

УДК 631.95+004.8

ИНТЕГРАЦИЯ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ РАННЕГО ОБНАРУЖЕНИЯ ПАТОГЕНОВ В РАСТЕНИЯХ НА ОСНОВЕ АНАЛИЗА ХЛОРОФИЛЛА

^{1*} *Абдурахимов А.А.,* ² *Пономарев К.О.,* ² *Прохошин А.С.*

*az.abdurakhimov@gmail.com

¹ Научно-исследовательский институт развития цифровых технологий и искусственного интеллекта,

100125, Узбекистан, г. Ташкент, Мирзо-Улугбекский р-он, м-в Буз-2, д. 17А;

² Тюменский государственный университет,

625003, Россия, г. Тюмень, ул. Володарского, д. 6.

В данном исследовании анализируются индексы хлорофилла в растениях как индикаторы наличия фитопатогенов и абиотического стресса. Особое внимание уделяется идентификации ранних признаков заражения земляники паутинным клещом с анализом уровня пигментов растения и использованием методов машинного обучения. Измерение индексов хлорофилла А, В и общего хлорофилла, необходимых для выявления степени влияния стрессового фактора на растение, проводилось с использованием спектрометра CI-710s. Анализ данных о содержании хлорофилла позволил определить начало стрессового состояния растения. Применение алгоритмов машинного обучения к табличным данным значительно повысило эффективность диагностики и предсказания рисков развития заболеваний.

Ключевые слова: хлорофилл, машинное обучение, обнаружение фитопатогенов, заражение, абиотический стресс.

Цитирование: *Абдурахимов А.А., Пономарев К.О., Прохошин А.С.* Интеграция методов машинного обучения для раннего обнаружения патогенов в растениях на основе анализа хлорофилла // Проблемы вычислительной и прикладной математики. – 2024. – № 5(61). – С. 107-114.

1 Введение

Интеллектуальный мониторинг значительно повышает устойчивость и эффективность сельского хозяйства. Интеграция интеллектуальных систем мониторинга и управления, основанных на машинном обучении, революционизирует аграрный сектор, переводя его от традиционных методов к точному земледелию, управляемому данными. Этот подход использует машинное обучение и аналитику больших данных для мониторинга состояния сельскохозяйственных культур и условий окружающей среды в режиме реального времени, что позволяет осуществлять точное орошение, внесение удобрений и борьбу с вредителями [1, 2].

Интеллектуальная система на основе машинного обучения анализирует данные о вспышках болезней и нашествиях вредителей, позволяя агрономам и фермерам принимать превентивные меры защиты [3]. Паутинные клещи являются серьезными вредителями земляники, которые приводят к значительным потерям урожая. Современные методы машинного обучения могут существенно улучшить процесс диагностики состояния растений, предоставляя возможности для раннего обнаружения и предотвращения распространения заболеваний. Используя данные о содержании хлорофилла и других физиологических показателях, применением алгоритмов машинного обучения, как метод случайного леса, можно эффективно анализировать

большие объемы информации, выявляя закономерности, указывающие на начало стресса или заболевания растений. Данный подход не только повышает точность диагностики, но и сокращает время, необходимое для реакции на угрозы, что является ключевым фактором для поддержания устойчивости и продуктивности сельскохозяйственных культур.

Методы машинного обучения делают сельское хозяйство более оперативным, адаптивным и менее ресурсоемким. Несмотря на трудности внедрения новых технологий, включая высокую стоимость и технические сложности, преимущества интеллектуальных систем значительны: повышение урожайности, снижение воздействия на окружающую среду и финансовая стабильность фермеров [4].

Таким образом, интеграция машинного обучения и передовых аналитических методов открывает новые возможности для агрономии, предоставляя фермерам инструменты для более точного и своевременного управления здоровьем растений. Раннее обнаружение стрессовых факторов, влияющих на урожайность и качество продукции, является важной задачей, решаемой методами машинного обучения [5].

2 Связанные работы

В многочисленных исследованиях неоднократно демонстрировалась возможность оценки состояния растительных ассоциаций по спектральному вегетационному индексу NDVI [6]. Однако уровень хлорофилла и ряд других физиологических параметров, измеренных физически, а не дистанционно, могут показать более точный и быстрый результат по наличию абиотического стресса у растений, вызванного фитопатогенами [7, 8]. Кроме того, стоит отметить, что в настоящее время всё чаще используется машинное обучение для решения сложных задач, в которых взаимосвязи и закономерности заранее не определены. Возможности алгоритмов машинного обучения при разработке моделей, направленных на прогноз заболеваний, демонстрируются исследователями во многих работах (например, [9]). Можно сделать вывод, что использование машинного обучения имеет огромный потенциал и отличные перспективы при изучении физиологии растений, которые явно реагирует на различные виды стресса (засуха, засоление, внедрение патогена), например, изменяя форму листа или уровень хлорофилла в листьях [10].

Внедрение новых цифровых и интеллектуальных технологий играет важную роль в области защиты растений. Так, авторы [11] показали возможность использования нейронной сети в качестве программного ядра online-систем дистанционного фитосанитарного мониторинга растений. Они использовали индекс когнитивной значимости (CSI) для определения инфицирования растений фитопатогенной микрофлорой.

Разработаны модели заболевания растений в системы типа «вредитель - растение» [1]. В работе авторов Nguyen, C., et al разработана модель глубокого обучения с помощью гиперспектральной визуализации выявление вирусных заболеваний растений. В исследованиях [4] проведен анализ влияния абиотического стресса на уровень хлорофилла и предложены методы диагностики с использованием алгоритмов машинного обучения.

Известно [8], что наиболее используемая модель в машинном обучении является модель случайного леса. В работах [5] и [12] предложены модели, использующие случайный лес и нейронные сети для классификации состояния растений по спектральным данным. В статье [13] исследовалось применение алгоритмов глубокого обучения для классификации овощных трипсов и паутинного клеща на ранних стадиях заражения растений.

Вышеуказанные работы подтверждают тот факт, что применение алгоритмов машинного обучения предоставляет возможность осуществлять мониторинг и управление развитием растений. Однако требуются большие объемы данных, имеющих в свободном доступе, или собственные результаты, полученные в контролируемых условиях с использованием высокоточного дорогостоящего оборудования.

3 Методы

Для разработки модели машинного обучения по предсказанию наличия фитопатогенов на основе спектральных данных необходим набор данных. Получение достоверных результатов проведено неразрушающим методом измерения уровней хлорофилла растений. В качестве исследуемых растений выбрана земляника садовая (*Fragaria × ananassa* Duch.) сорта Мурано, выращенная в лабораторных условиях Института экологической и сельскохозяйственной биологии (Х-БИО) Тюменского государственного университета с марта по сентябрь 2023 года. Растения выращивались методом гидропоники в пластиковых горшках на минеральной вате в фитотроне. Полив осуществлялся минеральными удобрениями по технологической карте, разработанной сотрудниками лаборатории. Экспериментальные условия поддерживались следующим образом: температура воздуха $18 \pm 2^\circ\text{C}$, относительная влажность $18 \pm 10\%$, фотопериод 16:8 часов (свет:темнота). Для создания условий абиотического стресса растения заражались атлантическим паутинным клещом (*Tetranychus atlanticus* McGregor, 1941).

Сбор данных о состоянии растений проводился ежедневно с помощью спектрометра CI-710s (CID Bio-Science, США). Измерялись уровни хлорофилла А (CPHLA), хлорофилла В (CPHLB), общий хлорофилл (CPHLT), индексы отражения каротиноидов (CRI1 и CRI2) и водный индекс (WBI). Все собранные данные экспортировались в формат CSV для последующей обработки.

Для анализа данных использовался программный пакет *Python* с библиотеками *Streamlit*, *pandas*, *matplotlib*, *seaborn* и *scikit-learn*. Библиотека *Streamlit* применялась для создания интерактивного веб-приложения, позволяющего пользователям загружать данные и следить за моделированием в реальном времени. Для классификации данных использовалась модель случайного леса (*Random Forest Classifier*) из библиотеки *scikit-learn*. Выбор алгоритма связан с высокой точностью и способностью работать с большими объемами данных, что делает его особенно подходящим для задач, связанных с классификацией [8]. Разделение данных на тренировочный и тестовый наборы проводили с помощью функции *train_test_split*, что позволило оценить надежность модели на независимых данных.

Модель случайного леса объединяет результаты нескольких деревьев решений, что снижает вероятность ошибок в предсказаниях. Основное уравнение модели:

$$y - \frac{1i}{n_{trees}} = \sum_{i=1}^{n_{trees}} T_i(x), \quad (1)$$

где $T_i(x)$ – результат предсказания одного дерева, n_{trees} – количество деревьев в лесу, x – входные данные.

Важность каждого признака оценивается суммированием его вклада во всех деревьях модели:

$$Feature Importance = \sum_{i=1}^{n_{trees}} I(T_i, f), \quad (2)$$

где $I(T_i, f)$, – вклад признака f в дереве T_i .

Для оценки качества модели использовалась матрица путаницы, которая позволяет оценить количество истинно положительных (TP), истинно отрицательных (TN), ложноположительных (FP) и ложноотрицательных (FN) предсказаний. На её основе вычисляются ключевые метрики:

$$\text{Точность} - \text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}, \quad (3)$$

$$\text{Полнота} - \text{Recall} = \frac{TP}{TP + FN}, \quad (4)$$

$$\text{Погрешность} - \text{Precision} = \frac{TP}{TP + FP}. \quad (5)$$

ROC – кривая (Receiver Operating Characteristic). ROC – кривая строится на основе соотношения истинно положительных и ложноположительных предсказаний:

TPR (True Positive Rate) – доля истинно положительных

$$TPR = \frac{TP}{TP + FN}. \quad (6)$$

FPR (False Positive Rate) – доля ложноположительных:

$$FPR = \frac{FP}{FP + TN}, \quad (7)$$

AUC (Area Under the Curve). Площадь под ROC – кривой (AUC) используется для оценки качества модели:

$$AUC = \int_0^1 TPR(FPR) d(FPR). \quad (8)$$

Для визуализации данных и результатов модели использовались библиотеки matplotlib и seaborn. Было разработано интерактивное веб-приложение на основе библиотеки *Streamlit*, позволяющее загружать и обрабатывать новые данные, изменять параметры входных данных и наблюдать влияние изменений на предсказания модели в реальном времени.



Рис. 1 Схема сельскохозяйственной системы мониторинга и управления для анализа уровня хлорофилла в листьях растений

4 Результаты

Модель случайного леса продемонстрировала высокую точность в предсказании наличия фитопатогенов на основе спектральных данных о хлорофилле и других физиологических параметрах растений. Важность признаков была оценена с помощью метода случайного леса, что позволило выявить основные индикаторы стресса у растений, вызванного фитопатогенами (рисунок 2).




Рис. 2 Важность признаков для модели случайного леса

Из рисунка 2 видно, что наибольший вклад в предсказание модели вносит уровень хлорофилла В (CPHLB), что согласуется с результатами других исследований [13], показывающих его высокую чувствительность к абиотическим стрессорам. Далее следуют индексы отражения каротиноидов CRI2 и CRI1. Меньшее влияние оказывают общий хлорофилл (CPHLT), хлорофилл А (CPHLA) и водный индекс (WBI).

Важность признаков для модели случайного леса помогает понять, какие физиологические параметры растений более важны для определения наличия патогена. Это может быть полезно для агрономов и исследователей, желающих оптимизировать процесс диагностики и выявления болезней в растениях, а также для дальнейшего совершенствования модели.

На рисунке 3 представлена матрица путаницы и ROC-кривая модели.

Модель, верно, предсказала 9 случаев отсутствия патогена (истинно отрицательные) и 11 случаев наличия патогена (истинно положительные). Были зафиксированы 2 ложноположительных и 1 ложноотрицательное предсказание, что свидетельствует о высокой точности модели с минимальными ошибками в предсказаниях. Ключевой показатель — AUC, равный 0.97, указывает на высокую чувствительность и специфичность модели при предсказании наличия патогенов растений, ось X : доля ложноположительных срабатываний (FPR), ось Y : доля истинноположительных срабатываний (TPR).

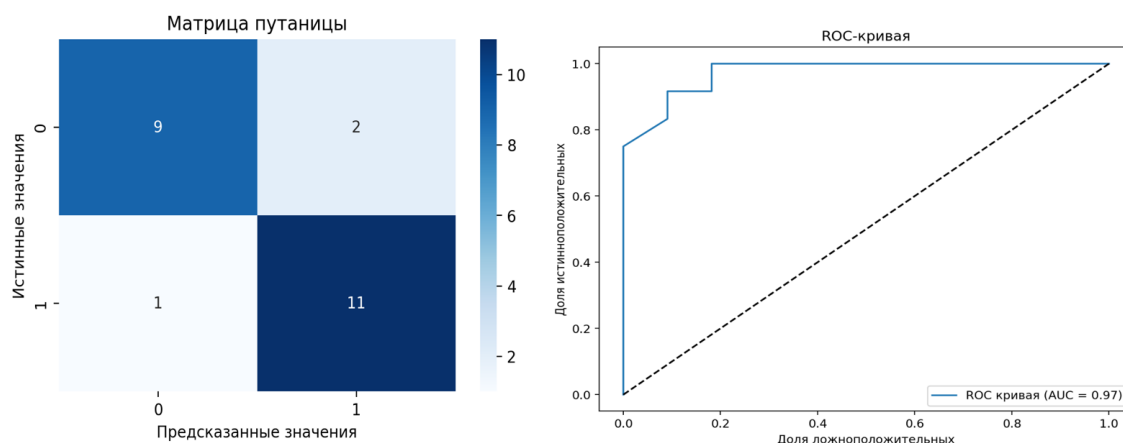


Рис. 3 График матрицы путаницы (а) и ROC-кривая (б): черная пунктирная линия - случайные предсказания, синяя линия - производительность модели

Исследование выполнено при финансовой поддержке Российского научного фонда в рамках проекта № 23-76-01011 (<https://rscf.ru/project/23-76-01011/>).

5 Заключение

В исследовании показано, что использование методов машинного обучения, таких как случайный лес, позволяет эффективно выявлять фитопатогены на ранних стадиях на основе спектральных данных о содержании хлорофилла и других физиологических показателях растений. Результаты анализа важности признаков, матрицы путаницы и ROC-кривой демонстрируют высокую точность и эффективность предложенной модели.

Рекомендовано дальнейшее использование предложенной методологии в реальных агрономических условиях для мониторинга состояния сельскохозяйственных культур, что может способствовать своевременному обнаружению и предотвращению распространения заболеваний, а также повышению урожайности.

Литература

- [1] Шамилев С.Р. Биолого-математическое и компьютерное моделирование заболевания растений // Экономика. Бизнес. Информатика. – 2017. – Т. 3. – № 2. – С. 130–145.
- [2] Адылова Ф.Т., Давронов Р.Р., Сафаров Р.А. Универсальный подход к интерпретации результатов прогнозирования моделей машинного обучения // Проблемы вычислительной и прикладной математики. – 2022. – № 4(42). – С. 128–137.
- [3] Nguyen C., Sagan V., Maimaitiyiming M., Maimaitijiang M., Bhadra S., Kwasniewski M.T. Sensors (Switzerland). – 2021. – Vol. 21. – No. 3. – P. 1–23. doi: 10.3390/s21030742.
- [4] Kalaji H.M., Jajoo A., Oukarroum A., Brestic M., Zivcak M., Samborska I.A., Cetner M. D., Lukasik I., Goltsev V., Ladle R. J. Chlorophyll a fluorescence as a tool to monitor physiological status of plants under abiotic stress conditions. // Acta Physiologiae Plantarum. – 2016. – Vol. 38. – No. 4. – P. 1–11. doi: 10.1007/s11738-016-2113-y.
- [5] Raczko E., Zagajewski B. Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images // European Journal of Remote Sensing. – 2017. – Vol. 50. – No. 1. – P. 144–154. doi: 10.1080/22797254.2017.1299557.
- [6] Онаев М.К., Туктаров Р.Б., Тарбаев В.А., Гафуров Р.Р. Использование спутниковых методов исследований в изучении режима затопления и современного состояния рас-

- тительного покрова лиманов. // Успехи современного естествознания. – 2018. – № 7. – С. 183–188.
- [7] Савин И.Ю., Коновалов С.Н., Бобкова В.В., Шарычев Д.В. Спектральные вегетационные индексы как индикаторы содержания пигментов в листьях яблони (*Malus domestica* Borkh.) // Sel'skokhozyaistvennaya Biologiya. – 2023. – Т. 58. – № 3. – С. 473–482. doi: 10.15389/agrobiology.2023.3.473rus.
- [8] Бардина Т.В., Чугунова М.В., Кулибаба В.В., Бардина В.И. Использование методов биотестирования для оценки экологического состояния почвогрунтов рекультивированного карьера // Биосфера. – 2020. – Т. 12. – № 1–2. – С. 1–11. doi: 10.24855/biosfera.v12i1.539.
- [9] Равшанов Н., Пекось О.А., Бакаев И.И. Прогнозирование сердечно-сосудистых заболеваний методами машинного обучения. // Проблемы вычислительной и прикладной математики. – 2023. – № 1(46). – С. 109–115.
- [10] Демидчик В.В., Шапко А.Ю., Бондаренко В.Ю., Смоликова Г.Н., Пржевальская Д.А., Черныш М.А., Пожванов Г.А., Барковский А.В., Смолич И.И., Соколик А.И., Ю М., Медведев С.С. Феномика растений: фундаментальные основы, программно-аппаратные платформы и методы машинного обучения. Физиология Растений. – 2020. – Т. 67. – № 3. – С. 227–245. doi: 10.31857/s0015330320030069.
- [11] Воробьев Н.И., Лысов А.К., Корнилов Т.В., Хютти А.В. Вычислительная нейросеть для обработки светоотражательных спектров растений и дистанционного фитосанитарного мониторинга картофеля // Аграрная наука Евро-Северо-Востока. – 2024. – Т. 25. – № 2. – С. 283–292. doi: 10.30766/2072-9081.2024.25.2.283-292.
- [12] Knauer U., von Rekowski C.S., Stecklina M., Krokotsch T., Minh T.P., Hauffe V., Kiliass D., Ehrhardt I., Sagischewski H., Chmara S., Seiffert U. Tree species classification based on hybrid ensembles of a convolutional neural network (CNN) and random forest classifiers. Remote Sensing // – 2019. – Vol. 11. – No. 23. – P. 1–15. doi: 10.3390/rs11232788.
- [13] Nguyen D., Tan A., Lee R., Lim W.F., Hui T.F., Suhaimi F. Early detection of infestation by mustard aphid, vegetable thrips and two-spotted spider mite in bok choy with deep neural network (DNN) classification model using hyperspectral imaging data // Computers and Electronics in Agriculture. – 2024. – Vol. 220. doi: 10.1016/j.compag.2024.108892.
- [14] Shin Y.K., Bhandari S.R., Lee J.G. Monitoring of salinity, temperature, and drought stress in grafted watermelon seedlings using chlorophyll fluorescence // Frontiers in Plant Science. – 2021. – Vol. 12. – P. 786309. doi: 10.3389/fpls.2021.786309.

Поступила в редакцию 21.10.2024

UDC 631.95+004.8

INTEGRATION OF MACHINE LEARNING METHODS FOR EARLY DETECTION OF PATHOGENS IN PLANTS BASED ON CHLOROPHYLL ANALYSIS

^{1*}Abdurakhimov A.A., ²Ponomarev K.O., ²Prokhoshin A.S.

*az.abdurakhimov@gmail.com

¹Digital Technologies and Artificial Intelligence Development Research Institute,
17A, Buz-2, Tashkent, 100125 Uzbekistan;

²Tyumen State University, 6, Volodarsky st., Tyumen, 625003 Russia.

His study analyses chlorophyll indices in plants as indicators of the presence of phytopathogens and abiotic stress. Special attention is given to the identification of early signs of strawberry spider mite infestation by analysing plant pigment levels and using machine learning methods. The measurement of chlorophyll A, B and total chlorophyll indices, which are necessary to identify the degree of effect of stress factors on the plant, was carried out using a CI-710s spectrometer. Analysis of the chlorophyll content data allowed the onset of plant stress to be determined. The application of machine learning algorithms to the tabular data significantly increased the efficiency of the diagnosis and prediction of the risk of disease development.

Keywords: Chlorophyll, machine learning, phytopathogen detection, infestation, abiotic stress.

Citation: Abdurakhimov A.A., Ponomarev K.O., Prokhoshin A.S. 2024. Integration of machine learning methods for early detection of pathogens in plants based on chlorophyll analysis. *Problems of Computational and Applied Mathematics*. 5(61): 107-114.

ПРОБЛЕМЫ ВЫЧИСЛИТЕЛЬНОЙ И ПРИКЛАДНОЙ МАТЕМАТИКИ

№ 5(61) 2024

Журнал основан в 2015 году.

Издается 6 раз в год.

Учредитель:

Научно-исследовательский институт развития цифровых технологий и
искусственного интеллекта.

Главный редактор:

Равшанов Н.

Заместители главного редактора:

Азамов А.А., Арипов М.М., Шадиметов Х.М.

Ответственный секретарь:

Ахмедов Д.Д.

Редакционный совет:

Азамова Н.А., Алоев Р.Д., Амиргалиев Е.Н. (Казахстан), Бурнашев В.Ф.,
Загребина С.А. (Россия), Задорин А.И. (Россия), Игнатъев Н.А.,
Ильин В.П. (Россия), Исмагилов И.И. (Россия), Кабанихин С.И. (Россия),
Карачик В.В. (Россия), Курбонов Н.М., Маматов Н.С., Мирзаев Н.М.,
Мирзаева Г.Р., Мухамадиев А.Ш., Назирова Э.Ш., Нормуродов Ч.Б.,
Нуралиев Ф.М., Опанасенко В.Н. (Украина), Расулмухамедов М.М., Расулов А.С.,
Садуллаева Ш.А., Старовойтов В.В. (Беларусь), Хаётов А.Р., Халджигитов А.,
Хамдамов Р.Х., Хужаев И.К., Хужаеров Б.Х., Чье Ен Ун (Россия),
Шабозов М.Ш. (Таджикистан), Dimov I. (Болгария), Li Y. (США),
Mascagni M. (США), Min A. (Германия), Schaumburg H. (Германия),
Singh D. (Южная Корея), Singh M. (Южная Корея).

Журнал зарегистрирован в Агентстве информации и массовых коммуникаций при
Администрации Президента Республики Узбекистан.

Регистрационное свидетельство №0856 от 5 августа 2015 года.

ISSN 2181-8460, eISSN 2181-046X

При перепечатке материалов ссылка на журнал обязательна.

За точность фактов и достоверность информации ответственность несут авторы.

Адрес редакции:

100125, г. Ташкент, м-в. Буз-2, 17А.

Тел.: +(998) 712-319-253, 712-319-249.

Э-почта: journals@airi.uz.

Веб-сайт: <https://journals.airi.uz>.

Дизайн и вёрстка:

Шарипов Х.Д.

Отпечатано в типографии НИИ РЦТИИ.

Подписано в печать 30.10.2024 г.

Формат 60x84 1/8. Заказ №7. Тираж 100 экз.

PROBLEMS OF COMPUTATIONAL AND APPLIED MATHEMATICS

No. 5(61) 2024

The journal was established in 2015.
6 issues are published per year.

Founder:

Digital Technologies and Artificial Intelligence Development Research Institute.

Editor-in-Chief:

Ravshanov N.

Deputy Editors:

Azamov A.A., Aripov M.M., Shadimetov Kh.M.

Executive Secretary:

Akhmedov D.D.

Editorial Council:

Azamova N.A., Alov R.D., Amirgaliev E.N. (Kazakhstan), Burnashev V.F.,
Zagrebina S.A. (Russia), Zadorin A.I. (Russia), Ignatiev N.A., Ilyin V.P. (Russia),
Ismagilov I.I. (Russia), Kabanikhin S.I. (Russia), Karachik V.V. (Russia), Kurbonov
N.M., Mamatov N.S., Mirzaev N.M., Mirzaeva G.R., Mukhamadiev A.Sh., Nazirova
E.Sh., Normurodov Ch.B., Nuraliev F.M., Opanasenko V.N. (Ukraine), Rasulov A.S.,
Sadullaeva Sh.A., Starovoitov V.V. (Belarus), Khayotov A.R., Khaldjigitov A.,
Khamdamov R.Kh., Khujaev I.K., Khujayorov B.Kh., Chye En Un (Russia),
Shabozov M.Sh. (Tajikistan), Dimov I. (Bulgaria), Li Y. (USA), Mascagni M. (USA),
Min A. (Germany), Schaumburg H. (Germany), Singh D. (South Korea),
Singh M. (South Korea).

The journal is registered by Agency of Information and Mass Communications under the
Administration of the President of the Republic of Uzbekistan.

The registration certificate No. 0856 of 5 August 2015.

ISSN 2181-8460, eISSN 2181-046X

At a reprint of materials the reference to the journal is obligatory.
Authors are responsible for the accuracy of the facts and reliability of the information.

Address:

100125, Tashkent, Buz-2, 17A.

Tel.: +(998) 712-319-253, 712-319-249.

E-mail: journals@airi.uz.

Web-site: <https://journals.airi.uz>.

Layout design:

Sharipov Kh.D.

DTAIDRI printing office.

Signed for print 30.10.2024

Format 60x84 1/8. Order No. 7. Printed copies 100.

Содержание

Равшанов Н., Шадманов И.

Многомерная математическая модель одновременного тепло- и влагопереноса при сушке и хранении хлопка-сырца на открытых площадках 5

Туракулов Ж.

Численное исследование процесса фильтрования малоконцентрированных растворов через пористую среду 18

Мирзаахмедов М.К.

Математическое моделирование процессов термо-электро-магнитоупругой деформации тонких пластин сложной конструктивной формы 31

Халджигитов А.А., Джумаёзов У.З., Усмонов Л.С.

Новые связанные краевые задачи термоупругости в деформациях 43

Нормуродов Ч.Б., Зиякулова Ш.А.

Численное моделирование уравнений эллиптического типа дискретным вариантом метода предварительного интегрирования 59

Фаязов К.С., Рахимов Д.И., Фаязова З.К.

Некорректная начально-краевая задача для уравнения смешанного типа третьего порядка 69

Игнатъев Н.А., Абдуллаев К.Д.

Разметка документов по семантическим ролям 80

Зайнидинов Х.Н., Ходжаева Д.Ф., Хурамов Л.Я.

Продвинутые модели обработки сигналов в системе умного дома 91

Абдурахимов А.А., Пономарев К.О., Прохошин А.С.

Интеграция методов машинного обучения для раннего обнаружения патогенов в растениях на основе анализа хлорофилла 107

Xalikov A.A., Xurramov A.Sh.

"Pop-Namangan-Andijon" uchastkasining temir yo'l transport tarmog'ida radioaloqa ishonchliligini hisoblashning mantiqiy-ehtimoliy modeli 115

Contents

Ravshanov N., Shadmanov I.

Multidimensional mathematical model of simultaneous heat and moisture transfer during drying and storage of raw cotton in open areas 5

Turakulov J.

Numerical study of the process of filtration of low-concentration solutions through a porous medium 18

Mirzaakhmedov M.K.

Mathematical modeling of thermo-electro-magnit-elastic deformation processes of thin plates of complex constructive form 31

Khaldjigitov A.A., Djumayozov U.Z., Usmonov L.S.

New coupled thermoelasticity boundary-value problems in strains 43

Normurodov Ch.B., Ziyakulova Sh.A.

Numerical modeling of elliptic type equations by a discrete variant of the pre-integration method 59

Fayazov K.S., Rahimov D.I., Fayazova Z.K.

Ill-posed initial-boundary value problem for a third-order mixed type equation . . 69

Ignatev N.A., Abdullaev K.D.

Document annotation by semantic roles 80

Zaynidinov H., Hodjaeva D., Xuramov L.

Advanced signal processing models in a smart home system 91

Abdurakhimov A.A., Ponomarev K.O., Prokhoshin A.S.

Integration of machine learning methods for early detection of pathogens in plants based on chlorophyll analysis 107

Khalikov A.A., Khurramov A.Sh.

The logical-probable model of calculating the reliability of the radio communication in rail transpot network of the "Pop-Namangan-Andijan"plot 115