует реальным условиям, особенно при наличии слоистых почв. Во-вторых, модель игнорирует влияние гравитации на более глубокие слои почвы, что может привести к погрешностям в расчетах для глубоких профилей. Наконец, модель не учитывает возможные вариации влажности почвы до начала инфильтрации, а также сложные процессы, связанные с капиллярными силами.

Модель Филиппа описывает процесс проникновения воды в почву, при котором скорость инфильтрации постепенно уменьшается со временем [20]. На начальном этапе инфильтрация происходит быстро за счёт сорбционных процессов (впитывания воды почвой), однако затем скорость замедляется и приближается к постоянному уровню (6):

$$I(t) = St^{-\frac{1}{2}} + At, \quad (6)$$

где  $Z$  – глубина влажного фронта,

$I(t)$  – скорость инфильтрации в момент времени  $t$ ;

$S$  – сорбционная способность почвы (выражаемая константой);

$A$  – константа скорости инфильтрации, которая достигается после определённого временного периода;

$t$  – время.

Модель применяется для расчета водного баланса и описания процессов водопоглощения в гидрологии и агрономии, в особенности в условиях искусственного орошения или кратковременных осадков. При этом, в случае описания более сложных процессов влагопереноса, таких как влияние более глубоких слоев почвы и ее неоднородности, модель Филиппа представляется ограниченной, что поднимает вопрос использования для более точного прогнозирования дополнительных моделей. Несмотря на это, она полезна для прогнозирования инфильтрации в простых условиях и часто используется в исследованиях инфильтрации и управления водными ресурсами.

Фрактальные модели влагопереноса применяют самоподобие для описания сложной структуры почвы и процессов движения воды [21]. Они учитывают взаимодействие воды с пористыми структурами на разных масштабах, что позволяет моделировать такие процессы, как конденсация, испарение и адсорбция. Преимуществом фрактальных моделей есть высокая точность влагообмена, в особенности для неоднородных почв. При этом, высокая вычислительная сложность является недостатком, а также требование точных входных данных и необходимость наличия глубоких знаний в области фрактальной геометрии, что существенно ограничивает их использование на практике.

В результате анализа существующих моделей влагопереноса выявлены ключевые ограничения, такие как зависимость от точных данных сенсоров, сложность вычислений и недостаточная точность прогнозов в реальных полевых условиях. Эти факторы существенно снижают практическую применимость традиционных подходов и актуализируют задачу разработки и интеграции инновационных методов. Одним из перспективных решений является использование рекуррентных нейронных сетей (RNN), которые способны эффективно обрабатывать временные ряды данных и адаптироваться к неполным или неточным исходным данным.

Интеграция RNN в систему «Умный сад» может быть реализована в качестве дополнения к существующей модели влагопереноса. RNN может выполнять две основные функции:

1. Резервный источник данных. В случае отказа сенсоров, обеспечивающих показатели для модели влагопереноса, RNN будет использовать исторические данные и текущие климатические параметры для прогнозирования влажности почвы с высокой точностью. Это позволит поддерживать работоспособность системы в условиях ограниченности данных.

2. Динамическое уточнение прогнозов. Благодаря способности дообучения, RNN сможет регулярно обновлять свои параметры на основе новых данных влажности почвы. Это обеспечит адаптацию модели к текущим условиям, включая изменение климатических факторов или характеристик почвы, и повысит точность прогнозирования.

Дополнительно RNN может быть интегрирована с данными метеорологических платформ (например, Meteostat), чтобы учитывать такие параметры, как температура воздуха, осадки, скорость ветра и относительная влажность. Эти данные позволят модели более точно учитывать динамику процессов испарения и инфильтрации, улучшая результаты прогнозирования.

**2.3. Формализация оценки отказоустойчивости.** Для оценки отказоустойчивости, а также точности, используется среднеквадратическая ошибка (MSE) между истинными и прогнозируемыми значениями влажности почвы (7):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (7)$$

где  $\hat{y}_i$  – прогнозируемое значение влажности почвы;

$y_i$  – истинное значение влажности почвы;

$n$  – количество прогнозируемых точек.

Отказоустойчивость модели (FT) оценивается с учетом разницы допустимого значения MSE и фактического значения MSE (8):

$$FT = \frac{MSE_a - MSE_f}{MSE_a} \cdot 100\%, \quad (8)$$

где  $MSE_a$  – допустимое значение MSE;  $MSE_f$  – фактическое значение MSE.

Таким образом показатель отказоустойчивости находится в пределах от минус бесконечности до 100%. 100%-е значение отказоустойчивости означает, что фактическое значение MSE равно нулю, а допустимое значение MSE больше нуля – это случай максимально-возможной отказоустойчивости. Если допустимое и фактическое значение MSE равны, тогда отказоустойчивость будет равна 0% – система на грани выхода за предельно допустимое значение MSE. И, наконец, если фактическое значение MSE выше допустимого – значение отказоустойчивости будет отрицательным, что означает неспособность системы удерживаться в рамках допустимого порога MSE.

Последняя формула может также применяться для оценки точности прогнозирования влажности почвы. Стоит заметить, что допустимое пороговое значение MSE в ней задается пользователем.

**2.4. Разработка и обучение RNN.** Для обучения и тестирования модели RNN был выбран датасет The global seamless soil moisture dataset (GSSM) [22]. Данный выбор обусловлен его высокой временной разрешающей способностью, долгосрочным периодом измерений, а также глобальным покрытием, что позволяет получить региональные данные для различных климатических условий. Для обеспечения соответствия задачам исследования на данные наложены погодные измерения, предоставленные платформой Meteostat [23], для получения ежедневных данных.

Предобработка данных включала:

1. Вычисление ежемесячных средних значений влажности почвы на основе данных GSSM.

2. Интеграцию погодных данных, таких как температура воздуха, осадки, скорость ветра и относительная влажность, для расчёта испарения и динамики влажности почвы. Погодные данные (температура, осадки, скорость ветра, относительная влажность) для каждой точки местности извлекались из платформы Meteostat с почасовым разрешением. На основе этих данных рассчитывалась скорость испарения с использованием формулы, учитывающей температуру, влажность, скорость ветра и коэффициент испарения. Расчётное значение испарения вычиталось из предыдущего значения влажности почвы, скорректированного с учётом осадков и снегового покрова. Для регионов с отрицательной температурой учитывалась задержка влаги в виде снега. Итоговые значения влажности нормализовались относительно среднего значения за месяц, чтобы соответствовать реальным данным GSSM.

3. Корректировка рассчитанных значений влажности почвы в зависимости от преобладающего типа почвы в Москве и Ростове-на-Дону соответственно. Значения влажности почвы умножались на коэффициент удержания влаги в зависимости от типа почвы для выбранных регионов.

4. Масштабирование данных влажности в диапазоне 0–1.

Для формирования входных данных в RNN использовались следующие признаки:

- ◆ Среднегодовое значение влажности.
- ◆ Среднемесячные значения влажности.
- ◆ Среднедневные значения влажности.
- ◆ Среднечасовые значения влажности.

Каждому значению влажности добавлялся показатель, представляющий обратную величину времени до момента измерения, что позволило сформировать двумерный массив входных данных для модели RNN. Исследование сосредоточено на регионах Москвы и Ростова-на-Дону, где проводились расчёты на основе данных GSSM и погодных данных Meteostat за период с 2012 по 2022 год.

Разделение данных производилось в пропорции 80% на тренировочную и 20% на тестовую выборки. Тренировочная выборка дополнительно разделялась на тренировочную и валидационную в соотношении 80% к 20%.

Разработанная и обученная модель RNN построена на архитектуре LSTM (Long Short-Term Memory). Она включает:

1. Входной слой.
2. LSTM-слой с 10 нейронами, возвращающий последовательность состояний.
3. Полносвязный слой Dense с одним нейроном для финального предсказания.

Стоит заметить, что изначально эксперименты проводились с большим количеством слоев и нейронов в слоях, однако это не дало существенного повышения точности получаемых результатов. Поэтому архитектура нейронной сети была оптимизирована для минимизации требований к вычислительным ресурсам при сохранении достаточной точности прогнозов влажности почвы.

В качестве функции потерь выбрана среднеквадратичная ошибка (MSE), а в качестве оптимизатора – Adam. Размер батча установлен на 32 для повышения эффективности работы модели. Обучение модели длилось 10 эпох с валидацией на 20% тренировочной выборки. На каждой эпохе сохранялась лучшая модель по минимальному значению MSE на валидационной выборке.

На рис. 1 представлены графики изменения MSE для валидационной и тренировочной выборки (данных) Москвы.

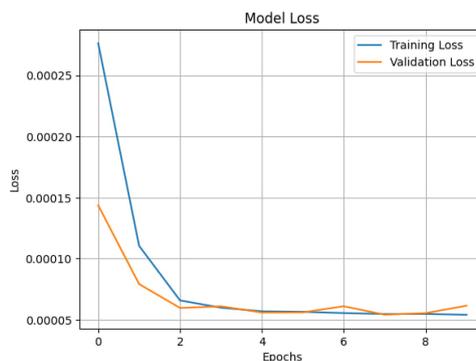


Рис. 1. Графики потерь (MSE) на тренировочной и валидационной выборках (Москва)

На рис. 2 представлены графики изменения MSE для валидационной и тренировочной выборок (данных) Ростова-на-Дону.

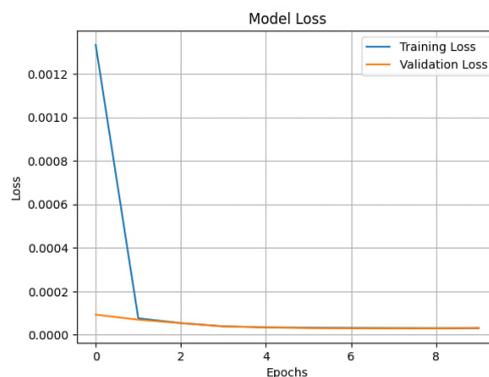


Рис. 2. Графики потерь (MSE) на тренировочной и валидационной выборках (Ростов-на-Дону)

По графикам функции потерь на данных Москвы и Ростова-на-Дону видно, что модель обучена успешно, переобучения не наблюдается.

Оценка модели на тестовой выборке показала удовлетворительное качество предсказаний, с приемлемым значением MSE. Предсказания модели коррелировали с истинными значениями, что подтверждается визуализацией результатов. Таким образом, разработанная модель RNN демонстрирует потенциал для прогнозирования временных рядов влажности почвы в различных климатических условиях.

**3. Результаты исследования и их обсуждение.** Разработанная модель RNN была протестирована на данных двух регионов: Москвы и Ростова-на-Дону, представленных разными типами почвы – глинистой и суглинистой. Для каждого региона проведён анализ точности модели, включая сравнение прогнозируемых и истинных значений, оценку ошибок и их распределения, а также исследование поведения модели при изменении входных данных.

В табл. 1 приведены значения среднеквадратичной ошибки (MSE) для тестовых выборок каждого региона и типа почвы.

Таблица 1

**MSE на тестовых выборках для разных регионов (типов почвы)**

Регион	Тип почвы	Ошибка MSE
Москва	Глинистая	$5.04 \times 10^{-5}$
Ростов-на-Дону	Суглинистая	$2.94 \times 10^{-5}$

Полученные значения MSE показывают, что модель RNN демонстрирует хорошую точность прогнозирования для обоих регионов. Однако, в Ростове-на-Дону ошибка MSE значительно ниже, чем в Москве, что может быть связано с более стабильными характеристиками суглинистой почвы по сравнению с глинистой. Для глинистой почвы характерны большие колебания уровня влажности, что усложняет её прогнозирование.

Для визуальной оценки точности прогнозирования показателей влажности почвы, из тестовой выборки были взяты 30 значений входных данных, которые были переданы на вход обученной модели нейросети, и затем полученные результаты сравнены с истинными значениями. Эти действия были выполнены для каждого региона соответственно.

Графики сравнения 30 прогнозируемых и истинных значений влажности почвы для Москвы представлен на рис. 3.

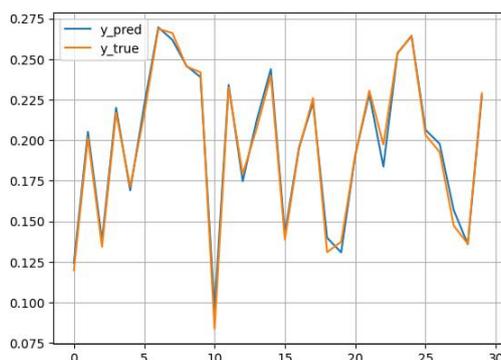


Рис. 3. Графики сравнения 30 прогнозируемых и истинных значений влажности почвы для Москвы

Графики сравнения 30 прогнозируемых и истинных значений влажности почвы для Ростова-на-Дону представлен на рис. 4.

Эти графики показывают высокую степень соответствия между прогнозируемыми значениями и фактическими данными, что указывает на хорошее качество модели. Отклонения прогнозируемых значений от истинных минимальны и несущественны.

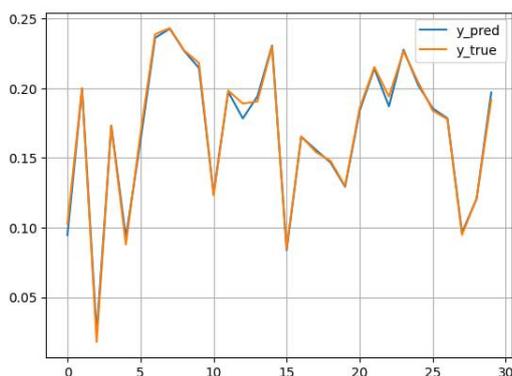


Рис. 4. Графики сравнения 30 прогнозируемых и истинных значений влажности почвы для Ростова-на-Дону

Для оценки распределения ошибок построены диаграммы размаха для каждого региона (рис. 5).

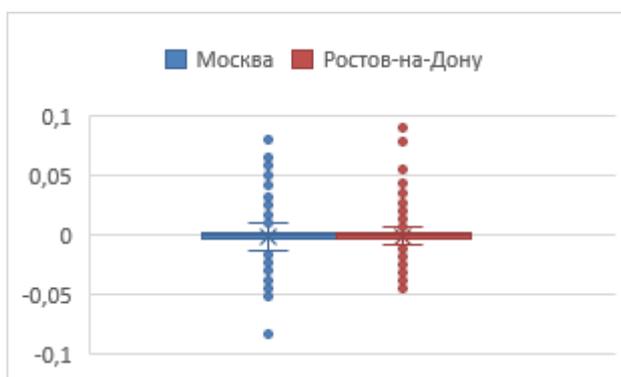


Рис. 5. Диаграмма размаха значений ошибок (разниц истинных и прогнозируемых показателей влажности)

Медианные значения для обоих регионов близки к нулю, что свидетельствует о низком систематическом смещении модели. Однако для Москвы наблюдаются чуть более крупные выбросы, что может быть связано с высокой гетерогенностью глинистой почвы. В Ростове-на-Дону выбросы тоже есть, но чуть меньше, что подтверждает стабильность модели для суглинистой почвы. Разброс значений ошибок в Москве больше, что свидетельствует о возможной необходимости дальнейшей оптимизации модели для работы с глинистой почвой.

Для проверки устойчивости модели была проведена дополнительная серия экспериментов с укороченными входными данными. Включались только данные за последний месяц и день, при этом остальные входные значения обнулялись. Несмотря на это, ошибка MSE практически не изменилась (отклонение менее  $10^{-6}$ ), что демонстрирует способность модели эффективно работать даже при ограниченном количестве данных. Результаты экспериментов с укороченными входными данными представлены в табл. 2.

Из результатов дополнительных экспериментов можно заключить, что больший период входных данных гарантирует более точные результаты. При этом даже в случае ограничения входных данных периодом в один день снижает точность не существенно, погрешность не превышает  $10^{-5}$ .

Таблица 2

**MSE на тестовых выборках для разных периодов входных данных**

Период входных данных	Ошибка MSE	
	Москва	Ростов-на-Дону
Год	$5.04 \times 10^{-5}$	$2.94 \times 10^{-5}$
Месяц	$5.29 \times 10^{-5}$	$3.09 \times 10^{-5}$
Неделя	$5.54 \times 10^{-5}$	$3.23 \times 10^{-5}$
День	$6.05 \times 10^{-5}$	$3.53 \times 10^{-5}$

Разработанная модель RNN показала высокую точность прогнозирования влажности почвы на тестовых выборках для обоих регионов и при различных периодах входных данных. Низкие значения ошибки MSE и соответствие прогнозируемых значений реальным данным подтверждают целесообразность её использования. Результаты также указывают на необходимость дальнейшей оптимизации модели для более сложных типов почв и условий, таких как глинистая почва в Москве.

**Заключение.** В ходе исследования была разработана и протестирована модель рекуррентной нейронной сети (RNN) для прогнозирования временных рядов влажности почвы в рамках системы «Умный сад». Выполненный анализ показал, что модель демонстрирует высокую точность и отказоустойчивость при работе с различными типами почв и климатическими условиями, а также обладает низкой зависимостью от полноты входных данных.

На основе проведённого моделирования установлено, что:

- ◆ Разработанная модель RNN позволяет корректно прогнозировать значения влажности почвы для тестовых выборок, о чём свидетельствуют низкие значения среднеквадратичной ошибки (MSE), составившие  $5.04 \times 10^{-5}$  для глинистой почвы (Москва) и  $2.94 \times 10^{-5}$  для суглинистой почвы (Ростов-на-Дону).

- ◆ Модель сохраняет устойчивость к сбоям в работе сенсоров и ограниченности входных данных, что делает её эффективной для использования в реальных условиях, в том числе при недостатке измерений.

- ◆ Для сложных типов почв, таких как глинистая, характерен больший разброс значений ошибок, что указывает на необходимость дальнейшей оптимизации модели.

Проведённые эксперименты подтвердили, что разработанная архитектура RNN способна учитывать сложные зависимости во временных рядах влажности почвы и адаптироваться к особенностям разных регионов. Модель может быть успешно интегрирована в системы мониторинга, такие как «Умный сад», для повышения точности прогнозирования и устойчивости к отказам.

Перспективы дальнейшей работы включают:

1. Оптимизацию модели для сложных типов почв с учётом их гетерогенности.
2. Интеграцию дополнительных данных (например, состава почвы или уровня органических веществ) для повышения точности прогнозов.
3. Адаптацию модели для применения в других климатических и экологических условиях, что обеспечит универсальность её использования.

Таким образом, представленная в статье модель RNN открывает новые возможности для точного мониторинга влажности почвы и эффективного управления водными ресурсами в системах сельского хозяйства.

## БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Anagnostopoulos V. et al.* A modernized version of a 1D soil vegetation atmosphere transfer model for improving its future use in land surface interactions studies // *Environmental Modelling & Software*. – 2017. – Vol. 90. – P. 147-156. – <https://doi.org/10.1016/j.envsoft.2017.01.004>.

2. *Gili P. et al.* An unmanned lighter-than-air platform for large scale land monitoring // *Remote Sensing*. – 2021. – Vol. 13, No. 13. – P. 2523. – <https://doi.org/10.3390/rs13132523>.
3. *Sadeghi M. et al.* The optical trapezoid model: A novel approach to remote sensing of soil moisture applied to Sentinel-2 and Landsat-8 observations // *Remote sensing of environment*. – 2017. – Vol. 198. – P. 52-68. – <https://doi.org/10.1016/j.rse.2017.05.041>.
4. *Dubois P.C., Van Zyl J., Engman T.* Measuring soil moisture with imaging radars // *IEEE transactions on geoscience and remote sensing*. – 1995. – Vol. 33, No. 4. – P. 915-926.
5. *Oh Y., Sarabandi K., Ulaby F.T.* An empirical model and an inversion technique for radar scattering from bare soil surfaces // *IEEE transactions on Geoscience and Remote Sensing*. – 1992. – Vol. 30, No. 2. – P. 370-381. – <https://doi.org/10.1109/36.134086>.
6. *Attema E.P.W., Ulaby F.T.* Vegetation modeled as a water cloud // *Radio science*. – 1978. – Vol. 13, No. 2. – P. 357-364. – <https://doi.org/10.1029/RS013i002p00357>.
7. *Rice S.O.* Reflection of electromagnetic waves from slightly rough surfaces // *Communications on pure and applied mathematics*. – 1951. – Vol. 4, No. 2-3. – P. 351-378. – <https://doi.org/10.1002/cpa.3160040206>.
8. *Beckmann P., Spizzichino A.* The scattering of electromagnetic waves from rough surfaces // *Norwood*. – 1987.
9. *Fung A.K., Li Z., Chen K.S.* Backscattering from a randomly rough dielectric surface // *IEEE Transactions on Geoscience and remote sensing*. – 1992. – Vol. 30, No. 2. – P. 356-369. – <https://doi.org/10.1109/36.134085>.
10. *Shi J. et al.* A parameterized multifrequency-polarization surface emission model // *IEEE transactions on geoscience and remote sensing*. – 2005. – Vol. 43, No. 12. – P. 2831-2841. – <https://doi.org/10.1109/TGRS.2005.857902>.
11. *Njoku E.G. et al.* Soil moisture retrieval from AMSR-E // *IEEE transactions on Geoscience and remote sensing*. – 2003. – Vol. 41, No. 2. – P. 215-229. – <https://doi.org/10.1109/TGRS.2002.808243>.
12. *Kui L. et al.* Wide-area soil moisture retrieval using SAR images and multispectral data // *Trans. Chin. Soc. Agric. Eng.* – 2020. – Vol. 36 (7). – P. 134-140. – <https://doi.org/10.11975/j.issn.1002-6819.2020.07.015>.
13. *Wu S. et al.* Joint retrieval of soil moisture from Sentinel-1 and Sentinel-2 remote sensing data based on neural network algorithm // *Transactions of Atmospheric Sciences*. – 2021. – Vol. 44, No. 4. – P. 636-644. – <https://doi.org/10.13878/j.cnki.dqkxxb.20190419001>.
14. *Chen S. et al.* Spatial downscaling methods of soil moisture based on multisource remote sensing data and its application // *Water*. – 2019. – Vol. 11, No. 7. – P. 1401. – <https://doi.org/10.3390/w11071401>.
15. *Zhao W. et al.* A spatial downscaling approach for the SMAP passive surface soil moisture product using random forest regression // *Journal of hydrology*. – 2018. – Vol. 563. – P. 1009-1024. – <https://doi.org/10.1016/j.jhydrol.2018.06.081>.
16. *Zhang Q.* Precision agriculture technology for crop farming. – Taylor & Francis, 2016. – 374 с. – <https://doi.org/10.1201/b19336>.
17. *Слинько О.В., Кондратьев О.В.* Роботизированные средства в садоводстве // *Теория и практика современной аграрной науки*. – 2022. – С. 615-618.
18. *Кондратьева О.В., Слинько О.В., Федоров А.Д.* Развитие роботизированных систем в садоводстве // *Агропромышленный комплекс: проблемы и перспективы развития*. – 2023. – С. 100-106.
19. *Stafford J. et al.* Precision agriculture for sustainability. – Burleigh Dodds Science Publishing Limited, 2019. – 494 с. – <https://doi.org/10.1201/9781351114592>.
20. *Philip J.R.* The theory of infiltration: 1. The infiltration equation and its solution // *Soil science*. – 1957. – Vol. 83, No. 5. – P. 345-358. – <http://dx.doi.org/10.1097/00010694-195705000-00002>.
21. *Despommier D.* The vertical farm: Feeding the world in the 21st century. – New York: St. – Martin's Press, 2010. – 159 с.
22. *Wang Y. et al.* GSSM: A global seamless soil moisture dataset from 1981 to 2022 matching CCI to SMAP with a novel bias correction method // *Earth System Science Data Discussions*. – 2024. – Vol. 2024. – P. 1-27. – <https://doi.org/10.5194/essd-2024-200>.
23. *Lamprecht C.* Meteostat API. – Режим доступа: <https://meteostat.net/en/blog/introduction-meteostat-rapidapi>.

## REFERENCES

1. *Anagnostopoulos V. et al.* A modernized version of a 1D soil vegetation atmosphere transfer model for improving its future use in land surface interactions studies, *Environmental Modelling & Software*, 2017, Vol. 90, pp. 147-156. Available at: <https://doi.org/10.1016/j.envsoft.2017.01.004>.
2. *Gili P. et al.* An unmanned lighter-than-air platform for large scale land monitoring, *Remote Sensing*, 2021, Vol. 13, No. 13, pp. 2523. Available at: <https://doi.org/10.3390/rs13132523>.

3. *Sadeghi M. et al.* The optical trapezoid model: A novel approach to remote sensing of soil moisture applied to Sentinel-2 and Landsat-8 observations, *Remote sensing of environment*, 2017, Vol. 198, pp. 52-68. Available at: <https://doi.org/10.1016/j.rse.2017.05.041>.
4. *Dubois P.C., Van Zyl J., Engman T.* Measuring soil moisture with imaging radars, *IEEE transactions on geoscience and remote sensing*, 1995, Vol. 33, No. 4, pp. 915-926.
5. *Oh Y., Sarabandi K., Ulaby F.T.* An empirical model and an inversion technique for radar scattering from bare soil surfaces, *IEEE transactions on Geoscience and Remote Sensing*, 1992, Vol. 30, No. 2, pp. 370-381. Available at: <https://doi.org/10.1109/36.134086>.
6. *Attema E.P.W., Ulaby F.T.* Vegetation modeled as a water cloud, *Radio science*, 1978, Vol. 13, No. 2, pp. 357-364. Available at: <https://doi.org/10.1029/RS013i002p00357>.
7. *Rice S.O.* Reflection of electromagnetic waves from slightly rough surfaces, *Communications on pure and applied mathematics*, 1951, Vol. 4, No. 2-3, pp. 351-378. Available at: <https://doi.org/10.1002/cpa.3160040206>.
8. *Beckmann P., Spizzichino A.* The scattering of electromagnetic waves from rough surfaces, *Norwood*, 1987.
9. *Fung A.K., Li Z., Chen K.S.* Backscattering from a randomly rough dielectric surface, *IEEE Transactions on Geoscience and remote sensing*, 1992, Vol. 30, No. 2, pp. 356-369. Available at: <https://doi.org/10.1109/36.134085>.
10. *Shi J. et al.* A parameterized multifrequency-polarization surface emission model, *IEEE transactions on geoscience and remote sensing*, 2005, Vol. 43, No. 12, pp. 2831-2841. Available at: <https://doi.org/10.1109/TGRS.2005.857902>.
11. *Njoku E.G. et al.* Soil moisture retrieval from AMSR-E, *IEEE transactions on Geoscience and remote sensing*, 2003, Vol. 41, No. 2, pp. 215-229. Available at: <https://doi.org/10.1109/TGRS.2002.808243>.
12. *Kui L. et al.* Wide-area soil moisture retrieval using SAR images and multispectral data, *Trans. Chin. Soc. Agric. Eng.*, 2020, Vol. 36 (7), pp. 134-140. Available at: <https://doi.org/10.11975/j.issn.1002-6819.2020.07.015>.
13. *Wu S. et al.* Joint retrieval of soil moisture from Sentinel-1 and Sentinel-2 remote sensing data based on neural network algorithm, *Transactions of Atmospheric Sciences*, 2021, Vol. 44, No. 4, pp. 636-644. Available at: <https://doi.org/10.13878/j.cnki.dqkxb.20190419001>.
14. *Chen S. et al.* Spatial downscaling methods of soil moisture based on multisource remote sensing data and its application, *Water*, 2019, Vol. 11, No. 7, pp. 1401. Available at: <https://doi.org/10.3390/w11071401>.
15. *Zhao W. et al.* A spatial downscaling approach for the SMAP passive surface soil moisture product using random forest regression, *Journal of hydrology*, 2018, Vol. 563, pp. 1009-1024. Available at: <https://doi.org/10.1016/j.jhydrol.2018.06.081>.
16. *Zhang Q.* Precision agriculture technology for crop farming. Taylor & Francis, 2016, 374 p. Available at: <https://doi.org/10.1201/b19336>.
17. *Slin'ko O.V., Kondrat'ev O.V.* Robotizirovannye sredstva v sadovodstve [Robotic tools in horticulture], *Teoriya i praktika sovremennoy agrarnoy nauki* [Theory and practice of modern agricultural science], 2022, pp. 615-618.
18. *Kondrat'eva O.V., Slin'ko O.V., Fedorov A.D.* Razvitie robotizirovannykh sistem v sadovodstve [Development of robotic systems in horticulture], *Agropromyshlennyy kompleks: problemy i perspektivy razvitiya* [Agro-industrial complex: problems and development prospects], 2023, pp. 100-106.
19. *Stafford J. et al.* Precision agriculture for sustainability. Burleigh Dodds Science Publishing Limited, 2019, 494 p. Available at: <https://doi.org/10.1201/9781351114592>.
20. *Philip J.R.* The theory of infiltration: 1. The infiltration equation and its solution, *Soil science*, 1957, Vol. 83, No. 5, pp. 345-358. Available at: <http://dx.doi.org/10.1097/00010694-195705000-00002>.
21. *Despommier D.* The vertical farm: Feeding the world in the 21st century. New York: St. – Martin's Press, 2010, 159 p.
22. *Wang Y. et al.* GSSM: A global seamless soil moisture dataset from 1981 to 2022 matching CCI to SMAP with a novel bias correction method, *Earth System Science Data Discussions*, 2024, Vol. 2024, pp. 1-27. Available at: <https://doi.org/10.5194/essd-2024-200>.
23. *Lamprecht C.* Meteostat API. Available at: <https://meteostat.net/en/blog/introduction-meteostat-rapidapi>.

**Обайд Саадулдин Садах** – Тамбовский государственный технический университет; e-mail: saadmonster555@gmail.com; г. Тамбов, Россия; кафедра «Информационные процессы и управление»; аспирант; ORCID: 0009-0002-76953257; SPIN-код: 9620-2914.

**Погонин Василий Александрович** – Тамбовский государственный технический университет; e-mail: pogvas@inbox.ru; г. Тамбов, Россия; кафедра «Информационные процессы и управление»; д.т.н.; профессор; SPIN-код: 3040-4060.

**Кирина Ирина Борисовна** – Мичуринский государственный аграрный университет; e-mail: rodina1947@mail.ru; г. Мичуринск, Россия; кафедра «Садоводства, биотехнологий, селекции и семеноводства сельскохозяйственных культур»; к.с.-х.н.; доцент; зав. кафедрой; ORCID: 0000-0001-6765-8753; SPIN-код: 7143-4500.

**Obaid Saaduldin Sadakh** – Tambov State Technical University; e-mail: saadmonster555@gmail.com; Tambov, Russia; the Department of Information Processes and Management; postgraduate student; ORCID: 0009-0002-76953257; SPIN code: 9620-2914.

**Pogonin Vasily Aleksandrovich** – Tambov State Technical University; e-mail: pogvas@inbox.ru; Tambov, Russia; the Department of Information Processes and Management; dr. of eng. sc.; professor; SPIN-code: 3040-4060.

**Kirina Irina Borisovna** – Michurinsk State Agrarian University; e-mail: rodina1947@mail.ru; Michurinsk, Russia; the Department of "Horticulture, Biotechnology, Breeding and Seed Production of Agricultural Crops"; cand. of agr. sc.; associate professor; head of department; ORCID: 0000-0001-6765-8753; SPIN-code: 7143-4500.