

4. Маркусенко, М. В. Влияние валютной политики на сбалансированное экономическое развитие: проблемы и их решение в Республике Беларусь / М. В. Маркусенко // Белорус. экон. журн. — 2014. — № 3 (68).

Markusenko, M. V. Vliyanie valyutnoy politiki na sbalansirovannoe ekonomicheskoe razvitiye: problemy i ikh reshenie v Respublike Belarus' / M. V. Markusenko // Belorus. ekon. zhurn. — 2014. — № 3 (68).

5. Маркусенко, М. В. Влияние инструментов валютной политики на инвестиционную деятельность белорусских товаропроизводителей / М. В. Маркусенко // Эффектив. антикризис. упр. — 2015. — № 6 (93). — С. 82–89.

Markusenko, M. V. Vliyanie instrumentov valyutnoy politiki na investitsionnuyu deyatel'nost' belorusskikh tovaroproizvoditeley / M. V. Markusenko // Effektiv. antikrizis. upr. — 2015. — № 6 (93). — S. 82–89.

6. Холопов А. В. Валютный курс как инструмент макроэкономического регулирования / А. В. Холопов // Мировая экономика и междунар. отношения. — 2004. — № 12. — С. 25–33.

Kholopov A. V. Valyutnyy kurs kak instrument makroekonomicheskogo regulirovaniya / A. V. Kholopov // Mirovaya ekonomika i mezhdunar. otnosheniya. — 2004. — № 12. — S. 25–33.

7. Xue, Y. The Compensation Thesis vs the Mundell-Fleming Model in a fixed Exchange Rate Regime [Electronic resource] / Y. Xue // uOttawa. — Mode of access: https://www.ruor.uottawa.ca/bitstream/10393/25224/1/2004_yan_xue.pdf. — Date of access: 22.10.2017.

8. Кононов, А. Ю. Эволюция валютной политики КНР : автореф. дис. ... канд. экон. наук : 08.00.14 / А. Ю. Кононов ; Дальневост. федер. ун-т. — Владивосток, 2017. — 28 с.

Kononov, A. Yu. Evolyutsiya valyutnoy politiki KNR : avtoref. dis. ... kand. ekon. nauk : 08.00.14 / A. Yu. Kononov ; Dal'nevost. feder. un-t. — Vladivostok, 2017. — 28 s.

9. Китай ужесточил правила вывоза иностранной валюты за рубеж [Электронный ресурс] // Immigrant.Today. — Режим доступа: <https://immigrant.today/article/11662-kitaj-uzhestochil-pravila-vyvoza-inostrannoj-valjuty-za-rubezh.htm>. — Дата доступа: 22.10.2017.

10. Prasad, E. The Renminbi's role in the global monetary system [Electronic resource] / E. Prasad // Brookings. — Mode of access: http://www.brookings.edu/~media/research/files/reports/2012/2/renminbi%20monetary%20system%20prasad/02_renminbi_monetary_system_prasad.pdf. — Date of access: 22.09.2017.

Статья поступила в редакцию 06.12.2017 г.

УДК 338.436.33

A. Mozol
A. Mozol
BSEU (Minsk)

IMPACT ASSESSMENT OF WEATHER AND CLIMATIC FACTORS AND FORECASTING CROP PRODUCTIVITY

Adequate response of agrarian management to the manifestations of risk factors in the business activities and tactical, as well as timely operational management of risk situations determines the effectiveness of the entire economic process. The search, justification and application of innovative methods and algorithms for assessing the manifestations of the level and magnitude of the effect of inefficiency factors is a priority task in the systems of assessing the processes of formation and use of the agrarian production potential in conditions of uncertainty and allows the development of strategic and tactical programs for managing the risks of agricultural production.

Keywords: neural network model; risk; sustainability; cyclicity; agroindustrial production; yield forecasting; climatic factors; hydrothermal coefficient; singular spectral analysis; multilayer perceptron.

ОЦЕНКА ВЛИЯНИЯ ПОГОДНО-КЛИМАТИЧЕСКИХ ФАКТОРОВ ПРИ ПРОГНОЗИРОВАНИИ УРОЖАЙНОСТИ

Адекватное реагирование менеджмента аграрных организаций на проявления рисков факторов при ведении производственно-хозяйственной деятельности субъекта хозяйствования и тактическое, а также своевременное оперативное управление рисковыми ситуациями определяет эффективность и результативность всего хозяйственного процесса. Поиск, обоснование и применение инновационных методов и алгоритмов систем оценки проявлений уровня и величины действия факторов неэффективности является приоритетной задачей в системах оценки процессов формирования и использования аграрного производственного потенциала в условиях неопределенности и позволяет разрабатывать стратегические и тактические программы управления рисками сельскохозяйственного производства.

Ключевые слова: нейросетевая модель; риск; устойчивость; цикличность; агропромышленное производство; прогнозирование урожайности; погодно-климатические факторы; гидротермический коэффициент; сингулярный спектральный анализ; многослойный персептрон.

Нейронные сети привлекательны с интуитивной точки зрения, так как они основаны на самой примитивной биологической модели нервных систем. В будущем развитие нейробиологических моделей должно привести человечество к созданию мыслящих компьютеров [1, 2]. В настоящее время простейшие нейронные сети, которые строит система ST Neural Networks, являются мощным оружием в арсенале специалиста по прикладной кибернетике, который решает экономические проблемы, в частности, в аграрном производстве [3, 4].

Несмотря на большое разнообразие вариантов нейронных сетей, все они имеют общие черты. Так, все они так же, как и мозг человека, состоят из большого числа связанных между собой однотипных элементов — *нейронов*, которые имитируют нейроны головного мозга [5–7].

Искусственный нейрон так же, как и живой, состоит из синапсов, связывающих входы нейрона с ядром; ядра нейрона, которое осуществляет обработку входных сигналов и аксона, который связывает нейрон с нейронами следующего слоя. Каждый синапс имеет вес, который определяет, насколько соответствующий вход нейрона влияет на его состояние. Состояние нейрона определяется по формуле

$$S = \sum_{i=1}^n x_i w_i, \quad (1)$$

где n — число входов нейрона; x_i — значение i -го входа нейрона; w_i — вес i -го синапса.

Затем определяется значение аксона нейрона по формуле:

$$Y = f(S), \quad (2)$$

где f — некоторая функция, которая называется *активационной*. Наиболее часто в качестве активационной функции используется так называемый *сигмоид*, который имеет следующий вид:

$$f(x) = \frac{1}{1 + e^{-ax}}. \quad (3)$$

Основное достоинство этой функции в том, что она дифференцируема на всей оси абсцисс и имеет очень простую производную:

$$f'(x) = af(x)(1 - f(x)). \quad (4)$$

При уменьшении параметра α сигмоид становится более пологим, вырождаясь в горизонтальную линию на уровне 0,5 при $\alpha = 0$. При увеличении α сигмоид все больше приближается к функции единичного скачка.

Нейронные сети обратного распространения — это мощнейший инструмент поиска закономерностей, прогнозирования, качественного анализа. Такое название — *сети обратного распространения (back propagation)* — они получили из-за используемого алгоритма обучения, в котором ошибка распространяется от выходного слоя к входному, т.е. в направлении, противоположном направлению распространения сигнала при нормальном функционировании сети [8].

Нейронная сеть обратного распространения состоит из нескольких слоев нейронов, причем каждый нейрон слоя i связан с каждым нейроном слоя $i + 1$, т.е. речь идет о *полносвязной* нейронной сети.

В общем случае задача обучения нейронной сети сводится к нахождению некоей функциональной зависимости $Y = F(X)$, где X — входной, а Y — выходной векторы. В общем случае такая задача, при ограниченном наборе входных данных, имеет бесконечное множество решений. Для ограничения пространства поиска при обучении ставится задача минимизации целевой функции ошибки нейронной сети, которая находится по методу наименьших квадратов:

$$E(w) = \frac{1}{2} \sum_{j=1}^p (y_j - d_j)^2, \quad (5)$$

где y_j — значение j -го выхода нейросети; d_j — целевое значение j -го выхода; p — число нейронов в выходном слое.

Обучение нейросети производится методом градиентного спуска, т.е. на каждой итерации изменение веса производится по формуле

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}}, \quad (6)$$

где η — параметр, определяющий скорость обучения.

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_i} \cdot \frac{dy_i}{dS_j} \cdot \frac{\partial S_j}{\partial w_{ij}}, \quad (7)$$

где y_j — значение выхода j -го нейрона; S_j — взвешенная сумма входных сигналов, определяемая по формуле (7).

При этом множитель

$$\frac{\partial S_j}{\partial w_{ij}} = x_i, \quad (8)$$

где x_i — значение i -го входа нейрона.

Далее рассмотрим определение первого множителя формулы (7)

$$\frac{\partial E}{\partial y_i} = \sum_k \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial S_k} \cdot w_{jk}^{(n+1)}, \quad (9)$$

где k — число нейронов в слое $n + 1$.

Введем вспомогательную переменную

$$\delta_j^{(n)} = \frac{\partial E}{\partial y_i} \cdot \frac{dy_i}{dS_j}. \quad (10)$$

Тогда мы сможем определить рекурсивную формулу для определения n -го слоя, если нам известно следующего $(n + 1)$ -го слоя

$$\delta_j^{(n)} = \left[\sum_k \delta_k^{(n+1)} \cdot w_{jk}^{(n+1)} \right] \frac{dy_i}{dS_j}. \quad (11)$$

Нахождение же для последнего слоя НС не представляет трудности, так как нам известен целевой вектор, т.е. вектор тех значений, которые должна выдавать НС при данном наборе входных значений [9]:

$$\delta_j^{(N)} = (y_i^{(N)} - d_i) \frac{dy_i}{dS_j}. \quad (12)$$

И наконец запишем формулу (7) в раскрытом виде

$$\Delta w_{ij}^{(n)} = -\eta \cdot \delta_j^{(n)} \cdot x_i^n. \quad (13)$$

Рассмотрим теперь полный алгоритм обучения нейросети.

1. Подать на вход нейронной сети один из требуемых образов и определить значения выходов нейронов нейросети.

2. Рассчитать для выходного слоя нейронной сети по формуле (12) и рассчитать изменения весов выходного слоя N по формуле (13).

3. Рассчитать по формулам (11) и (13) соответственно и $\Delta w_{ij}^{(N)}$ для остальных слоев нейронной сети, $n = N - 1 \dots 1$.

4. Скорректировать все веса нейронной сети:

$$\Delta w_{ij}^{(N)}(t) = \Delta w_{ij}^{(N)}(t - 1) + \Delta w_{ij}^{(N)}(t). \quad (14)$$

5. Если ошибка существенна, то перейти на шаг 1.

На этапе 2 сети поочередно в случайном порядке предъявляются вектора из обучающей последовательности.

Простейший метод градиентного спуска, рассмотренный выше, очень неэффективен в случае, когда производные по различным весам сильно отличаются. Это соответствует ситуации, когда значение функции S для некоторых нейронов близка по модулю к 1 или когда модуль некоторых весов много больше 1. В этом случае для плавного уменьшения ошибки надо выбирать очень маленькую скорость обучения, но при этом обучение может занять nepозволительно много времени [9].

Простейшим методом усовершенствования градиентного спуска является введение момента t , когда влияние градиента на изменение весов изменяется со временем. Тогда формула (13) примет вид

$$\Delta w_{ij}^{(n)} = -\eta \cdot \delta_j^{(n)} \cdot x_i^n + \mu \Delta w_{ij}^{(n)}(t - 1). \quad (15)$$

Дополнительным преимуществом от введения момента является способность алгоритма преодолевать мелкие локальные минимумы.

Решение этих уравнений реализовано в прикладном программном пакете Statistica Neural Networks. Именно его и будем использовать для дальнейшей работы с нейронными сетями.

Для дальнейшей работы с хаотическим рядом произведем его сглаживание методом сингулярного спектрального анализа. Это позволит избавиться от возмущений, аномальных значений, а также снизить ошибку прогноза. Сглаженный ряд представлен на рис. 1: сплошной линией обозначен исходный ряд, а пунктирной — сглаженный.




Рис. 1. Исходный и сглаженный временные ряды

Источник: разработано авторами.

Для начала работы в Statistica следует выбрать какого рода анализ нас интересует, а именно нейросетевой. В следующем окне выберем тип анализа — временные ряды (регрессия). Далее вводим эндогенные и экзогенные переменные. Строим нейронную сеть зависимости урожайности зерновых и зернобобовых культур от погодных условий в Республике Беларусь [10–16].

Следующим шагом становится определение процентной составляющей ряда, которая будет направлена на обучение сети. Как правило, обучающая выборка составляет около 70 % всего ряда, именно потому, что от того, как мы обучим сеть, будет зависеть качество нейронной сети. Под тестовую и контрольную выборки определим по 15 % длины ряда, для определения результатов обучения по расхождениям с фактическими значениями.

Особенностью программы Statistica Neural Network является то, что модель для построения нейронной сети можно определить как пользователем, так и позволить программе это сделать. В данной работе воспользуемся вторым способом и зададим параметр определить функцию активации автоматически в процессе обучения [17].

Архитектура сети многослойный персептрон (MLP) используется сейчас наиболее часто. Она была предложена в работе Rumelhart, McClelland (1986) [18]. Каждый элемент сети строит взвешенную сумму своих входов с поправкой в виде слагаемого и затем пропускает эту величину активации через передаточную функцию, и таким образом получается выходное значение этого элемента. Элементы организованы в послонную топологию с прямой передачей сигнала. Такую сеть легко можно интерпретировать как модель вход-выход, в которой веса и пороговые значения (смещения) являются свободными параметрами модели. Такая сеть может моделировать функцию любой степени сложности, причем число слоев и число элементов в каждом слое определяют сложность функции. Количество входных и выходных элементов определяется условиями задачи. Сомнения могут возникнуть в отношении того, какие входные значения использовать, а какие нет, это определилось ранее, путем избавления от корреляции между факторами. Именно такой архитектурой мы и воспользуемся.

Основными параметрами погодных условий, влияющими на формирование урожаев сельскохозяйственных культур, являются количество осадков за отдельные периоды вегетационного периода и температурный режим [14, 15]. Эти факторы имеют как самостоятельное, так и общее влияние на урожайность, что целесообразно измерять также величиной гидротермического коэффициента (ГТК). Эти данные, а также данные об урожайности сельскохозяйственных культур, начиная с 1940 года по настоящее время, и послужили основой (исходными данными) для построения сети [10–16].

В окне выбора параметров архитектуры многослойный персептрон (рис. 2) укажем интервал, в промежутке которого сеть может выбирать количество нейронов. Также следует указать, сколько требуется обучить нейронных сетей и сколько отобрать для отображения. Каждый раз, изменяя параметры входных данных, будем строить сети и отбирать наилучшие из них.




Рис. 2. Определение параметров архитектуры многослойный персептрон

Источники: разработано авторами.

На рис. 3 видны итоги и содержание каждой из построенных сетей. Нами было построено 2187 сетей, и отображена 61 с наилучшим качеством.

Index	Net name	Training perf.	Test perf.	Validation perf.	Training error	Test error	Validation error	Training algorithm	Error function	Hidden activation	Output activation
37	MLP 5-13-1	0,958168	0,994318	0,975567	5,22262	0,419320	1,090620	BFGS 3	SOS	Tanh	Exponential
38	MLP 5-2-1	0,991448	0,992471	0,978231	0,50663	0,400569	0,351180	BFGS 19	SOS	Logistic	Logistic
39	MLP 5-9-1	0,926185	0,995515	0,976309	11,59431	0,437437	0,418943	BFGS 2	SOS	Logistic	Exponential
40	MLP 5-6-1	0,962834	0,993270	0,974439	2,94576	0,968476	1,905823	BFGS 7	SOS	Identity	Exponential
41	MLP 5-6-1	0,962927	0,993253	0,974419	2,94482	0,969799	1,931284	BFGS 8	SOS	Identity	Exponential
42	MLP 5-4-1	0,962855	0,993266	0,974434	2,95115	0,946641	1,831893	BFGS 7	SOS	Identity	Exponential
43	MLP 5-2-1	0,991538	0,993901	0,976518	0,51290	0,296573	0,447321	BFGS 39	SOS	Logistic	Logistic
44	MLP 5-5-1	0,962819	0,993273	0,974442	2,99007	0,929111	1,674217	BFGS 5	SOS	Identity	Exponential
45	MLP 5-10-1	0,962927	0,993253	0,974419	2,94482	0,969862	1,931390	BFGS 8	SOS	Identity	Exponential
46	MLP 5-9-1	0,962927	0,993253	0,974419	2,94482	0,969885	1,931430	BFGS 7	SOS	Identity	Exponential
47	MLP 5-3-1	0,962874	0,993263	0,974430	2,94612	0,960359	1,889082	BFGS 7	SOS	Identity	Exponential
48	MLP 5-9-1	0,962774	0,993282	0,974451	2,94916	0,962635	1,867529	BFGS 7	SOS	Identity	Exponential
49	MLP 5-8-1	0,962892	0,993259	0,974426	2,94495	0,969074	1,921563	BFGS 7	SOS	Identity	Exponential
50	MLP 5-5-1	0,962889	0,993260	0,974427	2,94551	0,962487	1,900027	BFGS 7	SOS	Identity	Exponential
51	MLP 5-8-1	0,962812	0,993274	0,974443	2,94838	0,959534	1,868180	BFGS 7	SOS	Identity	Exponential
52	MLP 5-12-1	0,962927	0,993253	0,974419	2,94482	0,969884	1,931428	BFGS 7	SOS	Identity	Exponential
53	MLP 5-2-1	0,962927	0,993253	0,974419	2,94482	0,969884	1,931401	BFGS 7	SOS	Identity	Exponential
54	MLP 5-8-1	0,962838	0,993270	0,974438	2,94603	0,965989	1,898647	BFGS 7	SOS	Identity	Exponential
55	MLP 5-13-1	0,953552	0,998807	0,980524	8,71191	0,426319	0,303486	BFGS 2	SOS	Logistic	Exponential
56	MLP 5-13-1	0,992079	0,989686	0,975168	0,44984	0,473448	0,405568	BFGS 63	SOS	Tanh	Logistic
57	MLP 5-2-1	0,926174	0,995688	0,977972	8,18197	0,643721	1,934992	BFGS 4	SOS	Exponential	Logistic
58	MLP 5-4-1	0,962907	0,993256	0,974423	2,94498	0,966332	1,916555	BFGS 7	SOS	Identity	Exponential
59	MLP 5-7-1	0,962853	0,993267	0,974435	2,94664	0,960532	1,883947	BFGS 7	SOS	Identity	Exponential
60	MLP 5-12-1	0,962789	0,993279	0,974448	2,94695	0,968288	1,892939	BFGS 7	SOS	Identity	Exponential
61	MLP 5-3-1	0,962927	0,993253	0,974419	2,94482	0,969862	1,931425	BFGS 6	SOS	Identity	Exponential

Рис. 3. Содержание нейронных сетей

Источники: разработано авторами.

Из таблицы на рис. 3 можно проследить по колонкам слева направо номер, архитектуру сети, производительность по каждой из выборок, ошибки по каждой из выборок, алгоритм и функцию активации.

Исходя из отобранных сетей, выберем 5 наилучших по качеству, а именно по производительности. Производительность определяется величиной корреляции между полученным после обучения и исходным рядами, и чем ближе этот показатель к единице, тем точнее сеть описывает происходящий процесс. Наилучшими сетями оказались следующие (рис. 4).

Index	Net. name	Training perf.	Test perf.	Validation perf.	Training error	Test error	Validation error	Training algorithm	Error function	Hidden activation	Output activation
2	MLP 5-7-1	0,991030	0,992703	0,979568	0,659782	0,464687	0,355498	BFGS 15	SOS	Sine	Logistic
6	MLP 5-10-1	0,992942	0,990256	0,974921	0,416330	0,407565	0,380099	BFGS 24	SOS	Tanh	Tanh
38	MLP 5-2-1	0,991448	0,992471	0,978231	0,506632	0,400569	0,351180	BFGS 19	SOS	Logistic	Logistic
43	MLP 5-2-1	0,991538	0,993901	0,976518	0,512899	0,296573	0,447321	BFGS 39	SOS	Logistic	Logistic
56	MLP 5-13-1	0,992079	0,989686	0,975168	0,449838	0,473448	0,405568	BFGS 63	SOS	Tanh	Logistic

Рис. 4. Сети с наилучшими показателями

Источник: разработано авторами.

Для наглядности представим значения полученных результатов, после обучения сети на графике вместе с исходным рядом на рис. 5 видно, что сеть № 2 ближе всего находится по своим значениям к исходному ряду.




Рис. 5. Графическая интерпретация исходного и обученных рядов

Источник: разработано авторами.

Таким образом, сеть № 2 показывает самые лучшие результаты обучения с минимальными результатами ошибок. Архитектура сети — многослойный персептрон. Параметры: вход — 5 факторов, скрытых нейронов — 7, выход — 1.




Рис. 6. Гистограмма распределения остатков

Источник: разработано авторами.

Ошибка прогноза построенной сети составляет всего 4,7 % (рис. 7). Теперь построим прогноз на будущие периоды, а именно, на следующие четыре года (рис. 8).

Predictions spreadsheet for Productivity Samples: Train, Test, Validation	
Case name	MAPE
MEAN case 1-37	0,047296026

Рис. 7. Средняя ошибка аппроксимации для построенной нейронной сети

Источник: разработано авторами.

All samples	
Case name	Productivity(Output) MLP 5-7-1
2017	29,46363
2018	34,21516
2019	37,14152
2020	32,31481
2021	35,41521

Рис. 8. Прогнозные значения урожайности зерновых и зернобобовых культур Республики Беларусь на 2017–2020 гг.

Источник: разработано авторами.

По результатам проведенного исследования можно сделать следующие выводы: построена качественная модель, по которой получаются весьма точные прогнозы с минимальными ошибками. По результатам прогноза было определено, что в 2017 г. урожайность снизится в связи затянувшимися холодными весной и летом, недостаточное количество осадков, выпавших в виде снега в зимнее время и т.д. Таким образом, наличие

информации о неблагоприятных погодных условиях позволяет реализовать неотложные мероприятия по устранению их влияния, что подтверждается данными в источниках [19, 20]. Что касается остальных лет, для которых построен прогноз, то видно, что после 2017 г. урожайность увеличится, это может быть обусловлено благоприятной температурой и повышением количества осадков, выпавших на территории Беларуси в 2018–2019 гг. В 2020 г. опять наблюдается снижение урожайности по прогнозу построенной нами модели, соответственно для предотвращения снижения урожайности стоит актуализировать проведение мероприятий по уменьшению риска потерь урожайности, а соответственно и прибыли от реализации данной сельскохозяйственной продукции.

Источники

1. Мещеряков, Д. И. Прогнозная модель урожайности сельскохозяйственных культур на основе искусственных нейронных сетей / Д. И. Мещеряков, В. О. Мосейко // Изв. Волгоград. гос. техн. ун-та. — 2006. — Т. 10. — С. 288–293.
Meshcheryakov, D. I. Prognostnaya model' urozhaynosti sel'skokhozyaystvennykh kul'tur na osnove iskusstvennykh neyronnykh setey / D. I. Meshcheryakov, V. O. Moseyko // Izv. Volgograd. gos. tekhn. un-ta. — 2006. — T. 10. — S. 288–293.
2. Прогнозирование урожайности сельскохозяйственных культур: перспективы использования искусственных нейронных сетей / А. И. Шакирин [и др.] // Переработка и управление качеством сельскохозяйственной продукции : сб. ст. III Междунар. науч.-практ. конф., Минск, 23–24 марта 2017 г. / Белорус. гос. аграр. техн. ун-т. — Минск, 2017. — С. 248–250.
Prognostirovanie urozhaynosti sel'skokhozyaystvennykh kul'tur: perspektivy ispol'zovaniya iskusstvennykh neyronnykh setey / A. I. Shakirin [i dr.] // Pererabotka i upravlenie kachestvom sel'skokhozyaystvennoy produktsii : sb. st. III Mezhdunar. nauch.-prakt. konf., Minsk, 23–24 marta 2017 g. / Belarus. gos. agrar. tekhn. un-t. — Minsk, 2017. — S. 248–250.
3. Мозоль, А. В. Устойчивость и цикличность экономического развития и их особенности в Республике Беларусь / А. В. Мозоль, А. А. Мозоль // Экономический рост Республики Беларусь: глобализация, инновационность, устойчивость : материалы VIII Междунар. науч.-практ. конф., Минск, 21–22 мая 2015 г. : в 2 т. / Белорус. гос. экон. ун-т ; редкол.: В. Н. Шимов [и др.]. — Минск, 2015. — Т. 2. — С. 77–78.
Mozol', A. V. Ustoychivost' i tsiklichnost' ekonomicheskogo razvitiya i ikh osobennosti v Respublike Belarus' / A. V. Mozol', A. A. Mozol' // Ekonomicheskiy rost Respubliki Belarus': globalizatsiya, innovatsionnost', ustoychivost' : materialy VIII Mezhdunar. nauch.-prakt. konf., Minsk, 21–22 maya 2015 g. : v 2 t. / Belarus. gos. ekon. un-t ; redkol.: V. N. Shimov [i dr.]. — Minsk, 2015. — T. 2. — S. 77–78.
4. Мозоль, А. В. Динамика урожайности сельскохозяйственных культур в аграрном производстве и ее параметры / А. В. Мозоль, А. А. Мозоль // Экономический рост Республики Беларусь: глобализация, инновационность, устойчивость : материалы IX Междунар. науч.-практ. конф., Минск, 19–20 мая 2016 г. : в 2 т. / Белорус. гос. экон. ун-т ; редкол.: В. Н. Шимов [и др.]. — Минск, 2016. — Т. 2. — С. 74–76.
Mozol', A. V. Dinamika urozhaynosti sel'skokhozyaystvennykh kul'tur v agrarnom proizvodstve i ee parametry / A. V. Mozol', A. A. Mozol' // Ekonomicheskiy rost Respubliki Belarus': globalizatsiya, innovatsionnost', ustoychivost' : materialy IX Mezhdunar. nauch.-prakt. konf., Minsk, 19–20 maya 2016 g. : v 2 t. / Belarus. gos. ekon. un-t ; redkol.: V. N. Shimov [i dr.]. — Minsk, 2016. — T. 2. — S. 74–76.
5. Малинецкий, Г. Г. Современные проблемы нелинейной динамики / Г. Г. Малинецкий, А. В. Потапов. — М. : УРСС, 2000. — 213 с.
Malinetskiy, G. G. Sovremennye problemy nelineynoy dinamiki / G. G. Malinetskiy, A. V. Potapov. — M. : URSS, 2000. — 213 s.
6. Каханер, Д. Численные методы и программное обеспечение : пер. с англ. / Д. Каханер, К. Моулер, С. Нэш. — М. : Мир, 1998. — 351 с.
Kakhaner, D. Chislennyye metody i programmnnoye obespechenie : per. s angl. / D. Kakhaner, K. Mouler, S. Nesh. — M. : Mir, 1998. — 351 s.
7. Kugiumtzis, D. Regularized local linear prediction of chaotic time series / D. Kugiumtzis, O. C. Lingjorde, N. Ghristophersen // Physica D. — 1998. — Vol. 112. — P. 344–360.

8. *Короткий, С.* Нейронные сети: алгоритм обратного распространения / С. Короткий. — СПб., 2002. — 328 с.
9. *Короткий, С.* Neyronnye seti: algoritm obratnogo rasprostraneniya / S. Korotkiy. — SPb., 2002. — 328 s.
9. *Короткий, С.* Нейронные сети: основные положения / С. Короткий. — СПб., 2002. — 357 с.
10. *Короткий, С.* Neyronnye seti: osnovnye polozheniya / S. Korotkiy. — SPb., 2002. — 357 s.
10. Статистический ежегодник Республики Беларусь / Нац. стат. ком. Респ. Беларусь. — Минск, 2013. — 634 с.
11. Сельское хозяйство Республики Беларусь : стат. сб. / Нац. стат. ком. Респ. Беларусь. — Минск, 2014. — 372 с.
12. Сельское хозяйство Республики Беларусь : стат. сб. / Нац. стат. ком. Респ. Беларусь. — Минск, 2015. — 318 с.
13. Сельское хозяйство Республики Беларусь : стат. сб. / Нац. стат. ком. Респ. Беларусь. — Минск, 2016. — 230 с.
14. Республиканский центр по гидрометеорологии, контролю радиоактивного загрязнения и мониторингу окружающей среды (Гидромет) [Электронный ресурс]. — Режим доступа: <http://belgidromet.by/>. — Дата доступа: 01.04.2017.
15. База данных ООН UN Comtrade [Электронный ресурс]. — Режим доступа: <https://comtrade.un.org/>. — Дата доступа: 01.04.2017.
16. Национальный статистический комитет Республики Беларусь [Электронный ресурс]. — Режим доступа: <http://www.belstat.gov.by/>. — Дата доступа: 01.04.2017.
17. *Farmer, J. D.* Exploring chaos to predict the future and reduce noise / J. D. Farmer, J. J. Sidorowich // *Evolution, Learning, and Cognition* / ed. Y. C. Lee. — Singapore : World Sci., 1988. — P. 277–330.
18. *McClelland, J. L.* Parallel Distributed Processing : in 2 vol. Vol. 2 : Psychological and Biological Models / J. L. McClelland, D. E. Rumelhart. — Cambridge, Massachusetts : The Massachusetts Inst. of Technology, 1986. — 551 p.
19. 7 млн тонн зерновых культур будет собрано в Беларуси в 2017 г. [Электронный ресурс] // ПРОДУКТ.BY. — Режим доступа: <http://produkt.by/news/7-mln-tonn-zernovyh-kultur-budet-sobrano-v-belarusi-v-2017-godu>. — Дата доступа: 24.06.2016.
20. *Крапивина, Л.* Белорусский АПК по итогам 9 месяцев: достижения и точки роста / Л. Крапивина // Белорусское сельское хозяйство [Электронный ресурс]. — Режим доступа: <http://agriculture.by/news/apk-belarusi/beloruskij-apk-po-itogam-9-mesjacev-dostizheniya-i-tochki-rosta>. — Дата доступа: 24.06.2016.
21. *Крапивина, Л.* Belorusskij APK po itogam 9 mesyatsjev: dostizheniya i tochki rosta / L. Krapivina // Belorusskoe sel'skoe khozyaystvo [Elektronnyy resurs]. — Rezhim dostupa: <http://agriculture.by/news/apk-belarusi/beloruskij-apk-po-itogam-9-mesjacev-dostizheniya-i-tochki-rosta>. — Data dostupa: 24.06.2016.

Статья поступила в редакцию 10.12.2017 г.

УДК 378.014.54(476)

O. Morozovich
E. Golomazova
BSEU (Minsk)

DEVELOPMENT OF THE OPERATIONAL APPROACH TO THE RESEARCH OF THE COMPETENCES MARKED BY THE LABOR MARKET

Essential changes in the state of the external environment (labor automation, machine learning, digitalization and globalization of the economy, etc.) require the availability of tools and methods for identifying and assessing the competencies and skills that are needed at the current time by the labor market and are in demand.