

Л. Ю. Емалетдинова, А. Н. Кабирова, В. С. Белобородов

НЕЙРОНЕЧЕТКОЕ МОДЕЛИРОВАНИЕ ПРОГНОЗИРОВАНИЯ ЗНАЧЕНИЙ ВРЕМЕННОГО РЯДА*Ключевые слова: прогнозирование, временной ряд, нечеткая нейронная сеть, алгоритм самоорганизации, кластеры.*

Проводится обзор методов решения задачи прогнозирования на основе нейросетевых технологий: нейронной сети и нечеткой нейронной сети. Рассматривается адаптивный алгоритм самоорганизации нечеткой сети, который применяется для определения параметров и обучения сети. Основу алгоритма самоорганизации составляет понятие группирования, то есть кластеризации данных. При этом каждый кластер ассоциируется с правилом вывода нечеткой сети. В начальный момент времени центр кластера устанавливается равным значению первого входного вектора. Количество данных, относящихся к одному кластеру, зависит от евклидова расстояния между вновь поступившим входным вектором и центром кластера. Проводятся экспериментальные исследования с целью определения оптимального значения евклидова расстояния, обеспечивающего требуемую точность аппроксимации и допустимую вычислительную сложность, а также с целью определения периода прогнозирования. Рассмотренный алгоритм позволяет определить в реальном времени все требуемые параметры нечеткой сети: количество кластеров, центр каждого кластера и их мощности, а также значение приписанной к кластеру накопленной функции. В сети используется гауссовская функция принадлежности. Построение нечеткой модели прогнозирования осуществляется с помощью программного комплекса, реализованного на языке программирования Python. Выборка строится на основе заданной функции. Обучение сети производится на 50% всей составленной выборки данных, а оставшиеся 50% используются для тестирования. Приведена таблица с результатами сравнительного анализа ошибки прогнозирования в зависимости от значения евклидова расстояния, а также δ . Результаты исследования показали эффективность применения адаптивного алгоритма самоорганизации нечеткой сети для решения задач прогнозирования.

L. U. Emaletdinova, A. N. Kabirova, V. S. Beloborodov

NEURO-FUZZY MODELLING OF TIME SERIES VALUE FORECASTING*Keywords: forecasting, time series, a fuzzy neural network, self-organization algorithm, clusters.*

The review of methods for solving the forecasting problem on the basis of neural network technologies, neural network and fuzzy neural network, is carried out. The adaptive algorithm of fuzzy network self-organization is considered, which is used to determine the parameters and training of the network. The basis of the self-organization algorithm is the concept of grouping, i.e. clustering of data. In this, each cluster is associated with an inference rule of the fuzzy network. At the initial moment of time, the center of the cluster is set equal to the value of the first input vector. The amount of data belonging to one cluster depends on the Euclidean distance between the newly arrived input vector and the center of the cluster. Experimental studies are carried out to determine the optimal value of the Euclidean distance, providing the required approximation accuracy and acceptable computational complexity, as well as to determine the prediction period. The considered algorithm allows to determine in real time all the required parameters of the fuzzy network: the number of clusters, the center of each cluster and their powers, as well as the value of the accumulated function assigned to the cluster. The network uses a Gaussian membership function. The fuzzy forecasting model is built using a software package implemented in the Python programming language. The sample is constructed based on the given function. The network is trained on 50% of the whole compiled data sample and the remaining 50% is used for testing. A table with the results of comparative analysis of prediction error depending on the value of Euclidean distance and δ . The results of the study have shown the effectiveness of applying the adaptive fuzzy network self-organization algorithm for solving prediction problems.

Введение

В настоящее время задача прогнозирования значений временного ряда является актуальной и применяется в различных сферах деятельности человека. Наряду с наличием традиционных методов, основанных на построении авторегрессионных моделей, моделей скользящего среднего и других, широко используются и нейросетевые технологии прогнозирования. Преимущество использования нейросетевых моделей заключается в возможности аппроксимации значений временного ряда нелинейными зависимостями, в то время, как классические модели используют линейные функции.

Один из подходов, основанный на нейросетевом прогнозировании, позволяет предсказывать значения временного ряда в конкретный момент времени на

основе некоторой совокупности предыдущих значений [1-9]. В работе [1] приводится метод построения прогнозной нейросетевой модели на основе перцептрона: описывается алгоритм определения состава входных переменных прогнозной нейросетевой модели в зависимости от типа исходного временного ряда, а также алгоритм формирования обучающей выборки. В работе [2] приводятся результаты сравнительного анализа прогнозирования значений временного ряда классической моделью SARIMA, моделью на основе сверточной нейронной сети и перцептрона. Объектом для анализа были выбраны данные о почасовом потреблении электроэнергии в разных регионах США по открыто опубликованным данным компании PJM Interconnection LLC с 1 января 2018 года по 31 декабря 2021 года, содержащие более 50 тысяч строк данных. Анализ результатов показал, что

нейросетевые модели обеспечивают большую точность прогнозирования, чем классическая модель. При этом точность прогнозирования сверточной нейронной сетью превышает точности прогнозирования с использованием персептрона. В работе [3] приводятся результаты сравнительного анализа прогнозирования временного ряда значений посуточной температуры в г. Сургут с использованием сетей LSTM, TCN и их комбинации TCN – LSTM. Результаты показали превосходство комбинации сетей. В работе [4] описывается подход к прогнозированию нагрузок в электроэнергетической системе на основе однослойной нейронной сети с самоорганизацией. В работе [5] для прогнозирования загрязнения атмосферного воздуха авторы применяют модель рекуррентной нейронной сети типа LSTM. В работе [6] приводятся результаты применения многослойного персептрона, одномерной и двухмерной сверточных сетей, рекуррентной нейронной сети типа LSTM и ансамбля сетей для краткосрочного прогнозирования почасового электропотребления гарантирующего поставщика. В работе [7] для прогнозирования разрушения сплавов, полученных на основе технологии 3D-печати используется двунаправленная рекуррентная нейросетевая модель с долгой краткосрочной памятью ViLSTM. В работе [8] наряду с другими задачами также решается и задача прогнозирования количества заданий, поступающих через систему электронного документооборота. При этом в качестве модели прогнозирования количества заданий авторы используют многослойную нейронную сеть прямого распространения.

Наряду с уже традиционными нейросетевыми моделями прогнозирования немалый интерес у авторов вызывают исследования с целью прогнозирования на основе нечетких нейронных сетей [10-15].

Так, например, в работе [10] проводится сравнительный анализ трех методов: регрессионный анализ, нейронная сеть и нечеткая нейронная сеть. Сравнение подходов основывалось на решении задачи суточного прогнозирования величины электрической нагрузки. В результате было получено, что метод, основанный на нечеткой нейронной сети, является наилучшим с точки зрения точности прогнозирования. В работе [11] решается задача прогнозирования величины электрической нагрузки в электротехнических комплексах летательных аппаратов также на основе нечеткой нейронной сети, что обеспечило необходимую точность и быстроту прогнозирования. Автор работы [12] использует математическую модель на основе нечеткой логики для прогнозирования изменения технического состояния водопропускных труб на железной дороге.

В перечисленных выше работах структура и состав нечетких нейронных сетей определяются экспертами. В работе [4] предложен подход к построению нечеткой нейронной сети, определению её параметров и обучению с помощью алгоритма самоорганизации.

Задача, решаемая нечеткой нейронной сетью, состоит в таком отображении взаимосвязи пар данных (x, d) , чтобы ожидаемое значение d , соответствующее входному вектору x , формировалось выходной функцией сети $y(x)$.

В сети используется гауссовская функция принадлежности для переменной x с центром c и вариацией δ вида:

$$\mu(x) = \exp\left[-\left(\frac{x-c}{\delta}\right)^2\right].$$

Обучение нечеткой сети, так же как и обычной нейронной сети может проводиться либо по алгоритму с учителем, основанному на минимизации целевой функции, либо по алгоритму самоорганизации, согласно которому выполняется кластеризация данных.

В работе [4] предложены различные алгоритмы самоорганизации: алгоритм пикового группирования, алгоритм C-means, алгоритм Густафсона-Кесселя. Однако все эти алгоритмы требуют предварительного знания количества кластеров. В отличие от них алгоритм адаптивной самоорганизации не требует предварительного знания количества кластеров. Число кластеров определяется в процессе работы алгоритма.

Рассмотрим этапы выполнения адаптивного алгоритма самоорганизации.

Адаптивный алгоритм самоорганизации нечеткой сети

Суть алгоритма заключается в следующем:

1. На вход получаем первую пару данных (x_1, d_1) :
 - а) создается первый кластер с центром $c_1 = x_1$;
 - б) устанавливается $w_1 = d_1$;
 - в) задается мощность множества $L_1 = 1$;
 - г) задается количество кластеров $M=1$.
2. Устанавливается r – предельное евклидово расстояние между вектором x и центром, при котором данные будут трактоваться как принадлежащие к созданному кластеру.
3. После считывания k -й обучающей пары (x_k, d_k) рассчитываются расстояния между вектором x_k и всеми существующими центрами $|x_k - c_l|, l = \overline{1, M}$. Допустим, ближайший центр – это $c_{l_p}, p \in \overline{1, M}$.

В зависимости от значения $|x_k - c_{l_p}|$ может возникнуть одна из двух ситуаций:

- а) если $|x_k - c_{l_p}| > r$, то создается новый кластер со своим центром $c_{M+1} = x_k, w_{M+1} = d_k, L_{M+1} = 1$. Параметры ранее созданных кластеров не изменяются.

Количество кластеров M увеличивается на 1 ($M:=M+1$).

- б) если $|x_k - c_{l_p}| \leq r$, то данные включаются в l_p -й кластер. При этом новые (верхний индекс «н») параметры данного кластера вычисляются на основе предыдущих значений (верхний индекс «п»):

$$w_{l_p}^n = w_{l_p}^p + d_k,$$

$$L_{lp}^n = L_{lp}^n + 1,$$

$$c_{lp}^n = \frac{c_{lp}^n \cdot L_{lp}^n + x_k}{L_{lp}^n}.$$

Параметры остальных кластеров не меняются.

После определения всех параметров нечеткой сети строится функция, которая аппроксимирует входные данные:

$$\hat{f}(x) = \frac{\sum_{l=1}^M w_l \cdot \mu_l(x)}{\sum_{l=1}^M L_l \cdot \mu_l(x)} = \frac{\sum_{l=1}^M w_l \cdot \exp(-\frac{|x - c_l|^2}{\delta^2})}{\sum_{l=1}^M L_l \cdot \exp(-\frac{|x - c_l|^2}{\delta^2})},$$

где w_l, c_l, L_l – найдены в результате работы алгоритма.

Модель соответствующей нечеткой нейронной сети можно представить следующим образом:

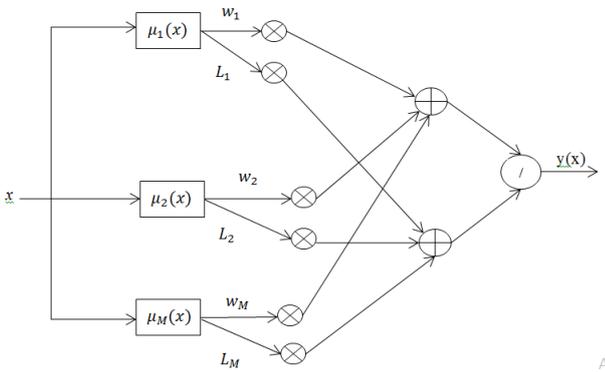


Рис. 1 – Структура нечеткой нейронной сети
Fig. 1 – Structure of the fuzzy neural network

Самое трудоемкое составляющее данного алгоритма – это правильный подбор предельного эвклидова расстояния r между вектором x и центром. Так как, если r выбирать малым, точность аппроксимации данных возрастает, однако это требует увеличения необходимых вычислений и негативно влияет на обобщающие способности сети. Если выбирать данный параметр слишком большим, то уменьшается вычислительная сложность, однако возрастает погрешность аппроксимации. Поэтому необходимо проводить дополнительные исследования для определения оптимального значения r . Кроме этого необходимо провести экспериментальные исследования с целью определения периода прогнозирования, в рамках которого отклонение прогнозного значения от реального будет удовлетворять требуемой точности прогнозирования.

Пример применения адаптивного алгоритма самоорганизации нечеткой сети

Для проведения экспериментальных исследований сгенерируем значения временного ряда, используя функцию следующего вида:

$$f(x) = 0.3 \cos(0.3 \pi x) + 0.4 \cos(0.2 \pi x) + 0.8 \cos(0.4 \pi x) + 1.6 \cos(0.7 \pi x) + 3.3 \cos(2.7 \pi x).$$

В результате имеем 50000 значений построенного временного ряда. Первые 25000 значений используются для построения нечеткой нейронной сети. Оставшиеся значения используются для тестирования построенной сети

С помощью нечеткой модели были спрогнозированы каждые очередные значения временного ряда. Экспериментальные исследования показали, что шаг прогнозирования два удовлетворяет заданной точности (табл. 1).

Таблица 1 – Ошибка прогнозирования

Table 1 – Prediction error

Шаг h	Реальное значение ряда	Прогнозное значение ряда	Ошибка прогнозирования
1	4.819351	4.738282	0.081069
2	4.823432	4.782854	0.040577
3	4.803230	0	4.803230
4	4.758971	0	4.758971
...

Таким образом, из табл. 1 видно, что построенная сеть способна достаточно точно предсказать только первые два значения, а остальные прогнозируемые значения обнуляются в связи с использованием гауссовской функции в качестве функции принадлежности.

Для дальнейшего прогнозирования очередных двух значений временного ряда необходимо повторить третий шаг адаптивного алгоритма для предыдущих двух прогнозных значений и тем самым уточнить параметры w_l, c_l, L_l каждого кластера, где $l = \overline{1, M}$.

В таблице 2 приведены некоторые сравнительные результаты работы сети при различных значениях эвклидова расстояния r и параметра гауссовской функции δ .

Таблица 2 – Влияние r и δ на качество прогноза

Table 2 – Impact of r and δ on the quality of the forecast

r	δ	M_{OB}	M_{BB}	RMSE
0.05	0.01	2580	5085	0.82248
0.05	0.05	2580	5085	0.89673
0.1	0.01	1267	2519	1.26665
0.1	0.1	1267	2519	1.51659
0.5	0.5	250	501	2.52132

Здесь M_{OB} – количество кластеров на обучающей выборке, M_{BB} – количество кластеров на всей выборке, RMSE - среднеквадратическая ошибка.

Из табл. 2 видно, что наименьшее значение среднеквадратического отклонения RMSE достигается при $r = 0.05, \delta = 0.01$. Графические результаты прогнозирования с использованием данной модели представлены на рис. 2-3.

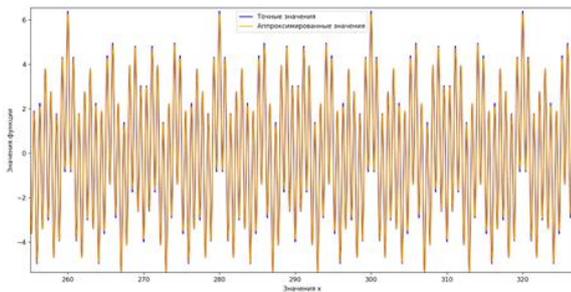


Рис. 2 – Точные и спрогнозированные значения временного ряда на тестовой выборке

Fig. 2 – Exact and predicted values of the time series on the test sample

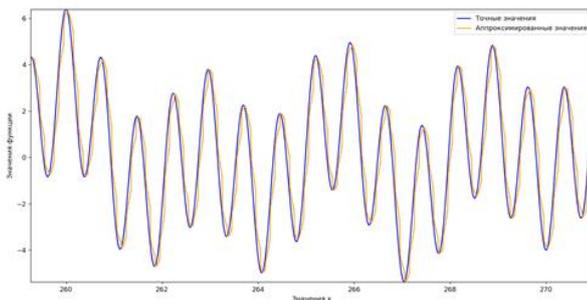


Рис. 3 – Часть точных и спрогнозированных значений временного ряда на тестовой выборке (в приближении)

Fig. 3 – Part of the exact and predicted values of the time series on the test sample (in approximation)

Заключение

Полученные результаты исследований показали эффективность применения адаптивного алгоритма самоорганизации нечеткой сети для предсказания последующих значений временного ряда. При этом результаты прогнозирования зависят от параметра евклидова расстояния r и параметра гауссовской функции принадлежности δ . Уменьшение значений данных параметров приводит к увеличению числа кластеров и к улучшению качества прогнозирования. Однако это приводит и к увеличению вычислительных затрат. Кроме этого прогнозирование на количество шагов более двух требует дообучения нейронечеткой сети.

Литература

1. Л.Ю. Емалетдинова, З.И. Мухаметзянов, Д.В. Катасева, А.Н. Кабирова. Метод построения прогнозной нейросетевой модели временного ряда // Компьютерные исследования и моделирование. – 2020. – Т. 12. – № 4. – С. 737-756.
2. Л.Ю. Емалетдинова, А.Н. Кабирова, Н.Р. Вильданов. Нейросетевое моделирование задачи прогнозирования значений временного ряда // Вестник технологического университета. – 2022. – Т.25. – №10. – С. 101-106.
3. Л.Ю. Емалетдинова, Н.Р. Вильданов, А.С. Катасев. Использование нейросетевой модели TCN-LSTM для прогнозирования значений временного ряда // Научно-технический вестник Поволжья. – 2023. – № 6. – С. 62-64.
4. С.Осовский. Нейронные сети для обработки информации / Пер. с польск. И.Д. Рудинского. – 2-е изд.,

- перераб. и доп. – М.: Горячая линия – Телеком, 2019. – 448 с.: ил.
5. И.В. Дель, А.В. Старченко. Использование методов нейросетевого моделирования для прогнозирования качества атмосферного воздуха // Вестник Томского государственного университета. Управление, вычислительная техника и информатика. – 2023. – № 65. – С. 15-24.
6. Н.А. Серебряков. Краткосрочное прогнозирование почасового электропотребления гарантирующего поставщика с помощью нейросетевых моделей // Южно-Сибирский научный вестник. – 2023. – № 5(51). – С. 166-169.
7. А.А. Хлыбов, Ю.Г. Кабалдин, М.С. Аносов, Д.А. Шатагин. Прогнозирование разрушения сплавов, полученных на основе технологии 3D-печати с использованием нейросетевой модели // Научно-технический вестник Поволжья. – 2023. – № 11. – С. 303-306.
8. С.С. Кильдеев. Модели и методы прогнозирования и распределения заданий по исполнителям в системах электронного документооборота / С. С. Кильдеева, А. С. Катасев, Н. Г. Галипов // Вестник Технологического университета. – 2021. – Т. 24, № 1. – С. 79-85.
9. А.С. Кузнецова. Использование нейросетевой модели для прогнозирования в режиме реального времени последствий выброса опасного газа из технологического оборудования / А. С. Кузнецова, А. И. Купцов, Ф. М. Гимранов // Вестник Технологического университета. – 2019. – Т. 22, № 7. – С. 114-119.
10. В.З. Манусов, Е.В. Бирюков. Краткосрочное прогнозирование электрической нагрузки на основе нечеткой нейронной сети и ее сравнение с другими методами // Известия Томского политехнического университета. – 2006. – Т. 309, № 6. – С. 153-157.
11. А.Е. Чернов, Р.А. Малеев, Д.А. Ерошкин, Е.Н. Федоренко. Прогнозирование величины электрической нагрузки в электротехнических комплексах летательных аппаратов // Известия МГТУ МАМИ. – 2022. – Т. 16, № 1. – С. 99-106.
12. М.Г. Рюмин. Применение алгоритмов нечеткой логики для прогнозирования технического состояния водопропускных труб на железной дороге / М. Г. Рюмин // Транспортные сооружения. – 2023. – Т. 10, № 3.
13. Е.А. Энгель. Интеллектуальная система прогнозирования температуры на основе модифицированной нечеткой нейросети / Е. А. Энгель, Н. Е. Энгель // Вестник кибернетики. – 2023. – Т. 22, № 3. – С. 76-81.
14. Д.В. Медведев. Модель прогнозирования лесных пожаров на основе нейро-нечеткой системы ANFIS / Д. В. Медведев // Научно-аналитический журнал "Вестник Санкт-Петербургского университета Государственной противопожарной службы МЧС России". – 2023. – № 4. – С. 185-198.
15. Синтез моделей прогнозирования и диагностики профессиональных заболеваний на основе гибридной нечеткой технологии / Р. И. Сафронов, К. В. Разумова, А. Ю. Рыбаков, А. В. Лях // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. – 2023. – Т. 13, № 3. – С. 102-121.

References

1. L.Y. Emaletdinova, Z.I. Mukhametzyanov, D.V. Kataseva, A.N. Kabirova. Method of building a predictive neural network model of time series // Computer Research and Modelling. - 2020. - V. 12. - № 4. - P. 737-756.

2. L.Y. Emaletdinova, A.N. Kabirova, N.R. Vildanov. Neural network modelling of the task of forecasting the values of time series // Herald of Technological University. - 2022. - V.25. - №10. - P. 101-106.
3. L.Yu. Emaletdinova, N.R. Vildanov, A.S. Katasev. Using the neural network model TCN-LSTM for forecasting the values of time series // Scientific and Technical Bulletin of the Volga Region. - 2023. - № 6. - P. 62-64.
4. S. Osovsky. Neural networks for information processing / Per. from Polish. I.D. Rudinsky. - 2nd ed., revision and supplement - M.: Hotline - Telecom, 2019. -448 p.: ill.
5. I.V. Del, A.V. Starchenko. The use of neural network modelling methods for forecasting atmospheric air quality // Bulletin of Tomsk State University. Management, Computer Science and Informatics. - 2023. - № 65. - P. 15-24.
6. N.A. Serebryakov. Short-term forecasting of hourly power consumption of the guaranteeing supplier with the help of neural network models // South-Siberian scientific bulletin. - 2023. - № 5(51). - P. 166-169.
7. A.A. Khlybov, Y.G. Kabaldin, M.S. Anosov, D.A. Shatagin. Prediction of the fracture of the alloys obtained on the basis of 3D-printing technology using neural network model // Scientific and Technical Bulletin of the Volga Region. - 2023. - № 11. - P. 303-306.
8. S. S. Kildeev. Models and methods of forecasting and distribution of tasks to performers in the systems of electronic document management / S. S. Kildeev, A. S. Katasev, N. G. Talipov // Herald of Technological University. - 2021. - V. 24, № 1. - P. 79-85.
9. A. S. Kuznetsova. Using neural network model for real-time prediction of the consequences of hazardous gas release from process equipment / A. S. Kuznetsova, A. I. Kuptsov, F. M. Gimranov // Herald of Technological University. - 2019. - V. 22, № 7. - P. 114-119.
10. V.Z. Manusov, E.V. Biryukov. Short-term forecasting of an electric load on the basis of a fuzzy neural network and its comparison with other methods // Proceedings of Tomsk Polytechnic University. - 2006. - V. 309, № 6. - P. 153-157.
11. A.E. Chernov, R.A. Maleev, D.A. Eroshkin, E.N. Fedorenko. Prediction of the electrical load value in the electrical complexes of the aircraft // Izvestiya MSTU MAMI. - 2022. - V. 16, № 1. - P. 99-106.
12. M.G. Ryumin. Fuzzy logic algorithms application for the technical condition forecasting of the culverts on the railway (in Russian) / M. G. Ryumin // Transport structures. - 2023. - V. 10, № 3.
13. Engel, E.A.. Intelligent system of temperature forecasting based on the modified fuzzy neural network / E. A. Engel, N. E. Engel // Vestnik kibernetiki. - 2023. - V. 22, № 3. - P. 76-81.
14. D.V. Medvedev. Model of forest fire forecasting based on neuro-fuzzy system ANFIS / D. V. Medvedev // Scientific and analytical journal 'Bulletin of St. Petersburg University of the State Fire Fighting Service of the Ministry of Emergency Situations of Russia'. - 2023. - № 4. - P. 185-198.
15. Synthesis of models for prediction and diagnosis of occupational diseases on the basis of hybrid fuzzy technology / R. I. Safronov, K. V. Razumova, A. Y. Rybakov, A. V. Lyakh // Proceedings of South-West State University. Series: Management, Computer Science, Informatics. Medical Instrumentation. - 2023. - V. 13, № 3. - P. 102-121.

© **Л. Ю. Емалетдинова** – профессор кафедры Прикладной математики и информатики (ПМИ), Казанский национальный исследовательский технический университет им. А.Н. Туполева (КНИТУ им. А.Н. Туполева), Казань, Россия, lilia@stcline.ru; **А. Н. Кабилова** – доцент кафедры ПМИ, КНИТУ им. А.Н. Туполева, kabirovaaigul@mail.ru; **В. С. Белобородов** – магистр кафедры ПМИ, КНИТУ им. А.Н. Туполева, viit230498@gmail.com.

© **L. U. Emaletdinova** – Professor of the department of Applied Mathematics and Informatics (AMI), Kazan National Research Technical University named after A.N. Tupolev (KNRTU named after A.N. Tupolev), Kazan, Russia, lilia@stcline.ru; **A. N. Kabirova** – Associate Professor of the AMI department, KNRTU named after A.N. Tupolev, kabirovaaigul@mail.ru; **V. S. Beloborodov** – Master-student of the AMI department, KNRTU named after A.N. Tupolev, viit230498@gmail.com.