Научный журнал Российского НИИ проблем мелиорации, № 2(18), 2015 г., [16–30]

УДК 635.657:631.5:631.6:519.71

С. О. Лавренко, Н. Н. Лавренко, В. И. Пичура
Херсонский государственный аграрный университет, Херсон, Украина

НЕЙРОПРОГРАММИРОВАНИЕ УРОЖАЙНОСТИ ЗЕРНА НУТА НА МЕЛИОРИРУЕМЫХ ПОЧВАХ

Цель исследований – усовершенствование элементов технологии выращивания нута на мелиорируемых почвах в типичных климатических условиях зоны сухой степи Украины. Для высокоточного программирования урожая зерна нута в зависимости от четырех агротехнологических факторов (суммарного водопотребления, минеральных удобрений, загущения растений и глубины основной обработки почвы) применен метод обобщенной регрессионной искусственной нейронной сети GRNN (4-54-2-1) с 54 нейронами в первом скрытом слое и двумя – во втором; продуктивность обучения – 0,22; контрольная – 0,37; тестовая – 0,36; ошибка обучения – 0,29; контрольная – 0,45; тестовая – 0,47. Множественная корреляция с учетом нелинейных закономерностей влияния факторов на урожайность зерна нута составила 0,96. Коэффициенты асимметрии фактической и расчетной урожайности составили 0,37 и 0,23 соответственно. Достоверность моделирования составила 92,08 %. Кросс-проверка прогнозных моделей была проведена с использованием статистических критериев оценки достоверности: средняя ошибка, средняя абсолютная ошибка, стандартное отклонение ошибки, средняя относительна ошибка, коэффициент корреляции. Для обработки использованы модификации программы Statistica Advanced и Automated Neural Networks for Windows v.10 Ru. Определены нелинейные закономерности степени влияния изучаемых факторов на динамику формирования урожайности зерна нута: суммарное водопотребление – 37,01 %; внесение минеральных удобрений – 22,88 %; загущение растений – 22,29 %; глубина основной обработки почвы – 17,82 %. Представленные в работе результаты нейромоделирования можно использовать для четырехфакторного высокоточного программирования урожайности зерна нута на мелиорируемых почвах в типичных климатических условиях сухой степи.

Ключевые слова: нейропрограммирование, урожайность, нут, основная обработка почвы, минеральное удобрение, загущение растений, суммарное водопотребление.

S. O. Lavrenko, N. N. Lavrenko, V. I. Pichura
Kherson State Agricultural University, Kherson, Ukraine

NEURAL NETWORK MODELING OF CHICKPEA GRAIN YIELD ON AMELIORATED SOILS

The aim of the research is to improve the management practices for chickpea growing upon ameliorated soils in typical climate conditions of arid steppe of Ukraine. For precision programming of chickpea grain yield depending on four factors (water consumption, mineral feterlizers, plant density, and the depth of soil primary tillage) generalized regression method of artificial neural network GRNN (4-54-2-1) with 54 neurons in the first buried layer and two neurons in the second layer was applied; productivity neural network training is 0.22; control – 0.37; test – 0.36; training error – 0.29; control – 0.45; test – 0.47. Multiple correlation considering non-linear patterns of the impact of studying factors on chickpea grain yield was 0.96. Asymmetry parameters of actual and calculated yield were 0.37 and 0.23, respectively. The accuracy of the simulation was 92.08 %. Cross-validation of predictive

models was done using statistical criteria for significance: mean error, mean absolute error, standard error deviation, average relative error, correlation coefficient. For processing the modifications of such software as Statistica Advanced and Automated Neural Networks for Windows v.10 Ru were used. Non-linear patterns of the impact of studying factors on the dynamics of forming the chickpea grain yield were determined: water consumption – 37.01 %; mineral fertilizer applying – 22.88 %; plant density – 22.29 %; depth of the primary soil tillage – 17.82 %. The results of neural network modeling presented in the work can be used for four-factor precise programming of chickpea grain yield on ameliorative soils in typical climate conditions of arid steppe.

Keywords: neural network modeling, yield, chickpea, primary soil tillage, mineral fertilizer, plant density, water consumption.

Введение. Информационное пространство эволюционирует очень быстро, поэтому применение устаревших методов программирования и прогнозирования различных процессов может не соответствовать действительности. На современном научном этапе моделирование реальных систем, в т. ч. в земледелии и растениеводстве, не всегда возможно по причине большой размерности данных и сложности (нелинейности) взаимосвязи изучаемых процессов. По этой причине приходится искать альтернативные методы моделирования, программирования и прогнозирования в различных отраслях сельского хозяйства. Такой альтернативой традиционным методам стало применение метода искусственных нейронных сетей (ИНС), потому что нелинейная структура ИНС позволяет строить модели, которые с достаточной точностью описывают реальные процессы, и определять сложные закономерности в различных областях знаний: мелиорации, гидрологии, земледелии, агрохимии и т. п. [1–6].

Нейронные сети (НС) позволяют решать задачи, с которыми не могут справиться традиционные методы. Они способны успешно выполнять это, опираясь на неполную, искаженную информацию [7], т. е. ИНС не предполагают никаких ограничений по характеру входной информации. Нейросетевое моделирование в чистом виде базируется лишь на данных, не привлекая никаких априорных соображений [8].

НС нашли широкое применение при построении прогнозных моделей поведения сложных динамических систем, содержащих многочислен-

ные изменяющиеся во времени параметры при взаимодействии с различными характеристиками окружающей среды [9].

НС позволяют с любой степенью точности аппроксимировать произвольную непрерывную функцию, несмотря на отсутствие или наличие периодичности или цикличности, т. е. НС возможно «научить» таким образом, чтобы она с высокой достоверностью распознавала любой набор данных и определяла дальнейшее развитие изучаемого процесса на определенный период. Поскольку временные ряды большинства показателей в земледелии и растениеводстве представляют собой непрерывные функции, то применение НС при их прогнозировании является вполне оправданным и корректным.

Основными преимуществами НС являются [10, 11]:

- независимость методов синтеза НС от размерности пространства признаков;

- высокая допустимость зашумленных данных и низкий коэффициент ошибок;

- параллельная обработка информации одновременно всеми нейронами, что делает возможным аппаратный анализ сложных сигналов в реальном времени;

- аппроксимация любой непрерывной функции. Таким образом, нет необходимости заранее принимать модельные гипотезы, и даже в ряде случаев предположения о том, какие переменные действительно важны;

- проводят анализ влияния входных параметров на результат. При обучении системы выделяются ключевые характеристики. Возможно извлечение существенных данных из избыточной информации;

- инвариантны размерности пространства признаков;

- самоорганизация структуры НС – процесс упорядочения взаимосвязей между отдельными нейронами, имеющий отношение к реализации целевой функции системы [12]. Алгоритм самоорганизации НС базируется

на двух эмпирических феноменах ее обучения, которые обычно наблюдаются при изменении чисел нейронов в скрытом слое и количества скрытых слоев [13];

- непрерывное усовершенствование и оптимизация структуры НС различными алгоритмами обучения, извлечения правил, упрощения сетей;

- отказоустойчивость в смысле монотонного, а не катастрофического изменения качества решения задачи в зависимости от числа вышедших из строя элементов;

- корректировка синоптических весов при поступлении новой информации, что дает возможность улучшать качество работы и компенсировать незначительные отклонения в характеристиках обрабатывающих элементов в процессе эксплуатации НС.

К недостаткам и ограничениям НС можно отнести:

- отсутствие четких алгоритмов выбора функции активации и механизмов, регулирующих работу сети в целом;

- большое количество весов и пороговых уровней НС снижает скорость обработки входных данных, что также может привести к «параличу» сети при обучении;

- сложность обучения, формирования и аппроксимации НС.

Решение любой задачи с использованием ИНС включает в себя следующие этапы [14]:

- разработка нейросетевой модели (НСМ);

- формирование входного и желаемого выходного сигналов НСМ;

- формирование сигнала ошибок и функционала оптимизации;

- формирование структуры НСМ, адекватной решаемой задаче;

- разработка алгоритма настройки НСМ, эквивалентного процесса решения задачи в нейросетевом логическом базисе;

- решение задачи с использованием разработанной НСМ.

Система методов ИНС позволяет создать модели различных архи-

тектур для высокоточного моделирования, программирования и прогнозирования в системе земледелия, мелиорации и растениеводства.

Материал и методы. Исследования по усовершенствованию элементов технологии возделывания нута на мелиорированных почвах для типичных климатических условий зоны сухой степи были проведены в течение 2012–2014 гг. на землях сельскохозяйственного кооператива «Радянська земля» Белозерского района Херсонской области (Украина). Основными почвами являются темно-каштановые солонцеватые. Они имеют достаточно четкую выраженную дифференциацию почвенного профиля на гумусово-элювиальный и гумусово-иллювиальный горизонты. Общая глубина гумусового горизонта составляет 50–55 см, окраска темно-серая с коричневым оттенком. Вскипание от HCl наблюдается с глубины 60–70 см. Белоглазка отмечается на глубине 110–130 см. Количество гумуса составляет 2,5–3,0 %.

Грунтовые воды на территории хозяйства залегают на глубине от 3 до 5 м и не влияют на почвообразующие процессы. Они слабоминерализованные с общим содержанием солей 1–3 г/л. Химизм засоления сульфатно-хлоридный.

В полевых опытах исследовалось влияние различных факторов на урожайность зерна нута. Изучались варианты: фактор А – основная обработка почвы: отвальная на глубину 20–22 см, отвальная на глубину 28–30 см; фактор В – фон питания: без удобрений, $N_{45}P_{45}$, $N_{90}P_{90}$; фактор С – загущение растений: норма высева семян 0,5; 1,0; 1,5 млн шт./га; фактор D – условия увлажнения: без орошения, на фоне орошения.

Полевые опыты были заложены в четырехкратной повторности. Расположение вариантов осуществлялось методом расщепленных делянок. Во время проведения исследований руководствовались общепринятой методикой проведения полевых опытов.

Агротехника нута была общепринятой для почвенно-климатических

условий зоны сухой степи. В опытах выращивали сорт нута Розана (рисунок 1). После уборки предшественника (озимой пшеницы на зерно) проводили двукратное дискование стерни на глубину 6–8 и 10–12 см. Основную обработку почвы выполняли на глубину согласно вариантам схемы опытов. Под основную обработку вносили минеральные удобрения сеялкой СЗ-3,6 в дозах согласно вариантам схемы опытов. С целью дополнительного уничтожения сорняков и выравнивания почвы через 2 недели выполняли культивацию на глубину 12–14 см. При наступлении физической спелости почвы весной проводили боронование. Предпосевную культивацию выполняли на глубину заделки семян. Посев выполнялся на глубину 5–7 см трактором John Deere 8400 с сеялкой John Deere 740A. Нормы высева семян устанавливали согласно вариантам схемы опытов.

Рисунок 1 – Растения нута в полевом опыте (автор фото – С. О. Лавренко)

Семена за 1–2 часа до посева обрабатывали биопрепаратами селекционных высокоэффективных штаммов клубеньковых бактерий («Ризобофит нутовый» + «Фосфоэнтерин» + «Биополицид») при расчетной дозе

инокулюма 10^6 бактерий /1 семя. После посева поле прикатывали. Для борьбы с сорняками до всходов культуры вносили почвенный гербицид «Гезагард 500 FW к. с.» нормой 3,0 л/га. Против вредителей в фазу «бутонизация – начало цветения» использовали инсектицид «Нурел Д» нормой 1,0 л/га.

Во время проведения опытов влажность почвы поддерживали на уровне 75–80 % НВ в вариантах с орошением с помощью дождевальной машины «Кубань». Орошение земель в хозяйстве осуществляется водами Ингулецкой оросительной системы. Суммарное водопотребление на посевах нута за вегетационный период определяли упрощенным методом водного баланса.

Уборку зерна проводили прямым комбайнированием при полной спелости бобов.

Для определения степени влияния факторов и прогнозирования урожая зерна нута был применен метод обобщенной регрессионной ИНС (GRNN).

На рисунке 2 представлена схема математической модели НС для программирования урожайности сельскохозяйственных культур с n входами (дендритами, т. е. количеством факторов), причем синапсы этих дендритов имеют веса w_1, w_2, …, w_n. До синапса поступают импульсы силы X_1, X_2, …, X_n соответственно (факторы влияния), тогда после прохождения синапса и дендритов к нейронам поступают импульсы w_1X_1, w_2X_2, …, w_nX_n. Нейрон преобразует полученный суммарный импульс $S = w_1X_1 + w_2X_2 + \ldots + w_nX_n$ в соответствии с некоторой передаточной функцией $F(S)$. Сила выходного импульса (урожайность) равна: $Y = F(S) = F(w_1X_1 + w_2X_2 + \ldots + w_nX_n)$.

Кросс-проверка прогнозных моделей проведена с использованием статистических критериев оценки достоверности: средняя ошибка, средняя

абсолютная ошибка, стандартное отклонение ошибки, средняя относительна ошибка, коэффициент корреляции [17]. Для обработки использованы модификации программы Statistica Advanced и Automated Neural Networks for Windows v.10 Ru.

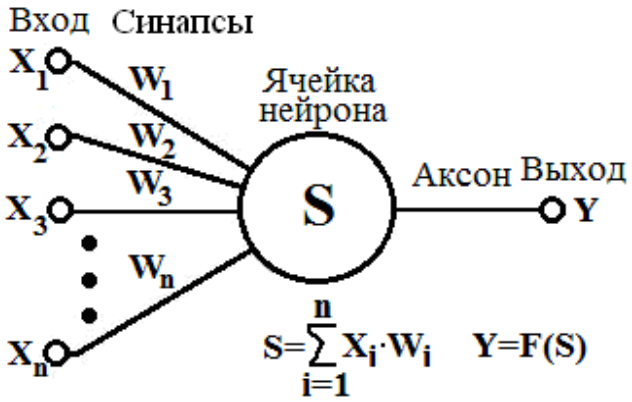

Рисунок 2 – Схема математической модели нейросети для программирования урожайности сельскохозяйственных культур [15, 16]

Результаты и обсуждение. Из полученных экспериментальных данных видно, что все поставленные на изучение технологические элементы выращивания нута существенно повлияли на величину урожая зерна (таблица 1).

Таблица 1 – Урожайность зерна нута в зависимости от технологических приемов его выращивания, среднее за 2012–2014 гг.

В т/га

Основная обработка почвы (фактор А)	Фон питания (фактор В)	Загущение растений, млн шт./га (фактор С)		
		0,5	1,0	1,5
1	2	3	4	5
Без орошения (фактор D)				
Отвальная вспашка на глубину 20–22 см	Без удобрений	1,26	1,48	1,55
	$N_{45}P_{45}$	1,41	1,68	1,77
	$N_{90}P_{90}$	1,52	1,80	1,90
Отвальная вспашка на глубину 28–30 см	Без удобрений	1,28	1,50	1,60
	$N_{45}P_{45}$	1,44	1,72	1,83
	$N_{90}P_{90}$	1,56	1,85	1,98
На фоне орошения (фактор D)				
Отвальная вспашка на глубину 20–22 см	Без удобрений	2,18	2,48	2,70
	$N_{45}P_{45}$	2,66	3,02	3,31
	$N_{90}P_{90}$	2,83	3,24	3,53

Продолжение таблицы 1

1	2	3	4	5
Отвальная вспашка на глубину 28–30 см	Без удобрений	2,22	2,53	2,74
	$N_{45}P_{45}$	2,71	3,10	3,38
	$N_{90}P_{90}$	2,89	3,33	3,60
Примечание – $НСР_{05}$ за годы исследований колебалась, т/га: для факторов A, D – от 0,035 до 0,048; B, C – 0,043–0,059; взаимодействия AD – 0,050–0,068; BD, CD, AB, AC – 0,061–0,083; BC – 0,075–0,102; ABD, ACD – 0,086–0,118; BCD, ABC – 0,106–0,144; комплексного взаимодействия ABCD – 0,150–0,204.				

Главным фактором формирования высокого и качественного урожая зерна нута на юге Украины является орошение. Именно его внедрение обеспечило значительное увеличение урожайности культуры. При естественном увлажнении средняя урожайность зерна нута за годы исследований составляла 1,62 т/га. Выращивание культуры при орошении увеличило показатель почти в 1,8 раза. Прирост урожайности зерна нута, где лимитирующий фактор нивелировался искусственным увлажнением, колебался от 0,93 до 1,62 т/га.

Создание глубокого пахотного слоя почвы 28–30 см в сравнении с 20–22 см увеличило урожайность зерна нута в вариантах без орошения на 0,02–0,08, а при орошении – на 0,04–0,09 т/га. Но достоверным этот прирост нельзя считать, потому что он находился в пределах погрешности опыта.

В вариантах без удобрения урожайность зерна нута была наименьшей и составляла при естественном увлажнении от 1,26 до 1,60, тогда как при орошении – от 2,18 до 2,74 т/га. Внесение удобрений по-разному повлияло на продуктивность культуры в разных условиях увлажнения. Внесение $N_{45}P_{45}$ увеличило урожайность зерна нута в среднем на 13,1 %, что составило 0,15–0,23 т/га в вариантах без орошения; наибольшие показатели прироста урожайности зерна были получены при орошении культуры (0,48–0,64 т/га).

Внесение азотно-фосфорных удобрений в количестве 90 кг/га действующего вещества значительно увеличило урожай культуры. При этой

норме средняя урожайность зерна нута по опыту в вариантах без орошения составляла 1,77 т/га, а при орошении – в 1,83 раза больше (3,24 т/га). При сравнении этих вариантов с неудобренными прибавки составили соответственно 0,26–0,38 и 0,65–0,86 т/га.

Прирост урожайности зерна нута в зависимости от увеличения нормы минеральных удобрений при естественном увлажнении составлял от 0,11 до 0,15 т/га, а при орошении – 0,17–0,23 т/га, что больше на 53,3–54,5 %.

Формирование оптимальной плотности травостоя в условиях дефицита влаги (как почвенной, так и воздушной) является важным агротехнологическим элементом. Посев нута с загущением 0,5 млн шт./га сформировал наименьшую урожайность зерна, которая без орошения колебалась от 1,26 до 1,56 т/га, а при орошении – от 2,18 до 2,89 т/га. Загущение растений 1,0 млн шт./га увеличило выход продукции (зерна) на 0,22–0,29 т/га при естественном и на 0,30–0,44 т/га при искусственном увлажнении в сравнении с предыдущим вариантом. При максимальном загущении растений нута (1,5 млн шт./га) была получена наивысшая урожайность в обоих условиях увлажнения. В вариантах без орошения этот показатель колебался от 1,55 до 1,98 т/га, тогда как при искусственном увлажнении – от 2,70 до 3,60 т/га.

Для оценки и уточнения ранжирования факторов влияния на урожайность зерна нута авторами была создана обобщающая регрессионная ИНС (рисунок 3) GRNN (4-54-2-1) с 54 нейронами в первом скрытом слое и двумя – во втором; продуктивность обучения – 0,22; контрольная – 0,37; тестовая – 0,36; ошибка обучения – 0,29; контрольная – 0,45; тестовая – 0,47. Множественная корреляция с учетом нелинейных закономерностей влияния факторов на урожайность зерна нута составила 0,96 (таблица 2). Коэффициенты асимметрии фактической и расчетной урожайности составили 0,37 и 0,23 соответственно.

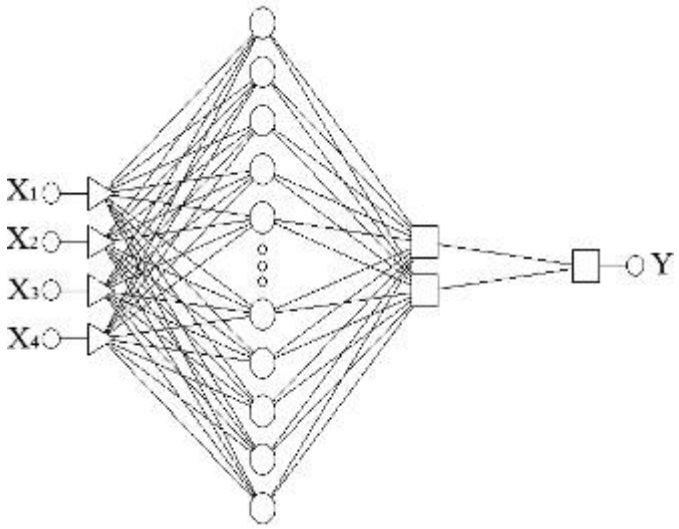

а)

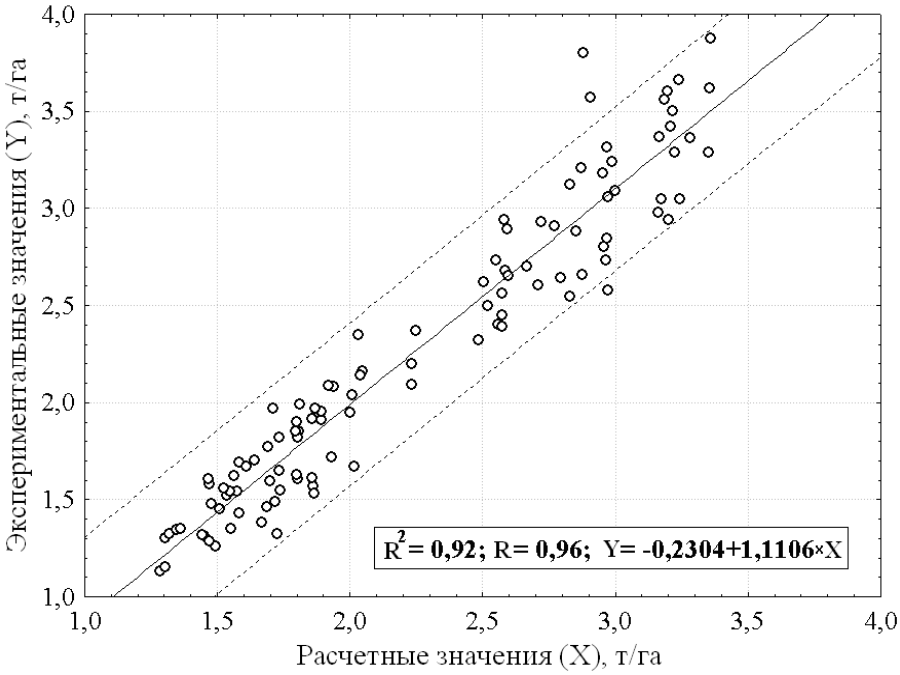

б)

а – архитектура GRNN; *б* – уровень аппроксимации нейронной модели

Рисунок 3 – Характеристика обобщающей регрессионной модели прогнозирования урожайности зерна нута

Таблица 2 – Оценка ошибки регрессионной нейронной модели прогнозирования урожайности зерна нута

Критерий	Ошибка модели
Средняя ошибка, т/га	–0,0182
Средняя абсолютная ошибка, т/га	0,1699
Стандартное отклонение ошибки, т/га	0,2204
Корреляция	0,96
Средняя абсолютная относительная ошибка, %	7,92

Функция отклика регрессионной НС имеет вид:

$$S_n = \sum_{n=1}^{4} w_n^{(1)}(t) x_n^{(t)} ,$$

$$S_j = \sum_{j=1}^{54} w_j^{(2)}(t) f(S_n) ,$$

$$S_m = \sum_{m=1}^{2} w_m^{(3)}(t) f(S_j) ,$$

$$y_i(t) = f(S_m),\ \partial ei = \overline{1,4} ,$$

где t – дискретное значение временного ряда;

w – матрица весовых коэффициентов;

$x_n^{(t)}$ – n-я координата входного вектора в определенный момент t;

$f(S_n; S_j; S_m)$ – передаточная функция скрытых и выходящих слоев НС.

Систему формул можно представить в виде:

$$y_i(t) = f(\sum_{m=1}^{2} w_m^{(3)}(t) f(\sum_{j=1}^{54} w_j^{(2)}(t) f(\sum_{n=1}^{4} w_n^{(1)}(t) x_n^{(t)}))),\ \partial ei = \overline{1,4} .$$

В результате оценки отклика НС было осуществлено ранжирование факторов влияния на динамику формирования урожайности зерна нута (рисунок 4):

- на первом месте суммарное водопотребление ($м^3$/га) с коэффициентом влияния 3,47;

- на втором – доза внесения минеральных удобрений (кг/га действующего вещества) (1,35);

- на третьем – загущение растений (млн шт./га) (1,25);

- на четвертом – глубина основной обработки почвы (см) (0,97).

Выводы и предложения. Впервые применен метод искусственных нейронных сетей для моделирования и программирования урожайности зерна нута. В результате моделирования создана регрессионная искусственная нейронная сеть, достоверность моделирования составила 92,08 %. Также определены нелинейные закономерности степени влияния изучае-

мых факторов на динамику формирования урожайности зерна нута: суммарное водопотребление (м^3/га) – 37,01 %; внесение минеральных удобрений (кг/га действующего вещества) – 22,88 %; загущение растений (млн шт./га) – 22,29 %; глубина основной обработки почвы (см) – 17,82 %.

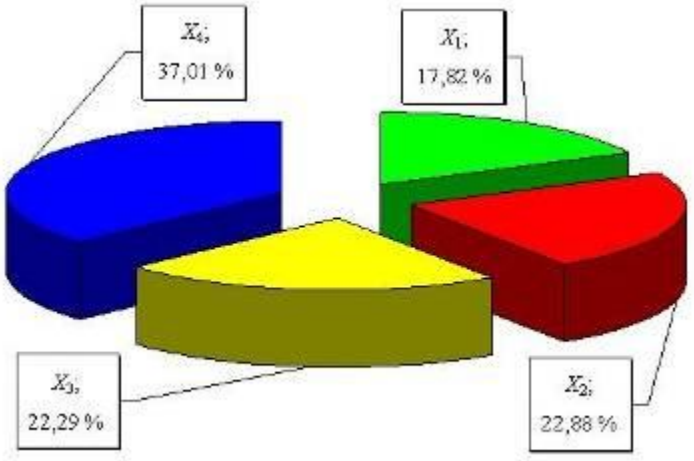

X_1 – глубина основной обработки почвы, см; X_2 – доза внесения минеральных удобрений, кг/га действующего вещества; X_3 – загущение растений, млн шт./га; X_4 – суммарное водопотребление, м^3/га

Рисунок 4 – Степень влияния фактора на формирование урожайности зерна нута

Представленные в работе результаты нейромоделирования можно использовать для четырехфакторного высокоточного программирования урожайности зерна нута на мелиорированных почвах в типичных климатических условиях зоны сухой степи.

Список литературы

1 Козадаев, А. С. Предварительная оценка качества обучающей выборки для искусственных нейронных сетей в задачах прогнозирования временных рядов / А. С. Козадаев // Вестник Тамбовского университета / Серия: Естественные и технические науки. – 2008. – Т. 13. – № 1. – С. 99–100.

2 Пичура, В. И. Применение интеллектуальных искусственных нейронных сетей для прогнозирования химических показателей оросительной воды (на примере Ингулецкого магистрального канала) / В. И. Пичура // Водное хозяйство России: проблемы, технологии, управление: науч.-практ. журн. – Екатеринбург, 2012. – № 2. – С. 17–28.

3 Пичура, В. И. Пространственно-временное прогнозирование агрохимических показателей мелиорируемых почв с использованием нейротехнологий (на примере Херсонской области) / В. И. Пичура // Агрохимия и почвоведение: межведомств. тематич. науч. сб. – Харьков: Институт почвоведения и агрохимии им. А. Н. Соколовского, 2012. – Вып. 78. – С. 87–95.

4 Кузьменко, Я. В. Оценка и прогнозирование стока малых рек в условиях ан-

тропогенных воздействий и изменений климата [Электронный ресурс] / Я. В. Кузьменко, Ф. Н. Лисецкий, В. И. Пичура // Современные проблемы науки и образования. – 2012. – № 6. – С. 1–9. – Режим доступа: www.science-education.ru/106-7640, 2015.

5 Лисецкий, Ф. Н. Периодичность климатических, гидрологических процессов и озерного осадконакопления на юге Восточно-Европейской равнины / Ф. Н. Лисецкий, В. Ф. Столба, В. И. Пичура // Проблемы региональной экологии: обществ.-науч. журн. – Москва, 2013. – № 4. – С. 19–25.

6 Basin organization of nature management for solving hydroecological problems / F. N. Lisetskii, Ya. V. Pavlyuk, Zh. A. Kirilenko, V. I. Pichura // J Russian Meteorology and Hydrology. – 2014. – V. 39, № 8. – P. 550–557. – DOI: 10.3103/S106837391408007X.

7 Кравченко, М. Л. Моделирование экономических систем с применением нейронных сетей / М. Л. Кравченко, Т. И. Грекова // Вестник Томского государственного университета. – 2006. – № 290. – С. 169–172.

8 Крючин, О. В. Использование технологии искусственных нейронных сетей для прогнозирования временных рядов на примере валютных пар / О. В. Крючин // Вестник Тамбовского университета / Серия: Естественные и технические науки. – 2010. – Т. 15. – № 1. – С. 312.

9 Кравченко, Ю. А. Экстраполяция изменений параметров сложных систем на основе периодической нечеткой клеточной нейронной сети / Ю. А. Кравченко // Известия Таганрогского государственного радиотехнического университета. – 2007. – Т. 73. – № 1. – С. 242–246.

10 Копыткова, Л. Б. К вопросу построения нейросетевой модели цифровой обработки сигналов / Л. Б. Копыткова // Вестник Ставропольского государственного университета. – 2009. – № 4. – С. 10–16.

11 Манжула, В. Г. Нейронные сети Кохонена и нечеткие нейронные сети в интеллектуальном анализе данных / В. Г. Манжула, Д. С. Федяшов // Фундаментальные исследования. – 2011. – № 4. – С. 108–114.

12 Владимирский, Б. М. Нейронные сети как источник идей и инструмент моделирования процессов самоорганизации и управления / Б. М. Владимирский // Экономический вестник Ростовского государственного университета. – 2006. – Т. 4. – № 4. – С. 14.

13 Арзамасцев, А. А. Алгоритм самоорганизации структуры искусственной нейронной сети в процессе ее обучения / А. А. Арзамасцев // Вестник Тамбовского университета / Серия: Естественные и технические науки. – 2007. – Т. 12. – № 1. – С. 105–106.

14 Семейкин, В. Д. Моделирование искусственных нейронных сетей в среде MATLAB / В. Д. Семейкин, А. В. Скупченко // Вестник Астраханского государственного технического университета / Серия: Управление, вычислительная техника и информатика. – 2009. – № 1. – С. 159–164.

15 Рутковская, Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский. – М.: Горячая линия – Телеком, 2004. – 452 с.

16 Machine Learning, Neural and Statistical Classification / Ed. D. Mitchie [et al.]. – Chichester: Ellis Horwood, 1994. – 304 p.

17 Павлюк, Я. В. Использование нейротехнологий для моделирования временных процессов формирования водности рек / Я. В. Павлюк, Э. А. Терехин, В. И. Пичура // Эрозионные и русловые процессы и современные методы их исследования: материалы X Семинара молодых ученых вузов, объединяемых советом по проблеме эрозионных, русловых и устьевых процессов. – Белгород: ЛитКараВан, 2014. – С. 141–148.

Лавренко Сергей Олегович
Ученая степень: кандидат сельскохозяйственных наук
Ученое звание: доцент

Должность: доцент кафедры земледелия, ученый секретарь университета
Место работы: Государственное высшее учебное заведение «Херсонский государственный аграрный университет»
Адрес организации: ул. Р. Люксембург, 23, г. Херсон, Украина, 73006
E-mail: lso2@yandex.ru

Lavrenko Sergiy Olegovich
Degree: Candidate of agricultural sciences (PhD of agricultural sciences)
Title: Associate professor
Position: Associate professor department of Agriculture, Scientific Secretary of the University
Affiliation: Kherson State Agricultural University
Affiliation address: str. R. Luxemburg, 23, Kherson, Ukraine, 73006
E-mail: lso2@yandex.ru

Лавренко Наталия Николаевна
Должность: аспирант кафедры земледелия
Место работы: Государственное высшее учебное заведение «Херсонский государственный аграрный университет»
Адрес организации: ул. Р. Люксембург, 23, г. Херсон, Украина, 73006
E-mail: lso2@yandex.ru

Lavrenko Natalia Nikolayevna
Position: Postgraduate student department of agriculture
Affiliation: Kherson State Agricultural University
Affiliation address: str. R. Luxemburg, 23, Kherson, Ukraine, 73006
E-mail: lso2@yandex.ru

Пичура Виталий Иванович
Ученая степень: кандидат сельскохозяйственных наук
Ученое звание: доцент
Должность: доцент кафедры геоинформационных систем и технологий
Место работы: Государственное высшее учебное заведение «Херсонский государственный аграрный университет»
Адрес организации: ул. Р. Люксембург, 23, г. Херсон, Украина, 73006
E-mail: pichura@yandex.ru

Pivhura Vitalii Ivanovich
Degree: Candidate of agricultural sciences (PhD of agricultural sciences)
Title: Associate professor
Position: Associate professor Chair of Geographic Information Systems and Technology
Affiliation: Kherson State Agricultural University
Affiliation address: str. R. Luxemburg, 23, Kherson, Ukraine, 73006
E-mail: pichura@yandex.ru