

DOI: 10.32517/0234-0453-2021-36-8-41-51

ИССЛЕДОВАНИЕ ПРИМЕНИМОСТИ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОЦЕНКИ ДЕЯТЕЛЬНОСТИ КАФЕДР

А. Р. Муканова¹, Ш. А. Оцоков¹ ✉

¹ *Национальный исследовательский университет «МЭИ»*

✉ shamil24@mail.ru

Аннотация

В настоящее время в ряде образовательных организаций в России и за рубежом, в том числе и в Национальном исследовательском университете «МЭИ» внедряется европейская модель совершенствования EFQM, призванная анализировать и улучшать образовательную, научную и другие виды деятельности кафедр. В соответствии с этой моделью каждой кафедре университета присваивается балл, равный сумме баллов по двум группам критериев: критериев из группы возможностей и критериев из группы результатов. Для получения таких оценок комиссия, состоящая из внешних экспертов, ассессоров EFQM и сотрудников университета, проводит встречи с заведующими кафедр. По результатам обсуждения итогов встреч комиссия определяет балл и рейтинг кафедр в соответствии с моделью EFQM.

Целью представленной в статье работы является исследование возможности применения машинного обучения для упрощения работы экспертов в части получения оценок по критериям из группы результатов.

В статье предложена система оценивания деятельности кафедр по критериям из группы результатов на основе машинного обучения. Разработана программа на языке программирования Python, которая оценивает деятельность кафедр по этим критериям для каждой кафедры НИУ «МЭИ». Исходные данные для таких оценок программа получает из системы мониторинга ключевых показателей деятельности, внедренной в НИУ «МЭИ».

Ключевые слова: машинное обучение, модель EFQM, оценка работы кафедр.

Для цитирования:

Муканова А. Р., Оцоков Ш. А. Исследование применимости методов машинного обучения для оценки деятельности кафедр. *Информатика и образование*. 2021;36(8):41–51. DOI: 10.32517/0234-0453-2021-36-8-41-51

RESEARCH OF THE APPLICABILITY OF MACHINE LEARNING METHODS FOR ASSESSMENT OF DEPARTMENTS' PERFORMANCE

A. R. Mukanova¹, Sh. A. Otsokov¹ ✉

¹ *National Research University "Moscow Power Engineering Institute"*

✉ shamil24@mail.ru

Abstract

Currently, a number of educational organizations in Russia and abroad, including the National Research University "Moscow Power Engineering Institute" (MPEI), are introducing the European improvement model EFQM, designed to analyze and improve the educational, scientific and other activities of the departments. In accordance with this model, each university department is assigned a score equal to the sum of points for two groups of criteria: criteria from the group of opportunities and criteria from the group of results. To obtain such assessments, a commission consisting of external experts, EFQM assessors and university staff meets with heads of departments. Based on the results of the discussion of the results of the meetings, the commission determines the score and rating of the departments in accordance with the EFQM model.

The purpose of the work presented in the article is to study the possibility of using machine learning to simplify the work of experts in terms of obtaining estimates according to criteria from a group of results.

The article proposes a system for evaluating the activities of departments according to criteria from a group of results based on machine learning. A program in the Python programming language has been developed, which evaluates the activities of departments according to these criteria for each department of the MPEI. The program receives the initial data for such assessments from the monitoring system of key performance indicators implemented in MPEI.

Keywords: machine learning, EFQM model, assessment of departments' performance.

For citation:

Mukanova A. R., Otsokov Sh. A. Research of the applicability of machine learning methods for assessment of departments' performance. *Informatics and Education*. 2021;36(8):41–51. DOI: 10.32517/0234-0453-2021-36-8-41-51 (In Russian.)

1. Введение

Эффективным инструментом улучшения качества системы управления любой организацией, независимо от формы собственности, сферы деятельности и размера, являются модели премий в области качества. Среди европейских организаций популярно применение модели Европейской премии качества, разработанной Европейским фондом управления качеством — European Foundation for Quality Management, EFQM. Эта модель и называется по названию разработавшего ее фонда — **модель EFQM**.

Оценка качества работы кафедр по данной модели проводится с целью стимулирования руководства к применению самооценки своей деятельности по критериям, отражающим современные подходы к управлению вузами на основе постоянного совершенствования деятельности [1].

Рассматриваемая в данной статье **модель совершенствования EFQM** состоит из двух групп критериев — «Возможности» и «Результаты».

Группа «Результаты» объединяет следующие критерии:

- результаты для потребителей;
- результаты для персонала;
- результаты для общества;
- ключевые результаты деятельности.

Эта группа критериев включает в себя основные показатели и результаты деятельности кафедры — чего достигла организация, используя имеющиеся возможности.

Выставление баллов кафедрам проводится комиссией, состоящей из внешних экспертов, ассессоров EFQM и сотрудников университета, на основе данных, полученных во время проведения встреч с заведующими кафедр.

С внедрением в Национальном исследовательском университете «МЭИ» системы мониторинга ключевых показателей деятельности, позволяющей фиксировать в базе данных численные значения показателей критериев из группы «Результаты», стало возможным использование математических методов оценки результатов деятельности кафедр.

Целью данной работы является исследование возможности применения моделей машинного обучения для упрощения работы экспертов в части получения оценок по критериям из группы «Результаты».

В качестве среды разработки использовался дистрибутив Python Anaconda. Выбор данной среды разработки обусловлен наличием хорошо документированных библиотек машинного обучения, обработки данных, построения графиков, кроссплатформенностью и удобством использования.

Методы оценки деятельности кафедр исследования по каждому из критериев группы «Результаты» независимо друг от друга, за исключением результатов для общества в связи с отсутствием на текущий момент данных в системе мониторинга ключевых показателей деятельности.

2. Методология

Существует множество типов задач машинного обучения. Одним из этих типов является задача обучения по прецедентам [2]. Постановка задачи обучения по прецедентам в общем виде формулируется следующим образом:

Дано конечное множество прецедентов (объектов, ситуаций), по каждому из которых собраны некоторые данные. Требуется по этим частным данным выявить общие зависимости, закономерности, взаимосвязи, присущие не только этой конкретной выборке, но и всем прецедентам в целом, в том числе тем, которые еще не наблюдались [3–6].

В машинном обучении данные играют незаменимую роль. Качество и количество набора данных влияет на эффективность обучения и прогнозирования [7, 8]. Поэтому немаловажным является этап подготовки имеющихся данных с помощью специальных алгоритмов обработки.

В задаче оценки деятельности кафедры по критериям EFQM из группы «Результаты» предполагаются известными множество показателей деятельности кафедр университета и множество экспертных оценок по заданным критериям. Данная задача относится к задачам регрессии, для решения которых известен ряд алгоритмов, таких как, например:

- гребневая регрессия;
- градиентный бустинг деревьев регрессии;
- многослойный персептрон.

2.1. Гребневая регрессия

Для регрессии общая прогнозная формула линейной модели выглядит следующим образом:

$$\hat{y} = w[0] \cdot x[0] + w[1] \cdot x[1] + \dots + w[p] \cdot x[p] + b, \quad (1)$$

где:

$x[0], \dots, x[p]$ — признаки для отдельной точки данных;

w, b — параметры модели, оцениваемые в ходе обучения;

$\hat{y}$ — прогноз, выдаваемый моделью.

Линейные модели для регрессии можно охарактеризовать как **регрессионные модели**, в которых прогнозом является прямая линия — для одного признака, плоскость — когда используем два признака, гиперплоскость — для большего количества измерений [7].

В гребневой регрессии коэффициенты w не только выбираются с точки зрения того, насколько хорошо они позволяют предсказывать на обучающих данных, они еще подгоняются в соответствии с дополнительным ограничением: величина коэффициентов должна быть как можно меньше. Это означает, что каждый признак должен иметь как можно меньшее влияние на результат и в то же время он должен по-прежнему обладать хорошей прогнозной силой. Это ограничение является примером регуляризации, используемой для предотвращения переобучения модели (состояние модели, в котором она не способна хорошо обобщать новые данные) [9].

2.2. Градиентный бустинг деревьев регрессии

Дерево решений — метод представления решающих правил в определенной иерархии, включающей в себя элементы двух типов — узлы и листья. Узлы включают в себя решающие правила и производят проверку значения признака с целью определить принадлежность целевой переменной к тому или иному диапазону значений [10, 11].

Прецеденты попадают в узел, проходят проверку и разбиваются на два подмножества: удовлетворяющие и не удовлетворяющие установленному правилу. Далее к каждому подмножеству снова применяется правило, процедура повторяется. Это продолжается до тех пор, пока не будет достигнуто условие останова алгоритма. Последний узел, когда не осуществляется проверка и разбиение, становится листом.

Лист определяет решение для каждого попавшего в него примера. Для дерева регрессии это соответствующий листу модальный интервал целевой переменной. В листе содержится подмножество объектов, удовлетворяющих всем правилам ветви, которая заканчивается этим листом [12].

Градиентный бустинг деревьев регрессии — метод машинного обучения, который объединяет в себе множество деревьев для создания более мощной модели. Бустинг (англ. boosting — улучшение) — это процедура последовательного построения композиции алгоритмов машинного обучения, когда каждый следующий алгоритм стремится компенсировать недостатки композиции всех предыдущих алгоритмов [13, 14].

2.3. Многослойный персептрон

Многослойный персептрон — нейронная сеть, состоящая из нескольких слоев (L1, L2), содержащих элементы — нейроны (рис. 1). Эти элементы сети имеют несколько входов, каждому из которых соответствует вес w . Нейрон, получая сигнал X , перемножает сигналы на веса и суммирует получившиеся величины, после чего передает результат другому нейрону или на выход сети [15].

Обучение нейросетей выбранного типа проводится по алгоритму обратного распространения ошибки. То есть при сравнении ответа нейросети с верным вычисляется ошибка, на основе которой корректируются значения передаваемых нейронами весов «вверх» по сети — от выходов к входам [16].

Для оценки качества построенных в рамках данной статьи моделей используется метрика R^2 — коэффициент детерминации (величина достоверности аппроксимации) [17–19].

3. Результаты

В таблице 1 приведен фрагмент данных для критерия «Результаты для потребителей», используемых в качестве обучающей и тестовой выборки для построения моделей машинного обучения. Выставление балла производится на основе фактических значений следующих показателей: средний балл ЕГЭ студентов, поступивших на кафедру, доля магистров и доля сторонних магистров в составе ППС, доля целевиков и доля трудоустроенных выпускников кафедры по отношению к плану кафедры.




Рис. 1. Архитектура многослойного персептрона
Fig. 1. Architecture of the multilayer perceptron

Таблица 1 / Table 1

Значения показателей критерия «Результаты для потребителей»

Values of indicators of the criterion "Results for consumers"

Кафедра	Средний балл ЕГЭ	Доля магистров, %	Доля сторонних магистров, %	Доля целевиков, %	Доля трудоустроенных выпускников, %	Оценка экспертов
ПГТ	65,7	28,5	9,4	4,4	88,0	70
АСУТП	67,4	35,1	27,8	11,1	93,0	130
ИТФ	74,4	23,8	7,5	5,4	90,0	65
ТЭС	67,4	41,4	34,6	3,4	90,0	105
МКМ	83,2	17,4	18,5	0,7	78,0	45

Перечисленные показатели используются в качестве признаков для построения модели машинного обучения, а выставленный экспертами EFQM балл (столбец «Оценка экспертов») является целевой переменной.

3.1. Проверка работы модели градиентного бустинга деревьев регрессии

При построении моделей машинного обучения учитывалось влияние различных параметров, задаваемых для модели, на правильность ее работы. Для повышения точности моделей использовался алгоритм решетчатого поиска, который осуществляет перебор значений параметров в заданных диапазонах с заданным шагом. Алгоритм решетчатого поиска позволяет найти значения параметров, соответствующих наибольшей точности. Выбор данного алгоритма обусловлен тем, что используемые в работе моде-

ли имели незначительное количество параметров и перебор значений этих параметров осуществлялся достаточно быстро.

Качество моделей проверяется на отдельной тестовой выборке прецедентов, и на основе этого выделяют лучшую модель с лучшей комбинацией параметров [20]. На рисунке 2 представлена тепловая карта для правильности моделей, выраженной в виде функции двух параметров: максимальной глубины деревьев и их количества, используемого для построения модели. С помощью этих параметров регулируется сложность модели, чтобы избежать переобучения и в то же время добиться высокой точности.

Из представленной тепловой карты видно, что наилучшим значением правильности обладает модель, использующая глубину деревьев, равную 3, и количество деревьев, равное 40. При этом правиль-




Рис. 2. Визуализация работы алгоритма решетчатого поиска для модели градиентного бустинга деревьев регрессии

Fig. 2. Visualization of the lattice search algorithm for the gradient boosted regression trees model




Рис. 3. Истинные и предсказанные оценки модели градиентного бустинга деревьев регрессии
Fig. 3. True and predicted estimates of the gradient boosted regression trees model

ность выставления балла по критерию «Результаты для потребителей» составила 89 %, что является приемлемым значением, учитывая малый объем используемых для обучения и тестирования модели данных.

График на рисунке 3 позволяет сравнить истинные (отображены гистограммой) и предсказанные (отмечены треугольниками для каждой кафедры из тестовой выборки) результаты. Для большей наглядности кафедры из тестовой выборки были отсортированы в порядке увеличения балла по критерию «Результаты для потребителей». Исходя из формы кривой предсказанных баллов можно сделать вывод о возможности применения данной модели для получения оценок работы кафедр. Однако наличие выбросов в предсказанных оценках не позволяет судить о высокой надежности модели.

3.2. Проверка работы модели многослойного персептрона

Модель многослойного персептрона весьма чувствительна к использованию данных, признаки которых лежат в диапазонах разного масштаба. Вследствие чего было принято решение использовать алгоритм предварительной обработки данных, а именно их масштабирования таким образом, чтобы значения всех признаков лежали в диапазоне [0; 1].

Так же как и в случае градиентного бустинга деревьев регрессии, необходимо найти набор значений двух некоррелирующих между собой и обеспечи-

вающих наибольшую точность модели параметров для многослойного персептрона. В качестве переменных рассматривалось количество скрытых слоев персептрона и параметр α , посредством которого осуществляется регуляризация модели во избежание ее переобучения. Тепловая карта для правильности моделей, выраженной в виде функции этих двух параметров, представлена на рисунке 4. Параметры лучшей модели: количество скрытых слоев = 20, $\alpha = 1$.

Правильность работы модели на тестовом наборе составила 90,8 %, что несколько выше модели деревьев регрессии, рассмотренной выше. Необходимо упомянуть, что при настолько ограниченном объеме исходных данных имеет место случайность разделения имеющихся данных на обучающий и тестовые наборы. Поэтому разница правильности моделей на 1,8 % несущественна, а высокая оценка качества позволяет судить об отличной работе алгоритма.

Один из способов анализа построенной нейронной сети заключается в исследовании весов модели. Визуализация весовых коэффициентов, которые были вычислены для элементов каждого слоя, представлена на рисунке 5. По данной матрице весов можно судить о важности признаков и корректности преобразования их значений. В данном случае признаки имеют практически одинаковую значимость.

В таблице 2 приведены значения баллов, проставленных экспертами EFQM и полученные в результате




Рис. 4. Тепловая карта для модели многослойного перцептрона

Fig. 4. Heatmap for the multilayer perceptron model




Рис. 5. Матрица весов, поступающих на вход нейронов скрытых слоев

Fig. 5. Matrix of weights entering the input of neurons of hidden layers

Таблица 2 / Table 2

Значения истинных и предсказанных моделью многослойного перцептрона баллов

Values of true scores and scores predicted by the multilayer perceptron model

Кафедра	Оценка экспертов	Оценка модели машинного обучения	Кафедра	Оценка экспертов	Оценка модели машинного обучения
ПТС	55	53,09	ЭППЭ	85	89,92
ЭЭП	60	44,68	ИТНО	90	99,39
ИЭиОТ	60	64,49	ТОТ	95	84,98
РМДиПМ	65	70,92	Эл.ст.	110	104,85
ВМСС	70	66,01	РТП и АС	120	111,94
ПГТ	70	58,01	НТ	125	139,56
ЭГТС	75	75,75	АСУТП	130	126,33




Рис. 6. Истинные и предсказанные оценки модели многослойного перцептрона

Fig. 6. True and predicted estimates of the multilayer perceptron model

работы модели многослойного перцептрона. Графическое изображение полученных оценок показано на рисунке 6. На основе представленных данных можно оценить степень различия между оценками. В подавляющем большинстве прецедентов разница не превышает 10 баллов.

Для критериев «Результаты для персонала» и «Ключевые результаты» также были построены

модели МО и проведен анализ полученных результатов (рис. 7–9).

3.3. Проверка работы модели гребневой регрессии

Среди рассматриваемых гребневая регрессия является наиболее простой в понимании и построении моделью. Также для обучения модели не потребова-




Рис. 7. Тепловая карта правильности при подборе параметров для градиентного бустинга

Fig. 7. Heatmap of correctness when selecting parameters for gradient boosting




Рис. 8. Тепловая карта правильности при подборе параметров для многослойного персептрона
Fig. 8. Heat map of correctness in the selection of parameters for the multilayer perceptron




Рис. 9. Истинные и предсказанные оценки
Fig. 9. True and predicted estimates

лись поиск оптимальных параметров и масштабирование данных.

Наиболее высокие показатели правильности показала модель гребневой регрессии, построенная на

наборе данных для критерия «Ключевые результаты», ее показатель правильности составил 98,8 %.

В таблице 3 представлены численные значения коэффициентов для каждого показателя, входящего

Таблица 3 / Table 3

Значения коэффициентов в модели гребневой регрессии Coefficient values in the ridge regression model

Показатель	Коэффициент
Публикации	7,851
Доля иностранных студентов	1,687
Доля иностранных преподавателей	28,141
Академическая мобильность	2,249
Платные образовательные услуги (ПОУ)	0,0217
Научно-исследовательские и опытно-конструкторские работы (НИОКР)	0,0168



Рис. 10. Истинные и предсказанные оценки модели гребневой регрессии
Fig. 10. True and predicted ridge regression model estimates

в состав критерия «Ключевые результаты», полученные в результате работы модели гребневой регрессии. Константа регрессионной модели (1) составила 3,53. Эта величина является баллом кафедры при нулевом значении всех показателей. Как видно, она вносит незначительный вклад в выставяемый балл, который зависит в основном от величины значений показателей, что соответствует принципам системы EFQM.

Представленные в таблице 3 показатели являются относительными величинами и вычислены как отношение фактических значений данных показателей к плановым для кафедры.

Учитывая разный по масштабу диапазон значений данных для показателей (например, значение показателя «ПОУ» может на несколько порядков отличаться от показателя «Публикации»), можно

сделать вывод о примерно равном влиянии показателей на результирующую оценку, предсказанную моделью. График на рисунке 10 позволяет сравнить истинные и предсказанные результаты.

Данные в таблице 4 позволяют сравнить используемые модели машинного обучения с точки зрения правильности выдаваемых ими результатов.

Отметим, что для каждого из критериев используется определенный моделью EFQM набор показателей. В зависимости от набора данных меняется и качество модели машинного обучения. Оптимальным выбором для получения оценок по критерию «Результаты для потребителей» будет модель многослойного персептрона, градиентный бустинг деревьев подойдет при оценке по критерию «Результаты для персонала», а для критерия «Ключевые результаты»

Таблица 4 / Table 4

Значения коэффициентов детерминации для сравнительного анализа качества работы моделей The values of the coefficients of determination for the comparative analysis of the quality of the models

Критерий	Модель		
	Гребневая регрессия	Градиентный бустинг деревьев регрессии	Многослойный персептрон
Результаты для потребителей	0,712	0,893	0,908
Результаты для персонала	0,904	0,931	0,875
Ключевые результаты	0,988	0,583	0,961

наилучший результат показала модель гребневой регрессии.

4. Выводы

Авторами проведено исследование возможности применения моделей машинного обучения для упрощения работы экспертов в части получения оценок по критериям из группы «Результаты». Разработана программа на языке Python, включающая в себя построение моделей машинного обучения, проверку качества их работы и подбор оптимальных параметров, получение с их помощью баллов по критериям из группы «Результаты». Проведен сравнительный анализ предсказанных моделями оценок.

В ходе исследования получены три модели машинного обучения — гребневой регрессии, градиентного бустинга деревьев регрессии, многослойный перцептрон, — точность предсказанных оценок которых превышает 90 % для каждого из критериев группы «Результаты».

Опираясь на полученные результаты, можно сделать вывод о перспективности применения машинного обучения для оценки деятельности кафедр по системе EFQM.

Список источников / References

1. Маслов Д. В., Мазалецкая А., Стид К. Модель совершенствования EFQM. *Высшее образование в России*. 2005;(9):48–55.

Maslov D. V., Mazaleczkaya A., Stid K. Model of EFQM improvement. *Vysshee Obrazovanie v Rossii = Higher Education in Russia*. 2005;(9):48–55.

2. Овсянников А. Д. Об использовании терминов «искусственный интеллект», «машинное обучение» и «глубокое обучение». *Цифровая экономика в социально-экономическом развитии России: взгляд молодых. Материалы XV международной научно-практической конференции студентов, магистрантов и аспирантов*. Челябинск; 2019. С. 549–551.

Ovsyanitskiy A. D. On the use of the terms “artificial intelligence”, “machine learning” and “deep learning”. *The digital economy in the socio-economic development of Russia: the view of the young. Proc. 15th Int. Scientific and Practical Conf.* Chelyabinsk; 2019. P. 549–551.

3. Профессиональный информационно-аналитический ресурс, посвященный машинному обучению, распознаванию образов и интеллектуальному анализу данных. Режим доступа: <http://www.machinelearning.ru>

Professional information and analytical resource dedicated to machine learning, pattern recognition and data mining. Available at: <http://www.machinelearning.ru>

4. Галимов Р. Г. Основы алгоритмов машинного обучения — обучение с учителем. *Аллея науки*. 2017;1(14):810–817.

Galimov R. G. Fundamentals of machine learning algorithms — supervised learning. *Alley of Science*. 2017;1(14):810–817.

5. Stanula P., Ziegenbein A., Metternich J. Machine learning algorithms in production: A guideline for efficient data source selection. *Procedia CIRP*. 2018;78:261–266. DOI: 10.1016/j.procir.2018.08.177

6. Portugal I., Alencar P., Cowan D. The use of machine learning algorithms in recommender systems: A systematic review. *Expert Systems with Applications*. 2018;97:205–227. DOI: 10.1016/j.eswa.2017.12.020

7. Мюллер А., Гвидо С. Введение в машинное обучение с помощью Python: пер. с англ. М.: Альфа-книга; 2018. 480 с.
Müller A., Guido S. An introduction to machine learning with Python. Moscow, Al'fa-kniga; 2018. 480 p.

8. Shalev-Shwartz S., Ben-David S. Understanding machine learning: From theory to algorithms. New York, Cambridge University Press; 2014. 449 p. DOI: 10.1017/SBO9781107298019

9. Клячкин В. Н. Метод оценки параметра гребневой регрессии. *Вестник Ульяновского государственного технического университета*. 1998;(1):38–40.

Klyachkin V. N. A method for estimating the parameter of ridge regression. *Bulletin of the Ulyanovsk State Technical University*. 1998;(1):38–40.

10. Бородин И. Д. Рефлексия в машинном обучении на примере обучения деревьев решений. *Аллея науки*. 2017;4(9):857–865.

Borodin I. D. Reflection in machine learning on the example of learning decision trees. *Alley of Science*. 2017;4(9):857–865.

11. Леусенко В. П. Принятие решений с рассмотрением полезностей. Деревья решений. Актуальные проблемы современной экономики. *Математические методы, модели и информационные технологии. Материалы XVIII научно-практической конференции преподавателей, студентов, аспирантов и молодых ученых*. Таганрог; 2017. С. 184–187.

Leusenko V. P. Decision making with consideration of utility. Decision trees. *Mathematical methods, models and information technologies. Proc. 18th Scientific and Practical Conf.* Taganrog; 2017. P. 184–187.

12. Azad M., Moshkov M. Multi-stage optimization of decision and inhibitory trees for decision tables with many-valued decisions. *European Journal of Operational Research*. 2017;263(3):910–921. DOI: 10.1016/j.ejor.2017.06.026

13. Кафтаников И. В., Парасич А. В. Методы снижения взаимозависимости ошибок деревьев решений при обучении лесов решений. *Научный поиск. Материалы VII научной конференции аспирантов и докторантов*. Челябинск; 2015. С. 315–320.

Kaftannikov I. V., Parasich A. V. Methods for reducing the interdependence of decision tree errors in training decision forests. *Scientific search. Proc. 7th Scientific Conf.* Chelyabinsk; 2015. P. 315–320.

14. Дьяконов И. Д., Новикова С. В. Решение задачи прогнозирования при помощи градиентного бустинга над решающими деревьями. *Научный форум: технические и физико-математические науки. Материалы XV международной научно-практической конференции*. М.; 2018. С. 9–12.

Dyakonov I. D., Novikova S. V. Solution of the forecasting problem using gradient boosting over decision trees. *Scientific forum: technical and physical and mathematical sciences. Proc. 15th Int. Scientific and Practical Conf.* Moscow; 2018. P. 9–12.

15. Чаткин В. В. Различия между искусственным интеллектом, машинным обучением и глубоким обучением. *Конкурентоспособность территорий. Материалы XXII Всероссийского экономического форума молодых ученых и студентов*. Екатеринбург; 2019. С. 185–187.

Chatkin V. V. Differences between artificial intelligence, machine learning and deep learning. *Territories competitiveness. Proc. 22nd All-Russian Economic Forum of Young Scientists and Students*. Ekaterinburg; 2019. P. 185–187.

16. Мингалиев З. З., Кычкин И. М. Решение обратных многомерных задач на основе многослойного перцептрона. *Вестник современных исследований*. 2019;(3.3):30–34.

Mingaliev Z. Z., Kychkin I. M. Solution of multidimensional inverse problems based on multilayer perceptron. *Bulletin of Modern Research*. 2019;(3.3):30–34.

17. Арефьев А. В., Шумаев В. В. Оценка значимости уравнения регрессии, его коэффициентов, коэффициента детерминации. *Инновационные идеи молодых исследователей для агропромышленного комплекса России. Мате-*

риалы Всероссийской научно-практической конференции студентов, аспирантов и молодых ученых. Пенза; 2019. С. 103–104.

Arefiev A. V., Shumaev V. V. Estimation of the significance of the regression equation, its coefficients, the coefficient of determination. *Innovative ideas of young researchers for the agro-industrial complex of Russia. Proc. All-Russian Scientific and Practical Conf.* Penza; 2019. P. 103–104.

18. Кинякин В. Н., Милевская Ю. С. Некоторые предостережения по проверке качества модели регрессии с помощью коэффициента детерминации. *Вестник Московского университета МВД России*. 2014;(8):200–204.

Kinyakin V. N., Milevskaya Yu. S. Some caveats for checking the quality of a regression model using the coefficient of determination. *Bulletin of the Moscow University of the Ministry of Internal Affairs of Russia*. 2014;(8):200–204.

19. Базилевский М. П. Отбор оптимального числа информативных регрессоров по скорректированному коэффициенту детерминации в регрессионных моделях как задача частично целочисленного линейного программирования. *Прикладная математика и вопросы управления*. 2020;(2):41–54. DOI: 10.15593/2499-9873/2020.2.03

Bazilevskii M. P. Selection an optimal number of variables in regression models using adjusted coefficient of determination as a mixed integer linear programming problem. *Applied Mathematics and Control Sciences*. 2020;(2):41–54. DOI: 10.15593/2499-9873/2020.2.03

20. Бринк Х., Ричардс Д., Феверолф М. Машинное обучение. СПб.: Питер; 2017. 336 с.

Brink X., Richards D., Feverolf M. Machine learning. Saint Petersburg, Piter; 2017. 336 p.

Информация об авторах

Муканова Александра Ренатовна, студентка 4-го курса бакалавриата кафедры вычислительных машин, систем и сетей, Институт информационных и вычислительных технологий, Национальный исследовательский университет «МЭИ», г. Москва, Россия; ORCID: <http://orcid.org/0000-0003-2973-7148>; e-mail: aleksmukanova@mail.ru

Оцоков Шамиль Алиевич, доктор тех. наук, доцент кафедры вычислительных машин, систем и сетей, Институт информационных и вычислительных технологий, Национальный исследовательский университет «МЭИ», г. Москва, Россия; ORCID: <http://orcid.org/0000-0001-7451-5443>; e-mail: shamil24@mail.ru

Information about the authors

Alexandra R. Mukanova, a 4th year undergraduate student of the Department of Computing Machines, Systems and Networks, Institute of Information Technologies and Computer Science, National Research University “Moscow Power Engineering Institute”, Moscow, Russia; ORCID: <http://orcid.org/0000-0003-2973-7148>; e-mail: aleksmukanova@mail.ru

Shamil A. Otsokov, Doctor of Sciences (Engineering), Associate Professor at the Department of Computing Machines, Systems and Networks, Institute of Information Technologies and Computer Science, National Research University “Moscow Power Engineering Institute”, Moscow, Russia; ORCID: <http://orcid.org/0000-0001-7451-5443>; e-mail: shamil24@mail.ru

Поступила в редакцию / Received: 07.03.2021.

Поступила после рецензирования / Revised: 01.06.2021.

Принята к печати / Accepted: 08.06.2021.