

ARTIFICIAL INTELLIGENCE ИСКУСТВЕННЫЙ ИНТЕЛЛЕКТ

УДК 654.026

Р.Н. Ермаков

ДЕТЕКТИРОВАНИЕ СЕТЕВЫХ ПРОТОКОЛОВ С ПРИМЕНЕНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ И АЛГОРИТМОВ НЕЧЕТКОЙ ЛОГИКИ В СИСТЕМАХ АНАЛИЗА ТРАФИКА

Ермаков Роман Николаевич, кандидат биологических наук, окончил Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича. Ведущий инженер АО «НИИ «Масштаб». Имеет научные публикации (статьи) в области математического моделирования, экспертных систем и систем управления [e-mail: romul151925@mail.ru].

Аннотация

В работе рассматривается новый эффективный подход к анализу сетевого трафика с целью определения протокола информационного обмена прикладного уровня. Дается краткое описание структуры алгоритма классификации сетевых пакетов на принадлежность к одному из известных сетевых протоколов (TLS v1, TLS v1.2, HTTP, SSH v2, DNS, DHCP v6 и др). Для определения протокола используется принцип высокоскоростной однопакетной классификации, который заключается в том, что анализируется информация, передаваемая в каждом конкретном пакете. Используются элементы поведенческого анализа, а именно, классифицируются переходные состояния протоколов информационного обмена, что позволяет достичь более высокого уровня верности классификации и более высокой степени обобщения на новых тестовых выборках. Применяются алгоритмы нечеткой логики и нейронные сети. Демонстрируются результаты тестирования построенного программного модуля, способного идентифицировать сетевые протоколы информационного обмена.

Ключевые слова: классификация сетевых пакетов, искусственные нейронные сети, логистическая регрессия, анализ сетевого трафика, глубокий анализ пакетов.

doi:

DETECTION OF NETWORK PROTOCOLS WITH APPLICATION OF MACHINE LEARNING METHODS AND FUZZY LOGIC ALGORITHMS IN TRAFFIC ANALYSIS SYSTEMS

Roman Nikolaevich Ermakov, Candidate of Science in Biology; graduated from the Bonch-Bruевич Saint-Petersburg State University of Telecommunications; Leading Engineer of JSC "Research Institute "Mashtab"; an author of articles in the field of mathematical modeling, expert systems, and control systems. e-mail: romul151925@mail.ru.

Abstract

The article deals with a new effective approach to analyzing the network traffic in order to determine the protocol of information exchange. A brief description of the structure of the algorithm for classifying network packets by belonging to one of the known network protocols (TLS v1, TLS v1.2, HTTP, SSH v2, DNS, DHCP v6, etc.) is given. To define the protocol, the principle of high-speed one-packet classification is used, which consists in analyzing the information transmitted in each particular packet. Elements of behavioral analysis are used, namely, the transition states of information exchange protocols are classified, which allows to achieve a higher level of accuracy of classification and a higher degree of generalization in new test samples. Fuzzy logic algorithms and neural networks are used. The test results of the constructed software module capable of identifying network protocols for information exchange are demonstrated.

Keywords: : network packet classification, artificial neural networks, logistic regression, machine learning, network traffic analysis, in-depth packet analysis.

ВВЕДЕНИЕ

В последние годы не ослабевает интерес операторов телекоммуникационного рынка к системам анализа сетевого трафика network traffic analysis (NTA), глубокой инспекции пакетов (DPI) и к системам обеспечения комплексной информационной безопасности. Полагаем, что и в дальнейшем его рост будет продолжаться, особенно для систем обеспечения информационной безопасности, использующих современные интеллектуальные математические модели и методы.

Анализ трафика в течение многих лет остается актуальным направлением исследований. Этому способствуют две основные причины: (1) рост трафика, в том числе вредоносного, (2) появление новых технологий.

Разработано и эксплуатируется множество систем обеспечения информационной безопасности. К таким системам можно отнести:

- системы управление правами доступа (IDM – Identity Management);
- системы контроля действий администраторов (PAM – Privelege Accounts Management);
- развитые межсетевые экраны (NGFW – Next Generation Firewalls);
- средства анализа защищенности (SIEM – Security Information and Event Management);
- антивирусные решения (AV – Antivirus, Antibot, Malware Protection);
- системы обнаружения вторжений и аномалий (IDS – Intrusion Detection System, APIDS – Application protocol-based IDS);
- системы предотвращения атак (IPS – Intrusion Prevention System);
- системы аудита и мониторинга средств безопасности (NMS – Security Information and Event Management);
- системы защиты от атак класса «Отказ в обслуживании» (DDoS PS – DDoS Protection Systems);
- системы управления политиками сетевого трафика (PCEF – Policy and Charging Enforcement Function, PCRF – Policy and Charging Rules Function, NAC – Network Access Control);
- другие системы.

Системы анализа трафика NTA являются необходимым инструментом многих представленных классов других систем обеспечения информационной безопасности, таких как IDS, IPS, NMS, DDoS PS и др.

Идентификация протоколов инфокоммуникационного обмена позволяет решать следующие типы задач:

- разработка датчиков обнаружения атак [1];
- идентификация типов устройства [2], задействованных в информационном обмене;
- определение типовых приложений, запущенных на устройствах, задействованных в процессе информационного обмена;
- создание датчиков обнаружения аномального или поддельного трафика (в случае выдачи одного протокола за другой протокол);
- классификация сетевых приложений прикладного уровня вплоть до седьмого уровня модели OSI (SKYPE, Facebook и др.).

Вместе с тем классификатор сетевых пакетов (КСП) прикладного уровня может быть очень полезен при распознавании внутреннего состояния, в котором может находиться тот или иной протокол в процессе информационного обмена на этапе handshake (рукопожатия), что является важным элементом поведенческого анализа.

Классификация трафика может быть осуществлена на основе:

- использования традиционных подходов к анализу трафика (сигнатурный и поведенческий) в зависимости от того, зашифрован трафик или нет [3]. Основан на анализе номеров портов пакетов, сигнатуры протокола (payload-based). Поведенческий (статистический) анализ характеристик обмена (statistical analysis) пакетами между абонентами и статистических свойств сетевого трафика основан на исследовании последовательности размеров пакетов, временных интервалов между пакетами и т. д.;
- разработки и применения математических методов:
 - a) базовые статические алгоритмы;
 - b) machine leaning (метод опорных векторов и метод случайных лесов [4]);
 - c) алгоритмы нечеткой логики;
 - d) методы теории нейронных сетей.

Качественная классификация сетевых пакетов приложений прикладного уровня, как в плане характеристик классификации (точность, время, надежность и др.), так и в плане уменьшения требований к вычислительной мощности, оказывает важное влияние на функ-

ционирование систем NTA [5, 6], анализ трафика DPI, IDS/IPS [7], DDoS PS [8] и др. Как на весь технологический процесс, так и на качество анализа.

По уровню классификации сетевых пакетов различают: «поверхностный» анализ пакетов (SPI – Shallow Packet Inspection), «средний» анализ пакетов (MPI – Medium Packet Inspection) и «глубокий» анализ пакетов (DPI – Deep Packet Inspection). Анализаторы «поверхностного» уровня функционируют в простейших межсетевых экранах, где решение о блокировании того или иного пакета обычно принимается в соответствии со списком запрещенных IP-адресов и номеров портов. Программные средства анализа трафика, относящиеся к «среднему» уровню, позволяют проводить фильтрацию трафика с использованием информации о формате передаваемых данных, а также более полной локализации отправителя. Эти инструменты обычно выступают в роли посредника (проxy) между провайдером доступа к сети Интернет и внутренней сетью. Системы «глубокого» анализа пакетов предназначены для идентификации приложений, участвующих в сетевых взаимодействиях. Поэтому «углубленный» разбор предполагает анализ содержимого сетевых пакетов всех уровней и назначение подобных систем – это обеспечение информационной безопасности и мониторинг качества канала связи.

Как правило, для анализа сетевого трафика исследователи в своих работах определяют протокол прикладного уровня с использованием алгоритмов машинного обучения «с учителем» [4, 9, 10]. В [4] задача классификации решалась *методом опорных векторов* и с помощью *алгоритма «случайных лесов»*. Результаты исследований на тестовых выборках в этой работе показали, что оба подхода приводят к высокой верности классификации, 98% и выше. Однако ничего не сказано о среднем времени классификации пакетов алгоритмами на конкретных аппаратных платформах и операционных системах. Остается вопрос: можно ли использовать такие «тяжеловесные» алгоритмы классификации в реальных системах анализа трафика с учетом предъявляемых требований по вычислительной производительности? Для классификации сетевых пакетов в настоящей работе использовались алгоритмы нечеткой логики (модель Мамдани) и методы машинного обучения, в частности нейронные сети, а именно, логистическая регрессия.

Разработка КСП состояла из четырех этапов: (1) мониторинг и сбор пакетной статистической информации наиболее известных протоколов сетевого трафика, (2) предобработка первичной пакетной статистической информации, (3) построение КСП и (4) тестирование.

1 Постановка задачи классификации трафика

Постановку задачи классификации трафика можно сформулировать следующим образом:

Имеется множество исследуемых объектов – IP-пакетов прикладного уровня:

$$P = \{P_1, P_2, \dots, P_W\}, \quad (1)$$

где P_W – классифицирующийся пакет из последовательности пакетов (трафика) размерностью W .

Каждый объект (IP-пакет) характеризуется набором переменных (атрибутов):

$$P_1 = \{X_1, X_2, \dots, X_N, Z\}, \quad (2)$$

где X_1 – наблюдаемые переменные, значения которых известны; N – количество атрибутов пакета; Z – зависимое множество, которое необходимо определить (тип протокола, внутреннее состояние протокола в процессе информационного обмена).

При этом каждая переменная X_n принимает значение из некоторого множества:

$$X_n = \{X_{n_1}, X_{n_2}, \dots, X_{n_M}\}, \quad (3)$$

где X_{n_M} – варианты значений атрибутов.

Таким образом, задача классификации сводится к определению множества Y на основе значений атрибутов последовательности пакетов.

Решая прикладную задачу, определим наиболее подходящие атрибуты пакета. В исследовании [11] различными способами решалась данная задача. Однако в настоящей работе был выделен следующий набор атрибутов:

- X_1 – *EtherType* (тип стандарта протокола Ethernet);
- X_2 – *Source IP Address* (IP-адрес отправителя);
- X_3 – *Destination IP Address* (IP-адрес получателя);
- X_4 – *Multicast* (принимает значение 1, если multicast, в противном случае – 0);
- X_5 – *IP Protocol* (тип транспортного уровня);
- X_6 – *Packet Length* (длина сетевого пакета в байтах);
- X_7 – *Source Port* (порт TCP/UDP отправителя);
- X_8 – *Destination Port* (порт TCP/UDP получателя);
- X_9 – *Hex_length* (количество байт в строковом контенте протокола верхнего уровня – часть payload);
- X_{10} – *Payload_hex* (передаваемая строка в контенте протокола верхнего уровня – часть payload);
- X_{11} – *Payload_type* (атрибут для обеспечения обучения моделей классификации сетевых пакетов по схеме с учителем).

Также был включен дополнительный параметр – маркировка класса payload type, чтобы иметь возможность обучения моделей классификации сетевых пакетов по схеме с учителем.

2 МОНИТОРИНГ И СБОР ПАКЕТНОЙ СТАТИСТИЧЕСКОЙ ИНФОРМАЦИИ НАИБОЛЕЕ ИЗВЕСТНЫХ И ЧАСТО ВСТРЕЧАЮЩИХСЯ ПРОТОКОЛОВ СЕТЕВОГО ТРАФИКА

Мониторинг и сбор пакетной статистической информации наиболее часто встречающихся протоколов сетевого трафика (TLS v1, TLS v1.2, SSH v2, HTTP, FTP и др.) был осуществлен с использованием открытого программного обеспечения Wireshark [12] и включал в себя решение следующих задач:

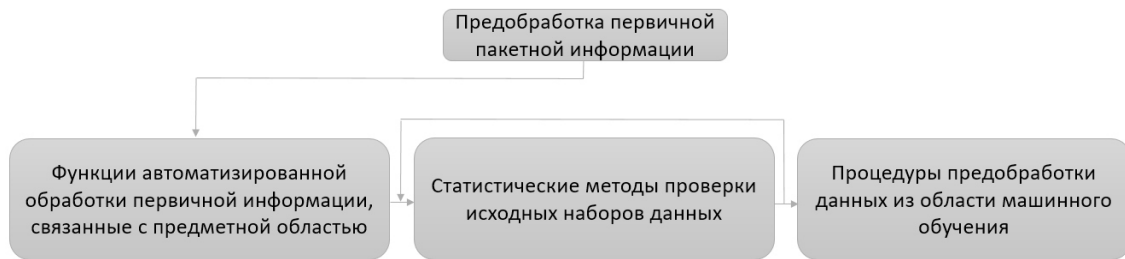


Рис.1. Интеллектуальная автоматизированная предобработка первичных пакетных данных

а) выбор наиболее подходящих входных переменных для построения модели классификации сетевых пакетов;

б) формирование набора первичных репрезентативных выборок – DUMP в PCAP-формате с пакетной информацией по указанным выше протоколам (объемом трафика ~1Гб);

в) автоматическое формирование вторичных выборок для анализа.

3 ПРЕДОБРАБОТКА ПЕРВИЧНОЙ ПАКЕТНОЙ СТАТИСТИЧЕСКОЙ ИНФОРМАЦИИ

Предобработка первичной пакетной информации состоит из трех последовательно выполняющихся блоков, которые представлены на рисунке 1.

В первом блоке алгоритма предобработки задействован следующий функционал:

- проверка payload на предмет зашифрованной контентной информации (потребовало реализации отдельного специального технологического программного обеспечения (ПО) на языке Python);
- обработка payload для лучшего визуального восприятия и возможности эвристического (поведенческого) анализа;
- разделение полученных классифицируемых сетевых пакетов на однородные группы (A, B, C, D) на основе значений некоторых входных признаков (тип стандарта протокола Ethernet, Multicast и тип транспортного уровня), а также формирование тестовых и тренировочных наборов.

Разделение классифицируемых сетевых пакетов на принадлежность к протоколам (DHCP v6, DNS, FTP, HTTP и др.) на группы ($GROUP_A$, $GROUP_B$, $GROUP_C$, $GROUP_D$) производится на основе следующих логических правил:

$$\begin{aligned}
 GROUP_A &= if(ethertype == IPv4) \&\& (Multicast == 0) \&\& (IP_PROTO == TCP), \\
 GROUP_B &= if(ethertype == IPv4) \&\& (Multicast == 0) \&\& (IP_PROTO == UDP), \\
 GROUP_C &= if(ethertype == IPv4) \&\& (Multicast == 1) \&\& (IP_PROTO == UDP), \\
 GROUP_D &= if(ethertype == IPv6) \&\& (Multicast == 1) \&\& (IP_PROTO == UDP).
 \end{aligned}
 \tag{4}$$

В результате вычислений по выражению (4), классифицируемые сетевые пакеты распределяются по группам для идентификации соответствующих протоколов информационного обмена:

$$\begin{aligned}
 GROUP_A &= \{TLSv1, TLSv1.2, TCP, SSHv2, HTTP\}, \\
 GROUP_B &= \{UDP, STUN, QUIC, NBNS, DNS, BROWSER\}, \\
 GROUP_C &= \{SSDP, MDNS, LLMNR\}, \\
 GROUP_D &= \{SSDP, MDNS, LLMNR, DHCP v6\}.
 \end{aligned}
 \tag{5}$$

Попавшие в одну группу протоколы будем считать во многом схожими, а общую выборку в группе – однородной. Внутри каждой группы данные разделяются на тренировочные и тестовые наборы данных.

На современном этапе развития математического моделирования принято считать, что репрезентативные исходные наборы данных во многом обеспечивают конечный успех всего моделирования – получение адекватных моделей. Как правило, проводятся статисти-

ческие проверки исходных данных, выявляются и исключаются из тренировочных выборок сильно зашумленные или избыточные исходные данные. Во втором блоке алгоритма предобработки выделяются хорошие наборы данных для дальнейшего построения моделей классификации сетевых пакетов прикладного уровня.

В третьем блоке алгоритма используются следующие процедуры предобработки данных, как правило, применяемых в методах машинного обучения:

1) *обработка категориальных данных*,
 2) *масштабирование признаков*, которое включает в себя приведение разных признаков к одинаковой шкале (на практике существуют два общих подхода к приведению разных признаков к одинаковой шкале:

- нормализация;
- стандартизация,

3) *отбор содержательных признаков*.

Нормализация атрибутов осуществлялась с помощью нечетких индикаторов. Нечеткий индикатор – это число в диапазоне [0, 1], которое характеризует оценку показателя используемого в качестве атрибута.

В основу нечеткого индикатора положена оценка эксперта, которая моделируется функцией принадлежности, при этом носителем выступает допустимое множество значений анализируемого показателя.

В общем случае могут также применяться различные модели функции принадлежности, например, такие как треугольная, либо трапециевидная или обобщенная колоколообразная (рис. 2).




Рис. 2. Трапециевидная функция принадлежности mf (membership function) нечеткому множеству

4 ПОСТРОЕНИЕ КЛАССИФИКАТОРА СЕТЕВЫХ ПАКЕТОВ

В настоящее время идея совместного использования нейросетевого подхода классификации сетевых пакетов и анализ DPI, NTA активно обсуждается исследователями и специалистами.

Следует отметить, что ряд входных признаков из числа выделенных и представленных выше являются категориальными. Другие являются количественными. Учитывая значительное количество анализируемых данных для оптимизации вычислений, требуется использовать декомпозицию (свертку). Для этой цели специалисты машинного обучения часто применяют линейный дискриминантный анализ (LDA) [13] и/или глубокие сверточные нейронные сети [14]. В нашей работе для этой цели используются модели на основе логических правил и алгоритмов нечеткой логики (применялся алгоритм нечеткого вывода Мамдани [15 – 17]). Применение предложенного нами способа позволяет оперировать нашими знаниями об объекте исследования, например, с использованием RFC-описаний сетевых протоколов.

При реализации «глубокого» анализа пакетов в настоящей работе рассматривается комбинированный метод классификации трафика, основанный на приме-

нении теорий нейронных сетей и нечетких множеств. При этом существенный выигрыш в классификации трафика получен при двухэтапном решении задачи, а именно:

- первый этап включает в себя - выполнение процедуры снижения размерности входного пространства признаков (свертки) (рис. 3);

- второй этап завершает классификацию трафика с применением логистической регрессии «с учителем» (рис. 3) или с использованием алгоритма нечеткого вывода Мамдани.

4.1 Метод однопакетной классификации сетевых пакетов на основе алгоритмов нечеткой логики и нейронных сетей

4.1.1 Особенности алгоритма нечеткого вывода Мамдани

Алгоритм нечеткого вывода Мамдани задействован в общей схеме классификации сетевых пакетов в настоящей работе. Рассмотрим основные особенности данного алгоритма.

Целевой функцией будем считать выполнение такого отображения своих входов (вектор X) в выход Y , которое обеспечивало бы как можно более точную аппроксимацию реальной системы, например, в смысле средней абсолютной погрешности.

Указанное отображение предполагает существование некоторой геометрической поверхности, которую принято называть поверхностью отображения, в пространстве, задаваемым декартовым произведением $X \times Y$ [18].

Алгоритм Мамдани представляет собой множество правил, где каждое правило задает в указанном пространстве некоторую нечеткую точку. На основе множества нечетких точек формируется нечеткий график, механизм интерполяции между точками, который зависит от используемого аппарата нечеткой логики.

Формально алгоритм Мамдани может быть определен следующим образом:

- формирование базы правил систем нечеткого вывода;
- фаззификация входных переменных;
- агрегирование подусловий в нечетких правилах продукций, при этом для нахождения степени истинности каждого из правил нечетких продукций используются парные нечеткие логические операции, те правила, степень истинности которых отлична от нуля, считаются активными и используются для дальнейших расчетов;
- активизация подзаключений в нечетких правилах продукций, которую также часто называют выводом на правилах, выполняется с использованием операторов нечеткой импликации, например, если вывод следует осуществлять в соответствии с правилом: ЕСЛИ ($x = A$) ТО ($y = B$), используя импликацию Мамдани, можно определить активизированную функцию принадлежности импликации $A \rightarrow B$, которая представляет собой некоторое нечеткое отношение:

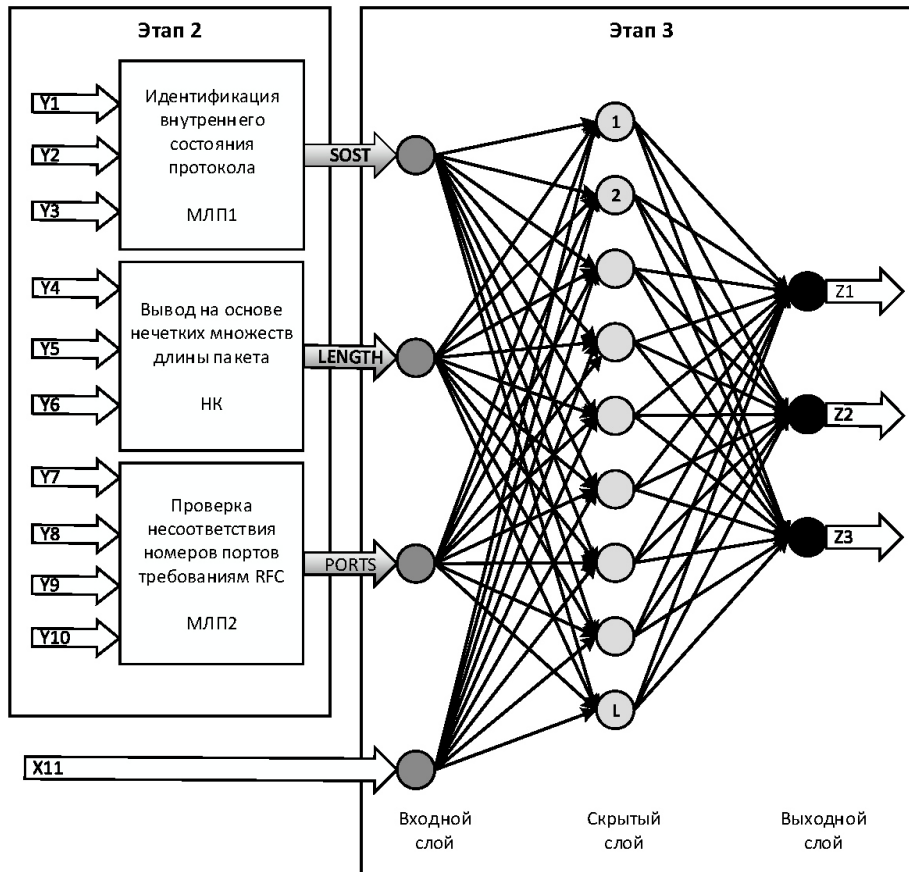


Рис. 3 Структурная схема двухступенчатого алгоритма классификации сетевых пакетов

R1: ЕСЛИ $\mu_R(x,y) = \text{MIN}(\mu_A(x), \mu_B(y))$,
 R: $A \rightarrow B$ на декартово произведение $X \times Y$; (6)

• аккумуляция заключений (процесс определения общего вывода) нечетких правил продукций наиболее часто выполняется так, как показано на следующем примере. Пусть дана нечеткая модель с базой правил вида:

R1: ЕСЛИ $(x = A1)$ ТО $(y = B1)$,
 R2: ЕСЛИ $(x = A2)$ ТО $(y = B2)$, (7)

при этом требуется определить результирующую функцию принадлежности $\mu_{res}(y)$ вывода из всей базы правил, тогда все правила, входящие в базу, можно объединить в одно составное правило следующего вида:

R: ЕСЛИ $(x = A1)$ ТО $(y = B1)$
 ИЛИ ЕСЛИ $(x = A2)$ ТО $(y = B2)$. (8)

Это означает, что правило R состоит из двух простых правил R1 и R2, объединенных логической связкой ИЛИ, которое может быть представлено и так:

$R = R1 \cup R2$. (9)

Поскольку каждое правило представляет собой нечеткое отношение двух аргументов (импликацию), результирующее отношение R можно найти с использованием одной из s-норм, например, оператора MAX,

его функцию принадлежности $\mu_R(x,y)$ можно получить на основе функций принадлежности составляющих его отношений (импликаций) по формуле (10):

$$\mu_R(x,y) = \text{MAX}(\mu_{R1}(x,y), \mu_{R2}(x,y)); \quad (10)$$

• дефаззификация входных переменных, которая, как правило, задействует популярный метод центра тяжести. Однако мы применили также очень эффективный метод дефаззификации, называемый методом высот (рис.4), расчеты по которому производятся по формуле (11):

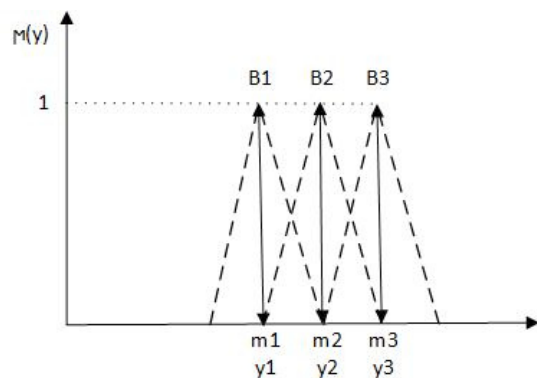


Рис. 4. Замена нечетких множеств B_j одноэлементными множествами (синглтонами)

$$y^* = \frac{\sum_{j=1}^m y_j \mu_{B_j^*}(y)}{\sum_{j=1}^m \mu_{B_j^*}(y)}, \quad (11)$$

где m – число правил.

Таким образом, основными достоинствами алгоритма являются простой способ отображения входных данных (вектор X) в выход Y для достижения высокой точности аппроксимации реальной системы при минимальной вычислительной нагрузке и возможность построения эффективных нейронечетких сетей, что предопределило наш интерес к алгоритму нечеткого вывода Мамдани в части его применимости в задачах определения протоколов информационного обмена прикладного уровня на основе классификации сетевых пакетов.

4.1.1 Искусственные нейронные сети

С середины 2000-х годов отмечается возрождение интереса к теме, связанной с практическим применением искусственных нейронных сетей в задачах распознавания образов, аппроксимации функций, обработки сигналов и др. Этому способствовали разработанный прорывной алгоритм быстрого обучения, предложенный Дж. Хинтоном [19], и более позднее появление графических процессоров для параллельных численных расчетов (примерно в 2011 году).

Нейросетевой классификатор – это, по сути, геометрический классификатор, с построения которого начинается вся современная литература по машинному обучению, например, в работах [20 – 22].

Представленный на рисунке 3 алгоритм производит расчеты с использованием искусственных нейронных сетей.

В настоящее время архитектура нейронной сети, как правило, определяется на основе одного из общепринятых подходов:

1) с использованием языка программирования Python с его богатым и быстро обновляющимся арсеналом библиотек, связанных с методами машинного обучения (Scikit-learn [23], Keras [24], Spark [25, 26], TensorFlow [27 – 29], Theano [14]);

2) с использованием языка программирования C/C++ и специализированных открытых библиотек, в которых реализованы многие алгоритмы машинного обучения, например, OpenCV [30].

Эти подходы предполагают построение интеллектуальных решений с использованием доступных современных аппаратных платформ, таких как x64-86 (CPU). Однако для других появляющихся и совершенствующихся аппаратных платформ и технологий, таких как Эльбрус [31], графические ускорители вычислений GPU и др., находится место собственным реализациям нейросетевых решений с применением любого языка программирования высокого уровня (C/C++, Python и др.).

В данной работе использовалась собственная реализация нейросетевого решения (логистическая регрессия), разработанная на C/C++. Вместе с тем, очень

важно отметить, что геометрические классификаторы во многих случаях оказываются весьма полезными и эффективными, особенно в задачах определения протоколов информационного обмена и приложений прикладного уровня.

Возвращаясь к выбранной в данной работе архитектуре нейронной сети (многослойная сеть прямого пространства с одним скрытым слоем, который включает 12 нейронов для модели классификации сетевых пакетов на соответствие протоколу TLS v1 и 11 нейронов для протоколов TLS v1.2 и HTTP), напомним, что при решении большинства прикладных задач полученная взвешенная сумма входных сигналов (см. рис. 5) преобразуется в выход нейрона с помощью некоторой нелинейной функции σ , не обладающей памятью. Данную функцию принято называть активационной:

$$y = \sigma(\omega_0 + \omega_1 x_1 + \omega_2 x_2 + \dots + \omega_n x_n). \quad (12)$$

Выбор активационной функции зависит от специфики решаемой прикладной задачи, часто используют сигмоидную функцию (сигмоиду). В данной работе в качестве активационной функции также применялась сигмоида. Сигмоида и ее производная, показанные на рисунке 5, имеют следующий вид:

$$\sigma(x) = \frac{1}{1 + e^{-x}}; \quad \sigma'(x) = \frac{e^{-x}}{(1 + e^{-x})^2}. \quad (13)$$




Рис. 5. Сигмоида и ее производная

Методы градиентного спуска и масштабируемых сопряженных градиентов [32 – 34] использовались в данной работе для обучения нейронной сети.

4.1.3 Структурная схема алгоритма определения протокола информационного обмена

Структурная схема алгоритма классификации сетевых пакетов на принадлежность протоколам TLS v1 и TLS v1.2 представлена на рис.6., где входные показатели $Y1 - Y10$ и $X11$ характеризуют:

- $Y1$ – номер порта [TCP/UDP] отправителя;
- $Y2$ – номер порта [TCP/UDP] получателя;
- $Y3$ – значение первого байта в строковом контенте (часть payload) протокола верхнего уровня;
- $Y4$ – степень принадлежности малому значению длины пакета (нечеткому множеству);

Y5 – степень принадлежности большому значению длины пакета (нечеткому множеству);

Y6 – степень принадлежности среднему значению длины пакета (нечеткому множеству);

Y7 – степень принадлежности малому значению номера порта [TCP/UDP] отправителя (нечеткому множеству);

Y8 – степень принадлежности большому значению номера порта [TCP/UDP] отправителя (нечеткому множеству);

Y9 – степень принадлежности малому значению номера порта [TCP/UDP] получателя (нечеткому множеству);

Y10 – степень принадлежности большому значению номера порта [TCP/UDP] получателя (нечеткому множеству);

X11 – принадлежность определенному в RFC 2246 и RFC 5246 интервалу целых чисел Content Type для протоколов TLS v1 и TLS v1.2 соответственно.

Выходные показатели имеют вид:

Z1 – вероятность принадлежности к классу TLS v1 (результатирующий показатель);

Z2 – вероятность принадлежности к классу TLS v1.2 (результатирующий показатель);

Z3 – код внутреннего состояния наиболее вероятно класса (результатирующий показатель).

На первой ступени расчетов, например, в блоке проверки несоответствия используемых номеров портов требованиям RFC на основе несложных логических правил проверяются номера портов для исследуемых протоколов TLS v1 и TLS v1.2, как правило, для передающей

и принимающей сторон используется порт 443 и номер порта из интервала целых чисел, нижняя граница которого превышает 50000.

Вторая ступень использует методы логической регрессии или алгоритмы нечеткой логики, а именно, алгоритм нечеткого вывода Мамдани. Результаты расчетов коэффициентов парной корреляции (табл. 1) входных признаков модели второй ступени показали, что входные признаки являются независимыми и могут эффективно использоваться в модели на основе логической регрессии. Для подобных расчетов, как правило, используются различные математические пакеты. В данной работе применялся IBM SPSS Statistics 19.

Наряду с независимостью входных признаков, интерес представляет значимость входных синтетических признаков, поступающих на вторую ступень расчетов. Используя число ошибок классификации, когда для классификации используется каждый из входных признаков в отдельности, а также метод анализа иерархий [35] и наши знания о сетевых протоколах прикладного уровня, мы определили весовые коэффициенты для признаков модели второй ступени по степени значимости для протоколов TLS v1 и TLS v1.2:

$W_{ports} = 0,1267$; $W_{x11} = 0,566$; $W_{length} = 0,0398$; $W_{sost} = 0,2674$.

Наиболее значимым признаком модели второй ступени расчетов является принадлежность определенному в RFC интервалу целых чисел Content Type для исследуемых протоколов TLS v1 и TLS v1.2. На втором месте по значимости определяемое в МЛП1 внутреннее состояние протокола. Следует также отметить, высокую

Таблица 1

Результаты расчетов коэффициентов парной корреляции

	PORTS	X11	LENGTH	SOST
PORTS	1	0,211	0,11	0,073
X11	0,211	1	0,397	0,176
LENGTH	0,11	0,397	1	0,188
OST	0,073	0,176	0,188	1

Таблица 2

Характеристики используемой аппаратной платформы

Ресурсы	Аппаратная платформа
Центральный процессор	Intel Core i5-6400 2,7 GHz
Оперативная память	8 Gb
Установленное ПО	ОС MS Windows 10 Pro 64 bit

Таблица 3

Результаты тестирования программного модуля для протоколов TLS v1 и TLS v1.2

Выборка		Не TLS v1 и не TLS v1.2		TLS v1		TLS v1.2	
		Логистическая регрессия	С использованием нечетких множеств	Логистическая регрессия	С использованием нечетких множеств	Логистическая регрессия	С использованием нечетких множеств
Тестовая выборка	Кол-во пакетов	881	881	104	104	269	269
	Ложное срабатывание	5	5	75	17	10	18
	Верность	99%	99%	28%	84%	96%	93%

Таблица 4

Общие результаты тестирования программного модуля

Выборка		Не TLS v1 и не TLS v1.2 и не HTTP		HTTP		Общий результат тестирования	
		Логистическая регрессия	С использованием нечетких множеств	Логистическая регрессия	С использованием нечетких множеств	Логистическая регрессия	С использованием нечетких множеств
Тестовая выборка	Кол-во пакетов	881	881	25	25	1254	1254
	Ложное срабатывание	5	5	1	2	91	42
	Верность	99%	99%	96%	92%	93%	97%

полезность итогового внутреннего состояния исследуемых протоколов – Z3. Данный результирующий признак очень полезен для дальнейшей оптимизации построенного КСП прикладного уровня, о чем свидетельствуют результаты проведенных тестов (см. раздел 5).

На основе описанного выше двухступенчатого алгоритма определения протокола информационного обмена был разработан тестовый программный модуль.

5 ТЕСТИРОВАНИЕ ПОСТРОЕННОГО КСП

На данном этапе производятся расчеты с использованием искусственных нейронных сетей и алгоритмов нечеткой логики.

Для использования в межсетевых экранах, в DPI-системах, в COB и в др., для операционных систем LINUX и операционных систем линейки Windows на языке программирования C/C++ построен программный модуль.

В таблице 2 приводятся характеристики используемой при проведенном тестировании аппаратной платформы.

Результаты тестирования представлены в таблицах 3 и 4.

В таблице 5 представлены измерения вычислительных ресурсов используемых вариантов моделей на второй ступени расчетов.

Основные преимущества представленного решения:

- высокая вычислительная производительность классификации с использованием нейронных сетей и алгоритмов нечеткой логики;
- возможность применения параллельных вычислений;

Таблица 5

Результаты вычислительной производительности

Метод	Логистическая регрессия	С использованием нечетких множеств
Среднее время классификации пакета, мс	0,755	0,6735

- высокая верность классификации и обобщение на тестовых выборках;

- совместимость с доверенными аппаратными платформами, такими как Эльбрус, и переносимость на различные операционные системы.

ЗАКЛЮЧЕНИЕ

Представленная в данной работе методика распознавания сетевых протоколов информационного обмена иллюстрирует развитие систем анализа трафика (NTA) и других систем обеспечения информационной безопасности, таких как IDS, IPS, NMS, DDoS PS и т.п., в условиях действия программ импортозамещения с применением нового подхода анализа трафика, в основе которого лежит использование алгоритмов машинного обучения, алгоритмов нечеткой логики, позволяющих проводить классификацию сетевых пакетов приложений прикладного уровня.

Существует перспектива появления нейросетевого КСП промышленного уровня с показателями не уступающими известным DPI-решениям, но работающего на совершенно другом уровне.

В данной работе делается попытка перехода от простого логического КСП на правила, главным недостатком которого является трудоемкость и рутинность формирования правил, к современному высокотехнологичному нейросетевому классификатору, базирующемуся на методах машинного обучения и интеллектуальной обработке данных. Идея совместного использования нейросетевого подхода классификации сетевых пакетов и DPI, NTA и др. сейчас обсуждаемая.

Предложен новый эффективный алгоритм определения протоколов информационного обмена на основе классификации сетевых пакетов с использованием алгоритмов нечеткой логики и методов машинного обучения. Основной эффект алгоритма заключается в том, что для определения протокола используется принцип высокоскоростной однопакетной классификации, который позволяет анализировать информацию, передаваемую в каждом конкретном пакете. Используются элементы

поведенческого анализа, а именно, классифицируются переходные состояния протоколов информационного обмена, что позволяет достичь более высокого уровня верности классификации и более высокой степени обобщения на новых тестовых выборках.

Дальнейшее развитие КСП связано с обеспечением информационной безопасности, а также с поиском новых способов определения DDoS-атак. На первом этапе с использованием КСП могут определяться протоколы информационного обмена прикладного уровня и типы устройств, задействованные при обмене. Далее могут быть выявлены приложения на устройствах информационного обмена и затем сетевые приложения прикладного уровня. Такой способ определения потенциальных сетевых угроз не является высокоскоростным. Однако он может быть очень эффективным в рамках тестовой среды для проведения полноценных комплексных исследований в задачах идентификации DDoS-атак.

СПИСОК ЛИТЕРАТУРЫ

1. Лось А.Б., Даниелян Ю.Ю. Сравнительный анализ систем обнаружения вторжений, представленных на отечественном рынке // Вестник МФЮА.– 2014. – № 3. – С. 181–187.
2. Kawai H., Ata S., Nakamura N., Oka I. Identification of Communication Devices from Analysis of Traffic Patterns. Electric Industry Co., Ltd. Japan, 2018.
3. Хазов В. Введение в DPI: Аналитика, обстановка на рынке и тренды. – URL: <https://vasexperts.ru/blog/privet-mir/>.
4. Рыжков Д.О. Определение протокола прикладного уровня для анализа сетевого трафика с применением алгоритмов машинного обучения // Матер. IX Междунар. студенческой науч. конф. «Студенческий научный форум». – URL: <https://scienceforum.ru/2017/article/2017032799>.
5. Rehak M., Pechoucek M., Grill M., Stiborek J., Bartos K., and Celeda P. Adaptive multiagent system for network traffic monitoring // IEEE Intelligent Systems. 2009. Vol. 24 (3). pp 16–25.
6. Anu Gowsalya R.S., Miruna Joe Amali S. SVM Based Network Traffic Classification Using Correlation Information // International Journal of Research in Electronics and Communication Technology (IJRECT). 2014. Vol. 1, iss. 2. pp. 7–11.
7. Singh J., Nene M.J. A Survey on Machine Learning Techniques for Intrusion Detection Systems // International Journal of Advanced Research in Computer and Communication Engineering. November 2013. Vol. 2, iss. 11. pp 4349–4355.
8. Abraham S. and Nair S. Cyber Security Analytics: A stochastic model for Security Quantification using Absorbing Markov Chains // Journal of Communications. December 2014. Vol. 9 (12). pp. 899–907.
9. Szabo G., Szule J., Turanyi Z., Pongracz G. Multi-level Machine Learning Traffic Classification System // ICN 2012 : The Eleventh International Conference on Networks. pp 69–77.
10. Sun R., Yang B., Peng L., Chen Z., Zhang L., and Jing S. Traffic Classification Using Probabilistic Neural Networks // Sixth International Conference on Natural Computation (ICNC 2010). pp. 1914–1919.
11. Елагин В.С., Зарубин А.А., Онуфриенко А.В. Эффективность DPI-системы для идентификации трафика и обеспечения качества обслуживания OTT-сервисов // Научные технологии в космических исследованиях Земли. – 2018. – Т. 10, № 3. – С. 40–53.
12. Sanders C. Practical packet analysis: 2nd edition. 2011. No Starch Press, Inc. 38 Ringold Street, San Francisco, CA 94103.
13. Izenman A.J. Linear Discriminant Analysis. In: Modern Multivariate Statistical Techniques. Springer Texts in Statistics. Springer, New York, 2013. 733 p.
14. Bourez C. Deep learning with Theano. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB, UK. 2017. 284 p.
15. Mamdani E.H., Assilian S. An experiment in linguistic synthesis thesis with a fuzzy logic controller // International Journal of Man-Machine Studies. 1975. Vol. 7, no. 1, pp. 1–13.
16. Mamdani E.H. Advances in the linguistic synthesis of fuzzy controllers // International Journal of Man-Machine Studies, 1976. Vol. 8. pp. 669–678.
17. Mamdani E.H. Applications of fuzzy logic to approximate reasoning using linguistic synthesis // IEEE Transactions on Computers. 1977. Vol. 26, no. 12. pp. 1182–1191.
18. Пегат А. Нечеткое моделирование и управление : пер. с англ. – М. : БИНОМ. Лаборатория знаний, 2009. – 312 с.
19. Rumelhart D.E., Hinton G.E., Williams R.J. Learning Representations by Backpropagating Error // LETTERS TO NATURE. 1986. Vol. 323. pp 533–536.
20. Bishop C.M. Neural Networks for Pattern Recognition // Department of Computer Science and Applied Mathematics Aston University Birmingham. UK, 1995. P. 479.
21. Рашка С. Python и машинное обучение / пер. с англ. А.В. Логунова. – М. : ДМК Пресс, 2017. – 418 с.
22. Флах П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных / пер. с англ. А.А. Слинкина. – М. : ДМК Пресс, 2015. – 400 с.
23. Garreta R., Moncecchi G. Learning scikit-learn: Machine Learning in Python. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB. UK, 2013. 99 p.
24. Gulli A., Pal S. Deep Learning with Keras. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB, UK. 2017. 318 p.
25. Изучаем Spark: молниеносный анализ данных / Х. Карау, Э. Конвински, П. Венделл, М. Захария. – М. : ДМК Пресс, 2015. – 304 с.

26. Pentreath N. Machine Learning with Spark. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB, UK, 2015. 319 p.

27. McClure N. TensorFlow Machine Learning Cookbook // Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB, UK, 2017. 422 p.

28. Abrahams S., Hafner D., Erwitte E., Scarpinelli A. Tensorflow for machine intelligence. Bleeding Edge Press, Santa Rosa, CA 95404. 2016. 298 p.

29. Bonnin R. Building Machine Learning Projects with TensorFlow. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB, UK, 2016. 282 p.

30. Beyeler M. Machine Learning for OpenCV. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB, UK, 2017. 382 p.

31. Бычков И.Н., Глухов В.И., Трушкин К.А. Доверенная программно-аппаратная платформа «Эльбрус». Отечественное решение для АСУ ТП КВО // ИСУП. – 2014. – № 1 (49). – URL: <https://isup.ru/articles/15/4788/>.

32. Nocedal J., Wright S.J. Numerical Optimization, Springer, 1999. 663 p.

33. Васильев Ф.П. Методы оптимизации. – М. : Факториал Пресс, 2002. – 824 с

34. Галушкин А.И. Нейронные сети: основы теории. – М. : Горячая Линия – Телеком, 2012. – 496 с.

35. Саати Т.Л. Взаимодействие в иерархических системах // Техническая кибернетика. – 1979. – № 1. – С. 68–84.

REFERENCES

1. Los A.B., Danielian Iu.Iu. Sravnitelnyi analiz sistem obnaruzheniia vtorzhenii, predstavlenykh na otechestvennom rynke [Comparative Analysis of Intrusion Detection Systems Available on Domestic Market]. Vestnik MFUA [Herald of the Moscow University of Finance and Law], 2014, no. 3, pp. 181–187.

2. Kawai H., Ata S., Nakamura N., Oka I. Identification of Communication Devices from Analysis of Traffic Patterns. Electric Industry Co., Ltd. Japan, 2018.

3. Khazov V. Vvedenie v DPI: Analitika, obstanovka na rynke i trendy [Introduction in DPI: Analytics, Market Environment and Trends]. Available at: <https://vasexperts.ru/blog/privet-mir/>.

4. Ryzhkov D.O. Opredelenie protokola prikladnogo urovnia dlia analiza setevogo trafika s primeneniem algoritmov mashinnogo obucheniia [Application-Layer Protocol Identification for Analyzing the Network Traffic Using Machine-Learning Algorithms]. Mater. IX Mezhdunar. studencheskoi nauch. konf. "Studencheskii nauchnyi forum" [Proc. of the 9th Int. Student Sci. Conf. 'Student Scientific Forum']. Available at: <https://scienceforum.ru/2017/article/2017032799>.

5. Rehak M., Pechoucek M., Grill M., Stiborek J., Bartos K., and Celeda P. Adaptive Multiagent System for Network Traffic Monitoring. IEEE Intelligent Systems, 2009, vol. 24 (3), pp 16–25.

6. Anu Gowsalya R.S., Miruna Joe Amali S. SVM Based Network Traffic Classification Using Correlation Information. International Journal of Research in Electronics and Communication Technology (IJRECT), 2014, vol. 1, iss. 2, pp. 7–11.

7. Singh J., Nene M.J. A Survey on Machine Learning Techniques for Intrusion Detection Systems. International Journal of Advanced Research in Computer and Communication Engineering, November 2013, vol. 2, iss. 11, pp 4349–4355.

8. Abraham S. and Nair S. Cyber Security Analytics: A Stochastic Model for Security Quantification Using Absorbing Markov Chains. Journal of Communications, December 2014, vol. 9 (12), pp. 899–907.

9. Szabo G., Szule J., Turanyi Z., Pongracz G. Multi-Level Machine Learning Traffic Classification System. The Eleventh International Conference on Networks. (ICN 2012). pp 69–77.

10. Sun R., Yang B., Peng L., Chen Z., Zhang L., and Jing S. Traffic Classification Using Probabilistic Neural Networks. Sixth International Conference on Natural Computation (ICNC 2010). pp. 1914–1919.

11. Elagin V.S., Zarubin A.A., Onufrienko A.V. Effektivnost DPI-sistemy dlia identifikatsii trafika i obespecheniia kachestva obsluzhivaniia OTT-servisov [Efficiency of DPI System for Traffic Identification and Maintenance of OT-Service Quality]. Naukoemkie tekhnologii v kosmicheskikh issledovaniakh Zemli [High Tech in Earth Space Research], 2018, vol. 10, no. 3, pp. 40–53.

12. Sanders C. Practical Packet Analysis. 2nd edition. 2011. No Starch Press, Inc. 38 Ringold Street, San Francisco, CA 94103.

13. Izenman A.J. Linear Discriminant Analysis. Modern Multivariate Statistical Techniques. Springer Texts in Statistics. Springer, New York, 2013. 733 p.

14. Bourez C. Deep Learning with Theano. Packt Publishing Ltd. Livery Place 35, Livery Street Birmingham, B3 2PB, UK. 2017. 284 p.

15. Mamdani E.H., Assilian S. An Experiment in Linguistic Synthesis Thesis with a Fuzzy Logic Controller. International Journal of Man-Machine Studies, 1975, vol. 7, no. 1, pp. 1–13.

16. Mamdani E.H. Advances in the Linguistic Synthesis of Fuzzy Controllers. International Journal of Man-Machine Studies, 1976, vol. 8, pp. 669–678.

17. Mamdani E.H. Applications of Fuzzy Logic to Approximate Reasoning Using Linguistic Synthesis. IEEE Transactions on Computers, 1977, vol. 26, no. 12, pp. 1182–1191.

18. Piegat A. Nechetkoe modelirovanie i upravlenie. Per. s angl. [Fuzzy Modeling and Control. Translated from Engl.]. Moscow, BINOM. Laboratoriia znaniy Publ., 2009. 312 p.

19. Rumelhart D.E., Hinton G.E., Williams R.J. Learning Representations by Backpropagating Error. Letters to Nature, 1986, vol. 323, pp. 533–536.

20. Bishop C.M. Neural Networks for Pattern Recognition. Department of Computer Science and Applied Mathematics Aston University Birmingham. UK, 1995. 479 p.
21. Rashka S. Python i mashinnoe obuchenie. Per. s angl. A.V. Logunova [Python and Machine Learning. Translated from Engl. by A.V. Logunov]. Moscow, DMK Press, 2017. 418 p.
22. Flakh P. Mashinnoe obuchenie. Nauka i iskusstvo postroeniia algoritmov, kotorye izvlekaiut znaniia iz dannykh. Per. s angl. A.A. Slinkina [Machine Learning: The Art and Science of Algorithms that Make Sense of Data. Translated from Engl. by A.A. Slinkin]. Moscow, DMK Press, 2015. 400 p.
23. Garreta R., Moncecchi G. Learning Scikit-Learn: Machine Learning in Python. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB. UK, 2013. 99 p.
24. Gulli A., Pal S. Deep Learning with Keras. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB, UK. 2017. 318 p.
25. Karau Kh., E. Konvinski, P. Vendell, M. Zakhariia. Izuchaem Spark: molnienosnyi analiz dannykh [We Learn Spark: Lightning Fast Data Analysis]. Moscow, DMK Press, 2015. 304 p.
26. Pentreath N. Machine Learning with Spark. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB. UK, 2015. 319 p.
27. McClure N. TensorFlow Machine Learning Cookbook. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB, UK, 2017. 422 p.
28. Abrahams S., Hafner D., Erwitte E., Scarpinelli A. TensorFlow for Machine Intelligence. Bleeding Edge Press, Santa Rosa, CA 95404. 2016. 298 p.
29. Bonnin R. Building Machine Learning Projects with TensorFlow. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB. UK, 2016. 282 p.
30. Beyeler M. Machine Learning for OpenCV. Packt Publishing Ltd. Livery Place 35 Livery Street Birmingham B3 2PB. UK, 2017. 382 p.
31. Bychkov I.N., Glukhov V.I., Trushkin K.A. Doverennaia programmno-apparatnaia platforma 'Elbrus'. Otechestvennoe reshenie dlia ASU TP KVO [Trusted Software and Hardware Platform 'Elbrus'. Domestic Decision for Automated Control Systems for Technological Processes and for Critical Important Objects]. ISUP, 2014, no. 1 (49). Available at: <https://isup.ru/articles/15/4788/>.
32. Nocedal J., Wright S.J. Numerical Optimization. Springer, 1999. 663 p.
33. Vasilev F.P. Metody optimizatsii [Optimization Methods]. Moscow, Faktorial Press, 2002. 824 p.
34. Galushkin A.I. Neironnye seti: osnovy teorii [Neural Networks: Fundamentals of the Theory]. Moscow, Goriachaia Liniia – Telekom Publ., 2012. 496 p.
35. Saati T.L. Vzaimodeistvie v ierarkhicheskikh sistemakh [Interaction in Hierarchical Systems]. Tekhnicheskaiia kibernetika [Technical Cybernetics], 1979, no. 1, pp. 68–84.