

ПРОГНОЗИРОВАНИЕ УРОЖАЙНОСТИ КАРТОФЕЛЯ В РЕСПУБЛИКЕ БЕЛАРУСЬ НА ОСНОВЕ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ

А. А. МОЗОЛЬ, магистр экономических наук, ассистент
УО «Белорусский государственный экономический университет»

FORECASTING POTATO PRODUCTIVITY IN THE REPUBLIC OF BELARUS ON THE BASIS OF NEURAL NETWORK MODELING

A. A. MOZOL, Master of economic sciences, Assistant
Belarusian State Economic University

В статье рассмотрены актуальные вопросы прогнозирования производства агропромышленной продукции. Проведен анализ временного ряда урожайности картофеля в Республике Беларусь. Рассчитаны прогнозные значения уровня урожайности картофеля в зависимости от погодноклиматических условий на 2022–2030 годы с использованием нейросетевого моделирования. Полученные результаты позволят повысить эффективность распределения ресурсов и результативность агропромышленного производства.

Ключевые слова: нейросетевые модели, прогнозирование, агропромышленный комплекс, погодноклиматические условия, урожайность, риск.

The article deals with topical issues of forecasting the production of agro-industrial products. An analysis of the time series of potato yields in the Republic of Belarus was carried out. The predicted values of the potato yield level depending on the weather and climate conditions for 2022–2030 were calculated using neural network modeling. The results obtained will improve the efficiency of resource allocation and the effectiveness of agro-industrial production.

Key words: neural network models, forecasting, agro-industrial complex, weather and climate conditions, productivity, risk.

Введение. На современном этапе развития экономики, характеризующемся рыночной нестабильностью, возрастанием дефицита сырьевых ресурсов, жесткой конкуренцией между предприятиями, увеличением предпринимательских рисков, эффективность функционирования хозяйствующих субъектов обеспечивается за счет опережающего ро-

ста результатов деятельности над затратами привлеченных производственных ресурсов. Нынешний этап эволюции хозяйственных систем требует повышения эффективности всех направлений деятельности АПК путем минимизации рисков, освоения новых технологий, поиска резервов снижения затрат и обеспечения качества продукции.

Анализ источников. Исследованию вопросов прогнозирования производства агропромышленной продукции посвятили свои работы белорусские и зарубежные учёные, такие как: Н. И. Холод, И. И. Ленков, Г. О. Читая, М. М. Ковалёв, В. Н. Шимов, Е. А. Червякова, С. Ф. Миксюк, А. А. Быков, М. В. Горелова, Е. А. Семин, Л. А. Шишкина, А. В. Олейник, Р. Стоун, Х. Мэйнке, И. Б. Загайтов, Э. Н. Кузьбожев, И. Б. Молчанов, В. М. Пасов, А. В. Мозоль и др. Однако перманентная изменчивость условий деятельности агропромышленных предприятий, стремительно развивающийся инструментарий системного анализа и менеджмента требует постоянного совершенствования методов, подходов и способов адекватного реагирования на происходящие изменения.

Методы источников. Системный подход, сингулярный спектральный анализ, метод главных компонент, нейросетевое моделирование, вероятностно-статистические методы оценки рисков и имитационного моделирования.

Основная часть. Беларусь один из основных производителей картофеля в мире. Занимает первое место по его производству на душу населения (625 кг). Выращиванием картофеля занимаются практически все сельскохозяйственные организации. Картофельное поле республики в 2020 г. составило 254 тыс. га [1]. Около 80 % от общего объема выращиваемого в стране картофеля производится в личных подсобных хозяйствах [2].

Проблема прогнозирования агроэкономических показателей многие годы остаётся неизменно актуальной, так же, как и подбор экономико-математических моделей для построения и обоснования полученных результатов прогнозов. Не менее важным аспектом выступает точность расчётов использованных методов, которая не всегда находится в допустимых пределах. Это обуславливает тот факт, что традиционные подходы к математическому моделированию при прогнозировании агропоказателей не отражают реальной ситуации в будущем.

Нейронные сети давно стали популярным инструментом аналитиков и аппарата управления. Их преимуществами выступают, несомненно, точность проводимых расчётов и построения прогнозов. Однако присутствует и обратная сторона применения нейросетевого ана-

лиза: для получения адекватных результатов необходимо проводить углубленный поиск исходных данных для исследования характеров зависимостей, представляющих собой внушительные по длине временные ряды. Также не менее важную роль играет выбор метода, способного обеспечить достоверность и точность прогноза при снижении затрат времени и средств на его разработку.

Эффективное управление воспроизводством в сельском хозяйстве требует обязательного знания законов и закономерностей его развития. Причем чрезвычайно важное значение имеет изучение не только тенденций и направлений развития отрасли, но и механизмов, под влиянием которых эти тенденции реализуются.

При исследовании цикличности сельскохозяйственного производства одним из ключевых методологических вопросов является обоснование общих подходов к определению параметров циклов. Его решение в значительной мере связано с выбором математического инструментария для исследования этого процесса, а именно с обоснованием типа кривой, которая бы наиболее точно отображала тенденцию изменения экономического явления во времени. Таким образом, предлагается использовать нейросетевые модели для прогнозирования временных рядов урожайностей сельскохозяйственных культур на примере картофеля. Для работы с нейронными сетями требуется достаточно длинный временной ряд для успешного обучения нейронной сети. Был произведён углубленный поиск информации и данных для проведения настоящего исследования.

По данным об урожайности картофеля в Республике Беларусь [1], достаточно сложно определить динамику и цикличность развития описываемого явления. Для более наглядного представления о процессах формирования урожайности картофеля была произведена его визуализация. С этой целью была построена гистограмма временного ряда урожайности картофеля по Республике Беларусь за период с 1940 по 2021 г.




Рис. 1. Гистограмма временного ряда урожайности картофеля по Республике Беларусь

Примечание. Источник: собственная разработка.

Если проанализировать ряд урожайности картофеля (рис. 1), можно заметить, что некоторые значения значительно отличаются. Таким образом, для дальнейшей работы с хаотическим рядом произведём его сглаживание методом сингулярного спектрального анализа (ССА). Это позволит избавиться от возмущений, аномальных значений, а также снизить ошибку прогноза [3]. Данный метод основан на теореме Такенса и предполагает переход от одномерного представления исходного ряда $x_t = x_1, x_2 \dots x_N$ к многомерному:

$$X_{\tau \times (N-\tau+1)} = \left(\begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_\tau \end{bmatrix} \begin{bmatrix} x_2 \\ x_3 \\ \vdots \\ x_{\tau+1} \end{bmatrix} \dots \begin{bmatrix} x_{N-\tau+1} \\ x_{N-\tau+2} \\ \vdots \\ x_N \end{bmatrix} \right), \quad (1)$$

где N – число элементов исходного ряда;

τ – оптимальная размерность [4].

Для метода ССА следующим шагом будет обработка матрицы X с использованием методов факторного анализа, в частности, метода главных компонент. Целью его применения является снижение размерности имеющегося пространства запаздываний и переход к новым,

информативно более обоснованным переменным – главными компонентами. Отличительной особенностью применения метода главных в реализации схемы ССА является то, что он позволяет одновременно обработать всю матрицу X .

Для перехода к главным компонентам по данным, представленным в виде матрицы X , строится корреляционная матрица, которая затем раскладывается на собственные значения и собственные векторы матрицы C :

$$C = \frac{1}{N} X * X' = V * \Lambda * V'. \quad (2)$$

где Λ – диагональная матрица собственных значений;

$V = (V^1, V^2, \dots, V^\tau)$ – ортогональная матрица, составленная из нормированных собственных векторов [4].

В конечном счете получим матрицу главных компонент:

$$Y = V' * X = (Y_1, Y_2, \dots, Y_\tau). \quad (3)$$

Собственные значения $\lambda_1, \lambda_2, \dots, \lambda_\tau$ можно рассматривать как вклад главных компонент $Y_1, Y_2, \dots, Y_\tau$ в общее информационное содержание исходного временного ряда. По полученным главным компонентам можно полностью восстановить исходную матрицу:

$$X = \sum_{i=1}^{\tau} V^i Y_i, \quad (4)$$

По матрице X , в свою очередь, появляется возможность восстановить исходный временной ряд $(x_i)_{i=1}^N$.

Предположим, что из τ компонент для дальнейшего анализа оставлены лишь первые r . Тогда для восстановления исходной матрицы X можно использовать первые r собственных векторов V^i . В таком случае:

$$\tilde{X} = (V^1, V^2, \dots, V^r) \begin{pmatrix} Y_1 \\ Y_2 \\ \dots \\ Y_r \end{pmatrix} = \sum_{i=1}^r V^i Y_i, \quad (5)$$

где $\tilde{X}$ — восстановленная матрица, имеющая r столбцов и τ строк.

Теперь исходный временной ряд, воссозданный из этой матрицы, определится как: $\tilde{x}_{i+s-r, r-i+1}$. Последовательная процедура получения $(\tilde{x}_i)_{i=1}^N$ называется ССА-сглаживанием исходного временного ряда $(x_i)_{i=1}^N$ по первым r компонентам [5].

Сглаженный ряд методом ССА представлен на рис. 2: сплошной линией обозначен исходный ряд, а пунктирной – сглаженный.




Рис. 2. Исходный и сглаженный временной ряд урожайности картофеля в Республике Беларусь, ц/гектаров

Примечание. Источник: собственная разработка.

Таким образом, применение метода сингулярного спектрального анализа в данном случае поможет преодолеть несколько проблем. Во-первых, метод поможет избавиться от неких выбросов, т.к. происходит сглаживание временного ряда урожайностей. Во-вторых, учитывая тот факт, что в исследовании рассматриваются ряды урожайностей, длина их не столь велика, как рекомендовано для нейронных сетей, сглаженный ряд позволит сети быстрее обучиться, уделяя меньше внимания выбросам.

Основными параметрами погодных условий, влияющими на формирование урожаев сельскохозяйственных культур, являются количество осадков за отдельные периоды вегетационного периода и температурный режим [6]. Эти факторы имеют как самостоятельное, так и общее влияние на урожайность, что целесообразно измерять также ве-

личиной гидротермического коэффициента. Именно погодноклиматические условия оказывают наибольшее влияние на производственную эффективность, поэтому для дальнейшего моделирования воспользуемся временными рядами погодных колебаний в качестве исходных данных для построения нейронных сетей [7].

Алгоритм обучения гетерогенной нейронной сети [8] реализован в программе STATISTICA Neural Networks в последовательности (6)–(11) до тех пор, пока функция ошибки не стала несущественной и получены нейронные сети для прогнозирования урожайности картофеля на 2022–2030 годы (рис. 3):

$$y = \sum_{i=1}^m v_i y_i - b, \quad (6)$$

$$y_i = F(S_i) = F(\sum_{l=1}^n \omega_{li} x_l - b_i), \quad (7)$$

$$\delta_i = (y - d) v_i, \quad (8)$$

$$v_i(t + 1) = v_i(t) - \eta(y - d) y_i, \quad (9)$$

$$\omega_{li}(t + 1) = \omega_{li}(t) - \eta \delta_i \frac{dy_i}{ds_i} x_l, \quad (10)$$

$$\delta(v) = (y - d), \quad (11)$$

где n – количество входов нейронной сети;
 m – количество скрытых слоёв нейросети;
 v_i – i -й весовой коэффициент выходного нейрона;
 y – выходное значение нейронной сети;
 y_i – выходные значения нейронных элементов i -го скрытого слоя, $i = \overline{1, m}$;
 b – скрытое смещение;
 x_l – значение l -го входа нейрона, $l = \overline{1, n}$;
 ω_{li} – коэффициент синаптической связи между l -м нейроном распределительного слоя и i -м нейроном обрабатывающего слоя синапса;
 δ_i – нейронных элементов скрытого слоя;
 d – целевое значение выхода нейронной сети;
 t – параметр времени;
 η – коэффициент скорости обучения;
 $\delta(v)$ – функция ошибки.

В описанном алгоритме для построения нейросетевой модели для ряда урожайности картофеля $n=5$, а входы означают следующее: x_1 – сумма осадков за третью декаду августа и первую декаду сентября; x_2 – сумма осадков за вторую декаду июня; x_3 – среднедекадная температура воздуха за третью декаду июня; x_4 – среднедекадная температура воздуха за первую декаду сентября; x_5 – гидротермический коэффициент. В качестве выходного параметра для каждой из моделей выступает d – урожайность картофеля [9].

Результаты построения нейронных сетей представлены на рис. 3. Для картофеля наилучшей сетью стала MLP 5-6-1





Рис. 3. Графическая интерпретация исходного и обученных рядов урожайностей картофеля

Примечание. Источник: собственная разработка.

Средняя ошибка аппроксимации для модели составила 3,514 %. Содержание Модели нейронной сети отражено на рис. 4. Представим прогнозные значения уровня урожайности картофеля, а также интервальный прогноз (с вероятностью 95 % прогнозное значение величины урожайности будет находиться в интервале устойчивости) в таблице.



Соединения MLP 5-6-1	Значения весов MLP 5-6-1
Осадки (X1)-1 → скрытый нейрон 1	0,54597
Осадки (X1)-1 → скрытый нейрон 2	3,97073
Осадки (X1)-1 → скрытый нейрон 3	4,47871
Осадки (X1)-1 → скрытый нейрон 4	1,65174
Осадки (X1)-1 → скрытый нейрон 5	-5,60936
Осадки (X1)-1 → скрытый нейрон 6	-0,19298
Осадки (X2)-1 → скрытый нейрон 1	-0,72777
Осадки (X2)-1 → скрытый нейрон 2	0,03213
Осадки (X2)-1 → скрытый нейрон 3	-0,94647
Осадки (X2)-1 → скрытый нейрон 4	-0,17799
Осадки (X2)-1 → скрытый нейрон 5	0,44614
Осадки (X2)-1 → скрытый нейрон 6	-2,45290
Температура (X3)-1 → скрытый нейрон 1	-3,29088
Температура (X3)-1 → скрытый нейрон 2	-3,88558
Температура (X3)-1 → скрытый нейрон 3	-1,64953
Температура (X3)-1 → скрытый нейрон 4	-0,02039
Температура (X3)-1 → скрытый нейрон 5	-1,09912
Температура (X3)-1 → скрытый нейрон 6	-0,96336
Температура (X4)-1 → скрытый нейрон 1	-1,18946
Температура (X4)-1 → скрытый нейрон 2	0,00982
Температура (X4)-1 → скрытый нейрон 3	-0,66701
Температура (X4)-1 → скрытый нейрон 4	0,25075
Температура (X4)-1 → скрытый нейрон 5	1,68505
Температура (X4)-1 → скрытый нейрон 6	-0,66974
ГТК (X5)-1 → скрытый нейрон 1	-1,89990
ГТК (X5)-1 → скрытый нейрон 2	-1,05012
ГТК (X5)-1 → скрытый нейрон 3	-1,12534
ГТК (X5)-1 → скрытый нейрон 4	1,44436
ГТК (X5)-1 → скрытый нейрон 5	-1,67792
ГТК (X5)-1 → скрытый нейрон 6	-0,75322
входное смещение → скрытый нейрон 1	-0,46676
входное смещение → скрытый нейрон 2	0,03681
входное смещение → скрытый нейрон 3	0,03980
входное смещение → скрытый нейрон 4	-0,07447
входное смещение → скрытый нейрон 5	-0,63620
входное смещение → скрытый нейрон 6	-1,24766
скрытый нейрон 1 → Картофель	0,07356
скрытый нейрон 2 → Картофель	-0,52353
скрытый нейрон 3 → Картофель	2,96189
скрытый нейрон 4 → Картофель	0,27539
скрытый нейрон 5 → Картофель	-1,83921
скрытый нейрон 6 → Картофель	-1,49802
скрытое смещение → Картофель	0,23401

Функция активации скрытых нейронов

Экспоненциальная

$$f(a, x) = \begin{cases} \alpha(e^x - 1), & x < 0 \\ x, & x \geq 0 \end{cases}$$

Функция активации выходных нейронов

Логистическая

$$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$$

Рис. 4. Содержание модели нейронной сети MLP 5-6-1 для прогнозирования уровня средней урожайности картофеля
Примечание. Источник: собственная разработка.

**Прогнозные значения уровня урожайности картофеля
в Республике Беларусь на 2022–2030 гг., ц/гектаров**

Годы	Нижняя граница прогноза	Точечный прогноз	Верхняя граница прогноза
2022	219,1	222,9	226,9
2023	223,2	227,2	231,2
2024	231,7	235,8	240,0
2025	214,4	218,2	222,1
2026	223,9	227,8	231,9
2027	226,2	230,2	234,3
2028	205,8	209,4	213,2
2029	225,0	229,2	233,0
2030	238,8	243,1	247,4

Примечание. Источник: собственная разработка.

Имея данные об уровнях урожайности картофеля, становится возможным управлять рисковыми ситуациями, возникающими в процессе производства. Опираясь на прогнозные показатели, можно предотвратить дефицит или же наоборот профицит запасов культур. Также имея данные об уровне урожайности в зависимости от погодно-климатических условий, становится возможным снижение затрат на содержание и обработку сельскохозяйственных культур. Например, если ожидается высокая урожайность картофеля в предстоящем году, то не стоит вносить дополнительные удобрения, организовывать дополнительный полив почвы, задействуя при этом человеческий труд, который в свою очередь повлечёт за собой увеличение себестоимости культуры, как готовой продукции. Данный факт будет сопровождаться снижением конкурентоспособности картофеля на рынке, что приведёт к потерям прибыли.

Подводя итог, стоит отметить, что нейронные сети проявляют отличные характеристики при моделировании и прогнозировании с минимальными отклонениями и ошибками. Соответственно представляется небезынтересным их использование в агропромышленном комплексе Республики Беларусь для прогнозирования показателей и принятия управленческих решений в области предотвращения риска и обеспечения устойчивого развития производства.

Заключение. Предлагаемые методики и инструменты управления, основанные на новейших достижениях кибернетики и менеджмента, в условиях турбулентной неопределённости позволят повысить достоверность среднесрочных прогнозов продуктивности и результативности агропромышленного производства, что обеспечит более точные

параметры планирования и ресурсного обеспечения в АПК. Результатом этого будет повышение экономической и социально-экономической эффективности аграрного производства в условиях управления неблагоприятными факторами.

Список литературы

1. Статистический сборник сельское хозяйство Республики Беларусь 2021 / Национальный статистический комитет Республики Беларусь. – Минск, 2021. – 178 с.
2. Национальный статистический комитет Республики Беларусь – Режим доступа: <http://www.belstat.gov.by/> – Дата доступа: 01.05.2022г.
3. Мозоль, А. А. Методика среднесрочного прогнозирования агропромышленного производства Республики Беларусь в условиях неустойчивой экономической конъюнктуры / А. А. Мозоль // Вестн. Белорус. гос. экон. ун-т. – 2021. – № 5. – С. 58–66.
4. Читая, Г. О. Математические модели анализа и прогнозирования динамики финансовых активов / Г. О. Читая, А. Е. Тарасюк // Белорус. экон. журн. – 2016. – № 4. – С. 132–141.
5. Лоскутов, А. Ю. Анализ временных рядов [Электронный ресурс] : курс лекций / А. Ю. Лоскутов. – [М. : Физ. фак. МГУ, 2010]. – Режим доступа: http://chaos.phys.msu.ru/loskutov/PDF/Lectures_time_series_analysis.pdf. – Дата доступа: 01.04.2020.
6. Олейник, А. В. Цикличность сельскохозяйственного производства / А. В. Олейник // Белорус. экон. журн. – 2004. – № 1. – С. 39–48.
7. Белгидромет [Электронный ресурс]. – Режим доступа: <https://belgidromet.by/ru/>. – Дата доступа: 01.04.2020.
8. Нейросетевые технологии обработки данных : учеб. пособие / В. А. Головкин, В. В. Краснопрошин.
9. Мозоль, А. А. Оценка влияния погодно-климатических факторов при прогнозировании урожайности / А. В. Мозоль, А. А. Мозоль // Науч. тр. : [юбил. сб.] / Белорус. гос. экон. ун-т. – Минск, 2018. – Вып. 11. – С. 288–296.

Информация об авторе

Мозоль Алеся Александровна – магистр экономических наук, ассистент кафедры математических методов в экономике УО «Белорусский государственный экономический университет». Информация для контактов: тел. моб. +375 33 327-18-49; e-mail: a.mozol@aol.com.

Материал поступил в редакцию 24.05.2022 г.