

## ПРОГНОЗИРОВАНИЕ КАЧЕСТВА ФУНКЦИОНИРОВАНИЯ ТЕХНИЧЕСКОГО ОБЪЕКТА С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ

М. И. Корнилова<sup>1</sup>, С. В. Бусыгин<sup>2</sup>, В. Н. Ковальногов<sup>3</sup>, В. Н. Клячкин<sup>4</sup>

<sup>1, 2, 3, 4</sup> Ульяновский государственный технический университет, Ульяновск, Россия  
<sup>1</sup> masha.kornilova.1995@mail.ru, <sup>2</sup> sergey18.06.95@mail.ru, <sup>3</sup> kvn@ulstu.ru, <sup>4</sup> v\_kl@mail.ru

**Аннотация.** *Актуальность и цели.* Качество функционирования сложных технических систем определяется множеством характеристик. Прогнозирование значений этих характеристик по результатам мониторинга показателей работы объекта дает возможность выполнять постоянно растущие требования по обеспечению безопасности и надежности. Необходимая точность прогнозирования требует построения качественных математических моделей. В качестве технического объекта рассмотрено горелочное устройство: оценивается качество функционирования таких устройств по одной из основных характеристик – температуре ядра пламени. Цель исследования – разработка методики построения математической модели, которая бы обеспечила достаточно точный прогноз характеристик функционирования технического объекта. *Материалы и методы.* Для построения моделей по результатам наблюдений за исследуемым объектом используются как классические методы регрессионного анализа, так и методы машинного обучения. В работе проводится сравнение двух подходов: применения линейного регрессионного анализа и композиционного метода «случайный лес (Random Forest)». *Результаты и выводы.* Разработана технология математического моделирования и прогнозирования характеристик качества функционирования технических объектов с использованием двух подходов: линейной регрессии и метода случайного леса. В рассматриваемом примере оценки качества горелочного устройства по температуре ядра пламени оба подхода дали практически одинаковый и вполне приемлемый результат. Очевидно, что в других задачах эти результаты могут существенно различаться.

**Ключевые слова:** показатели функционирования, регрессионный анализ, машинное обучение, случайный лес, система Statistica

**Финансирование:** исследование выполнено при поддержке гранта Президента Российской Федерации, проект НШ-28.2022.4.

**Для цитирования:** Корнилова М. И., Бусыгин С. В., Ковальногов В. Н., Клячкин В. Н. Прогнозирование качества функционирования технического объекта с использованием машинного обучения // Надежность и качество сложных систем. 2023. № 4. С. 152–158. doi: 10.21685/2307-4205-2023-4-14

## FORECASTING THE QUALITY OF THE TECHNICAL OBJECT'S FUNCTIONING USING MACHINE LEARNING

M.I. Kornilova<sup>1</sup>, S.V. Busygin<sup>2</sup>, V.N. Kovalnogov<sup>3</sup>, V.N. Klyachkin<sup>4</sup>

<sup>1, 2, 3, 4</sup> Ulyanovsk State Technical University, Ulyanovsk, Russia  
<sup>1</sup> masha.kornilova.1995@mail.ru, <sup>2</sup> sergey18.06.95@mail.ru, <sup>3</sup> kvn@ulstu.ru, <sup>4</sup> v\_kl@mail.ru

**Abstract.** *Background.* The quality of functioning of complex technical systems is determined by many characteristics. Forecasting the values of these characteristics based on the results of monitoring the performance of the facility makes it possible to fulfill the ever-growing requirements for safety and reliability. The necessary accuracy of forecasting requires the construction of high-quality mathematical models. As a technical object, the burner device is considered: the quality of operation of such devices is evaluated according to one of the main characteristics – the temperature of the flame core. The purpose of the study is to develop a methodology for building a mathematical model that would provide a fairly accurate forecast of the characteristics of the functioning of a technical object. *Materials and methods.* To build models based on the results of observations of the object under study, both classical methods of regression analysis and machine learning methods are used. The paper compares two approaches: the use of linear regression analysis and the compositional method "Random Forest". *Results and conclusions.* The technology of mathematical modeling and forecasting of the characteristics of the quality of functioning of technical objects using two approaches

has been developed: linear regression and the random forest method. In the example under consideration, the evaluation of the quality of the burner device from the temperature of the flame core, both approaches gave almost the same and quite acceptable result. Obviously, in other tasks, these results can vary significantly.

**Keywords:** performance indicators, regression analysis, machine learning, random forest, Statistica system

**Financing:** the study was supported by a grant from the President of the Russian Federation, project NSH-28.2022.4.

**For citation:** Kornilova M.I., Busygin S.V., Kovalnogov V.N., Klyachkin V.N. Forecasting the quality of the technical object's functioning using machine learning. *Nadezhnost' i kachestvo slozhnykh sistem = Reliability and quality of complex systems*. 2023;(4):152–158. (In Russ.). doi: 10.21685/2307-4205-2023-4-14

### Постановка задачи

Качество функционирования сложных технических систем определяется множеством характеристик. Прогнозирование значений этих характеристик по результатам мониторинга показателей работы объекта дает возможность выполнять постоянно растущие требования по обеспечению безопасности и надежности [1–3].

Необходимая точность прогнозирования требует построения качественных математических моделей. Для построения таких моделей по результатам наблюдений за исследуемым объектом используются как классические методы регрессионного анализа, так и методы машинного обучения [4, 5]. Исходные данные могут быть получены различными способами: по результатам эксплуатации объекта, по данным специально поставленных испытаний, по информации, полученной с помощью математического моделирования работы рассматриваемого объекта.

В настоящей работе проводится сравнение двух подходов: применения линейного регрессионного анализа и композиционного метода «случайный лес (Random Forest)». Для численного исследования используются два модуля локализованной версии 13.3 системы Statistica: «Множественная регрессия» и «Случайные леса» [6].

В качестве технического объекта рассмотрено горелочное устройство: оценивается качество функционирования таких устройств по одной из основных характеристик – температуре ядра пламени (в терминологии регрессионного анализа – отклик). Величина этой температуры зависит от нагрузки, расхода воздуха, метана и биогаза, составов топлива и окислителя, и других – всего 17 показателей (регрессоров) [7].

Из методов машинного обучения был выбран метод «случайный лес» как один из наиболее эффективных в задачах классификации и регрессии [8, 9]. Известно, что лучшие результаты в подобных исследованиях дает глубокое обучение нейронных сетей, однако для применения этого подхода необходим достаточно большой объем выборочных данных (сотни тысяч, а лучше миллионы наблюдений [10]), что для технических систем, как правило, нереально: для построения моделей обычно используется несколько десятков или сотен наблюдений.

Выборка исходных данных разбивается на две части: обучающую и тестовую. Обучающая часть предназначена для построения математических моделей: необходимо построить алгоритм, который для заданного набора показателей функционирования обеспечил бы достаточно точный результат о характеристике качества работы объекта. При этом, как и в любых задачах машинного обучения, возможно переобучение.

Тестовая часть выборки предназначена для оценки качества полученной модели: на тестовом наборе показателей функционирования проводится сравнение опытных и прогнозируемых данных, полученных по построенной модели. О качестве модели и отсутствии переобучения можно судить по различным критериям. В данном исследовании использована средняя абсолютная процентная ошибка (Mean Absolute Percentage Error)

$$\text{MAPE} = \frac{1}{l_T} \sum_{i=1}^{l_T} \frac{|\tilde{y}_i - y_i|}{y_i} 100\%,$$

где  $y_i$  – опытное значение отклика в  $i$ -м наблюдении;  $\tilde{y}_i$  – прогнозируемое значение отклика по рассматриваемой модели;  $l_T$  – объем тестовой выборки.

Цель исследования – разработка методики построения математической модели с наименьшим значением ошибки MAPE, которая бы обеспечила достаточно точный прогноз характеристик функционирования технического объекта.

**Линейная регрессионная модель**

Модель множественной линейной регрессии имеет вид [4, 5]

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \epsilon,$$

где  $Y$  – отклик (случайная величина);  $x_j$  ( $j = 1 \dots p$ ) – факторы, оказывающие влияние на отклик (регрессоры);  $p$  – количество регрессоров (в рассматриваемом примере  $p = 17$ );  $\epsilon$  – ошибки наблюдений;  $\beta_j$  (здесь  $j = 0 \dots p$ ) – параметры модели, которые необходимо оценить.

Часть файла исходных данных-прецедентов, используемых для оценки параметров, показана на рис. 1.

X1	X2	X3		X12	X13	X14	X15	X16	X17	Y
195	22344	2000		0,2315	0,7685	0	0	483	1,14	2030
247	25798,5	2437,5		0,2315	0,7685	0	0	487	1,08	2055
254	26870,375	2562,5		0,2315	0,7685	0	0	491	1,07	2060
299	31064,775	2962,5		0,2315	0,7685	0	0	495	1,07	2078
310	32609,5	3025		0,2315	0,7685	0	0	499	1,1	2095
355	36877,4	3550	...	0,2315	0,7685	0	0	503	1,06	2105
401	48272,35	4037,5		0,2315	0,7685	0	0	507	1,22	2120
420	45141,25	4187,5		0,2315	0,7685	0	0	511	1,1	2145
425	49017,15	4275		0,2315	0,7685	0	0	515	1,17	2147
430	50715	4312,5		0,2315	0,7685	0	0	519	1,2	2150
400	40358,85	4037,5		0,1956	0,7559	0,0156	0,0329	477	1,02	1891
400	40358,85	4037,5		0,1788	0,7500	0,0229	0,0483	477	1,02	1803

Рис. 1. Часть файла исходных данных-прецедентов

Вектор оценок  $\tilde{\beta}$  параметров модели по методу наименьших квадратов определяется по формуле

$$\tilde{\beta} = (X^T X)^{-1} X^T Y, \tag{3}$$

где  $Y$  – вектор наблюдений, содержащий  $l_0$  значений откликов (в рассматриваемом опыте  $l = 300$  наблюдений; выборка разбивалась на обучающую и тестовую части в пропорции 80/20, поэтому объем обучающей части выборки  $l_0 = 240$ );  $X$  – регрессионная матрица, содержащая элементы  $x_{ij}$  (регрессоры) – результаты  $i$ -го наблюдения ( $i = 1 \dots l$ ) за  $j$ -й переменной.

Для проверки значимости модели используется критерий Фишера. Если модель оказалась значимой, далее проверяется значимость каждого регрессора по критерию Стьюдента. При незначимости соответствующий регрессор удаляется из модели, и расчет проводится заново. Последовательное удаление незначимых регрессоров из модели представляет алгоритм пошаговой регрессии.

В практических ситуациях иногда возникают проблемы с обращением регрессионной матрицы  $(X^T X)^{-1}$ . Это связано с мультиколлинеарностью регрессоров, когда между ними существует корреляционная связь, близкая к линейной: есть коэффициенты корреляции, близкие к единице.

В рассматриваемой выборке исследовалось наличие корреляционных связей между показателями. Сильная корреляция (выборочный коэффициент корреляции  $r > 0,9$ ) имеет место между парами показателей  $X_4$ - $X_5$ ,  $X_4$ - $X_9$ ,  $X_5$ - $X_9$ ,  $X_6$ - $X_7$ ,  $X_6$ - $X_{11}$ .

Для случая мультиколлинеарности регрессоров разработаны варианты регуляризации регрессионной модели. Один из них – использование гребневой регрессии (или ридж-регрессии), когда к диагональным элементам матрицы добавляется некоторое малое число:

$$\tilde{\beta} = (X^T X + E)^{-1} X^T Y,$$

$E$  – единичная матрица. Параметр  $\lambda$  обычно меньше 0,1 и может быть подобран по некоторому критерию.

Для характеристики качества модели может быть использован коэффициент детерминации – квадрат коэффициента корреляции между опытными  $y_i$  и прогнозируемыми  $\tilde{y}_i$  значениями (показывает, какая доля дисперсии отклика может быть объяснена рассматриваемыми регрессорами):

$$R^2 = \frac{\sum_{i=1}^l \tilde{y}_i^2 - l_0 \bar{y}^2}{\sum_{i=1}^l y_i^2 - l_0 \bar{y}^2}.$$

Чем ближе коэффициент детерминации к единице, тем более качественной считается модель.

Поскольку регрессионная матрица в рассматриваемом примере имеет множество сильно коррелированных столбцов, по обучающей части выборки в системе Statistica строилась гребневая регрессия, при этом параметр  $\lambda$  подбирался так, чтобы обеспечить максимум коэффициента детерминации. Проводился отбор значимых регрессоров методами пошаговой регрессии с исключением.

На рис. 2 приведены результаты расчета. Из таблицы следует, что при принятом значении  $\lambda = 0,001$  коэффициент детерминации оказался равным  $R^2 = 0,72$ ; модель значима, поскольку значение статистики Фишера  $F(7,232) = 85,94$  соответствует вероятности ошибки  $p < 0,05$ .

Методами пошаговой регрессии программа отобрала семь значимых регрессоров (X1, X4, X7, X10, X13, X14 и X15) из 17. Их значимость следует из того, что значения критерия Стьюдента  $t(232)$  соответствуют вероятности ошибки  $p < 0,05$ .

N=240	Итоги Гребневой регрессии для зависимой переменной: Y4 (22-240+60)  =.00100 R= .84951932 R2= .72168308 Скоррект. R2 .71328559 F(7,232)=85,940 p<0,0000 Станд. ошибка оценки: 66,661 Исключенные наблюдения: 241:300					
	БЕТА	Ст.Ош. БЕТА	B	Ст.Ош. B	t(232)	p-знач.
Св.член			1292,158	182,3952	7,0844	0,000000
X1	0,517522	0,038808	0,709	0,0532	13,3353	0,000000
X4	-0,524149	0,055388	-0,057	0,0060	-9,4632	0,000000
X7	0,446110	0,054188	26,937	3,2720	8,2326	0,000000
X10	0,357107	0,035544	6487,877	645,7684	10,0468	0,000000
X13	-0,259730	0,041161	-1,530	0,2425	-6,3101	0,000000
X14	-0,452516	0,042187	-19,338	1,8029	-10,7265	0,000000
X15	-0,608903	0,035780	-8,247	0,4846	-17,0181	0,000000

Рис. 2. Результаты расчета по линейной регрессионной модели

Регрессионная линейная модель в виде уравнения для расчета прогнозируемых значений температуры ядра пламени может быть представлена в явном виде

$$\tilde{y}_i = 1292,158 + 0,71x_{1i} - 0,057x_{4i} + 26,937x_{7i} + 6487,88x_{10i} - 1,53x_{13i} - 19,34x_{14i} - 8,247x_{16i}.$$

По этой формуле был проведен расчет прогнозируемых значений для тестовой выборки в Excel (рис. 3) и найдено значение средней абсолютной процентной ошибки MAPE = 3,65 %. Именно это значение и будет сравниваться с результатом по методу «случайный лес».

=1292,158+0,71*A2-0,057*B2+26,937*C2+6487,88*D2-1,53*E2-19,34*F2-8,247*G2												
	A	B	C	D	E	F	G	H	I	J	K	L
1	x1	x4	x7	x10	x13	x14	x16	y	y-пр			
2	500	0	0	0,2315	527	10	0,1	2190	2148,568	0,018919		
3	400	0	0	0,2195	477	10	0,5	2120	2073,067	0,022138		
4	400	0	0	0,2315	477	10	1	2185	2146,645	0,017554		
5	400	0	0	0,2315	477	10	0,4	2051	2151,593	0,049046		
6	400	0	0	0,2315	477	10	0,4	2101	2151,593	0,024081		
7	400	0	0	0,2315	477	10	0,4	1710,5	2151,593	0,257896		
8	400	0	0	0,2315	477	10	0,4	1622,6	2151,593	0,325987		
9	400	4037,5	0	0,2315	477	10	0,4	1980	1921,456	0,029568		
10	400	4037,5	0	0,2315	477	10	0,4	2005	1921,456	0,041668		
11	400	1211,25	0	0,2315	477	10	0,4	2110	2082,552	0,013008		
12	400	1211,25	0	0,2315	477	10	0,4	2097	2082,552	0,00689		
13	170	0	0	0,2315	446	15	0,4	1890	1939,023	0,025938		
14	300	0	0	0,2315	448	15	0,4	2060	2028,263	0,015406		
15	400	0	0	0,2315	450	15	0,4	2160	2096,203	0,029535		
16	500	0	0	0,2315	452	15	0,4	2170	2164,143	0,002699		
17	170	0	0	0,2315	446	15	0,4	1890	1939,023	0,025938		
18	300	0	0	0,2315	448	15	0,4	2021	2028,263	0,003594		
19	300	0	0	0,2315	491	14	0,4	1798	1981,813	0,102232		

Рис. 3. Прогноз температуры ядра пламени по тестовой выборке

Заметим, что полученный показатель (ошибка 3,65 %) имеет вполне приемлемое значение, несмотря на достаточно низкий коэффициент детерминации  $R^2 = 0,72$ .

### Метод Random Forest для решения задач регрессии

Random Forest, или «случайный лес», – это алгоритм машинного обучения, предложенный Л. Брейманом [11], в нем используется ансамбль решающих деревьев. Алгоритм сочетает в себе бэггинг (случайный выбор с возвращением) и метод случайных подпространств. Он состоит из множества независимых деревьев решений, используется случайная выборка наблюдений из обучающего набора и случайный набор показателей при принятии решений о разбиении узлов.

Точность прогнозирования случайного леса зависит от количества показателей в случайном наборе, объема случайной выборки из обучающего набора, количества деревьев, максимальной глубины деревьев, максимального количества узлов в деревьях, минимального числа объектов в листьях, минимального количества объектов в дочернем узле.

Для решения задачи использовался модуль «Случайный лес» локализованной версии 13.3 пакета Statistica. Настройки показаны на рис. 4: приняты доля тестовой выборки – 0,2 (20 % от всего набора данных), доля подвыборки – 0,5; число случайных показателей (предикторов) – 5 и т.д.

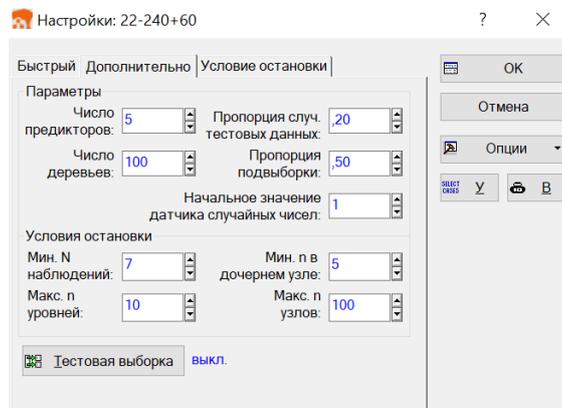


Рис. 4. Настройки случайного леса

На рис. 5 показаны рассчитанные системой Statistica прогнозируемые значения отклика для тестовой выборки по полученной с помощью «случайного леса» модели.

Наблюд. значение	Предск. значение	Остаток значение	
9	2147,000	2109,643	37,357
13	1891,000	2019,807	-128,807
16	2112,000	2031,759	80,241
21	2182,000	2031,759	150,241
33	1900,000	1993,576	-93,576
40	1900,000	1979,999	-79,999
50	2145,000	2110,017	34,983
53	1803,000	2048,813	-245,813
58	2092,000	2050,056	41,944
59	2120,000	2070,914	49,086
61	2178,000	2111,735	66,265
62	2171,000	2108,018	62,982
63	2089,000	2072,657	16,343
65	1950,000	2015,712	-65,712
73	2145,000	2055,075	89,925
77	2198,000	2108,690	89,310
81	2098,000	2057,409	40,591
87	2191,000	2115,538	75,462
91	1981,000	2032,188	-51,188
93	2121,000	2032,329	88,671
94	2185,000	2029,899	155,101
95	2095,000	2047,814	47,186
111	1955,000	2030,350	-75,350

Рис. 5. Прогнозируемые значения температуры по методу «случайного леса», найденные системой Statistica

По этим данным нетрудно подсчитать значение средней абсолютной процентной ошибки:  $MARE = 3,64 \%$ . Таким образом, точность полученных моделей оказалась практически одинаковой. Попытки улучшить этот результат путем изменения настроек (см. рис. 4) не дали эффекта.

### Заключение

Разработана технология математического моделирования и прогнозирования характеристик качества функционирования технических объектов с использованием двух подходов: линейной регрессии и метода «случайного леса». В рассматриваемом примере оценки качества горелочного устройства по температуре ядра пламени оба подхода дали практически одинаковый и вполне приемлемый результат. Очевидно, что в других задачах эти результаты могут существенно различаться.

Возникает вопрос: какую же из моделей предпочесть? При одинаковой точности предпочтительнее линейная регрессионная модель, поскольку она записана в явном виде. С ее помощью можно анализировать влияние различных факторов на качество работы горелки. Модель «случайного леса» в явном виде не выводится, и проводить такой анализ будет гораздо сложнее.

### Список литературы

1. Биргер И. А. Техническая диагностика. 2-е изд. М. : URSS, 2019. 240 с.
2. Северцев Н. А., Бецов А. В., Дарьина А. Н. Методы и модели создания автоматизированных средств контроля для повышения безопасности функционирования технических систем // Надежность и качество сложных систем. 2019. № 2. С. 19–26.
3. Юрков Н. К. Риски отказов сложных систем // Надежность и качество сложных систем. 2014. № 1. С. 18–24.
4. Валеев С. Г. Регрессионное моделирование при обработке наблюдений. М. : Наука, 1991. 272 с.
5. Валеев С. Г., Клячкин В. Н. Практикум по прикладной статистике. Ульяновск : УлГТУ, 2008. 134 с.
6. Боровиков В. П. STATISTICA. Искусство анализа данных на компьютере: для профессионалов. 2-е изд. СПб. : Питер, 2003.
7. Kovalnogov V., Fedorov R., Klyachkin V. [et al.]. Applying the Random Forest Method to Improve Burner Efficiency // Mathematics. 2022. № 10. P. 1–25.
8. Neykov M., Liu J. S., Cai T. On the Characterization of a Class of Fisher-Consistent Loss Functions and its Application to Boosting // Journal of Machine Learning Research. 2016. № 17. P. 1–32.
9. Wyner A. J., Olson M., Bleich J., Mease D. Explaining the Success of AdaBoost and Random Forests as Interpolating Classifiers // Journal of Machine Learning Research. 2017. № 18. P. 1–33.
10. Воронина В. В., Михеев А. В., Ярушкина Н. Г., Святов К. В. Теория и практика машинного обучения: учеб. пособие. Ульяновск : УлГТУ, 2017. 290 с.
11. Breiman L. Random Forests // Machine Learning. 2001. Vol. 45, № 1, P. 5–32.

### References

1. Birger I.A. *Tekhnicheskaya diagnostika. 2-e izd. = Technical diagnostics. 2nd ed.* Moscow: URSS, 2019:240. (In Russ.)
2. Severtsev N.A., Betskov A.V., Dar'ina A.N. Methods and models for creating automated controls to improve the safety of technical systems. *Nadezhnost' i kachestvo slozhnykh system = Reliability and quality of complex systems.* 2019;(2):19–26. (In Russ.)
3. Yurkov N.K. Risks of failures of complex systems. *Nadezhnost' i kachestvo slozhnykh system = Reliability and quality of complex systems.* 2014;(1):18–24. (In Russ.)
4. Valeev S.G. *Regressiionnoe modelirovanie pri obrabotke nablyudeniy = Regression modeling in the processing of observations.* Moscow: Nauka, 1991:272. (In Russ.)
5. Valeev S.G., Klyachkin V.N. *Praktikum po prikladnoy statistike = Practical training in applied statistics.* Ul'yanovsk: UIGTU, 2008:134. (In Russ.)
6. Borovikov V.P. *STATISTICA. Iskusstvo analiza dannykh na komp'yutere: dlya professionalov. 2-e izd. = STATISTICS. The art of data analysis on a computer: for professionals. 2nd ed.* Saint Petersburg: Piter, 2003. (In Russ.)
7. Kovalnogov V., Fedorov R., Klyachkin V. et al. Applying the Random Forest Method to Improve Burner Efficiency. *Mathematics.* 2022;(10):1–25.
8. Neykov M., Liu J.S., Cai T. On the Characterization of a Class of Fisher-Consistent Loss Functions and its Application to Boosting. *Journal of Machine Learning Research.* 2016;(17):1–32.
9. Wyner A.J., Olson M., Bleich J., Mease D. Explaining the Success of AdaBoost and Random Forests as Interpolating Classifiers. *Journal of Machine Learning Research.* 2017;(18):1–33.

10. Voronina V.V., Mikheev A.V., Yarushkina N.G., Svyatov K.V. *Teoriya i praktika mashinnogo obucheniya: ucheb. posobie = Theory and practice of machine learning: textbook*. Ulyanovsk: UIGTU, 2017:290. (In Russ.)
11. Breiman L. Random Forests. *Machine Learning*. 2001;45(1):5–32.

**Информация об авторах / Information about the authors**

**Мария Игоревна Корнилова**

аспирант,  
Ульяновский государственный технический  
университет  
(Россия, г. Ульяновск, ул. Северный Венец, 32)  
E-mail: masha.kornilova.1995@mail.ru

**Сергей Викторович Бусыгин**

аспирант,  
Ульяновский государственный технический  
университет  
(Россия, г. Ульяновск, ул. Северный Венец, 32)  
E-mail: sergey18.06.95@mail.ru

**Владислав Николаевич Ковальногов**

доктор технических наук, доцент, заведующий  
кафедрой тепловой и топливной энергетики,  
Ульяновский государственный технический  
университет  
(Россия, г. Ульяновск, ул. Северный Венец, 32)  
E-mail: kvn@ulstu.ru

**Владимир Николаевич Клячкин**

доктор технических наук, профессор, профессор  
кафедры прикладной математики и информатики,  
Ульяновский государственный технический  
университет  
(Россия, г. Ульяновск, ул. Северный Венец, 32)  
E-mail: v\_kl@mail.ru

**Maria I. Kornilova**

Postgraduate student,  
Ulyanovsk State Technical University  
(32 Severny Venets street, Ulyanovsk, Russia)

**Sergey V. Busygin**

Postgraduate student,  
Ulyanovsk State Technical University  
(32 Severny Venets street, Ulyanovsk, Russia)

**Vladislav N. Kovalnogov**

Doctor of technical sciences, associate professor,  
head of the sub-department  
of thermal and fuel energy,  
Ulyanovsk State Technical University  
(32 Severny Venets street, Ulyanovsk, Russia)

**Vladimir N. Klyachkin**

Doctor of technical sciences, professor,  
professor of the sub-department  
of applied mathematics and informatics,  
Ulyanovsk State Technical University  
(32 Severny Venets street, Ulyanovsk, Russia)

**Авторы заявляют об отсутствии конфликта интересов /  
The authors declare no conflicts of interests.**

**Поступила в редакцию / Received 20.08.2023**

**Поступила после рецензирования / Revised 30.08.2023**

**Принята к публикации / Accepted 15.09.2023**