

УДК 338.2

НЕЙРОСЕТЕВОЙ ПОДХОД К ПРОГНОЗИРОВАНИЮ СТОИМОСТИ ФЕРРОСПЛАВНОЙ ПРОДУКЦИИ*

*Сиротин Д.В., к.э.н., научный сотрудник лаборатории моделирования
пространственного развития территорий (sirotin.d.umk@mail.ru)*

Институт экономики УрО РАН
(620014, Россия, Екатеринбург, ул. Московская, 29)

Аннотация. В работе отмечается возрастающая роль ферросплавной подотрасли в качественном развитии металлургии в целом. В условиях усиления рисков глобального экономического развития прогнозирование развития металлургии не только в средне- и долгосрочной перспективе, но и на краткосрочные периоды. Негативное влияние оказывает также высокая волатильность цен на основные ферросплавы. В связи с этим возрастает необходимость в развитии методического инструментария прогнозирования изменений рыночных цен на металлургическую продукцию с высокой степенью точности. Одним из важных направлений применения в металлургии прогнозного инструментария является построение моделей прогнозирования стоимости ферросплавной продукции, что определило основную цель исследования. На примере построения прогнозной модели изменения цены на ферросилиций обоснована актуальность нейросетевого подхода к прогнозированию стоимости ферросплавной продукции. В рамках задач отраслевого развития возможности нейронных сетей на сегодняшний день изучены достаточно слабо. В работе приведено формальное описание модели прогнозирования временных рядов на базе нейронных сетей. Отмечено, что при построении нейросетей любая задача временного ряда представляется в виде многомерной регрессии. С учетом этого выделены основные параметры обучения прогнозных сетей. В качестве входных переменных использована средняя цена на ферросилиций на российском рынке, а также цены субъектов РФ. При проведении исследования обучены сети, удовлетворяющие качественным критериям прогнозных моделей. Отбор моделей проведен с учетом результатов графического анализа и кросс-проверки. В результате проведенного исследования построена нейросетевая модель, которая может быть использована для прогнозирования изменения цены на ферросилиций на внутреннем рынке РФ на краткосрочную перспективу. Полученная модель отличается высокой точностью прогнозирования и может быть полезна при обосновании стратегических решений в деятельности отраслевых научно-исследовательских институтов и металлургических предприятий.

Ключевые слова: металлургия, ферросплавное производство, ферросилиций, нейронная сеть, моделирование, прогнозирование временных рядов, цена.

DOI: 10.17073/0368-0797-2020-1-78-83

ВВЕДЕНИЕ

Металлургическое производство является комплексной отраслью промышленности, напрямую зависящей от секторов-потребителей металла и реагирующей на все колебания в этих отраслях. К важным задачам развития металлургии сегодня относится создание условий для выпуска высококачественной металлопродукции, соответствующей заявленным характеристикам, малыми партиями, а также значительное сокращение доли брака, развитие сервисного обслуживания, смягчение ценовой политики. Рост значимости качественных факторов развития металлургии определяет необходимость повышения технологического и ресурсного потенциалов, которые формируются на базе ферросплавного комплекса [1].

По данным за 2018 г. производство ферросплавов в России составляет около 2,1 млн т в год, из которых чуть больше половины приходится на Уральский феде-

ральный округ (УрФО). Структура ферросплавной продукции УрФО и России в целом достаточно обширна и учитывает ферросплавы как крупнотоннажной (ферро- и силикомарганец, феррохром, ферросилиций), так и малотоннажной (сплавы на основе ванадия, молибдена и др.) групп. Основной вес приходится на кремний- и марганецсодержащие ферросплавы и феррохром, в совокупности формирующие почти 87 % общего объема ферросплавного производства РФ. При этом рынок ферросплавной продукции отличается высокой волатильностью цен (табл. 1).

В структуре ферросплавного производства России доля ферросилиция в 2018 г. составила 44,1 % (932,1 тыс. т в год). Отечественное производство кремниевых ферросплавов полностью покрывает потребности внутри страны. Их основное производство сосредоточено в Сибирском и Уральском федеральных округах [3]. При этом экспортируется в среднем 45 % продукции. Ферросилиций применяется в качестве основного раскислителя почти для всех сортов стали, а также широко используется в виде легирующей добавки при выплавке ряда конструкционных и транс-

* Статья подготовлена в соответствии с планом НИР лаборатории моделирования пространственного развития территорий ФГБУН Института экономики УрО РАН на 2019 г.

Уровень средних цен производителей РФ на основные ферросплавы, руб/т без НДС [2]

Table 1. Average prices of Russian producers for basic ferroalloys, RUB/ton without VAT

Продукция	2016 г.	2017 г.	2018 г.				
	декабрь	декабрь	январь	март	июнь	сентябрь	декабрь
Ферросилиций	49 481	60 580	62 130	65 089	72 774	74 377	72 495
Феррохром	117 711	125 179	107 538	114 744	114 925	119 463	118 391
Ферромолибден	790 451	833 205	835 783	1 191 234	1 122 975	1 353 243	1 268 946

форматорных сталей, что делает его одним из ключевых ферросплавов.

В развитии мировой экономики в последние годы наблюдается усиление рисков глобального экономического развития, учитывающих высокие темпы изменений мировой рыночной конъюнктуры, неопределенность геополитических преобразований, необходимость учета трендов четвертой промышленной революции, что отражается на темпах развития отраслей народного хозяйства [4 – 6]. В частности, на фоне растущей вероятности торговых войн повышается волатильность цен на продукты ферросплавного производства [7]. В этих условиях усложняется прогнозирование развития металлургии в целом на средне- и долгосрочную перспективу, а также на краткосрочные периоды. В связи с этим, важную роль в работе предприятий в условиях новых экономических вызовов, учитывающих организацию экономической деятельности на базе новых бизнес-моделей, играет развитие методического инструментария прогнозирования изменений рыночной конъюнктуры с высокой степенью точности.

Задача настоящего исследования заключается в построении модели прогнозирования изменения цены на ферросилиций в условиях возрастающей волатильности рыночной конъюнктуры. Такая модель должна обладать способностью к адаптации¹.

ОПИСАНИЕ МЕТОДА ИССЛЕДОВАНИЯ

В эконометрике задача прогнозирования временных рядов рассматривается как частный случай регрессии. Методический инструментарий прогнозирования учитывает модели экспоненциального сглаживания, регрессионные и авторегрессионные модели [8, 9] и др. Стоит отметить набирающий популярность подход, учитывающий нейросетевое моделирование. Преимущества искусственных нейронных сетей определяют их свойства, учитывающие способности к обучению и адаптации за счет корректировки параметров сети, умение абстрагировать обрабатываемую информа-

цию [10 – 12]. Основы теории и методологии искусственных нейронных сетей и их дальнейшее развитие раскрываются в работах и В. Видроу [13], М. Мински, С. Пайперта [14], У. Мак-Каллока, У. Питтса [15], Ф. Розенблатта [16], Д. Хебба [17], Д. Хопфилда [18] и др. Для построения прогнозной модели изменения цены на ферросилиций нейросетевой подход представляется оптимальным.

Искусственная нейронная сеть представляет собой совокупность простейших вычислительных элементов (нейронов), алгоритм работы которых задается передаточной функцией (функцией активации) (рис. 1).

Приведенная на рис. 1 схема учитывает весовые коэффициенты (W_1, \dots, W_m), корректирующие импульс входных сигналов (X_1, \dots, X_m) в сумматор (S), на выходе которого посредством функции активации (F) информационные сигналы преобразуются в выходную информацию (Y).

Для прогнозирования временных рядов модель на базе нейронных сетей будет соответствовать линейной авторегрессии [20]

$$\overline{x(n)} = \sum_{k=1}^p W_k x(n - p + k - 1), \tag{1}$$

где $W_k, k = \overline{1, p}$ – весовые коэффициенты нейросети; p – длина «скользящего окна», равная количеству одновременно подаваемых в сеть элементов временного ряда; $x(n)$ – прогнозная оценка $x(n)$ в момент n . Разность между реальными $x(n)$ и выдаваемыми сетью прогнозными значениями $\overline{x(n)}$ определяет ошибку прогнозирования $E(n)$.

На предварительном этапе исследования проанализирован временной ряд, составляющий месячные значения средней цены на ферросилиций на внутреннем рынке РФ с января 1998 г. по январь 2019 г., выделены характерные периоды колебания цены (рис. 2).

Как видно на рис. 2, график имеет возрастающий линейный тренд. Разложение исследуемого ряда на спектральные составляющие по методу Фурье показало наличие временного лага, составляющего 3 года и 7 месяцев. Наличие циклической составляющей преимущественно связано с кризисными явлениями и имеет, скорее, непостоянный характер. Это подтверждает отсутствие резких скачков в изменении цены до

¹ Под адаптацией понимается процесс изменения параметров и структуры системы на базе текущей информации с целью достижения ее определенного (стабильного) состояния при изменяющихся условиях работы.

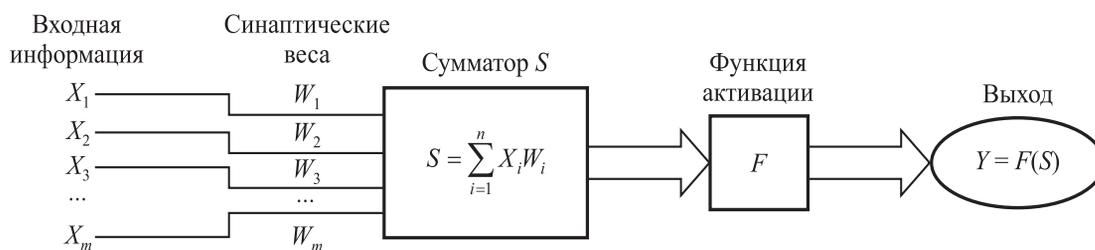


Рис. 1. Схема искусственного нейрона [19]

Fig. 1. Scheme of an artificial neuron [19]

2004 г. В связи с этим учет циклической составляющей может негативно повлиять на качество модели.

Задача построения нейронной сети сводится к реализации алгоритма поиска подходящих моделей путем анализа сети различной топологии [21]. При обучении сетей исходные данные были распределены на обучающую (70 %) и контрольную (30 %) подвыборки. Последние 12 наблюдений исключены из общей выборки в целях проведения на их основе кросс-проверки. Для активации выходных нейронов, учитывая тип решаемой задачи, при обучении использована тождественная функция. На скрытом слое сети в качестве функции активации применялись, помимо тождественной, логистическая и гиперболическая функции. В качестве функции ошибки использована сумма квадратов [22].

На основе нейросетевых алгоритмов регрессионного типа обучен ряд моделей временных рядов двух типов. Для моделей первого типа в качестве зависимой переменной принят временной ряд, отражающий среднюю цену на ферросилиций на российском рынке, в качестве независимой – ряд, сдвинутый на лаг назад.

Модели второго типа отличаются тем, что при их обучении в качестве независимых переменных использованы сдвинутые на лаг назад цены на ферросилиций, производимый в Уральском и Сибирском федеральных округах.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Было обучено более 30 сетей, из которых наибольшей производительностью (выше 99 %) и меньшим значением ошибки отличались модели, использующие для активации нейронов на скрытом и выходном слоях тождественную функцию. Это характерно как для сетей на базе единого временного ряда (модели I-го типа), так и для сетей, обученных на основе данных волатильности цен на ферросилиций в регионах РФ (модели II-го типа). В результате обучения отобрано по одной модели каждого типа, которые отличались максимальной производительностью на всех подвыборках (табл. 2).

Производительность является одним из основных показателей качества нейросети и характеризуется величиной корреляции между исходным и предсказанным рядом. Особое значение имеет производительность на контрольной подвыборке, используемой для остановки процесса обучения сети.

АНАЛИЗ И ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Проверка качества построения прогноза нейросетями целесообразна на независимых данных. С этой целью, по данным за период с февраля 2018 г. по январь 2019 г. не используемых в обучении сетей, проведена кросс-проверка. Результаты подтвердили ошибку прогнозных значений модели MLP 2-4-1 на уровне 6,4 %. Точность сети MLP 1-1-1 оценена значительно выше, ошибка построенного данной сетью прогноза составила всего 2,8 %. Графический анализ результатов кросс-проверки представлен на рис. 3.

Из рис. 3 видно, что обе модели улавливают зависимость, тем не менее, наиболее близкий к реальным значениям прогноз строит модель MLP 1-1-1. Данные описательной статистики также подтвердили высокое качество модели.

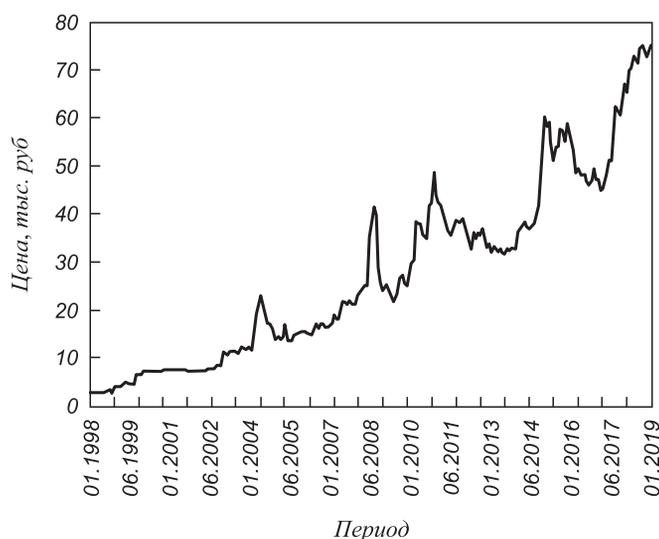


Рис. 2. Линейный график изменения средней цены на ферросилиций на российском рынке

Fig. 2. Line graph of changes in the average price of ferrosilicon on the Russian market

Результаты обучения отобранных нейронных сетей

Table 2. Training results of selected neural networks

Тип модели	Архитектура сети	Производительность обучения	Контрольная производительность	Алгоритм обучения*	Функция ошибки	Функция активации скрытых нейронов	Функция активации выходных нейронов
I	MLP 1-1-1	0,992817	0,991975	BFGS 7	Сумма квадратов	Тожественная	Тожественная
II	MLP 2-4-1	0,992277	0,991526	BFGS 3	Сумма квадратов	Тожественная	Тожественная

* При обучении сетей использован алгоритм Бройдена-Флетчера-Гольдфарба-Шанно (BFGS). Цифра в названии алгоритма обозначает номер итерации, на которой этот алгоритм был остановлен.

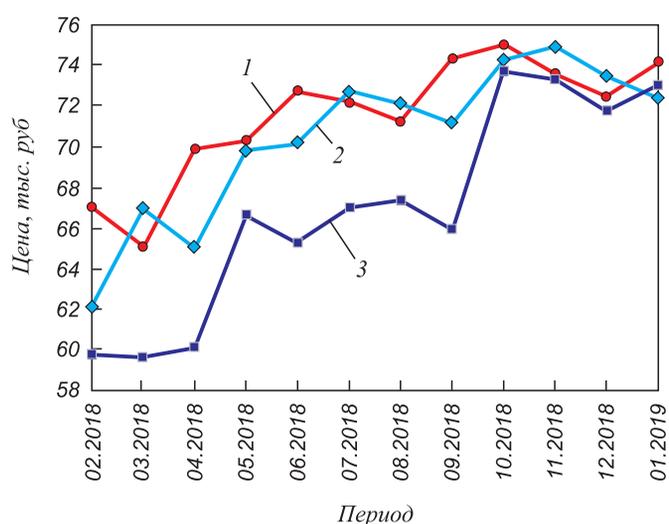


Рис. 3. График сопоставления спрогнозированных и реальных значений средней цены ферросилиция на отечественном рынке:

- 1 – реальные значения средней цены на ферросилиций;
- 2 – ряд, спрогнозированный нейросетью MLP 1-1-1;
- 3 – ряд, спрогнозированный нейросетью MLP 2-4-1

Fig. 3. Comparison graph of predicted and real values of the average ferrosilicon price in the domestic market:

- 1 – real values of the average price of ferrosilicon;
- 2 – series predicted by MLP 1-1-1 neural network;
- 3 – series predicted by MLP 2-4-1 neural network

Выводы

В результате проведенного исследования разработана модель, которая отличается способностью к адаптации и может быть использована в целях построения прогноза изменения цены на ферросилиций на отечественном рынке на краткосрочную перспективу. Построенная модель отличается высокой производительностью и достаточно низким значением ошибки в отклонениях прогнозных величин. Практическая значимость такой модели обосновывается возможностью ее использования в деятельности отраслевых научно-исследовательских институтов и металлургических предприятий при обосновании стратегических

решений развития отрасли. Проведенное исследование демонстрирует возможности нейросетевого подхода в прогнозировании изменений цен на продукты ферросплавного производства.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Галкин М.П., Бродов А.А. Современные требования к производству специальных сталей и сплавов // Сб. тр. XV Междунар. конгресса сталеплавателей, 15 – 19 октября 2018. – М.: Ассоциация сталеплавателей, 2018. С. 23 – 26.
2. Катунин В.В., Петракова Т.М., Иванова И.М. Основные показатели работы черной металлургии России в 2018 г. // Черная металлургия. Бюл. ин-та «Черметинформация». 2019. № 3. С. 293 – 314.
3. Жучков В.И., Леонтьев Л.И., Дашевский В.Я. Состояние и развитие металлургии ферросплавов в России // Перспективы развития металлургии и машиностроения с использованием завершенных фундаментальных исследований и НИОКР: ФЕРРОСПЛАВЫ: Тр. науч.-практич. конф. с междунар. участием, 29 октября – 2 ноября 2018. – Екатеринбург: Изд. и тип. «Альфа Принт», 2018. С. 12 – 20.
4. Глазьев С.Ю. Рынок в будущее. Россия в новых технологическом и мирохозяйственном укладах. – М.: Книжный мир, 2018. – 768 с.
5. Perez K. Technological revolutions and the role of government in unleashing golden ages // Journal of Globalization Studies. 2012. Vol. 3. No. 2. P. 19 – 25.
6. Романова О.А., Сиротин Д.В. Металлургический комплекс Среднего Урала в условиях развития Индустрии 4.0: дорожная карта перепозиционирования комплекса // Проблемы прогнозирования. 2019. № 2. С. 37 – 50.
7. Адно Ю.Л. Итоги 2018 года: проблемы и противоречия экономического развития // Черные металлы. 2019. № 7. С. 73 – 82.
8. Cubadda G., Guardabascio B. Representation, estimation and forecasting of the multivariate index-augmented autoregressive model // Int. J. Forecast. 2018. Vol. 35. No. 1. P. 67 – 79.
9. Сиротин Д.В. Анализ пространственной интеграции отраслевых рынков металлопродукции // Изв. вуз. Черная металлургия. 2017. Т. 60. № 1. С. 74 – 79.
10. Pradhan R.P., Kumar R. Forecasting exchange rate in India: An application of artificial neural network model // Journal of Mathematics Research. 2010. Vol. 2. No. 4. P. 111 – 117.
11. Yildiz B., Yalama A., Coskun M. Forecasting the Istanbul Stock Exchange National 100 Index using an artificial neural network // An International Journal of Science, Engineering and Technology. 2008. Vol. 46. P. 36 – 39.
12. Catalao J. etc. An artificial neural network approach for day-ahead electricity prices forecasting // 6th WSEAS Int. Conf. on Neural Networks, USA, Stevens Point. 2005. P. 80 – 83.

13. Widrow B., Hoff M.E. Adaptive switching circuits // IRE WESCON. – N.Y., 1960. P. 96 – 104.
14. Minsky M.L., Papert S.S. Perceptrons: An Introduction to Computational Geometry. – MIT Press, Cambridge, MA, 1969. – 258 p.
15. McCulloch W.S., Pitts W.A. A Logical calculus of the ideas immanent in nervous activity // Bull. Math. Biophys. 1943. Vol. 5. P. 115 – 133.
16. Розенблатт Ф. Аналитические методы изучения нейронных сетей // Зарубежная радиоэлектроника. 1965. № 5. С. 40 – 45.
17. Hebb D.O. The Organization of Behavior: A Neuropsychological Theory. – New-York: John Wiley & Sons, Inc., 1949. – 335 p.
18. Hopfield J. Neural networks and physical system with emergent collective computational properties // Proceeding of the National Academy of Sciences of the USA. 1982. Vol. 79. No. 8. P. 2554 – 2558.
19. Романова О.А., Сиротин Д.В. Методологический подход к оценке перепозиционирования металлургического комплекса региона: препринт. – Екатеринбург: Институт экономики УрО РАН, 2017. – 91 с.
20. Головкин В.А. Нейронные сети: обучение, организация и применение. Кн. 4. – М.: ИПРЖР, 2001. – 256 с.
21. Graupe D. Principles of Artificial Neural Networks / 3rd Ed. – World Scientific, 2013. – 363 p.
22. Филатова Т.В. Применение нейронных сетей для аппроксимации данных // Вестник Томского государственного университета. 2004. № 284. С. 121 – 125.

Поступила в редакцию 25 сентября 2019 г.
После доработки 30 октября 2019 г.
Принята к публикации 23 января 2020 г.

IZVESTIYA VUZOV. CHERNAYA METALLURGIYA = IZVESTIYA. FERROUS METALLURGY. 2020. VOL. 63. NO. 1, PP. 78–83.

NEURAL NETWORK APPROACH TO FORECASTING THE COST OF FERROALLOY PRODUCTS

D.V. Sirotin

Institute of Economics, UB RAS, Ekaterinburg, Russia

Abstract. The article notes the increasing role of ferroalloy sub-sector in the qualitative development of metallurgy. Progress predicts of modern metallurgy are difficult in the context of increasing risks of global economic development. The high volatility of domestic producers' prices for the main ferroalloys also has a negative impact. It is necessary to develop methodological tools for forecasting changes in market prices for metallurgical products with a high degree of accuracy. One of the important areas of application in metallurgy forecasting tools is construction of a model for forecasting the cost of ferroalloy products. It is the main purpose of the study. On the example of constructing a forecast model for changing the price of ferrosilicon, relevance of the neural network approach to forecasting the cost of ferroalloy products was substantiated. As part of the tasks of industry development, the capabilities of neural networks have been poorly studied to date. Formal description of the time series forecasting model based on neural networks is given. When constructing neural networks, any time series problem is represented as a multidimensional regression problem. The main parameters of predictive networks training are highlighted. The average price of ferrosilicon on the Russian market and the prices in the Russian regions were used as input variables. The networks that meet the qualitative criteria of forecasting models were trained. Selection of the networks was carried out taking into account the results of graphical analysis and cross-checking. A neural network model was constructed to predict the change in ferrosilicon price in the short term with high accuracy. This model can be useful in strategic decisions justifying in the activities of industry research institutes and metallurgical enterprises.

Keywords: metallurgy, ferroalloy production, ferrosilicon, neural network, modeling, time series forecasting, price.

DOI: 10.17073/0368-0797-2020-1-78-83

REFERENCES

1. Galkin M.P., Brodov A.A. Modern requirements for the production of special steels and alloys. *Sbornik trudov XV mezhdunarodnogo kongressa staleplavil'shchikov, 15-19 oktyabrya 2018, Moskva* [Proc. of the 15th Int. Congress of Steelmakers, October 15-19, 2018, Moscow]. Moscow: Assotsiatsiya staleplavil'shchikov, 2018, pp. 23–26. (In Russ.).
2. Katunin V.V., Petrakova T.M., Ivanova I.M. Key performance indicators of the Russian steel industry in 2018. *Chernaya metallurgiya. Byul. in-ta "Chermetinformatsiya".* 2019, no. 3, pp. 293–314. (In Russ.).
3. Zhuchkov V.I., Leont'ev L.I., Dashevskii V.Ya. State and development of ferroalloys metallurgy in Russia. In: *Perspektivy razvitiya metallurgii i mashinostroeniya s ispol'zovaniem zavershennykh fundamental'nykh issledovaniy i NIOKR: FERROSPRAY: Trudy nauchno-prakticheskoi konferentsii s mezhdunarodnym uchastiem, 29 oktyabrya – 2 noyabrya 2018, Ekaterinburg* [Prospects for the Development of Metallurgy and Mechanical Engineering using Completed Fundamental Research and R&D: FERROALLOYS: Proc. of Sci. and Pract. Conf. with Int. Participation, 29 October – 2 November, 2018, Ekaterinburg]. Ekaterinburg: Al'fa Print, 2018, pp. 12–20. (In Russ.).
4. Glaz'ev S.Yu. *Ryvok v budushchee. Rossiya v novykh tekhnologicheskoy i mirokhozyaistvennom ukkladakh* [Jerk into the future. Russia in new technological and world economic structures]. Moscow: Knizhnyi mir, 2018, 768 p. (In Russ.).
5. Perez K. Technological revolutions and the role of government in unleashing golden ages. *Journal of Globalization Studies.* 2012, vol. 3, no. 2, pp. 19–25.
6. Romanova O.A., Sirotin D.V. Metallurgical complex of Central Urals in the conditions of development under Industry 4.0: The road map for repositioning the complex. *Studies on Russian Economic Development.* 2019, vol. 30, no. 2, pp. 136–145.
7. Adno Yu.L. 2018 results: Challenges and contradictions of economic development. *Chernye metally.* 2019, no. 7, pp. 73–82. (In Russ.).
8. Cubadda G., Guardabascio B. Representation, estimation and forecasting of the multivariate index-augmented autoregressive model. *Int. J. Forecast.* 2018, vol. 35, no. 1, pp. 67–79.
9. Sirotin D.V. Spatial integration analysis of metal production markets. *Izvestiya. Ferrous Metallurgy.* 2017, vol. 60, no. 1, pp. 74–79. (In Russ.).
10. Pradhan R.P., Kumar R. Forecasting exchange rate in India: An application of artificial neural network model. *Journal of Mathematics Research.* 2010, vol. 2, no. 4, pp. 111–117.
11. Yildiz B., Yalama A., Coskun M. Forecasting the Istanbul Stock Exchange National 100 Index using an artificial neural network. *An International Journal of Science, Engineering and Technology.* 2008, vol. 46, pp. 36–39.
12. Catalao J. etc. An artificial neural network approach for day-ahead electricity prices forecasting. In: *6th WSEAS Int. Conf. on Neural Networks, USA, Stevens Point.* 2005, pp. 80–83.
13. Widrow B., Hoff M.E. Adaptive switching circuits. In: *1960 IRE WESCON. N.Y., 1960*, pp. 96–104.
14. Minsky M.L., Papert S.S. *Perceptrons: An Introduction to Computational Geometry.* MIT Press, Cambridge, MA, 1969, 258 p.

15. McCulloch W.S., Pitts W.A. A logical calculus of the ideas immanent in nervous activity. *Bull. Math. Biophys.* 1943, vol. 5, pp. 115–133.
16. Rozenblatt F. Analytical methods for analysis of neural networks. *Zarubezhnaya radioelektronika*. 1965, no. 5, pp. 40–45. (In Russ.).
17. Hebb D.O. *The Organization of Behavior: A Neuropsychological Theory*. New-York: John Wiley & Sons, Inc., 1949, 335 p.
18. Hopfield J. Neural networks and physical system with emergent collective computational properties. In: *Proc. of the National Academy of Sciences of the USA*. 1982, vol. 79, no. 8, pp. 2554–2558.
19. Romanova O.A., Sirotnin D.V. *Metodologicheskii podkhod k otsenke perepozitsionirovaniya metallurgicheskogo kompleksa regiona* [Methodological approach to repositioning assessment of the region metallurgical complex]. Ekaterinburg: Institut ekonomiki UrO RAN, 2017, 91 p. (In Russ.).
20. Golovko V.A. *Neironnye seti: obuchenie, organizatsiya i primeneniye: kn. 4* [Neural networks: training, organization and application: Book 4]. Moscow: Radiotekhnika, 2001, 256 p. (In Russ.).
21. Graupe D. *Principles of Artificial Neural Networks*. 3rd Ed. World Scientific, 2013, 363 p.
22. Filatova T.V. Use of neural networks for data approximation. *Vestnik Tomskogo gosudarstvennogo universiteta*. 2004, no. 284, pp. 121–125. (In Russ.).

Acknowledgements. The article was prepared in accordance with the Research Plan of the Laboratory for Modeling the Spatial Development of Territories of the Institute of Economics of the Ural Branch of the Russian Academy of Sciences for 2019.

Information about the author:

D.V. Sirotnin, *Cand. Sci. (Economics)*, Research Associate of the Laboratory for Modeling the Spatial Development of Territories (sirotind.umk@mail.ru)

Received September 25, 2019

Revised October 30, 2019

Accepted January 23, 2020
