При использовании материалов статьи необходимо использовать данную ссылку:
Шестопалов Р.П. О выборе предпочтительного алгоритма подстройки весов при обучении нейросетевых алгоритмов обработки информации // Информационно-экономические аспекты стандартизации и технического регулирования. 2021. № 2 (60). С. 90-101

УДК 004.023:[504.054+504.064.2]

О ВЫБОРЕ ПРЕДПОЧТИТЕЛЬНОГО АЛГОРИТМА ПОДСТРОЙКИ ВЕСОВ ПРИ ОБУЧЕНИИ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ ОБРАБОТКИ ИНФОРМАЦИИ

Шестопалов Р.П.

В статье представлены результаты, позволяющие обосновать выбор предпочтительного алгоритма подстройки весовых коэффициентов искусственных нейронных сетей на стадии их обучения. Предложено оценивать существующие алгоритмы подстройки по достигаемым в процессе обучения значениям трех показателей: вероятности успешного обучения нейросети за заданное время, среднего времени успешного обучения нейросети и ресурсоемкости алгоритмов. В основу ранжирования алгоритмов подстройки весов нейросети предлагается положить ранжирования по максимальному удалению. Материалы статьи могут быть полезны специалистам, разрабатывающим нейросети и совершенствующим процесс их обучения.

Ключевые слова: нейронная сеть, алгоритм подстройки весов нейросети, вероятность успешного обучения нейросети, среднее время успешного обучения нейросети

ВВЕДЕНИЕ

В последние десятилетия научно-технический прогресс в различных отраслях мировой экономики, в социальной и оборонной сферах деятельности передовых государств характеризуется стремлением к глобальной автоматизации все большего объема операций и процессов, ранее осуществлявшихся с участием человека. При этом преследуются цели повышения эффективности различных операций и процессов в плане увеличения их результативности, оперативности, безопасности и снижения ресурсоемкости. Приведем далее ряд характерных примеров, иллюстрирующих данные тенденции на фоне современных реалий.

Так, пандемия коронавируса выявила потребность в автоматизации, во-первых, задач мониторинга распространения заболевания среди широких масс населения, во-вторых, оперативной обработки больших объемов тестов на коронавирус, анализа медицинских изображений, оперативного мониторинга состояния пациентов, в-третьих, прогнозирования результатов применения различных методов и методик лечения, анализа эффективности действия вакцин и пр. (см., например, [18, 21, 33]).

Угроза распространения терроризма на планете обусловила развитие методов глобального контроля и мониторинга больших масс людей и ситуаций, как то:

оперативного распознавания лиц людей; идентификации личности по индивидуальным биологическим признакам (по голосу, отпечаткам пальцев, особенностям строения тела, походки, сетчатки глаз и т.п.); распознавания автомобильных номеров; мониторинга информационных потоков в компьютерных сетях для обнаружения деструктивного контекста; обнаружения подделок документов; анализа данных с видеокамер и разнообразных датчиков-сенсоров; анализа аэрокосмических снимков (например, для обнаружения баз террористов и местонахождения их лидеров) (см., например, [2, 17, 24]).

Возникновение и распространение локальных военных конфликтов с применением традиционных (неядерных) средств вооружения (Сирия, Ливия, Нагорный Карабах, Йемен и др.) показали, что преимущество современных танков, артиллерии и дорогостоящих комплексов

Шестопалов Роман Павлович, студент факультета компьютерных технологий и информатики ФГАОУ ВО «Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина)»
Санкт-Петербург

противовоздушной обороны может быть нейтрализовано относительно недорогим, но массовым применением автоматических разведовательно-ударных комплексов беспилотных летательных аппаратов, обладающих функциями распознавания сигналов радаров, адаптивного пилотирования, перераспределения целей в процессе атаки и пр. (см., например, [8, 10, 11]).

Стремление обеспечить безопасность военнослужащих в ходе патрулирования и разминирования территорий бывших боевых действий активизировало развитие интеллектуальных роботизированных систем (как отдельных единиц, так и коллективов роботов) с возможностями распознавания состояния внешней среды, идентификации объектов и препятствий перед роботом, возможности оптимизации прокладки маршрутов движения, управления манипуляторами, поддержания равновесия и пр. [см., например, 19, 20].

Кризисные тенденции в мировой экономике требуют оперативных, но выверенных решений, основанных на автоматизированном анализе больших объемов социально-экономических данных, позволяющем в автоматизированном режиме выполнять задачи прогнозирования временных рядов (например, рядов товарного спроса, цен на сырьё, курсов валют, объемов продаж и пр.); оценки стоимости недвижимости; оценки рисков невозврата кредитов и предсказания банкротств; оптимизации товарных и денежных потоков, автоматического трейдинга (торговли на бирже); обеспечения безопасности транзакций по пластиковым картам; автоматизации считывания и распознавания чеков и документов и пр. (см., например, [6, 7, 13]).

Обострение политической борьбы в ходе выборов в различных странах (характерный пример последнего времени представляет США) вывело на первый план необходимость создания защищенных автоматических систем подсчета голосов избирателей в ходе выборов. Кроме того, крайне актуально иметь независимые от влияния ангажированных средств массовой информации средства анализа опросов, предсказания результатов выборов, динамики рейтингов, изучения и визуализации социальной динамики населения (см., например, [22]).

Возобновление лунной программы и планирование полетов на Марс требуют создания космической техники с высокой надежностью. Сложность космической техники, высокая цена ее отказа и одновременно жесткие условия функционирования, обусловленные действиями факторов космического пространства, делают актуальной проблему автоматизации прогнозирования возникновения отказов бортовой аппаратуры космических аппаратов и космических станций длительного функционирования, а также диагностики причин ее отказов. Множественность и динамичность факторов, иерархичность и сложность структуры оборудования космических аппаратов и космических станций требуют обработки больших объемов информации (см., например, [5, 15, 16]).

Кроме перечисленных примеров актуальность автоматической обработки больших объемов разнообразной информации характерна для отраслей связи, интернета, автоматизации производства, экологического мониторинга, геологоразведки, индустрии компьютерных игр, создания беспилотного автотранспорта и многих других направлений.

Эффективным средством решения большинства перечисленных выше проблем являются нейросетевые алгоритмы обработки информации (НСАОИ), представляющие собой гибкий и мощный набор инструментов решения разнообразных задач обработки и анализа данных (см., например, [9, 12, 26]), но требующий настройки (обучения) для решения конкретных задач.

Принцип и основные этапы обучения НСАОИ

Любая нейросеть упрощенно может быть представлена в виде набора искусственных нейронов (ИсН) с определенным образом заданными связями между их входами и выходами. Обычно в нейросети выделяют несколько типов ИсН, объединенных в так называемые слои: входной слой нейронов, выходной слой нейронов и внутренние (скрытые) слои нейронов (см. рисунок 1). Каждый ИсН (см. рисунок 2) представляет собой модуль, преобразующий n -мерный вектор входных сигналов $X_{<n>} =< x_1, x_2, ..., x_n >$ в выходной сигнал (импульс) y .

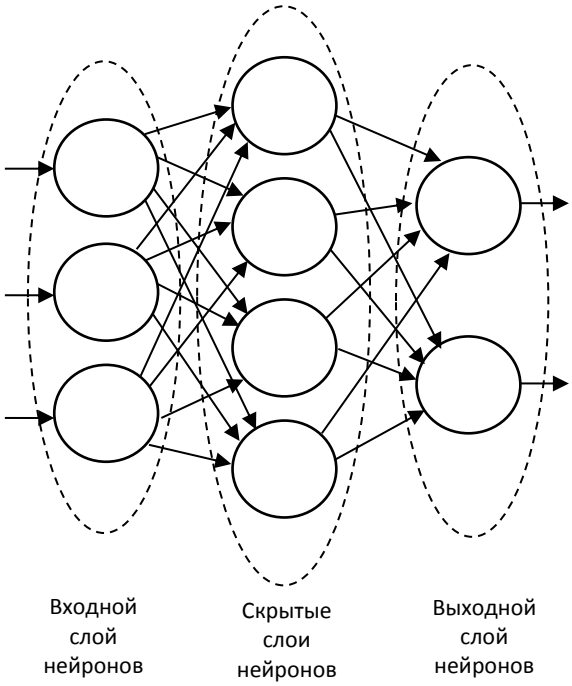

Рисунок 1. Типовая структура нейросети

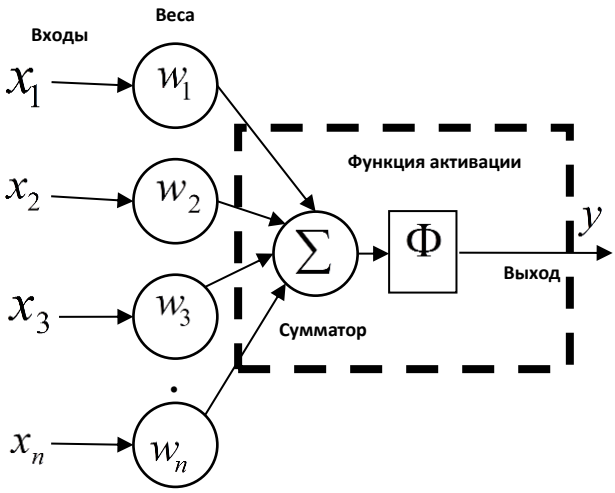

Рисунок 2. Преобразование информации в ИсН

Закон преобразования входных сигналов в выходной сигнал в ИсН математически описывается выражением:

$$y = \Phi(\sum_{i=1}^{n} \omega_i x_i - \theta), \quad (1)$$

где y - выходной сигнал ИсН; ω_i, $i = 1,...,n$ - веса преобразования амплитуд входных сигналов в ИсН; θ - пороговый уровень реагирования ИсН на суммарный входной сигнал $X = \sum_{i=1}^{n} \omega_i x_i$; $\Phi(X - \theta)$ - функция активации искусственного нейрона [1].

Принцип обучения НСАОИ заключается в целенаправленном подборе количественных значений весов нейросети, при которых нейросеть функционирует с приемлемым для пользователя значением ошибки [1, 3, 4, 26]. При этом под ошибкой функционирования сети понимается количественная оценка степени расхождения фактического выхода нейросети с его наилучшим (идеальным) значением.

Можно выделить следующие основные этапы обучения НСАОИ:

1. Формирование обучающей выборки.

Обучающая выборка («Training Sample Of Examples» (TSOE)) представляет собой множество пар входных и выходных векторов обучающих сигналов

$$\text{TSOE} = \{(X_{<n>1}, Y_{<m>1}), (X_{<n>2}, Y_{<m>2}), ..., (X_{<n>i}, Y_{<m>i}), ..., (X_{<n>N}, Y_{<m>N})\}, \quad (2)$$

где $X_{<n>i} = < x_{1i}, x_{2i}, ..., x_{ni} >$ - i-й входной n-мерный вектор обучающих сигналов;

$Y_{<m>i} = < y_{1i}, y_{2i}, ..., y_{mi} >$ - i-й выходной m-мерный вектор обучающих сигналов.

Параметрами обучающей выборки являются: объем TSOE, измеряемый количеством обучающих примеров N, и R - степень репрезентативности TSOE, $R \in [0,1]$, которая отражает степень соответствия характеристик TSOE характеристикам генеральной совокупности входов и выходов моделируемого с помощью НСАОИ физического процесса.

2. Тестирование работы НСАОИ на обучающем примере из TSOE.

На вход обучаемой нейросети подается входной тестовый массив данных $X_{<n>i} = < x_{1i}, x_{2i}, ..., x_{ni} >$. В результате распространения тестового сигнала по нейросети на ее выходе формируется выходной сигнал $Y^*_{<m>i} = < y^*_{1i}, y^*_{2i}, ..., y^*_{mi} >$. Так как для каждого входного тестового массива данных $X_{<n>i} = < x_{1i}, x_{2i}, ..., x_{ni} >$ в TSOE задан $Y_{<m>i} = < y_{1i}, y_{2i}, ..., y_{mi} >$ - выходной тестовый (опорный) массив данных (представляющий собой «правильный» ответ $Y_{<m>i}$ НСОИ на входной сигнал $X_{<n>i}$), то далее вычисляется количественная оценка степени расхождения фактического выхода нейросети $Y^*_{<m>i}$ с

опорным значением $Y_{<m>i}$. При этом, для скалярного выхода нейросети ошибка ε_i рассчитывается как

$$\varepsilon_i = \left| y_i - y^*_i \right| . \quad (3)$$

При векторном выходе нейросети (при $m > 1$) имеем вектор ошибок $\mathrm{E}_{<m>i} = < \varepsilon_{1i}, \varepsilon_{2i}, ..., \varepsilon_{mi} >$, который преобразуется либо к обобщенной усредненной ошибке вида (4), либо к обобщенной взвешенной ошибке вида (5):

$$\overline{E}^{(1)}_i = \frac{\sum_{j=1}^{m_i} \varepsilon_{ji}}{m} \quad (4)$$

или

$$\overline{E}^{(2)}_i = \alpha_1 \varepsilon_{1i} + \alpha_2 \varepsilon_{12} + ... + \alpha_m \varepsilon_{mi} = \sum_{j=1}^{m} \alpha_j \varepsilon_{ji} , \sum_{j=1}^{m} \alpha_j = 1. \quad (5)$$

Завершающей операцией этапа тестирования работы НСАОИ на обучающем примере из TSOE является анализ значимости величины ошибки функционирования НСАОИ. Для этого задается $\varepsilon_{Пор}$ - пороговое значение допустимой ошибки нейросети и проверяется выполнение неравенства

$$\varepsilon_i < \varepsilon_{Пор} , \text{ либо } \overline{E}^{(1)}_i < \varepsilon_{Пор} , \text{ либо } \overline{E}^{(2)}_i < \varepsilon_{Пор} . \quad (6)$$

Если неравенство вида (6) не выполняется, то далее необходимо выполнить подстройку весов нейросети.

В некоторых источниках (например, [1, 3, 4, 26]) этап 2 называют «прямым распространением ошибки».

3. Подстройка весов нейросети.

Для подстройки весов нейросети вычисляются частные производные

$$\Delta_{w_k i} = \frac{\partial \varepsilon_i}{\partial \omega_k} , \text{ либо } \Delta_{w_k i} = \frac{\partial \overline{E}^{(1)}_i}{\partial \omega_k} , \text{ либо } \Delta_{w_k i} = \frac{\partial \overline{E}^{(2)}_i}{\partial \omega_k} \quad (7)$$

Подстройка весов нейросети выполняется на основе информации о величине вклада веса нейросети в итоговую ошибку на выходе нейросети. В первую очередь целесообразно уменьшить значения весов с наибольшим вкладом в ошибку нейросети. Правило подстройки весов НСАОИ (для первой итерации подстройки и i -го обучающего примера) можно записать как

$$\begin{aligned} \omega^{(1)}_{1i} &= \omega^{(0)}_1 - h^{(1)} \times \Delta_{w_1 i} \\ \omega^{(1)}_{2i} &= \omega^{(0)}_2 - h^{(1)} \times \Delta_{w_2 i} , \\ &... \\ \omega^{(1)}_{Ki} &= \omega^{(0)}_K - h^{(1)} \times \Delta_{w_{K1} i} \end{aligned} \quad (8)$$

где < $\omega^{(0)}_1$, $\omega^{(0)}_2$,..., $\omega^{(0)}_K$ > - вектор начальных значений весов обучаемой нейросети;

h - величина шага подстройки весовых коэффициентов нейросети.

Операции (7) и (8) повторяются, пока не будут выполнены условия (6).

В некоторых источниках (например, [1, 3, 4, 26]) этап 3 называют «обратным распространением ошибки». После завершения подстройки весов нейросети по выбранному обучающему примеру переходят к следующему примеру из обучающей выборки TSOE, пока не будет завершено тестирование по всем примерам из TSOE (см. рисунок 3).

Особое место в структуре алгоритма обучения НСАОИ занимает блок 6, реализующий конкретный алгоритм подстройки весов нейросети.

В настоящее время известно достаточно большое количество алгоритмов подстройки весов нейросети, основанных на различных подходах и способах отыскания экстремумов функции многих переменных. Например, в источниках [1, 3, 4, 25] приводятся в сумме около 22 наименований алгоритмов подстройки весов нейросети: «алгоритм обратного распространения»; «алгоритм обучения Кохонена»; «алгоритм Левенберга – Марквардта»; «алгоритм сопряженных градиентов»; «псевдообратный алгоритм»; «алгоритм быстрого распространения»; «алгоритм анализа главных компонентов»; «алгоритм пометки ближайших классов»; «алгоритм на основе метода К-средних»; «алгоритм «Дельта минус дельта с чертой»»; «Квази-Ньютоновский алгоритм»; «алгоритм обучающего векторного квантователя»; «алгоритм линейного дискриминантного анализа»; «алгоритм обобщенно-регрессионной нейронной сети»; «алгоритм пошагового прямого или обратного отбора входных данных»; «алгоритм радиальной подвыборки»; алгоритм метода К-ближайших соседей (KNN)»; «алгоритм обучения вероятностной нейронной сети»; «алгоритм проекции Саммона»; «генетический алгоритм отбора входных данных»; «алгоритм

установки явных отклонений»; «алгоритм установки изотропных отклонений».

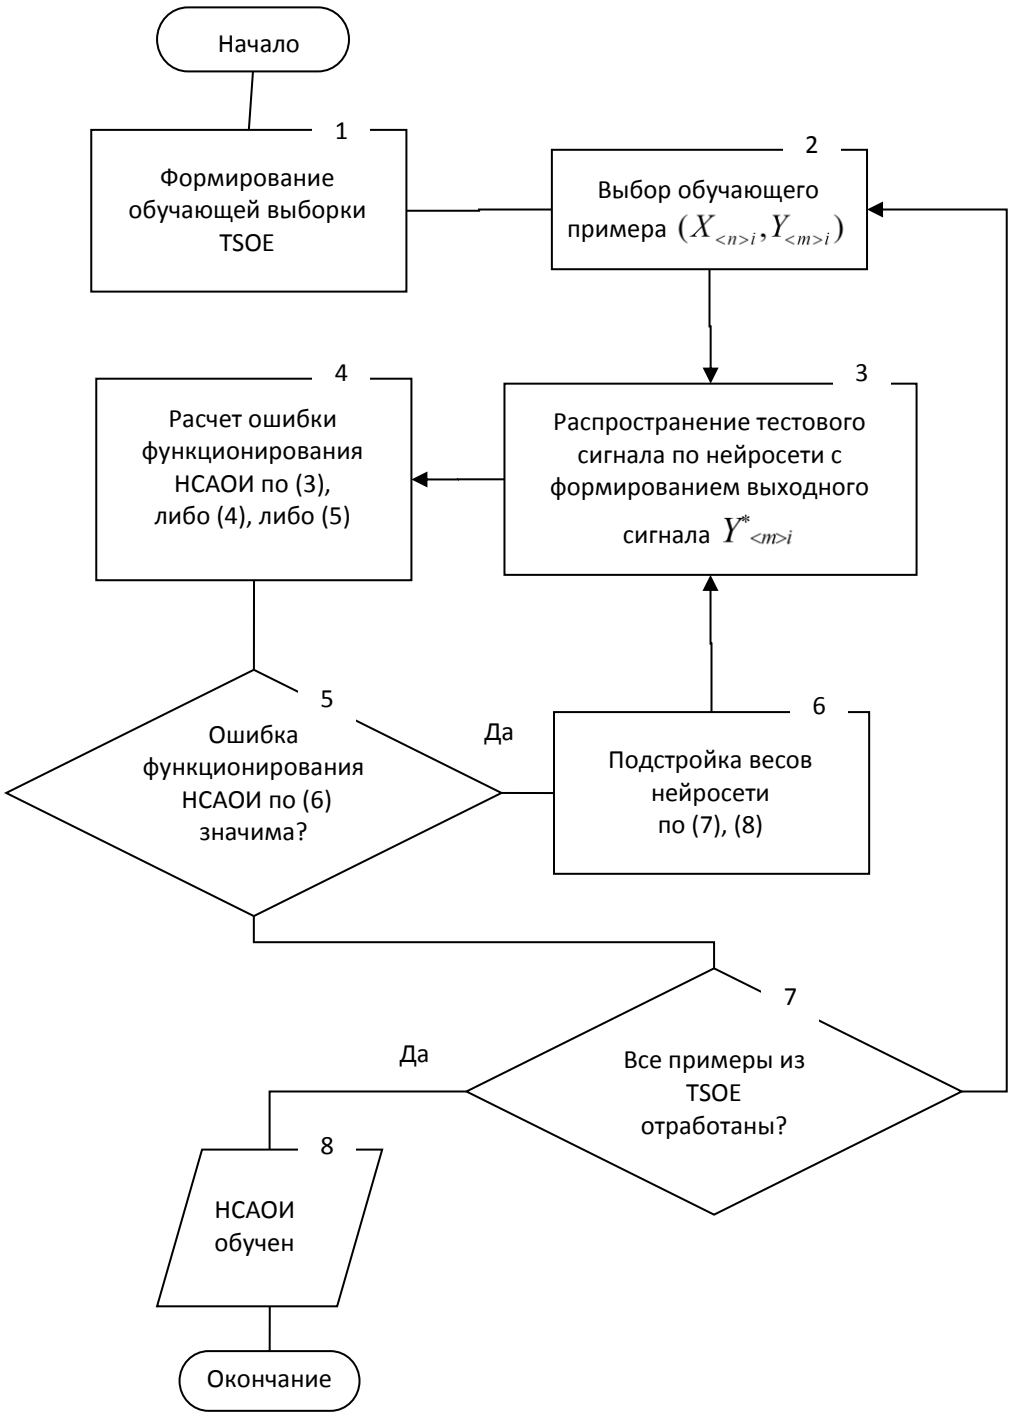

Рисунок 3. Алгоритм обучения НСАОИ

В зависимости от выбранного алгоритма подстройки весов нейросети, по мере отработки примеров обучающей выборки из TSOE НСАОИ выдает ответы с уменьшающимися ошибками. После многократной отработки примеров происходит стабилизация весов НСАОИ, при этом НСАОИ дает удовлетворительные ответы на подавляющее большинство примеров из TSOE.

От выбора конкретного алгоритма подстройки весов нейросети зависят такие показатели качества обучения нейросети, как результативность, оперативность и

ресурсоемкость обучения. Результативность обучения характеризуется степенью уверенности, что в процессе функционирования обученной нейросети показатель ошибки функционирования будет в заданном допуске. Оперативность обучения характеризуется затратами времени на обучение НСАОИ, трудоемкость обучения – затратами вычислительных ресурсов на реализацию процесса подстройки весов нейросети и затратами времени на формирование обучающей выборки TSOE.

Чайкой К.В. и Шестопаловым Р.П. в статье [25] введено понятие CRTE - *текущей остаточной ошибки обучения* нейросети (Current Residual Training Error), под которой предложено понимать «текущее значение усредненной на множестве TSOE ошибки функционирования нейросети, рассчитанное для текущего состояния весов нейросети». Кроме того, сформулирован *критерий обученности* нейронной сети, сводящийся к выполнению двух условий: «условия снижения CRTE до или ниже заданного порогового значения $\varepsilon_{Пор}$ допустимой ошибки нейросети», а также выполнения «условия адекватности обучающей выборки TSOE по объему испытаний и степени репрезентативности физической задаче, для выполнения которой обучается нейросеть».

В статье [25] также предложены следующие показатели результативности и оперативности обучения нейросети, зависимые от конкретного алгоритма подстройки весов нейросети.

1. **Показатель результативности обучения,** который представляет собой Probability of Reducing the Training Error - PRTE(A_l ; $\varepsilon_{Пор}$; t) - вероятность снижения текущей остаточной ошибки обучения нейросети за время t до или ниже $\varepsilon_{Пор}$ (заданного порогового значения допустимой ошибки функционирования НСАОИ) при использовании алгоритма подстройки весов нейросети A_l:

$$\text{PRTE}(A_l;\ \varepsilon_{Пор};\ t) = \int_0^{\varepsilon_{Пор}} \varphi_{CRTE}(\varepsilon; A_l; t)\,d\varepsilon, \qquad (9)$$

где

$$\varphi_{CRTE}(\varepsilon; A_l; t) = \frac{1}{(\sigma^{(0)}_{CRTE} - k_{l\sigma}t)\sqrt{2\pi}} \cdot e^{-\frac{[\varepsilon-(M^{(0)}_{CRTE}-k_{lM}t)]^2}{2(\sigma^{(0)}_{CRTE}-k_{l\sigma}t)^2}} \qquad (10)$$

значение плотности распределения значений CRTE в произвольном временном сечении t ; $M^{(0)}_{CRTE}$ и $\sigma^{(0)}_{CRTE}$ - начальные значения математического ожидания $M_{CRTE}(t)$ и соотвественно среднеквадратического отклонения $\sigma_{CRTE}(t)$ при t =0; $k_{lM} = \frac{\Delta^l_{M_{CRTE}}}{\Delta t}$ - коэффициент эффективности l -го алгоритма подстройки весов нейросети по снижению математического ожидания $M_{CRTE}(t)$ в процессе подстройки весов; $k_{l\sigma} = \frac{\Delta^l_{\sigma_{CRTE}}}{\Delta t}$ - коэффициент эффективности l -го алгоритма подстройки весов нейросети по снижению среднеквадратического отклонения $\sigma_{CRTE}(t)$ в процессе подстройки весов; $\Delta^l_{M_{CRTE}}$, $\Delta^l_{\sigma_{CRTE}}$ - абсолютные величины снижения $M_{CRTE}(t)$ и $\sigma_{CRTE}(t)$ за время Δt .

2. **Показатель оперативности обучения,** который представляет собой Average Time of Successful Neural Network Training - ATST(A_l ; $\varepsilon_{Пор}$) - среднее время успешного обучения нейросети при использовании алгоритма подстройки весов нейросети A_l и при заданном пороговом значении допустимой ошибки функционирования $\varepsilon_{Пор}$:

$$\text{ATST}(A_l;\ \varepsilon_{Пор}) = \int_0^{\infty} [1 - PST(A_l; \varepsilon_{Пор}; t)]dt, \qquad (11)$$

где PST((A_l ; $\varepsilon_{Пор}$; t) = PRTE((A_l ; $\varepsilon_{Пор}$; t) × PATSPP, т.е. вероятность успешного обучения нейросети (Probability of Successful Neural Network Training (PST)) за время t при применении алгоритма подстройки весов A_l ; PATSPP - вероятность адекватности обучающей выборки физической задаче (Probability of Adequacy of the Training Sample to the Physical Problem).

Помимо рассмотренных выше показателей (9) и (11) будем учитывать следующий показатель ресурсоемкости обучения.

3. **Показатель ресурсоемкости обучения** представляет собой Weighted Average Normalized Resource Costs – WNRC (A_l) - средневзвешенные нормированные затраты ресурсов (вычислительных ресурсов на

реализацию процесса подстройки весов нейросети и временных затрат на формирование обучающей выборки TSOE):

$$\text{WNRC}(A_l) = \delta_1 \times \text{NCCR}(A_l) + \delta_2 \times \text{NTC}(A_l), \quad (12)$$

где NCCR(A_l) есть Normalized Cost of Computing Resources - нормированные затраты вычислительных ресурсов на реализацию процесса подстройки весов нейросети с использованием алгоритма A_l; NTC(A_l) есть Normalized Time Costs - нормированные временные затраты на реализацию процесса подстройки весов нейросети с использованием алгоритма A_l.

Введенные показатели (9), (11) и (12) позволяют выбрать предпочтительный алгоритм подстройки весов НСАОИ.

Выбор предпочтительного алгоритма подстройки весов при обучении НСАОИ

Пусть априорно рассматриваемые потенциально возможные для применения алгоритмы подстройки весовых коэффициентов A_l составляют множество альтернатив $A_{\{L\}} = \{A_1,...,A_L\}$. Каждая альтернатива оценивается по S частным показателям $K_1,...,K_S$, а $X_{l<S>} = (x_{l1}, ..., x_{lS})$ – вектор оценок альтернативы A_l, $l \in \{1, ..., L\}$ по S частным показателям.

В нашем случае имеем:

L =22; S =3 (Probability of Reducing the Training Error; Average Time of Successful Neural Network Training; Weighted Average Normalized Resource Costs); x_{l1} = PRTE(A_l; $\varepsilon_{Пор}$; t); x_{l2} = ATST(A_l; $\varepsilon_{Пор}$); x_{l3} = WNRC (A_l).

Пусть для каждого частного показателя K_s, $s = 1,...,S$ можно указать пороговое значение Ξ_s такое, что альтернативы, оценки которых по показателю K_s ниже, чем Ξ_s, крайне нежелательны. Более предпочтительными считаются альтернативы, оценки которых по частным показателям как можно дальше отстоят от критических значений Ξ_s.

Исходя из сущности данного подхода к ранжированию альтернатив, данный метод можно назвать методом ранжирования по максимальному удалению от критических значений частных показателей или, сокращённо, методом ранжирования по максимальному удалению (РМУ). [27]

Представим математическую модель, лежащую в основе метода РМУ, в формализованном виде следующим образом.

Альтернативу A_i будем считать более предпочтительной, чем A_j, если

$\min\{x_{i1} - \Xi_1, ..., x_{iS} - \Xi_S\} > \min\{x_{j1} - \Xi_1, ..., x_{jS} - \Xi_S\}$.

Тогда выбор наилучшей альтернативы A^* осуществляется как решение задачи

$$A^* = \arg\max_{A_i \in A_{\{L\}}} \left[\min_{s \in \{1,..., S\}} \{(x_{is} - \Xi_s)\} \right]. \quad (13)$$

В работе [14] показано, что задача (13) может быть решена как задача линейного программирования

$$z_{iv} \to \max_{\substack{i \in \{1,..., L\} \\ v \in \{1,..., S\}}} \quad (14)$$

при ограничениях

$x_{iv} - \Xi_v - z_{iv} \geq 0$, $v \in \{1, ..., S\}$, $A_i \in A_{\{L\}}$.

При небольшом числе альтернатив задача может быть решена непосредственным расчётом значений $\min_l (x_{ls} - \Xi_s)$ и выбором альтернативы с максимальным значением данного критерия. Обобщим правило (13) на случай, когда частные показатели K_s, $s \in \{1,...,S\}$ различны по важности. В данной постановке это означает, что удаление оценок альтернатив от критических значений по одним частным показателям важнее, чем по другим. Например, важнее обеспечить более высокие значения результативности обучения НСАОИ по сравнению с показателями оперативности или ресурсоемкости обучения. Или в большей степени можно уступить по показателям результативности обучения, зато - увеличить показатели оперативности обучения и снизить затраты на обучение. [28]

Допустим, что определены значения весовых коэффициентов $\alpha_1,...,\alpha_S$, характеризующих важность удаления оценки альтернативы по каждому из частных показателей. Тогда задача (13) может быть записана в виде

$$A^* = \arg\max_{A_l \in A_{\{L\}}} \left[\min_{s \in \{1,..., S\}} \{\alpha_s (x_{ls} - L_s)\} \right]. \quad (15)$$

Соответственно, задача линейного программирования (14) принимает вид

$$\sum_{s=1}^{S} \alpha_s z_{ls} \to \max_{l \in \{1,..., L\}} \quad (16)$$

при ограничениях $x_{ls} - \Xi_s - z_{ls} \geq 0$, $s \in \{1,...,S\}$, $A_l \in A_{\{L\}}$.

Или, введя функцию $\Psi(A_l) = \sum_{s=1}^{S} \alpha_s z_{ls}$, можно записать:

$$A^* = \arg\max_{A_l \in A_{\{L\}}} \Phi(A_l) \qquad (17)$$

$x_{ls} - \Xi_s - z_{ls} \geq 0$, $s \in \{1,...,S\}$.

В случае, если заранее можно строго проранжировать частные показатели по важности, то можно воспользоваться следующим способом оценивания значений коэффициентов α_s. [27]

Пусть частные показатели K_s, $s \in \{1, ..., S\}$ представлены в проранжированном виде множеством $K^r_{\{S\}} = \{K^r_1,...,K^r_S\}$. Тогда можно сформировать соответствующее упорядоченное множество из коэффициентов важности $\alpha^r_{\{S\}} = \{\alpha_1, ..., \alpha_\Sigma\}$. Допустим, что определены значения коэффициентов сравнительной предпочтительности $\rho_{\iota\varphi}$ между соседними коэффициентами важности α_ι и α_φ в упорядоченном множестве $\alpha_{\{S\}}$, такие что $\rho_{ij} = \frac{\alpha_i}{\alpha_j}$, $j = i+1$; $i,j \in (1, ..., S\}$.

С учётом этого можно составить следующую систему из (S+1) уравнений с S неизвестными α_i:

$$\begin{cases} \alpha_1 = \rho_{12}\alpha_2, \\ \alpha_2 = \rho_{23}\alpha_3, \\ \quad\vdots \\ \alpha_{S-1} = \rho_{(S-1)S}\alpha_S, \\ \sum_{s=1}^{S} \alpha_s = 1. \end{cases} \qquad (18)$$

Решая (18), имеем:

$$\alpha_S = \left(1 + \rho_{(S-1)S} + ... + \prod_{i=2}^{S-1} \rho_{i(i+1)} + \prod_{i=1}^{S-1} \rho_{i(i+1)}\right)^{-1} = M_S,$$

$$\alpha_{S-1} = \rho_{(S-1)S} M_S,$$

$$\alpha_{S-2} = \rho_{(S-2)(S-1)}\rho_{(S-1)S} M_S,$$

$$\vdots$$

$$\alpha_j = \prod_{i=j+1}^{S} \rho_{(i-1)i} M_S,$$

$$\vdots$$

$$\alpha_1 = \prod_{i=2}^{S} \rho_{(i-1)i} M_S. \qquad (19)$$

Если при строгом ранжировании частных показателей K_s по важности возникают затруднения, то можно воспользоваться методом, описанным в работе [14]. При этом предполагаются известными значения, принимаемые каждой из L альтернатив по всем частным показателям K_s, $s = \overline{1,S}$, т.е. векторы $X_l = (x_{l1}, ..., x_{lS})$, $l \in \{1, ..., L\}$. Кроме того, есть информация о парных сравнениях альтернатив, т.е. для каждой пары альтернатив α_i, α_j известна более предпочтительная. [27]

Тогда, задача отыскания весовых коэффициентов $\alpha_v \geq 0$ формулируется как

$$\sum_{ij \in I} Y_{ij} \to \min \qquad (20)$$

при ограничениях

$$\sum_{s=1}^{S} (x_{is} - x_{js})\alpha_s + Y_{ij} \geq 0,$$

$$\sum_{s=1}^{S} \alpha_s = 1,\ \alpha_s \geq 0,\ Y_{ij} \geq 0,$$

где I есть множество всех пар индексов i, j, для которых $a_i \succ a_j$.

Данная задача относится к классу задач линейного программирования и при сравнительно небольшом числе весовых коэффициентов может эффективно решаться с помощью ЭВМ. [28]

ЗАКЛЮЧЕНИЕ

Таким образом, в данной статье представлены результаты, позволяющие обосновать выбор предпочтительного алгоритма подстройки весовых коэффициентов в нейросетевых алгоритмах обработки информации на стадии их обучения. Предложено оценивать существующие алгоритмы подстройки весов по трем показателям: показателю

результативности обучения в виде вероятности снижения текущей остаточной ошибки обучения нейросети за время t до или ниже заданного порогового значения ошибки функционирования нейросети; показателя оперативности обучения в виде среднего времени успешного обучения нейросети и показателя ресурсоемкости процесса обучения в виде средневзвешенных нормированных затрат ресурсов.

В основу решения задачи ранжирования алгоритмов подстройки весов нейросети предложено положить способ ранжирования по максимальному удалению от наиболее неприемлемых пороговых значений частных показателей с учетом их важности. Показано, что в рамках описанной постановки задача выбора предпочтительного алгоритма подстройки весовых коэффициентов в нейросетевых алгоритмах обработки информации на стадии их обучения может быть отнесена к классу задач линейного программирования. iea

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ И ЛИТЕРАТУРЫ:

1. Аггарвал Ч. Нейронные сети и глубокое обучение: учебный курс.: Пер с англ. - СПб.: ООО «Диалектика», 2020. - 752 с.
2. Андреев С. Российские нейросети помогут военным и найдут террористов в соцсетях // Life.ru [Электронный ресурс] URL: https://life.ru/p/1169069
3. Будума Н., Локашо Н. Основы глубокого обучения. Создание алгоритмов для искусственного интеллекта следующего поколения. Пер с англ. - М.: Манн, Иванов и Фербер, 2020. - 304 с.
4. Васенков Д.В. Методы обучения искусственных нейронных сетей // Компьютерные инструменты в образовании. № 1, 2007. - С. 20-29.
5. Вечеркин В.Б., Лоскутов А.И., Шестопалова О.Л. Автоматизация контроля состояния сложных технических систем на основе использования конечно-автоматной модели и нейросетевых структур // Информационно-управляющие системы, №2 (57), 2012. - С. 74 - 81.
6. Галушкин А.И. Применения нейрокомпьютеров в финансовой деятельности. – Новосибирск: Наука, 2002. – 215 с.
7. Головачев С.С. Использование искусственных нейронных сетей для прогнозирования американского фондового рынка в период кризиса // Управление экономическими системами: электронный научный журнал, № 11(47), 2012. – 19 с. [Электронный ресурс] URL: https://cyberleninka.ru/
8. Дроны и искусственный интеллект (ИИ) // «Российские беспилотники (Russian Drone)» [Электронный ресурс] URL: https://russiandrone.ru/
9. Ефимов Д.В. Нейросетевые системы управления. - М.: Высшая школа, 2002. – 184 с.
10. Котов М. Российскими боевыми беспилотниками будет управлять нейросеть // «Life.ru» [Электронный ресурс] URL: https://life.ru/p/
11. Кореванов С.В., Казин В.В. Искусственные нейронные сети в задачах навигации беспилотных летательных аппаратов // Научный вестник МГТУ ГА, № 201, 2014. – 4 с.
12. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика. М.: Горячая линия-Телеком, 2002. – 380 с.
13. Курников Д.С., Петров С.А. Использование нейронных сетей в экономике // Juvenis scientia, № 6, 2017. – С.10-12.
14. Литвак Б.Г. Экспертная информация: Методы получения и анализа. – М.: Радио и связь, 1982. – 184 с.
15. Лоскутов А.И., Патраков С.С., Шестопалова О.Л. Интеллектуальная информационно-диагностическая система оценивания технического состояния бортовой аппаратуры космических аппаратов при подготовке их к запуску // Информационно-управляющие системы, №2 (69), 2014. - С. 18-24.
16. Ломакин М.И., Миронов А.Н., Шестопалова О.Л. Многомодельная обработка измерительной информации в интеллектуальных системах прогнозирования надежности космических средств // Измерительная техника. – 2014. – № 1, 13 с.
17. Назаренко Ю.Л. Использование нейросетей в рамках решения проблем кибербезопасности // European science Электронный журнал. 2017. [Электронный ресурс] – URL: https://cyberleninka.ru/
18. Нейросеть научили диагностировать коронавирусную инфекцию по рентгеновским снимкам легких // ТАСС НАУКА: Электронное общественно-политическое средство массовой информации. [Электронный ресурс] – URL: https://nauka.tass.ru/nauka/
19. Птичкин С. Робот сообразит за троих. Искусственный интеллект все чаще помогает военным // Российская газета – Спецвыпуск № 187 (8241). [Электронный ресурс] URL: https://rg.ru/2020/08/23/
20. Рахметуллаев М.А., Алтынбекова Л.Б. Искусственные нейронные сети в военной сфере // Молодой ученый. - 2020. - № 19 (309).

- С. 48-53. [Электронный ресурс] URL: https://moluch.ru/archive/309/.
21. Салькова А. Нейросеть научилась определять коронавирус по кашлю // Газета.Ru: Электронное общественно-политическое средство массовой информации. [Электронный ресурс] URL: https://www.gazeta.ru/science/
22. Тищенко М. Нейросети против вбросов: ЦИКу предложили использовать искусственный интеллект на выборах // RT на русском: Электронное общественно-политическое средство массовой информации. [Электронный ресурс] URL: https://russian.rt.com/russia/
23. Ученые разработали нейросеть, предсказывающую тяжесть заболевания пациента с COVID-19 // BFM.RU: Электронное общественно-политическое средство массовой информации. [Электронный ресурс] URL: https://www.bfm.ru/news/
24. Черкашин Д. Российские спецслужбы будут использовать нейросети для распознавания террористов // iGuides.ru: Электронное средство информации о науке и информационных технологиях сервисах и приложениях [Электронный ресурс] – URL: https://www.iguides.ru/main/
25. Чайка К.В., Шестопалов Р.П. Оценивание качества обучения нейросетевых алгоритмов обработки информации // Информационно-экономические аспекты стандартизации и технического регулирования № 2 (60), 2021. – 17-26.
26. Ясницкий Л.Н. Введение в искусственный интеллект. - М.: Издательский центр «Академия», 2005. – 176 с.
27. Гапонюк, Петр Никитович. Институциональная методология управления модернизацией современной системы образования: диссертация ... доктора педагогических наук: 13.00.01. - Москва, 2012. - 492 с.
28. Брум, Александр Наумович. Управление технико-экономическими показателями кабельных сетей при разработке инвестиционных проектов: диссертация ... кандидата технических наук: 05.13.10. - Москва, 2000. - 165 с.

ABOUT CHOOSING THE PREFERRED ADJUSTMENT ALGORITHM WEIGHTS FOR TRAINING NEURAL NETWORK ALGORITHMS OF INFORMATION PROCESSING

Shestopalov Roman Pavlovich, student of the Faculty of Computer Technologies and Informatics of the St. Petersburg State Budgetary Electrotechnical University (LETI), the St. Petersburg

The article presents the results that allow us to justify the choice of the preferred algorithm for adjusting the weight coefficients of artificial neural networks at the stage of their training. Asked to evaluate existing algorithms adjust in achieved in the process of learning the values of probability of successful training of the neural network for a given time, the average time of successful training of the neural network and the intensity of the algorithms. The ranking of algorithms for adjusting the weights of the neural network is based on the ranking by maximum removal. The materials of the article can be useful for specialists who develop neural networks and improve the process of their training.

Keywords: neural network, algorithm for adjusting the weights of the neural network,, probability of successful training of the neural network, average time of successful training of the neural network

REFERENCES:

1. Aggarval CH. Neyronnyye seti i glubokoye obucheniye: uchebnyy kurs. [*Neural networks and deep learning: a training course*]: Per s angl. - SPb.: OOO «Dialektika», 2020. - 752 p.
2. Andreyev S. Rossiyskiye neyroseti pomogut voyennym i naydut terroristov v sotssetyakh [*Russian neural networks will help the military and find terrorists in social networks*] // Life.ru [Electronic resource] URL: https://life.ru/p/1169069
3. Buduma N., Lokasho N. Osnovy glubokogo obucheniya. Sozdaniye algoritmov dlya iskusstvennogo intellekta sleduyushchego pokoleniya. [*Fundamentals of deep learning. Creation of algorithms for next generation artificial intelligence*] Per s angl. - M.: Mann, Ivanov i Ferber, 2020. - 304 p.

4. Vasenkov D.V. Metody obucheniya iskusstvennykh neyronnykh setey [*Teaching Methods of Artificial Neural Networks*] // Komp'yuternyye instrumenty v obrazovanii» [*Journal Computer Tools in Education*]. № 1, 2007. - pp. 20-29.
5. Vecherkin V.B., Loskutov A.I., Shestopalova O.L. Avtomatizatsiya kontrolya sostoyaniya slozhnykh tekhnicheskikh sistem na osnove ispol'zovaniya konechno-avtomatnoy modeli i neyrosetevykh struktur [*Automation of monitoring the state of complex technical systems based on the use of a finite-automaton model and neural network structures*] // Informatsionno-upravlyayushchiye sistemy [*Information and control systems*], №2 (57), 2012. - C. 74 -81.
6. Galushkin A.I. Primeneniya neyrokomp'yuterov v finansovoy deyatel'nosti [*The use of neurocomputers in financial activities*]. – Novosibirsk: Nauka, 2002. – 215 p.
7. Golovachev S.S. Ispol'zovaniye iskusstvennykh neyronnykh setey dlya prognozirovaniya amerikanskogo fondovogo rynka v period krizisa [*The use of artificial neural networks for forecasting the American stock market during the crisis*] // Upravleniye ekonomicheskimi sistemami: elektronnyy nauchnyy zhurnal, [*Management of economic systems: electronic scientific journal*] № 11(47), 2012. – 19 p. [Electronic resource] URL: https://cyberleninka.ru/
8. Drony i iskusstvennyy intellekt (II) [*Drones and Artificial Intelligence (AI)*] // «Rossiyskiye bespilotniki (Russian Drone)» [*Russian Drones (Russian Drone)*] [Electronic resource] URL: https://russiandrone.ru/
9. Yefimov D.V. Neyrosetevyye sistemy upravleniya [*Neural network control systems*]. - M.: Vysshaya shkola, 2002. – 184 p.
10. Kotov M. Rossiyskimi boyevymi bespilotnikami budet upravlyat' neyroset' [*Russian combat drones will be controlled by a neural network*] // «Life.ru» [Electronic resource] URL: https://life.ru/p/
11. Korevanov S.V., Kazin V.V. Iskusstvennyye neyronnyye seti v zadachakh navigatsii bespilotnykh letatel'nykh apparatov [*Artificial neural networks in navigation problems for unmanned aerial vehicles*]// Nauchnyy vestnik MGTU GA, № 201, 2014. – 4 s.
12. Kruglov V.V., Borisov V.V. Iskusstvennyye neyronnyye seti. Teoriya i praktika. [*Artificial neural networks. Theory and practice*] – M.: Goryachaya liniya-Telekom, 2002. – 380 p.
13. Kurnikov D.S., Petrov S.A. Ispol'zovaniye neyronnykh setey v ekonomike [*The use of neural networks in economics*] // Juvenis Scientia [*Juvenis scientia*], № 6, 2017. – pp.10-12.
14. Litvak B.G. Ekspertnaya informatsiya: Metody polucheniya i analiza [*Expert information: Methods of obtaining and analysis*]. – M.: Radio i svyaz', 1982. – 184 p.
15. Loskutov A.I., Patrakov S.S., Shestopalova O.L. Intellektual'naya informatsionno-diagnosticheskaya sistema otsenivaniya tekhnicheskogo sostoyaniya bortovoy apparatury kosmicheskikh apparatov pri podgotovke ikh k zapusku [*Intelligent information and diagnostic system for assessing the technical condition of spacecraft onboard equipment in preparation for launch*] // Informatsionno-upravlyayushchiye sistemy [*Information and control systems*], №2 (69), 2014. - C. 18-24.
16. Lomakin M.I., Mironov A.N., Shestopalova O.L. Mnogomodel'naya obrabotka izmeritel'noy informatsii v intellektual'nykh sistemakh prognozirovaniya nadezhnosti kosmicheskikh sredstv [*Multi-model processing of measuring information in intelligent systems for predicting the reliability of space vehicles*] // Izmeritel'naya tekhnika [*Izmeritelnaya tekhnika*]. – 2014. – № 1, 13 s.
17. Nazarenko YU.L. Ispol'zovaniye neyrosetey v ramkakh resheniya problem kiberbezopasnosti [*The use of neural networks in the framework of solving cybersecurity problems*] // European science. 2017. [Electronic resource] – URL: https://cyberleninka.ru/
18. Neyroset' nauchili diagnostirovat' koronavirusnuyu infektsiyu po rentgenovskim snimkam legkikh [*The neural network was taught to diagnose coronavirus infection by X-rays of the lungs*] // TASS NAUKA. [Electronic resource] – URL: https://nauka.tass.ru/nauka/
19. Ptichkin S. Robot soobrazit za troikh. Iskusstvennyy intellekt vse chashche pomogayet voyennym [*The robot will figure out for three. Artificial intelligence increasingly helps the military*] // Rossiyskaya gazeta – Spetsvypusk № 187 (8241). [Electronic resource] URL: https://rg.ru/2020/08/23/
20. Rakhmetullayev M.A., Altynbekova L.B. Iskusstvennyye neyronnyye seti v voyennoy sfere [*Artificial neural networks in the military sphere*] // Molodoy uchenyy [*Young scientist*]. - 2020. - № 19 (309). - S. 48-53. [Electronic resource] URL: https://moluch.ru/archive/309/.
21. Sal'kova A. Neyroset' nauchilas' opredelyat' koronavirus po kashlyu [*Neural network learned to detect coronavirus by coughing*] // Gazeta.Ru. [Electronic resource] URL: https://www.gazeta.ru/science/
22. Tishchenko M. Neyroseti protiv vbrosov: TSIKu predlozhili ispol'zovat' iskusstvennyy intellekt na vyborakh [*Neural networks against stuffing: the CEC was offered to use artificial intelligence in elections*] // RT na russkom. [Electronic resource] URL: https://russian.rt.com/russia/

23. Uchenyye razrabotali neyroset', predskazyvayushchuyu tyazhest' zabolevaniya patsiyenta s COVID-19 [*Scientists have developed a neural network that predicts the severity of the disease in a patient with COVID-19*] // BFM.RU. [Electronic resource] URL: https://www.bfm.ru/news/

24. Cherkashin D. Rossiyskiye spetssluzhby budut ispol'zovat' neyroseti dlya raspoznavaniya terroristov [*Russian special services will use neural networks to recognize terrorists*] // iGuides.ru [Electronic resource] – URL: https://www.iguides.ru/main/

25. Chayka K.V., Shestopalov R.P. Otsenivaniye kachestva obucheniya neyrosetevykh algoritmov obrabotki informatsii [*Assessment of the quality of training neural network algorithms for information processing*] // Informatsionno-ekonomicheskiye aspekty standartizatsii i tekhnicheskogo regulirovaniya [*Information and economic aspects of standardization and technical regulation*] № 2 (60), 2021. - pp. 17-26.

26. Yasnitskiy L.N. Vvedeniye v iskusstvennyy intellect [*Introduction to Artificial Intelligence*]. - M.: Izdatel'skiy tsentr «Akademiya», 2005. – 176 p.

27. Gaponyuk, Petr Nikitovich. Institutsional'naya metodologiya upravleniya modernizatsiyey sovremennoy sistemy obrazovaniya: dissertatsiya ... doktora pedagogicheskikh nauk [*Institutional methodology of modernization management of the modern education system: dissertation ... Doctor of Pedagogical Sciences*]: 13.00.01. - Moskva, 2012. - 492 p.

28. Brum, Aleksandr Naumovich. Upravleniye tekhniko-ekonomicheskimi pokazatelyami kabel'nykh setey pri razrabotke investitsionnykh proyektov: dissertatsiya ... kandidata tekhnicheskikh nauk [*Management of technical and economic indicators of cable networks in the development of investment projects: dissertation ... of a candidate technically Sciences*]: 05.13.10. - Moskva, 2000. - 165 p.