

Инженерно-технические науки

Engineering and technical sciences

УДК 338.5:004.5

ВОЗМОЖНОСТЬ ИСПОЛЬЗОВАНИЯ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ЦЕНЫ НАСОСНОЙ ТЕХНИКИ

Г. Н. Бояркин, И. В. Ревина, О. Г. Шевелёва
Омский государственный технический университет

Обоснование цены на продукцию является актуальной задачей в экономике. Методикам оценки цены уделяют большое внимание. В работе предложена информационная модель прогнозирования цены на насосную технику с использованием нейронных сетей. Были выбраны основные технические характеристики насосной техники, использованные в вычислительном эксперименте. Сформированная и обученная нейронная сеть показала высокий уровень корреляции прогнозируемых и реальных значений цены. Таким образом, прогнозирование цен с использованием нейронных сетей является удобным инструментом в управлении бизнес-процессами. Особенно это является актуальным на этапе разработки новой продукции, при сравнении цен на аналогичную продукцию разных производителей.

Ключевые слова: ценообразование, методы прогнозирования, нейронные сети, насосная техника

ВВЕДЕНИЕ

Цена – это важный параметр конкурентоспособности продукции. Цена на продукцию – это денежное выражение стоимости. Стоимость определяется затратами на производство и реализацию продукции, полезностью продукции для потребителя [1].

Производственные затраты, в соответствии с экономическим содержанием, включают следующие группы:

- затраты на оплату труда;
- материальные затраты (на сырье, материалы, комплектующие и др.);
- амортизационные отчисления;
- отчисления на социальные нужды;
- прочие отчисления.

Калькуляция по статьям затрат позволяет определить различные виды себестоимости – технологическую, цеховую, производственную и полную. Полная себестоимость является основой для формирования цены произведенной продукции [2].

В условиях рыночной экономики, наряду с законом стоимости, действует закон спроса и предложения. Закон спроса (предложения) отражает связь между ценой на товар и величиной спроса (предложения) на товар.

При выборе стратегии ценообразования различают следующие подходы:

- расчетный (метод полных издержек – прибавление к себестоимости товара определенной величины, обеспечивающий безубыточность);

- нормативно-параметрический (метод удельных показателей, метод регрессионного анализа, агрегатный метод, метод расчета цены с учетом потребительского эффекта и др.);
- методы рыночного ценообразования (метод определения престижных цен, метод следования за рыночными ценами, метод с ориентацией на спрос и др.) [3].

Таким образом, при определении цены приходится учитывать много факторов.

При прогнозировании цены на техническую продукцию часто используют корреляционную связь между ценой и одним или несколькими техническими параметрами, определяющими потребительские свойства технической продукции [4,5].

Использование статистических методов анализа данных (регрессионный анализ, метод максимального правдоподобия и др.) ведет к усреднению значений, а, следовательно, и к потере определенной информативности.

Нейронные сети являются одним из инструментов интеллектуального анализа данных. Нейронные сети – это мощный распределенный вычислительный процесс, состоящий из простых элементов, работающих по определенным правилам. Выбор архитектуры сети, ее параметров для решения конкретной задачи является неформальной и трудно формализованной процедурой [6].

При наличии большого объема данных, неполной информации, избыточной информации, данных с большим уровнем зашумления и т. д. наиболее целесообразно использовать нейронные сети. Они эффективно позволяют решать поставленные задачи поиска закономерностей. Поэтому нейронные сети активно используют в исследованиях экономиче-

ских процессов [7, 8, 9], в прогнозировании [10, 11, 12], в ценообразовании [13, 14].

Целью данной работы является выбрать нейронную сеть, позволяющую прогнозировать цены на насосную технику.

ПОСТАНОВКА ЗАДАЧИ

Насосы различаются по конструкции, области использования, по типу [15]. В данной работе были выбраны центробежные насосы для перекачки сточных вод. Основными характеристиками насосов данной группы являются:

- производительность (x_1);
- напор (x_2);
- мощность электрического двигателя (x_3);
- номинальный диаметр напорного патрубка (x_4);
- номинальный диаметр рабочего колеса (x_5);
- КПД (x_6);
- масса (x_7);
- частота вращения (x_8);
- номинальный ток (x_9).

Указанные основные параметры (x_i , $i=1\dots 9$) будут рассматриваться как входные при моделировании. Цена (Y) – выходной параметр моделирования. Таким образом, для прогнозирования цены на насосы можно использовать нейронную сеть (рис.1).

Для этого необходимо:

- построить нейронную сеть, где в качестве входных данных будут основные характеристики насосов, а на выходе значение цены;
- обучить нейронную сеть по известным алгоритмам;
- оценить точность работы обученной нейронной сети;

- протестировать нейронную сеть по известным сочетаниям характеристики – цена;
- выполнить прогнозирование цены с использованием нейронной сети.

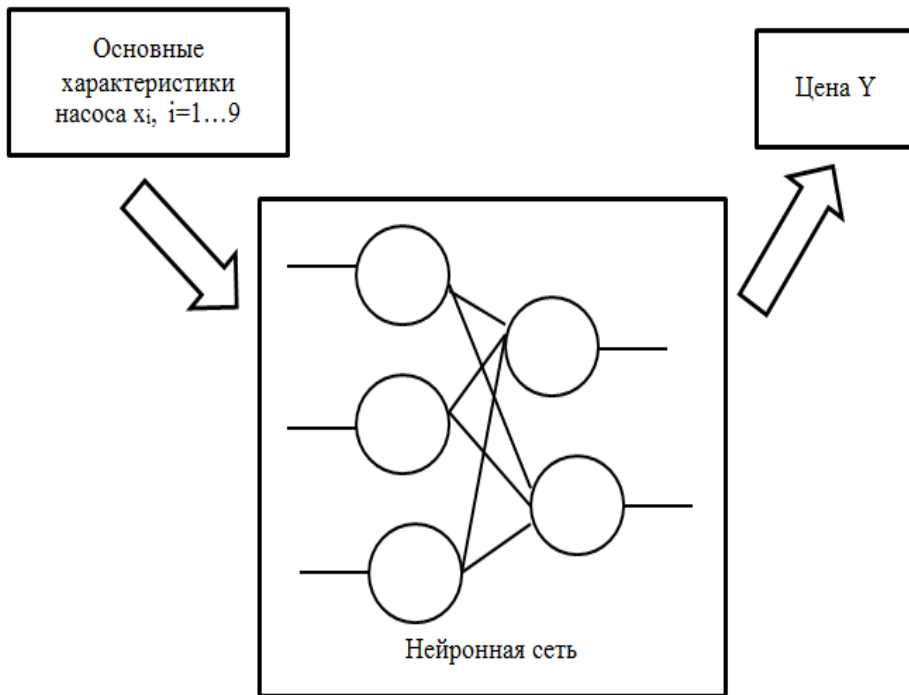


Рис.1. Обработка данных с использованием нейронной сети

НЕЙРОСЕТЕВАЯ МОДЕЛЬ ПРОГНОЗИРОВАНИЯ ЦЕНЫ

Моделирование с использованием нейронных сетей является трудоемким, для его реализации воспользуемся готовыми программными продуктами.

Первые пакеты по нейронным сетям появились в конце 80 годов XX века. На сегодняшний день количество таких пакетов весьма обширно. Это могут быть надстройки к программным продуктам для поддержания нейросетевого моделирования: Deep Learning Toolbox (ранее Matlab Neural Network Toolbox), Statistica Automated Neural Network, набор библиотек для реализации некоторой обработки данных: Excel Neural Package, специализированные нейросетевые пакеты: NeuroSolutions, Neural Work Professional, NeuroShell, Mem Brain, Neuro Pro и др.

Анализ указанных программных продуктов по таким критериям как простота в использовании, функциональные возможности обработки данных, документирования, скорость работы показал, что наиболее предпочтительным является Matlab Neural Network Toolbox. Этот пакет и будет использоваться в данной работе.

Исходные (входные) данные для моделирования были взяты из открытых Internet источников, на основе которых была сформирована исходная база данных. Она включала 520 наименований насосов, из которых 500 – обучающая выборка и 20 – контрольная выборка.

Фрагмент базы данных представлен на рис. 2.

	Наименования	Производительность, Q м ³ /ч	Напор	Мощность эл. двигатель, кВт	Номинальный диаметр напорного	Номинальный диаметр рабочего	КПД, %	Масса, кг	Частота вращения	Номинальный ток, А	Цена
1	ПФ2 50/120.110 - 1,1/2 - 016	10	15	1,1	50	120	45	42	2730	2,6	93279
2	ПФ2 50/140.138 – 3/2 - 016	25	20	3	50	140	48	45	2940	7	98058
3	ПФ2 50/140.138 – 3/2 - 036	25	20	3	50	140	50	45	2940	7	116230
4	ПФ2 50/150.155 – 3/2 - 016	16	32	3	50	150	66	70	2940	7	98058
5	ПФ2 50/200.185 – 7,5/2 - 016	25	40	7,5	50	200	44	155	2895	20	213998
6	ПФ2 50/200.180 – 11/ 2 - 016	45	34	11	50	200	60	160	2895	21	231187
7	ПФ2 65/135.125 – 3/2 - 016	50	11	3	65	135	68	65	2940	7	99100

Рис. 2. Фрагмент базы данных для моделирования

В данной работе при моделировании использовалась нейронная сеть прямого распознавания, состоящая из двух слоев, один из которых является скрытым. Выбор структуры сети осуществлялся из соображений, что недостаточная сложность может привести к значительной ошибке, а избыточная сложность может привести к восприятию шума в качестве данных для моделирования, т.е.

лишает нейронную сеть важного свойства обобщения.

Обучение нейронной сети осуществлялась методом обратного распространения ошибки. В процессе обучения происходит определение значений весов сети на основе примеров (базы данных), образующих обучающее множество, которое имеет вид:

$$\langle \tilde{X}, \tilde{Y} \rangle = \{(\tilde{x}_k, \tilde{y}_k)\}_{k=1, \dots, 500}, \quad (1)$$

где $\tilde{x}_k \in R^n$ – входной вектор из k -го примера ($n=9$ – количество входов), $\tilde{y}_k \in R^m$ – вектор требуемых значений (указаний учителя) ($m=1$ – количество выходов). Обучение сети происходит с учителем.

Для каждого входного множества существует парное множество, задающее требуемые значения выхода. Вместе эти множества образуют обучающую пару.

$w \in R^W$ – текущий вектор весов нейронной сети, определяющий степень близости вектора ответа сети y_k на k -ом примере и соответствующий вектор указаний учителя \tilde{y}_k . W – количество весовых коэффициентов в нейронной сети прямого распространения.

Качество обучения, определяющее степень соответствия данным из обучающего множества задается функцией вида:

$$E(w) = \sum_{k=1}^{500} (y_k(w) - \tilde{y}_k)^2 = \sum_{k=1}^{500} (F(x_i, w) - \tilde{y}_k)^2. \quad (2)$$

Цель обучения нейронной сети – определить такое значение вектора весов w^* , чтобы функция (2) принимала минимальное значение. Таким образом, про-

$$w^* = \arg \min_{w \in R^n} E(w). \quad (3)$$

Существует множество методов для решения (3). В программном продукте Deep Learning Toolbox (ранее Matlab Neural Network Toolbox) можно выбрать несколько алгоритмов для решения. Алгоритм Левенберга-Марквардта обладает некоторыми преимуществами: достаточно быстрая сходимость; минимальное время вычисления; нет негативного влияния локальных минимумов. Алгоритм Левенберга-Марквардта представляет комбинацию метода наименьших квадратов с методом градиентного спуска [16]. Анализ алгоритма Левенберга-Марквардта показал, что он позволяет достичь наименьшей ошибки нейронных сетей [17].

Алгоритм создания и настройки нейронной сетевой модели в Deep Learning Toolbox (ранее Matlab Neural Network Toolbox) состоял из нескольких этапов:

1. определение обучающей выборки; выбираем структуры сети;
2. разбиваем обучающую выборку на три подмножества «Training»,

цесс обучения нейронной сети сводится к решению задачи безусловной оптимизации вида:

«Validation», «Testing» (обучение производится согласно «Training», остановка обучения будет производится согласно «Validation», а общая работа сети будет определяться согласно набору данных «Testing»);

3. определяем количество нейронов в скрытом слое (изменяем для корректировки работы сети);
4. выбираем алгоритм обучения;
5. запускаем работу сети;
6. получаем и анализируем результаты в (если полученные результаты являются не удовлетворительными, этапы моделирования повторяют с 3 шага).

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

По результатам вычислительных экспериментов оптимальной является двухслойная структура нейронной сети, состоящая из 25 нейронов в скрытом слое и одного нейрона в открытом слое. Сеть имеет 9 входов характеристики насосов и 1 выход цена насосов. На рис. 3 представлена структура нейронной сети.

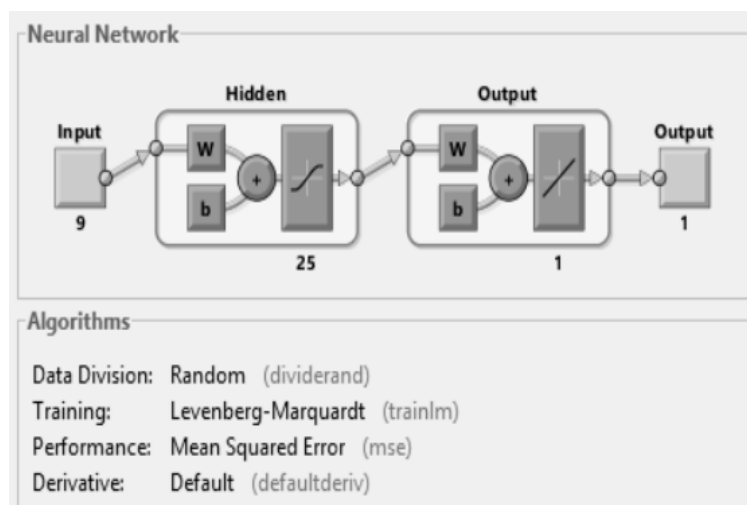


Рис. 3. Структура нейронной сети

Обучение сети происходит за 39 итераций, т.е. обучение останавливается, когда обучающая способность сети перестает улучшаться на наборе данных «Validation». Точность обучения (зависимости среднеквадратической ошибки от итерации обучения) представлена на рис. 4, показаны ошибки для трех наборов данных «Training», «Validation»,

«Testing». Обучение прекращается, когда ошибка на наборе «Validation» не уменьшается. «Best» показывает лучший результат обучения. «Test» показывает обобщающую способность сети.

Аппроксимация данных нейронной сетью и ошибка сети представлена на рис. 5. считаем удовлетворительной для целей исследования.

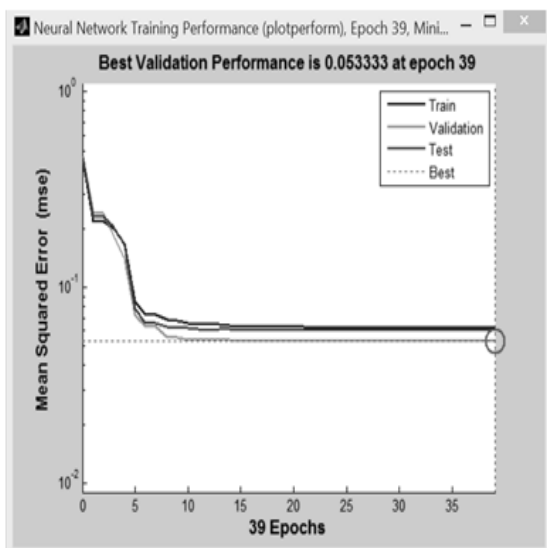


Рис. 4. Точность обучения нейронной сети (зависимости среднеквадратической ошибки от итерации обучения)

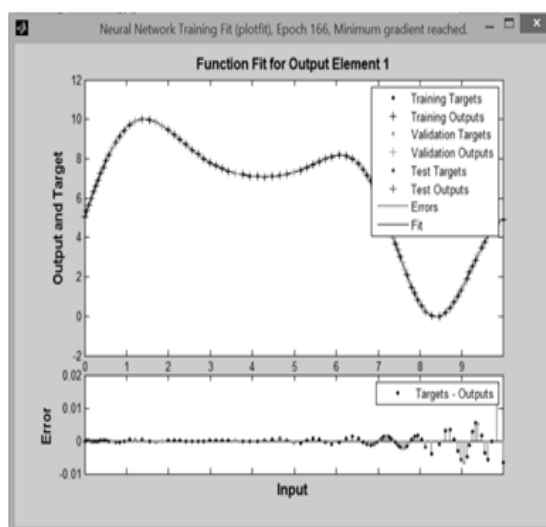


Рис. 5. Аппроксимация данных нейронной сетью и ошибка сети

На рис. 6 представлен график регрессионной зависимости.

Линия «Fit» – это линия регрессии на основе эмпирических данных, а линия « $Y=T$ » – это линия, построенная на основе рассчитанных после обучения значений (массивом «T» представлены данные, используемые для обучения, а «Y» – массив выходных данных, которые рассчитываются по обучению нейронной сети и служат для проверки точности модели).

$R=0.96432$ – коэффициент корреляции позволяет говорить о сильной связи между переменными. Таким образом, построенная нейронная сеть имеет высокую точность.

Полученные результаты сохраняем в «Script» (рис. 7).

Сохраненный «Script» позволит выполнить моделирование данных, не участвовавших в процессе обучения нейронной сети.




Рис. 6. График регрессионной зависимости

Для проверки работы обученной нейронной сети выбираем данные, не задействованные в процессе обучения (рис. 2 см. заливку) и запускаем сохраненный “Script”. На рис. 8 а) представлены результаты моделирования, а на рис 8 б)

```
File Edit Text Go Cell Tools Debug Desktop Window Help
- 1.0 + + 1.1 x
1 % Solve an input-output fitting problem with a neural network
2 % Script generated by NFTOOL
3 % Created Sun Apr 02 20:09:29 PKT 2018
4 %
5 % This script assumes these variables are defined:
6 %
7 % In - input data.
8 % data - target data.
9 %
10 inputs = In';
11 targets = data';
12 %
13 % Create a Fitting Network
14 hiddenLayerSize = 25;
15 net = fitnet(hiddenLayerSize);
16 %
17 % Choose Input and Output Pre/Post-Processing Functions
18 % For a list of all processing functions type: help nprocess
19 net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};
20 net.outputs{2}.processFcns = {'removeconstantrows','mapminmax'};
21 %
22 % Setup Division of Data for Training, Validation, Testing
23
```

Рис. 7. Script обученной нейронной сети

исходное значение. Цена, предложенная нейронной сетью 228091, а цена исходных данных 231187. Полученные результаты позволяют говорить о возможности использования нейронных сетей для прогнозирования.

```
Command Window
>> sim(net, [45;34;11;50;200;60;160;2895;21])
ans =
    228091
```

а)

45	34	11	50	200	60	160	2895	21	231187
----	----	----	----	-----	----	-----	------	----	--------

б)

Рис. 8. Результаты моделирования

ЗАКЛЮЧЕНИЕ

В работе была разработана информационная модель прогнозирования цены на насосную технику с использованием нейронных сетей.

Выполненный вычислительный эксперимент показал высокий уровень корреляции прогнозируемых и реальных значений цены.

Таким образом, прогнозирование цен с помощью нейронных сетей является удобным инструментом в управлении бизнес-процессами. Такое прогнозирование особенно актуально при разработке

новой продукции технического назначения, при сравнении цен на продукцию аналогов разных производителей.

ЛИТЕРАТУРА

1. Фатхутдинов Р.А. Организация производства. М.:ИНФРА-М, 2000. 672 с.
2. Горфинкель В.Я., Швандер В.А. Экономика организаций (предприятий). М.: ЮНИТИ, 2004. 608 с.
3. Васюхин О.В. Основы ценообразования. СПб: СПбГУ ИТМО, 2010. 110 с.
4. Killingsworth E.C., Wolz R.R. Requirements for business jet aircraft// AIAA-90-2038, SAE, ASME, and ASEE, 26th Joint Propulsion Conference. 1990. P.10.

5. Цейтлтна Т.О., Балашов В.В., Дунаевский А.И., Смирнов А.В. Прогнозирование цены перспективного сверхзвукового административного самолета Труды МФТИ. 2009. Том 1 № 3, с.160 – 170.
6. Хайкин С. Нейронные сети: полный курс. 2-е изд. М.: Издательский дом “Вильямс”, 2006. 1104 с.
7. [Xiaobing H](#), [Xiaolian L](#), [Yuanqian R](#). Enterprise credit risk evaluation based on neural network algorithm [Cognitive Systems Research Vol. 52](#), December 2018, Pages 317-324.
8. Ступак А.А. Управление запасами с использованием нейронных сетей «Управление инвестициями и инновациями» 2017, №3 с.95-102.
9. Курников Д.С., Петров С.А. Использование нейронных сетей в экономике, [Juvenis scientia\(@jscientia\)](#) 2017, №6 с.10-12.
10. [Pengju Z](#). Quantitative analysis of portfolio based on optimized BP neural network [Cognitive Systems Research Vol. 52](#), December 2018, Pages 709-714.
11. Федотов Д.В., Семенкин Е.С. О прогнозировании экономических показателей с помощью нейроэволюционных моделей. Вестник СибГАУ, 2014, №5(57). С.299-304.
12. Омаров А.В., Репников А.И., Грязнов И.Е. Решение задач прогнозирования с помощью нечетких нейронных сетей в пакете “MATLAB”, Известие ВолГТУ, 2018 № 2(212), с.80-82.
13. Dongqing Z, Guangming Z, [Jing L](#), Kaiping M, Huan Liu Prediction of soybean price in China using QR-RBF neural network model [Computers and Electronics in Agriculture, Vol. 154](#), November 2018, Pages 10-17.
14. Бугорский В.Н., Никитин Н.А. Нейронные сети в управлении розничной торговлей, Прикладная информатика, 2006, №2, с. 34-41.
15. Карелин В.Я., Минаев А.В. Насосы и насосные станции М.: Стройиздат, 1986. 320 с.
16. MATLAB – book1. Режим доступа: <http://matlab.exponenta.ru/neuralnetwork/book1/index.php>. (дата обращения: 20.06.18).
17. Hagan M.T., Menhaj M. Training Feedforward Networks with the Marquardt Algorithm // IEEE Transactions on Neural Networks. 1994. Vol.5. №6. P. 989-993.

Рукопись поступила в редакцию 12.07.2019г.

JEL code: C45, D41

POSSIBILITY OF USING NEURAL NETWORKS FOR PREDICTING THE PRICE OF PUMP TECHNOLOGY

G.N. Boyarkin, I.V. Revina, O.G. Shevelyova

Justification of product prices is an urgent task in the economy. Pricing techniques pay great attention. The paper proposes an information model for forecasting the price of pumping equipment using neural networks. The main technical characteristics of the pumping equipment used in the computational experiment were chosen. The formed and trained neural network showed a high level of correlation between predicted and real price values. Thus, price prediction using neural networks is a convenient tool in managing business processes. This is especially relevant at the stage of developing new products, when comparing prices for similar products from different manufacturers.

Key words: pricing, forecasting methods, neural networks, pumping technology

References

1. Fathutdinov R.A. Organizaciya proizvodstva. M.:INFRA-M, 2000. 672 s.
2. Gorfinkel' V.YA., SHvander V.A. Ekonomika organizacij (predpriyatij). M.: YUNITI, 2004. 608 s.
3. Vasyuhin O.V. Osnovy cenoobrazovaniya. SPb: SPbGU ITMO, 2010. 110 s.
4. Killingsworth E.C., Wolz R.R. Requirements for business jet aircraft// AIAA-90-2038, SAE, ASME, and ASEE, 26th Joint Propulsion Conference. 1990. P.10.
5. Cejltina T.O., Balashov V.V., Dunaevskij A.I., Smirnov A.V. Prognozirovanie ceny perspektivnogo sverhzvukovogo administrativnogo samoleta Trudy MFTI. 2009. Tom 1 № 3, s.160 – 170.
6. Hajkin S. Nejronnye seti: polnyj kurs. 2-e izd. M.: Izdatel'skij dom "Vil'yams", 2006. 1104 s.
7. [Xiaobing H](#), [Xiaolian L](#), [Yuanqian R](#). Enterprise credit risk evaluation based on neural network algorithm [Cognitive Systems Research Vol. 52](#), December 2018, Pages 317-324.
8. Stupak A.A. Upravlenie zapasami s ispol'zovaniem nejronnyh setej «Upravlenie investiciyami i innovacijami» 2017, №3 s.95-102.
9. Kurnikov D.S., Petrov S.A. Ispol'zovanie nejronnyh setej v ekonomike, Juvenis scientia(@jscientia) 2017, №6 s.10-12.
10. [Pengju Z](#). Quantitative analysis of portfolio based on optimized BP neural network [Cognitive Systems Research Vol. 52](#), December 2018, Pages 709-714.
11. Fedotov D.V., Semenkin E.S. O prognozirovanii ekonomicheskikh pokazatelej s pomoshch'yu nejroevolyucionnyh modelej. Vestnik SibGAU, 2014, №5(57). S.299-304.
12. Omarov A.V., Repnikov A.I., Gryaznov I.E. Reshenie zadach prognozirovaniya s pomoshch'yu nechetkih nejronnyh setej v pakete "MATLAB", Izvestie VolGTU, 2018 № 2(212), s.80-82.
13. Dongqing Z, Guangming Z, Jing L, Kaiping M, Huan Liu Prediction of soybean price in China using QR-RBF neural network model Computers and Electronics in Agriculture, Vol. 154, November 2018, Pages 10-17.
14. Bugorskij V.N., Nikitin N.A. Nejronnye seti v upravlenii roznicnoj trgovlej, Prikladnaya informatika, 2006, №2, s. 34-41.
15. Karelin V.YA., Minaev A.V Nasosy i nasosnye stancii M.: Strojizdat, 1986. 320 s.
16. MATLAB – book1, see <http://matlab.exponenta.ru/neuralnetwork/book1/index.php>. (see 20.06.18)
17. Hagan M.T., Menhaj M. Training Feedforward Networks with the Marquardt Algorithm // IEEE Transactions on Neural Networks. 1994. Vol.5. №6. P. 989-993.