

# КОМПЬЮТЕРНОЕ ОБЕСПЕЧЕНИЕ И ВЫЧИСЛИТЕЛЬНАЯ ТЕХНИКА

## COMPUTER SOFTWARE AND COMPUTING EQUIPMENT

Научная статья  
УДК. 004.75  
<https://doi.org/10.24143/2072-9502-2022-1-42-52>

### Применение методов машинного обучения для автоматизированной классификации и маршрутизации в библиотеке ИТЛ

---

*Владимир Валерьевич Никулин<sup>1✉</sup>, Сергей Дмитриевич Шибайкин<sup>2</sup>,  
Мария Сергеевна Соколова<sup>3</sup>*

<sup>1-3</sup>Национальный исследовательский Мордовский государственный университет им Н. П. Огарёва,  
Саранск, Республика Мордовия, Россия, [nikulinvv@mail.ru](mailto:nikulinvv@mail.ru)<sup>✉</sup>

---

**Аннотация.** Проводится анализ эффективности применения методов машинного обучения для автоматизированной классификации и маршрутизации в библиотеке ИТЛ. Рассматриваются технология ITSM, библиотека ИТЛ, дается определение инциденту, ИТ-услуги. Далее выполняется векторизация и выделение ключевых слов в информации, записанной на естественном языке, для этого будет использоваться лемматизация (приведение словоформы к нормальной (словарной) форме) и мера TF-IDF. Приведен сравнительный анализ применения методов машинного обучения, а также сравнение результатов автоматической классификации текстовой информации с помощью градиентного бустинга и сверточной нейронной сети. Рассмотрены различные параметры данных методов. Лучшие результаты для обучающей и тестовой выборки показал градиентный бустинг – 95 % верно классифицированных инцидентов; в случаях с нейронной сетью результат составляет 91 %, у сверточной нейронной сети – 92 %. Точность рукописного классификатора составляет 90 %, т. к. некоторые из инцидентов не подпадают под его условия и остаются неклассифицированными. Результаты применения методов машинного обучения для автоматизированной классификации инцидентов позволяют с высокой точностью выполнять маршрутизацию заявок на восстановление работоспособности ИТ-сервисов, сократить время реагирования и ошибки, связанные с человеческим фактором.

**Ключевые слова:** классификация, ИТ-сервис, инцидент, градиентный бустинг, нейронная сеть, векторизация, ИТЛ, ITSM

**Для цитирования:** Никулин В. В., Шибайкин С. Д., Соколова М. С. Применение методов машинного обучения для автоматизированной классификации и маршрутизации в библиотеке ИТЛ // Вестник Астраханского государственного технического университета. Серия: Управление, вычислительная техника и информатика. 2022. № 1. С. 42–52. <https://doi.org/10.24143/2072-9502-2022-1-42-52>.

Original article

### Application of machine learning techniques for automated classification and routing in ITIL library

---

*Vladimir V. Nikulin<sup>1✉</sup>, Sergei D. Shibaikin<sup>2</sup>, Maria S. Sokolova<sup>3</sup>*

<sup>1-3</sup>National Research Ogarev Mordovia State University,  
Saransk, Republic of Mordovia, Russian, [nikulinvv@mail.ru](mailto:nikulinvv@mail.ru)<sup>✉</sup>

---

**Abstract.** The article analyzes applying the machine learning methods for automated classification and routing in the ITIL library. The ITSM technology and the ITIL library are considered, the definitions to the incident and IT services

are given. Further, the vectorization and extraction of keywords in the information written in natural language is carried out, for which lemmatization and the TF-IDF measure will be used. A comparative analysis of the application of machine learning methods, as well as a comparison of the results of automatic classification of text information using gradient boosting and a convolutional neural network is presented. Various parameters of these methods are considered. Gradient boosting showed the best results for the training and test sampling - 95% of correctly classified incidents; in cases with a neural network the result made 91%, a convolutional neural network had 92%. The accuracy of the handwritten classifier is 90%, as some of the incidents do not fall under its terms and remain unclassified. The results of the machine learning methods application for the automated classification of incidents make it possible to route requests for the restoration of the operability of IT services with high accuracy, to reduce the response time and errors associated with the human factor.

**Keywords:** classification, IT-service, incident, gradient boosting, neural network, vectorization, ITIL, ITSM

**For citation:** Nikulin V. V., Shibaikin S. D., Sokolova M. S. Application of machine learning techniques for automated classification and routing in ITIL library. *Vestnik of Astrakhan State Technical University. Series: Management, Computer Science and Informatics. 2022;1:42-52.* (In Russ.) <https://doi.org/10.24143/2073-5529-2022-1-42-52>.

### Введение

Information Technology Service Management (ITSM) – это идеология управления ИТ как набором услуг. В рамках этой идеологии ИТ-отдел или аутсорсер предоставляет бизнесу услуги с измеримыми характеристиками. Все параметры этой услуги подробно описаны в специальном соглашении – SLA (англ. Service Level Agreement – соглашение об уровне сервиса), которое составляют обе заинтересованные стороны – и ИТ, и бизнес. Идеология ITSM основана на ITIL (англ. IT Infrastructure Library – библиотека инфраструктуры информационных технологий), библиотеке лучших практик. Библиотека ITIL описывает бизнес-процесс, который позволяет предоставлять услуги в соответствии с требованиями клиентов (предприятий) на основе реального опыта ведения бизнеса. Однако ITSM и ITIL являются различными понятиями. ITSM – это подход, а ITIL – практическое руководство [1–4].

В процессе оказания ИТ-услуг могут возникнуть различные проблемы: услуга может стать недоступной, выполняться с ошибками, может появиться возможность получения несанкционированного доступа к информации и т. д. Возможны отклонения от штатного предоставления услуги. ITIL определяет такие отклонения как инциденты. Таким образом, инцидент – это незапланированное прерывание или снижение качества ИТ-услуги. Сбой конфигурационной единицы (неисправность или вовремя не проведенное техническое обслуживание аппаратной или программной части ИТ-системы), который еще не повлиял на услугу, также является инцидентом.

Как правило, действия по устранению ИТ-инцидентов оказывают значительное влияние на общее восприятие ИТ пользователем. Чтобы эффективно управлять этой деятельностью, необхо-

димо сформировать соответствующий план действий. В соответствии с рекомендациями ITIL для этого должен быть построен процесс управления инцидентами. В большинстве случаев организации используют собственные рукописные классификаторы (программы, написанные на любом языке программирования), основанные на поиске определенных слов в текстах запросов на основе логических операций (если-то-иначе). Соответственно, при добавлении ИТ-сервисов приходится вручную добавлять новые логические условия в код классификатора.

Для правильного устранения инцидента критически важна задача его классификации. Классификация – это назначение соответствующей категории инциденту диспетчерами дежурной службы инфотелекоммуникационной системы для его дальнейшей маршрутизации специалистам.

В данной работе рассматривается вопрос целесообразности внедрения алгоритмов машинного обучения в системы ITIL. Для этого рассмотрим структуру отдела и предполагаемую эффективность внедрения данного решения. Схематическая структура отдела представлена на рис. 1.

Специалисты по системам выполняют роль маршрутизатора для инцидентов и перенаправляют их специалистам ФГ (функциональных групп), отвечающих за функционирование сервисов.

Внедрение методов машинного обучения предполагает автоматизацию маршрутизации инцидентов, что уменьшит время реагирования и устраним неточность, связанную с человеческим фактором. Также это позволит оптимизировать рабочие места в отделах, отвечающих за непрерывное функционирование ИТ-сервисов, т. к. роль специалистов групп будет выполнять алгоритм машинного обучения.

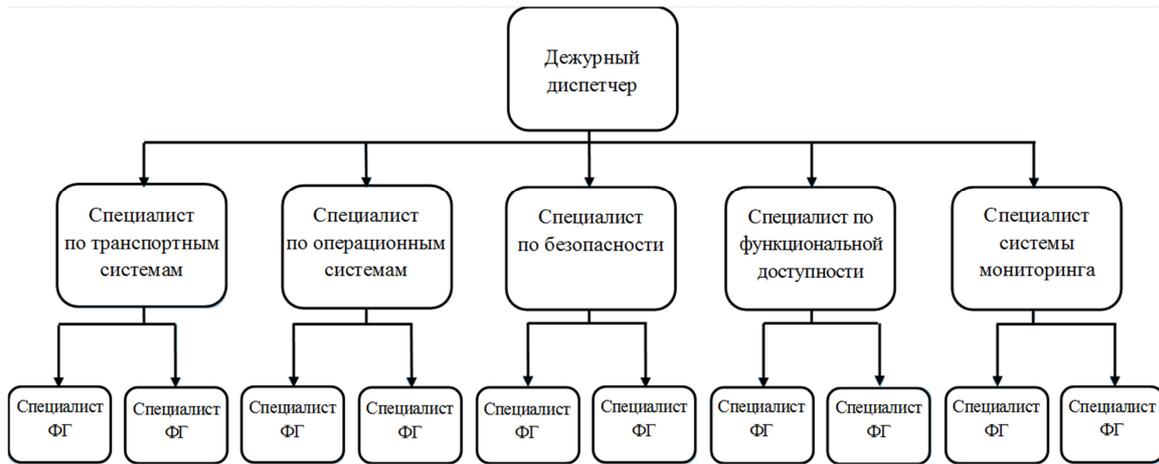


Рис. 1. Схематическое представление подразделения информатизации: ФГ – функциональная группа

Fig. 1. Schematic representation of the informatization unit: ФГ – functional group

Использование разработанного классификатора, основанного на подходе градиентного бустинга, позволит уменьшить количество ошибок при классификации и маршрутизации заявок и позволит предсказать категории для инцидентов, которые не попали под рукописный классификатор.

#### Анализ методов машинного обучения

Машинное обучение – обширный раздел [5], использующий математические, статистические и вычислительные методы для решения задач по определенному алгоритму. Существует множество методов машинного обучения, такие как метод ближайших соседей, дерево решений, случайный лес, байесовский классификатор, нейронные сети, сверточные нейронные сети, адаптивный бустинг, градиентный бустинг и др. [6, 7].

Нейронные сети представляют собой имитацию работы мозга. Они состоят из последовательности нейронов, соединенных между собой синапсами. Сети состоят из входного слоя, скрытого слоя и выходного слоя. Каждый из нейронов получает и обрабатывает данные, которые передаются нейронам на следующем уровне. Так как обработка сигналов у них идентичная, чтобы получить верное решение, необходимо правильно выбрать параметры синапсов, которые связывают нейроны. Существует множество разновидностей нейронных сетей, такие как сверточная нейронная сеть, импульсная нейронная сеть, хаотическая нейронная сеть и др. Пример нейронной сети представлен на рис. 2.

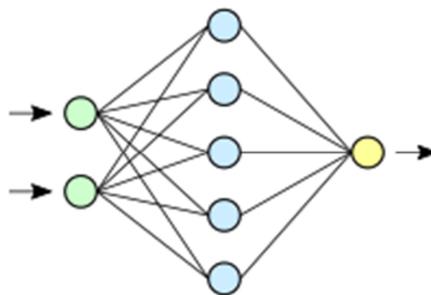


Рис. 2. Пример нейронной сети

Fig. 2. An example of a neural network

В данном примере первый слой (два нейрона) – это входной слой, второй слой (пять нейронов) – скрытый (вычислительный) слой, третий – (один нейрон) – выходной слой. Один из частных случаев нейронной сети – сверточная нейронная сеть. Особенностью сверточной нейронной сети является то,

что в ней в операции свертки используется ограниченная матрица,двигающаяся по входному слою и формирующая после каждого движения сигнал активации нейрона следующего слоя. Для всех нейронов используется одна и та же матрица, которую называют ядром свертки.

Бустинг – это метод, который заключается в обучении слабых классификаторов для получения более сильного классификатора. Обычно при таком методе каждому объекту присваивается определенный вес, который связан с точностью обучения. После того как слабый классификатор добавлен, происходит перерасчет весовых коэффициентов – вес каждого из объектов пересчитывается таким образом, что неверно классифицированные объекты получают больший вес, а правильно – меньший вес. Далее идет процесс нормализации, чтобы все веса в сумме были равны единице, и процесс идет заново. Таким образом, в сле-

дующей итерации обучение в большей степени фокусируется на объектах, которые были ошибочно классифицированы.

В данной работе выполнено сравнение различных методов машинного обучения для выяснения наиболее эффективного подхода к задаче автоматической классификации инцидентов. Каждый инцидент состоит из перечня атрибутов, каждый из которых имеет вид «атрибут-значение». Так как список атрибутов очень велик, выбраны только самые основные, количество которых достаточно для эффективной векторизации (табл. 1).

Таблица 1

Table 1

Список выбранных атрибутов с примерами значений

List of selected attributes with example values

Статус	Критичность	Объект	Класс объекта	Показатель	MSG
OPEN	MINOR	server.ru@vm-16401_server@Processor	VSM_CPU_CNTR	Total CPU Utilization	VMware CPU Container Total CPU Utilization >= 80 % for 10 min.
OPEN	MAJOR	service:[service]:Errorsrequests	ZabbixDefaultClass	–	Apiman: Errors request in API service more than 5 on server.ru
OPEN	MAJOR	service:[service]:Errorsrequests	ZabbixDefaultClass	–	Apiman: Errors request in API service/account-charges more than 5 on server.ru
OPEN	MINOR	server.ru@vm-3801_server@Processor	VSM_CPU_CNTR	Total CPU Utilization	VMware CPU Container Total CPU Utilization >= 80 % for 10 min.
OPEN	CRITICAL	IS:	–	–	Integration Service on ip:port is disconnected.
OPEN	CRITICAL	IS:	–	–	Integration Service on ip:port is disconnected.
OPEN	MAJOR	ip Application27	PIM_Port	Portstatus	Application ip port ne dostupennaservere
OPEN	MAJOR	service:[service]:Errorsrequests	ZabbixDefaultClass	–	Apiman: Errors request in API service more than 5 on server.ru
OPEN	MAJOR	ip Application31	PIM_Port	Portstatus	Application ip Application31 ne dostupennaservereip
OPEN	MAJOR	service:[service]:Errorsrequests	ZabbixDefaultClass	–	Apiman: Errors request in API service more than 5 on server.ru
OPEN	MAJOR	server.ru@vm-8790_vm-ora-odb-22@Processor	VSM_CPU_CNTR	Total CPU Utilization	VMware CPU Container Total CPU Utilization >= 90 % for 10 min.
OPEN	MINOR	server.ru@vm-2659_infra@Processor	VSM_CPU_CNTR	Total CPU Utilization	VMware CPU Container Total CPU Utilization >= 80 % for 10 min.

Кроме того, перечень данных атрибутов присутствует в пользовательских запросах, которые создаются в консоли инициатора инцидентов помимо систем оповещения, поэтому можно объединять разные системы мониторинга в единую систему с автоматизированной классификацией.

Рассмотрим более подробно атрибуты. «Статус» сообщает, актуален ли на данный момент инцидент или он уже устранен (статусы OPEN, CLOSE). «Критичность» отображает, насколько данный инцидент влияет на предоставляемую услугу или ИТ-сервис в целом. «Объект» настраивается вручную и необходим для уточнения вида

параметра, по которому произошел инцидент, а «Класс объекта» показывает модуль системы, по которому проходит проверка метрики. Показатель – конкретная метрика, по которой возник инцидент. «MSG» (сообщение) отображается в системе и необходим для краткого описания инцидента для лучшего восприятия.

**Классификация инцидентов**

Каждый инцидент можно классифицировать (категоризировать) по типу (превышение допустимых метрик допустимого значения, неработоспособность оборудования и т. д.), по группам, назна-

Nikitin V. V., Shvaikin S. D., Sokolova M. S. Application of machine learning techniques for automated classification and routing in ITIL library

ченным на устранение инцидента, а также по принадлежности к ИТ-сервису.

Категоризируем сервисы по выполняемой ими роли. Для этого введем иерархическую классифи-

кацию, позволяющую наглядно понять природу возникшего инцидента (рис. 3).

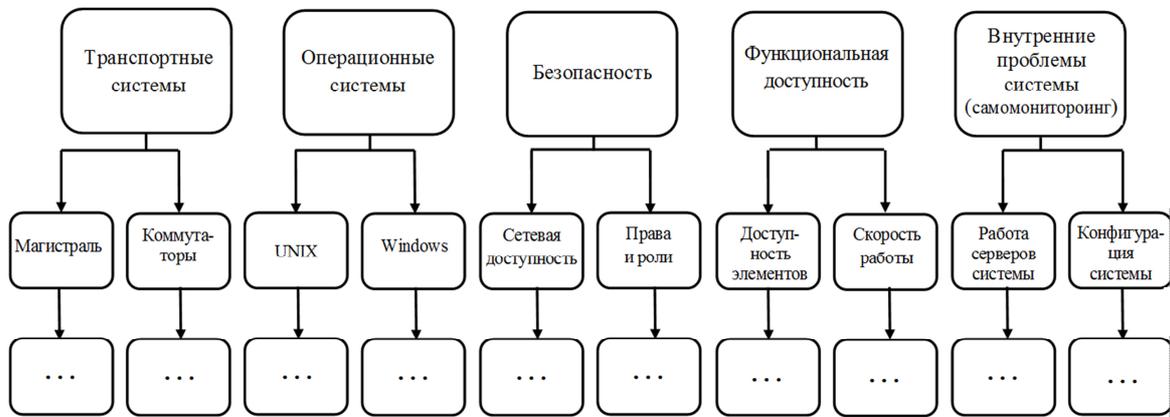


Рис. 3. Иерархическое представление сервисов

Fig. 3. Hierarchical representing of services

В качестве первого уровня выступают основные разделения сервисов по выполняемым ими ролям: транспортные системы, операционные системы, безопасность, функциональная доступность, внутренние проблемы системы (самомониторинг). На втором уровне проблемы начинают конкретизироваться – для операционной системы, к примеру, уточняется, относится ли инцидент к системе UNIX или Windows. Третий уровень необязателен для всех

систем. Обычно он необходим для точного установления источника инцидента, если это возможно. Так, к примеру, если есть проблема в коммутаторе в транспортной системе, 3 уровень будет указывать, какой конкретно коммутатор послужил источником проблемы. Для того чтобы исходные данные можно было использовать в машинном обучении, проведем трехуровневую классификацию инцидентов. Пример представлен в табл. 2.

Таблица 2

Table 2

**Трехуровневая классификация инцидентов**

**Three-level classification of incidents**

Описание инцидента	Web-stranicaurl.ru nedostupna. (Ob'ekt: index.html)
Операционная категоризация (уровень 1)	Транспортные системы
Операционная категоризация (уровень 2)	Коммутатор
Операционная категоризация (уровень 3)	Недоступен коммутатор (адрес)

В качестве операционной категоризации первого уровня служит назначение системы, которое дает общее представление об инциденте (в примере – «Транспортные системы»). В качестве второго уровня – более точный для классификации атрибут «Коммутатор», который указывает на неполадки в работе сетевого оборудования. И в качестве третьего уровня выступает атрибут «Причина и адрес коммутатора», который позволяет точно определить источник неполадки. Таким образом, в решении задачи классификации инцидентов для первого уровня выделено 5 уникальных атрибутов, для второго – 10, для третьего – от 3 до 20.

Также для категоризации инцидентов введем дополнительное поле «ИТ-сервис». Инциденты будут классифицироваться по признаку предоставления услуги или же по принадлежности к какой-либо системе, к примеру, «Личный кабинет Ростелеком», «База данных SystemName», «Бухгалтерская система» и т. д.

В качестве системы, в которой будет проводиться классификация, выбрана VMSProactiveNet 9.6 [8]. Она имеет встроенный коллектор событий, который в реальном времени отображает открытые и закрытые инциденты. На рис. 4 представлен коллектор событий с примерами инцидентов, приходящих в систему.

Никиулин В. В., Шибайкин С. Д., Соколова М. С. Применение методов машинного обучения для автоматизированной классификации и маршрутизации в библиотеке ГПД

Modified	↓	Occurred	Message
18/06/2021 09:37		18/06/2021 09:27	Na servere proizvoditsya obnovlenie (Discoveryng) dannyh Monitoring Studio.
18/06/2021 09:37		18/06/2021 09:25	Status vipolneniya zaprosa .ru:DBQuery:START_OR_AUDIT = 2.00 zapros ne vipolnyaetsya
18/06/2021 09:37		18/06/2021 09:36	VMware CPU Container Total CPU Utilization >= 80% for 10 min.
18/06/2021 09:36		18/06/2021 18:53	wAIT IT-servis < > - s ploshchadki v MRF Volga (Saransk)sostoyanie servisa sostavlyaet 44.30%.
18/06/2021 09:36		18/06/2021 09:23	wAIT IT-servis < > - s ploshchadki v MRF Moskva sostoyanie servisa sostavlyaet 50.03%.
18/06/2021 09:35		13/06/2021 18:22	Fajlovaya sistema root zapolnena na 77.69%.
18/06/2021 09:34		18/06/2021 09:33	wAIT Pokazatel proizvoditelnosti servisa .RU na ploshchadke <SSZSP00MN002> sostavlyaet 0.00%.
18/06/2021 09:34		18/06/2021 09:33	wAIT Pokazatel dostupnosti servisa .RU na ploshchadke <SSZSP00MN002> sostavlyaet 0.00%.
18/06/2021 09:34		18/06/2021 09:20	nedostupen site
18/06/2021 09:33		18/06/2021 09:26	VNIMANIE!!! Server .ru byl Perezagruzen. (Uptime = 539.00 seconds)
18/06/2021 09:32		18/06/2021 09:23	wAIT IT-servis < > - s ploshchadki v MRF Sibir . Dimitrova GPP sostoyanie servisa v predelah normy.
18/06/2021 09:32		18/06/2021 03:32	Cannot connect to some of Exchange Servers on port ;, .RU
18/06/2021 09:31		18/06/2021 08:18	Total 18 probe results were found in last 3000 seconds, 18 failed (Pass rate 0REPLACE_PERCENT_SIGN) Load failure category information. <...</td>
18/06/2021 09:30		18/06/2021 09:18	site dostupen
18/06/2021 09:30		21/05/2021 09:13	Fajlovaya sistema run-user-1006 ne smontirovana

Рис. 4. Коллектор событий с примерами инцидентов

Fig. 4 Event collector with examples of incidents

### Подготовка обучающей выборки и параметров методов машинного обучения

В качестве обучающей выборки выступает выгрузка из данной системы, содержащей информацию о 10 000 инцидентов, зафиксированных системой и полностью или частично классифицированных. Все они имеют вид, указанный в табл. 1. Перед составлением обучающей выборки необходимо подготовить исходные данные. Для этого используется мера TF-IDF [9], с помощью которой можно получить оценку важности отдельного слова в контексте одного участка (в данном случае – инцидента) для всего остального потока инцидентов. Данная мера работает по следующему прин-

ципу: вес слова, которое несет смысловую нагрузку, пропорционален частоте употребления этого слова в инциденте и обратно пропорционален частоте употребления в остальных документах. Такими словами являются все слова, не являющиеся предлогами, цифрами, местоимениями, междометиями, частицами, именами числительными и т. д. С помощью такого подхода можно преобразовать исходные данные в вектор фиксированной длины. Каждому слову, которое имеет вес, будет присвоен собственный номер, что в итоге позволит получить длину вектора.

В табл. 3 представлены примеры расчета веса для некоторых слов.

Таблица 3

Table 3

### Примеры расчета веса слов Examples of calculating the weight of words

Слово	IDF	Количество вхождений
web-stranica	1,66	65
VMware	1,81	46
Zapros	1,5	96
Status	1,46	104
Server	0,86	413
Available	2,64	7
Cluster	2,52	8
kod	2,5	9
System	1,88	39
Container	2,9	4
Adapter	2,27	16

После расчета веса слов и последующей векторизации получили вектор длиной 250, который будет подаваться на вход всех исследуемых классификаторов. Это обусловлено количеством ИТ-

сервисов (140 сервисов), а также наличием нескольких интегрированных систем, которые также отсылают инциденты в данную систему.

После того как была выполнена начальная подготовка данных, их можно использовать для обучения алгоритмов машинного обучения, в качестве которых будут выступать ранее описанная нейронная сеть [6, 7], сверточная нейронная сеть (CNN) [10] и градиентный бустинг [11].

Нейронная сеть построена в 5 слоев. Во входном слое 250 нейронов, во втором, третьем и четвертом скрытом слое по 30 нейронов, и количество нейронов, равное количеству атрибутов на уровне классификации, – в выходном слое.

Для построения сверточной нейронной сети была выбрана следующая архитектура (рис. 5).

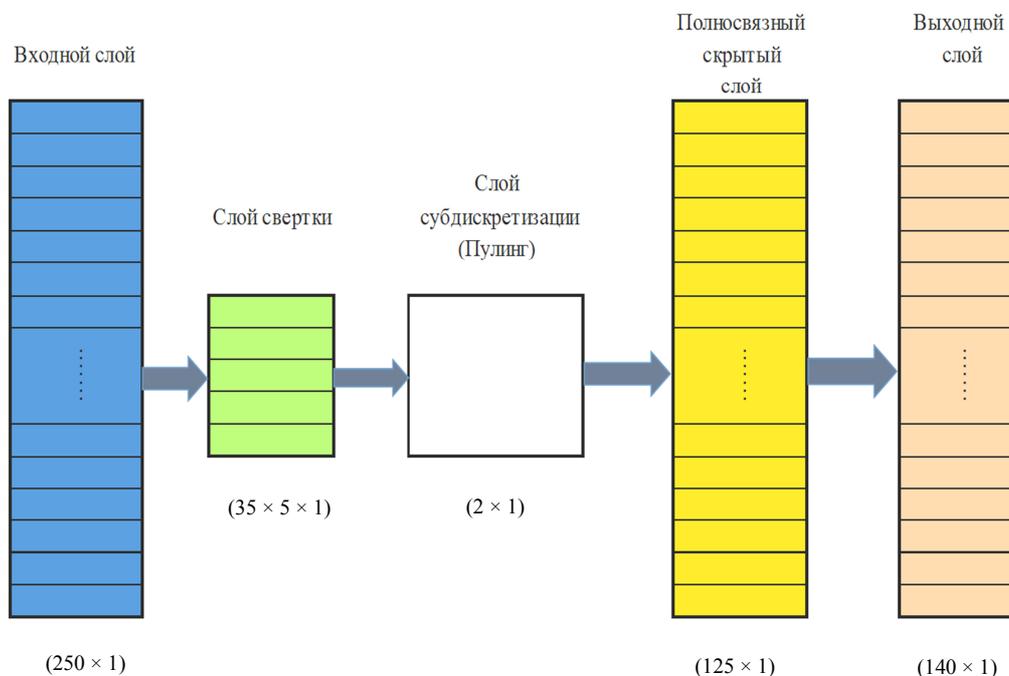


Рис. 5. Архитектура сверточной нейронной сети

Fig. 5. Convolutional neural network architecture

Операция свертки подразумевает, что каждый фрагмент входа поэлементно умножается на матрицу весов, а результат суммируется. Эта сумма является элементом выхода, который называется картой признаков. Взвешенная сумма входов пропускается через функцию активации.

Слой субдискретизации (пулинга) представляет собой нелинейное уплотнение карты признаков, выполняя нелинейное преобразование. Пулинг интерпретируется как разбиение карты признаков (элементы входного вектора, получившиеся после свертки) на более мелкие матрицы, нахождение из них максимальных элементов, т. е. происходит увеличение глубины значений.

Также используем параметр `categorical_crossentropy` (категориальная перекрестная энтропия между выходным тензором и целевым тензором в библиотеке TensorFlow) [12], применяемый при мультиклассовости меток, который вычисляет потерю кросс-энтропии между метками и прогнозами. Он необходим для измерения сходства между прогнозируемым атрибутом и истинным.

Для градиентного бустинга применим следующие параметры: максимальная длина деревьев – 10; `objective='multi:softmax'` – установка XGBoost [11] для выполнения мультиклассовой классификации, для которой также необходимо указать количество классов (зависит от уровня классификации, указанного в табл. 2); `num_parallel_tree = 1` (увеличение случайного леса); `subsample = 0,5` – отношение подвыборки обучающего экземпляра.

После обработки 10 000 инцидентов были построены графики метрик исследованных методов. Также была рассчитана точность рукописного классификатора, на данный момент использующегося в системе. Для оценки точности классификатора использованы метрики F-меры (F-score) [13], которые являются гармоническим средним между точностью и полнотой. Точность системы в пределах класса – это доля инцидентов, действительно принадлежащих данному классу относительно всех инцидентов, которые система отнесла к этому классу. Полнота системы – это доля найденных классификатором инцидентов, принадлежащих классу, относительно всех инцидентов этого класса

в тестовой выборке. Оценка работы алгоритмов выполнялась с помощью четырех метрик (Accuracy, Sensitivity, Specifity, Precision) [7, 13]:

– Accuracy – определяет долю правильно классифицированных данных на основе обучающей выборки и тестовых данных;

– Sensitivity (recall) – определяет долю правильно классифицированных данных обучающей выборки относительно общего числа всех правильно классифицированных данных;

– Specifity – определяет долю правильно классифицированных тестовых данных к общему числу всех некорректно классифицированных данных;

– Precision – определяет долю правильно классифицированных данных на основе данных обучающей выборки.

Оценка работы классификаторов приведена в табл. 4 и на рис. 6.

Таблица 4

Table 4

Результаты работы классификаторов

Classifier performance results

Метрики	Градиентный бустинг	Нейронная сеть	Сверточная нейронная сеть	Рукописный классификатор
TN	4 800	4 700	4 750	4 600
FP	250	450	400	500
FN	200	300	250	400
TP	4 750	4 550	4 600	4 500
Accuracy	0,955	0,925	0,935	0,91
Sensitivity	0,96	0,938	0,948	0,918
Specifity	0,95	0,913	0,92	0,902
Precision	0,95	0,91	0,92	0,9

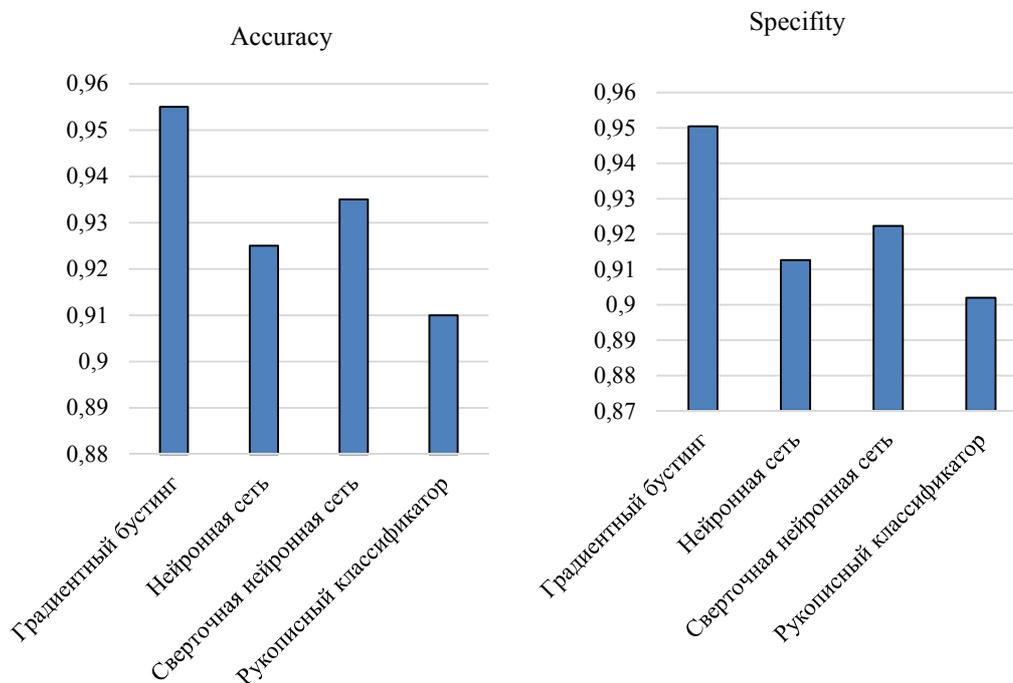


Рис. 6. Оценка работы классификаторов на основе метрик F-меры

Fig. 6. Evaluating the performance of classifiers based on F-measure metrics

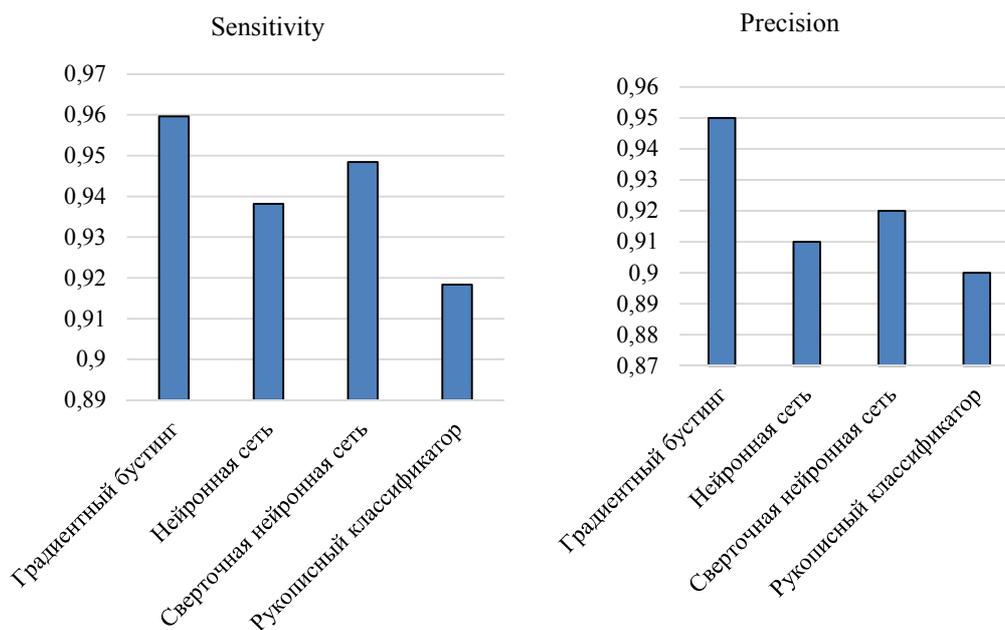


Рис. 6 (окончание). Оценка работы классификаторов на основе метрик F-меры

Fig. 6 (ending). Evaluating the performance of classifiers based on F-measure metrics

Лучшие результаты для обучающей и тестовой выборки показал градиентный бустинг – 95 % верно классифицированных инцидентов; в случаях с нейронной сетью этот показатель составляет 91 %, у сверточной нейронной сети – 92 %. Более низкая точность рукописного классификатора, составляющая 90 %, обусловлена тем, что некоторые из инцидентов не подпадают под его условия и остаются неклассифицированными. Это, к примеру, инциденты по метрикам, которые на данный момент находятся на этапе постановки, или же системные оповещения, автоматически приходящие в систему.

### Заключение

Результаты исследования демонстрируют возможность практического применения градиентного бустинга для автоматизированного создания заявок на отладку и устранение неисправностей путем интеграции его с такими системами, как OTRS – открытая система обработки заявок. Еще одним перспективным направлением является применение данной технологии для автоматизированного создания проблем (причину или потенциальную причину одного или нескольких возникающих инцидентов) в консоли управления проблемами.

### Список источников

1. *Ilieva R., Anguelov K., Gashurova D.* Monitoring and optimization of e-Services in IT Service Desk Systems // 2016 19th International Symposium on Electrical Apparatus and Technologies (SIELA). № 7543013. DOI: 10.1109/SIELA.2016.7543013.
2. *Hermita E. S., Sucahyo Y. G., Gandhi A.* Designing IT Service Management at Indonesia Internet Domain Names Registry Association's Helpdesk Function // ICICM 2020: Proceedings of the 2020 10th International Conference on Information Communication and Management. August 2020. P. 10–15. DOI: <https://doi.org/10.1145/3418981.3418987>.
3. *Jelliti M., Sibilla M., Jamoussi Y., Ghezala H. B.* A model based framework supporting ITIL Service IT Management // Enterprise, Business-Process and Information Systems Modeling - 11th International Workshop BPMDS 2010 and 15th International Conference EMMSAD 2010 Held at CAiSE 2010 Proceedings 50 LNBIP. P. 208–219. DOI: 10.1007/978-3-642-13051-9\_18.
4. *Ahmad N., Tarek Amer N., Qutaifan F., Alhilali A.* Technology adoption model and a road map to successful implementation of ITIL // Journal of Enterprise Information Management. 2013. N. 26 (5). P. 553–576. DOI: 10.1108/JEIM-07-2013-0041.
5. *Zuev D., Kalistratov A., Zuev A.* Machine learning in IT service management // 9th Annual International Conference On Biologically Inspired Cognitive Architectures, BICA 2018 (Prague, 22–24 августа 2018 г.). Изд-во: Elsevier B. V. P. 675–679. DOI: 10.1016/j.procs.2018.11.063.
6. *Шибайкин С. Д., Егунова А. И., Аббакумов А. А.* Анализ применения нейронных сетей, градиентного бустинга и метода ближайших соседей для классификации нормативно-справочной информации // Науч.-техн. вестн. Поволжья. 2020. № 2. С. 54–58.
7. *Шибайкин С. Д., Аббакумов А. А., Никулин В. В.* Анализ применения методов машинного обучения компьютерных систем для повышения защищенности от мошеннических текстов // Вестн. Астрахан. гос. техн.

ун-та. Сер.: Управление, вычислительная техника и информатика. 2020. № 1. С. 29–40. DOI: <https://doi.org/10.24143/2072-9502-2020-1-29-4>.

8. BMC ProactiveNet 9.6. URL: <https://docs.bmc.com/docs/display/public/proactivenet96/Home?key=proactivenet96> (дата обращения: 01.10.2021).

9. Shi C. Y., Xu C. J., Yang X. J. Study of TFIDF algorithm // J. Comput. Appl. 2009. N. 29. P. 167–170.

10. Abadi M., Agarwal A., Barham P., Brevdo E., Chen Z., Citro C., Corrado G. S., Davis A., Dean J., Devin M., Ghemawat S., Goodfellow I., Harp A., Irving G., Isard M., Jia Y., Jozefowicz R., Kaiser L., Kudlur M., Levenberg J., Man' e D., Monga R., Moore S., Murray D., Olah C., Schuster M., Shlens J., Steiner B., Sutskever I., Talwar K., Tucker P., Vanhoucke V., Vasudevan V., Vi'egas F., Vinyals O., Warden P., Wattenberg M., Wicke M., Yu Y., Zheng X. TensorFlow: Large-scale machine learning on heterogeneous systems // Preliminary White Paper, November. 2015. N. 9.

19 p. URL: <https://arxiv.org/pdf/1603.04467.pdf> (дата обращения: 01.10.2021).

11. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System // 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining KDD, 2016. P. 785–794. DOI: 10.1145/2939672.2939785.

12. Taherkhani A., Cosma G., McGinnity T. Adaboost-CNN: an adaptive boosting algorithm for convolutional neural networks to classify multi-class imbalanced datasets using transfer learning // Neurocomputing 404. 2020. P. 351–366. DOI: 10.1016/J.NEUCOM.2020.03.064.

13. Goutte C., Gaussier E. A probabilistic interpretation of precision, recall and F-Score, with implication for evaluation // Conference: Proceedings of the 27th European conference on Advances in Information Retrieval Research. April 2005. Lecture Notes in Computer Science 3408:345-359. DOI: 10.1007/978-3-540-31865-1\_25.

## References

1. Ilieva R., Anguelov K., Gashurova D. Monitoring and optimization of e-Services in IT Service Desk Systems. 2016 19th International Symposium on Electrical Apparatus and Technologies (SIELA). № 7543013. DOI: 10.1109/SIELA.2016.7543013.

2. Hermita E. S., Sucahyo Y. G., Gandhi A. Designing IT Service Management at Indonesia Internet Domain Names Registry Association's Helpdesk Function. ICICM 2020: Proceedings of the 2020 10th International Conference on Information Communication and Management. August 2020. Pp. 10-15. DOI: <https://doi.org/10.1145/3418981.3418987>.

3. Jelliti M., Sibilla M., Jamoussi Y., Ghezala H. B. A model based framework supporting ITIL Service IT Management. Enterprise, Business-Process and Information Systems Modeling - 11th International Workshop BPMDS 2010 and 15th International Conference EMMSAD 2010 Held at CAiSE 2010 Proceedings 50 LNBIP. Pp. 208-219. DOI: 10.1007/978-3-642-13051-9\_18.

4. Ahmad N., Tarek Amer N., Qutaifan F., Alhilali A. Technology adoption model and a road map to successful implementation of ITIL. Journal of Enterprise Information Management, 2013, no. 26 (5), pp. 553-576. DOI: 10.1108/JEIM-07-2013-0041.

5. Zuev D., Kalistratov A., Zuev A. Machine learning in IT service management. 9th Annual International Conference On Biologically Inspired Cognitive Architectures, BICA 2018 (Prague, 22–24 avgusta 2018 g.). Izd-vo: Elsevier B. V. Pp. 675-679. DOI: 10.1016/j.procs.2018.11.063.

6. Shibaikin S. D., Egunova A. I., Abbakumov A. A. Analiz primeneniia neironnykh setei, gradientnogo bustinga i metoda blizhaishikh sosedei dlia klassifikatsii normativno-spravochnoi informatsii [Analysis of using neural networks, gradient boosting and method of nearest neighbors for classification of normative and reference information]. Nauchno-tekhnikeskii vestnik Povolzh'ia, 2020, no. 2, pp. 54-58.

7. Shibaikin S. D., Abbakumov A. A., Nikulin V. V., Analiz primeneniia metodov mashinnogo obucheniia komp'iuternykh sistem dlia povysheniia zashchishchennosti

ot moshennicheskikh tekstov [Analysis of applying machine learning methods of computer systems to improve security against fraudulent texts]. Vestnik Astrakhanskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya: Upravlenie, vychislitel'naiia tekhnika i informatika, 2020, no. 1, pp. 29-40. DOI: <https://doi.org/10.24143/2072-9502-2020-1-29-4>.

8. BMC ProactiveNet 9.6. Available at: <https://docs.bmc.com/docs/display/public/proactivenet96/Home?key=proactivenet96> (accessed: 01.10.2021).

9. Shi C. Y., Xu C. J., Yang X. J. Study of TFIDF algorithm. J. Comput. Appl., 2009, no. 29, pp. 167-170.

10. Abadi M., Agarwal A., Barham P., Brevdo E., Chen Z., Citro C., Corrado G. S., Davis A., Dean J., Devin M., Ghemawat S., Goodfellow I., Harp A., Irving G., Isard M., Jia Y., Jozefowicz R., Kaiser L., Kudlur M., Levenberg J., Man' e D., Monga R., Moore S., Murray D., Olah C., Schuster M., Shlens J., Steiner B., Sutskever I., Talwar K., Tucker P., Vanhoucke V., Vasudevan V., Vi'egas F., Vinyals O., Warden P., Wattenberg M., Wicke M., Yu Y., Zheng X. TensorFlow: Large-scale machine learning on heterogeneous systems. Preliminary White Paper, November 2015, no. 9, 19 p. Available at: <https://arxiv.org/pdf/1603.04467.pdf> (accessed: 01.10.2021).

11. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System. 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining KDD, 2016. Pp. 785-794. DOI: 10.1145/2939672.2939785.

12. Taherkhani A., Cosma G., McGinnity T. Adaboost-CNN: an adaptive boosting algorithm for convolutional neural networks to classify multi-class imbalanced datasets using transfer learning. Neurocomputing 404, 2020. Pp. 351-366. DOI: 10.1016/J.NEUCOM.2020.03.064.

13. Goutte C., Gaussier E. A probabilistic interpretation of precision, recall and F-Score, with implication for evaluation. Conference: Proceedings of the 27th European conference on Advances in Information Retrieval Research. April 2005. Lecture Notes in Computer Science 3408:345-359. DOI: 10.1007/978-3-540-31865-1\_25.

Статья поступила в редакцию 28.10.2021; одобрена после рецензирования 15.12.2021; принята к публикации 19.01.2022  
The article is submitted 28.10.2021; approved after reviewing 15.12.2021; accepted for publication 19.01.2022

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

**Владимир Валерьевич Никулин** – кандидат технических наук, доцент; заведующий кафедрой инфокоммуникационных технологий и систем связи; Национальный исследовательский Мордовский государственный университет им. Н. П. Огарёва; Саранск, ул. Большевикская, 68; nikulinvv@mail.ru

**Vladimir V. Nikulin** – Candidate of Technical Sciences, Assistant Professor; Head of the Department of Infocommunication Technologies and Communication Systems; National Research Mordovian State University after N. P. Ogarev; Saransk, Bolshevik street, 68; nikulinvv@mail.ru

**Сергей Дмитриевич Шибайкин** – кандидат технических наук; доцент кафедры инфокоммуникационных технологий и систем связи; Национальный исследовательский Мордовский государственный университет им. Н. П. Огарёва; Саранск, ул. Большевикская, 68; shibaikinsd@rambler.ru

**Sergei D. Shibaikin** – Candidate of Technical Sciences; Assistant Professor of the Department of Infocommunication Technologies and Communication Systems; National Research Mordovian State University after N. P. Ogarev; Saransk, Bolshevik street, 68; shibaikinsd@rambler.ru

**Соколова Мария Сергеевна** – аспирант кафедры инфокоммуникационных технологий и систем связи; Национальный исследовательский Мордовский государственный университет им. Н. П. Огарёва; Саранск, ул. Большевикская, 68; Manunia131313@mail.ru

**Maria S. Sokolova** – Postgraduate Student of the Department of Infocommunication Technologies and Communication Systems; National Research Mordovian State University after N. P. Ogarev; Saransk, Bolshevik street, 68; Manunia131313@mail.ru

