



Math-Net.Ru

All Russian mathematical portal

V. A. Borodin, O. M. Protalinskiy, V. F. Shurshev, Using machine learning methods in power equipment repair programs, *Vestn. Astrakhan State Technical Univ. Ser. Management, Computer Sciences and Informatics*, 2019, Number 3, 25–33

<https://www.mathnet.ru/eng/vagtu585>

Use of the all-Russian mathematical portal Math-Net.Ru implies that you have read and agreed to these terms of use

<https://www.mathnet.ru/eng/agreement>

Download details:

IP: 18.97.14.88

April 22, 2025, 13:00:24



КОМПЬЮТЕРНОЕ ОБЕСПЕЧЕНИЕ И ВЫЧИСЛИТЕЛЬНАЯ ТЕХНИКА

DOI: 10.24143/2072-9502-2019-3-25-33
УДК 004.8

ИСПОЛЬЗОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ПРИ СОСТАВЛЕНИИ ПРОГРАММ РЕМОНТА ЭНЕРГЕТИЧЕСКОГО ОБОРУДОВАНИЯ

В. А. Бородин¹, О. М. Проталинский², В. Ф. Шуришев¹

¹ *Астраханский государственный технический университет,
Астрахань, Российская Федерация*

² *Национальный исследовательский университет «МЭИ»,
Москва, Российская Федерация*

Рассматривается процесс планирования ремонта энергетического оборудования. Ввиду наличия большого количества правил сопоставления технологических карт дефектам оборудования предлагается использование системы поддержки принятия решений. Такая система может ускорить процесс планирования и снизить экономические затраты. Построена концептуальная модель системы, далее она представлена в виде задачи классификации с пересекающимися классами. Использован подход «один против всех» – для каждой технологической карты создан отдельный классификатор. Для оценки классификаторов предложены метрики: доля верно классифицированных объектов, точность, полнота и F -мера. Для обобщения результатов оценки выбрана концепция микро-усреднения. Описан алгоритм классификации дефектов. Проведен эксперимент с использованием разных алгоритмов классификации: деревьев принятия решений, байесовского классификатора и многослойного персептрона. В результате эксперимента установлено, что верно классифицированных объектов обнаружено 80–90 % (высокие значения), но средние значения точности и полноты оказались низкими (3–7 %). Также были обнаружены наборы данных, где одинаковым входным данным соответствуют разные выходные. Таким образом, машинное обучение может быть использовано для поддержки принятия решений, но в некоторых случаях информации о заказе недостаточно. Классификация дефектов может сочетаться с уточнением результатов в ручном режиме или с другими алгоритмами.

Ключевые слова: система поддержки принятия решений, система управления производственными активами, технологические карты, дефекты, оборудование, ремонтная программа, классификатор.

Для цитирования: *Бородин В. А., Проталинский О. М., Шуришев В. Ф.* Использование методов машинного обучения при составлении программ ремонта энергетического оборудования // Вестник Астраханского государственного технического университета. Серия: Управление, вычислительная техника и информатика. 2019. № 3. С. 25–33. DOI: 10.24143/2072-9502-2019-3-25-33.

Введение

Энергетика является одной из самых важных отраслей промышленности. Отказы в работе энергетических предприятий могут привести как к серьезным экономическим потерям, так и к негативным социальным последствиям. Для того чтобы снизить количество аварийных ситуаций, необходимо постоянное обслуживание и своевременный ремонт энергетического оборудования. Внедрение систем управления производственными активами позволяет сократить риски отказов и провести оптимальное планирование ремонтных программ. Ввиду широкого распространения энергетического оборудования и высокой его стоимости даже незначительная

оптимизация процесса может привести к существенному снижению затрат, а также к улучшению условий труда персонала [1].

Для того чтобы спланировать ремонт оборудования, рассматриваются нормативные документы – технологические карты, которые содержат данные о затратах, необходимых при проведении работ; данные об использовании инструментов, машин, механизмов и материалов; о квалификации и объемах трудовых ресурсов, мерах безопасности [2, 3].

Для составления ремонтной программы необходимо сопоставить дефекты оборудования технологическим картам. В некоторых системах управления производственными активами возможен только ручной ввод прямых соответствий между ними. На крупных предприятиях может учитываться большое количество типов оборудования, технологических карт и типовых дефектов; неавтоматизированная работа с такими объемами документов может быть неэффективна по времени и приводить к ошибкам, т. к. требует запоминания большого количества правил. Другая проблема – передача опыта от одного сотрудника к другому. Все это подтверждает актуальность использования системы поддержки принятия решений при составлении ремонтной программы. Вопросам разработки подобных систем посвящены работы [4–15].

Цель разработки – поиск путей снижения экономических потерь за счет повышения эффективности процесса планирования. На первом этапе достижения поставленной цели основной задачей является построение математической модели системы.

Концептуальная модель сопоставления

Рассмотрим основные сущности, используемые при планировании ремонтной программы.

Неисправности определяются типовыми дефектами, характерными для того или иного типа оборудования. Типы оборудования – это конкретные модели, например трансформатор или опора линии электропередач. Технологическая карта – это документ, описывающий выполнение определенных работ. Тогда сопоставление технологических карт дефектам можно представить в виде концептуальной модели

$$Tcrds = f(Dfs), \quad (1)$$

где $Dfs \subseteq \{Df_1, Df_2, \dots, Df_n\}$ – подмножество дефектов, выявленных у единицы оборудования, принадлежит множеству типовых дефектов; $Tcrds \subseteq \{Tcrd_1, Tcrd_2, \dots, Tcrd_m\}$ – подмножество технологических карт для устранения данных дефектов.

Эту концептуальную модель можно представить как задачу классификации с пересекающимися классами (*multi-label classification*) [16], т. к. возможно соответствие набора дефектов нескольким технологическим картам (рис. 1).

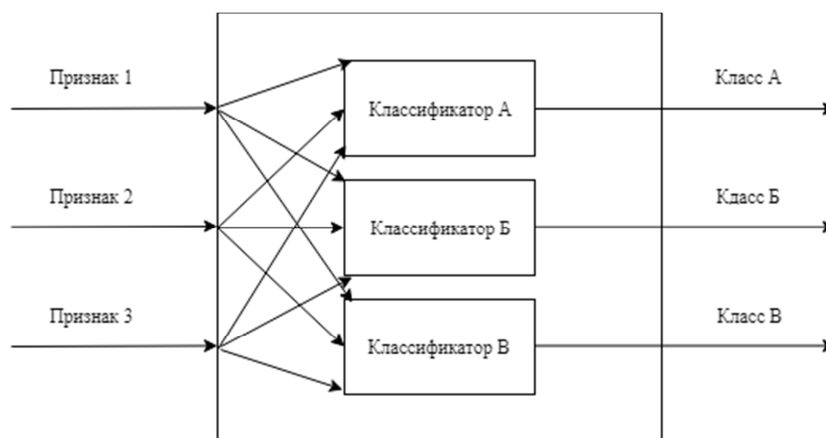


Рис. 1. Задача классификации с пересекающимися классами

Для решения задачи используют подход «один против всех» (*one-vs-rest*), где для каждого класса создается свой бинарный классификатор.

Далее математическая модель была проверена на наборе данных о назначении технологических карт дефектам из системы управления производственными активами. Данные состояли из информации о единице оборудования, наборе дефектов в заказе и назначенных технологических картах. Вычисление коэффициента корреляции Пирсона показало корреляционную связь появления технологической карты при наличии дефекта в заказе на ремонт.

Проверка адекватности модели

Дальнейший этап разработки системы поддержки принятия решений – поиск эффективного классификатора. Данные заказов на ремонт разбиты на тестовую и обучающую выборки. Модель классификации была протестирована на нескольких классификаторах: деревьях принятия решений, байесовском классификаторе и многослойном персептроне [17–20]. На основе подхода «один против всех» для каждой технологической карты создан классификатор, обученный на заказах, для определения необходимости использования технологической карты при данном наборе дефектов.

Для оценки работы классификаторов были вычислены метрики: доля верно классифицированных объектов, точность, полнота и F -мера [18].

Для вычисления метрик необходимо рассчитать следующие показатели: TP – количество истинно-положительных срабатываний классификатора, TN – количество истинно-отрицательных, FP – количество ложно-положительных, FN – количество ложно-отрицательных.

Тогда доля верно классифицированных объектов рассчитывается следующим образом:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}.$$

Точность вычисляется как доля документов, действительно принадлежащих данному классу, относительно всех документов, которые система отнесла к этому классу:

$$Precision = \frac{TP}{TP + FP}.$$

Полнота рассчитывается как доля найденных классификатором документов, принадлежащих классу, относительно всех документов этого класса в тестовой выборке:

$$Recall = \frac{TP}{TP + FN}.$$

F -мера вычисляется как гармоническое среднее между точностью и полнотой:

$$F = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}.$$

Для обобщения результатов всех классификаторов выбрана концепция микро-усреднения (значения метрик всех классификаторов усредняются).

Таким образом, алгоритм классификации дефектов состоял из нескольких этапов. Данные сгруппированы по номеру заказа ремонтной программы. Неполные данные без дефектов или технологических карт исключены из множества. Повторяющиеся заказы также исключены. Далее множества дефектов и технологических карт были упорядочены и представлены в виде логической матрицы. Каждая строка матрицы содержит информацию о заказе. Первые N столбцов матрицы соответствуют дефектам, следующие M столбцов – технологическим картам. Значение «истина» соответствует наличию данного дефекта или технологической карты в заказе, «ложь» – отсутствию (рис. 2).

Дефект 1	Дефект 2	Дефект 3	...	Тех. карта 1	Тех. карта 2	Тех. карта 3	..
1	1	0		0	1	1	
0	1	0		1	0	0	
1	1	1		1	1	1	
1	0	0		0	0	1	

Рис. 2. Пример логической матрицы для классификации

На следующем этапе вычислен коэффициент корреляции между дефектами и каждой технологической картой. Затем для каждого классификатора (дерева принятия решений, байесовский классификатор, многослойный перцептрон) произведено обучение и сбор метрик оценки точности классификаторов (рис. 3).



Рис. 3. Алгоритм классификации

Результаты исследования

Все классификаторы показали высокий процент правильно классифицированных объектов – около 80–90 %. Однако средние значения остальных метрик оказались низкими (3–7 %) (рис. 4–6).

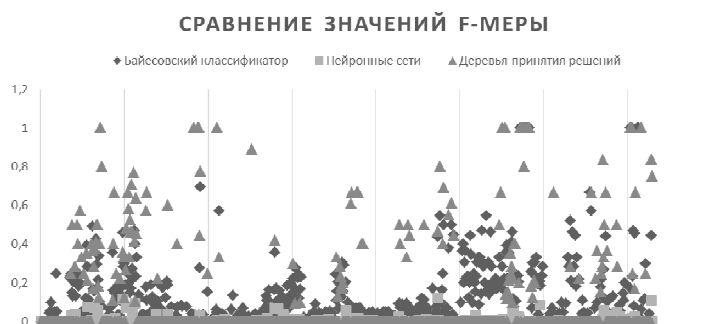


Рис. 4. Сравнение значений F -меры для разных классификаторов




Рис 5. Доля верно классифицированных объектов и F -мера для различных технологических карт в выборке




Рис. 6. Значение F -меры для разных технологических карт при классификации деревьями принятия решений

Для объяснения такого разрыва значений метрик результаты классификации проанализированы более подробно. Проведено обучение на всей выборке. Средние значения метрик выросли, но не превышали 70 % для точности и 40 % для полноты и F -меры. Даже с учетом эффекта переобучения для некоторых технологических карт полнота и точность классификаторов остались нулевыми. Анализ показал, что в некоторых заказах один и тот же набор дефектов приводит к отличающимся наборам технологических карт. Эти данные могут быть уточнены,

если добавить в модель информацию о типе оборудования, что повысит эффективность классификации. Но для части данных существуют заказы, в которых для одного и того же набора дефектов и типа оборудования используются разные технологические карты. Таким образом, машинное обучение может быть эффективным способом поддержки принятия решений, но невозможно автоматизировать процесс составления ремонтной программы только с его помощью. В некоторых случаях необходимо комбинирование алгоритма с другими методами либо уточнение результатов работы классификаторов пользователем системы.

Заключение

Машинное обучение может быть эффективным способом поддержки принятия решений, но не позволяет полностью автоматизировать процесс составления ремонтной программы. Неравномерное распределение технологических карт в заказах, недостаточный объем выборки, конфликтующие сэмплы снижают эффективность алгоритма. Для решения этой проблемы в процессе развития системы могут быть использованы эвристические алгоритмы, исключающие неэффективные бинарные классификаторы. Кроме того, при обнаружении низких значений метрик или наличии конфликтующих сэмплов решение о выборе технологических карт может производиться пользователем системы – накопление данных в процессе эксплуатации системы и последующее переобучение могут повысить эффективность классификаторов.

СПИСОК ЛИТЕРАТУРЫ

1. Проталинский О. М., Проталинский И. О., Кладов О. Н. Система оптимального управления производственными активами энергетических предприятий // Автоматизация и ИТ в энергетике. 2017. № 4 (93). С. 5–8.
2. Яцура А. И. Система технического обслуживания и ремонта энергетического оборудования: справ. М.: НЦ ЭНАС, 2006. 491 с.
3. Методические указания по разработке технологических карт и проектов производства работ по техническому обслуживанию и ремонту ВЛ // ПАО «ФСК ЕЭС». URL: http://www.fsk-ees.ru/upload/docs/STO_56947007-29.240.55.168-2014.pdf (дата обращения: 30.04.2019).
4. Шуришев В. Ф., Кочкин Г. А., Кочкина В. Р. Модель системы поддержки принятия решений на основе рассуждений по прецедентам // Вестн. Астрахан. гос. техн. ун-та. Сер.: Управление, вычислительная техника и информатика. 2013. № 2. С. 175–183.
5. Звезинцев А. И., Квятковская И. Ю. Применение модифицированного алгоритма генетического программирования для идентификации математических моделей путем расширения обучающего множества искусственной нейронной сетью // Вестн. Астрахан. гос. техн. ун-та. Сер.: Управление, вычислительная техника и информатика. 2013. № 2. С. 58–65.
6. Орехова Т. П., Квятковская И. Ю. Функциональная подсистема управления основными средствами АСУП энергосетевой компании // Вестн. Астрахан. гос. техн. ун-та. Сер.: Управление, вычислительная техника и информатика. 2012. № 1. С. 49–55.
7. Проталинский О. М., Ханова А. А., Щербатов И. А., Проталинский И. О., Кладов О. Н., Уразалиев Н. С., Степанов П. В. Онтология процесса управления ремонтами в электросетевой компании // Вестн. Моск. энергет. ин-та. 2018. № 6. С. 110–119.
8. Бялецкая Е. М., Квятковская И. Ю. О принципах когнитивного моделирования сложных систем // Вестн. Астрахан. гос. техн. ун-та. 2006. № 1 (30). С. 116–119.
9. Шуришев В. Ф., Демич Н. В. Исследование алгоритма комплексного эволюционного метода, применяемого в компьютерной системе поддержки принятия решения о выборе состава холодильных агентов, с помощью вычислительных экспериментов // Вестн. Астрахан. гос. техн. ун-та. 2006. № 1 (30). С. 141–146.
10. Проталинский О. М., Проталинская Ю. О., Проталинский И. О., Щербатов И. А., Кладов О. Н. Система управления производственными активами предприятий энергетики ЕАМОptima // Автоматизация и ИТ в энергетике. 2018. № 9 (110). С. 24–26.
11. Лисин И. Ю., Короленок А. М., Колотилов Ю. В., Карлина Е. П., Шуришев В. Ф. Системный анализ информационных потоков технической документации для поддержки решений при планировании ремонтных работ // Территория Нефтегаз. 2018. № 11. С. 12–17.
12. Шуришев В. Ф., Демич О. В. Использование метода самоорганизации поиска в задаче поддержки принятия решения при определении компонентов системы энергоучета // Вестн. Кузбас. гос. техн. ун-та. 2005. № 5. С. 25–27.
13. Квятковская И. Ю. Этапы проблемно-ориентированной методологии поддержки принятия управленческих решений для слабоструктурированных проблем // Вестн. Астрахан. гос. техн. ун-та. Сер.: Управление, вычислительная техника и информатика. 2009. № 1. С. 60–65.

14. Шадлов Д. В., Галимова Л. В., Хоменко Т. В., Шуршев В. Ф. Формализация алгоритма принятия решений при определении очередности производства ремонтных работ // Ремонт. Восстановление. Модернизация. 2018. № 4. С. 36–39.
15. Умеров А. Н., Шуршев В. Ф. Методы и программные средства аппроксимации экспериментальных данных // Вестн. Астрахан. гос. техн. ун-та. 2005. № 1. С. 97–104.
16. Multi Label Text Classification with Scikit-Learn // Towards Data Science. URL: <https://towardsdatascience.com/multi-label-text-classification-with-scikit-learn-30714b7819c5> (дата обращения: 30.04.2019).
17. Сегаран Т. Программируем коллективный разум. СПб.: Символ-Плюс, 2008. 368 с.
18. Hacking G. Mastering Machine Learning with scikit-learn. Packt Publishing Ltd, 2014. 238 p.
19. Рассел С., Норвиг П. Искусственный интеллект: современный подход: 2 изд. М.: ООО «И. Д. Вильямс», 2016. 1408 с.
20. Круглов В. В., Дли М. И., Голунов Р. Ю. Нечеткая логика и искусственные нейронные сети. М.: Физматлит, 2001. 201 с.

Статья поступила в редакцию 31.05.2019

ИНФОРМАЦИЯ ОБ АВТОРАХ

Бородин Виталий Александрович – Россия, 414056, Астрахань; Астраханский государственный технический университет; аспирант кафедры автоматизации и управления; vitkt@yandex.ru.

Проталинский Олег Мирославович – Россия, 111250, Москва; Национальный исследовательский университет «МЭИ»; д-р техн. наук, профессор; профессор кафедры автоматизированных систем управления тепловыми процессами; protalinskiy@gmail.com.

Шуршев Валерий Фёдорович – Россия, 414056, Астрахань; Астраханский государственный технический университет; д-р техн. наук, профессор; профессор кафедры прикладной информатики; v.shurshev@mail.ru.



USING MACHINE LEARNING METHODS IN POWER EQUIPMENT REPAIR PROGRAMS

V. A. Borodin¹, O. M. Protalinskiy², V. F. Shurshev¹

¹ *Astrakhan State Technical University,
Astrakhan, Russian Federation*

² *National Research University “Moscow Power Engineering Institute”,
Moscow, Russian Federation*

Abstract. The article discusses the process of planning the repair of energy equipment. Using a decision support system is proposed because of the large number of rules of comparing flow charts of technical defects. Such a system can speed up the planning process and reduce economic costs. A conceptual model of the system has been built; further it will be presented as a multi-label classification of cross-cutting classes. The “one-vs-all” approach has been used: each flow chart can use its individual classifier. Metrics are proposed for evaluating classifiers: a portion of accurately classified objects, precision, fullness and F-measure. To summarize the evaluation results the concept of micro-average was chosen. A defect classification algorithm has been described. An experiment was conducted using different classification algorithms: decision trees, Bayes classifier and multi-layer perceptron. The results of the experiment proved that 80-90% of the correctly classified objects were found (high values), but the average values of accuracy and fullness occurred low (3–7%). There were found sets of data, where different output data corresponded to similar input data. Thus, machine learning can be used to support decision-making, but in some cases infor-

mation about the order is not complete. Defect classification can be combined with manual clarifying of results or with different algorithms.

Key words: decision support system, asset management system, flow charts, defects, equipment, repair program, classifier.

For citation: Borodin V. A., Protalinskiy O. M., Shurshev V. F. Using machine learning methods in power equipment repair programs. *Vestnik of Astrakhan State Technical University. Series: Management, Computer Science and Informatics*. 2019;3:25-33. (In Russ.) DOI: 10.24143/2072-9502-2019-3-25-33.

REFERENCES

1. Protalinskiy O. M., Protalinskiy I. O., Kladov O. N. Sistema optimal'nogo upravleniya proizvodstvennymi aktivami energeticheskikh predpriyatij [System of optimal management of production assets of energy enterprises]. *Avtomatizatsiya i IT v energetike*, 2017, no. 4 (93), pp. 5-8.
2. Yashchura A. I. *Sistema tekhnicheskogo obsluzhivaniya i remonta energeticheskogo oborudovaniya: spravochnik* [System of maintenance and repair of power equipment: guidebook]. Moscow, NC ENAS, 2006. 491 p.
3. *Metodicheskie ukazaniya po razrabotke tekhnologicheskikh kart i proektov proizvodstva rabot po tekhnicheskomu obsluzhivaniyu i remontu VL* [Guidelines for developing process charts and projects of maintenance and repair of high voltage lines]. PAO «FSK EES». Available at: http://www.fsk-ees.ru/upload/docs/STO_56947007-29.240.55.168-2014.pdf (accessed: 30.04.2019).
4. Shurshev V. F., Kochkin G. A., Kochkina V. R. Model' sistemy podderzhki prinyatiya reshenij na osnove rassuzhdenij po precedentam [Model decision support system based on reasoning precedents]. *Vestnik Astrahanskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika i informatika*, 2013, no. 2, pp. 175-183.
5. Zvezincev A. I., Kvyatkovskaya I. Yu. Primenenie modifitsirovannogo algoritma geneticheskogo programmirovaniya dlya identifikatsii matematicheskikh modelej putem rasshireniya obuchayushchego mnozhestva iskusstvennoj nejronnoj set'yu [Application of a modified genetic programming algorithm to identify mathematical models by expanding the training set with artificial neural network]. *Vestnik Astrahanskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika i informatika*, 2013, no. 2, pp. 58-65.
6. Orekhova T. P., Kvyatkovskaya I. Yu. Funktsional'naya podsistema upravleniya osnovnymi sredstvami ASUP energosetевой kompanii [Functional subsystem of fixed assets management of automated technical process management system in energy company]. *Vestnik Astrahanskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika i informatika*, 2012, no. 1, pp. 49-55.
7. Protalinskiy O. M., Hanova A. A., Shcherbatov I. A., Protalinskiy I. O., Kladov O. N., Urazaliev N. S., Stepanov P. V. Ontologiya processa upravleniya remontami v elektrosetевой kompanii [Ontology of repair management process in the electric grid company]. *Vestnik Moskovskogo energeticheskogo instituta*, 2018, no. 6, pp. 110-119.
8. Byaleckaya E. M., Kvyatkovskaya I. Yu. O principah kognitivnogo modelirovaniya slozhnykh sistem [On principles of cognitive modeling of complex systems]. *Vestnik Astrahanskogo gosudarstvennogo tekhnicheskogo universiteta*, 2006, no. 1 (30), pp. 116-119.
9. Shurshev V. F., Demich N. V. Issledovanie algoritma kompleksnogo evolyucionnogo metoda, primenyaemogo v komp'yuternoj sisteme podderzhki prinyatiya resheniya o vybore sostava holodil'nykh agentov, s pomoshch'yu vychislitel'nykh eksperimentov [Studying the algorithm of complex evolutionary method used in computer decision support system on the choice of refrigerants composition using computational experiments]. *Vestnik Astrahanskogo gosudarstvennogo tekhnicheskogo universiteta*, 2006, no. 1 (30), pp. 141-146.
10. Protalinskiy O. M., Protalinskaya Yu. O., Protalinskiy I. O., Shcherbatov I. A., Kladov O. N. Sistema upravleniya proizvodstvennymi aktivami predpriyatij energetiki EAMOptima [EAMOptima System of energy assets control]. *Avtomatizatsiya i IT v energetike*, 2018, no. 9 (110), pp. 24-26.
11. Lisin I. Yu., Korolenok A. M., Kolotilov Yu. V., Karlina E. P., Shurshev V. F. Sistemnyy analiz informatsionnykh potokov tekhnicheskoy dokumentatsii dlya podderzhki reshenij pri planirovanii remontnykh rabot [System analysis of information flow of technical documentation to support decisions in planning repair work]. *Territoriya Neftegaz*, 2018, no. 11, pp. 12-17.
12. Shurshev V. F., Demich O. V. Ispol'zovanie metoda samoorganizatsii poiska v zadache podderzhki prinyatiya resheniya pri opredelenii komponentov sistemy energoucheta [Using method of self-organization of search in the task of supporting decision-making in determining the components of the energy accounting system]. *Vestnik Kuzbasskogo gosudarstvennogo tekhnicheskogo universiteta*, 2005, no. 5, pp. 25-27.
13. Kvyatkovskaya I. Yu. Etapy problemno-orientirovannoy metodologii podderzhki prinyatiya upravlencheskikh reshenij dlya slabostruktirovannykh problem [Stages of problem-oriented methodology for supporting management decision-making for weakly structured problems]. *Vestnik Astrahanskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika i informatika*, 2009, no. 1, pp. 60-65.

14. Shadlov D. V., Galimova L. V., Homenko T. V., Shurshev V. F. Formalizaciya algoritma prinyatiya reshenij pri opredelenii ocherednosti proizvodstva remontnyh rabot [Formalization of decision-making algorithm in determining the order of repair work]. *Remont. Vosstanovlenie. Modernizaciya*, 2018, no. 4, pp. 36-39.

15. Umerov A. N., Shurshev V. F. Metody i programmnye sredstva approksimacii eksperimental'nyh dannyh [Methods and software for experimental data approximation]. *Vestnik Astrahanskogo gosudarstvennogo tekhnicheskogo universiteta*, 2005, no. 1, pp. 97-104.

16. *Multi Label Text Classification with Scikit-Learn. Towards Data Science*. Available at: <https://towardsdatascience.com/multi-label-text-classification-with-scikit-learn-30714b7819c5> (accessed: 30.04.2019).

17. Segaran T. *Programmiruem kollektivnyj razum* [We program the collective mind]. Saint-Petersburg, Simvol-Plyus Publ., 2008. 368 p.

18. Hackeling G. *Mastering Machine Learning with scikit-learn*. Packt Publishing Ltd, 2014. 238 p.

19. Rassel C., Norvig P. *Iskusstvennyj intellekt: sovremennyj podhod* [Artificial intelligence: a modern approach]. Moscow, OOO «I. D. Vil'yams» Publ., 2016. 1408 p.

20. Kruglov V. V., Dli M. I., Golunov R. Yu. *Nechetkaya logika i iskusstvennye nejronnye seti* [Fuzzy logic and artificial neural networks]. Moscow, Fizmatlit Publ., 2001. 201 p.

The article submitted to the editors 31.05.2019

INFORMATION ABOUT THE AUTHORS

Borodin Vitaly Aleksandrovich – Russia, 414056, Astrakhan; Astrakhan State Technical University; Postgraduate Student of the Department of Automation and Control; vitkt@yandex.ru.

Protalinskiy Oleg Miroslavovich – Russia, 111250, Moscow; National Research University “Moscow Power Engineering Institute”; Doctor of Technical Sciences, Professor; Professor of the Department of Automated Control Systems for Thermal Processes; protalinskiy@gmail.com.

Shurshev Valeriy Fedorovich – Russia, 414056, Astrakhan; Astrakhan State Technical University; Doctor of Technical Sciences, Professor; Professor of the Department of Applied Informatics; v.shurshev@mail.ru.

