

## НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ И ПРОГНОЗИРОВАНИЕ ФУНКЦИОНАЛЬНЫХ ЗАВИСИМОСТЕЙ ТЕМПЕРАТУРЫ ОТ ЕДИНИЦ АЦП ДЛЯ КОНТРОЛИРУЕМОГО ВЫРАЩИВАНИЯ КУЛЬТУРНЫХ РАСТЕНИЙ БИОТЕХНОЛОГИЧЕСКИМИ СПОСОБАМИ

Н. И. Лебедь<sup>1✉</sup>, В. А. Цепляев<sup>2</sup>, А. Н. Цепляев<sup>3</sup>,  
К. Е. Токарев<sup>4</sup>, А. Г. Хорошевский<sup>1</sup>

*Кафедры: «Электроснабжение и энергетические системы» (1), nik8872@yandex.ru;  
«Технические системы в АПК» (2); «Математическое моделирование  
и информатика» (4), ФГБОУ ВО «Волгоградский государственный аграрный  
университет», Волгоград, Россия;*

*Всероссийский научно-исследовательский институт орошаемого земледелия –  
филиал ФГБНУ «ФНЦ ВНИИГиМ им. А. Н. Костякова» (3), Волгоград, Россия*

**Ключевые слова:** биотехнологии; имитационное моделирование; искусственный интеллект; искусственные нейронные сети; культурные растения; растениеводство.

**Аннотация:** Аналитически и экспериментально обоснован метод получения функциональных зависимостей входных и выходных величин при использовании в разработке программных кодов контроллеров методом регрессионного анализа использованием нейронных сетей на примере получения корреляции между температурой от единиц АЦП посредством NTC-датчика. Получены нейросетевые модели MLP- и RBF-архитектур, их статистические показатели для прогнозирования значений температуры от единиц АЦП. Для проверки результатов исследований проведено имитационное моделирование узла мониторинга температуры выращивания культурных растений биотехнологическими способами посредством САПР Proteus ISIS, доказавшее высокую эффективность предлагаемого метода, где фактические экспериментальные температуры, а также смоделированные и прогнозируемые совпадают на 95 % при применении архитектуры сети MLP 1-14-1 со следующими характеристиками – один входной нейрон, четырнадцать скрытых нейронов, один выходной нейрон, алгоритм обучения: BFGS 132, функция ошибки: сумма квадратов, функция активации скрытых нейронов: гиперболическая, функция активации выходных нейронов: синус.

---

### Введение

Стандарт МЭК 61131-3 описывает пять языков программирования, являющихся результатом изучения наиболее удачных фирменных разработок мировых лидеров рынка программируемых логистических контроллеров. Развитие идеи программной реализации электрических схем привело к появлению языка функциональных блоков и диаграмм FBD (*англ.* Function Block Diagram – графический язык программирования) [1].

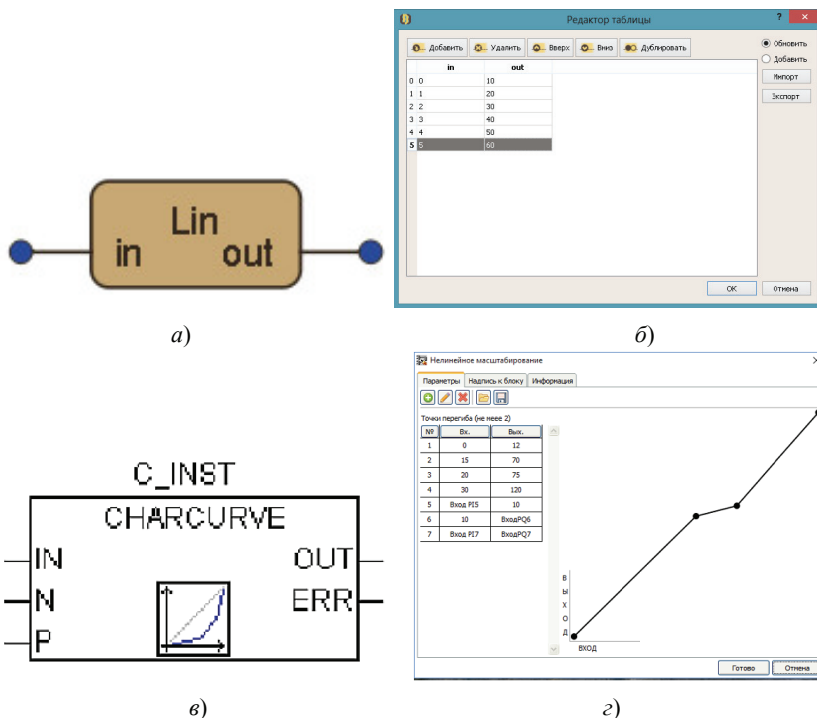
Сами блоки, представленные на схеме как функциональные модули, могут выполнять стандартные и специальные функции. FBD-схемы ясно отражают

взаимосвязь входов и выходов диаграммы. FBD работает с последовательностью цепей, каждая из которых содержит логическое или арифметическое выражение, вызов функционального блока, переходили инструкцию возврата.

Существует множество интегрированных сред разработки и программирования для промышленных логистических контроллеров (ПЛК), в том числе и отечественной разработки. Как правило, каждый производитель аппаратной продукции выпускает индивидуальное специализированное программное обеспечение для программирования ПЛК собственного производства. Так, в отечественной индустрии производственных автоматизированных систем существуют ПЛК производства Owen, Zentec, а также среды их программирования на языке FBD Owen Logic, ZWorkbench. Кроме этого, существуют универсальные среды программирования, поддерживающие несколько производителей ПЛК, в частности среда CoDeSys и др.

При работе с аналоговыми значениями, полученными, например, от аналого-цифрового преобразователя (АЦП) входа ПЛК, возникает необходимость преобразования, масштабирования этих величин в соответствии с алгоритмом разрабатываемого кода программы. В частности, для этих целей в средах программирования существуют специализированные блоки линейного масштабирования, суть которых – перенос значений из текущего диапазона значений в новый диапазон, заданный параметрами, а также нелинейного масштабирования, в частности функциональные блоки: «Линеаризация» (ПО ZWorkbench), CHARCURVE (ПО CoDeSys 2.3) и др.

Так, блок функции «Линеаризация» осуществляет преобразование значений на входе в соответствующие им новые значения на выходе, которые определяются таблицей линеаризации, задаваемой в свойствах блока (рис. 1). Причем проме-



**Рис. 1. Функциональные блоки реализации нелинейного масштабирования:**  
 а – «Линеаризация»; б – настройки блока «Линеаризация»;  
 в – Charcurve; г – настройки блока Poligon

жуточные значения определяются зависимостью, задаваемой при создании таблицы линеаризации. Так, значению 0,5 на входе соответствует значение 15 на выходе. Количество выходов может изменяться, при этом добавляется соответствующий столбец в таблице линеаризации. Таким образом, данная функция позволяет, к примеру, преобразовывать аналоговый сигнал с датчика температуры в значения температуры в градусах Цельсия.

Аналогичные функции осуществляет блок Charcurve (среда программирования CoDeSys), выполняя пересчет входных данных по заданной переходной функции путем кусочно-линейной аппроксимации (см. рис. 1, в), а также функциональный блок Poligon, где масштабирование входного сигнала реализуется по нелинейному закону в соответствии с таблицей точек перегиба (см. рис. 1, г). Кроме этого, все указанные блоки для удобства внесения больших данных имеют функцию «импорт» при переносе данных из ПО Microsoft Excel.

При отладке технологических процессов, а также в приборостроении для настройки экспериментальных датчиков или использовании серийных датчиков в качестве косвенных необходимо для обработки сигнала с АЦП микроконтроллера при точном перерасчете выходного показателя иметь большой ряд данных зависимостей входных и выходных значений с достаточным числом промежуточных результатов для точной работы датчиков. На практике для получения таких зависимостей проводят расчеты по полученным заранее математическим моделям или, при моделировании сложных технических систем, все полученные зависимости выявляются экспериментальным путем.

Для решения задачи получения множества промежуточных значений функциональных зависимостей входных и выходных величин при использовании в разработке алгоритмов и программных кодов для логистических контроллеров предлагается использование нейронных сетей.

Нейросетевой подход, в отличие от традиционных методов, основанных на предположениях и ограничениях, законах распределения, подходит как для линейных, так и для сложных нелинейных зависимостей [2 – 5].


*Цель исследования* – обоснования метода получения промежуточных значений зависимостей входных и выходных величин при использовании в разработке алгоритмов и программных кодов логистических контроллеров методом регрессионного анализа посредством использования нейронных сетей.

### **Объекты и методы исследования**

В качестве объекта исследований использована имитационная модель процесса автоматизированного выращивания растений в контролируемых условиях биотехнологическими способами. Управление моделью реализовано программируемым сетевым логистическим контроллером Q-PLC на базе микроконтроллера ARM-архитектуры платы ESP-WROOM-32 с процессором Xtensa LX6, в качестве источника получения входных сигналов представлен NTC-датчик температуры, подключенный к внутреннему АЦП информационно-измерительной системы.

Ранее получены результаты зависимостей фактической температуры от данных датчика (с шагом в 5 °С), выраженных в битном числе и полученных от АЦП микроконтроллера, полученное множество значений в целом характеризуется нелинейной зависимостью (рис. 2).

Для разработки прогнозных нейросетевых моделей использовался программный комплекс STATISTICA Neural Networks, где в качестве типа анализа для построения моделей использовалась «Регрессия».



**Рис. 2. Зависимость фактической температуры от значений с датчика, выраженных в битном числе и полученных от АЦП микроконтроллера**

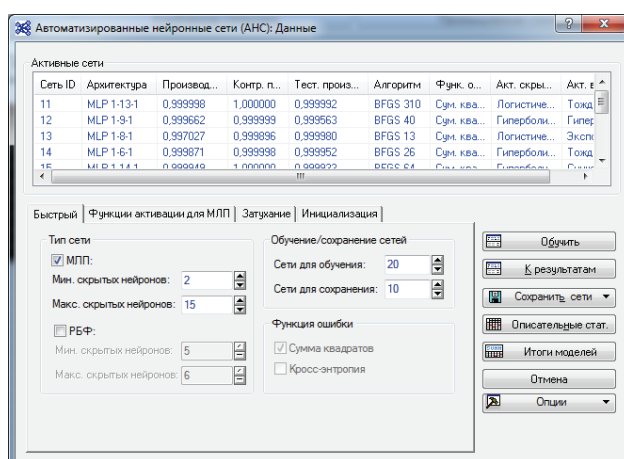
### Результаты исследований

В качестве входного слоя для обучения нейросети использовалась непрерывная входная переменная АЦП, выраженная в единицах битного числа. В качестве выходного слоя принята температура окружающей среды в градусах Цельсия.

Для обучения, тестирования и контроля выделены соответственно 70, 15 и 15 % данных. Архитектура нейронной сети включала многослойный перцептрон (MLP), а также сеть радиально-базисных функций (RBF) с одним промежуточным слоем, содержащим от 2 до 15 нейронов (для минимизации нежелательного «переобучения») (рис. 3). При создании сети исследован набор функций активации нейронов, включая линейную, логарифмическую сигмоидную и др. Количество циклов обучения (эпох) установлено на 1000.

Для обучения нейронной сети использовался алгоритм BFGS (*англ.* Broyden–Fletcher–Goldfarb–Shanno), который является итерационным методом численной оптимизации и предназначается для поиска локального максимума или минимума нелинейной функции без ограничений [6, 7]. После анализа среднеквадратичных ошибок для дальнейшего использования приняты нейросети MLP 1-14-1 и RBF 1-5-1.

В таблице 1 представлены характеристики построенных нейросетевых моделей для их точного анализа и последующей настройки итогового выбора, а на рис. 4 – предсказанные значения температуры для всех типов моделей обучающей и контрольной выборок (табл. 2).



**Рис. 3. Настройки параметров проектирования нейронной сети типа MLP в пакете «Автоматизированные нейронные сети» ПО Statistica**

Таблица 1

## Характеристики нейросетевых моделей

Модель	Архитектура	Производительность		Контрольная ошибка	Алгоритм обучения	Функция ошибки
		обучения	контрольная			
52	MLP 1-14-1	0,999959	0,999999	0,015233	BFGS 36	Сумма квадратов
53		0,999998	1,000000	0,006083	BFGS 688	
54		0,999993	1,000000	0,013051	BFGS 62	
55		0,999999	1,000000	0,007234	BFGS 132	
56	RBF 1-5-1	0,993233	0,997943	3,953184	RBFT	

Продолжение табл. 1

Модель	Архитектура	Функция активации нейронов	
		скрытых	выходных
52	MLP 1-14-1	Гиперболическая	Синус
53			
54			
55			
56	RBF 1-5-1	Гауссиан	Тождественная

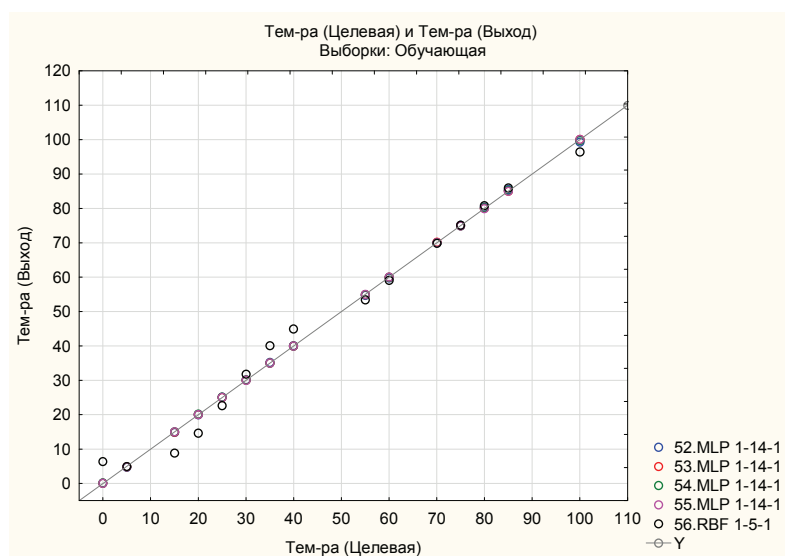


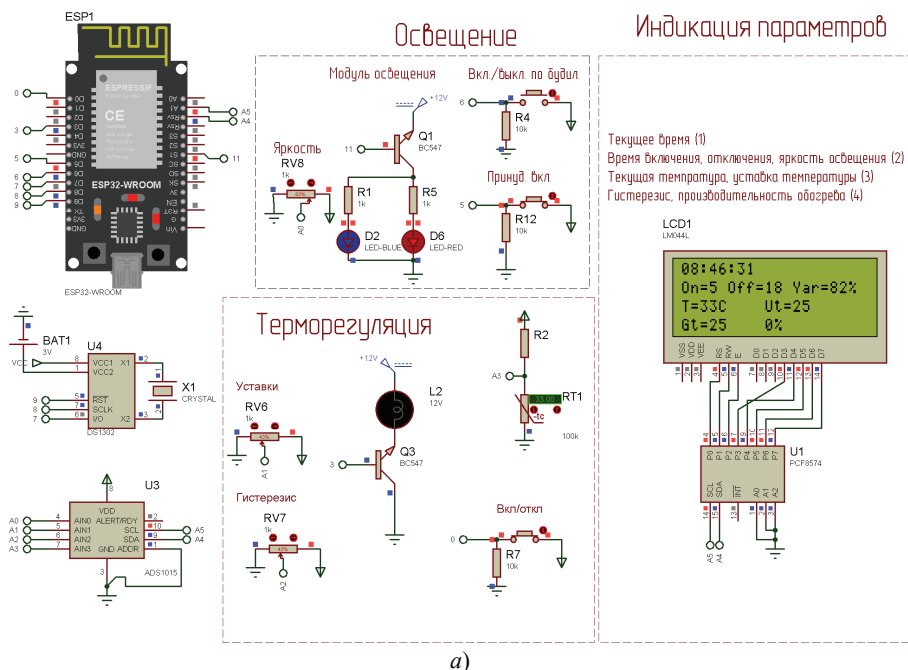
Рис. 4. Предсказанные значения для выходного параметра «Температура» (обучающая выборка)

Как видно из представленных результатов, наибольшей производительностью как по обучающей, так и контрольной выборкам ( $\approx 1$ ) обладает модель №55 (MLP 1-14-1), в качестве примера для сравнения нескольких моделей примем модель №56 (RBF 1-5-1). Прогнозируемые значения температур модели № 55 совпадают с целевыми на 98–99 % (см. рис. 4, табл. 2).

**Предсказанные значения для выходного параметра «Температура»  
(контрольная выборка), °С**

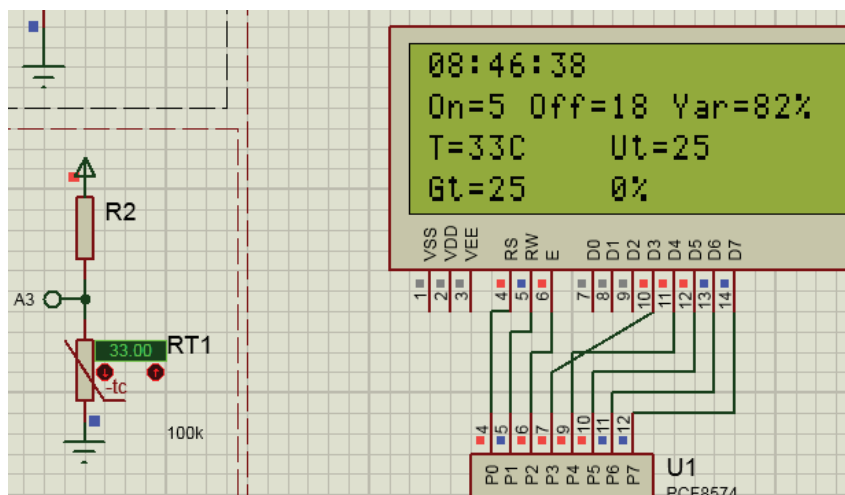
Целевая температура	Температура на выходе				
	MLP 1-14-1				56 RBF 1-5-1
	52	53	54	55	
10,0	9,71312	9,87097	9,81684	9,89863	5,66424
45,0	44,93577	44,89741	44,92344	44,93915	46,91254
95,0	95,07053	95,09657	95,19722	95,17154	93,87639

Для проверки результатов исследований и оценки их эффективности проведем имитационное моделирование объекта исследования – процесса автоматизированного выращивания растений в контролируемых условиях биотехнологическими способами [8, 9], в частности узла мониторинга температур окружающей среды посредством NTC-датчика. Моделирование проводилось в среде автоматизированного проектирования (САПР) электронных схем Proteus ISIS (рис. 5, а). Для наглядности модели и повышения производительности в режиме реального времени, узлы, не участвующие в эксперименте, из модели исключены (мониторинг остаточного кислорода, контроль кислотности рабочей среды и др.). Прогнозируемые полученные данные зависимости температуры от сигнала АЦП импортировались в функциональный блок Poligon (нелинейное масштабирование) при разработке специализированного программного обеспечения автоматизированной системы, далее программный код преобразовывался в бинарный hex-файл и загружался в память микроконтроллера имитационной модели.



**Рис. 5. Проверка результатов нейросетевого прогнозирования  
посредством имитационного моделирования (начало):**

а – имитационная модель в момент симуляции



б)

**Рис. 5. Окончание:**

б – сравнение фактических показаний датчика с измеренными

Таблица 3

**Предсказанные значения промежуточных температур, °С**

Целевая температура	Температура, полученная при имитационном моделировании	Выходная температура		ADC (АЦП)
		55	56	
4	4	3,96804	2,45789	749
33	33	33,17987	32,06138	424
43	42	43,02682	44,46253	327
46	45	45,86303	48,06719	302

Далее проводилась симуляция. Как видно из результатов моделирования, фактические температуры с измеренными совпадают на 95 %, а с учетом округления до одного знака запятой вписываются в погрешность самого датчика (рис. 5, б, табл. 3).

Для оценки средней ошибки выбранных моделей № 55 и 56 при построении таблицы предсказанных значений добавлен столбец «Абсолютные остатки», в результате получены значения средних ошибок по всем предсказанным температурам обучающих выборок моделей № 55 и 56 (табл. 4).

Таблица 4

**Средние ошибок для предсказанных значений температуры (обучающая выборка)**

Температура целевая, °С	Выходная температура, °С	Абсолютные остатки	Средняя ошибка аппроксимации, %
1	2	3	4
Модель 56RBF 1-5-1			
5	16,11970	11,11970	2,223940210
15	10,85794	4,14206	0,276137503
20	12,31256	7,68744	0,384372005

Продолжение табл. 4

1	2	3	4
25	16,49772	8,50228	0,340091328
30	23,03508	6,96492	0,232164126
35	30,96791	4,03209	0,115202470
40	38,83484	1,16516	0,029128964
55	54,52245	0,47755	0,008682810
60	60,35674	0,35674	0,005945696
70	70,88371	0,88371	0,0126244164
75	74,32754	0,67246	0,008966153
80	80,35280	0,35280	0,004409941
85	84,90600	0,09400	0,001105929
100	99,30388	0,69612	0,006961197
Средняя ошибка			26 %
Модель 55MLP 1-14-1			
5	4,88562	0,114376	0,022875169
15	15,00249	0,002487	0,000165770
20	20,06460	0,064599	0,003229965
25	25,01391	0,013908	0,000556319
30	29,99035	0,009648	0,000321607
35	34,96564	0,034356	0,000981608
40	39,96409	0,035911	0,000897786
55	55,02173	0,021734	0,000395158
60	60,03979	0,039788	0,000663136
70	70,05108	0,051084	0,000729775
75	74,90642	0,093577	0,001247688
80	80,00178	0,001780	0,000022248
85	84,99723	0,002773	0,000032618
100	99,99519	0,004815	0,000048149
Средняя ошибка			3,2 %

### Заключение

Сравнивая показатели нейросетевого прогнозирования и экспериментального исследования, видно, что прогнозные значения температур по обучающей выборке имеют среднюю ошибку в 3,2 % при применении архитектуры сети MLP 1-14-1 со следующими характеристиками – один входной нейрон, четырнадцать скрытых нейронов, один выходной нейрон, алгоритм обучения: BFGS 132, функция ошибки: сумма квадратов, функции активации скрытых нейронов: гиперболическая, функция активации выходных нейронов: синус), что констатирует высокую сходимость исследуемого нейросетевого метода. Предлагаемый метод с высокой эффективностью возможно применять для отладки технологических процессов, в приборостроении для настройки экспериментальных устройств при обработке сигналов с АЦП микроконтроллера для точного перерасчета вы-

ходного показателя, где необходим большой ряд данных зависимостей входных и выходных значений с достаточным числом промежуточных результатов для точной работы датчиков.

*Исследование выполнено за счет гранта Российского научного фонда № 25-21-20019 и Волгоградской области.*

#### *Список литературы*

1. Чупаев, А. В. Обзор МЭК-комплексов программирования / А. В. Чупаев, Р. Р. Галямов, А. Ю. Шарифуллина // Приоритетные направления развития науки и технологий : докл. XXXII Междунар. науч.-практ. конф., Тула, 15 марта 2023 г. / под общ. ред. В. М. Панарина. – Тула, 2023. – С. 181 – 185.
2. Шимохин, А. В. Применение Statistica 13 – Автоматизированные нейронные сети в обучении нейросетевому моделированию обучающихся в экономических направлениях / А. В. Шимохин, Д. А. Воробьев // Электронный научно-методический журнал Омского ГАУ. – 2018. – № 4(15). – URL : [https://www.elibrary.ru/download/elibrary\\_36745064\\_95342843.pdf](https://www.elibrary.ru/download/elibrary_36745064_95342843.pdf) (дата обращения: 09.09.2025).
3. Statistical Analysis and Prediction of Paddy Yield Using Neural Network / A. Rahman, R. Ismail, U. A. B. Rozali, Kh. A. B. Arshad // Indonesian Journal of Fundamental Sciences. – 2023. – Vol. 9, No. 1. – P. 17 – 28. doi: 10.26858/ijfs.v9i1.48441
4. Илларионов, М. Г. Прогнозирование на основе аппарата нейронных сетей / М. Г. Илларионов, А. П. Кирпичников, Р. Р. Латыпова // Вестник Казанского технологического университета. – 2012. – Т. 15, № 1. – С. 163 – 164.
5. Ломовцева, Н. А. Использование модуля нейронных сетей в системе STATISTICA для решения задачи классификации / Н. А. Ломовцева, Ю. Е. Кувайскова // Вестник Ульяновского государственного технического университета. – 2021. – № 4(96). – С. 59 – 61.
6. Нейросетевое прогнозирование физико-механических характеристик композитных материалов используемых для усиления строительных конструкций / В. И. Римшин, А. К. Соловьев, Л. А. Сулейманова, П. А. Амелин // Эксперт: теория и практика. – 2023. – № 4(23). – С. 101 – 107. doi:10.51608/26867818\_2023\_4\_101
7. Денисенко, А. Ф. Выбор и применение нейронных сетей для моделирования эксплуатационных характеристик шпиндельных узлов / А. Ф. Денисенко, Р. В. Ладыгин // Машины, агрегаты и процессы. Проектирование, создание и модернизация : материалы Междунар. науч.-практ. конф., Санкт-Петербург, 26 января 2024 г. – Санкт-Петербург, 2024. – С. 18 – 20.
8. Свидетельство о регистрации программы ЭВМ №2022617977 Российская Федерация. Программный модуль компьютерного мониторинга признаков заражения посевов агрокультур при клональном микроразмножении / Н. И. Лебедь, К. Е. Токарев, М. Б. Лебедь ; заявитель и патентообладатель ФГБОУ ВО ВолГАУ. – № 2022617214 ; заявл. 19.04.2022 ; опублик. 27.04.2022.
9. Исследование и моделирование режимов работы программно-аппаратного комплекса системы микроклимата на базе программируемого микроконтроллера ATmega 2560 / Н. И. Лебедь, К. Е. Токарев, Д. Д. Нехорошев, М. П. Аксенов // Вестник ТГТУ. – 2022. – Т. 28, №4. – С. 596 – 605. doi: 10.17277/vestnik.2022.04.pp.596-605

## Neural Network Modeling and Forecasting of Functional Dependencies of Temperature on ADC Units for Controlled Cultivation of Crops by Biotechnological Methods

N. I. Lebed<sup>1</sup>✉, V. A. Tseplyaev<sup>2</sup>, A. N. Tseplyaev<sup>3</sup>,  
K. E. Tokarev<sup>4</sup>, A. G. Khoroshevsky<sup>1</sup>

*Departments: Power Supply and Energy Systems (1), nik8872@yandex.ru;  
Technical Systems in the Agro-Industrial Complex (2);  
Mathematical Modeling and Informatics (4), Volgograd State Agrarian University,  
Volgograd, Russia;  
All-Russian Research Institute of Irrigated Agriculture –  
Branch of the A.N. Kostyakov Federal Scientific Center of Irrigation and Metrology (3),  
Volgograd, Russia*

**Keywords:** biotechnology; simulation modeling; artificial intelligence; artificial neural networks; crops; plant growing.

**Abstract:** A method for obtaining functional dependencies of input and output values when used in the development of controller software codes using regression analysis and neural networks is analytically and experimentally substantiated. The method is used to obtain a correlation between temperatures from ADC units using an NTC sensor. Neural network models of MLP and RBF architectures, along with their statistical indicators for predicting temperature values from ADC units, are obtained. To verify the research results, a simulation modeling of a temperature monitoring unit for growing crops using biotechnological methods was carried out using the Proteus ISIS CAD system, which proved the high efficiency of the proposed method, where the actual experimental temperatures, as well as the modeled and predicted ones, coincide by 95% when using the MLP 1-14-1 network architecture with the following characteristics: one input neuron, fourteen hidden neurons, one output neuron, training algorithm: BFGS 132, error function: sum of squares, activation function of hidden neurons: hyperbolic, activation function of output neurons: sine.

### References

1. Chupayev A.V., Galyamov R.R., Sharifullina A.Yu.; Panarin V.M. (Ed.). *Prioritetnyye napravleniya razvitiya nauki i tekhnologii: doklad. XXXII Mezhdunar. nauch.-prakt. konf.* [Priority areas of science and technology development: report. XXXII Int. scientific-practical. conf.], Tula, 15 March 2023, Tula, 2023, pp. 181-185. (In Russ.).
2. Shimokhin A.V., Vorob'yev D.A. [Automated neural networks in teaching neural network modeling to students majoring in economics], *Elektronnyy nauchno-metodicheskiy zhurnal Omskogo gosudarstvennogo agrarnogo universiteta* [Electronic scientific and methodological journal of Omsk State Agrarian University], 2018, no. 4(15), available at: [https://www.elibrary.ru/download/elibrary\\_36745064\\_95342843.pdf](https://www.elibrary.ru/download/elibrary_36745064_95342843.pdf) (accessed 09 September 2025) (In Russ., abstract in Eng.).
3. Rahman A., Ismail R., Rozali U.A.B., Arshad Kh.A.B. Statistical Analysis and Prediction of Paddy Yield Using Neural Network, *Indonesian Journal of Fundamental Sciences*, 2023, vol. 9, no. 1, pp. 17-28. doi: 10.26858/ijfs.v9i1.48441
4. Illarionov M.G., Kirpichnikov A.P., Latypova R.R. [Forecasting based on neural networks], *Izvestiya Kazanskogo tekhnologicheskogo universiteta* [Bulletin of the Kazan Technological University], 2012, vol. 15, no. 1, pp. 163-164. (In Russ., abstract in Eng.).

5. Lomovtseva N.A., Kuvayskova Yu.Ye. [Using the neural network module in the STATISTICA system to solve the classification problem], *Izvestiya Ulyanovskogo gosudarstvennogo tekhnicheskogo universiteta* [Bulletin of the Ulyanovsk State Technical University], 2021, no. 4(96), pp. 59-61. (In Russ., abstract in Eng.).

6. Rimshin V.I., Solov'yev A.K., Suleymanova L.A., Amelin P.A. [Neural network forecasting of physical and mechanical characteristics of composite materials used to strengthen building structures], *Ekspert: teoriya i praktika* [Expert: theory and practice], 2023, no. 4(23), pp. 101-107. doi: 10.51608/26867818\_2023\_4\_101 (In Russ., abstract in Eng.).

7. Denisenko A.F., Ladyagin R.V. *Mashiny, agregaty i protsessy. Proyektirovaniye, sozdaniye i modernizatsiya: materialy Mezhdunar. nauch.-prakt. konf.* [Machines, units and processes. Design, creation and modernization: materials of the International. scientific-practical. conf.], St. Petersburg, 26 January 2024, St. Petersburg, 2024, pp. 18-20. (In Russ., abstract in Eng.).

8. Lebed' N.I., Tokarev K.Ye., Lebed' M.B. *Programmnyy modul' dlya kompyuternogo monitoringa priznakov zarazheniya sel'skokhozyaystvennykh kul'tur pri klonal'nom mikrorazmnozhenii* [Software module for computer monitoring of signs of infection of agricultural crops during clonal micropropagation], Russian Federation, 2022, No. 2022617977 (In Russ.).

9. Lebed' N.I., Tokarev K.Ye., Nekhoroshev D.D., Aksenov M.P. [Research and modeling of operating modes of the hardware and software complex of the microclimate system based on the programmable microcontroller ATmega 2560], *Transactions of the Tambov State Technical University*, 2022, vol. 28, no. 4, pp. 596-605. doi: 10.17277/vestnik.2022.04.pp.596-605 (In Russ., abstract in Eng.).

---

## **Modellierung und Vorhersage neuronaler Netze funktioneller Temperaturabhängigkeiten von ADC-Einheiten für den kontrollierten Anbau von Pflanzen mit biotechnologischen Methoden**

**Zusammenfassung:** Es ist eine Methode zur Ermittlung funktionaler Abhängigkeiten von Eingabe- und Ausgabewerten bei der Entwicklung von Controller-Softwarecodes unter Verwendung von Regressionsanalysen und neuronalen Netzwerken analytisch und experimentell begründet. Am Beispiel der Ermittlung einer Korrelation zwischen Temperaturen von ADC-Einheiten über den NTC-Sensor werden neuronale Netzwerkmodelle von MLP- und RBF-Architekturen und ihre statistischen Indikatoren zur Vorhersage von Temperaturwerten von ADC-Einheiten ermittelt. Zur Überprüfung der Forschungsergebnisse ist die Simulationsmodellierung der Temperaturüberwachungseinheit für den Anbau von Nutzpflanzen mit biotechnologischen Methoden unter Verwendung des CAD-Systems Proteus ISIS durchgeführt, die die hohe Effizienz der vorgeschlagenen Methode bewiesen hat, bei der die tatsächlichen experimentellen Temperaturen sowie die modellierten und vorhergesagten zu 95 % übereinstimmen, wenn die Netzwerkarchitektur MLP 1-14-1 mit den folgenden Eigenschaften verwendet wird: ein Eingabeneuron, vierzehn versteckte Neuronen, ein Ausgabeneuron, Trainingsalgorithmus: BFGS 132, Fehlerfunktion: Summe der Quadrate, Aktivierungsfunktion der versteckten Neuronen: hyperbolisch, Aktivierungsfunktion der Ausgabeneuronen: Sinus.

## **Modélisation en réseau neuronal et prédiction des dépendances fonctionnelles de la température des unités ADC à la culture contrôlée de plantes cultivées par des méthodes biotechnologiques**

**Résumé:** Est validée analytiquement et expérimentalement la méthode d'obtention des dépendances fonctionnelles des valeurs d'entrée et de sortie lorsqu'elle est utilisée dans le développement de codes de programmation de contrôleurs par l'analyse de régression à l'aide de réseaux neuronaux, en prenant l'exemple de la corrélation de température entre les unités ADC au moyen d'un capteur NTC. Sont obtenus les modèles de réseau neuronal des architectures MLP et RBF, leurs mesures statistiques permettant de prédire les valeurs de température à partir des unités ADC. Pour valider les résultats de la recherche, est réalisée une simulation de l'unité de surveillance de la température des plantes cultivées par des méthodes biotechnologiques utilisant la CAO Proteus ISIS, prouvant la grande efficacité de la méthode proposée, où les températures expérimentales réelles ainsi que les températures simulées et projetées coïncident de 95 % en appliquant l'architecture du réseau MLP 1-14-1 avec les caractéristiques suivantes – un neurone d'entrée, quatorze neurones cachés, un neurone de sortie, algorithme d'apprentissage: BFGS 132, fonction d'erreur: somme des carrés, fonction d'activation des neurones cachés: hyperbolique, fonction d'activation des neurones de sortie: sinus.

---

**Авторы:** *Лебедь Никита Игоревич* – доктор технических наук, профессор кафедры «Электроснабжение и энергетические системы»; *Цепляев Виталий Алексеевич* – кандидат технических наук, ректор, доцент кафедры «Технические системы в АПК», ФГБОУ ВО «Волгоградский государственный аграрный университет», Волгоград, Россия; *Цепляев Алексей Николаевич* – доктор сельскохозяйственных наук, ведущий научный сотрудник лаборатории систем орошения и управления поливом отдела оросительных технологий, Всероссийский научно-исследовательский институт орошаемого земледелия – филиал ФГБНУ «ФНЦ ВНИИГиМ им А. Н. Костякова», Волгоград, Россия; *Токарев Кирилл Евгеньевич* – кандидат экономических наук, доцент кафедры «Математическое моделирование и информатика»; *Хорошевский Андрей Геннадьевич* – аспирант кафедры «Электроснабжение и энергетические системы», ФГБОУ ВО «Волгоградский государственный аграрный университет», Волгоград, Россия.