

10. <https://proglib.io/p/bootstrap-4-part-1>
11. Materials of the website "Metanit" [Electronic resource]. – Access mode: <https://metanit.com/>
12. Materials of the website "Internet work" [Electronic resource]. – Access mode: <http://blogwork.ru/>
13. Timur Mashnin, Bootstrap: fast creation of modern websites, 2016, 66с.
14. Bootstrap components [Electronic resource] // URL: <https://getbootstrap.com/docs/3.3/components>
15. Bootstrap in the examples. / Translated from English. Rahimov R. N. / Scientific ed. Kiselev A. N. – M.: DMK Press, 2017. – 314 p.
16. N. Poluektova, Development of web applications : a textbook for universities / N.R. Poluektova. — Moscow : Yurayt Publishing House, 2022.
17. John Duckett: "HTML and CSS. Website development and design", Publishing house: EXMO, 2020
18. Ilya Sidorenko, "Interface designer. Principles of work and career building", Publishing house: Olympus-Business, 2019
19. IT Blog. Linux-based server administration (Ubuntu, Debian, CentOS, openSUSE) // Bootstrap Framework tutorial: a study conducted by PwC. - Moscow-2019. - access mode: <https://andreyex.ru/uchebnoe-posobie-po-framework-bootstrap/>
20. Research conducted by Copyright © 2020 Rudebox Design [Electronic resource] – Access mode: <https://www.rudebox.org.ua/bootstrap-5-what-is-new-and-release-date>.

АННОТАЦИЯ

В данной статье рассматривается концепция адаптивного дизайна в процессе создания веб-сайта. Раскрыта суть фронтэнд-фреймворков и их разновидностей, а также описан подробный анализ фреймворка Bootstrap. Сделан вывод, что фреймворки Bootstrap и подобные им упрощают процесс веб-разработки и облегчают разработку адаптивного дизайна веб-сайта. Мир веб-программистов уже видел Bootstrap 5, но многих до сих пор интересует, что нового принесла в себе Bootstrap 4.. Потому что именно эта версия привнесла новый виток технологий в этот фреймворк и зарекомендовала себя как стабильный и эффективный инструмент для веб-разработки. Bootstrap - это популярный набор инструментов для веб-приложений и пользовательских интерфейсов с использованием HTML, CSS и JavaScript. Основой адаптивного дизайна являются правила media queries, которые описывают стилистические свойства элементов для разных разрешений экрана. Кроме того, Bootstrap использует динамический язык стилей LESS, который расширяет возможности CSS: разработчики могут управлять цветами, создавать вложенные столбцы и переменные.

БЛАГОДАРНОСТЬ

Эта публикация является результатом реализации проекта Erasmus+ «Передовой центр для докторантов и молодых исследователей в области информатики» (ACeSYRI), регистрационный номер 610166-EPP-1-2019-1-SK-EPPKA2-CBHE-JP.

УДК 004.942
МРНТИ 28.23.37

Камышова Г. Н., кандидат физико-математических наук, доцент, <https://orcid.org/0000-0002-8569-6259>

Финансовый университет при Правительстве Российской Федерации, г. Москва, Ленинградский проспект 49/2, 125167, Россия, gnkamyshova@fa.ru

Бапиев И. М., доктор Ph.D, <https://orcid.org/0000-0001-8468-8938>

НАО «Западно-Казахстанский аграрно-технический университет имени Жангир хана», г. Уральск, ул. Жангир хана 51, 090009, Казахстан, bapiev@mail.ru

Терехова Н. Н., кандидат технических наук, доцент, <https://orcid.org/0000-0001-7724-6517>

Саратовский государственный университет генетики, биотехнологии и инженерии им. Н.И. Вавилова, г. Саратов, пр-кт им. Петра Столыпина 4 стр3, 410012, Россия, nterehova2015@yandex.ru

Kamyshova G. N., Candidate of Physical and Mathematical Sciences, Associate Professor, <https://orcid.org/0000-0002-8569-6259>

Financial University under the Government of the Russian Federation, Moscow, Leningradsky prospect 49/2, 125167, Russia, gnkamyshova@fa.ru

Bapiyev I. M., Ph.D., <https://orcid.org/0000-0001-8468-8938>

NJSC "West Kazakhstan Agrarian Technical University named after Zhangir Khan", Uralsk, st. Zhangir Khan 51, 090009, Kazakhstan, bapiyev@mail.ru

Terekhova N. N., candidate of technical sciences, associate professor, <https://orcid.org/0000-0001-7724-6517>, Saratov State University of Genetics,

Biotechnology and Engineering named after N.I. Vavilov, Saratov, Ave. Petra Stolypina 4 building 3, 410012, Russia, nterehova2015@yandex.ru

НЕЙРОСЕТЕВЫЕ МОДЕЛИ ДЛЯ УВЕЛИЧЕНИЯ ПОТЕНЦИАЛА ТЕРРИТОРИЙ РИСКОВАННОГО ЗЕМЛЕДЕЛИЯ NEURAL NETWORK MODELS TO INCREASE THE POTENTIAL OF RISK FARMING TERRITORIES

АННОТАЦИЯ

Изменение климата становится одной из глобальных проблем нашего столетия, и, безусловно, влияет на все сферы деятельности человека. Однако особенно подвержено этому влиянию сельское хозяйство, а как следствие задача обеспечения населения планеты достаточным количеством продовольствия становится еще более сложной задачей, в то время как население планеты неуклонно растет. Современный этап развитие цифровых технологий и методов интеллектуального анализа данных, позволяет даже на локальном уровне оперировать как глобальными климатическими данными, так и государственными и локальными данными, наряду с данными специальных систем управления агробизнесом. Однако, эта информация остается зачастую невостребованной и требует разработки новых подходов, моделей и сервисов, позволяющих оптимизировать методы управления, чтобы уменьшить воздействие изменчивости климата для эффективного снижения рисков на уровне фермерских хозяйств. В настоящее время, появилось много новых инструментов, позволяющих создавать интеллектуальные модели, одним из которых выступают искусственные нейронные сети. Целью настоящей работы является создание модели на основе нескольких архитектур нейронных сетей для прогнозирования биоклиматического потенциала разных территорий одного региона имеющих значительно отличающиеся общие климатические характеристики. В результате мы получаем, что использование комбинация нескольких искусственных нейронных сетей (многослойной и вероятностной) приводит к улучшению точности прогноза и, как следствие, снижению сельскохозяйственных рисков.

ANNOTATION

Climate change is becoming one of the global problems of our century, and, of course, affects all spheres of human activity. However, agriculture is particularly susceptible to this influence, and as a result, the task of providing the world's population with enough food becomes even more difficult, while the world's population is steadily growing. The current stage of development of digital technologies and methods of data mining allows even at the local level to operate both global climate data and state and local data, along with data from special agribusiness management systems. However, this information often remains unclaimed and requires the development of new approaches, models and services to optimize management practices in order to reduce the impact of climate variability in order to effectively reduce risks at the farm level. Currently, many new tools have appeared that allow you to create intelligent models, one of which is artificial neural networks. The aim of this work is to create a model based on several architectures of neural networks to predict the bioclimatic potential of different territories of the same region with significantly different general

climatic characteristics. As a result, we find that the use of a combination of several artificial neural networks (multilayer and probabilistic) leads to an improvement in the accuracy of the forecast and, as a result, to a reduction in agricultural risks.

Ключевые слова: нейронные сети, агроклиматические параметры, рискованное земледелие.

Key words: neural networks, agro-climatic parameters, risk farming.

Введение. Сельское хозяйство сталкивается с серьезной проблемой обеспечения растущего населения мира, которое, согласно прогнозам, к 2050 году увеличится до девяти миллиардов человек, необходимыми продуктами питания [1]. Изменение климата становится одной из глобальных проблем нашего столетия, и, безусловно, влияет на все сферы деятельности человека [2]. Однако особенно подвержено этому влиянию сельское хозяйство, а как следствие *задача обеспечения населения планеты достаточным количеством продовольствия становится еще более сложной задачей.* Даже такие страны как Россия, которые являются наиболее обеспеченными земельными и водными ресурсами для ведения сельского хозяйства, подвержены влиянию изменения климата. Примерно 70-80% территории России находится в так называемой зоне рискованного земледелия, зоне особенно сильно подверженной климатическим колебаниям. Агроклиматические факторы оказывают значительное влияние на сельскохозяйственное производство в зонах рискованного земледелия. Отсюда, сельхозтоваропроизводители всегда искали пути и средства, чтобы справиться с изменчивостью климата, включая использование различных традиционных индикаторов для прогнозирования сезонного поведения климата. Поэтому адекватная оценка и прогнозирование агроклиматических факторов это основа устойчивого развития сельского хозяйства и обеспечения продовольственной безопасности.

За последние два десятилетия были достигнуты значительные успехи в науке и приложениях сезонного прогнозирования климата [3]. Прогнозирование агроклиматических факторов должно быть основано на междисциплинарных исследованиях [4], [5] таких как прогнозирование климата, уменьшение масштабов прогноза с больших территорий до местных приложений, интеграции прогнозов климата в оперативные модели сельскохозяйственных культур для разработки альтернативных сценариев оперативного принятия решений для минимизации воздействия климатических рисков и максимизации выгод для фермерского сообщества, а также наращивание потенциала на местном уровне во всех этих областях.

Следует использовать преимущества существующих баз данных. Так как это позволяет значительно улучшать построение прогнозных моделей и основанных на них программных продуктах. Все это позволит в значительной мере совершенствовать планирование для снижения отрицательного воздействия изменения климата.

Сезонные прогнозы могут быть получены с использованием математических моделей климатической системы. В прогнозировании климата на региональном и национальном уровнях используется широкий спектр методов прогнозирования, как эмпирико-статистических, так и динамических [6].

Так на государственном уровне формируются прогнозы температуры и увлажнения. Данные о сумме температур выше 10°C ($^{\circ}\text{C}$) за 2021 г. и средние значения за 2001–2020 гг. приведены на рисунке 1, данные об Индекс сухости М.И. Будыко за 2021 г. и средние значения за 2001–2020 гг. на рисунке 1 [7].




Рисунок 1 – Сумма температур выше 10°C ($^{\circ}\text{C}$) за 2021 г. и средние значения за 2001–2020 гг. [7]




Рисунок 2 – Индекс сухости М.И. Будыко за 2021 г. и средние значения за 2001–2020 гг.[7]

Однако, предсказание общих климатических трендов требует значительных уточнений на местном уровне с учетом пространственно- временной изменчивости показателей даже в рамках одного региона. Так, например, Саратовская область (Россия) относится к так называемым зонам рискованного земледелия. Значительная изменчивость природно-климатических условий влечет за собой деление области на две существенно различающиеся между собой зоны, разделенные руслом реки Волги (Право- и Левобережье). Помимо этого, выделено 7 природно-экономических микрзон с учетом почвенно-климатических условий [8].

Современный этап развитие цифровых технологий и методов интеллектуального анализа данных, позволяет даже на локальном уровне оперировать как глобальными климатическими данными (мировые сервисы погоды, например World Weather Information Service, Google Earth), так и государственными (Росгидромет) и локальными (региональные отделения Росгидромета и данные специальных систем управления агробизнесом). Например, отражение климатической информации в одной из таких систем Агросигнал.

Однако, эта информация остается зачастую не востребуемой и требует разработки новых подходов, моделей и сервисов, позволяющих оптимизировать методы управления, чтобы уменьшить воздействие изменчивости климата для эффективного снижения рисков и устранения пробелов в урожайности на уровне фермерских хозяйств. В настоящее время, появилось много новых инструментов, позволяющих создавать интеллектуальные модели, одним из которых выступают искусственные нейронные сети (например, [9]-[12]). Различные нейросетевые модели для устойчивого сельского хозяйства и снижения рисков рассматривались в следующих работах [14]-[17]. Целью настоящей работы является создание модели на основе искусственной нейронной сети для прогнозирования биоклиматического потенциала разных территорий одного региона имеющих значительно отличающиеся общие климатические характеристики (температура, осадки и тп).

Материалы и методы исследований. В качестве материалов исследования выступает климатическая информация Правобережья и Левобережья Саратовской области по данным соответствующих метеостанций в период 2010-2020гг. (дата-сеты сайта Погода и климат [18]).

В силу высокой стохастичности климатических процессов, в качестве методов нами предлагаются так называемые статистические нейронные сети [19] (сети радиальных базисных функций), которые, в отличие от обычных нейронных сетей, используют методы, основанные на регрессии. Такие сети используют сходство между наблюдениями предикторов и аналогичными наборами исторических наблюдений (преемников) для получения наилучшей оценки для зависимой переменной. Они представляет собой трехуровневую сеть с одним скрытым уровнем (рисунок3).




Рисунок 3 – Статистическая нейронная сеть

Количество нейронов в скрытом слое равно количеству исторических наблюдений предикторов (преемников). Фактически каждый нейрон в скрытом слое представляет собой пару исторических наблюдений предикторов/зависимых. Выход каждого нейрона на самом деле является вкладом исторического наблюдения в оценку события в реальном времени. Как показано на рисунке 3, эта сеть использует функцию качества Гаусса. Входными данными для этой функции является евклидово расстояние между каждым входным сигналом нейрона и заданным вектором того же размера, что и входной. Функция Гаусса использует следующее соотношение:

$$f(X_r, b) = e^{I^2}, I = \|X_r - X_b\| * 0.8326/h$$

где X_r — вход сети с неизвестным выходом, X_b — наблюдаемые входы во времени или в месте b , а h — разброс (спред). Выход функции приближается от 0 к 1, когда $\|X_r - X_b\|$ приближается от большого значения к 0 соответственно. Значение выхода между этими пределами зависит от h , который также известен как спред.

Тогда общая форма вычисления зависимой переменной (Y_r) с помощью предиктора $X_{r,t}$ выглядит следующим образом:

$$Y_r = LW * f(X_r, X_b) + Bias$$

где LW и $Bias$ это весовая матрица соединений из скрытого слоя в выходной слой и матрица смещения выходного слоя соответственно. При разработке сети матрицы LW и смещения рассчитываются путем решения системы уравнений

$$T_b = LW * f(X_r, b) + Bias,$$

где T_b — цель, связанная с b -м наблюдением. Далее мы настраиваем сеть для определенных наборов (входов X , выходов Y). Мы используем метод проб и ошибок для проверки различных значений спреда, начиная с 0,1 и заканчивая 6 с шагом в 0,1. Вероятностная сеть играет роль точной оценочной функции, применение различных значений разброса в калибровочном наборе приводит к аналогичной усредненной ошибке, равной приблизительно нулю. Поэтому для практического изучения производительности сети используется подход перекрестной проверки. В этом подходе каждая пара входных/выходных данных исключается из n наблюдений набора данных один раз, а остальные $(n-1)$ пары данных используются для оценки пропущенного. Эта итерация повторяется n раз, и усредненная ошибка моделирования для всех n пар данных считается индикатором реальной производительности сети. Таким образом, мы находим такой разброс (h), который минимизирует среднюю ошибку пространственной оценки.

Помимо такого типа сетей мы рассматриваем вероятностные нейронные сети, архитектура которой аналогична архитектуре сети радиальных базисных функций. При представлении входных данных первый слой вычисляет расстояния от входного вектора до калибровочных входных векторов и создает вектор вероятностей в виде $f(X_r, X_b)$. В последнем слое полная передаточная функция на выходе выбирает максимальную из этих вероятностей. Такие сети хорошо работают для задач классификации.

Предлагаемая модель предполагает применение разных сетей, каждая из которых обучена оптимальнее работать в определенных условиях (такой подход применялся в работе [20] для прогнозирования притока). А именно, одна сеть обучена оценивать биоклиматический параметр для засушливых условий, а другая сеть обучена для влажных условий. Для переключения между двумя сетями при прогнозировании в реальном времени, применяется классифицирующая вероятностная нейронная сеть, которая позволяет определить будут ли условия засушливыми или влажными. Схема модели представлена на рисунке 4.




Рисунок 4 – Схема нейросетевой модели

Результаты и их обсуждение. Модель отработывалась на 25-летних дата-сетах. В силу ее универсальности в качестве предикторов и зависимой переменной могут выступать различные биоклиматические параметры. В нашей работе мы рассматривали общую оценку биоклиматического потенциала - показатель, характеризующий сельскохозяйственную продуктивность в данных климатических условиях [21]. В качестве его меры можно принять показатель в форме относительных величин объединяющих влияние тепла, а так же соотношение тепла и влаги.

$$\text{БКП} = K_p \frac{\sum T_{>10^{\circ}\text{C}}}{\sum T_{>10^{\circ}\text{C, база}}}$$

где $\sum T_{>10^{\circ}\text{C}}$ — среднесуточная температура воздуха выше 10°C ; K_p — коэффициент биологической продуктивности климата, зависящий от влагообеспеченности. $\sum T_{>10^{\circ}\text{C, база}} = 1000$. Отношение годовой суммы осадков к испаряемости за год, определяемые различными способами используются в качестве показателей влагообеспеченности. Фрагмент дата-сета для моделирования представлен в таблице 1. В качестве предикторов рассматривались: $\sum T_{>10^{\circ}\text{C}}$ — предиктор 1, $\sum P$ - среднегодовое количество осадков (предиктор 2), $\sum d$ - сумма средних суточных значений дефицита влажности воздуха (предиктор 3), КУ - коэффициент увлажнения (предиктор 4).

Таблица 1 – Пример дата-сета

Год	Предиктор 1	Предиктор 2	Предиктор 3	Предиктор 4	Зависимая переменная: БКП
1996	2885	487	1787	0,29	2,3
1997	2940	423	2208	0,19	1,6
...	...	...			
2020	2739	641	1735	0,37	2,6

На рисунке 4 представлено сравнение статистического и нейросетевого моделирования, полученного с помощью моделей засушливых и влажных условий для трех случайно выбранных лет периода прогнозирования. Синий – фактически рассчитанное значение, красный – статистический прогноз, зеленый – нейросетевой прогноз.




Рисунок 4 – Сравнение результатов моделирования для засушливых (сверху) и влажных (снизу) условий

Сравнение коэффициентов достоверности аппроксимации для засушливых условий – статистический прогноз $R^2 = 0,013$, нейросетевой прогноз – $R^2 = 0,621$. Для влажных условий – статистический прогноз $R^2 = 0,076$, нейросетевой прогноз – $R^2 = 0,753$. Итоги моделирования приводят к следующим выводам: использование комбинация нескольких искусственных нейронных сетей (многослойной и вероятностной) приводит к улучшению точности прогноза и, как следствие, снижению сельскохозяйственных рисков.

Огромные возможности для управления всем диапазоном изменчивости климата открывают как климатические информационные ресурсы об изменении климата, так и продукты моделирования – прогнозы погоды и прогнозы биоклиматических показателей. Появляющаяся способность вероятно прогнозировать агроклиматические параметры будущих сезонов применяя нейросетевые методы и модели начала влиять на принятие решений на многих уровнях. Последние достижения в области прогнозирования климата и обслуживания климатической информацией открывают огромный потенциал для оптимизации методов управления, преодоления пробелов в урожайности и обеспечения устойчивого производства.

СПИСОК ЛИТЕРАТУРЫ

1. Pereira L.S. Water, Agriculture and Food: Challenges and Issues/ Pereira L.S.// Water Resour Manage. – 2017. – Vol. 31. – 2985–2999.
2. United Nations World Water Development Report 2020. Water and Climate Change/ M. Miletto et al. . – Paris, UNESCO. – 2020. [Online]. Available: <https://unesdoc.unesco.org/ark:/48223/pf0000372985.locale=en>
3. Третий Оценочный доклад Росгидромета об изменениях климата и их последствиях на территории Российской Федерации. Общее резюме. – М.: 2022. –126 с.

4. Ise T. Forecasting Climatic Trends Using Neural Networks: An Experimental Study Using Global Historical Data / Ise T., Oba Y. // *Front. Robot. AI* 6:32. doi: 10.3389/frobt.2019.00032.
5. Sévellec F. A novel probabilistic forecast system predicting anomalously warm 2018-2022 reinforcing the long-term global warming trend / Sévellec F., Drijfhout, S. S. // *Nat. Commun.* 9:3024. doi: 10.1038/s41467-018-05442-8.
6. World Meteorological Congress: Abridged final report of the Extraordinary session.- WMO-No. 1281, 2021. – 269 p.
7. Доклад об особенностях климата на территории Российской Федерации за 2021 год. – Москва, 2022. – 104 с.
8. Переведенцев Ю. П. Мониторинг и прогнозирование климатической изменчивости на территории Приволжского федерального округа/ Переведенцев Ю. П., Вильфанд Р. М., Шанталинский К. М., Гурьянов В. В., Николаев А. А., Исмагилов Н. В. // *Гидрометеорологические исследования и прогнозы.* 2019. № 1 (371). С. 67–94.
9. Keswani B. Adapting weather conditions based iot enabled smart irrigation technique in precision agriculture mechanisms / Keswani B., Mohapatra A.- G., Mohanty A., Khanna A., Rodrigues J. JPC., Gupta D., de Albuquerque V. H. C. // *Neural Comp and Appl.* – 2019. – Vol. 31. – № 1. – pp.277–292.
10. Tran T. T. K. A Review of Neural Networks for Air Temperature Forecasting / Tran T. T. K., Bateni S. M., Ki S. J., Vosoughifar H. // *Water.* – 2021. – Vol. 13. – 1294 p.
11. Qu J. Recent Advances and Challenges of Monitoring Climate Change from Space/ Qu J., Powell Jr., Alfred M., Sivakumar M. // *Satellite-Based Applications on Climate Change.* – 2015. – 359-366. 10.1007/978-94-007-5872-8_21.
12. Sévellec F. A novel probabilistic forecast system predicting anomalously warm 2018-2022 reinforcing the long-term global warming trend/ // *Nat. Commun.* – 2018. – 9:3024. doi: 10.1038/s41467-018-05442-8.
13. Соловьев Д.А. Совершенствование дождевальной техники на основе методов нейрорегулирования / Соловьев Д.А., Камышова Г.Н., Макаров С.А., Терехова Н.Н., Бакиров С. М. // *Научный журнал Российского НИИ проблем мелиорации.* - 2020.- № 4(40). с.23-38.
14. Kamyshova G. N. Neuromodeling in Irrigation Management for Sustainable Agriculture/ Kamyshova G. N., Soloviov D. A., Kolganov D. A., Korsak V.V. Terekhova N. N. // *Advances in Dynamical Systems and Applications.* – 2021. – V. 16. – № 1. –P. – 159-170.
15. Kamyshova G. N. Neural network models in reducing the risks of irrigated agriculture/ Kamyshova G. N. // *E3S Web of Conferences. ERSME-2020.* – 2020. - Vol. 217, 10004.
16. Kamyshova G. Approaches to the Intellectualization of Decision Support in Irrigated Agriculture Based on Self-organizing Neural Networks. In: Gibadullin, A. (eds) *Digital and Information Technologies in Economics and Management. DITEM 2021/* Kamyshova G., Ignar S., Kravchuk A., Terekhova N. // *Lecture Notes in Networks and Systems.* – 2022. – Vol 432.
17. Камышова Г.Н. Нейросетевые модели в оптимизации орошения сельскохозяйственных культур/ Камышова Г.Н. // *Нейрокомпьютеры.* 2022.- V.-24.-№ 5.с.44-54.
18. Портал погода и климат. Доступ: <http://www.pogodaiklimat.ru/>
19. Хайкин С. Нейронные сети: полный курс 2-е изд. – Диалектика: 2019. – 226 с.
20. Камышова Г.Н. Нейропрогнозирование водных ресурсов для снижения сельскохозяйственных рисков/ Камышова Г.Н., Терехова Н.Н. // *Математическое и компьютерное моделирование в экономике, страховании и управлении рисками.* 2021.- №6.- С. 86-90.
21. Прякина С.И., Васильева М.Ю. Природно-ресурсный потенциал зернового производства Саратовской области. – Саратов: ИЦ «Наука»: 2015. – 105с.

REFERENCES

1. Pereira L.S. Water, Agriculture and Food: Challenges and Issues/ Pereira L.S. // *Water Resour Manage.* - 2017. - Vol. 31. - 2985-2999.
2. United Nations World Water Development Report 2020. Water and Climate Change/ M. Miletto et al.. Paris, UNESCO. – 2020. [Online]. Available: <https://unesdoc.unesco.org/ark:/48223/pf0000372985.locale=en>

3. Third Assessment Report of Roshydromet on climate change and its consequences on the territory of the Russian Federation. General summary. - M.: 2022. -126 p.
4. Ise T. Forecasting Climatic Trends Using Neural Networks: An Experimental Study Using Global Historical Data / Ise T., Oba Y. // Front. robot. AI 6:32. doi: 10.3389/frobt.2019.00032.
5. Sévellec F. A novel probabilistic forecast system predicting anomalously warm 2018-2022 reinforcing the long-term global warming trend / Sévellec F., Drijfhout, S. S.// Nat. commun. 9:3024. doi: 10.1038/s41467-018-05442-8.
6. World Meteorological Congress: Abridged final report of the Extraordinary session.- WMO-No. 1281, 2021. - 269 p.
7. Report on climate features in the territory of the Russian Federation for 2021. - Moscow, 2022. - 104 p.
8. Perevedentsev Yu. P. Monitoring and forecasting of climatic variability on the territory of the Volga Federal District / Perevedentsev Yu. P., Vilfand R. M., Shantalinsky K. M., Guryanov V. V., Nikolaev A. A., Ismagilov N V. // Hydrometeorological research and forecasts. 2019. No. 1 (371). pp. 67–94.
9. Keswani B. Adapting weather conditions based iot enabled smart irrigation technique in precision agriculture mechanisms / Keswani B., Mohapatra A.- G., Mohanty A., Khanna A., Rodrigues J. JPC., Gupta D., de Albuquerque V. H. C. // Neural Comp and Appl. - 2019. - Vol. 31. – No. 1. – pp.277–292.
10. Tran T. T. K. A Review of Neural Networks for Air Temperature Forecasting / Tran T. T. K., Bateni S. M., Ki S. J., Vosoughifar H. // Water. - 2021. - Vol. 13. - 1294 p.
11. Qu J. Recent Advances and Challenges of Monitoring Climate Change from Space/ Qu J., Powell Jr., Alfred M., Sivakumar M. // Satellite-Based Applications on Climate Change. - 2015. - 359-366. 10.1007/978-94-007-5872-8_21.
12. Sévellec F. A novel probabilistic forecast system predicting anomalously warm 2018-2022 reinforcing the long-term global warming trend/ //Nat. commun. - 2018. - 9:3024. doi: 10.1038/s41467-018-05442-8.
13. Soloviev D.A. Improvement of sprinkling technique based on neurocontrol methods / Solovyov D.A., Kamyshova G.N., Makarov S.A., Terekhova N.N., Bakirov S.M. // Scientific journal of the Russian Research Institute of Land Reclamation Problems. - 2020.- No. 4(40). pp.23-38.
14. Kamyshova G. N. Neuromodeling in Irrigation Management for Sustainable Agriculture/ Kamyshova G. N., Soloviev D. A., Kolganov D. A., Korsak V. V. Terekhova N. N. //Advances in Dynamical Systems and Applications. - 2021. - V. 16. - No. 1. -P. - 159-170.
15. Kamyshova G. N. Neural network models in reducing the risks of irrigated agriculture/ Kamyshova G. N. // E3S Web of Conferences. ERSME-2020. - 2020. - Vol. 217, 10004.
16. Kamyshova G. Approaches to the Intellectualization of Decision Support in Irrigated Agriculture Based on Self-organizing Neural Networks. In: Gibadullin, A. (eds) Digital and Information Technologies in Economics and Management. DITEM 2021/ Kamyshova G., Ignar S., Kravchuk A., Terekhova N.// Lecture Notes in Networks and Systems. - 2022. - Vol 432.
17. Kamyshova G.N. Neural network models in crop irrigation optimization / Kamyshova G.N. // Neurocomputers. 2022.- V.-24.-No. 5. pp. 44-54.
18. Weather and climate portal. Access: <http://www.pogodaiklimat.ru/>
19. Khaykin S. Neural networks: a complete course 2nd ed. - Dialectics: 2019. -226 p.
20. Kamyshova G.N. Neuroprediction of water resources to reduce agricultural risks / Kamyshova G.N., Terekhova N.N. // Mathematical and computer modeling in economics, insurance and risk management. 2021.- №6.- S. 86-90.
21. Pryakhina S.I., Vasil'eva M.Yu. Natural resource potential of grain production in the Saratov region. - Saratov: Information Center "Nauka": 2015. -105c.

БЛАГОДАРНОСТЬ

Эта публикация является результатом реализации проекта Erasmus+ «Передовой центр для докторантов и молодых исследователей в области информатики» (ACeSYRI), регистрационный номер 610166-EPP-1-2019-1-SK-EPPKA2-CBHE-JP.