

Нейросетевое прогнозирование динамики цен на сельскохозяйственную продукцию

Neural network forecasting price dynamics for agricultural products

doi 10.26310/2071-3010.2021.270.4.006



В. Е. Парфенова,

д. э. н., профессор, Санкт-Петербургский государственный аграрный университет
✉ w.parfenova@mail.ru

V. E. Parfenova,

doctor of Economics, Professor, St. Petersburg State Agrarian University

Аграрная отрасль в экономике любой страны занимает особое место. Специфичность роли аграрной отрасли обусловлена, прежде всего, производством продуктов питания, как основы жизнедеятельности людей и воспроизводства рабочей силы, а также производством сырья для многих других отраслей. Поэтому уровень развития сельского хозяйства во многом определяет уровень экономической безопасности страны. В современных условиях развитие агропромышленного производства всецело зависит от ускорения научно-технического прогресса, использования достижений науки и техники. Однако усиление инновационной направленности возможно лишь при дальнейшем развитии и совершенствовании научных исследований и практической их реализации, как в сельскохозяйственном производстве, так и в процессах по его управлению. Важнейшей функцией управления является разработка научно-обоснованных прогнозов, что в условиях нарастающей рыночной неопределенности становится трудно решаемой задачей. В этих условиях классические методы прогнозирования становятся малоприменимыми. В условиях возросшей неопределенности необходимо применение специальных методов анализа и прогнозирования. В качестве альтернативы классическим методам прогнозирования может служить использование технологий нейронных сетей. Освоение этих инструментов является насущной задачей аграрной науки и практики. Объектом исследования в статье является мясной рынок говядины в России. Предметом исследования выступает динамика цен и ценовой прогноз на рынках говядины.

The agrarian industry occupies a special place in the economy of any country. The specificity of the role of the agrarian industry is due, first of all, to the production of food products, as the basis for the life of people and the reproduction of the labor force, as well as the production of raw materials for many other industries. Therefore, the level of development of agriculture largely determines the level of economic security of the country. In modern conditions, the development of agro-industrial production entirely depends on the acceleration of scientific and technological progress, the use of the achievements of science and technology. However, strengthening the innovation orientation is possible only with the further development and improvement of scientific research and their practical implementation, both in agricultural production and in the processes of its management. The most important function of management is the development of scientifically based forecasts, which in the context of growing market uncertainty becomes a difficult task. Under these conditions, classical forecasting methods become of little use. In conditions of increased uncertainty, it is necessary to use special methods of analysis and forecasting. The use of neural network technologies can be used as an alternative to classical forecasting methods. Mastering these tools is an urgent task of agricultural science and practice. The object of research in the article is the beef meat market in Russia. The subject of the research is the dynamics of prices and the price forecast in the beef markets.

Ключевые слова: временной ряд, прогноз, нейронные сети, аграрное производство.

Keywords: time series, forecast, neural networks, agricultural production.

Введение

Традиционные модели управления агропромышленным комплексом и соответствующие им аналитические методы анализа и моделирования, основанные на статистических и эконометрических моделях, были разработаны для условий относительно стабильной внешней среды и не предназначены для решения проблем, связанных с большой неопределенностью. В силу этого они становятся малоприменимыми при моделировании быстрых изменений и возросшей неопределенности, характерной для современной рыночной среды и переходу аграрной отрасли к инновационному типу развития.

В изменившихся условиях насущной практической необходимостью становится поиск новых аналитических инструментов, адекватных условиям значимой неопределенности. Такими инструментами в настоящее время выступают интеллектуальные технологии анализа и обработки данных. К ним, в частности, относятся нечеткий анализ, нечеткая логика, генетические алгоритмы, нейронные сети. Внедрение всех этих технологий в агроэкономическую науку и практику

является важнейшей задачей при переходе к инновационной модели управления аграрной отраслью.

Одним из важнейших направлений в этой области, которое в настоящее время находит широкое распространение, как в экономической, так и в других науках, является использование нейросетевых технологий [1] – [5]. Однако, несмотря на то, что нейросетевой инструментарий уже достаточно хорошо разработан, в аграрной науке и практике до сих пор преобладает традиционный аналитический подход, использующий модели классического анализа.

В качестве основных преимуществ использования нейронных сетей, именно для условий значимой неопределенности перед традиционным регрессионным и эконометрическим анализом можно отметить следующие. Нейросетевой подход не предполагает никаких ограничений на характер входной информации, не требует априори задания формальной статистической модели, по своей сути является нелинейным, способным выявлять любые сложные зависимости между входными и выходными характеристиками.

Кроме того, в отличие от традиционного подхода, который оперирует аналитическими моделями, нейро-

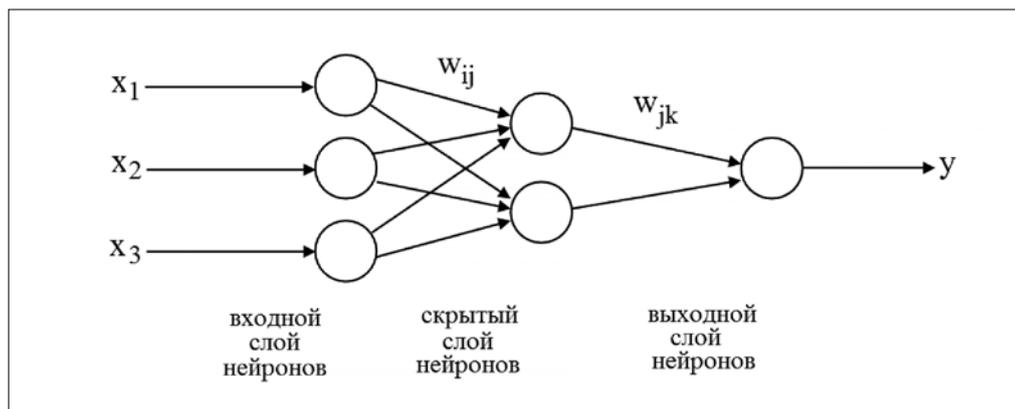


Рис. 1. Сеть прямого распространения с двумя слоями нейронов

сетевые модели относятся к классу обучаемых моделей, т. е. моделей, которые создаются путем тренировки. Для построения такой модели нейронной сети задаются списки входных тренировочных примеров и требуемых выходных данных или только входных данных, обучаясь на которых сеть сама выявляет имеющиеся закономерности между входами и выходами сети.

Наиболее важными приложениями нейросетевого подхода для практики в области экономики и менеджмента аграрной отрасли являются возможности решения задачи прогнозирования.

В настоящее время из всего имеющегося множества разновидностей известных нейронных сетей наиболее изученными и применяемыми являются нейронные сети персептронного типа с сигмоидными активационными функциями. При прогнозировании временных рядов обычно используются многослойные нейронные сети прямого распространения. Пример такой сети с одним скрытым слоем показан на рис. 1.

На рис. 1 x_1, x_2, x_3 — компоненты входного вектора X , w_{ij} ($i=1,2,3; j=1,2$), w_{jk} ($k=1$) — синаптические веса соответствующих дуг, y — выходное значение. Прямое распространение — сигнал (стрелка) идет слева направо. Обозначение данной сети (3–2–1), где цифры указывают количество нейронов каждого слоя.

Прежде, чем говорить о решении задачи с помощью нейронной сети, надо дать ряд используемых в статье понятий.

Единицей нейронной сети является нейрон. Поэтому, чтобы понять, как работает сеть, надо разобраться с работой нейрона (рис. 2).

На входы поступают данные (x_1, x_2). Задаются их веса (w_1, w_2). Именно через веса происходит обучение

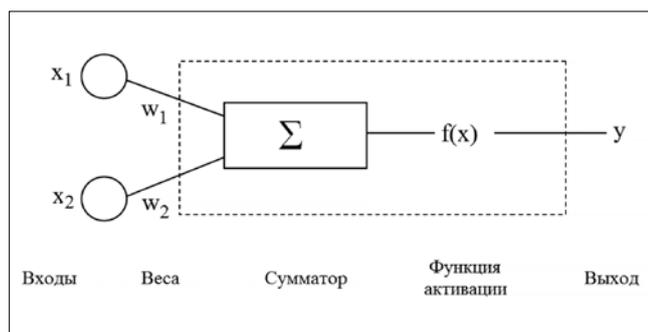


Рис. 2. Схема работы нейрона

сети. Входы умножаются на соответствующие веса. Далее результаты произведений поступают на нейрон и суммируются ($x_1w_1+x_2w_2$). После этого результат суммирования поступает в блок нелинейного преобразования, в котором находится функция активации ($f(x)$). Одной из наиболее часто используемых активационных функций является бинарная сигмоидальная функция с областью значений в (0, 1), определенная как:

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

с производной $f'(x) = f(x) * [1 - f(x)]$.

По строению нейронные (НС) сети разделяются на однослойные сети и многослойные, с прямыми связями и обратными связями. Входные сигналы не обрабатываются. Они лишь подают сигналы на обработку. В однослойных НС данные с выходного слоя сразу передаются на выходные нейроны, где сигналы обрабатываются. Многослойные сети имеют скрытые (обрабатывающие) слои.

Под слоем понимают множество весов с последующими за ним нейронами, которые взвешенные по весам суммируются. Входной слой не выполняет суммирование. По этой причине входной слой не входит в подсчет слоев. Следовательно, на рис. 1 изображена двухслойная сеть.

Сети с прямыми связями — это сети, в которых сигналы от входов направляются к выходному или скрытому слою. Сети с обратными связями имеют как прямые, так и обратные связи.

Обучение нейронной сети — это процесс, при котором меняются веса сети. При этом в процессе обучения веса сети постепенно становятся такими, чтобы каждый входной вектор выработывал желаемый выходной вектор. Разработаны разные правила обучения, которые делятся на два класса: обучение с учителем и без учителя.

Обучение с учителем предполагает, что для каждого входного вектора существует целевой выходной вектор. Вместе они составляют обучающую пару. При обучении без учителя нет целевого выходного вектора. Обучающее множество состоит лишь из входного вектора. В работе мы используем правило обучения с учителем, которое реализуется с помощью алгоритма обратного распространения ошибки [5]. Идея метода

заключается в распространении сигнала ошибки, равной разности между правильным ответом и ответом сети обратно на все нейроны, чьи выходные сигналы были входящими для последнего нейрона. Как правило, ошибка определяется как

$$E = \frac{1}{2} (\sum y_i - d_i)^2, \quad (2)$$

где y — выход нейронной сети; d — желаемое значение выхода. При обучении сети необходимо минимизировать ошибку обучения. В алгоритме обратного распространения для минимизации ошибки, используется метод градиентного спуска [6].

Полное решение с помощью сети можно в самом агрегированном виде представить в виде решения трех подзадач: создание сети, ее обучение и собственно решение задачи. Реализация этих подзадач включает несколько этапов [7].

Этап 1. Постановка задачи. Определяются цели моделирования. Устанавливаются входные и выходные параметры, а также структура входного вектора X и выходного вектора D . Компоненты векторов представляют собой числа.

Этап 2. Формирование примеров. Создается множество пар Xq, Dq ($q=1 \div Q$), где каждая пара составляет пример, характеризующий предметную область. Числовую информацию желательно нормировать, т. е. привести к диапазону $[0, 1]$ или $[-1, +1]$. Все множество примеров разбивают на два множества: обучающее и тестирующее. Тестирующее множество включает примеры, которые не использовались при обучении сети.

Этап 3. Проектирование сети. Определяется: количество входных нейронов Nx — должно быть равно размерности входного вектора X ; количество выходных нейронов — должно быть равно размерности вектора D ; количество скрытых слоев; количество нейронов в скрытых слоях. активационные функции скрытых слоев. На последующих этапах все эти характеристики могут корректироваться, если это улучшит работу сети.

Этап 4. Обучение сети. Цель обучения — подобрать веса нейронов w_{ij} ; так, чтобы на каждый входной вектор Xq множества обучающих примеров сеть выдавала вектор Yq , минимально отличающийся от заданного выходного вектора Dq . Достигается это путем использования алгоритмов обучения нейронной сети.

Этап 5. Проверка и оптимизация сети. Проводится на тестирующем множестве примеров. Если разница между компонентами желаемого выходного вектора Dq и действительного выходного вектора Yq окажется незначительной, то можно переходить к следующему, этапу 6, не выполняя оптимизацию сети. В противном случае пытаются оптимизировать сеть. Эта операция состоит в подборе наиболее подходящей для данной задачи структуры сети — количества скрытых слоев, количества скрытых нейронов, количества синаптических связей, а также вида и параметров активационных функций нейронов. Оптимизация нейронной сети подразумевает многократные возвраты назад на этапы 4, 3, 2 или даже на этап 1. Результатом оптимизации и проверки сети является готовая к использованию нейросетевая математическая модель предметной области.

Этап 6. Исследование предметной области — интеллектуальный анализ данных. Задача анализа временных рядов заключается в том, чтобы получить будущее значение некоторой величины, зная ее текущее и прошлые значения и располагая данными о среде. Рассмотрим применение нейронных сетей для решения задачи прогнозирования временных рядов.

Иллюстративный пример. Рассмотрим применение данного алгоритма для прогнозирования конкретного показателя, отражающего результаты деятельности аграрного производства. В качестве иллюстративного примера нами был взят временной ряд средних недельных внутренних цен на мясо (говядины) крупного рогатого скота (КРС) в живом весе в промежутке времени с 16.01.2020 по 02.12.2020 гг. (табл. 1) [8]. Нужно определить прогноз средней недельной цены мяса за пределами рассматриваемого промежутка.

Таблица 1

Недельные средние цены на мясо КРС в живом весе за 2020 г. (т. руб.)

Дата	Цена	Дата	Цена	Дата	Цена
16.01	121,26	20.05	120,64	30.09	119,74
23.01	123,31	27.05	119,74
29.01	120,53	18.11	121,02
.....	16.09	118,76	25.11	121,50
13.05	118,37	23.09	119,21	02.12	120,52

Формальная постановка задачи прогнозирования. Имеется временной ряд $x(t)$ на промежутке $t=1 \div h$. Тогда задача прогнозирования состоит в том, чтобы найти продолжение временного ряда, т. е. необходимо определить $x(h+1)$, $x(h+2)$ и так далее. Совокупность известных значений временного ряда образуют обучающую выборку, размерность которой равняется h . Метод выявления закономерности во временном ряде на основе нейронной сети получил название «метод окон» [9].

Идея его состоит в использовании двух окон W_1 и W_0 с фиксированными размерами n и m соответственно. Эти окна, перемещаются с некоторым шагом s по временной последовательности исторических данных, начиная с первого элемента, причем первое окно W_1 , получив такие данные, передает их на вход нейронной сети, а второе W_0 — на выход. Получающаяся на каждом шаге пара образует обучающий пример. В результате получается некоторая последовательность наблюдений:

$$W_{11}, W_{12}, \dots, W_{1j}, \dots, W_{1n} \quad (1);$$

$$W_{01}, W_{02}, \dots, W_{0j}, \dots, W_{0n} \quad (2)$$

Предполагается, что последовательность (1) однозначно отображается в последовательность (2) и эта связь определена на всем множестве данных.

Используя «метод окон», определим множество обучающих и тестирующих примеров для нашей задачи.

Выбираем размеры окон и шаг: $W_1=4$, $W_0=1$, $s=1$.

Преобразовываем входные данные к диапазон $[0, 1]$. Для этого умножаем каждое число табл. 1 на 0,00001. С помощью метода окон и преоб-

разованных данных табл. 1 формируем следующее обучающее множество примеров (табл. 2).

Таблица 2

Множество обучающих выборок нейронной сети

№ обучающей выборки	Входной слой (W_1)				Выходной слой (W_0)
	1	2	3	4	
1	121,26	123,31	120,53	119,6	120,31
2	123,31	120,53	119,6	120,31	119,6
3	120,53	119,6	120,31	119,6	120,06
...
38	118,63	119,71	119,54	119,58	120,66

В качестве тестирующего множества выступают 3 выборки (табл. 3).

Таблица 3

Тестирующее множество

№ обучающей выборки	Входной слой (W_1)				Выходной слой (W_0)
	1	2	3	4	
1	119,71	119,54	119,58	120,66	121,02
2	119,54	119,58	120,66	121,02	121,5
3	119,58	120,66	121,02	121,5	120,52

Для выявления лучшей сети были построены и протестированы следующие структуры нейронных сетей: 421, 431, 441, 4211, 4221, 4441, 44441, 444441. Каждая из построенных сетей была проверена на одном и том же тестирующем множестве. Для сетевых расчетов использовалась библиотека с открытым исходным кодом NumPy для языка программирования Python [10–11]. Выяснилось, что с увеличением нейронов скрытого слоя до четырех прогнозные свойства сети улучшаются. Та же тенденция наблюдается и при увеличении числа скрытых слоев. Из исследованных структур лучшей для прогноза оказалась сеть с четырьмя скрытыми слоями и четырьмя нейронами в каждом из них, т. е. структура 444441.

Качество обучения определялось с помощью ошибки обучения, рассчитанной как суммарное квадратичное отклонение желаемых значений на выходах нейронной сети в обучающей выборке от реальных значений, полученных на выходах нейронной сети в виде среднеквадратичной ошибки (суммирование производится по всем выходам):

$$E = \frac{1}{2} (\sum y_i - d_i)^2, \quad (3)$$

где y – выход нейронной сети; d – желаемое значение выхода.

Для оценки качества прогноза была использована средняя ошибка прогноза (AFER)

$$AFER = \frac{\sum_{i=1}^n |(F_i - T_i)|}{T_i} \cdot 100\%, \quad (4)$$

где F_i – выход сети на i -м тестовом множестве, T_i – целевой показатель этого множества, n – количество тестирующих множеств.

Таблица 4

Среднеквадратичная ошибка обучения для сети 4,4,4,4,4,1 (формула 4)

Тестирующее множество	Целевое значение	Выход сети	Относительная ошибка, %
1.	121,02	118,96	1,7
2.	121,5	118,96	2,09
3.	120,52	118,96	1,29
Относительная средняя ошибка, %			1,69

Результаты прогнозирования. На данной сети нами были выполнены два вида прогноза: одношаговый и многошаговый прогнозы [9].

Одношаговое прогнозирование применяется для краткосрочных прогнозов на один шаг вперед. На очередном текущем шаге в качестве исходной информации используются только объективные данные.

Многошаговое прогнозирование применяется для осуществления долгосрочного прогноза и предназначено для определения основного тренда. При этом прогнозирующая система использует результаты прогноза (выходные данные), полученные для моментов времени $k+1$, $k+2$ и т. д. в качестве входных данных для прогнозирования на моменты времени $k+2$, $k+3$, $k+4$ и т. д. Результаты прогноза на три недели вперед приведены в таблице 5. Для сравнения там же приведены результаты прогноза, полученные традиционным способом путем построения регрессии (последний столбец табл. 5). Для выведения регрессии по исходным данным (табл. 1) был построен график для определения линии тренда (рис. 3).

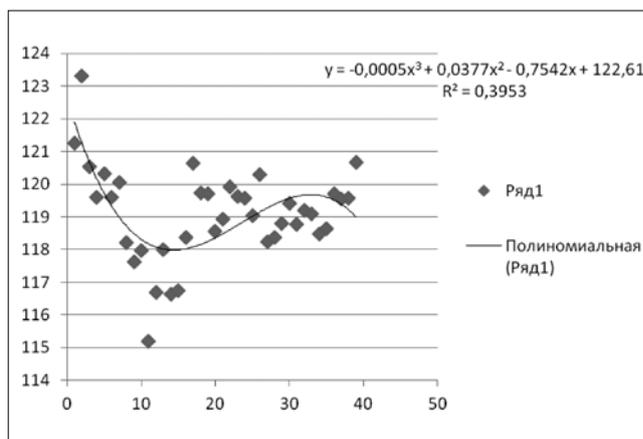


Рис. График изменения недельных цен на говядину

Наиболее подходящей линией оказалась полиномиальная функция 3-го порядка:

$$y(t) = 9848,6 + 340,37x - 16,378x^2 + 0,2602x^3 \quad (5)$$

Построенная регрессия была проверена на тестирующем множестве (табл. 3) с применением оценки качества (4). Оценка качества по регрессии оказалась хуже, чем аналогичная оценка, полученная по сети. В табл. 5 приведен недельный прогноз цен на мясо

Таблица 5

Недельный прогноз цен

Дата	Сетевой прогноз (руб./тонна)	Прогноз по регрессии (руб./тонна)
09.12.2020	118,96	117,61
16.12.2020	118,96	117,11
23.12.2020	118,96	116,56

говядины на декабрь 2020 года, полученный на сети и по регрессии.

Выводы

Применение нейронных сетей для прогнозирования имеет большие преимущества относительно статистических методов. Главными их преимуществами по сравнению со статистическими методами является то, что они по своей сути не линейны и не нуждаются в заранее построенной модели, основанной на тех или иных предположениях. В силу этого нейронные сети

успешно могут применяться как для линейных, так и нелинейных сложных зависимостей. Эти особенности нейронных сетей позволяют повысить адекватность математических моделей, приблизить их к экономической реальности.

В ходе нашего исследования было выявлено наличие нелинейной сложной временной зависимости анализируемой цены на мясо говядины. Для выявления этой зависимости с целью дальнейшего прогноза цены был использован традиционный регрессионный подход и технология нейронных сетей. Прогноз на нейронных сетях оказался точнее прогноза, полученного на основе регрессии.

Выбор структуры сети происходит эмпирически. Поэтому при проведении нейросетевого прогнозирования было построено несколько сетей, которые были обучены и протестированы на одних и тех же массивах данных. Анализ полученных результатов позволил выбрать сеть, дающую наиболее точный прогноз.

Полученные результаты подтверждают перспективность применения нейросетевых технологий при решении конкретных задач аграрной отрасли.

Список использованных источников

1. Каллан Р. Основные концепции нейронных сетей: пер. с англ./Р. Каллан. — М.: Издат. дом «Вильямс», 2001. — 287 с.
2. Люгер Ф. Искусственный интеллект: стратегии и методы решения сложных проблем, 4-е издание.: Пер. с англ. — М.: Вильямс, 2003. — 864 с.
3. Murray A. Applications of Neural Networks/A. Murray. — Springer, 2014. — 340 p.
4. Рассел С., Норвиг П. Искусственный интеллект. Современный подход. — М.: Изд-во «Вильямс», 2006. — 1408 с.
5. Хайкин С. Нейронные сети: Полный курс. — 2-е изд./Пер. с англ. — М.: Издательский дом Вильямс, 2008, 1103 с.
6. С. Ю. Городецкий, В. А. Гришагин. Нелинейное программирование и многоэкстремальная оптимизация. — Нижний Новгород: Издательство Нижегородского Университета, 2007.- 489 с.
7. Ясницкий Л. Н. Интеллектуальные системы. М. Лаборатория знаний.2016. 221 с.
8. <https://mcx.gov.ru/ministry/departments/departament-ekonomiki-investitsiy-i-regulirovaniya-rynkov/industry-information/info-monitoring-rynkov-apk/>(дата обращения 23.02.2021)
9. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы. — М.: Горячая линия — Телеком, 2004. — 452 с.
10. Джоши, Прадик. Искусственный интеллект с примерами на Python: Пер.с англ. — СПб.: 000 «Диалектика», 2019. — 448 с. — Парал.тит.англ.
11. Joshi Prateek. Artificial Intelligence with Python. — Birmingham — Mumbai.: Packt Publishing, 2017. — 521p.

References

1. Kallan R. Osnovnie kontseptsii neyronnikh setey: per. s angl./R. Kallan. — M.: Izdat. Dom «Vilyams», 2001 — 287 s.
2. Lyuger F. Iskustvennyy intellekt: strategii i metodi resheniya slozhnikh problem, 4-e izdanie.: Per. s angl. — M.: «Vilyams», 2003 — 864 s.
3. Murray A. Applications of Neural Networks/A. Murray. — Springer, 2014. — 340 p.
4. Rassel S., Norvig P. Iskustvennyy intellekt. Sovremenniy podkhod. — M.: Izda-vo «Vilyams», 2006 — 1408 s.
5. Khaykin S. Neyronnie seti. Polniy kurs. — 2-e izd./Per. S angl. — M.: Izdatelskiy dom Vilyams, 2008, 1103 s.
6. S. YU. Gorodetskiy, V. A. Grishagin. Nelineynoe programirovanie i mnogoekstremalnaya optimizatsiya. — Nizhniy Novgorod: Izdatelstvo Nizhegorodskovo Universiteta, 2007. — 489 s.
7. Yasnitskiy P.N. Intellektualnie sistemi. M. Laboratoriya znaniy. 2016. 221 s.
8. <https://mcx.gov.ru/ministry/departments/departament-ekonomiki-investitsiy-i-regulirovaniya-rynkov/industry-information/info-monitoring-rynkov-apk/>(data obrashcheniya 23.02.2021)
9. Rudkovskaya D. Neyronnie seti, geneticheskie algoritmi I netchetkie sistemi. — M.: Goryatchayaliniya — Telekom, 2004. — 452 s.
10. Dzhoshi, Pratik. Iskustvennyy intellekt s primerami na Python: per. s angl. — SPb. 000 «Dialektika», — 2019 . — 448 s. — Parap tit angl.
11. Joshi Prateek. Artificial Intelligence with Python. — Birmingham — Mumbai.: Packt Publishing, 2017. — 521 p.