

КЛАСТЕРНЫЙ АНАЛИЗ И НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ДИНАМИКИ ИНДЕКСА ПРОМЫШЛЕННОГО ПРОИЗВОДСТВА ОБРАБАТЫВАЮЩЕЙ ПРОМЫШЛЕННОСТИ РОССИИ*

Павел Борисович БОЛДЫРЕВСКИЙ^{a,*}, Андрей Константинович ИГОШЕВ^b, Людмила Анатольевна КИСТАНОВА^c

^a доктор физико-математических наук, профессор, заведующий кафедрой математических и естественнонаучных дисциплин, Национальный исследовательский Нижегородский государственный университет им. Н.И. Лобачевского (ННГУ), Нижний Новгород, Российская Федерация
b Pavel2@rambler.ru
ORCID: отсутствует
SPIN-код: 7004-7809

^b кандидат экономических наук, доцент кафедры экономики фирмы, Национальный исследовательский Нижегородский государственный университет им. Н.И. Лобачевского (ННГУ), Нижний Новгород, Российская Федерация
a kigoshev@iee.unn.ru
ORCID: отсутствует
SPIN-код: 9016-3628

^c старший преподаватель кафедры математических и естественнонаучных дисциплин, Национальный исследовательский Нижегородский государственный университет им. Н.И. Лобачевского (ННГУ), Нижний Новгород, Российская Федерация
lakistanova@mail.ru
ORCID: отсутствует
SPIN-код: 2835-1795

* Ответственный автор

История статьи:

Reg. № 606/2019
Получена 16.09.2019
Получена в доработанном виде 25.09.2019
Одобрена 11.10.2019
Доступна онлайн 29.11.2019

УДК 005.342
JEL: C02, C22, O13

Ключевые слова:

обрабатывающие производства, кластерный анализ, нейронные сети

Аннотация

Предмет. Обеспечение конкурентоспособности и экономической устойчивости предприятий российской промышленности обуславливает необходимость совершенствования и поиска новых форм и методов оценки всех сторон их деятельности.

Цели. Построение математических моделей пространственных данных и временных рядов индекса промышленного производства, позволяющих проводить анализ и прогнозирование динамики развития определенных секторов экономики РФ.

Методология. Для реализации поставленных целей использовались многомерные статистические методы кластерного анализа и нейросетевого моделирования. Информационной базой для разработки моделей динамики индекса производства обрабатывающей промышленности послужили статистические данные Федеральной службы государственной статистики с 1999 по 2016 г.

Результаты. Выполнена многомерная классификация субъектов Федерации по индексу производства предприятий обрабатывающей промышленности с использованием инструментов кластерного анализа. Предложена методика анализа и прогнозирования показателей индекса промышленного производства, основанная на применении искусственных нейронных сетей. Средняя ошибка прогнозирования при нейросетевом моделировании не превышала 0,08%.

Выводы. В результате классификации промышленных предприятий по значениям индекса промышленного производства выявлены два кластера, имеющие различные показатели устойчивости к изменению внешних факторов. Показана перспективность применения и приведены результаты нейросетевого моделирования прогнозных значений индекса промышленного производства для субъектов Федерации.

© Издательский дом ФИНАНСЫ и КРЕДИТ, 2019

Для цитирования: Болдыревский П.Б., Игошев А.К., Кистанова Л.А. Кластерный анализ и нейросетевое моделирование динамики индекса промышленного производства обрабатывающей промышленности России // *Экономический анализ: теория и практика*. – 2019. – Т. 18, № 11. – С. 2158 – 2171. <https://doi.org/10.24891/ea.18.11.2158>

Значение обрабатывающего сектора в промышленности достаточно велико, так как развитый сектор говорит о высоком уровне производственных технологий.

Обрабатывающая промышленность обеспечивает рост производительности труда, инноваций и международной торговли. В России более 60% всего промышленного выпуска продукции приходится на обрабатывающие производства, ведущая роль которых определяется тем, что они обеспечивают все отрасли экономики орудиями труда, новыми материалами, технологиями, являются наиболее активными драйверами научно-технологического прогресса и расширенного воспроизводства в целом [1, 2].

Основной характеристикой промышленного производства является индекс промышленного производства (ИПП). Анализ временных рядов ИПП по видам экономической деятельности показывает, что наиболее значительный отклик на временные изменения наблюдается для обрабатывающих производств Российской Федерации. Неустойчивость и колебания значений ИПП обрабатывающих производств объясняются высокой чувствительностью основных экономических показателей к фазам делового цикла [3].

На современном этапе анализа экономических систем представляют интерес процессы моделирования, направленные на выявление характерных закономерностей во временной динамике индекса производства обрабатывающей промышленности и обеспечивающие возможности его прогнозирования [2]. Для рассмотрения подобных задач в рамках данной статьи были проведены исследования временных рядов ИПП обрабатывающей промышленности для субъектов Российской Федерации. Информационной базой для проведения

исследований послужили данные Федеральной службы государственной статистики по ИПП, отнесенные к виду экономической деятельности «обрабатывающие производства» по субъектам Российской Федерации (в процентах к предыдущему году) с 1999 по 2016 г.

Как метод исследования использовался кластерный анализ, который наиболее достоверно отражает черты многомерной группировки и классификации [4–6]. Для анализа использовался метод классификации К-средних (K-means) с применением пакета прикладных программ MATLAB [7, 8].

Рассмотрим результаты исследований, приведенные в *табл. 1* и на *рис. 1*. Заметим, что 2002 г. был выведен из выборки ввиду значительного разброса данных, поэтому количество переменных равно 17. Количество субъектов, состоящих из областей, краев, республик составило 81 (отдельные субъекты были удалены из выборки ввиду не полностью представленного ряда).

Выполним кластеризацию по субъектам Российской Федерации. Массив данных при этом разбился на два кластера: в первый кластер вошли субъекты, имеющие более высокие значения дисперсии временных рядов ИПП; второй кластер имеет меньший разброс диапазона данных, то есть является более устойчивым к изменениям внешних факторов (*табл. 1*). Представленные результаты отражают факт значительного снижения ИПП обрабатывающих производств в кризисном 2009 г. как для первого, так и для второго кластеров.

Перечислим некоторых представителей первого кластера, составляющих его ядро (в скобках приведены номера субъектов Федерации в массиве данных): Республика Татарстан (44), Новосибирская область (70), Рязанская область (12), Липецкая область (9), Республика Башкортостан (41), Смоленская

* Статья подготовлена при финансовой поддержке РФФИ. Грант № 17-06-00089 А.

область (13), Ярославская область (17), Псковская область (27), Свердловская область (56), Костромская область (7), Волгоградская область (33), Ивановская область (5), Новгородская область (26), Челябинская область (60), Тамбовская область (14), Алтайский край (65), Нижегородская область (49), Хабаровский край (76). Очевидно, что промышленно развитые субъекты Федерации сильно зависят от снабжения комплектующими, сырьем необходимого качества и, конечно, от рынков сбыта, что в условиях кризиса и стагнации не достигает необходимого уровня.

Представители второго кластера оказались более устойчивыми к внешним изменениям. К ним относятся Омская область (71), Вологодская область (22), Иркутская область (68), Красноярский край (67), Курская область (8), Мурманская область (25), Томская область (72), Республика Коми (20), Ленинградская область (24), Республика Марий Эл (42), Санкт-Петербург (28), Камчатский край (74), Тюменская область (57), Республика Тыва (63), Москва (18), Чукотский автономный округ (81).

Более наглядно динамика ИПП по кластерам представлена на *рис. 1*.

Кластерный анализ показывает высокую нелинейность и неоднородность массивов группируемых данных, что затрудняет проведение дальнейших исследований на базе функциональных и математико-статистических (эконометрических) моделей, позволяющих оценивать взаимодействие ограниченного числа случайных факторов [9, 10]. Для более полного исследования ситуации в обрабатывающих производствах возникает потребность в осуществлении прогноза индекса производства по виду экономической деятельности «обрабатывающие производства» по субъектам Российской Федерации¹ (в процентах к предыдущему году) на последующие годы. Для повышения эффективности исследования нами были использованы методики нейросетевого

моделирования, которые не требуют стандартной математической формализации.

Следует заметить, что на современном этапе исследования сложных экономических систем подобные задачи, связанные с применением искусственных нейронных сетей и имитационного моделирования, представляются весьма актуальными. Очевидно, что разработка специальных компьютерных программ будет способствовать все более широкому внедрению этих методов в практические исследования современных социально-экономических процессов.

Создание моделей на основе искусственных нейронных сетей включает в себя следующие этапы:

- формирование пространства признаков;
- получение таблицы данных;
- установление нейронной сети;
- обучение модели сети;
- отладка обученной модели;
- проверка работоспособности нейронной сети на реальных данных.

Доказано, что при анализе сложных динамических систем нейронные сети обладают более значительными потенциальными возможностями по сравнению с традиционными математическими моделями и вместе с этим дают наилучшие результаты при изучении и прогнозировании стационарных и нестационарных временных рядов, содержащих тренд, сезонную и циклическую составляющие [11, 12]. К самому сложному и основополагающему этапу в работе с нейронными сетями относится их обучение [13]. Обучение нейронной сети заключается в многократном введении данных на вход сети. Нейронная сеть распознает значения выходных данных, сравнивает их с предложенными, сформулированными в виде правильного ответа, и в случае неправильного ответа выполняет необходимую корректировку сети. Такой процесс воспроизводится многократно для каждого

¹ Индекс производства. URL: http://www.gks.ru/free_doc/new_site/business/prom/ind_obr.xls

набора данных. Оценка выходных данных нейронной сети определяется точностью соответствия. Считается, что обучение сети выполнено достаточно эффективно, если она дает правильный ответ в 90% случаев.

Из разнообразного количества систем разработок нейроприложений с нашей точки зрения можно выделить систему Matlab, которая имеет весьма удобный GUI-интерфейс. Воспользуемся GUI-интерфейсом, в состав которого входит инструментальное средство NNTool. При помощи команды NNTool вызовем окно Network/Data Manager (управление сетью/данными) и осуществим последующие действия по формированию входов (Inputs) и целей (Targets) нейронной сети, по созданию новой сети (New Network), по выбору типа нейронной сети (нами выбрана двухслойная нейронная сеть) и по открытию окна процесса обучения (Train). Далее откроем окно Network для просмотра, активации, моделирования обучения и адаптации сети [14, 15].

Модельная нейронная сеть представляет собой двухслойный перцептрон, схема которого представлена на *рис. 2*. Здесь b – это множество входов, w – множество весов, знак «+» – сумматор. Данная сеть состоит из 17 входов, двух выходов и двух слоев, в каждом слое функция активации и количество нейронов различны. В первом слое количество нейронов равно 12. Во втором слое количество нейронов – 2.

Нейроны первого слоя настроены на гиперболическую функцию активации вида

$$\text{tansig}(n) = \frac{2}{1 + \exp(-2n)} - 1. \quad (1)$$

Нейроны второго слоя имеют линейную функцию активации, которая не изменяет выходной сигнал и имеет вид

$$\text{purelin}(nY) = n.$$

Построенная сеть обучается методом обратного распространения ошибки (Back Propagation) [16]. Для построения модели воспользуемся одним из самых быстрых методов обучения – методом Левенберга –

Марквардта [17, 18]. Результаты самого процесса и результаты обучения, происходящие в диалоговом окне, представлены на *рис. 2*.

Обучение произошло достаточно быстро, но его результаты показали относительно низкий коэффициент корреляции ($R = 0,85$). Для сравнения выполним построение другой модели на основе алгоритма Байесовской регуляризации [19, 20], которая функционирует немного медленнее, но более точно. Регрессия в этом случае имеет коэффициент корреляции, равный 0,94. Байесовская регуляризация минимизирует линейную комбинацию квадратичных ошибок и весов. При этом процесс моделирования трансформируется так, что на выходе получается сеть более высокого уровня с обобщающими свойствами. Алгоритм обучения и архитектура сети представлены на *рис. 3*.

Обученную нейронную сеть используем, подавая на вход данные для получения прогноза. Существенным преимуществом использования байесовского подхода при обучении нейронными сетями по сравнению с другими итерационными методами регуляризации является возможность определения ошибки.

Отметим, что при тестировании нейронной сети прогнозировались индексы производства по виду экономической деятельности «обрабатывающие производства» по субъектам Российской Федерации за период с 2017 по 2018 г., которые не принимали участия в обучении сети. Данные по промышленному производству, представленные Федеральной службой государственной статистики, размещены на сайте с учетом новых версий общероссийских классификаторов.

Результаты тестирования обученной нейронной сети для отмеченных субъектов Федерации представлены в *табл. 2*.

Средняя ошибка прогнозирования индекса производства по виду экономической деятельности «обрабатывающие производства» по субъектам Российской Федерации

(в процентах к предыдущему году) в 2017 г. составила 0,0121%, а в 2018 г. – 0,0769%, среднеквадратическая ошибка составила 3,431% в 2017 г. и 2,905% в 2018 г., что является хорошим результатом и пригодным для прогнозирования.

Неоспоримым достоинством нейронной сетевой модели прогнозирования является возможность учитывать достаточно большое количество входных факторов, получая при

этом прогнозные данные с минимальной погрешностью. Следует отметить, что многослойные нейронные сети позволяют осуществить нелинейную аппроксимацию функций с большим количеством переменных, следовательно, целесообразность и перспективность использования метода нейронных сетей при анализе и прогнозировании параметров сложных экономических систем очевидна.

Таблица 1

Описательная статистика для каждого кластера

Table 1

Descriptive statistics for each cluster

Год	Переменная	Описательная статистика для первого кластера (51 субъект)			Описательная статистика для второго кластера (30 субъектов)		
		среднее	несмещенное СКО	несмещенная дисперсия	среднее	несмещенное СКО	несмещенная дисперсия
1999	Var1	119,8569	9,47954	89,8617	101,8433	11,03601	121,7936
2000	Var2	113,7922	10,3039	106,1703	104,19	9,83174	96,663
2001	Var3	110,8706	14,05959	197,6721	106,1233	13,19921	174,2191
2003	Var4	110,3922	10,33804	106,8751	110,3433	18,6248	346,8832
2004	Var5	108,0059	10,56877	111,699	111,6	17,36914	301,6869
2005	Var6	106,9196	6,98272	48,7584	110,8267	15,12705	228,8275
2006	Var7	109,5686	8,77245	76,9558	110,3867	13,63223	185,8378
2007	Var8	110,9706	9,17924	84,2585	104	11,33886	128,5697
2008	Var9	103,3216	7,80175	60,8673	101,8033	7,25071	52,5728
2009	Var10	88,1647	12,33458	152,1419	97,3233	11,67726	136,3584
2010	Var11	114,0667	8,33025	69,3931	106,31	9,39278	88,2244
2011	Var12	114,2471	11,26329	126,8617	103,7333	12,37568	153,1575
2012	Var13	107,5392	7,19016	51,6984	105,5067	7,99116	63,8586
2013	Var14	103,402	6,18804	38,2918	104,9733	13,65925	186,5751
2014	Var15	103,7588	6,93966	48,1589	100,8067	9,67196	93,5469
2015	Var16	102,1039	10,24876	105,0372	101,4333	11,99406	143,8575
2016	Var17	103,6843	7,95081	63,2154	100,2867	10,29388	105,964

Примечание. СКО – среднеквадратическое отклонение.

Источник: авторская разработка

Source: Authoring

Таблица 2

Результаты тестирования обученной сети индекса производства по виду экономической деятельности «обрабатывающие производства» по субъектам Российской Федерации, % к предыдущему году

Table 2

Test results of the trained neural network to predict the industrial production index by type of economic activity Manufacturing for subjects of the Russian Federation, percentage as against the previous year

Субъект Федерации (номер в сети)	Данные Росстата		Прогноз		Ошибка прогноза	
	2017 г.	2018 г.	2017 г.	2018 г.	2017 г.	2018 г.
1. Области						
Белгородская (1)	110,4	106,5	101,325	97,4366	9,075	9,0634
Брянская (2)	106,8	105,7	106,5633	105,581	0,2367	0,119
Владимирская (3)	100	99,1	110,5731	98,2202	-10,5731	0,8798
Воронежская (4)	106,9	107	117,9158	122,6278	-11,0158	-15,6278
Ивановская (5)	105,4	98	105,367	98,0279	0,033	-0,0279
...
Кировская (48)	102,8	105,5	102,5189	105,4894	0,2811	0,0106
Нижегородская (49)	106,1	103,2	105,9741	103,2494	0,1259	-0,0494
...
Амурская (77)	99,3	99,9	99,335	99,9669	-0,035	-0,0669
Магаданская (78)	103,6	118,9	103,5505	118,3251	0,0495	0,5749
Сахалинская (79)	111,6	103,9	111,5788	104,1273	0,0212	-0,2273
Еврейская автономная (80)	117,6	82,8	117,4725	82,8765	0,1275	-0,0765
2. Города						
Москва (18)	101,7	111	101,6833	110,843	0,0167	0,157
Санкт-Петербург (28)	105,8	105,2	105,542	105,4165	0,258	-0,2165
3. Республики						
Карелия (19)	102	107,6	102,0659	107,4552	-0,0659	0,1448
Коми (20)	105,9	98,8	105,8651	99,1994	0,0349	-0,3994
...
Мордовия (43)	112,6	105,6	112,047	105,617	0,553	-0,017
Татарстан (44)	102,9	100,3	103,6144	101,1593	-0,7144	-0,8593
...
Тыва (63)	113,5	101,1	113,3451	101,0494	0,1549	0,0506
Хакасия (64)	100,2	101,4	100,4051	101,3376	-0,2051	0,0624
Саха (Якутия) (73)	97,1	97,5	97,2215	97,5019	-0,1215	-0,0019
4. Края						
Краснодарский (31)	104,5	104,2	104,9978	104,1454	-0,4978	0,0546
Ставропольский (40)	102,3	107,2	102,6157	107,3726	-0,3157	-0,1726
...
Камчатский край (74)	110,4	112,5	102,2447	107,8998	8,1553	4,6002
Приморский (75)	125,6	96,6	125,5478	96,7791	0,0522	-0,1791
Хабаровский край (76)	116,3	98,9	116,0725	98,9901	0,2275	-0,0901
5. Автономные округа						
Ханты-Мансийский (58)	97	98,3	96,995	98,3584	0,005	-0,0584
Ямало-Ненецкий (59)	101,2	99,5	101,2057	99,6289	-0,0057	-0,1289
Чукотский (81)	99,9	75,7	99,9299	75,7553	-0,0299	-0,0553
Среднее значение по массиву	106,568	102,5111	106,5558	102,5881	0,0121	-0,0769

Источник: авторская разработка по данным Росстата; [21]

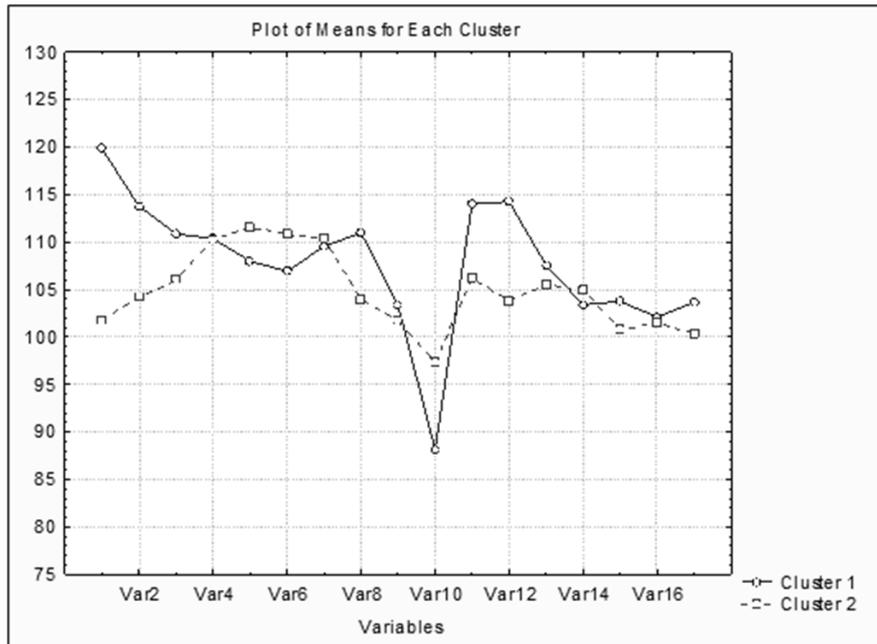
Source: Authoring, based on the Rosstat data; [21]

Рисунок 1

Средние значения переменных в первом и втором кластерах в динамике по годам (1999–2016 гг.)

Figure 1

Average values of variables in the first and second cluster over time (1999–2016)



Источник: авторская разработка

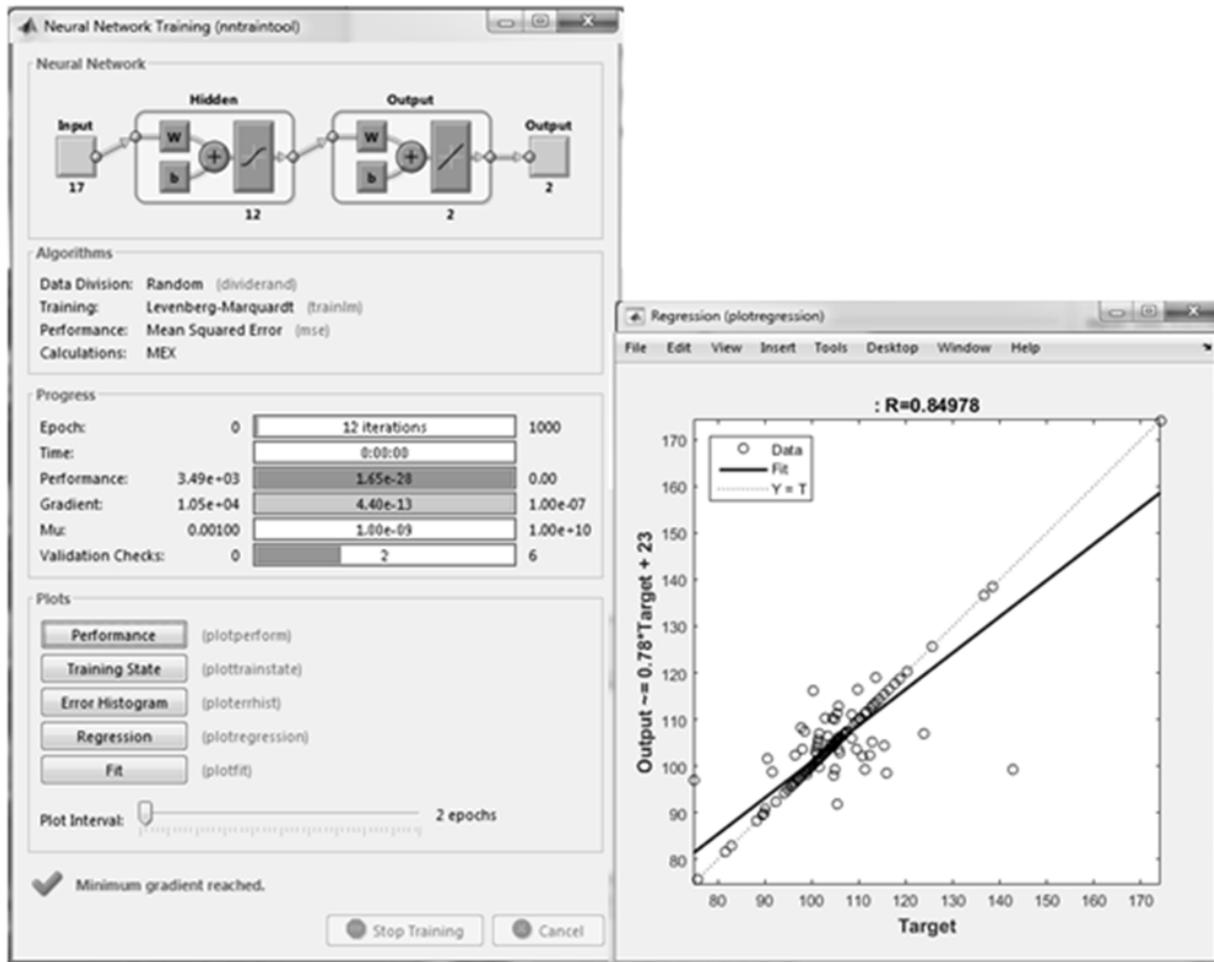
Source: Authoring

Рисунок 2

Диалоговое окно, отображающее: *a* – ход обучения методом Левенберга – Марквардта; *b* – результаты обучения

Figure 2

A dialog box displaying: *a* – the Levenberg–Marquardt training method; *b* – the results of training the neural network



a

b

Источник: авторская разработка

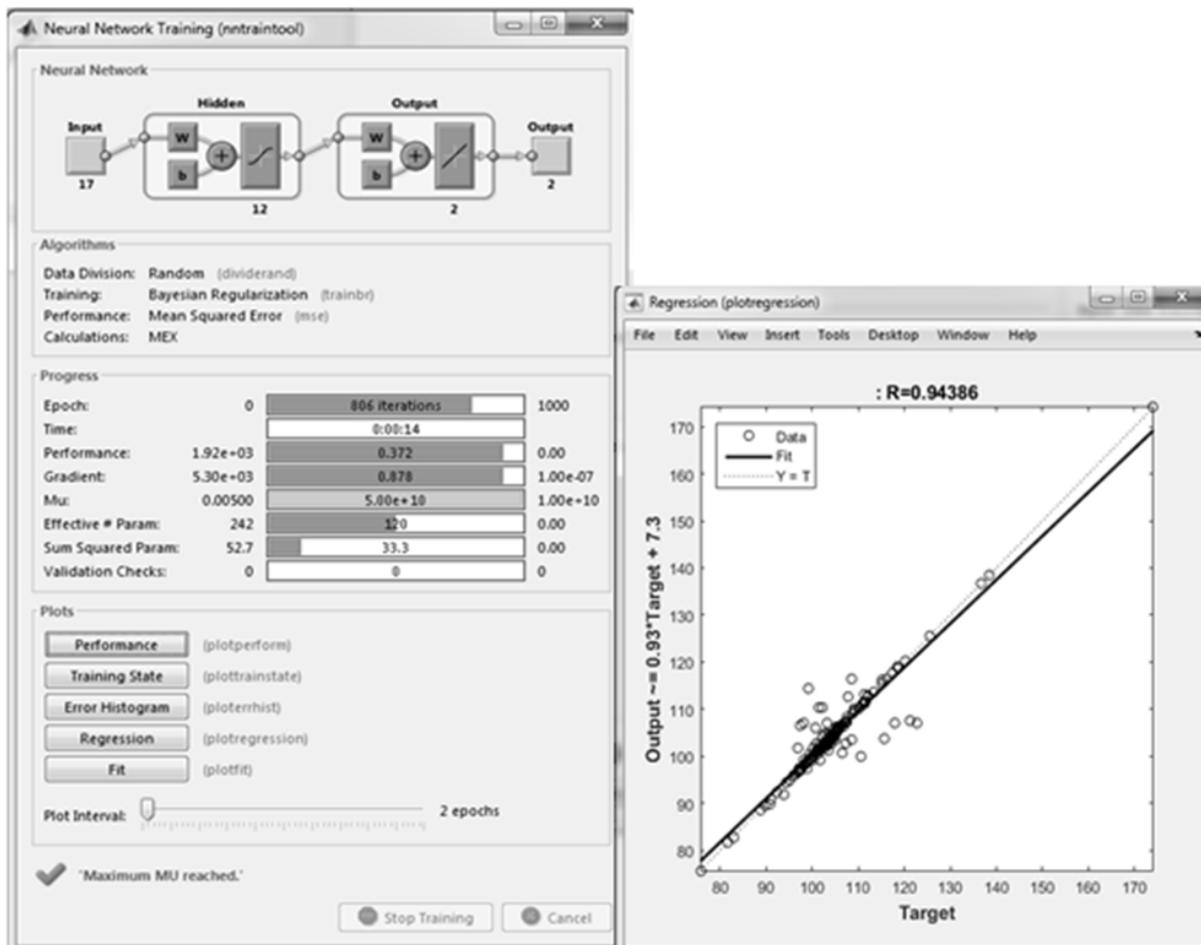
Source: Authoring

Рисунок 3

Диалоговое окно, отображающее: *a* – ход обучения методом байесовской регуляризации; *b* – результаты обучения нейронной сети

Figure 3

A dialog box displaying: *a* – the Bayesian regularization training method; *b* – the results of training the neural network

*a**b*

Источник: авторская разработка

Source: Authoring

Список литературы

1. Палаш С.В. Анализ структурной динамики обрабатывающей промышленности на национальном и региональном уровнях // Научно-технические ведомости Санкт-Петербургского государственного политехнического университета. Экономические науки. 2018. Т. 11. № 1. С. 64–76. URL: <https://doi.org/10.18721/JE.11106>
2. Почукаева О.В. Инновационные факторы развития российской обрабатывающей промышленности // Научные труды. Институт народнохозяйственного прогнозирования РАН. 2012. Вып. 10. С. 257–279. URL: <https://cyberleninka.ru/article/n/innovatsionnye-factory-razvitiya-rossiyskoy-obrabatyvayuschey-promyshlennosti>

3. *Подкорытов В.Н.* Экономические циклы: теоретические выводы или практические результаты? // *Известия Уральского государственного горного университета*. 2014. № 4. С. 63–67. URL: <https://cyberleninka.ru/article/v/ekonomicheskie-tsikly-teoreticheskie-vyvodyili-prakticheskie-rezultaty>
4. *Жамбю М.* Иерархический кластер-анализ и соответствия. М.: Финансы и статистика, 1988. 342 с.
5. *Мандель И.Д.* Кластерный анализ. М.: Финансы и статистика, 1988. 176 с.
6. *Coates A., Ng A.Y.* Learning Feature Representations with K-means. In: *Montavon G., Orr G.B., Müller K-R. Neural Networks: Tricks of the Trade. Lecture Notes in Computer Science*, vol. 7700. Springer-Verlag Berlin Heidelberg, 2012, pp. 561–580.
7. *Балдин А.В., Борисевич В.Б., Нестеренко В.И.* Факторный и кластерный анализ основных показателей производственной деятельности предприятий транспортного комплекса // *Российское предпринимательство*. 2006. № 1. С. 56–58. URL: <https://cyberleninka.ru/article/n/faktornyy-i-klasternyy-analiz-osnovnyh-pokazateley-proizvodstvennoy-deyatelnosti-predpriyatiy-transportnogo-kompleksa>
8. *Белашев Б.З., Долгий К.А.* Применение глобальной оптимизации в кластерном анализе данных // *Труды Карельского научного центра РАН. Сер.: Математическое моделирование и информационные технологии*. 2015. № 10. С. 15–23. URL: <https://cyberleninka.ru/article/v/primenenie-globalnoy-optimizatsii-v-klasternom-analize-dannyh>
9. *Макаров В.Л.* Обзор математических моделей экономики с инновациями // *Экономика и математические методы*. 2009. Т. 45. № 1. С. 3–14.
10. *Болдыревский П.Б., Игошев А.К., Кистанова Л.А.* Анализ основных факторов экономической устойчивости промышленных предприятий России // *Вестник Нижегородского университета им. Н.И. Лобачевского. Сер.: Социальные науки*. 2018. № 1. С. 7–13. URL: <https://cyberleninka.ru/article/v/analiz-osnovnyh-faktorov-ekonomicheskoy-ustoychivosti-promyshlennyh-predpriyatiy-rossii>
11. *Окунь А.С., Окунь С.А.* Нейросетевое моделирование как инструмент прогнозирования // *Финансовая аналитика: проблемы и решения*. 2011. № 33. С. 45–52. URL: <https://cyberleninka.ru/article/n/neyrosetevoe-modelirovanie-kak-instrument-prognozirovaniya>
12. *Калайдин Е.Н., Дюдин М.С.* Нейросетевое моделирование биржевой динамики // *Современная экономика: проблемы и решения*. 2012. № 9. С. 168–176. URL: <https://meps.econ.vsu.ru/meps/article/view/335/1025>
13. *Васенков Д.В.* Методы обучения искусственных нейронных сетей // *Компьютерные инструменты в образовании*. 2007. № 1. С. 20–29. URL: <https://cyberleninka.ru/article/n/metody-obucheniya-iskusstvennyh-neyronnyh-setey>
14. *Семейкин В.Д., Скупченко А.В.* Моделирование искусственных нейронных сетей в среде MATLAB // *Вестник Астраханского государственного технического университета. Сер.: Управление, вычислительная техника и информатика*. 2009. № 1. С. 159–164. URL: <https://cyberleninka.ru/article/n/modelirovanie-iskusstvennyh-neyronnyh-setey-v-srede-matlab>

15. Величко Е.П., Сокольчик П.Ю. Применение нейросетевого регулятора в системах позиционного регулирования // Вестник ПНИПУ. Химическая технология и биотехнология. 2015. № 2. С. 8–19. URL: <https://cyberleninka.ru/article/n/primenenie-neyrosetevogo-regulyatora-v-sistemah-pozitsionnogo-regulirovaniya>
16. Каллан Р. Основные концепции нейронных сетей. М.: Вильямс, 2001. 287 с.
17. Ферцев А.А. Ускорение обучения нейронной сети для распознавания изображений // Вестник Самарского государственного технического университета. Сер.: Физико-математические науки. 2012. № 1. С. 183–191. URL: <https://doi.org/10.14498/vsgtu990>
18. Осовский С. Нейронные сети для обработки информации. М.: Финансы и статистика, 2002. 244 с.
19. MacKay D.J.C. A Practical Bayesian Framework for Backpropagation Networks. *Neural Computation*, 1992, vol. 4, no. 3, pp. 448–472. URL: <https://doi.org/10.1162/neco.1992.4.3.448>
20. Нужный А.С., Шумский С.А. Регуляризация Байеса в задаче аппроксимации функции многих переменных // Математическое моделирование. 2003. Т. 15. № 9. С. 55–63. URL: <http://www.mathnet.ru/links/6e87e44c5b77d7b79081803af3f4ec51/mm397.pdf>
21. Гринчель Б.М., Назарова Е.А. Методы оценки конкурентной привлекательности регионов: монография. СПб.: ГУАП, 2014. 244 с.

Информация о конфликте интересов

Мы, авторы данной статьи, со всей ответственностью заявляем о частичном и полном отсутствии фактического или потенциального конфликта интересов с какой бы то ни было третьей стороной, который может возникнуть вследствие публикации данной статьи. Настоящее заявление относится к проведению научной работы, сбору и обработке данных, написанию и подготовке статьи, принятию решения о публикации рукописи.

CLUSTER ANALYSIS AND NEURAL NETWORK MODELING FOR MOVEMENTS OF INDUSTRIAL PRODUCTION INDEX OF THE RUSSIAN MANUFACTURING INDUSTRY

Pavel B. BOLDYREVSKII ^{a*}, Andrei K. IGOSHEV ^b, Lyudmila A. KISTANOVA ^c

^a National Research Lobachevsky State University of Nizhny Novgorod (UNN),
Nizhny Novgorod, Russian Federation
bpavel2@rambler.ru
ORCID: not available

^b National Research Lobachevsky State University of Nizhny Novgorod (UNN),
Nizhny Novgorod, Russian Federation
akigoshev@iee.unn.ru
ORCID: not available

^c National Research Lobachevsky State University of Nizhny Novgorod (UNN),
Nizhny Novgorod, Russian Federation
lakistanova@mail.ru
ORCID: not available

* Corresponding author

Article history:

Article No. 606/2019
Received 16 September 2019
Received in revised form
25 September 2019
Accepted 11 October 2019
Available online
29 November 2019

JEL classification: C02, C22,
O13

Keywords: manufacturing,
cluster analysis, neural
networks

Abstract

Subject Ensuring the competitiveness and economic sustainability of Russian industrial undertakings necessitates improving of and searching for new forms and methods of assessment of all aspects of their activities. Development of multidimensional statistical methods is an important area to achieve the targets.

Objectives We focus on building mathematical models of spatial data and time series of the industrial production index enabling to analyze and forecast the development of certain sectors of the Russian economy.

Methods The study employs multidimensional statistical methods of cluster analysis and neural network modeling. The statistics of the Federal State Statistics Service from 1999 to 2016 served as the information base for modeling the changes in the manufacturing index.

Results We performed multidimensional classification of the subjects of the Russian Federation by the manufacturing index, using cluster analysis tools. The paper presents the methodology for analyzing and forecasting the industrial production index based on artificial neural networks. The average forecast error in the neural network modeling was at or below 0.08 percent.

Conclusions The classification revealed two clusters with different indicators of resistance to changes in external factors. We demonstrate the potential of the use of neural network modeling for projected values of the industrial production index for the subjects of the Russian Federation, and provide the obtained results.

© Publishing house FINANCE and CREDIT, 2019

Please cite this article as: Boldyrevskii P.B., Igoshev A.K., Kistanova L.A. Cluster Analysis and Neural Network Modeling for Movements of Industrial Production Index of the Russian Manufacturing Industry. *Economic Analysis: Theory and Practice*, 2019, vol. 18, iss. 11, pp. 2158–2171.
<https://doi.org/10.24891/ea.18.11.2158>

Acknowledgments

The article was supported by the Russian Foundation for Basic Research (RFBR), grant № 17-06-00089 A.

References

1. Palash S.V. [Analysis of the structural dynamics in the manufacturing industry at the national and regional levels]. *Nauchno-tekhnicheskie vedomosti Sankt-Peterburgskogo gosudarstvennogo politekhnicheskogo universiteta. Ekonomicheskie nauki = Saint-Petersburg State Polytechnic University Journal. Economics*, 2018, vol. 11, no. 1, pp. 64–76. (In Russ.)
URL: <https://doi.org/10.18721/IE.11106>
2. Pochukaeva O.V. [Innovative factors of Russian manufacturing industry]. *Nauchnye trudy. Institut narodnokhozyaistvennogo prognozirovaniya RAN = Scientific Proceedings: Institute of National Economic Forecasting of RAS*, 2012, iss. 10, pp. 257–279.
URL: <https://cyberleninka.ru/article/n/innovatsionnye-factory-razvitiya-rossiyskoy-obrabatyvayushey-promyshlennosti> (In Russ.)
3. Podkorytov V.N. [Economic cycles: Theoretical conclusions or practical results?]. *Izvestiya Ural'skogo gosudarstvennogo gornogo universiteta = News of the Ural State Mining University*, 2014, no. 4, pp. 63–67. URL: <https://cyberleninka.ru/article/v/ekonomicheskie-tsikly-teoreticheskie-vyvodyili-prakticheskie-rezultaty> (In Russ.)
4. Jambu M. *Ierarkhicheskii klaster-analiz i sootvetstviya* [Classification Automatique Pour L'Analyse des Données]. Moscow, Finansy i statistika Publ., 1988, 342 p.
5. Mandel I.D. *Klasternyi analiz* [Cluster Analysis]. Moscow, Finansy i statistika Publ., 1988, 176 p.
6. Coates A., Ng A.Y. Learning Feature Representations with K-means. In: Montavon G., Orr G.B., Müller K-R. *Neural Networks: Tricks of the Trade. Lecture Notes in Computer Science*, vol. 7700. Springer-Verlag Berlin Heidelberg, 2012, pp. 561–580.
7. Baldin A.V., Borisevich V.B., Nesterenko V.I. [Factor and cluster analysis of the main indicators of production activity of transportation industry enterprises]. *Rossiiskoe predprinimatel'stvo = Russian Journal of Entrepreneurship*, 2006, no. 1, pp. 56–58.
URL: <https://cyberleninka.ru/article/n/fakturnyy-i-klasternyy-analiz-osnovnyh-pokazateley-proizvodstvennoy-deyatelnosti-predpriyatij-transportnogo-kompleksa> (In Russ.)
8. Belashev B.Z., Dolgii K.A. [Application of global optimization in data clustering analysis]. *Trudy Karelskogo nauchnogo tsentra RAN. Ser.: Matematicheskoe modelirovanie i informatsionnye tekhnologii = Transactions of Karelian Research Centre of Russian Academy of Sciences. Mathematical Modeling and Information Technologies*, 2015, no. 10, pp. 15–23.
URL: <https://cyberleninka.ru/article/v/primenenie-globalnoy-optimizatsii-v-klasternom-analize-dannyh> (In Russ.)
9. Makarov V.L. [A review of mathematical models of innovation-driven economy]. *Ekonomika i matematicheskie metody = Economics and Mathematical Methods*, 2009, vol. 45, no. 1, pp. 3–14. (In Russ.)
10. Boldyrevskii P.B., Igoshev A.K., Kistanova L.A. [Analysis of the main factors of economic stability of industrial enterprises in Russia]. *Vestnik Nizhegorodskogo universiteta im. N.I. Lobachevskogo. Ser.: Sotsial'nye nauki = Vestnik of Lobachevsky State University of Nizhni Novgorod. Social Sciences*, 2018, no. 1, pp. 7–13.
URL: <https://cyberleninka.ru/article/v/analiz-osnovnyh-faktorov-ekonomicheskoy-ustoychivosti-promyshlennyh-predpriyatij-rossii> (In Russ.)
11. Okun' A.S., Okun' S.A. [Neural network modeling as a tool for prediction]. *Finansovaya analitika: problemy i resheniya = Financial Analytics: Science and Experience*, 2011, no. 33, pp. 45–52. URL: <https://cyberleninka.ru/article/n/neyrosetevoe-modelirovanie-kak-instrument-prognozirovaniya> (In Russ.)

12. Kalaidin E.N., Dyudin M.S. [Neural Network Modeling of Exchange Dynamics]. *Sovremennaya ekonomika: problemy i resheniya = Modern Economics: Problems and Solutions*, 2012, no. 9, pp. 168–177. URL: <https://meps.econ.vsu.ru/meps/article/view/335/1025> (In Russ.)
13. Vasenkov D.V. [Methods of teaching artificial neural networks]. *Komp'yuternye instrumenty v obrazovanii = Computer Tools in Education Journal*, 2007, no. 1, pp. 20–29. URL: <https://cyberleninka.ru/article/n/metody-obucheniya-iskusstvennyh-neyronnyh-setey> (In Russ.)
14. Semeikin V.D., Skupchenko A.V. [Modelling of Artificial Neural Networks in Matlab Environment]. *Vestnik Astrakhanskogo gosudarstvennogo tekhnicheskogo universiteta. Ser.: Upravlenie, vychislitel'naya tekhnika i informatika = Vestnik of Astrakhan State Technical University. Series: Management, Computer Science and Informatics*, 2009, no. 1, pp. 159–164. URL: <https://cyberleninka.ru/article/n/modelirovanie-iskusstvennyh-neyronnyh-setey-v-srede-matlab> (In Russ.)
15. Velichko E.P., Sokol'chik P.Yu. [Neural network controllers in the system position control]. *Vestnik PNIPU. Khimicheskaya tekhnologiya i biotekhnologiya = PNRPU Bulletin. Chemical Technology and Biotechnology*, 2015, no. 2, pp. 8–19. URL: <https://cyberleninka.ru/article/n/primenenie-neyrosetevogo-regulyatora-v-sistemah-pozitsionnogo-regulirovaniya> (In Russ.)
16. Kallan R. *Osnovnye kontseptsii neyronnykh setei* [Basic Concepts of Neural Networks]. Moscow, Vil'yams Publ., 2001, 287 p.
17. Fertsev A.A. [Neural network training acceleration using nvidia cuda technology for image recognition]. *Vestnik Samarskogo gosudarstvennogo tekhnicheskogo universiteta. Ser.: Fiziko-matematicheskie nauki = Journal of Samara State Technical University, Series Physical and Mathematical Sciences*, 2012, no. 1, pp. 183–191. (In Russ.) URL: <https://doi.org/10.14498/vsgtu990>
18. Osovskii S. *Neironnye seti dlya obrabotki informatsii* [Neural networks for information processing]. Moscow, Finansy i statistika Publ., 2002, 244 p.
19. MacKay D.J.C. A Practical Bayesian Framework for Backpropagation Networks. *Neural Computation*, 1992, vol. 4, no. 3, pp. 448–472. URL: <https://doi.org/10.1162/neco.1992.4.3.448>
20. Nuzhnyi A.S., Shumskii S.A. [The Bayes regularization in the problem of function of many variables approximation]. *Matematicheskoe modelirovanie = Mathematical Models and Computer Simulations*, 2003, vol. 15, no. 9, pp. 55–63. URL: <http://www.mathnet.ru/links/6e87e44c5b77d7b79081803af3f4ec51/mm397.pdf> (In Russ.)
21. Grinchel' B.M., Nazarova E.A. *Metody otsenki konkurentnoi privlekatel'nosti regionov: monografiya* [Methods for assessing the competitive attractiveness of regions: a monograph]. St. Petersburg, SUAI Publ., 2014, 244 p.

Conflict-of-interest notification

We, the authors of this article, bindingly and explicitly declare of the partial and total lack of actual or potential conflict of interest with any other third party whatsoever, which may arise as a result of the publication of this article. This statement relates to the study, data collection and interpretation, writing and preparation of the article, and the decision to submit the manuscript for publication.