

Перспективы применения искусственных нейронных сетей для прогнозирования объемов грузоперевозок в транспортных системах

Цель исследования — выявить перспективы применения нейросетевого подхода применительно к задачам экономического прогнозирования транспортно-логистических показателей, в частности объемов грузовых перевозок в транспортной системе разнотипных региональных грузопотоков, а также обосновать эффективность применения искусственных нейронных сетей (ИНС) в сравнении с эффективностью традиционных экстраполятивных методов прогнозирования. Возможность прогноза с использованием ИНС для данных экономических показателей рассматривается авторами не как альтернатива традиционным методам статистического прогнозирования, а как одно из доступных простых средств для решения сложных задач.

Материалы и методы. При прогнозировании ИНС использовались три метода обучения: 1) алгоритм Левенберга-Марквардта — обучение сети останавливается, когда обобщение перестает улучшаться, что показывает увеличение средней квадратичной ошибки выходного значения; 2) метод регуляризации Байеса — обучение сети останавливается в соответствии с минимизацией адаптивных весовых коэффициентов; 3) метод масштабированных сопряженных градиентов, который используется для нахождения локального экстремума функции на основе информации о её значениях и градиенте. При прогнозировании использован пакет *Neural Network Toolbox* — нейросетевая модель состоит из скрытого слоя нейронов с сигмоидальной функцией активации и выходного нейрона с линейной функцией активации, на вход подаются значения временных динамических рядов, с выхода снимается прогнозируемое значение. Для более объективной оценки эффективности и перспектив применения ИНС результаты прогноза представлены в сравнении с результатами, полученными при прогнозировании методом экспоненциального сглаживания.

Результаты. При прогнозировании объемов грузовых перевозок железнодорожным транспортом получены удовлетворительные показатели верификации прогнозирования как методом экспоненциального сглаживания, так и ИНС, хотя нейронная сеть показала лучший результат (средняя относительная ошибка прогноза — 8,97% для ИНС и 11,21% для МЭС соответственно). Это объясняется тем, что временной динамический ряд значений объемов грузоперевозок данным видом транспорта, за исследуемый отчетный период, имеет пусть и нелинейный, но равномерно меняющийся характер. В случае прогнозирования объемов грузоперевозок автомобильным транспортом временной динамический ряд исходных значений за отчетный период имеет одновременно и нелинейный, и неравномерный меняющийся характер. Этим объясняется большие значения ошибок прогнозирования методом экспоненциального сглаживания (средняя относительная ошибка прогноза 47,47% для МЭС); ошибка прогноза с применением ИНС составила — 13,97%, следовательно результаты прогнозирования, полученные методом экспоненциального сглаживания, признаем неудовлетворительными, а для ИНС — удовлетворительными.

Заключение. Результаты исследования подтверждают целесообразность применения обучаемых искусственных нейронных сетей при прогнозировании объемов грузовых перевозок с разнотипными грузопотоками, исходные статистические данные которых имеют неравномерный нелинейно меняющийся характер во временном динамическом ряду. Достаточно высокая верификация при применении ИНС для сложнопрогнозируемых показателей транспортного процесса подтверждает практическое значение применения данного метода при моделировании транспортно-логистической сети.

Ключевые слова: статистический прогноз, обучаемые искусственные нейронные сети, метод экспоненциального сглаживания.

Dinar T. Yakupov, Oksana N. Rozhko

KNRTU-KAI, Kazan, Russia

Prospects of application of artificial neural networks for forecasting of cargo transportation volume in transport systems

The purpose of research — to identify the prospects for the use of neural network approach in relation to the tasks of economic forecasting of logistics performance, in particular of volume freight traffic in the transport system promiscuous regional freight traffic, as well as to substantiate the effectiveness of the use of artificial neural networks (ANN), as compared with the efficiency of traditional extrapolative methods of forecasting. The authors consider the possibility of forecasting to use ANN for these economic indicators not as an alternative to the traditional methods of statistical forecasting, but as one of the available simple means for solving complex problems.

Materials and methods. When predicting the ANN, three methods of learning were used: 1) the Levenberg-Marquardt algorithm-network training stops when the generalization ceases to improve, which is shown by the increase in the mean square error of the output value; 2) Bayes regularization method - network training is stopped in accordance with the minimization of adaptive weights; 3) the method of scaled conjugate gradients, which is used to find the local extremum of a function on the basis of information about its values and gradient. The Neural Network Toolbox package is used for forecasting. The neural network model consists of a hidden layer of neurons with a sigmoidal activation function and an output neuron with a linear

activation function, the input values of the dynamic time series, and the predicted value is removed from the output. For a more objective assessment of the prospects of the ANN application, the results of the forecast are presented in comparison with the results obtained in predicting the method of exponential smoothing.

Results. When predicting the volumes of freight transportation by rail, satisfactory indicators of the verification of forecasting by both the method of exponential smoothing and ANN had been obtained, although the neural network showed the best result (the average relative forecast error was 8.97% for ANN and 11.21% for the method of exponential smoothing, respectively). This can be explained by the fact that the temporal dynamic range of the values of the volumes of cargo transportation by this type of transport, for the period under review, has a nonlinear but uniformly changing character. In the case of forecasting the volumes of cargo transportation by road, the time series of initial values for the reporting period is simultaneously non-linear and unevenly changing.

This explains the large values of forecasting errors by the method of exponential smoothing (the average relative forecast error of 47.47% for methods of exponential smoothing); the forecast error with ANN was 13.97%, therefore the results of the prediction obtained by the method of exponential smoothing are considered unsatisfactory, and for ANN – satisfactory.

The conclusion. The results of the study confirm the feasibility of using trained artificial neural networks in forecasting the volumes of freight traffic with different cargo flows that have the initial statistical data of which have an uneven nonlinearly changing character in the time dynamic series. A sufficiently high verification in the application of ANN for difficult-to-forecast indicators of the transport process confirms the practical significance of the application of this method in the modeling of the logistics network.

Keywords: statistical forecast, exponential smoothing trained, artificial neural network.

1. Введение

Традиционно основными методами прогнозирования временных рядов являются статистические экстраполятивные методы, однако связанные с этими методами математические модели не всегда линейны, и следовательно прогнозирования сложных процессов, в которых модель данных может быть нелинейной весьма затруднительно. В таких случаях решить проблему получения достоверного прогноза можно при помощи аппарата искусственных нейронных сетей (ИНС), позволяющих моделировать разного рода зависимости, в основе которых могут быть линейные модели, обобщенно линейные модели и нелинейные модели [1,2]. Именно способность ИНС к обобщению и выделению скрытых зависимостей между входными и выходными данными лежит в основе получения достоверных статистических прогнозов.

На сегодняшний день ИНС — одна из перспективных информационно-вычислительных технологий в исследовании динамических систем в области экономики, позволяющая внедрять основанные на методах искусственного интеллекта статистические средства поддержки принятия управленческих решений. Согласно [3,4] применение ИНС оправдано в случаях, когда ре-

шение задач прогнозирования затруднено большими объемами входной информации либо данные неполны или избыточны, «зашумлены» и частично противоречивы. Именно такой исходный ряд данных может лежать в основе задач прогнозирования объемов грузовых перевозок.

В случае, когда экономическое развитие прогнозируемых показателей непрерывно и прогноз может быть простой экстраполяцией на основании оценки прошлых показателей деятельности логистических систем и их трендов, переносимых в будущее, объемы грузовых перевозок обычно прогнозируются с применением экстраполятивных методов, надежно зарекомендовавших себя на уровне прогнозов в определенных горизонтах сложившихся цепей поставок производственных предприятий, торговых и транспортно-экспедиционных компаний. Однако, при прогнозировании объемов грузовых перевозок на уровне федеральных либо региональной транспортно-логистических сетей с разноструктурными грузопотоками, в том числе транзитными, логистических процесс объединяет в себе два способа развития — гладкий и скачкообразный, создавая сценарий будущего из сочетания различных вариантов развития выбранных показателей, наиболее достоверным является прогноз, основанный на мето-

де обучаемых искусственных нейронных сетей.

Необходимость использования ИНС при прогнозировании данных экономических показателей перевозок обуславливается вовсе не тем, чтобы заменить традиционные методы. ИНС — это еще одно из возможных простых средств для решения задач, и цель данной статьи — показать, в какой мере нейросетевой подход может быть применен к задачам экономического прогнозирования транспортно-логистических показателей и попытаться обосновать перспективы и эффективность применения ИНС в сравнении с эффективностью других методов прогнозирования. Как отмечено в работах [5, 6] основными экстраполятивными методами статистического прогнозирования объемов грузовых перевозок традиционно являются: метод экспоненциального сглаживания, метод наименьших квадратов, анализ динамических рядов и другие, основанные на выявлении тенденции (характеристик тенденции) на периоде ретроспекции с предположением, что действующие на периоде ретроспекции факторы сохраняются и по своему наличию, и по своей интенсивности проявления, и для периода упрещения. Однако для таких столь труднопрогнозируемых, динамично изменяющихся показателей как объемы перевозок всех

производственных, торговых, транзитных и других грузов в рамках региона в целом, получить достоверные результаты прогноза, даже краткосрочного, довольно сложно, учитывая неравномерность грузопотоков во времени и пространстве, следовательно, возникает необходимость в их доступной верификации, которая может быть косвенно проведена при сравнении результатов прогнозирования по нескольким методам [7, 8]. Даже в этом случае прямой верификацией можно считать только сравнение разработанных прогнозов с практическими данными, которые будут получены только по окончании периода упреждения [8, 9]. Поэтому было принято решение о прогнозировании двумя методами, один из которых традиционный, метод экспоненциального сглаживания, а другой, не столь часто применяемый для прогноза объемов грузоперевозок, количественные показатели которых имеют нелинейный характер изменения во временном динамическом ряду, метод обучаемых ИНС.

2. Прогнозирование значений объемов грузоперевозок

Выполненное статистическое прогнозирование является неотъемлемой частью реализуемого в настоящее время, крупного проекта - совершенствование транспортно-логис-

тической сети Республики Татарстан. В рамках проекта рабочей группой разрабатывается методический подход, позволяющий оптимизировать процессы организации и управления региональными грузовыми перевозками через создание опорной сети логистических объектов, различных классов и назначения, на основе оценки логистического потенциала муниципальных районов региона. Для объективной оценки изменения динамики грузопотоков, а также перспектив развития сети необходимо выполнить прогнозирование ряда критериальных показателей логистического потенциала, а именно, объемов грузовых перевозок наземными видами транспорта административно-территориальных единиц (районов) республики, учитывая нестабильную динамику экономического развития региона был установлен трехлетний период прогнозирования.

2.1. Постановка задачи

1) Имеется временной динамический ряд (ВДР) значений объемов грузоперевозок железнодорожным (ж/д) транспортом по 11 районам на 2007–2016 гг. (табл. 1). Необходимо спрогнозировать значения на следующие 3 года (2017–2019 гг.).

2) Имеется временной динамический ряд (ВДР) значений объемов грузоперевозок

автотранспортом по 16 районам на 2007–2016гг. (табл. 2). Необходимо спрогнозировать значения на следующие 3 года (2017–2019 гг.).

2.2. Критерии оценки качества прогноза

Для оценки точности моделей прогнозирования, полученных различными методами, используются следующие критерии [10]:

1. MAE (Mean Absolute Error) – средняя абсолютная ошибка:

$$MAE = \frac{1}{n} \cdot \sum_i^n |y_i - f_i|,$$

где y_i – фактическое значение,
 f_i – спрогнозированное значение,
 n – размер горизонта прогнозирования.

2. MAPE (Mean Absolute Percentage Error) – средняя относительная ошибка прогноза:

$$MAPE = \frac{1}{n} \cdot \sum_i^n \frac{|y_i - f_i|}{y_i} \cdot 100\%$$

3. MSE (Mean Square Error) – среднеквадратическая ошибка:

$$MSE = \frac{1}{n} \cdot \sum_i^n (y_i - f_i)^2,$$

4. S_{cm}/\bar{y} – отношение стандартной ошибки к среднему значению:

$$\frac{S_{cm}}{\bar{y}} = \sqrt{\frac{\sum_i^n (y_i - f_i)^2}{n \cdot (n-1)}} \Big/ \frac{\sum_i^n y_i}{n} \cdot 100\%.$$

Модель прогнозирования считаем удовлетворительной,

Таблица 1

Объем грузоперевозок железнодорожным транспортом по 11 районам на 2007–2016 гг., тыс. т.

Год / Район	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016
Тукаевский	1356,4	1512,5	1143,2	1286,9	1052,92	1462,39	1406,14	1407,4	1416,1	1401
Нижнекамский	1091	890,9	702,3	592,4	652,14	905,75	870,91	871,91	870,91	859,6
Альметьевский	652,3	623,1	385,2	411,4	479,15	665,49	639,89	625,3	639,89	602,8
Высокогорский	546,8	526,7	452,9	394,5	354,5	492,36	493,42	487,01	473,42	478,3
Менделеевский	632,5	586,4	410,6	398,3	439,45	610,34	591,3	587,36	586,87	563,6
Зеленодольский	652,9	598,2	245,2	256,3	226,32	314,34	302,25	432,25	602,25	557,8
Бугульминский	1192,3	998,2	876,7	884,2	890,87	909,83	884,84	882,32	874,84	866,4
Елабужский	378,5	296,2	390,9	325,9	390,87	237,32	189,73	189,73	250,13	272,6
Бавлинский	32,1	27,6	13,2	18	10	25,25	25,25	25,12	24,28	23,9
Лениногорский	705,3	557,2	235,6	229,3	188,2	524,9	514,23	505,71	504,71	500,4
Зайнский	421,7	327	261,2	254,7	190	261,39	263,52	257,6	251,34	282,4

Объем грузоперевозок автомобильным транспортом по 16 районам на 2007–2016 гг., тыс. т.

Район \ Год	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016
Тукаевский	1761,7	1349,8	2152,3	1978,9	2082,9	1883,4	1996	2667,9	2349,8	2965,4
Нижнекамский	1450,3	1377,9	711,2	2858,7	2334,8	2019,8	1892,2	1960,9	2752,6	1638,6
Альметьевский	1385,4	1236,5	939,6	10283,2	9288,9	8537,7	8831,8	4220	8939,6	4645,6
Высокогорский	2792,4	2261,1	2190,4	1016,6	530,1	649,2	823,8	844,2	823,8	846,6
Лаишевский	1118,1	1108,2	535	514,9	619,6	787,8	671,7	749,8	617,7	796,9
Менделеевский	752,5	690,5	762,1	745,1	680,9	258,8	122,8	77,4	122,5	75,7
Мамадышский	1089,4	947,9	714,8	617	1231,7	1609,7	1359,2	1117,4	1231,7	874,3
Зеленодольский	1986,8	2189,1	1925,7	2269,6	2166,7	1670	1247,1	1390,4	2096,6	1641,1
Бугульминский	591,6	764,4	704,4	1164	1342,1	1638	1919,6	2019,7	1616,6	1423,9
Елабужский	2150	4130	2280	2180	2497,3	3014,2	3522	1268,2	1160,7	1063,6
Бавлинский	1250	916	790	1266	1372,2	1321,9	1124,5	745,9	806,7	709,1
Чистопольский	1090,4	1064,1	1096	1490,7	1550	1532,2	1421,7	1293,9	1522,6	1160,1
Мензелинский	478,8	627,7	470,1	301,8	322,1	182,9	171,2	60,6	301,8	197,9
Лениногорский	534,4	607,1	630,8	1199,1	1223,8	2018,4	2029,1	2278,8	1223,8	2375
Заинский	1852,1	2871,7	1795	1222,7	1222,4	537,7	471,5	398,4	354	335,2
Пестречинский	772,2	730,6	570,1	469,8	492,9	494,6	419,4	293,8	419,4	234,3

если значение S_{cm}/\bar{y} данной модели не превышает 5%.

3. Методы прогнозирования

Для выполнения прогноза использованы метод экспоненциального сглаживания (МЭС) и метод ИНС.

3.1. Метод экспоненциального сглаживания

Экспоненциальное сглаживание – один из простейших и распространенных приемов выравнивания ряда.

Экспоненциальное сглаживание можно представить, как фильтр, на вход которого последовательно поступают члены исходного ряда, а на выходе формируются текущие значения экспоненциальной средней [5].

Последовательность вычислений описана ниже.

Вычисляется m сглаженных значений:

$$\bar{y}_i = \begin{cases} y_1 & : i = 1 \\ \alpha \cdot y_i + (1 - \alpha) \cdot \bar{y}_{i-1} & : i > 1 \end{cases} \quad (1)$$

где \bar{y}_i – сглаженный ряд,
 y_i – исходный ряд,
 α – коэффициент сглаживания,
 i – номер компонента ВДР.

От величины α зависит, как быстро снижается вес влияния

предшествующих наблюдений. Чем больше α , тем меньше сказывается влияние предшествующих лет. Если значение α близко к единице, то это приводит к учету при прогнозе в основном влияния лишь последних наблюдений. Если значение α близко к нулю, то веса, по которым взвешиваются уровни временного ряда, убывают медленно, т.е. при прогнозе учитываются все (или почти все) прошлые наблюдения [5].

Коэффициент α выбран в диапазоне (0;1) с шагом 0,1.

Вычисляется цепной годовой прирост за период m лет:

$$y_{ceppr} = (y_m - y_1)/(m-1). \quad (2)$$

Выполняется прогнозирование $(i + 1)$ -ого значения:

$$\bar{y}_{i+1} = \alpha \cdot (\bar{y}_i + y_{ceppr}) + (1 - \alpha) \cdot \bar{y}_{i-1}, \quad (3)$$

а также $(i + 2...k)$ -ых значений (k – период упреждения, в данной работе $k = 3$);

4. Вычисляются MAE, MAPE, MSE, S_{cm}/\bar{y} .

5. То значение параметра α , при котором ошибка MAPE модели наименьшая, используется для прогнозирования на следующие 3 года.

3.2. Искусственные нейронные сети

Искусственная нейронная сеть (ИНС) – математическая

модель, а также её программное или аппаратное воплощение, построенная по принципу организации и функционирования биологических нейронных сетей – сетей нервных клеток живого организма [1].

В общем виде процесс построения нейросетевой модели прогнозирования имеет итерационный характер и состоит из нескольких этапов [1]:

1. Выбор архитектуры нейронной сети в соответствии с вектором входных и выходных значений.

2. Обучение сети.

3. Тестирование сети.

4. Оценка результатов.

Для прогнозирования использован пакет Neural Network Toolbox программной среды MATLAB. Нейросетевая модель состоит из скрытого слоя нейронов с сигмоидальной функцией активации и выходного нейрона с линейной функцией активации. На вход подаются значения ВДР за четыре предшествующих периода ($y_i; y_{i-1}; y_{i-2}; y_{i-3}$) и информация ($c_1; c_2; c_3; c_4$) о районе, для которого производятся вычисления. Каждому из 16 районов соответствует обозначение, представленное в двоичной системе (0000 – для Тукаевского района, ..., 1111 – для Пестречинского). Каждый

разряд двоичного обозначения района представляется одним входным значением. С выхода снимается прогнозируемое значение Y_{i+1} . Число нейронов N в скрытом слое подбирается экспериментально, согласно эмпирическому условию $N \leq I + O$, где I – число входов сети, O – число выходов.

Структура предлагаемой ИНС-модели приведена на рис. 1, структура нейрона [10] отображена на рис. 2.




Рис. 1. Структура предлагаемой ИНС модели




Рис. 2. Структура нейрона ИНС

Входные сигналы Y_j нейрона k суммируются с учетом соответствующих весов w_{jk} синоптических связей. Выходной сигнал Y_k нейрона определяется при этом зависимостью:

$$Y_k = f(s_k) = f\left(\sum_{j=i}^{i-n} w_{j,k} Y_j + b \cdot w_{b,k}\right) \quad (6)$$

где $b \cdot w_{b,k}$ – пороговое значение.

Функция активации сигмоидального нейрона является непрерывной и выражается в виде логистической сигмоидальной функции:

$$f(s_k) = \frac{1}{1 + e^{-\beta s_k}} \quad (7)$$

где β – параметр крутизны функции активации.

Функция активации выходного нейрона является непрерывной и выражается в виде линейной функции:

$$f(s_k) = c \cdot s_k \quad (8)$$

где c – параметр крутизны функции активации. [1]

Технически обучение ИНС заключается в нахождении коэффициентов w связей между нейронами.

В процессе обучения нейронная сеть способна выявлять сложные зависимости между входными данными и выходными, а также выполнять обобщение. Это значит, что в случае успешного обучения сеть сможет вернуть верный результат на основании данных, которые отсутствовали в обучающей выборке, а также неполных и/или «зашумленных», частично искаженных данных [1,10].

При прогнозировании на искусственных нейронных сетях (ИНС) использовались три следующих метода обучения:

1) Алгоритм Левенберга-Марквардта. Этот алгоритм, как правило, требует больше памяти, но меньше времени. Обучение останавливается, когда обобщение перестает улучшаться, что показывает увеличение средней квадратичной ошибки выходного значения.

2) Метод регуляризации Байеса. Этот алгоритм требует больше времени, но может привести к хорошему обобщению при сложных, малых или шумных наборах данных. Обучение останавливается в соответствии с минимизацией адаптивных весовых коэффициентов.

3) Метод масштабированных сопряженных градиентов. Данный метод используется для нахождения локального экстремума функции на основе информации о её значениях и градиенте, требует меньше времени.

Множество входных значений y_j и ожидаемых на выходе

значений d_j , используемое для тестирования нейронной сети, представляет собой тестовую выборку.

На вход обученной сети подается множество y_j , а с выхода снимаются значения \bar{y}_i , которые сопоставляются с ожидаемыми значениями d_j , на основе чего анализируются показатели точности решения задачи нейронной сетью.

Выбор ИНС-модели, которая будет использована для прогнозирования на следующие три года, производится по наименьшему значению критерия MAPE.

4. Прогнозирование объемов грузоперевозок железнодорожным транспортом

4.1. Прогнозирование методом экспоненциального сглаживания

Для разработки моделей прогнозирования использованы различные значения параметра α (0,1; 0,2;...0,9). Значения объемов грузоперевозок ж/д транспортом за 2007–2013 гг. сглажены и, на основе полученных сглаженных характеристик спрогнозированы значения за 2014–2016 гг. по каждому району. В табл. 3 приведены значения критериев точности полученных моделей. Как видно из таблицы, каждая из моделей показала неплохую точность прогнозирования. При этом наименьшая средняя относительная ошибка (11,21%) соответствует модели с $\alpha = 0,2$. Средняя абсолютная ошибка прогноза, полученного данной моделью, составляет 53,38, а значение среднеквадратической ошибки равно 5310,43. Отношение стандартной ошибки к среднему значению составило 2,22%, что дает основание считать модель адекватной. Данную модель будем использовать для прогнозирования объемов грузоперевозок ж/д транспортом на 2017–2019 гг.

Таблица 3

Значения критериев точности полученных моделей

α	MAE	MAPE	MSE	S_{cm}/\bar{y}
0,1	65,35	14,55	7060,56	2,56
0,2	53,38	11,21	5310,43	2,22
0,3	62,05	12,72	7384,53	2,61
0,4	63,40	13,13	9136,66	2,91
0,5	62,95	13,34	9931,11	3,03
0,6	60,30	13,00	10276,95	3,08
0,7	57,28	12,51	10756,70	3,16
0,8	57,56	12,46	11707,68	3,29
0,9	62,68	13,56	13262,04	3,50




Рис. 3. Гистограмма ошибок обучения сети net22

Таблица 4

Результаты обучения ИНС различными методами

Сеть	Структура	Метод обучения	MAE	MAPE	MSE	S_{cm}/\bar{y}
net2	(8;6;1)	Метод Левенберга-Марквардта	48,80	11,03	5142,27	2,18
net10	(8;7;1)		48,62	11,66	5240,51	2,20
net22	(8;8;1)		40,97	8,97	4641,09	2,07
net39	(8;9;1)		44,50	12,53	4613,36	2,07
net91	(8;6;1)	Метод регуляризации Байеса	48,08	14,55	5992,06	2,35
net45	(8;7;1)		44,95	13,68	5589,09	2,27
net59	(8;8;1)		46,60	11,71	6209,72	2,40
net82	(8;9;1)		45,93	12,50	6881,20	2,52
net63	(8;6;1)	Метод масштабированных сопряженных градиентов	41,62	9,13	6798,84	2,51
net6	(8;7;1)		60,31	10,88	8095,85	2,74
net19	(8;8;1)		63,74	13,16	8275,93	2,77
net38	(8;9;1)		61,10	12,78	7505,67	2,64




Рис. 4. Линейная регрессия результатов обучения сети net22

4.2. Прогнозирование с помощью ИНС

Прогнозирование проводилось с использованием пакета Neural Network Toolbox программной среды Matlab. Исходное множество данных разделено на подмножества: обучающая выборка (70%), тестовая выборка (валидационная выборка (15%) и проверочная выборка (15%)). Рассмотрены ИНС с 6, 7, 8 и 9 нейронами в скрытом слое, обученные разными методами (табл. 4).

Как видно из таблицы, критерий MAPE варьируется от 8,97 у сети net22 до 14,55 у сети net91, что говорит о хорошей точности прогнозирования всех ИНС-моделей. Таким образом, наибольшей точностью прогнозирования обладает сеть net22 со структурой (8;8;1) – 8 входов, 8 нейронов

в скрытом слое, 1 нейрон в выходном слое – обученная методом Левенберга-Марквардта. MAE прогнозирования данной моделью составляет 40,97, а MSE = 4641,09. Отношение стандартной ошибки к среднему значению составило 2,07%, что дает основание считать модель адекватной. Данную модель будем использовать для прогнозирования объемов грузоперевозок ж/д-транспортом на 2017–2019 гг.

На рис. 3 приведена гистограмма ошибок обучения сети net22, которая показывает, на каком числе примеров

(Instances) модель дает ту или иную погрешность (разность между целевым значением и выходом сети).

На рис. 4 показан график линейной регрессии результатов обучения сети net22, рассчитан коэффициент корреляции $R = 0,98799$, и выведено уравнение регрессии: $Output = 0,97 \cdot Target + 14$. Из рис. видно, что сеть неплохо аппроксимирует функцию.

4.3. Результаты прогнозирования объемов грузоперевозок ж/д транспортом

Временной динамический ряд значений объемов грузоперевозок ж/д транспортом за 2007–2016 гг. имеет равномерный нелинейно меняющийся

Таблица 5

Показатели точности лучших моделей МЭС и ИНС

Модель	MAE	MAPE	MSE	S_{cm}/\bar{y}
МЭС ($\alpha = 0,2$)	53,38	11,21	5310,43	2,22
net22	40,97	8,97	4641,09	2,07




Рис. 5. Величина средних относительных ошибок моделей, основанных на МЭC и ИНС.

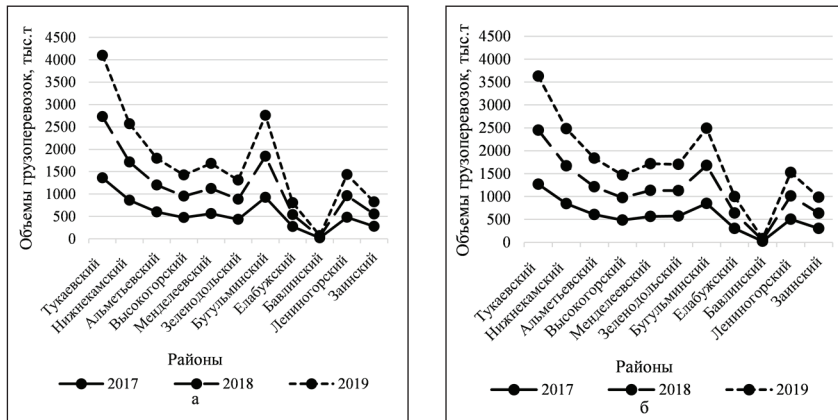


Рис. 6. Графики с накоплением прогнозных значений грузоперевозок ж/д транспортом: а) МЭC ($\alpha = 0,2$); б) net22.

характер. В целом, получены неплохие показатели точности прогнозирования как методом экспоненциального сглаживания, так и ИНС. ИНС показала лучший результат (средняя относительная ошибка прогноза – 8,97% для ИНС и 11,21% для МЭC. Спрогнозированные результаты, полученные обоими методами, признаем удовлетворительными. Пока-

затели точности лучших моделей МЭC и ИНС приведены в табл. 5.

На рис. 5 представлены гистограммы средних относительных ошибок моделей, основанных на МЭC и ИНС.

На рисунке 6 показаны графики с накоплением прогнозных значений грузоперевозок ж/д транспортом, полученных моделями МЭC и net22.

В таблице 6 приведены значения исходного ряда и спрогнозированные методом экспоненциального сглаживания и искусственными нейронными сетями.

5. Прогнозирование объемов грузоперевозок автотранспортом

5.1. Прогнозирование методом экспоненциального сглаживания

Для разработки моделей прогнозирования использованы различные значения параметра α (0,1; 0,2;...0,9). Значения объемов грузоперевозок автотранспортом за 2007–2013 гг. сглажены и, на основе полученных сглаженных характеристик спрогнозированы значения за 2014–2016 гг. по каждому району. В табл. 7 приведены значения критериев точности полученных моделей. Как видно из таблицы, каждая из моделей показала низкую точность прогнозирования. При этом наименьшая средняя относительная ошибка (47,47%) соответствует модели с $\alpha = 0,5$. Средняя абсолютная ошибка прогноза, полученного данной моделью, составляет 571,33, а значение среднеквадратической ошибки равно 996683,30. Отношение стандартной ошибки к среднему значению составило 9,60%,

Таблица 6

Значения исходного ряда и спрогнозированные с применением ИНС и МЭC (ж/д транспорт)

№ п/п	Район \ Год	Объемы перевозок железнодорожным транспортом, тыс. т															
		Исходные значения									Спрогнозированные значения						
		2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2017	2018	2019
1	Тукаевский	1356,4	1512,5	1143,2	1286,9	1052,9	1462,3	1406,1	1407,1	1416,1	1401,1	1363,0	1368,6	1365,7	1269,4	1180	1180
2	Нижнекамский	1091	890,9	702,3	592,4	652,1	905,7	870,9	871,9	870,9	859,6	859,7	857,3	851,9	845,1	827,6	810,7
3	Альметьевский	652,3	623,1	385,2	411,4	479,1	665,4	639,8	625,3	639,8	602,8	599,8	600,0	599,4	606,2	607,2	625,2
4	Высокогорский	546,8	526,7	452,9	394,5	354,5	492,3	493,4	487,0	473,4	478,3	476,9	476,5	475,0	484,6	491,3	492,8
5	Менделеевский	632,5	586,4	410,6	398,3	439,4	610,3	591,3	587,3	586,8	563,6	562,5	562,2	561,1	565,7	570,6	581,1
6	Зеленодольский	652,9	598,2	245,2	256,3	226,3	314,3	302,2	432,2	602,2	557,8	436,2	448,5	427,0	575	556,7	573,3
7	Бугульминский	1192,3	998,2	876,7	884,2	890,8	909,8	884,8	882,3	874,8	866,4	928,1	916,5	915,5	849,7	830,2	809,6
8	Елабужский	378,5	296,2	390,9	325,9	390,8	237,3	189,7	189,7	250,1	272,6	272,2	270,2	265,5	305,1	335,6	358,5
9	Бавлинский	32,1	27,6	13,2	18	10	25,2	25,2	25,1	24,2	23,9	23,7	23,6	23,5	25,5	27,1	29,1
10	Лениногорский	705,3	557,2	235,6	229,3	188,2	524,9	514,2	505,7	504,7	500,4	480,1	480,7	473,9	505,3	508,5	511,7
11	Зайнский	421,7	327	261,2	254,7	190	261,3	263,5	257,6	251,3	282,4	277,1	276,1	271,6	305,6	329,4	351

Таблица 7

Значения критериев точности моделей прогнозирования

α	MAE	MAPE	MSE	S_{cm}/\bar{y}
0,1	959,86	126,84	3141269,89	17,05
0,2	770,77	102,59	2085091,75	13,89
0,3	644,33	83,39	1512982,26	11,83
0,4	571,29	68,94	1212518,24	10,59
0,5	571,33	47,47	996683,30	9,60
0,6	563,60	51,88	1004381,70	9,64
0,7	564,18	59,59	1064698,78	9,93
0,8	599,22	52,45	1023555,16	9,73
0,9	633,38	58,96	1076252,06	9,98




Рис. 7. Гистограмма ошибок обучения сети net31

Таблица 8

Результаты обучения ИНС различными методами

Сеть	Структура	Метод обучения	MAE	MAPE	MSE	
net20	(8;6;1)	Метод Левенберга-Марквардта	216,87	25,03	119062,87	3,52
net4	(8;7;1)		212,53	23,46	99372,21	3,21
net8	(8;8;1)		196,38	23,45	108634,86	3,36
net16	(8;9;1)		222,66	31,67	111836,47	3,41
net27	(8;6;1)	Метод регуляризации Байеса	166,42	19,86	59548,45	2,49
net29	(8;7;1)		127,40	15,78	33444,26	1,86
net30	(8;8;1)		125,13	16,10	30866,07	1,79
net31	(8;9;1)		127,09	13,97	34274,97	1,89
net32	(8;6;1)	Метод масштабированных сопряженных градиентов	380,44	31,97	526712,18	7,40
net35	(8;7;1)		471,43	44,88	559684,91	7,62
net36	(8;8;1)		393,55	37,56	376308,40	6,25
net38	(8;9;1)		391,62	36,54	460802,88	6,92




Рис. 8. График линейной регрессии результатов обучения сети net31

что не дает основание считать модель адекватной. Данную модель, как наиболее точную среди всех, будем использовать для прогнозирования объемов грузоперевозок автотранспортом на 2017–2019 гг.

5.2. Прогнозирование с помощью ИНС

Прогнозирование проводилось с использованием пакета Neural Network Toolbox программной среды Matlab. Исходное множество данных разделено на подмножества: обучающая выборка (70%), тестовая выборка (валидационная выборка (15%) и проверочная выборка (15%)). Рассмотрены ИНС с 6, 7, 8 и 9 нейронами в скрытом слое, обученные разными методами (табл. 8).

Как видно из таблицы, критерий MAPE варьируется от

13,97 у сети net31 до 44,88 у сети net35, что говорит о неспособности некоторых из ИНС-моделей к прогнозированию с требуемой точностью. Таким образом, наибольшей точностью прогнозирования обладает сеть net31 со структурой (8;9;1) – 8 входов, 9 нейронов в скрытом слое, 1 нейрон в выходном слое – обученная методом регуляризации Байеса. MAE прогнозирования данной моделью составляет 127,09, а MSE = 34274,97. Отношение стандартной ошибки к среднему значению составило 1,89%, что дает основание считать модель адекватной. Данную модель будем использовать для прогнозирования объемов грузоперевозок автотранспортом на 2017–2019 гг.

На рис. 7 приведена гистограмма ошибок обучения сети net31, которая показыва-

ет, на каком числе примеров (Instances) модель дает ту или иную погрешность (разность между целевым значением и выходом сети).

На рис. 8 показан график линейной регрессии результатов обучения сети net31, рассчитан коэффициент корреляции $R = 0,99762$, и выведено уравнение регрессии: $Output = 0,99 \cdot Target + 9$. Из рис. видно, что сеть хорошо аппроксимирует функцию.

5.3. Результаты прогнозирования объемов грузоперевозок автомобильным транспортом

Временной динамический ряд значений объемов грузоперевозок автотранспортом за 2013–2015 гг. имеет неравномерный нелинейно меняющийся характер. Этим объясняются большие значения ошибок прогнозирования методом эк-

Таблица 9

Показатели точности лучших моделей МЭС и ИНС

Модель	MAE	MAPE	MSE	S_{cm}/\bar{y}
МЭС ($\alpha = 0,5$)	571,33	47,47	996683,30	9,60
Net31	127,09	13,97	34274,97	1,89




Рис. 9. Гистограммы средних относительных ошибок моделей, основанных на МЭС и ИНС

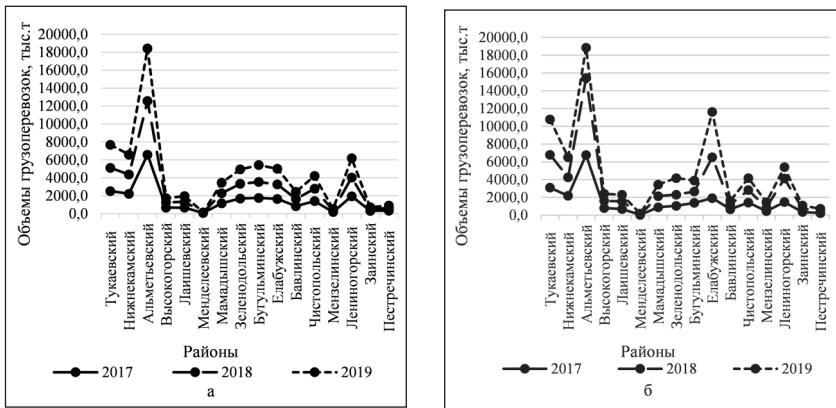


Рис. 10. Графики с накоплением прогнозных значений грузоперевозок автотранспортом: а) МЭС ($\alpha = 0,5$); б) net31

споненциального сглаживания (средняя относительная ошибка прогноза – 13,97% для ИНС и 47,47% для МЭС соответственно). Спрогнозированные результаты, полученные методом экспоненциального сглаживания, признаем неудовлетворительными. Спрогнозированные результаты, полученные ИНС – удовлетворительны. Показатели точности лучших моделей МЭС и ИНС приведены в табл. 9.

На рис. 9 показаны гистограммы средних относительных ошибок моделей, основанных на МЭС и ИНС.

На рис. 10 показаны графики с накоплением прогнозных значений грузоперевозок автотранспортом, полученных моделями, а) МЭС ($\alpha = 0,5$) и б) net31.

В табл. 10 приведены значения исходного ряда и спрогнозированные методом экспоненциального сглаживания и искусственными нейронными сетями.

6. Заключение

Задача исследования носила сложный постановочный характер – составить средне-

Таблица 10

Значения исходного ряда и спрогнозированные с применением ИНС и МЭС (автотранспорт)

№ п/п	Район \ Год	Объемы перевозок автомобильным транспортом, тыс.т															
		Исходные значения										Спрогнозированные значения					
		2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	МЭС	ИНС	МЭС	ИНС	МЭС	ИНС
1	Тукаевский	1761,7	1349,8	2152,3	1978,9	2082,9	1883,4	1996	2667,9	2349,8	2965,4	2511,4	2600,1	2575,3	3086,6	3704,1	3983,8
2	Нижнекамский	1450,3	1377,9	711,2	2858,7	2334,8	2019,8	1892,2	1960,9	2752,6	1638,6	2219,1	2146,9	2219,8	2177,4	2072,2	2261,1
3	Альметьевский	1385,4	1236,5	939,6	10283,2	9288,9	8537,7	8831,8	4220	8939,6	4645,6	6584,8	5982,5	5865,1	6770,2	8659,2	3408,0
4	Высокогорский	2792,4	2261,1	2190,4	1016,6	530,1	649,2	823,8	844,2	823,8	846,6	674,5	593,8	470,1	795,6	810,4	802,2
5	Лаишевский	1118,1	1108,2	535	514,9	619,6	787,8	671,7	749,8	617,7	796,9	664,4	661,7	625,8	686,9	863,2	747,5
6	Менделеевский	752,5	690,5	762,1	745,1	680,9	258,8	122,8	77,4	122,5	75,7	83,9	47,6	13,3	31,8	25,8	115,0
7	Мамадышский	1089,4	947,9	714,8	617	1231,7	1609,7	1359,2	1117,4	1231,7	874,3	1161,6	1128,7	1167,6	889,2	1255,2	1298,6
8	Зеленодольский	1986,8	2189,1	1925,7	2269,6	2166,7	1670	1247,1	1390,4	2096,6	1641,1	1691,7	1642,1	1605,3	1052,1	1252,3	1868,0
9	Бугульминский	591,6	764,4	704,4	1164	1342,1	1638	1919,6	2019,7	1616,6	1423,9	1761,5	1779,0	1880,9	1378,2	1277,7	1239,2
10	Елабужский	2150	4130	2280	2180	2497,3	3014,2	3522	1268,2	1160,7	1063,6	1640,6	1620,7	1745,0	1914,0	4612,4	5097,4
11	Бавлинский	1250	916	790	1266	1372,2	1321,9	1124,5	745,9	806,7	709,1	834,5	806,7	810,1	669,7	524,6	434,0
12	Чистопольский	1090,4	1064,1	1096	1490,7	1550	1532,2	1421,7	1293,9	1522,6	1160,1	1402,9	1380,8	1419,4	1420,8	1398,5	1357,5
13	Мензелинский	478,8	627,7	470,1	301,8	322,1	182,9	171,2	60,6	301,8	197,9	190,1	174,3	156,6	453,4	388,4	610,4
14	Лениногорский	534,4	607,1	630,8	1199,1	1223,8	2018,4	2029,1	2278,8	1223,8	2375	1939,1	2094,8	2141,5	1473,6	2644,9	1274,0
15	Заинский	534,4	607,1	630,8	1199,1	1223,8	2018,4	2029,1	2278,8	1223,8	2375	1939,1	2094,8	2141,5	1473,6	2644,9	1274,0
16	Пестречинский	772,2	730,6	570,1	469,8	492,9	494,6	419,4	293,8	419,4	234,3	328,8	293,5	281,8	228,3	328,4	164,8

срочный прогноз на базе временных динамических рядов статистических показателей, имеющих неравномерный нелинейно меняющийся характер. Традиционно объемы грузовых перевозок прогнозировались с применением экстраполятивных методов. Однако, они наиболее надежно зарекомендовали себя на уровне прогнозов логистических систем, имеющих сложившиеся цепи поставок и определенные горизонты их развития, то есть, когда экономическое развитие непрерывно и прогноз может быть простой экстраполяцией на основании оценки прошлых показателей деятельности логистических систем и их трендов, переносимых в будущее. В случае, когда прогнозирование должно объ-

единить в себе два способа развития транспортно-логистических процессов с структурными грузопотоками целых районов — линейный и нелинейный, создавая сценарий будущего из сочетания различных вариантов развития выбранных показателей традиционные методы недостаточно эффективны, поэтому для прогнозирования нами предложен метод обучаемых искусственных нейронных сетей, положительно зарекомендовавший себя в как в прогнозировании транспортно-логистических процессов [7,8,11], так и в целом при решении подобных сложных экономических задач прогнозирования [12-25]. Полученные результаты подтверждают целесообразность применения обучаемых искус-

ственных нейронных сетей в случае труднопрогнозируемых показателей на основании имеющегося временного динамического ряда неравномерного нелинейно меняющегося характера, апробированного при составлении статистических прогнозов различных экономических систем рядом исследователей [12-25]. В рамках разрабатываемого проекта совершенствования транспортно-логистической инфраструктуры региона, представленные результаты имеют прямое практическое значения для проведения дальнейшего исследования грузопотоков, необходимы при выборе типа, класса и размера производственных мощностей логистических объектов в разрабатываемой модели сети и мест их расположения

Литература

1. *Осовский, С.* Нейронные сети для обработки информации. Пер. с польского И.Д. Рудинского. М.: Финансы и статистика, 2004. 344 с.
2. *Koskela T.* Neural network methods in analyzing and modelling time varying processes Espoo, 2003. pp. 1–72. URL: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.77.5993> (paid access to article).
3. *Тадеусевич Р., Боровик Б., Гончаж Т., Лепер Б.* Элементарное введение в технологию нейронных сетей с примерами программ. Пер. с польск. И.Д. Рудинского. М.: Горячая линия Телеком, 2011. 408 с.
4. *Федоров Е.Е.* Искусственные нейронные сети. Красноармейск: ДВНЗ «ДонНТУ», 2016. 338 с.
5. *Меркулова Ю.В.* Ситуационно-стратегическое планирование в экономике: монография в 2-х томах. Т. 2. Моделирование оптимальных стратегий и программ. М.: Экономика, 2015. 464 с.
6. *Владимирова Л.П.* Прогнозирование и планирование в условиях рынка. М.: Дашков и К, 2012. 308 с.
7. *Pamula T.* Neural networks in transportation research recent applications // Transport problems Vol. 11, Issue 2, pp. 27–36. 2016. URL: http://transportproblems.polsl.pl/pl/Archiwum/2016/zeszyt2/2016t11z2_03.pdf.
8. *Gosasang V., Chandraprakaikul W., Kiattisin S.* An Application of Neural Networks for Forecasting Container Throughput at Bangkok Port // Proceedings of the World Congress on

References

1. *Osovskiy, S.* Neyronnye seti dlya obrabotki informatsii. Per. s pol'skogo I.D. Rudinskogo. Moscow: Finansy i statistika, 2004. 344 p. (In Russ.)
2. *Koskela T.* Neural network methods in analyzing and modelling time varying processes Espoo, 2003. pp. 1–72. URL: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.77.5993> (paid access to article).
3. *Tadeusevich R., Borovik B., Gonchazh T., Leper B.* Elementarnoe vvedenie v tekhnologiyu neyronnykh setey s primerami programm. Per. s pol'sk. I.D. Rudinskogo. Moscow: Goryachaya liniya Telekom, 2011. 408 p. (In Russ.)
4. *Fedorov E.E.* Iskusstvennyye neyronnye seti. Krasnoarmeysk: DVNZ «DonNTU», 2016. 338 p. (In Russ.)
5. *Merkulova Yu.V.* Situatsionno-strategicheskoe planirovanie v ekonomike: monografiya v 2-kh tomakh. Vol. 2. Modelirovanie optimal'nykh strategiy i programm. Moscow: Ekonomika, 2015. 464 p. (In Russ.)
6. *Vladimirova L.P.* Prognozirovanie i planirovanie v usloviyakh rynka. Moscow: Dashkov i K, 2012. 308 p. (In Russ.)
7. *Pamula T.* Neural networks in transportation research recent applications. Transport problems Vol. 11, Issue 2, pp. 27–36. 2016. URL: http://transportproblems.polsl.pl/pl/Archiwum/2016/zeszyt2/2016t11z2_03.pdf.
8. *Gosasang V., Chandraprakaikul W., Kiattisin S.* An Application of Neural Networks for Forecasting Container Throughput at Bangkok Port. Proceedings of the World Congress on En-gineer-

Engi-neering. Vol 1, WCE 2010, June 30 July 2, 2010, London, U.K. URL: http://www.iaeng.org/publication/WCE2010/WCE2010_pp137-141.pdf

9. *Schmidhuber, J.* Deep learning in neural networks: An overview // *Neural Networks*. Vol. 61. P. 85–117. 2015. URL: <http://www.sciencedirect.com/science/article/pii/S0893608014002135> (paid access to article).

10. *Wasserman P.D.* Advanced methods in neural computing. New York: Van Nostran Reinhold, 1993. 240 p.

11. *Костина Л.Н., Гареева Г.А.* Нейронные сети в задачах прогнозирования временных рядов // *Международный журнал «Инновационная наука»*. 6. 2015. С. 70–73.

12. *Jiang C. and Song F.* Sunspot Forecasting by Using Chaotic Time-series Analysis and NARX Network // *JCP*. 2011. 6(7). P. 1424–1429. URL: http://journaldatabase.info/articles/sunspot_forecasting_by_using_chaotic.html (paid article).

13. *Zhang X. and Frey R.* Improving ARMAGARCH forecasts for high frequency data with regime-switching ARMA-GARCH // *Journal of Computational Analysis & Applications*. 2015. 18(1). URL: <https://www.researchgate.net/publication/228142366>

14. *Kambouroudis D.S., McMillan D.G. and Tsakou K.* Forecasting Stock Return Volatility: A Comparison of GARCH, Implied Volatility, and Realized Volatility Models // *Journal of Futures Markets*. 2016. 36(12). P. 1127–1163. URL: <https://cronfa.swan.ac.uk/Record/cronfa34904> DOI: 10.1002/fut.21783

15. *Домашенко Д.В., Никулин Э.Е.* Прогнозирование рядов динамики рыночных индикаторов на основе нелинейной авторегрессионной нейронной сети // *Статистика и Экономика*. 2017. 3. С. 4-9. DOI: 10.21686/2500-3925-2017-3-4-9

16. *Грачев А.В., Киселева Т.В., Добрынин А.С., Койнов Р.С.* О методе выбора промежуточных узлов передачи данных для маршрутизации в иерархических сетях разной топологии // *Экономика, статистика и информатика*. 2014. № 5. С. 161–164 URL: <https://cyberleninka.ru/article/n/o-metode-vybora-promezhutochnyh-uzlov-peredachi-dannyh-dlya-marshrutizatsii-v-ierarhicheskikh-setyah-raznoy-topologii-1>

17. *Брагина Е.И., Декатов Д.Е., Егорова И.Е.* Разработка методологии поддержки принятия решений в стратегическом управлении предприятием в условиях неопределённости // *Интернет-вестник ВолГАСУ. Серия «Строительная информатика»*. 2013. № 9 (26). С. 1–5. URL: [http://vestnik.vgasu.ru/attachments/DekatoVegorovaBragina1-2013_9\(26\).pdf](http://vestnik.vgasu.ru/attachments/DekatoVegorovaBragina1-2013_9(26).pdf)

18. *Комлева Н.В., Хлопкова О.А.* Обработка контента в информационных средах на основе нейронечеткой модели принятия решений // *Статистика и Экономика*. 2013. № 5. С. 188–192. URL: DOI: 10.21686/2500-3925-2013-5-188-192

ing. Vol 1, WCE 2010, June 30 July 2, 2010, London, U.K. URL: http://www.iaeng.org/publication/WCE2010/WCE2010_pp137-141.pdf

9. *Schmidhuber, J.* Deep learning in neural networks: An overview. *Neural Networks*. Vol. 61. P. 85–117. 2015. URL: <http://www.sciencedirect.com/science/article/pii/S0893608014002135> (paid access to article).

10. *Wasserman P.D.* Advanced methods in neural computing. New York: Van Nostran Reinhold, 1993. 240 p.

11. *Kostina L.N., Gareeva G.A.* Neyronnye seti v zadachakh prognozirovaniya vremennykh ryadov. *Mezhdunarodnyy zhurnal «Innovatsionnaya nauka»*. 6. 2015. P. 70–73. (In Russ.)

12. *Jiang C. and Song F.* Sunspot Forecasting by Using Chaotic Time-series Analysis and NARX Network. *JCP*. 2011. 6(7). P. 1424–1429. URL: http://journaldatabase.info/articles/sunspot_forecasting_by_using_chaotic.html (paid article).

13. *Zhang X. and Frey R.* Improving ARMAGARCH forecasts for high frequency data with regime-switching ARMA-GARCH. *Journal of Computational Analysis & Applications*. 2015. 18(1). URL: <https://www.researchgate.net/publication/228142366>

14. *Kambouroudis D.S., McMillan D.G. and Tsakou K.* Forecasting Stock Return Volatility: A Comparison of GARCH, Implied Volatility, and Realized Volatility Models. *Journal of Futures Markets*. 2016. 36(12). P. 1127–1163. URL: <https://cronfa.swan.ac.uk/Record/cronfa34904> DOI: 10.1002/fut.21783

15. *Domashchenko D.V., Nikulin E.E.* Prognozirovanie ryadov dinamiki rynochnykh indikatorov na osnove nelineynoy avtoregressionnoy neyronnoy seti. *Statistika i Ekonomika*. 2017. 3. P. 4-9. DOI: 10.21686/2500-3925-2017-3-4-9 (In Russ.)

16. *Grachev A. V. Kiseleva T. V., Dobrynin A.S., Koynov R.S.* O metode vybora promezhutochnykh uzlov peredachi dannykh dlya marshrutizatsii v ierarhicheskikh setyakh raznoy topologii. *Ekonomika, statistika i informatika*. 2014. No. 5. P. 161–164 URL: <https://cyberleninka.ru/article/n/o-metode-vybora-promezhutochnyh-uzlov-peredachi-dannyh-dlya-marshrutizatsii-v-ierarhicheskikh-setyah-raznoy-topologii-1> (In Russ.)

17. *Bragina E.I., Dekatov D.E., Egorova I.E.* Razrabotka metodologii podderzhki prinyatiya resheniy v strategicheskom upravlenii predpriyatiem v usloviyakh neopredelennosti. *Internet-vestnik VolgGASU. Seriya «Stroitel'naya informatika»*. 2013. No. 9 (26). P. 1–5. URL: [http://vestnik.vgasu.ru/attachments/DekatoVegorovaBragina1-2013_9\(26\).pdf](http://vestnik.vgasu.ru/attachments/DekatoVegorovaBragina1-2013_9(26).pdf) (In Russ.)

18. *Komleva N.V., Khlopkova O.A.* Obrabotka kontenta v informatsionnykh sredakh na osnove neyronchetkoy modeli prinyatiya resheniy. *Statistika i Ekonomika*. 2013. No. 5. P. 188–192. URL: DOI: 10.21686/2500-3925-2013-5-188-192 (In Russ.)

19. Gunasekaran, M. and Ramaswami, K.S. A Fusion Model Integrating ANFIS and Artificial Immune Algorithm for Forecasting Indian Stock Market (June 22, 2011) // Journal of Applied Sciences, 11(16): pp. 3028-3033. URL: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2335390

20. Аль-Баредда Али Яхья Сенан, Пупков К.А. Алгоритм решения задачи синтеза управления методом искусственных нейронных сетей // Вестник РУДН, серия Инженерные исследования. 2016. № 2. С. 7–16. URL: <https://cyberleninka.ru/article/n/algorithm-resheniya-zadachi-sinteza-upravleniya-metodom-iskusstvennykh-neyronnykh-setey>

21. Аль-Баредда А.Я.С., Пупков К.А. Решение задачи синтеза системы управления методом искусственных нейронных сетей // Фундаментальные исследования. 2015. № 11 (Ч. 5). С. 853–857. URL: <https://fundamental-research.ru/ru/article/view?id=39521>

22. Long T.B., Thai L.H., Hanh T. Face Recognition Using Circularly Orthogonal Moments and Radial Basis Function Neural Network & Genetic Algorithm // 2012 7th IEEE Conference on Industrial Electronics and Applications (ICIEA). P. 523–527. URL: <http://conference.researchbib.com/view/event/>

23. Huang Jeng-Tze, Tseng Ming-Lei. Global Adaptive Neural Tracking Control of Strict-Feedback Systems with Bounded Uncertainty // 2012 7th IEEE Conference on Industrial Electronics and Applications (ICIEA). P. 175–180. URL: <http://conference.researchbib.com/view/event/>

24. Дивеев А.И., Шмалько Е.Ю. Вариационный генетический алгоритм для решения задачи оптимального управления // Современные проблемы науки и образования. 2014. № 1. URL: <http://www.science-education.ru/115-11474>

25. Аверкин А.Н. Гибридные модулярные нейронные сети // Статистика и Экономика. № 4. 2016. С. 8–11. DOI:10.21686/2500-3925-2016-4-8-11

19. Gunasekaran, M. and Ramaswami, K.S. A Fusion Model Integrating ANFIS and Artificial Immune Algorithm for Forecasting Indian Stock Market (June 22, 2011). Journal of Applied Sciences, 11(16): pp. 3028-3033. URL: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2335390 (In Russ.)

20. Al'-Bareda Ali Yakh'ya Senan, Pupkov K.A. Algorithm resheniya zadachi sinteza upravleniya metodom iskusstvennykh neyronnykh setey. Vestnik RUDN, seriya Inzhenernye issledovaniya. 2016. No. 2. P. 7–16. URL: <https://cyberleninka.ru/article/n/algorithm-resheniya-zadachi-sinteza-upravleniya-metodom-iskusstvennykh-neyronnykh-setey> (In Russ.)

21. Al'-Bareda A.Ya.S., Pupkov K.A. Reshenie zadachi sinteza sistemy upravleniya metodom iskusstvennykh neyronnykh setey. Fundamental'nye issledovaniya. 2015. No. 11 (Part 5). P. 853–857. URL: <https://fundamental-research.ru/ru/article/view?id=39521> (In Russ.)

22. Long T.B., Thai L.H., Hanh T. Face Recognition Using Circularly Orthogonal Moments and Radial Basis Function Neural Network & Genetic Algorithm. 2012 7th IEEE Conference on Industrial Electronics and Applications (ICIEA). P. 523–527. URL: <http://conference.researchbib.com/view/event/>

23. Huang Jeng-Tze, Tseng Ming-Lei. Global Adaptive Neural Tracking Control of Strict-Feedback Systems with Bounded Uncertainty. 2012 7th IEEE Conference on Industrial Electronics and Applications (ICIEA). P. 175–180. URL: <http://conference.researchbib.com/view/event/>

24. Diveev A.I., Shmal'ko E.Yu. Variatsionnyy geneticheskiy algoritm dlya resheniya zadachi optimal'nogo upravleniya. Sovremennye problemy nauki i obrazovaniya. 2014. No. 1. URL: <http://www.science-education.ru/115-11474> (In Russ.)

25. Averkin A.N. Gibridnye modulyarnye neyronnye seti. Statistika i Ekonomika. No. 4. 2016. P. 8–11. DOI:10.21686/2500-3925-2016-4-8-11 (In Russ.)

Сведения об авторах

Динар Тагазимович Якупов

Аспирант кафедры автоматизированных систем обработки информации и управления КНИТУ-КАИ, Казань, Россия
Эл. почта: yaqur@mail.ru

Оксана Николаевна Рожко

К.т.н., доцент кафедры автоматизированных систем обработки информации и управления КНИТУ-КАИ, Казань, Россия
Эл. почта: oxana.rozhcko@yandex.ru
Тел.: (917) 883-85-20

Information about the authors

Dinar T. Yakupov

Postgraduate of the Department of automated information processing and management systems KNRTU–KAI, Kazan, Russia
E-mail: yaqur@mail.ru

Oksana N. Rozhko

Cand. Sci. (Eng.), Associate professor, The Department of automated information processing and management systems KNRTU–KAI, Kazan, Russia
E-mail: oxana.rozhcko@yandex.ru
Tel.: (917) 883-85-20