

ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ УПРАВЛЕНИЯ ОРОШЕНИЕМ

КАМЫШОВА Галина Николаевна, Саратовский государственный аграрный университет имени Н.И. Вавилова

Современные методы точного земледелия, основанные на требованиях пространственно-временной оптимальности полива сельскохозяйственных культур, требуют новых подходов, так как достижение требуемой точности невозможно без применения современных цифровых технологий и интеллектуальных методов. В статье представлена модель оперативного управления орошением на основе искусственной нейронной сети. Преимуществами являются малая погрешность нейросетевого алгоритма и его способность адаптироваться к изменяющимся условиям в отличие от традиционных методов, что позволяет обеспечивать оптимальные результаты для различных типов почв и видов сельскохозяйственных культур.

84

АГРАРНЫЙ НАУЧНЫЙ ЖУРНАЛ

4
2021

Введение. Водные и земельные ресурсы во всем мире становятся дефицитными из-за роста населения и изменения образа жизни, загрязнения имеющихся ресурсов в результате деятельности человека и т.п.

Россия является одной из крупнейших аграрных держав, обладающих значительными земельными и водными ресурсами. Согласно последним статистическим данным [6], в Российской Федерации имеется 9,45 млн га мелиорированных земель, в том числе 4,67 млн га – орошаемых и 4,78 млн га – осущененных. В сельскохозяйственном производстве для выращивания сельскохозяйственных культур используется 7,13 млн га мелиорированных земель (75,4 % к налинию), в том числе 3,86 млн га орошаемых и 3,27 млн га осущененных. Поливы сельскохозяйственных культур осуществлялись на площади 1 386,8 тыс. га – это 423,9 тыс. га зерновых культур, 230,4 тыс. га – овощных культур и картофеля, 477,4 тыс. га – кормовых культур и 255,1 тыс. га – прочих. Динамика использования воды, в том числе на нужды орошения приведена на рис. 1.

Однако вопрос поиска новых методов и технологий эффективного использования ресурсов в сельском хозяйстве не теряет своей актуальности. Одним из таких секторов является орошаемое земледелие. Классическим постулатом является то, что для обеспечения максимальной эффективности орошение

необходимо проводить в то время, когда растениям нужна вода, вне зависимости от климата.

Количество воды, подаваемой на поле, должно определяться в соответствии с нормой водопотребления растений и водоудерживающей способностью почвы и необходимо ее равномерное распределение. Научные принципы, методы и программы нормирования орошения разрабатывались многими российскими [1, 3, 4] и зарубежными учеными [9, 11]. В настоящее время большинство систем планирования орошения и соответствующего автоматизированного оборудования задают фиксированную норму полива [5]. Орошение с переменной нормой очень важно не только для улучшения ирригационной системы, но также для снижения затрат на орошение и увеличения урожайности сельскохозяйственных культур. В то же самое время, текущий уровень развития цифровых технологий, который позволяет применять большое количество датчиков и сенсоров для сбора огромного количества данных, диктует нам необходимость разработки новых методов и моделей нормирования орошения на основе интеллектуальных технологий, а именно искусственных нейронных сетей.

Методика исследований. Как известно [2], классические методы определения режимов орошения делятся на детерминированные и расчетные. Нами предлагается использовать подход на основе многослойной нейронной сети, используя их свой-



Рис. 1. Динамика использования воды, млрд м³ [6]

ства универсальных аппроксиматоров, для определения необходимого объема орошения.

В качестве математического метода моделирования выступает нейросетевая модель [7]. Основным строительным блоком нейронных сетей является нейрон. Это элемент обработки, который принимает ряд входных данных, применяет к ним вес, суммирует их, включает смещение и передает результат в функцию активации, которая затем выдает результат. Эта функция активации реализует нелинейное преобразование линейно объединенного входа для получения нелинейного выхода.

Посредством комбинации этих нейронов во входном пространстве и соединений выходов нейронов с другими нейронами можно изучить функцию, которая отображает нелинейную взаимосвязь между входным пространством признаков и выходной целью. Отношение ввода-вывода системы можно описать уравнением (1)

$$y_k = f(\sum_{j=1}^n w_{j,k} x_j + \varphi_k), \quad (1)$$

где $f(*)$ – нелинейная функция активации, а $w_{1,k}, w_{2,k}, \dots, w_{n,k}$ – синоптические веса нейрона k , φ_k – смещение, x_1, x_2, \dots, x_n – входные сигналы, y_k – выходной сигнал нейрона.

Многослойная нейронная сеть прямого распространения строится путем упорядочивания нейронов по слоям, позволяя каждому нейрону в слое принимать в качестве входных данных только выходы единиц в предыдущем слое или внешние входы. Сеть с $n = 1, 2, 3, \dots$ слоев называется n -слойной сетью (рис. 2).

Второй уровень на рис. 2 называется выходным слоем, поскольку он производит выходные данные сети. Первый уровень известен как скрытый слой, поскольку он расположен между внешними входами и выходным слоем.

Математическая формула, выражающая зависимости многослойной нейронной сети, представлена в уравнении (2).

$$\hat{y}_i = F_i(\sum_j \varphi_{ij} f_j(\sum_l w_{jl} x_l + w_{j,0}) + \varphi_{i,0}). \quad (2)$$

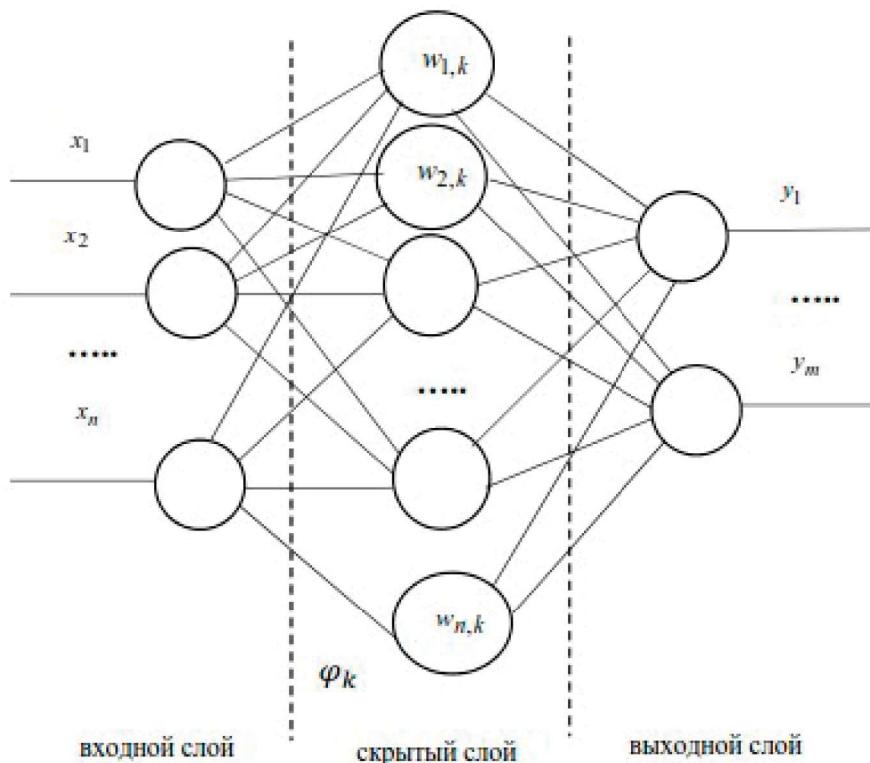


Рис. 2. Многослойная нейронная сеть

В уравнении (2) $\{w_{j,l}, \varphi_{ij}\}$ – это вектор, содержащий все регулируемые параметры сети, то есть веса и смещения, f_j – нелинейная функция активации.

Чтобы определить значение весов, сеть обучается с данными, содержащими примеры пар входов x_i и выходов y_i , известных как обучающий набор. Веса выбираются так, чтобы минимизировать глобальную функцию потерь, которая измеряет прогнозное значение \hat{y} , когда истинный выходной сигнал y является функцией по обучающему набору. Для задач регрессии, которые включают задачи динамического моделирования, минимизируемая функция стоимости представляет собой среднеквадратичную ошибку, которая вычисляется, как показано в уравнении (3):

$$l(\hat{y}, y) = \sum_{k=1}^N E(k) = \\ = \frac{1}{2N} \sum_{k=1}^N \sum_{i=1}^n \| \hat{y}_i(k) - y_i(k) \|^2. \quad (3)$$

Здесь $l(\hat{y}, y)$ – функция потерь, а n – количество обучающих примеров. Минимизация функции потерь и обновление весов достигается с помощью различных алгоритмов обучения, например, алгоритма Левенберга-Марквардта [12]. Его суть состоит в следующем: пусть $E(w)$ есть целевая функция ошибок, состоящая из n отдельных ошибок $e_i^2(w)$ всех нейронов.

$$E(w) = \sum_{i=1}^n e_i^2(w) = \|g(w)\|^2, \quad (4)$$

где $e_i^2(w) = (y_{mi} - y_i)^2$, а y_{mi}, y_i – желаемое и фактическое значения выхода i -го нейрона соответственно. Предполагается, что функция $g(*)$ и ее якобиан J известны в точке w . Целью алгоритма Левенберга – Марквардта является вычисление весового вектора w , при котором $E(w)$ минимизируется. Используя этот алгоритм, новый весовой вектор w_{k+1} может быть получен из предыдущего вектора весов w_k следующим образом:

$$w_{k+1} = w_k + \delta w_k, \quad (5)$$



где δw_k определяется по формуле:

$$\delta w_k = -\frac{J_k^T g(w_k)}{J_k J_k + \lambda I}. \quad (6)$$

В уравнении (6) J_k – это якобиан g , вычисленный в w_k , λ – параметр Марквардта; I – единичная матрица.

В качестве данных для апробации модели выступают данные экспериментальных исследований, проведенных на базе УНПО «Поволжье» Саратовского государственного аграрного университета и данные многолетних исследований основных сельскохозяйственных культур на основных орошаемых участках Саратовской области.

Результаты исследований. Нами предлагается следующая нейросетевая модель определения оптимального объема для оперативного управления орошением на основе многослойной нейронной сети с входным, скрытым и выходным слоями (рис. 2). Во входном слое вводится информация о текущей влажности почвы, типе почвы и ее гранулометрическом составе, типе сельскохозяйственной культуры и ее фазе роста. На выходе сети получаем необходимый объем орошения, рассчитанный исходя из фактической потребности сельскохозяйственной культуры в конкретной фазе роста и развития.

Характеристика объекта нейросетевого моделирования для апробации модели приведена в табл. 1. Нейросетевая модель учитывает факторы пространственно-временной изменчивости параметров орошаемого участка и роста сельскохозяйственной культуры.

Для обучения нейронной сети использовали наборы параметров текущей влажности почвы, типов почв и их гранулометрических составов, сельскохозяйственной культуры – кукурузы и ее фаз роста на экспериментальном участке. В случае если параметр имел только характеристику принадлежности к определенному типу, то данные кодировались. Например, «Темно-каштановая среднемощная» – код 1, «Темно-каштановая маломощная» – код 2 и т.п. Данные оптимальных требуемых значений рассчитывались с помощью специальной программы расчеты оптимального увлажнения расчетного слоя почвы.

На основании собранных данных устанавливаются оптимальные параметры нейронной сети [10]. Искусственная нейронная сеть состояла из входного слоя с пятью нейронами и выходного слоя с одним нейроном. Параметры промежуточного слоя варьировались до получения оптимальной точности. Для обучения сети использовался алгоритм Левенберга – Марквардта. Нейросетевое моделирование осуществлялось в Matlab [8].

Характеристика объекта нейросетевого моделирования

Параметр	Значения
Тип почвы	Темно-каштановая среднемощная Темно-каштановая маломощная
Гранулометрический состав	Суглинок легкий Суглинок средний Суглинок тяжелый
Тип сельскохозяйственной культуры	Кукуруза
Фазы роста	Посев–всходы 6–7 настоящих листьев Вымет метелки Молочная спелость

Обученная нейронная сеть тестируется с использованием набора данных конкретного участка орошения с определенными параметрами почвы и сельскохозяйственной культуры, определяя оптимальную поливную норму на выходе. Оценку качества построенной сети можно оценить, применяя так называемый метод ROC-анализа (Receiver Operator Characteristic). Основой данного анализа является построение так называемой ROC-кривой. Она показывает зависимость количества верно классифицированных положительных примеров от количества неверно классифицированных отрицательных примеров. Данные ROC-анализа с доверительным интервалом 95% приведены в табл. 2. Площадь под кривой ROC – 0,980; стандартная ошибка – 0,021; 95%-й доверительный интервал – 0,895–0,997; уровень значимости – 0,0001.

Таблица 2

Данные ROC-анализа

Критерий	Чувствительность	95%-й доверительный интервал
>0	100	85,1–100
>0	100	85,1–100
>0,003	100	85,1–100
>0,8	96,35	78,2–99,3
>0,85	90,81	70,5–97,3
>0,9	85,38	66,3–95,6
>1	0	0–16,2

Графики обучения при различных значениях параметра $R = 0,95–0,99$ и тестирования сети приведены на рис. 3.

Построенная нейросетевая модель, как видно из приведенного графика, показывает хорошее качество и может быть включена в систему управления.

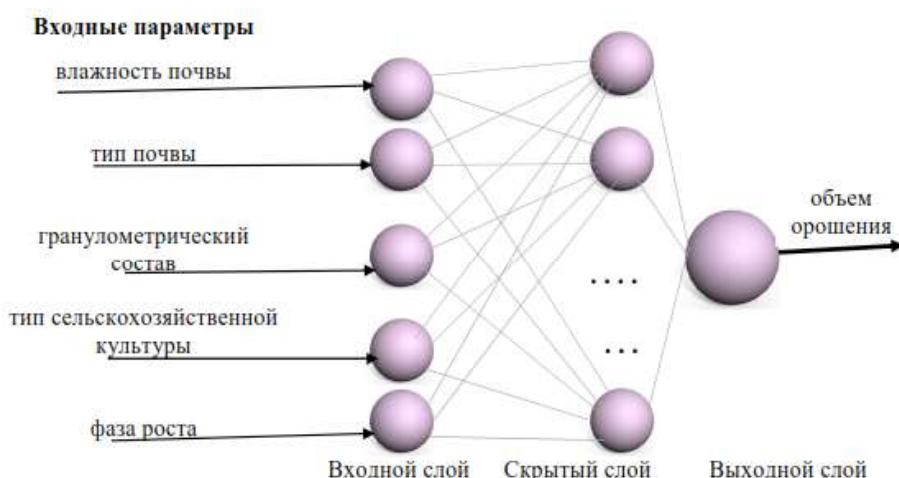


Рис. 3. Функциональная схема нейросетевой модели





Интеллектуализация и цифровизация дождевальных машин могут обеспечить максимальную эффективность использования воды и энергии за счет мониторинга влажности почвы на оптимальном уровне. Система управления является стержневым блоком всей системы. С ее помощью контролируется объем воды, что позволяет получить оптимальные результаты.

Мы предлагаем для оперативного планирования в системе управления орошением использовать управление с обратной связью. Блок управления постоянно получает обратную связь от датчиков, установленных в поле. Это позволяет блоку управления обновлять свои данные о важных параметрах системы. Блок управ-

ления принимает решение о поливе в соответствии с нейросетевой моделью на основе данных полученных с датчиков и информации об орошающем участке.

На рис. 4 показана блок-схема оперативного управления орошением на основе искусственной нейронной сети. Система управления состоит из четырех взаимосвязанных ступеней.

Входные параметры: тип почвы, гранулометрический состав, сельскохозяйственная культура, ее фазы роста и развития.

Входные данные от датчиков: на этом этапе собираются различные параметры, такие как температура, влажность воздуха, влажность почвы, скорость ветра.

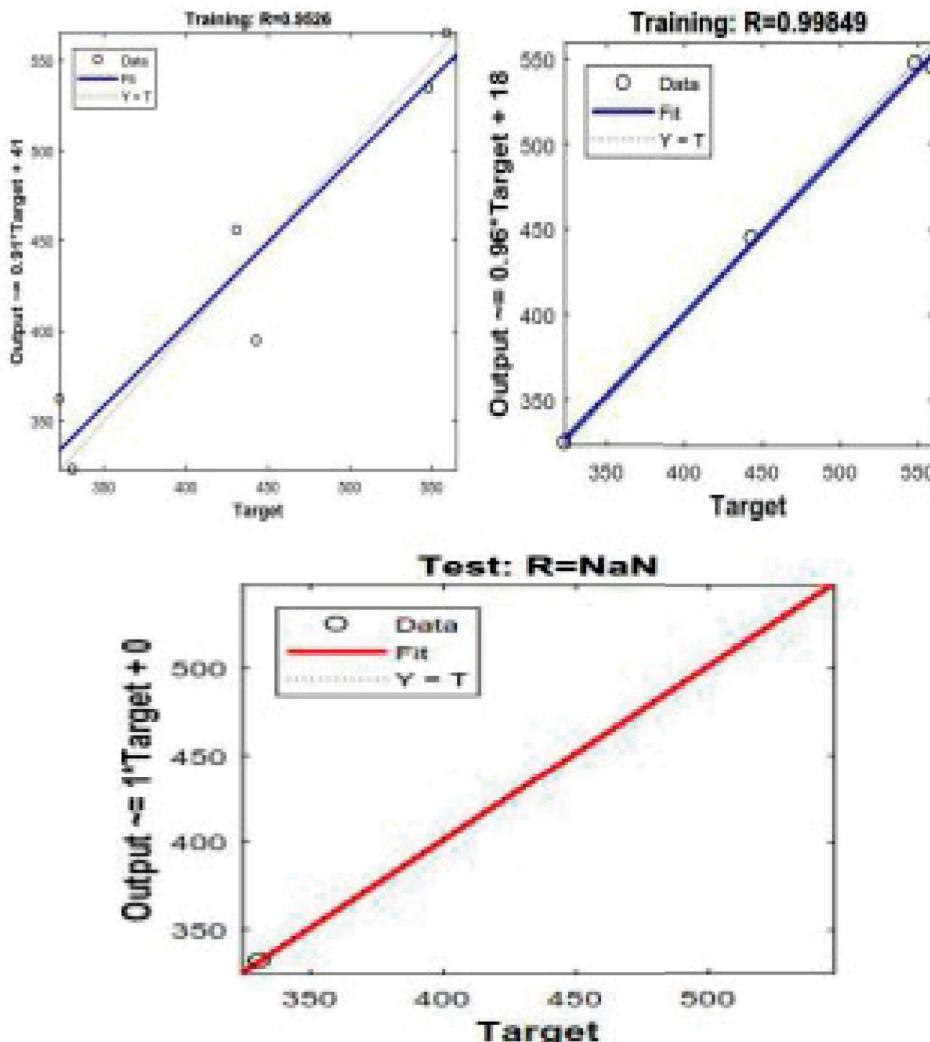


Рис. 4. Графики обучения и тестирования сети

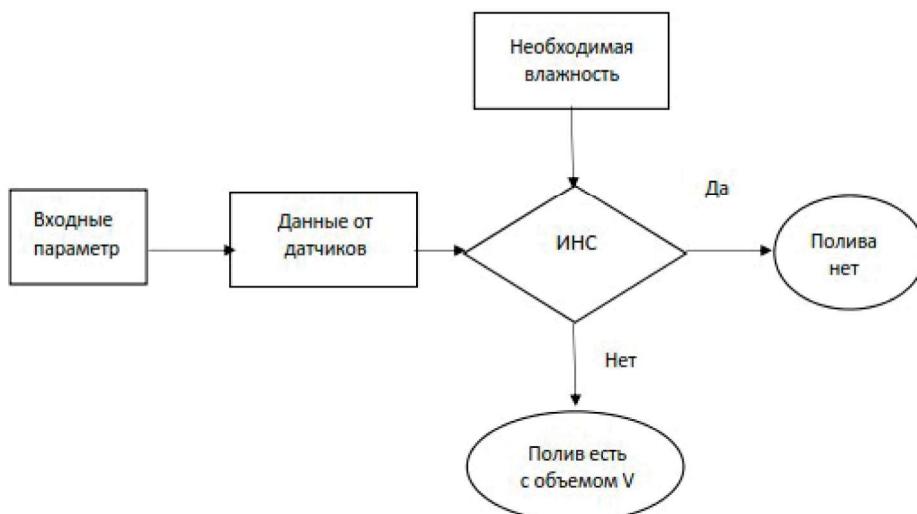


Рис. 5. Структурная схема системы управления поливом

Затем эти параметры передаются на следующий этап в качестве входных.

Необходимая влажность почвы: этот блок предоставляет информацию о количестве воды, необходимом для правильного роста растений.

ИНС: на этом этапе необходимая влажность почвы сравнивается с фактической влажностью почвы, и решение принимается динамически, то есть в определенный промежуток времени, а не задается изначально для всего полива.

Блок управления состоит из контроллера на основе искусственной нейронной сети. Этот контроллер связывает необходимую влажность почвы и измеренную влажность почвы.

Основная функция этого этапа – поддерживать фактическую влажность почвы, близкую к требуемой. В результате выходом этого этапа является управляющий сигнал, который контролирует количество воды, которое должно быть подано для оптимизации всей системы.

Заключение. Оперативное управление орошением позволяет внедрять современные методы точного земледелия, которые основаны на принципах пространственно-временной оптимальности в данном случае полива сельскохозяйственных культур. Достижение требуемой точности невозможно без применения современных цифровых технологий и интеллектуальных методов. К таким методам можно отнести искусственные нейронные сети. Так в работе [14] разработана ирригационная система, обеспечивающая экономию воды за счет использования беспроводных сенсорных сетей и нечеткого управления. Нейронные сети для разработки графиков поливов рассматривались в работе [13].

В нашей работе представлены результаты применения моделей искусственных нейронных сетей для оперативного управления орошением. В результате нейросетевой симуляции фактическая влажность почвы сопоставляется с необходимой влажностью почвы, на основе чего контролируется количество воды, которое должно быть подано для оптимизации орошения конкретного участка. Погрешность контроллера искусственной нейронной сети устойчивая и допустимая (менее 2 %), что позволяет сэкономить много энергии и воды.

Таким образом, нами представлен эффективный подход к решению проблемы управления орошением с использованием контроллера искусственной нейронной сети. Этот подход привел к возможной реализации лучшего и более эффективного управления, так как контроллеры на основе искусственной нейронной сети не требуют предварительных знаний системы и способны адаптироваться к изменяющимся условиям, в отличие от традиционных методов, что позволяет обеспечивать оптимальные результаты для различных типов почв и видов сельскохозяйственных культур.

СПИСОК ЛИТЕРАТУРЫ

1. Затинацкий С.В., Панкова Т.А. Ресурсосберегающая математическая модель нормирования орошения // Научное обозрение. – 2013. – № 11. – С. 10–13.
 2. Камышова Г.Н., Корсак В.В., Фалькович А.С., Холуденева О.Ю. Математическое моделирование в компонентах природы (интерактивный курс): учеб.-практ. пособие.– Саратов, 2012. – 155 с.
 3. Корсак В.В., Пронько Н.А., Клокова В.А., Холуденева О.Ю. Программа расчета дефицитов водного баланса поливных культур // Научная жизнь. – 2014. – № 6. – С. 77–83.
 4. Кравчук А.В., Корсак В.В., Кудайбергенова И.Р. Параметры увлажнения почвы в проведении экологических режимов орошения культур // Вестник учебно-методического объединения по образованию в области природообустройства и водопользования. – 2018. – № 11. – С. 126–130.
 5. Ольгаренко В.И., Ольгаренко И.В., Кисаров О.П., Селиков В.И. Информационные технологии планирования водопользования в хозяйствах // Политеатический сетевой электронный научный журнал Кубанского государственного аграрного университета. – 2012. – № 78. – С. 279–290.
 6. Охрана окружающей среды в России. 2020: стат. сборник / Росстат. – М., 2020. – 113 с.
 7. Хайкин С. Нейронные сети: полный курс. – 2-е изд. – М.; СПб., 2019. – 1103 с.
 8. Beale M., Hagan M., Demuth H. Neural Network Toolbox User's Guide. The Math Works, Inc, 2015, 406 p.
 9. Giusti E., Marsili -Libelli S. Fuzzy decision support system for irrigation and water conservation in agriculture // Environmental Modeling&Software, 2015, Vol. 63, 73–86.
 10. Kamlaris A., Prenafeta-Boldi FX. Deep learning in agriculture: a survey// Computers and Electronics in Agriculture, 2018, Vol. 147, 70–90.
 11. Navarro-Hellin H., Martinez-del-Ricon J., Domingo-Miguel R., Soto F. A decision support system for managing irrigation in agriculture // Computers and Electronics in Agriculture, 2016, Vol. 124, 121–131.
 12. Schmidhuber J. Deep Learning in neural networks: An overview // Neural Networks, 2015, Vol. 61, 85–117.
 13. Umair S.M., Usman R. Automation of Irrigation System Using ANN-based Controller. International Journal of Electrical and Computer Sciences, 2010, 10, 41–47.
 14. Xiaohong P., Zhi M., Laisheng X., Guodong L. A Water-Saving Irrigation System Based on Fuzzy Control Technology and Wireless Sensor Network. In: 5th International Conference on Wireless Communications, Networking and Mobile Computing, Beijing, 2009, 1–4.
- Камышова Галина Николаевна**, канд. физ.-мат. наук, доцент, зав. кафедрой «Математика, механика и инженерная графика», Саратовский государственный аграрный университет имени Н.И. Вавилова. Россия.
410056, г. Саратов, ул. Советская, 60.
Тел.: (8452) 74-96-63.
- Ключевые слова:** управление; орошение; искусственная нейронная сеть; оптимизация; модель.

APPLICATION OF ARTIFICIAL NEURAL NETWORKS FOR IRRIGATION CONTROL

Kamysheva Galina Nikolaevna, Candidate of Physical-Mathematical Sciences, Associate Professor, Head of the chair "Mathematics, Mechanics and Engineering Graphics", Saratov State Agrarian University named after N.I. Vavilov. Russia.

Keywords: management; irrigation; artificial neural network; optimization; model.

Modern methods of precision farming, based on the requirements of the spatio-temporal optimality of irriga-

tion of agricultural crops, require new approaches, since achieving the required accuracy is impossible without the use of modern digital technologies and intelligent methods. The article presents a model of operational irrigation management based on an artificial neural network. The advantage is the small error of the neural network algorithm and its ability to adapt to changing conditions, in contrast to traditional methods, which makes it possible to provide optimal results for different types of soils and types of crops.

