При использовании материалов статьи необходимо использовать данную ссылку:
Чайка К.В., Шестопалов Р.П. Оценивание качества обучения нейросетевых алгоритмов обработки информации // Информационно-экономические аспекты стандартизации и технического регулирования. 2021. № 2 (60). С. 17-26

УДК 004.023

ОЦЕНИВАНИЕ КАЧЕСТВА ОБУЧЕНИЯ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ ОБРАБОТКИ ИНФОРМАЦИИ

Чайка К.В., Шестопалов Р.П.

В статье представлены результаты, позволяющие оценить качество обучения нейросетевых алгоритмов обработки информации в различных технических приложениях. Изложены краткие сведения о понятиях искусственного нейрона и искусственной нейронной сети, приведена математическая модель преобразования сигналов в искусственном нейроне. Описан процесс обучения нейронной сети в соответствии с приведенной схемой процесса обучения. Перечислены основные существующие алгоритмы подстройки весов нейросети, основанные на различных методах поиска минимума функции многих переменных. Предложен критерий обученности нейросети, предполагающий выполнение двух условий: во-первых, адекватности обучающей выборки прикладной задаче по полноте и репрезентативности обучающих примеров, во-вторых, достижения в процессе обучения устойчивого снижения ошибки функционирования нейросети до заданного порогового значения. Введены вероятностные показатели качества процесса обучения нейросетевых алгоритмов обработки информации в виде вероятности успешного обучения нейросети за заданное время и среднего времени успешного обучения нейросети. Приведены аналитические выражения для их количественной оценки.

Ключевые слова: нейронная сеть, алгоритм обработки информации, показатель качества процесса обучения, вероятность обучения нейросети, среднее время обучения нейросети

ВВЕДЕНИЕ (краткие сведения о понятиях искусственного нейрона и искусственной нейронной сети)

В основу нейросетевых алгоритмов обработки информации положены упрощенные закономерности функционирования мозга живых существ, состоящего из огромного числа (порядка 109) специфических клеток - биологических нейронов, каждый из которых связан с соседними нейронами несколькими тысячами связей (дендритов и аксонов). Нейроны распознают электрохимические сигналы соседей посредством специальных отростков – дендритов, а передают импульсы другим нейронам с помощью аксонов (см. рисунок 1).

Аксоны соединяются с дендритами другой нервной клетки в специфических точках, которые называют синапсами. В синапсе вырабатывается биологически активное химическое вещество (нейромедиатор), способное изменять силу нервного импульса, проходящего через синапс. Возможность мозга регулировать количество нейромедиатора в синапсах нейронов лежит в основе приспособления мозга к адаптивному поведению в изменяющейся окружающей организм среде.

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

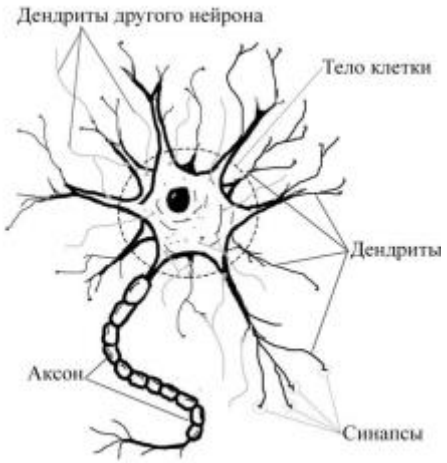

Рисунок 1. Схематическое изображение биологического нейрона

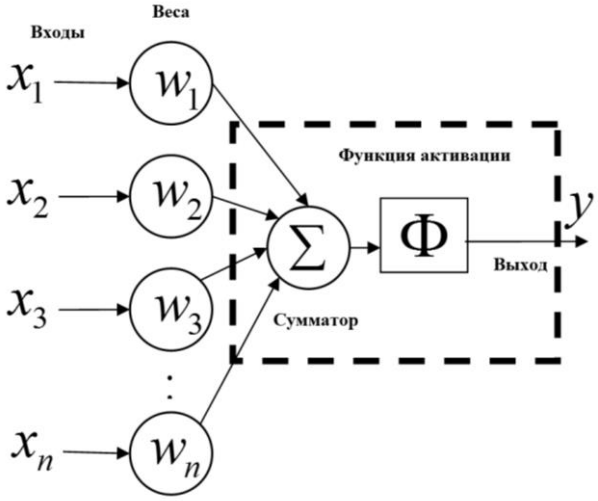

Рисунок 2. Модель искусственного нейрона

Такого рода биологический адаптационный механизм реализован в модели искусственного нейрона (см. рисунок 2). Способность к изменению силы сигнала, проходящего через синапс биологического нейрона, в модели искусственного нейрона достигается введением весов, которые усиливают полезные по влиянию на результат функционирования нейросети сигналы на фоне остальных, которые, соответственно, ослабляются. Так как в мозге живых существ импульсы, поступившие одновременно по нескольким дендритам, суммируются, то в модель искусственного нейрона введен сумматор. Способность биологического нейрона реагировать на поступившие сигналы возбуждением аксона в модели искусственного нейрона реализуется введением, так называемой, нелинейной функции активации, которая может иметь различный вид, отображающий закон формирования выходного сигнала.

Математически преобразование сигналов в искусственном нейроне можно отобразить следующим выражением [1 - 4]:

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

где y - выходной импульс искусственного нейрона; ω_i, $i = 1,...,n$ - веса синапсов дендритов искусственного нейрона; θ - пороговый уровень реагирования нейрона на суммарный входной сигнал $X = \sum_{i=1}^{n} \omega_i x_i$; $\Phi(X - \theta)$ - функция активации искусственного нейрона (передаточная функция нелинейного преобразования взвешенного входного сигнала с учетом пороговой чувствительности нейрона).

По разному комбинируя искусственные нейроны в так называемые слои, можно создавать различные нейронные структуры от простейшего однослойного перцептрона (рисунок 3) до многослойных нейронных сетей (рисунок 4) [5, 6].

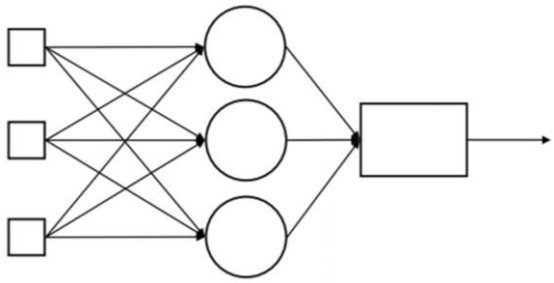

Рисунок 3. Схема однослойного персептрона

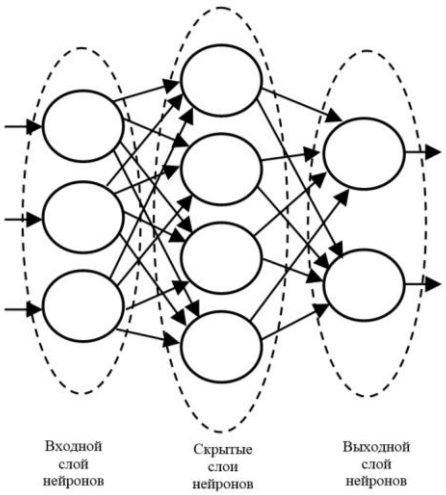

Рисунок 4. Схема многослойной нейросети

Описание процесса обучения нейронной сети

Принцип обучения искусственной нейронной сети заключается в таком подборе количественных значений весов заданной архитектуры нейронной сети, при котором достигалось бы приемлемое отклонение результатов выполнения задачи, поставленной перед сетью, относительно идеального результата ее функционирования [7-9].

Для настройки весов (обучения нейронной сети) обычно задается обучающая выборка (набор обучающих примеров), при этом каждый пример из выборки содержит набор входных данных для искусственной нейросети, а также заранее определенный результат функционирования сети при данном наборе входных данных [1, 2, 10 - 12]. Информацией для подстройки весов искусственной нейронной сети служит величина расхождения фактического результата функционирования сети с идеальным, то есть величина текущей ошибки обучения. Схема процесса обучения нейросети показана на рисунке 5.

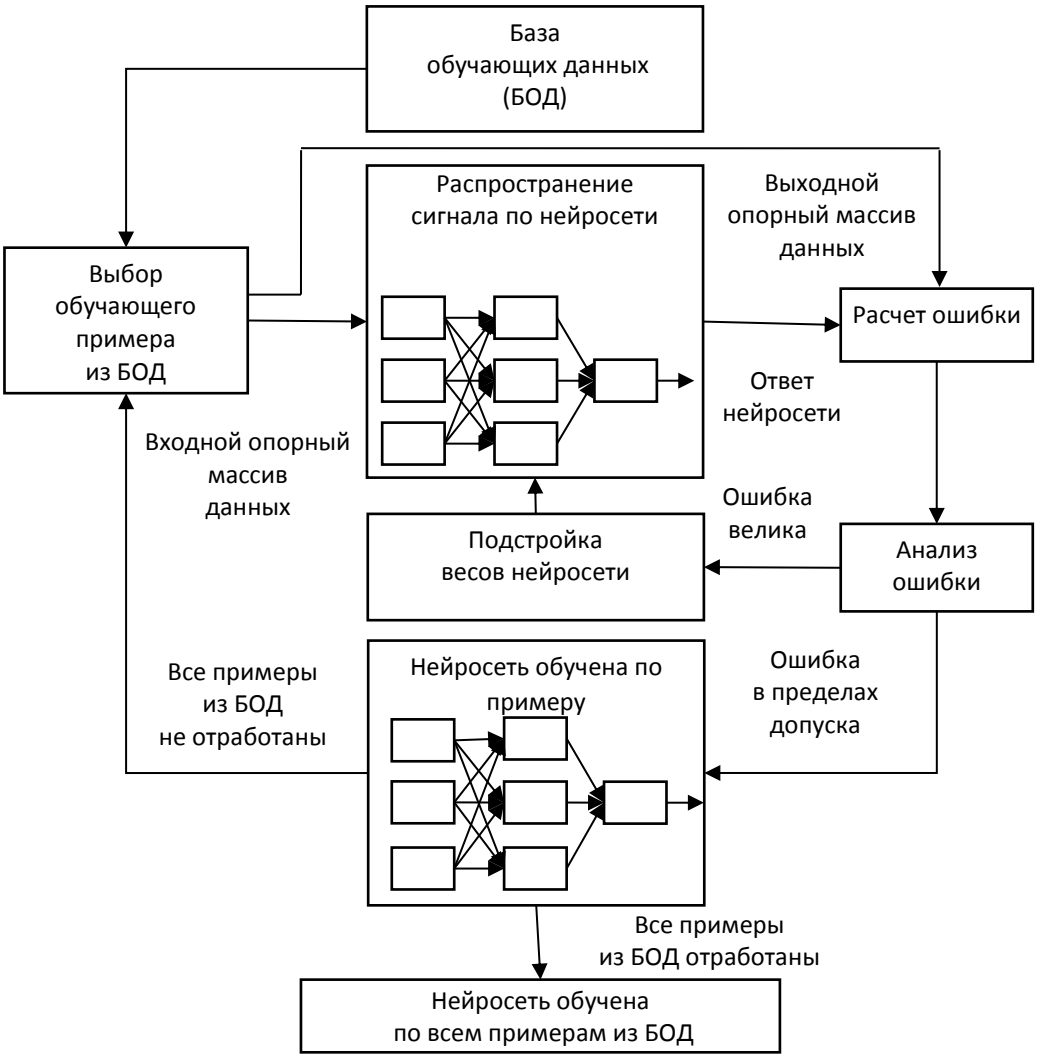

Рисунок 5. Схема процесса обучения нейронной сети

Сформированный набор обучающих примеров или, иначе, обучающая выборка («Training Sample Of Examples» (TSOE)) хранится в базе обучающих данных (БОД). TSOE представляет собой множество пар из входных и выходных векторов опорных (т.е. верифицированных) сигналов вида

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

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

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

N - мощность множества TSOE.

Параметрами обучающей выборки являются ее объем, измеряемый количеством N обучающих примеров, и степень репрезентативности R , $R \in [0,1]$, которая показывает степень учета в обучающей выборке всех существенных особенностей генеральной совокупности наборов сочетаний входов и выходов реального объекта.

Процесс обучения начинается, во первых, с произвольного назначения начальных значений весов нейросети

$$\Omega_{<K>0} =< \omega_{10}, \omega_{20},..., \omega_{K0}, >, \quad (3)$$

а во-вторых, с произвольного выбора обучающего примера из TSOE, например,

$$(X_{<n>i}, Y_{<m>i}) = (< x_{1i}, x_{2i},..., x_{ni} >, < y_{1i}, y_{2i},..., y_{mi} >). \quad (4)$$

Далее входной опорный массив данных $X_{<n>i} =< x_{1i}, x_{2i},..., x_{ni} >$ поступает на вход обучаемой нейросети, вызывая распространение сигнала по нейросети. Одновременно выходной опорный массив данных $Y_{<m>i} =< y_{1i}, y_{2i},..., y_{mi} >$ поступает на опорный вход блока расчета ошибки, где сравнивается с ответом нейросети $Y^*_{<m>i} =< y^*_{1i}, y^*_{2i},..., y^*_{mi} >$.

В блоке расчета ошибки вычисляется количественная оценка степени расхождения фактического выхода нейросети $Y^*_{<m>i}$ с опорным значением $Y_{<m>i}$.

Если имеем один выход нейросети, то ошибка ε_i рассчитывается по простому правилу

$$\varepsilon_i = \left| y_i - y^*_i \right|. \quad (5)$$

При $m > 1$ на выходе блока расчета ошибки возникает вектор ошибок

$$\mathrm{E}_{<m>i} =< \varepsilon_{1i}, \varepsilon_{2i},..., \varepsilon_{mi} >, \quad (6)$$

который может быть преобразован к обобщенной усредненной, либо обобщенной взвешенной ошибке путем несложных преобразований вида (7) и (8) соответственно

$$\overline{E}^{(1)}_i = \frac{\sum_{j=1}^{m_i} \varepsilon_{ji}}{m} \quad (7)$$

или $\overline{E}^{(2)}_i = \alpha_1 \varepsilon_{1i} + \alpha_2 \varepsilon_{12} + ... + \alpha_m \varepsilon_{mi} = \sum_{j=1}^{m} \alpha_j \varepsilon_{ji}$, $\sum_{j=1}^{m} \alpha_j = 1$. (8)

На следующем этапе процесса обучения нейросети проводится анализ значимости величины ошибки путем проверки выполнения неравенств

$$\varepsilon_i < \varepsilon_{Пор}, \text{ либо } \overline{E}^{(1)}_i < \varepsilon_{Пор}, \text{ либо } \overline{E}^{(2)}_i < \varepsilon_{Пор}, \quad (9)$$

где $\varepsilon_{Пор}$ - заданное пороговое значение допустимой ошибки нейросети.

Если неравенство вида (9) не выполняется, то делается вывод о том, что ошибка велика, и необходима подстройка весов нейросети. В противном случае принимается решение, что по рассматриваемому примеру нейросеть обучена, и далее переходят к следующему примеру из обучающей выборки TSOE.

Когда отработаны все примеры из TSOE, т.е. условия (9) выполнены для всех обучающих примеров, то считается, что нейросеть обучена полностью.

Подстройка весов нейросети выполняется на основе анализа степени вклада каждого веса нейросети в итоговую ошибку на выходе нейросети. Для этого вычисляются частные производные вида

$$\Delta_{w_k i} = \frac{\partial \varepsilon_i}{\partial \omega_k}, \text{ либо } \Delta_{w_k i} = \frac{\partial \overline{E}^{(1)}_i}{\partial \omega_k}, \text{ либо } \Delta_{w_k i} = \frac{\partial \overline{E}^{(2)}_i}{\partial \omega_k} \quad (10)$$

Далее в первую очередь уменьшаются значения тех весов, вклад которых в ошибку нейросети наиболее велик. Правило подстройки весов нейросети в общем виде для первой итерации подстройки и i -го обучающего примера можно записать в следующем виде

$$\begin{aligned} \omega^{(1)}_{1i} &= \omega^{(0)}_1 - h^{(1)} \times \Delta_{w_1 i} \\ \omega^{(1)}_{2i} &= \omega^{(0)}_2 - h^{(1)} \times \Delta_{w_2 i} \\ &... \\ \omega^{(1)}_{Ki} &= \omega^{(0)}_K - h^{(1)} \times \Delta_{w_{K1} i} \end{aligned}, \quad (11)$$

где < $\omega_1^{(0)}$, $\omega_2^{(0)}$,..., $\omega_K^{(0)}$ > - вектор начальных значений весов обучаемой нейросети;

h - величина шага подстройки весовых коэффициентов нейросети.

Процедуры (10) и (11) повторяются до тех пор, пока не будут выполнены условия (9).

В настоящее время разработано достаточно большое количество алгоритмов подстройки весов нейросети, основанных на различных методах поиска минимума функции многих переменных (например, методе градиентного спуска, методе Марквардта, методе случайного поиска и других).

Например, в литературе [1, 2, 10 – 15] приводятся следующие названия подобных алгоритмов: «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».

В зависимости от выбранного алгоритма обучения, функционирующего по определенному закону, нейросеть выдает ответы с уменьшающимися ошибками. После многократной отработки примеров происходит стабилизация весов сети, при этом нейронная сеть дает удовлетворительные ответы на подавляющее большинство примеров из TSOE.

Введем понятие *текущей остаточной ошибки обучения* нейросети.

Под текущей остаточной ошибкой обучения нейросети будем понимать текущее значение усредненной на множестве TSOE ошибки функционирования нейросети, рассчитанное для текущего состояния весов нейросети.

Оценивание качества обучения нейросети

Теперь можно, опираясь на схему процесса обучения нейросети (см. рисунок 5), сформулировать следующий *критерий обученности* нейронной сети.

Нейросеть обучена, если выполнены два условия:

1. Значение текущей остаточной ошибки обучения нейросети снизилось до заданного порогового значения допустимой ошибки нейросети или ниже.

2. Обучающая выборка TSOE адекватна по объему испытаний и степени репрезентативности физической задаче, для выполнения которой обучается нейросеть.

Далее введем показатели качества обучения нейросети, основываясь на вероятностной природе процесса обучения. Для этого зафиксируем некоторый временной интервал обучения $(0,t]$. На основании сформулированного выше критерия обученности нейронной сети можно констатировать, что вероятность успешного обучения нейросети за время t есть произведение вероятности двух событий: события А, состоящего в том, что за время t значение текущей остаточной ошибки обучения нейросети снизилось до или ниже заданного порогового значения допустимой ошибки нейросети, и события В, состоящего в том, что обучающая выборка TSOE адекватна по объему испытаний и степени репрезентативности физической задаче, для выполнения которой обучается нейросеть.

Обозначим вероятность успешного обучения нейросети (Probability of Successful Neural Network Training (PST)) за время t как PST (t); вероятность снижения ошибки обучения (Probability of Reducing the Training Error (PRTE) за время t как PRTE (t); вероятность адекватности обучающей выборки физической задаче (Probability of Adequacy of the Training Sample to the Physical Problem) как PATSPP.

Теперь можно записать выражение для оценивания вероятности успешного обучения нейросети за время t :

$$PST(t)=PRTE(t)\times PATSPP \qquad (12)$$

Обозначим среднее время успешного обучения нейросети (Average Time of Successful Neural Network Training) как ATST. Тогда значение ATST определится как

$$\text{ATST}=\int_0^{\infty}[1-PST(t)]dt \qquad (13)$$

Обозначим значение текущей остаточной ошибки обучения (Current Residual Training Error) нейросети как CRTE. В силу действия неполностью контролируемых и управляемых факторов процесса обучения значения CRTE являются случайными и для каждого шага подстройки весов нейросети характеризуются своим математическим ожиданием и своим рассеиванием относительно него. Вид распределения случайной текущей остаточной ошибки обучения в каждом временном сечении процесса обучения нейросети будем считать нормальным (Гауссовским).

Введем с учетом сказанного следующие обозначения:

$\hat{E}_{CRT}(t)$ - случайное значение текущей остаточной ошибки обучения для момента времени t; $M_{CRTE}(t)$ - значение математического ожидания $\hat{E}_{CRT}(t)$; $\sigma_{CRTE}(t)$ - значение среднеквадратического отклонения случайной величины $\hat{E}_{CRT}(t)$ от математического ожидания $M_{CRTE}(t)$.

В процессе нарастания шагов обучения нейросети значения математического ожидания $M_{CRTE}(t)$ и среднеквадратического отклонения $\sigma_{CRTE}(t)$ будут уменьшаться вследствие настройки весовых коэффициентов нейросети на все большее число примеров из обучающей выборки TSOE.

Тогда для математического ожидания можно записать

$$M_{CRTE}(t)=M_{CRTE}^{(0)}-k_{lM}t, \qquad (14)$$

где $k_{lM}=\frac{\Delta^{l}_{M_{CRTE}}}{\Delta t}$ - коэффициент эффективности l-го алгоритма подстройки весов нейросети по снижению математического ожидания $M_{CRTE}(t)$ в процессе подстройки весов. Аналогично для среднеквадратического отклонения $\sigma_{CRTE}(t)$ запишем

$$\sigma_{CRTE}(t)=\sigma_{CRTE}^{(0)}-k_{l\sigma}t, \qquad (15)$$

где $k_{l\sigma}=\frac{\Delta^{l}_{\sigma_{CRTE}}}{\Delta t}$ - коэффициент эффективности l-го алгоритма подстройки весов нейросети по снижению среднеквадратического отклонения $\sigma_{CRTE}(t)$ в процессе подстройки весов. $M_{CRTE}^{(0)}$ и $\sigma_{CRTE}^{(0)}$ - есть начальные значения соотвественно математического ожидания $M_{CRTE}(t)$ и среднеквадратического отклонения $\sigma_{CRTE}(t)$ при t=0.

С учетом сделанных допущений процесс изменения во времени текущей остаточной ошибки обучения может быть математически описан нестационарным Гауссовским случайным процессом с уменьшающимися значениями для математического ожидания $M_{CRTE}(t)$ = $M_{CRTE}^{(0)}-k_{lM}t$ и среднеквадратического отклонения $\sigma_{CRTE}(t)$ (см. рисунок 6). Плотность распределения значений такого случайного процесса в произвольном сечении можно записать как

$$\varphi_{CPNT}(\varepsilon;t)=\frac{1}{(\sigma_{CRTE}^{(0)}-k_{l\sigma}t)\sqrt{2\pi}}\cdot e^{-\frac{[\varepsilon-(M_{CRTE}^{(0)}-k_{lM}t)]^2}{2(\sigma_{CRTE}^{(0)}-k_{l\sigma}t)^2}} \qquad (16)$$

Теперь вероятность снижения текущей остаточной ошибки обучения нейросети до заданного порогового значения допустимой ошибки или ниже его может быть для любого заданного момента времени t рассчитана как

$$\text{PRTE}(t)=\int_0^{\varepsilon_{Пор}}\varphi_{CPNT}(\varepsilon;t)d\varepsilon \qquad (17)$$

Значение PATSPP - вероятности адекватности обучающей выборки физической задаче не зависит от времени обучения. Ее значения определяются объемом испытаний N и степенью репрезентативности обучающей выборки R.

С учетом всего сказанного выше выражение для оценивания вероятности успешного обучения нейросети за время t записывается как

$$\text{PST}(t)=[\int_0^{\varepsilon_{Пор}}\varphi_{CPNT}(\varepsilon;t)d\varepsilon]\times\text{PATSPP}(N,R) \qquad (18)$$

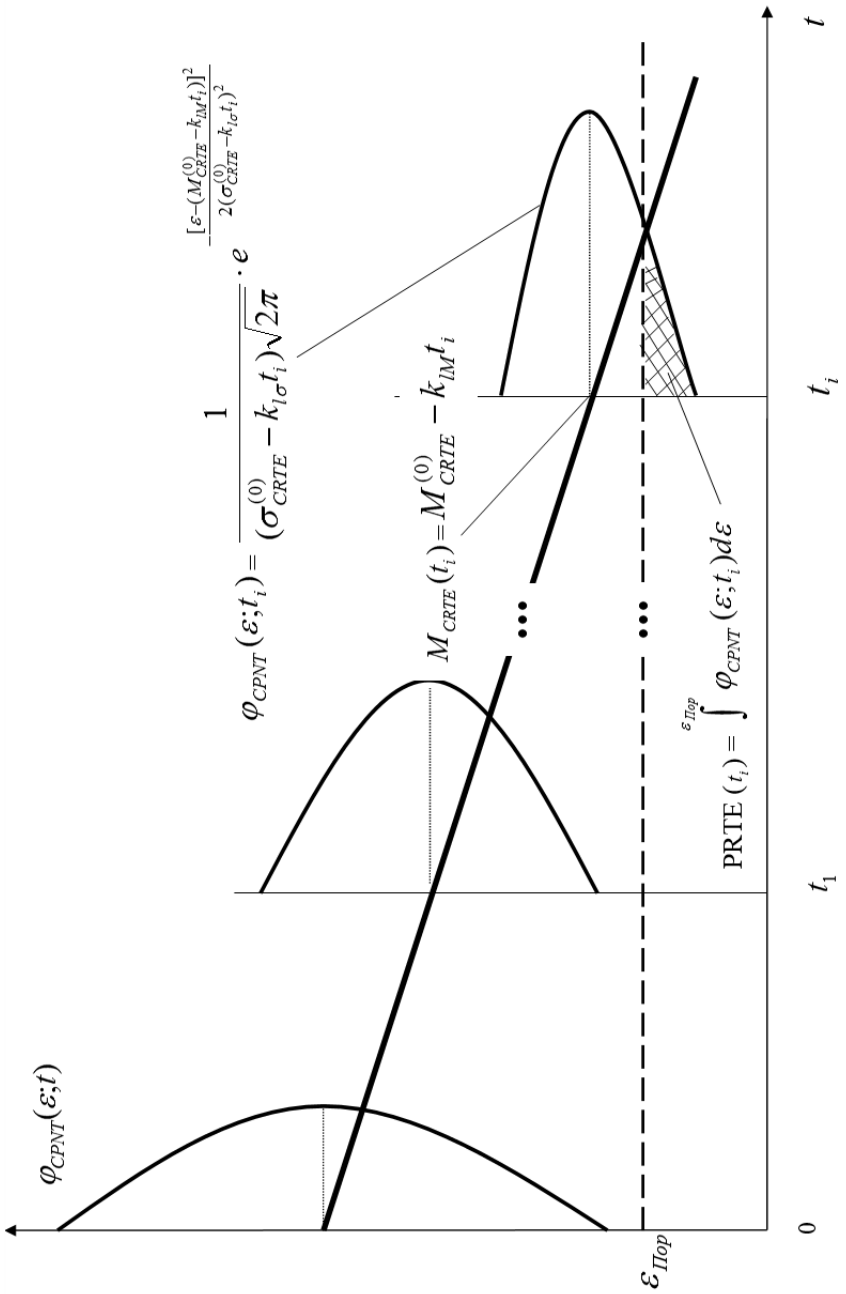

Рисунок 6. Случайный процесс изменения во времени текущей остаточной ошибки обучения

Соответственно оценка среднего времени успешного обучения нейросети вычисляется как

$$\mathrm{ATST}=\int_0^{\infty} \{1-[\int_0^{\varepsilon_{Пор}} \varphi_{CPNT}(\varepsilon;t)d\varepsilon] \times \mathrm{PATSPP}(N,R)\}dt \quad (19)$$

С учетом (18) можно ввести правило остановки процесса обучения.

Например, процесс обучения останавливается, когда значение вероятности PST(t) достигает уровня 1- $\Re$, где $\Re$ - вероятностный уровень остановки процесса обучения. Допустим, что $\Re$ =0,05, тогда процесс обучения останавливается при достижении вероятностью PST(t)уровня PST^* , равного (1-0,05), т.е. 0,95.

От значения уровня $\Re$ зависят как эффективность функционирования обученной нейросети (чем меньше $\Re$, тем выше эффективность), так и время обучения (чем

меньше $\Re$, тем дольше длится процесс обучения. Аналогичные выводы справедливы и для уровня $\varepsilon_{Пор}$.

Введенные показатели (18) и (19) позвлоляют оценить качество обучения нейросетевых алгоритмов обработки информации. При этом очевидно, что чем больше вероятность успешного обучения нейросети за время t и чем меньше среднее время успешного обучения нейросети, тем выше качество процесса обучения нейросетевых алгоритмов обработки информации.

Применение введенных показателей позволяет также обосновать выбор конкретного алгоритма подстройки весов нейросети из их исходного множества, описанного выше, а также обосновать оптимальные значения уровней $\Re$ и $\varepsilon_{Пор}$.

ЗАКЛЮЧЕНИЕ

Таким образом, в данной статье приведены основные сведения, раскрывающие сущность понятий искусственного нейрона и искусственной нейронной сети. Раскрыты особенности, последовательность и содержание операций по реализации процесса обучения нейросети. Сформулирован критерий обученности нейросети и предложены два показателя качества обучения нейросетевых алгоритмов обработки информации: вероятность успешного обучения нейросети за заданное время и среднее время успешного обучения нейросети. Приведены аналитические модели расчета введенных показателей качества обучения нейросетевых алгоритмов обработки информации. Материалы статьи могут быть полезны специалистам, разрабатывающим нейросети и совершенствующим процесс их обучения. 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. Настоящее и будущее нейронных сетей. [электронный ресурс] https://kit-e.ru/elcomp/
3. Ефимов Д.В. Нейросетевые системы управления. – М.: Высшая школа, 2002. – 184 с.
4. Ясницкий Л.Н. Введение в искусственный интеллект. - М.: Издательский центр «Академия», 2005. – 176 с.
5. Короткий С. Нейронные сети: основные положения. [электронный ресурс] http://www.gotai.net/
6. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика. М.: Горячая линия-Телеком, 2002. – 380 с.
7. 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.
8. 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.
9. 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.
10. Белов В.Г. О перспективах искусственного интеллекта. М.: Дело, 2006. – 82 с.
11. 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.
12. Васенков Д.В. Методы обучения искусственных нейронных сетей, Журнал «Компьютерные инструменты в образовании». № 1, 2007. - С. 20-29.
13. Обучение нейронной сети. [электронный ресурс] http://www.aiportal.ru/
14. Парадигмы обучения нейронных сетей. [электронный ресурс] http://apsheronsk.bozo.ru/
15. Староверов Б.А. Алгоритм формирования ансамбля нейронных сетей для информационной системы прогнозирования электропотребления // Информационно-экономические аспекты стандартизации и технического регулирования. 2019. № 5 (51). С. 37-42.

QUALITY TRAINING EVALUATING IN THE NEURAL NETWORK INFOR-MATION PROCESSING ALGORITHMS

Chaika Konstantin Vladimirovich, post-graduate student of the Faculty of Computer Technologies and Informatics of the St. Petersburg State Electrotechnical University (LETI), St. Petersburg
Shestopalov Roman Pavlovich, student of the Faculty of Computer Technologies and Informatics of the St. Petersburg State Budgetary Electrotechnical University (LETI), St. Petersburg

The article presents the results that allow us to evaluate the quality of training of neural network algorithms for information processing in various technical applications. Brief information about the concepts of an artificial neuron and an artificial neural net-work is presented, and a mathematical model of signal conversion in an artificial neu-ron is presented. The process of training a neural network in accordance with the above scheme of the learning process is described. The main existing algorithms for adjusting the weights of a neural network based on various methods of finding the minimum of a function of many variables are listed. The criterion of neural network training is pro-posed, which assumes the fulfillment of two conditions: first, the adequacy of the train-ing sample to the applied problem in terms of completeness and representativeness of the training examples, and second, the achievement of a steady reduction in the error of the neural network functioning to a given threshold value during the training process. Probabilistic indicators of the quality of the learning process of neural network algo-rithms for information processing are introduced in the form of the probability of suc-cessful training of the neural network for a given time and the average time of successful training of the neural network. Analytical expressions for their quantitative evaluation are given.

Key words: neural network, information processing algorithm, quality indicator of the training pro-cess, probability of neural network training, an average training time of the neural net-work.

REFERENCES:

1. Aggarval CH. Neyronnyye seti i glubokoye obucheniye: uchebnyy kurs: Per s angl. [*Neural networks and deep learning: a training course: Translated from English*] – SPb.: OOO «Dialektika», 2020. - 752 p.
2. Nastoyashcheye i budushcheye neyronnykh setey. [*Present and future of neural networks*] [electronic resource] https://kit-e.ru/elcomp/
3. Yefimov D.V. Neyrosetevyye sistemy upravleniya [*Neural network control systems*]. – M.: Vysshaya shkola [*Higher school*], 2002. – 184 p.
4. Yasnitskiy L.N. Vvedeniye v iskusstvennyy intellect [*Introduction to Artificial Intelligence*]. - M.: Izdatel'skiy tsentr «Akademiya» [*Publishing Center "Academy"*], 2005. – 176 p.
5. Korotkiy S. Neyronnyye seti: osnovnyye polozheniya. [*Neural networks: basic provisions*] [electronic resource] http://www.gotai.net/
6. 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.
7. 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. - pp. 74 -81.
8. 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 p.
9. 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. - pp. 18-24.

10. Belov V.G. O perspektivakh iskusstvennogo intellekta [*On the prospects of artificial intelligence*]. M.: Delo, 2006. – 82 p.
11. Buduma N., Lokasho N. Osnovy glubokogo obucheniya. Sozdaniye algoritmov dlya iskusstvennogo intellekta sleduyushchego pokoleniya. *Translated from English*. [*Fundamentals of deep learning. Creation of algorithms for next generation artificial intelligence*] - M.: Mann, Ivanov i Ferber, 2020. - 304 p.
12. Vasenkov D.V. Metody obucheniya iskusstvennykh neyronnykh setey, Zhurnal «Komp'yuternyye instrumenty v obrazovanii» [*Teaching methods of artificial neural networks, Journal "Computer tools in education"*]. № 1, 2007. - pp. 20-29.
13. Obucheniye neyronnoy seti. [*Training the neural network*] [electronic resource] URL: http://www.aiportal.ru/
14. Paradigmy obucheniya neyronnykh setey [*Paradigms of learning neural networks*]. [electronic resource] http://apsheronsk.bozo.ru/
15. Staroverov B.A. Algoritm formirovaniya ansamblya neyronnykh setey dlya informatsionnoy sistemy prognozirovaniya elektropotrebleniya [*Algorithm for forming an ensemble of neural networks for an information system for forecasting power consumption*] // Informatsionno-ekonomicheskiye aspekty standartizatsii i tekhnicheskogo regulirovaniya [*Information and economic aspects of standardization and technical regulation*]. 2019. № 5 (51). pp. 37-42.