

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ВОДОПОТРЕБЛЕНИЯ

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

КОЛГАНОВ Дмитрий Александрович, Саратовский государственный аграрный университет имени Н.И. Вавилова

ТЕРЕХОВА Надежда Николаевна, Саратовский государственный аграрный университет имени Н.И. Вавилова

Оптимизация управления водными ресурсами для орошаемого земледелия требует развития современных подходов к определению и прогнозированию водопотребления, несмотря на большое число уже разработанных моделей. В статье представлены подходы к нейросетевому моделированию водопотребления. Преимуществами такого моделирования являются высокая точность и способность адаптации к изменяющимся параметрам модели, что отличает их от традиционных методов и позволяет обеспечивать оптимальные результаты с точки зрения минимизации ошибок и увеличения тесноты связи между переменными.

88

АГРАРНЫЙ НАУЧНЫЙ ЖУРНАЛ

5
2021

Введение. Одна из стержневых проблем настоящего времени заключается в увеличении производства продуктов питания постоянно растущего населения. Однако дефицит водных ресурсов зачастую становится препятствием для обеспечения продовольственной безопасности. Все это требует разработки новых технологий и методов орошения, которые могли бы помочь в эффективном использовании воды. Помимо этого, необходимо также развивать современные методы управления оросительной водой для достижения высокой эффективности водопользования и интенсификации аграрного производства.

Орошение является единственным средством получения высоких и стабильных урожаев в зонах рискованного земледелия, к которым, в частности, относится Саратовская область. А для расчета потребности сельскохозяйственных культур в воде, управления водными ресурсами и определения водного баланса необходима точная оценка водопотребления [2].

Вследствие влияния различных климатических факторов и наличия нелинейности во взаимосвязях между этими факторами оценка водопотребления до сих пор является сложной задачей.

Существующие методы определения водопотребления, разработанные как отечественными [1, 3, 6], так и зарубежными учеными [7, 10, 11], можно разделить на расчетные и эмпирические, а также методы непосредственных измерений. Однако, с одной стороны, у большинства из них есть некоторые ограничения в отношении доступности данных или региональной примени-

мости. С другой стороны – сравнение их результатов показывает большое расхождение, которое может достигать 50 % оценки [13]. Даже метод Пенмана-Монтейта [10], рекомендованный ФАО как дающий более точные результаты, не всегда применим из-за того, что он требует большого количества метеорологических параметров, которые обычно недоступны на большинстве метеорологических станций.

Таким образом, необходима дальнейшая разработка методов оценки водопотребления, позволяющая минимизировать вышеобозначенные проблемы. Одним из таких подходов может стать приложение искусственного интеллекта, а именно, искусственных нейронных сетей, которое в настоящее время находит активное применение при решении различных проблем. Искусственные нейронные сети дают возможность моделировать и исследовать процессы без полного понимания их физической сущности, что особенно актуально в случае такого сложного нелинейного гидрологического процесса как водопотребление. Нейросетевые модели не зависят от региональных климатических особенностей и обеспечивают более точное моделирование сложных нелинейных зависимостей в отличие от традиционных методов. Цель данной статьи – продемонстрировать возможность применения нейросетевых методов для моделирования водопотребления.

Методика исследований. Искусственная нейронная сеть – это упрощенная модель нервной системы человеческого мозга, состоящая из взаимосвязанных нейронов в параллельной распределенной системе, которая может изучать



и запоминать информацию. Понятие нейронных сетей было введено и рассматривалось, например, в работах [5, 14]. Искусственная нейронная сеть (ИНС) обнаруживает взаимосвязь между набором входов и желаемых выходов, не предоставляя никакой информации о фактических задействованных процессах. ИНС состоят из ряда взаимосвязанных обрабатывающих элементов или нейронов. То, как устроены межнейронные связи, определяет топологию сети. Нейрон – это фундаментальная единица нервной системы человеческого мозга, которая получает и объединяет сигналы от других нейронов через входные пути, называемые «дендритами».

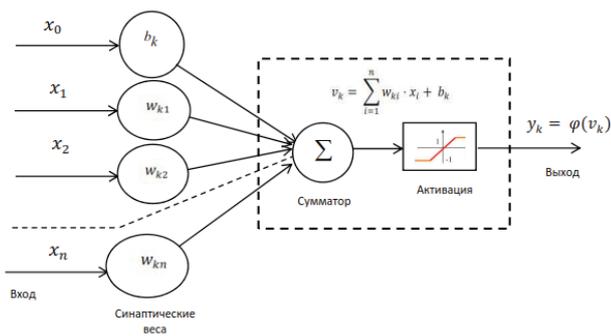
На рис. 1, а показана нелинейная модель нейрона, которая является основой для проектирования нейронной сети. Нейроны входного слоя получают входные сигналы (x_i), и эти сигналы передаются телу клетки через синапсы, характеристикой которых выступают веса. Вес w_{ki} является мультипликатором сигнала при входе i -синапса нейрона k . Линейным сумматором суммируются входные сигналы, которые взвешены по соответствующим синапсам нейрона. Функция активации или функция сжатия используется для ограничения допустимого диапазона амплитуд выходного сигнала нейрона до некоторого конечного значения. Внешнее смещение b_k имеет эффект увеличения или уменьшения чистого входа функции активации в зависимости от того, положительный он или отрицательный, соответственно.

Модель k -го нейрона математически представляется уравнением (1):

$$y_k = \varphi(u_k + b_k), \quad (1)$$

где x_1, x_2, \dots, x_n – входные сигналы, y_k – выходной сигнал и $w_{k1}, w_{k2}, \dots, w_{kn}$ – синаптические веса k -го нейрона, b_k – смещение, u_k – выход линейного сумматора из-за входного сигнала,

$u_k = \sum_{i=1}^n w_{ki} x_i$, $\varphi(*)$ – функция активации.



а

Внутренняя архитектура нейронной сети похожа на структуру биологического мозга с рядом слоев, полностью связанных между собой узлов или нейронов. Каждый нейрон связан с другими нейронами посредством прямых коммуникационных каналов, каждый из которых имеет соответствующий вес. Сеть обычно имеет два или более слоев нейронов для обработки нелинейных сигналов.

Одними из наиболее распространенных с точки зрения применения являются нейронные сети прямого распространения. Они могут быть одно- или многослойными (рис. 1, б), состоящие из входного и выходного слоев, а также одного или нескольких скрытых слоев. Входной сигнал движется только в прямом направлении от входных узлов к выходным узлам через скрытые узлы. Функция скрытого слоя заключается в выполнении промежуточных вычислений между входным и выходным слоями с помощью весов.

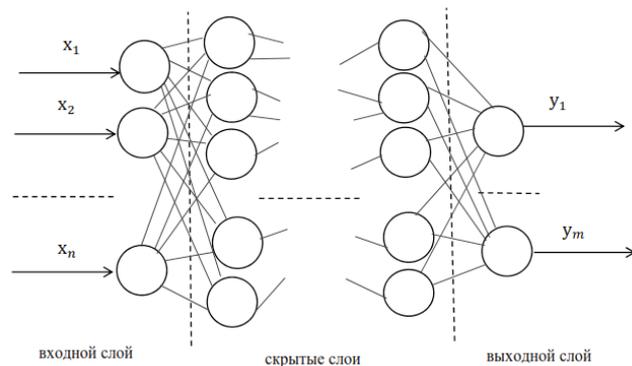
Нейронная сеть обучается с помощью ряда входных и желаемых выходных данных из набора обучающих данных. Существуют различные методы обучения, одним из которых является алгоритм обратного распространения ошибки. Это так называемый метод обучения с учителем. Его цель, как оптимизационная задача, состоит в минимизации среднеквадратичного отклонения реального выхода от необходимого, представленного уравнением (2):

$$K = \frac{1}{2} \sum_i \sum_m ([g_j^m - y_j^m])^2 \rightarrow \min, \quad (2)$$

где g_j^m и y_j^m – необходимый и реальный выходы соответственно; m и j – номера обучающего вектора и нейрона в выходном слое соответственно.

В литературе K также называют функционалом качества.

В соответствии с методом наискорейшего спуска на каждом этапе обучения изменяются веса и смещения в направлении антиградиента K в соответствии с формулами (3) – (4) [5]:



б

Рис. 1. Функциональная схема модели нейрона (а) и схема многослойной нейронной сети (б)

$$\Delta w_{ijk} = -r \left(\frac{\partial K(\mathbf{W}, \mathbf{B})}{\partial w_{ijk}} \right); \quad (3)$$

$$w_{ijk}(s+1) = w_{ijk}(s) + \Delta w_{ijk}, \quad (4)$$

где r – коэффициент скорости обучения; s – номер этапа; W, B – матрицы текущих значений весов и смещений соответственно.

Многослойные нейронные сети прямого распространения с помощью этого метода настраиваются достаточно эффективно.

На основе анализа доступных и необходимых для нейросетевого моделирования данных, а также учитывая требования к архитектуре нейросети и необходимым алгоритмам обучения и валидации, строится нейросетевая модель водопотребления.

Результаты исследований. Существует большое число методов определения водопотребления (см., например, обзор [6]). Различные методы требуют определенных данных, таким образом ограничивающих ореол их применимости. Анализ некоторых наиболее применяемых классических методов с точки зрения необходимых данных приведен в таблице.

Как видно из таблицы, состав и объем данных разнятся, что приводит к определенным достоинствам или недостаткам расчетных методов.

В силу развития и значительного применения в сельском хозяйстве настоящего времени цифровых технологий, таких как датчики, сенсоры и уже готовые погодные станции, способные собирать и аккумулировать климатические данные для конкретных гео-локаций, появляется возможность создавать модели водопотребления, учитывающие эту специфику. К таким устройствам можно отнести, например, метеорологические станции Vantage Pro2, которые измеряют количество атмосферных осадков, энергетическую освещенность, скорость ветра, температуру и относительную влажность воздуха, температуру и влажность листвы и почвы, атмосферное давление. А в основу моделирования водопотребления будут положены искусственные нейронные сети. Нейросетевые подходы к определению водопотребления рассмотрены, например, в работах [7, 8, 12].

За основу модели в нашей работе примем многослойную нейронную сеть прямого распространения. Как показывают исследования, водопотребление зависит от температуры (причем эта зависимость существенна), поэтому этот параметр является одним из ключевых входных параметров модели. Такой фактор, как влажность воздуха, связан с температурой и влияет на водопотребление, что дает основание для его включения в число входных параметров модели. Помимо этого, динамика водопотребления

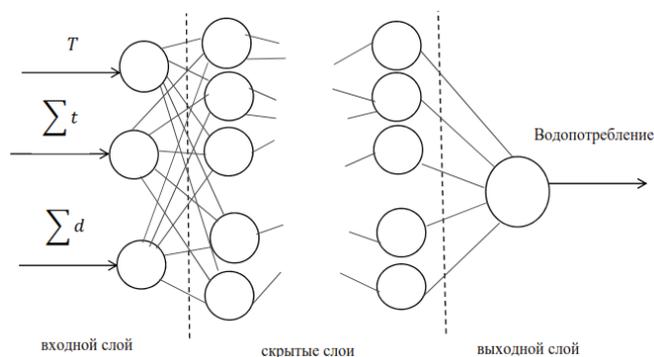


Рис. 2. Структура нейронной сети нейромодели:
 T – вегетационный период культуры, декады;
 Σ^t – сумма среднесуточных температур воздуха, °С;
 Σ^d – сумма среднесуточных дефицитов влажности воздуха, мбар

меняется в различные фазы роста и развития культуры, поэтому для конкретной культуры будем рассматривать параметр такой параметр, как средняя продолжительность вегетации культуры. Выходным параметром является водопотребление. Структурная схема представлена на рис. 2.

Нейронная сеть должна обучаться с помощью ряда входных и желаемых выходных данных из набора обучающих данных. Как было отмечено выше, искусственная нейронная сеть, используемая в этой модели, представляет собой многослойную нейронную сеть прямого распространения. Она должна быть приспособлена к ситуациям поставленной задачи посредством обучения, например, методом обучения с учителем [5], описанным выше. Одним из предположений метода является наличие целевого вектора, который является требуемым выходом для каждого входного. Таким образом, из этих векторов образуется обучающее множество для обучения сети. На вход сети подается входной вектор, на основе которого вычисляется выход. Затем полученный результат сравнивается с необходимым целевым, получая, таким образом, ошибку, которая по обратной связи возвращается в сеть, меняя по определенному алгоритму минимизации ошибки веса. Эта процедура повторяется до тех пор, пока ошибка по всему множеству не будет минимизирована.

Апробация нейромодели была проведена на примере люцерны [4]. Была принята следующая архитектура нейросети: входной слой с тремя нейронами и выходной слой с одним нейроном. Параметры промежуточного слоя варьировались до получения оптимальной точности. Алгоритм обратного распространения ошибки был использован в качестве алгоритма обучения сети. Нейросетевое моделирование осуществлялось в Matlab [9].

Чтобы оценить корреляцию между фактическими значениями и смоделированными зна-



чениями водопотребления, были построены диаграммы рассеяния (рис. 3.) для различных фаз нейромоделирования – обучение, тестирование, валидация.

Результат показывает, что разбросанные точки, статистически распределенные вокруг линии $y = x$, что подтверждает очень хорошее сходство, объясняющее высокий коэффициент корреляции между этапами обучения, тестирования и валидации, так как большинство значений, предсказанных с помощью нейросетевой модели, лежат около линии $y = x$.

Сравнивая фактические (Етфакт) и смоделированные (Етнейро) значения водопотребления (рис. 4, сверху) с классическими регрессионными методами (рис. 4, снизу), приходим к заключению, что в случае нейросетевого моделирования мы видим большое сходство, в то время как интерполяция фактических значений даже алгебраическими полиномами большой степени (на рисунке полином шестой степени), дает большое расхождение.

Нейросетевая модель водопотребления обладает свойством универсальности как в смысле диапазон условий, в которых изменяются входные переменные, обеспечивая применимость моделей, полученных для различных типов климатических условий, так и с точки зрения различных культур.

Заключение. В практике орошаемого земледелия, наряду с классическими методами водопотребления, широко распространены эмпирические модели, в основу которых положены классические регрессионные методы. Их использование при моделировании приводит к удовлетворительным результатам, если присутствуют все условия, необходимые для этого подхода. Однако, если некоторые переменные отсутствуют или не учитываются существенные факторы,

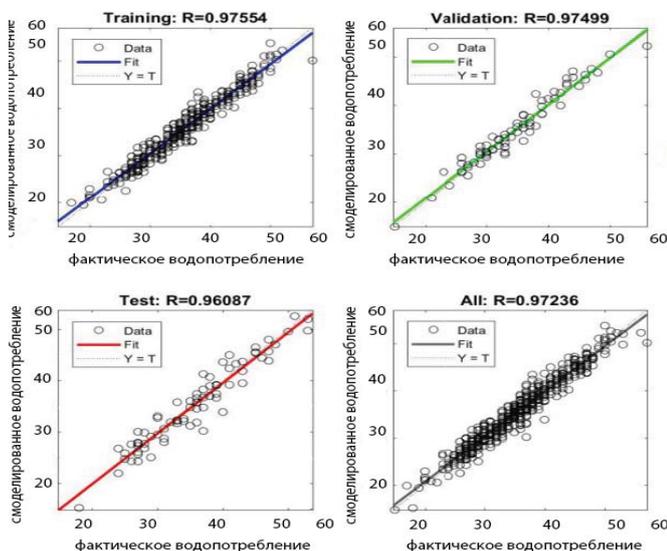


Рис. 3. Диаграммы рассеяния фактических и смоделированных значений водопотребления для различных фаз нейромоделирования

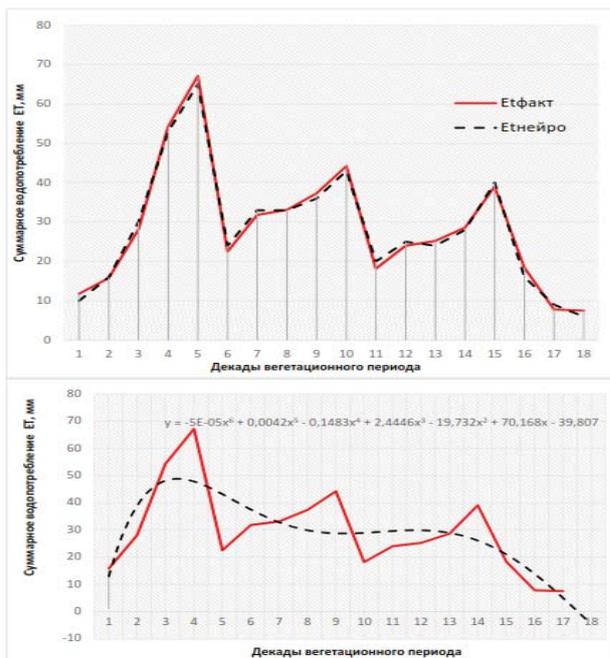


Рис. 4. Диаграммы сравнения фактического водопотребления с нейромоделью (сверху) и интерполяции алгебраическим полиномом (снизу) то метод не достигает необходимого уровня точности. В этом случае необходим принципиально новый подход, а именно моделирование на основе искусственных нейронных сетей.

В работепредставлены результаты применения нейромоделирования для прогнозирования водопотребления. Как показывают результаты, нейромодели демонстрируют лучшую точность, так как преимущество нейросетевого метода заключается в возможности улучшения критериев производительности путем изменения архитектуры сети. Помимо этого, полученные результаты подтверждают, что нейронные сети стали мощным инструментом моделирования во многих различных областях исследований. Они могут создавать простые и эффективные модели, которые являются точными и экономичными с точки зрения количества параметров. Точное определение водопотребления играет ключевую роль для определения эксплуатационных режимов орошения. Разработанные нейромодели могут быть использованы в системах интеллектуального управления орошением.

СПИСОК ЛИТЕРАТУРЫ

1. Дифференцированные оросительные нормы сельскохозяйственных культур для почвенно-климатических условий Республики Крым / А.Н. Бабичев [и др.] // Пути повышения эффективности орошаемого земледелия. – 2017. – № 4(68). – С. 133–137.
2. Информационные технологии планирования водопользования в хозяйствах / В.И. Ольгаренко [и др.] // Политематический сетевой электронный научный журнал Кубанского государственного аграрного университета. – 2012. – № 78. – С. 279–290.
3. Определение суммарного водопотребления



сельскохозяйственных культур в аридных зонах/ В.В. Корсак [и др.] // Научная жизнь. – 2016. – №1. – С. 41–51.

4. Панкова Т.А. Исследование изменчивости биоклиматических коэффициентов люцерны от влагообеспеченности сельскохозяйственного поля // Научная жизнь. – 2014. – №4. – С. 43–49.

5. Хайкин С. Нейронные сети: полный курс. – 2-е изд. – М.: СПб., 2019. – 1103 с.

6. Черемисинов А.А., Черемисинов А.Ю. Обзор расчетных методов определения суммарного испарения орошаемых сельскохозяйственных полей // Научный журнал Российского НИИ проблем мелиорации. – 2016. – №1(21). – С. 41–51.

7. Ahooghalandari M., Khiadani M., Jahromi M.E. Developing equations for estimating reference evapotranspiration in Australia // Water Resources Management. 2016, Vol. 30 (11), P. 3815–3828.

8. Antonopoulos V.Z., Antonopoulos A.V. Daily reference evapotranspiration estimates by artificial neural networks technique and empirical equations using limited input climate variables // Computers and Electronics in Agriculture. 2017. No. 132. P. 86–96.

9. Beale M., Hagan M., Demuth H. Neural Network Toolbox™ User's Guide. The Math Works, Inc, 2015. 406 p.

10. Chapter 2 - FAO Penman-Monteith equation. – URL: <http://www.fao.org/docrep/x0490e/x0490e06.htm>.

11. Dou X., Yang Y. Evapotranspiration estimation using four different machine learning approaches in different terrestrial ecosystems // Computers and Electronics in Agriculture, 2018, No. 148, P. 95–106.

12. Laaboudi A., Mouhouche B., Draoui B. Neural network approach to reference evapotranspiration modeling from limited climatic data in arid regions // International Journal of Biometeorology, 2012, No. 56, P. 831–841.

13. Lu J., Sun G., McNulty G.S., Amatya M.D. A comparison of six potential evapotranspiration methods for regional use in the southeastern united states // Journal of the American Water Resources Association, 2005, No. 41(3), P. 621–633.

14. Schmidhuber J. Deep Learning in neural networks: An overview // Neural Networks, 2015, Vol. 61, P. 85–117.

Камышова Галина Николаевна, канд. физ.-мат. наук, доцент, зав. кафедрой «Математика, механика и инженерная графика», Саратовский государственный аграрный университет имени Н.И. Вавилова. Россия.

Колганов Дмитрий Александрович, канд. техн. наук, доцент кафедры «Техносферная безопасность и транспортно-технологические машины», Саратовский государственный аграрный университет имени Н.И. Вавилова. Россия.

Терехова Надежда Николаевна, канд. техн. наук, доцент кафедры «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: водопотребление; орошение; искусственная нейронная сеть; оптимизация; модель.

NEURAL NETWORK MODELING OF WATER CONSUMPTION

Kamyshova Galina Nickolaevna, 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.

Kolganov Dmitry Alexandrovich, Candidate of Technical Sciences, Associate Professor of the chair "Technosphere Safety and Transport and Technological Machines", Saratov State Agrarian University named after N.I. Vavilov. Russia.

Terekhova Nadezhda Nickolaevna, Candidate of Technical Sciences, Associate Professor of the chair "Mathematics, Mechanics and Engineering Graphics", Saratov State Agrarian University named after N.I. Vavilov. Russia.

Keywords: water consumption; irrigation; artificial neural network; optimization; model.

Optimizing water management for irrigated agriculture requires the development of modern approaches to determining and predicting water consumption, despite the large number of already developed models. The article presents approaches to neural network modeling of water consumption. The advantage of such modeling is high accuracy and ability to adapt to changing parameters of the model, which distinguishes them from traditional methods and allows you to provide optimal results in terms of minimizing errors and increasing the tightness of the relationship between variables.

