

Использование нейросетевых технологий в прогнозировании эффективности производства зерна

Н.Д. Заводчиков, д.э.н., профессор, Н.В. Спешилова, д.э.н., профессор, С.С. Таспаев, к.э.н., ФГБОУ ВПО Оренбургский ГАУ

В настоящее время, в условиях вступления РФ во Всемирную торговую организацию и выдвигаемых Евросоюзом санкций, высокой изменчивости рынков сельскохозяйственной продукции, особую актуальность приобретают вопросы обеспечения продовольственной безопасности регионов России. Прогнозирование результатов деятельности предприятия и его ключевых показателей развития позволяют разрабатывать чётко продуманную программу функционирования хозяйства, в том числе в аграрном секторе производства. При прогнозировании особую роль играет выбор метода, способного обеспечить достоверность и точность прогноза при снижении затрат времени и средств на его разработку [1].

Огромное значение в системе экономической безопасности региона имеет сектор производства зерна. Получение проектного уровня урожайности зерновых культур в условиях рискованного земледелия, характеризующееся высоким значением коэффициента вариации (свыше 30%) для основных зерновых культур, ограничивает применение факторных моделей и требует использования методов нелинейной динамики для повышения адекватности получаемых моделей [2].

В имитационном моделировании, позволяющем проигрывать различные сценарии конъюнктуры рынка и финансово-экономического состояния предприятия, прогнозирование является первичным элементом в процессе принятия управленческих решений. При этом в различных отраслях народного хозяйства, для решения самых разнообразных производственных задач активно используются нейронные сети, позволяя максимально снижать трудозатраты и повышать качество процесса принятия решений.

В качестве инструментария реализации нейронных технологий нами был выбран программный продукт Deductor Studio Academic, который характеризуется следующими возможностями:

1) создание в сжатые сроки эффективной системы поддержки принятия бизнес-решений на основе аналитической платформы;

2) формирование единой аналитической надстройки над всеми существующими в компании системами сбора и хранения данных (торговые системы, бухгалтерские системы, отдельные базы и т.д.) благодаря мощным механизмам импорта. Уникальность данного решения состоит в том, что Deductor при необходимости автоматически объединит данные из разрозненных источников;

3) прохождение (на базе единой архитектуры) всех этапов построения аналитической системы – от создания хранилища данных до автоматического подбора моделей и визуализации полученных результатов.

Кроме того, Deductor предоставляет инструментальные средства, необходимые для решения самых разных аналитических задач:

– анализ тенденций и закономерностей, планирование, ранжирование. Простота использования и интуитивно понятная модель данных позволяет проводить анализ по принципу «что если», соотносить гипотезы со сведениями, хранящимися в базе данных, находить аномальные значения, оценивать последствия принятия бизнес-решений;

– прогнозирование. Построив модель на исторических примерах, можно использовать её для прогнозирования ситуации в будущем. По мере изменения ситуации нет необходимости перестраивать всё, необходимо всего лишь дообучить модель;

– управление рисками. Реализованные в системе алгоритмы позволяют достаточно точно определиться с тем, какие характеристики объектов как влияют на риски, благодаря чему можно про-

гнозировать наступление рискованного события и заблаговременно принимать необходимые меры к снижению размера возможных неблагоприятных последствий.

Таким образом, Deductor оптимизирован для решения аналитических задач и включает в себя полный набор механизмов, необходимых для решения поставленной задачи: получение информации из большого количества источников данных; полный спектр механизмов очистки и трансформации данных; мощные самообучающиеся алгоритмы построения моделей и обнаружения зависимостей; большой набор механизмов визуализации и экспорт результатов в различные форматы [3]. Это то, что обеспечивает создание эффективных прикладных решений в минимальные сроки. Инновационный подход к принятию управленческих решений в сфере аграрного производства в настоящее время весьма актуален. Представим методику использования нейронных сетей для прогнозирования развития зернового сектора сельскохозяйственного предприятия на примере ООО «СХП «Салис» Абдулинского района Оренбургской области как типичного представителя, специализирующегося на выращивании зерновых культур.

Алгоритм использования нейронных сетей для прогнозирования развития зернового сектора сельскохозяйственного предприятия включал несколько этапов:

- 1) сбор и анализ исходных данных;
- 2) подготовка данных для обработки в программе Deductor Studio Academic;
- 3) выбор алгоритма и задание параметров обучения нейронной сети;
- 4) получение графа нейросети и модели прогноза средней урожайности зерновых культур;
- 5) использование модели для расчёта прогнозных значений средней урожайности зерновых культур.

В конкретных условиях, в зависимости от характера задачи, последовательность этапов моделирования экономических процессов может изменяться [3].

На I этапе сбора и анализа исходных данных был определён перечень факторов, предположи-

тельно влияющих на изменение уровня средней урожайности зерновых культур, и с помощью корреляционного анализа отобраны наиболее существенные из них.

В нашем случае первоначальная выборка включала в себя 13 показателей: 1) количество осадков за год, мм; 2) средняя урожайность зерновых культур, ц/га; 3) средняя температура за вегетационный период, °С; 4) норма внесения минеральных удобрений, кг д. в./га; 5) норма внесения органических удобрений, т/га; 6) содержание гумуса в почве, %; 7) посевная площадь, га; 8) количество осадков за вегетативный период, мм; 9) норма высева семян, млн шт./га; 10) норма применения гербицидов, л/га; 11) норма применения пестицидов, кг/га; 12) продолжительность посева семян, дн.; 13) продолжительность уборки урожая, дн. После построения корреляционной матрицы по значениям парного линейного коэффициента корреляции было отобрано 9 показателей, имеющих наибольшее влияние на уровень средней урожайности зерновых культур, которые представлены в таблице 1, а в общем виде математическая модель зависимости среднего уровня урожайности зерновых культур от девяти выбранных нами факторов будет иметь вид, представленный в формулах 1.1, 1.2, так как нейрон в целом реализует скалярную функцию векторного аргумента.

$$S = \sum_{i=1}^9 w_i \cdot x_i + b, \tag{1.1}$$

$$y = f(s) \tag{1.2}$$

- где w_i – вес (weight) синапса, $i = 1-9$;
 b – значение смещения (bias);
 s – результат суммирования (sum);
 x_i – показатель (входной сигнал), $x_i = 1-9$;
 y – средняя урожайность зерновых культур (выходной сигнал);
 n – число показателей;
 f – нелинейное преобразование (функция активации).

II этап – это подготовка данных для обработки в программе Deductor Studio Academic. Для этого, воспользовавшись данными таблицы 1, формиру-

1. Значения факторов, влияющих на урожайность зерновых культур, в ООО «СХП «Салис», 2009–2013 гг.

Фактор	Обозначение переменных	Год				
		2009	2010	2011	2012	2013
Урожайность, ц/га	y	7,9	7,6	8,1	8,3	24,7
Посевная площадь, га	x_1	7953	10613	6974	6974	5919
Внесение минеральных удобрений, кг д. в/га	x_2	25	20	15	12	10
Внесение органических удобрений, т/га	x_3	20,0	21,0	18,0	17,0	20,0
Содержание гумуса в почве, %	x_4	9,6	9,3	8,4	7,7	7,0
Количество осадков, мм	x_5	261	274	286	292	301
Количество осадков за вегетативный период, мм	x_6	96	105	109	112	125
Норма высева семян, млн шт./га	x_7	7,0	6,5	6,0	5,5	5,0
Применение гербицидов, л/га	x_8	1,0	1,0	0,9	0,9	0,8
Применение пестицидов, кг/га	x_9	1,0	0,6	0,6	0,6	0,5

ется файл, блокнот для импорта в программу и на III этапе осуществляется выбор алгоритма и задание параметров обучения нейронной сети. На рисунке 1 показано окно программы, в котором производят настройку процесса обучения нейронной сети.

В нашем случае был выбран алгоритм обучения нейронной сети – обратное распространение ошибки. Получение графа нейросети и модели прогноза средней урожайности зерновых культур осуществляется на IV этапе. После завершения обработки

программой введённых показателей был получен вид нейронной сети, изображённой на рисунке 2.

С помощью данной программы мы можем изменять значения факторов и получать более достоверные прогнозные значения средней урожайности зерновых культур. Так как в процессе интенсификации аграрного производства первостепенное внимание должно быть уделено дифференцированному (с учётом почвенно-климатических и погодных условий, а также адаптивных особенностей куль-

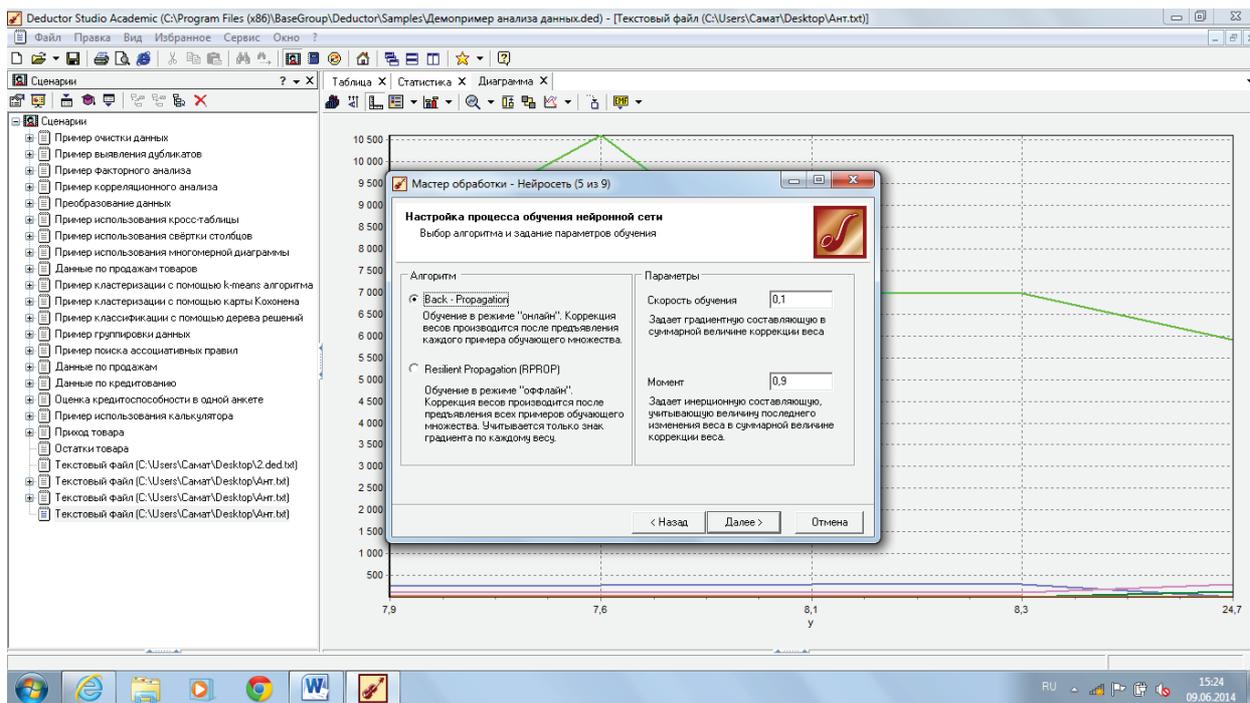


Рис. 1 – Выбор алгоритма и параметров обучения нейронной сети

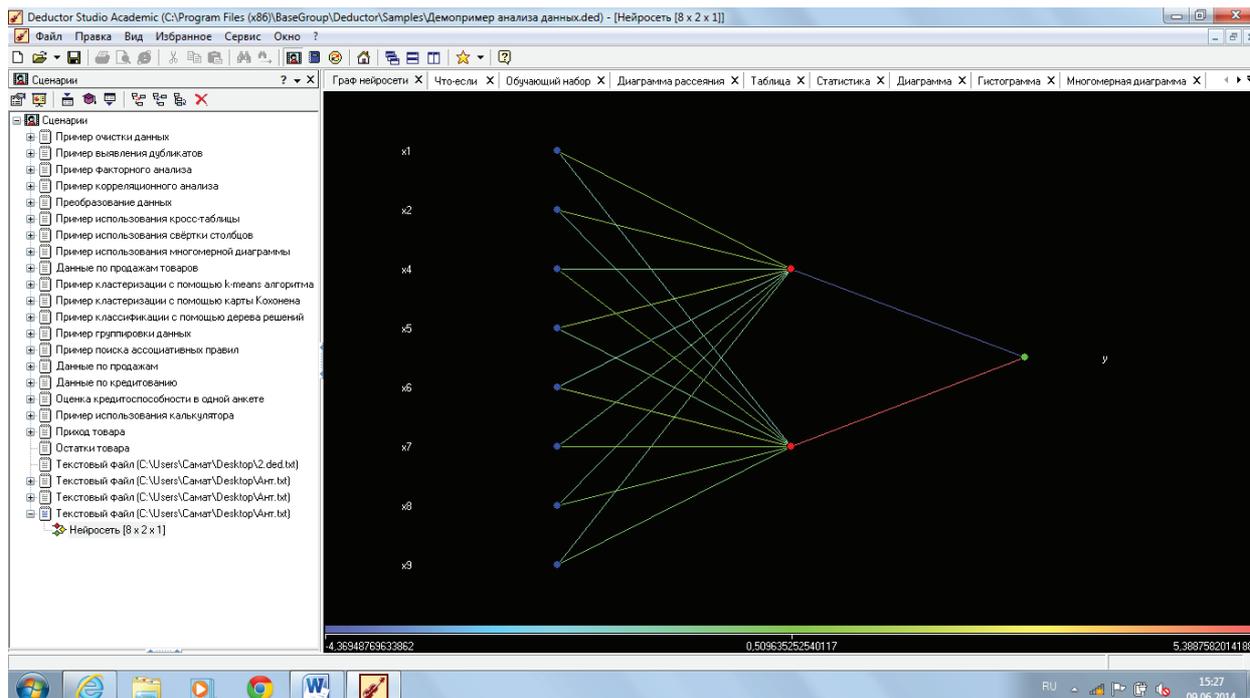


Рис. 2 – Граф нейронной сети для прогнозирования уровня средней урожайности зерновых культур

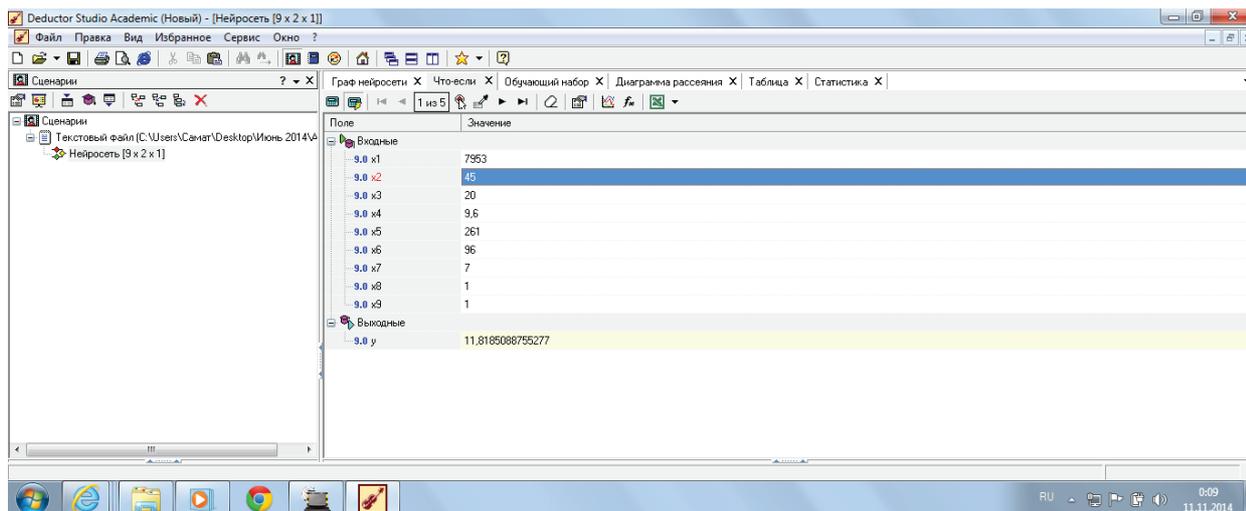


Рис. 3 – Прогноз средней урожайности зерновых культур при норме применения пестицидов 1,5 кг/га и норме внесения минеральных удобрений 45 кг д. в/га

2. Прогнозный экономический результат от дополнительной реализации зерна в ООО «СХП «Салис» в 2014 г.

Показатель	Дополнительная прибыль в планируемый период, результат
Посевная площадь под зерновыми культурами, га	7593
Прибавка урожайности с 1 га, ц	3,9
Дополнительный валовой сбор зерна всего, ц	29612,7
Средняя цена реализации зерна, 1 ц, руб.	850
Средняя себестоимость 1 ц зерна, руб.	759,2
Выручка от реализации дополнительного валового сбора зерна всего, руб.	25170795
Себестоимость дополнительного валового сбора зерна всего, руб.	22481961,8
Прибыль от реализации дополнительного валового сбора зерна всего, руб.	2688833,16
Рентабельность реализации дополнительного валового сбора зерновых, %	11,96

тивлируемых видов и сортов растений) применению техногенных факторов (сельскохозяйственных машин, удобрений, пестицидов, орошения и т.д.) [4], то в рамках полученной модели норму внесения минеральных удобрений с 25 до 45 кг д. в/га и получим прогноз средней урожайности зерновых культур (рис. 3).

При изменении нормы внесения минеральных удобрений с 25 до 45 кг д. в/га с учётом совместного действия остальных восьми факторов прогнозная средняя урожайность зерновых культур окажется на уровне 11,8 ц/га. Таким образом, в результате совместного действия всех факторов при неблагоприятных условиях средняя урожайность зерновых составит 7,9 ц/га, сохранение значений факторов при изменении нормы внесения минеральных удобрений с 25 до 45 кг д. в/га на 1 га в нашей модели показали прогнозный рост урожайности до 11,8 ц/га и увеличение валового сбора зерна на 29612,7 ц.

Существенные различия между фактической средней урожайностью зерновых и прогнозной обусловили необходимость расчёта дополнительного экономического эффекта. В таблице 2 отражены расчёты по определению экономического эффекта от дополнительной реализации зерна в ООО «СХП «Салис» в 2014 г.

Таким образом, дополнительная прибыль в планируемом периоде составит 2688833,16 руб., а уровень рентабельности реализации дополнительных объёмов зерна 11,96%.

Таким образом, использование вычислительных инструментов нейронных сетей позволяет решать задачи оптимизации производства зерна. В дальнейшем возможно расширение ряда входных факторов, увеличение временного интервала наблюдаемых значений факторных признаков, выбор дополнительных результативных показателей, значение которых целесообразно прогнозировать в рамках оптимизационных моделей с применением технологии нейронных сетей.

Литература

1. Дегтярёва Т.Д., Таспаев С.С. Планирование на предприятиях АПК: учебно-практическое пособие / под ред. проф. Т.Д. Дегтярёвой. Оренбург: Издательский центр ОГАУ, 2011. 170 с.
2. Рогачев А.Ф., Шубнов М.Г. Построение нейросетевых моделей прогнозирования временных рядов урожайности на основе автокорреляционных функций // Современные проблемы науки и образования. 2013. № 5. С. 18–25.
3. Спешилова Н.В., Шеврина Е.В., Коробейникова О.А. Экономико-математические модели и их практическое применение в АПК: учеб. пособие. 4-е изд., перераб. и доп. Оренбург: Издательский центр ОГАУ, 2012. 132 с.
4. Заводчиков Н.Д., Воронкова Е.А. Управление эффективностью использования энергоресурсов в растениеводстве. Оренбург: Издательский центр ОГАУ, 2012. 172 с.