

Научная статья

УДК 004.852

## **ОПРЕДЕЛЕНИЕ КАЧЕСТВА НЕЙРОСЕТЕВОЙ РЕГРЕССИИ С ПОМОЩЬЮ СТАТИСТИЧЕСКОЙ ТЕОРИИ ОБУЧЕНИЯ**

✉ **Новиков Егор Анатольевич;**

**Литвинов Владислав Леонидович.**

**Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича, Санкт-Петербург, Россия**

✉ ***egoredmc@gmail.com***

*Аннотация.* Рассматривается задача восстановления регрессии в формулировке статистической теории обучения, то есть как задача минимизации эмпирического риска при заданных условиях. Показано, что нейронная сеть прямого распространения реализует принцип минимизации эмпирического риска при решении задачи регрессии. Исследуется возможность практического определения доверительного интервала для качества обучения нейронной сети.

Предложен способ оценки верхней границы доверительного интервала качества нейросетевой модели для всей функциональной зависимости, к которой строится регрессия. Показана практическая работоспособность данного способа, а именно, что реальное значение качества обучения нейронной сети меньше предлагаемой верхней границы доверительного интервала. Описываемый способ может найти применение при решении практических задач, требующих гарантированную оценку качества нейросетевой регрессии.

В качестве дальнейшего направления исследования предполагается уточнение методов оценки комбинаторной размерности нейронной сети, поскольку именно эта составляющая привносит наибольшую неточность при оценке границы доверительного интервала.

*Ключевые слова:* статистическая теория обучения, минимизация эмпирического риска, нейронные сети, многослойный персептрон, комбинаторная размерность, VC-размерность, качество обучения, доверительный интервал

**Для цитирования:** Новиков Е.А., Литвинов В.Л. Определение качества нейросетевой регрессии с помощью статистической теории обучения // Науч.-аналит. журн. «Вестник С.-Петерб. ун-та ГПС МЧС России». 2023. № 2. С. 82–90.

Scientific article

## **ESTABLISHING NEURAL NETWORK REGRESSION QUALITY USING STATISTICAL LEARNING THEORY**

✉ **Novikov Egor A.;**

**Litvinov Vladislav L.**

**Saint-Petersburg state university of telecommunications them. prof. M.A. Bonch-Bruevich, Saint-Petersburg, Russia**

✉ ***egoredmc@gmail.com***

*Abstract.* Study considers regression estimation problem as it is posed in statistical learning theory, that is as empirical risk minimization problem. It is shown that feedforward neural network implements empirical risk minimization principle for regression estimation. The real world possibility of establishing confidence interval for neural network learning quality is being examined.

Article proposes new method of establishing upper boundary of the neural network regression quality confidence interval for whole function. It is shown that real value of neural network learning quality is less than expected upper boundary of the neural network regression quality confidence interval, thus the functioning of proposed method is shown. Described way may be of great use in real world problems, which require assured estimation of neural network regression quality.

The directions of further research lies in finding more precise estimations for neural network VC-dimension, since that part brings the most inaccuracy in upper boundary establishing process.

*Keywords:* statistical learning theory, empirical risk minimization, neural network, multilayer perceptron, VC-dimension, learning quality, confidence interval

**For citation:** Novikov E.A., Litvinov V.L. Establishing neural network regression quality using statistical learning theory // Scientific and analytical journal «Vestnik Saint-Petersburg university of State fire service of EMERCOM of Russia». 2023. № 2. P. 82–90.

## Введение

При решении задачи восстановления регрессии с помощью нейронной сети оценка качества этого решения представляет собой оценку качества обучения используемой нейронной сети [1, 2]. Для решения большинства практических задач оценка качества обучения получается путем прямого сравнения ожидаемого результата и полученного или методом перекрестной оценки (cross-validation), являющимся развитием метода прямого сравнения [1, 3, 4]. Однако указанные методы позволяют получить лишь конкретное значение, отвечающее используемой обучающей выборке, но не позволяют понимать качество обучения для всей области определения функции, к которой строится регрессия.

Для получения статистически значимой оценки работы нейронной сети строится доверительный интервал для качества обучения. На текущий момент предложено несколько способов построения такого доверительного интервала.

Первый из них заключается в построении доверительного интервала с помощью распределения Стьюдента на основе перекрестной найденной [5]. Второй – основан на использовании дополнительной нейронной сети, которая осуществляет поиск самого доверительного интервала качества обучения, путем минимизации некоторого функционала [6]. Третий способ позволяет построить доверительный интервал для качества обучения, который будет истинным лишь с определенной вероятностью [7].

Из приведенных выше способов построения доверительного интервала, первый и второй не используют информацию о свойствах обучающей выборки; третий способ хотя и использует информацию о выборке, но позволяет получить лишь вероятный доверительный интервал.

В данной работе предлагается способ получения доверительного интервала качества обучения нейронной сети, основывающийся на информации об используемой нейронной сети и размере используемой выборки. Идея предлагаемого способа заключается в том, чтобы хотя бы частично извлечь информацию о законе распределения исходных данных из нейронной сети, которая используется для построения регрессии. Способ основывается на статистической теории обучения и использует предлагаемый ею метод минимизации эмпирического функционала для определения верхней границы доверительного интервала значения ошибки решающего правила, которое представляет собой обученная нейронная сеть.

В работе приводится теоретическое описание предлагаемого способа и набор экспериментов, показывающих применимость способа для нескольких наборов данных, реализующих различные исходные функции.

Таким образом, объектом исследования является качество обучения нейронной сети. Предметом исследования является инновационный способ построения доверительного интервала для качества обучения нейронной сети.

### Теоретическое обоснование способа

С целью определения множества используемых методов и обозначений рассмотрим задачу восстановления регрессии на предмет минимизируемого функционала.

Согласно работам [1, 8, 9] при восстановлении регрессии нейронная сеть обучается с использованием метода градиентного спуска, который минимизирует градиент ошибки:

$$\nabla \mathbf{E}(\mathbf{w}) = \frac{1}{L} \sum_{k=1}^L \nabla Q(\mathbf{X}(k), d(k)), \quad (1)$$

где  $Q(\mathbf{X}(k), d(k))$  – функция потерь, определяемая как расстояние между реальным значением  $d(k)$  и предсказываемым значением  $\varphi(\mathbf{w}(n)\mathbf{X}(k))$  ( $\varphi$  – функция активации нейрона);  $L$  – размер обучающей выборки. В статистической теории обучения [2, 10–12] задача регрессии решается методом минимизации функционала эмпирического риска:

$$I_{\varphi}(\alpha) = \frac{1}{l} \sum_{i=1}^l Q(z_i, \alpha), \quad (2)$$

где  $(x_i, y_i) = z_i$  – пара значений вход-выход из обучающей выборки;  $l$  – размер обучающей выборки;  $Q(z, \alpha)$  – класс функций потерь,  $\alpha \in \Lambda$ .

Докажем, что метод градиентного спуска является частным случаем метода минимизации эмпирического риска.

Во-первых, покажем, что формулы (1) и (2) осуществляют одну и ту же процедуру. Обозначим  $L(\cdot, \cdot)$  – метрика в соответствующем пространстве. Тогда слагаемое в формуле (1) можно представить в виде  $Q(\mathbf{X}(k), d(k)) = L(d(k), \varphi(\mathbf{w}(n)\mathbf{X}(k)))$ , где  $\mathbf{w}(n)$  – весовые коэффициенты нейронной сети; а слагаемое в формуле (2) – в виде  $Q(z_i, \alpha) = L(y_i, F(x_i, \alpha))$ , где  $F(x, \alpha)$  – решающее правило. Таким образом, в обеих формулах для всей обучающей выборки берется среднее значение расстояния от ожидаемого значения до предсказанного с помощью текущего решающего правила. Отсюда следует, что классу параметров  $\Lambda$  соответствует множество всех возможных весовых коэффициентов нейронной сети  $\{\mathbf{W}\}$ .

Во-вторых, исследуем сходимость этих двух методов. Метод минимизации эмпирического риска (2) имеет глобальную сходимость в случае абсолютного ограничения на значения входных данных и при условии конечности комбинаторной размерности  $h$  множества решающих правил. Алгоритм градиентного спуска (1) имеет глобальную сходимость при ограничении скорости обучения  $\theta$  нейронной сети:

$$0 < \theta < \frac{2}{\sum_{k=1}^L M[\|\mathbf{X}(k)\|]} = \frac{2}{\sum_{k=1}^L \sum_{i=0}^m (x_i(k))^2}, \quad (3)$$

где  $M[\cdot]$  – оператор математического ожидания;  $m$  – размерность вектора входных данных  $\mathbf{X}$ . Учитывая тот факт, что нейронная сеть с конечным числом нейронов имеет заведомо конечную комбинаторную размерность и формулу (3), получаем, что условия сходимости метода градиентного спуска выполнены всегда, когда выполнены условия сходимости метода минимизации эмпирического риска. Кроме того, если не выполнены условия сходимости метода градиентного спуска, то будут не выполнены и условия сходимости метода минимизации эмпирического риска. Отсюда следует, что эти два метода сходятся и расходятся одновременно.

С учетом вышеизложенного, поскольку метод градиентного спуска осуществляет минимизацию для конкретного функционала эмпирического риска и минимизация одного

функционала обязательно соответствует минимизации другого, можно считать, что метод градиентного спуска является реализацией метода минимизации эмпирического риска.

При решении задачи регрессии для многослойных нейронных сетей используется также алгоритм обратного распространения ошибки [8], откуда следует необходимость рассмотреть его на предмет соответствия методу минимизации эмпирического риска.

Суть алгоритма обратного распространения ошибки заключается в следующем: используя информацию об ошибке нейронов выходного слоя, алгоритм рекурсивно высчитывает значение ошибки для нейронов предыдущего слоя. Иначе говоря, алгоритм обратного распространения ошибки определяет значение вектора ошибки  $\nabla E(\mathbf{w}(n))$  для каждого шага и не принимает непосредственного участия в минимизации эмпирического риска.

Исходя из описанных выше предпосылок, можно заключить, что процесс обучения и значение ошибки (качество обучения) нейронной сети описывается статистической теорией обучения и методом минимизации эмпирического риска.

Основываясь на этом, используем ограничение для качества обучения [12], а именно: с вероятностью  $1-\eta$  истинное значение качества обучения  $I(\alpha^*)$  будет ограничено сверху как:

$$I(\alpha^*) < I_\eta(\alpha^*) + \frac{BE(l)}{2} \left( 1 + \sqrt{1 + \frac{4I_\eta(\alpha^*)}{BE(l)}} \right), \quad (4)$$

где

$$E(l) = 4 \frac{h \left( \ln \frac{2l}{h} + 1 \right) - \ln \frac{\eta}{4}}{l},$$

$l$  – размер обучающей выборки;  $B$  – максимальное значение, которое принимает функция потерь  $Q(z, \alpha)$ .

Для построения доверительного интервала качества обучения используется значение комбинаторной размерности  $h$  множества решающих правил; в данном случае множеству решающих правил соответствует архитектура нейронной сети. Точно определить значение размерности  $h$  для какого-либо нетривиального множества обучающих правил не представляется возможным<sup>1</sup>, поэтому можно использовать верхнюю и нижнюю оценки значения  $h$  [13, 14]. Для нейронной сети  $F$  значение  $h(F)$  можно ограничить как:

$$2 \left\lfloor \frac{n}{2} \right\rfloor k \leq h(F) \leq 2\gamma(F) + 16w. \quad (5)$$

В формуле (5) значение  $\gamma(F)$  определяется следующим образом:

$$\gamma(F) = \frac{nw}{2} (nw - 1) + 2nw \log_2 d + w \log_2 w + w \log_2 (2nd + 1) + 2nw \log_2 w + nw \log_2 (2nd),$$

где  $w$  – число весов в сети  $F$ ;  $k$  – число входов;  $n$  – число вершин графа сети;  $d$  – верхняя граница степени полинома индуцированного локального поля нейрона  $\mathbf{w} \cdot \mathbf{X}$ . На каждом слое осуществляется умножение входного вектора этого слоя на вектор весов, поэтому будет  $d = m + 1$ , где  $m$  – число внутренних слоев сети.

Таким образом, зная длину выборки  $l$  и архитектуру нейронной сети  $F$  можно определить верхнюю границу доверительного интервала для значения качества обучения этой нейронной сети на данной выборке.

<sup>1</sup> На текущий момент проблема определения точной верхней границы комбинаторной размерности до сих пор остается открытой [14]

### Экспериментальное исследование

Для экспериментальной проверки предложенного метода возьмем некоторую функцию  $f(x)$ , регрессию к которой будем восстанавливать (для простоты и наглядности будем использовать  $f: \mathbb{R} \rightarrow \mathbb{R}$ ). С помощью этой функции построим выборку данных вход-выход некоторого достаточно большого размера  $l$ . После этого создадим и обучим с помощью имеющейся выборки нейронную сеть  $F$ , которая бы минимизировала соответствующий эмпирический риск  $I_3(\alpha)$ . Поскольку при обучении осуществляется минимизация значения ошибки нейронной сети на множестве значений вектора весов  $w$ , то эмпирический риск  $I_3(\alpha)$  соответствует значению ошибки нейронной сети, а вектор весов  $w$  – варьируемому параметру  $\alpha$ ; вектор весов  $w^*$ , полученной в результате обучения нейронной сети  $F^*$ , представляет собой значение  $\alpha^*$ , которое доставляет минимум функционалу  $I_3(\alpha)$ . Тогда функционал среднего риска (истинное значение качества обучения) представляется как:

$$I(\alpha) = \int_G L(f(x), F(x)) dx = \int_G Q(z, \alpha),$$

где  $G$  – конечная область, на которой осуществляется регрессия к функции  $f(x)$ ;  $L(\cdot, \cdot)$  – метрика в пространстве.

Представим для удобства формулу (4) в виде:

$$I(\alpha^*) < I_3(\alpha^*) + \beta,$$

где

$$\beta = \frac{BE(l)}{2} \left( 1 + \sqrt{1 + \frac{4I_3(\alpha^*)}{BE(l)}} \right).$$

Поскольку имеем верхнюю и нижнюю границы для значения комбинаторной размерности ( $h_{max}$  и  $h_{min}$  соответственно), то и для значений  $E$  и  $\beta$  можно определить только верхние и нижние границы. Чтобы гарантировать истинность доверительного интервала с заданной вероятностью необходимо сделать более сильное ограничение:

$$I(\alpha^*) < I_3(\alpha^*) + \beta_{min} \leq I_3(\alpha^*) + \beta, \quad (6)$$

где

$$\beta_{min} = \frac{BE_{min}(l)}{2} \left( 1 + \sqrt{1 + \frac{4I_3(\alpha^*)}{BE_{min}(l)}} \right);$$


$$E_{max} = 4 \frac{h_{max} \left( \ln \frac{2l}{h_{min}} + 1 \right) - \ln \frac{\eta}{4}}{l}, \quad E_{min} = 4 \frac{h_{min} \left( \ln \frac{2l}{h_{max}} + 1 \right) - \ln \frac{\eta}{4}}{l}.$$

В таком случае выполнение неравенства (6) для полученных значений  $I_3(\alpha^*)$ ,  $I(\alpha^*)$  и  $\beta_{min}$  будет подтверждать, что доверительный интервал построен верно, с взятой вероятностью  $1-\eta$ .


На рисунке представлены результаты эксперимента для различных функций а) – е): исходные данные, построенная регрессия, полученные значения  $I(\alpha)$ ,  $I_3(\alpha)$  и  $\beta_{min}$  приведены в таблице. Видно, все приведенные примеры удовлетворяют неравенству (6). Для экспериментов использовались выборки размерами 650–1000 элементов, нейронная сеть содержала 10 нейронов на скрытом слое с гиперболическим тангенсом в качестве функции активации. В качестве уровня значимости было взято  $\eta=0,05$ , то есть вероятность истинности полученных утверждений 95 %.

**Значения  $I(\alpha)$ ,  $I_2(\alpha)$  и  $\beta_{min}$**


Эксперимент	$I(\alpha)$	$I_2(\alpha)$	$\beta_{min}$
а)	$1,4 \cdot 10^{-3}$	$6,2 \cdot 10^{-5}$	$4,3 \cdot 10^{-3}$
б)	$2,20 \cdot 10^{-3}$	$1,22 \cdot 10^{-3}$	$2,17 \cdot 10^{-3}$
в)	$1,3 \cdot 10^{-3}$	$6,1 \cdot 10^{-5}$	$2,8 \cdot 10^{-3}$
г)	$1,8 \cdot 10^{-4}$	$5,7 \cdot 10^{-5}$	$5,9 \cdot 10^{-4}$
д)	$1,9 \cdot 10^{-3}$	$7,8 \cdot 10^{-5}$	$3,2 \cdot 10^{-3}$
е)	$1,4 \cdot 10^{-3}$	$1,9 \cdot 10^{-4}$	$2,2 \cdot 10^{-3}$




а)




б)




в)



г)



д)



е)

**Рис. Регрессия к функциям:  
а)  $\sin(x)$ ; б) единичной ступенчатой; в) линейной; г) логарифмической;  
д) затухающей периодической; е) нелинейной осциллирующей**

## Выводы

Из проведенных экспериментов можно сделать обоснованный вывод, что построенные доверительные интервалы для истинного значения качества обучения нейронной сети действительно содержат само истинное значение. Учитывая достаточно высокий уровень доверия, взятый для построения интервалов, это можно считать показателем работоспособности предлагаемого метода.

Также следует отметить, что для всех рассмотренных примеров значения ограничения  $\beta_{\min}$  примерно одного порядка, в то время как значения эмпирического риска  $I_3(\alpha)$  могут меняться для различных функций. Изменчивость значений  $I_3(\alpha)$  связана в первую очередь с тем, что значение эмпирического риска зависит наибольшим образом именно от качества регрессии; значение ограничения  $\beta_{\min}$  зависит более всего от архитектуры самой нейронной сети, которая не меняется в ходе экспериментов.

Кроме того, значение  $\beta_{\min}$  всегда оказывает значительное влияние на итоговый доверительный интервал (зачастую, наибольшее), из чего можно сделать вывод, что характеристика архитектуры сети имеет большое влияние на границы доверительного интервала. Значение  $I_3(\alpha)$  же оказывает подобное влияние на итоговый интервал только когда качество регрессии ниже среднего, как это можно видеть в экспериментах б) и е).

## Заключение

В работе представлен метод оценки доверительного интервала для качества обучения нейронной сети. Этот метод может применяться при решении задач, требующих точного определения качества регрессии, построенной с помощью нейронной сети.

На примере решения задачи регрессии к различным функциям показана работоспособность описываемого метода. По результатам проведенных экспериментов можно утверждать, что при достаточной выборке реальное значение качества обучения нейронной сети попадает в доверительный интервал, построенный на основе информации об архитектуре нейронной сети и значении ошибки её обучения на этой выборке.

### Список источников

1. Хайкин С. Нейронные сети: полный курс.: пер. с англ. М.: Изд. дом «Вильямс», 2006. 1104 с.
2. Вапник В.Н. Восстановление зависимостей по эмпирическим данным. М.: Наука, 1979. 448 с.
3. Du K.L., Swamy M.N.S. Neural Networks and Statistical Learning. London: Springer-Verlag, 2019. 998 p.
4. Stone M. Cross-validated Choice and Assessment of Statistical Predictions // Journal of the Royal Statistical Society. 1974. № 36. P. 111–133.
5. Khaki S., Nettleton D. Conformal Prediction Intervals for Neural Networks Using Cross Validation. 2020. URL: <https://arxiv.org/abs/2006.16941v1> (дата обращения: 15.03.2023).
6. Lower Upper Bound Estimation Method for Construction of Neural Network-Based Prediction Intervals / A. Khosravi [et al.] // IEEE Transactions on Neural Networks. 2011. № 22. P. 337–346.
7. Kivaranovic D., Johnson K.D., Leeb H. Adaptive, Distribution-Free Prediction Intervals for Deep Networks. 2020. URL: <https://arxiv.org/pdf/1905.10634.pdf> (дата обращения: 15.03.2023).
8. Рутковская Д., Пилиньский М., Рутковский Л. Нейронные сети, генетические алгоритмы и нечеткие системы. М.: «Горячая линия – Телеком», 2006. 452 с.
9. Поляк Б.Т. Введение в оптимизацию. М.: Наука, 1983. 384 с.
10. Вапник В.Н., Червоненкис А.Я. Теория распознавания образов (статистические проблемы обучения). М.: Наука, 1974. 416 с.

11. Вапник В.Н., Червоненкис А.Я. О равномерной сходимости частот появления событий к их вероятностям // Теория вероятностей и ее применения. 1971. № 2. С. 264–279.
12. Vapnik V.N. *Statistical Learning Theory*. N.Y.: J. Wiley, 1998. 736 p.
13. Baum E.B., Haussler D. What Size Net Gives Valid Generalization? // *Advances in Neural Information Processing Systems*. 1988. № 1. P. 81–90.
14. Karpinski M., Macintyre A. Polynomial Bounds for VC Dimension of Sigmoidal and General Pfaffian Neural Networks // *J. Computer Systems Science*. 1997. № 54. P. 169–176.

### References

1. Hajkin S. *Нейронные сети: полный курс.*: пер. с англ. М.: Изд. дом «Вильямс», 2006. 1104 с.
2. Vapnik V.N. *Vosstanovlenie zavisimostej po empiricheskim dannym*. М.: Nauka, 1979. 448 с.
3. Du K.L., Swamy M.N.S. *Neural Networks and Statistical Learning*. London: Springer-Verlag, 2019. 998 p.
4. Stone M. Cross-validated Choice and Assessment of Statistical Predictions // *Journal of the Royal Statistical Society*. 1974. № 36. P. 111–133.
5. Khaki S., Nettleton D. Conformal Prediction Intervals for Neural Networks Using Cross Validation. 2020. URL: <https://arxiv.org/abs/2006.16941v1> (data obrashcheniya: 15.03.2023).
6. Lower Upper Bound Estimation Method for Construction of Neural Network-Based Prediction Intervals / A. Khosravi [et al.] // *IEEE Transactions on Neural Networks*. 2011. № 22. P. 337–346.
7. Kivaranovic D., Johnson K.D., Leeb H. Adaptive, Distribution-Free Prediction Intervals for Deep Networks. 2020. URL: <https://arxiv.org/pdf/1905.10634.pdf> (data obrashcheniya: 15.03.2023).
8. Rutkovskaya D., Pilin'skij M., Rutkovskij L. *Нейронные сети, генетические алгоритмы и нечеткие системы*. М.: «Горькая линия – Телеком», 2006. 452 с.
9. Polyak B.T. *Vvedenie v optimizaciyu*. М.: Nauka, 1983. 384 с.
10. Vapnik V.N., Chervonenkis A.Ya. *Teoriya raspoznavaniya obrazov (statisticheskie problemy obucheniya)*. М.: Nauka, 1974. 416 с.
11. Vapnik V.N., Chervonenkis A.Ya. О равномерной сходимости частот появления событий к их вероятностям // Теория вероятностей и ее применения. 1971. № 2. С. 264–279.
12. Vapnik V.N. *Statistical Learning Theory*. N.Y.: J. Wiley, 1998. 736 p.
13. Baum E.B., Haussler D. What Size Net Gives Valid Generalization? // *Advances in Neural Information Processing Systems*. 1988. № 1. P. 81–90.
14. Karpinski M., Macintyre A. Polynomial Bounds for VC Dimension of Sigmoidal and General Pfaffian Neural Networks // *J. Computer Systems Science*. 1997. № 54. P. 169–176.

**Информация о статье:**

Статья поступила в редакцию: 01.04.2023; одобрена после рецензирования: 19.04.2023;  
принята к публикации: 20.04.2023

**The information about article:**

The article was submitted to the editorial office: 01.04.2023; approved after review: 19.04.2023;  
accepted for publication: 20.04.2023

*Информация об авторах:*

**Новиков Егор Анатольевич**, ассистент кафедры безопасности информационных систем Санкт-Петербургского государственного университета телекоммуникаций им. проф. М.А. Бонч-Бруевича (193232, Санкт-Петербург, пр. Большевиков д. 22, к. 1), e-mail: [egoredmc@gmail.com](mailto:egoredmc@gmail.com), <https://orcid.org/0000-0003-3448-3015>

**Литвинов Владислав Леонидович**, доцент кафедры информационных систем управления Санкт-Петербургского государственного университета телекоммуникаций им. проф. М.А. Бонч-Бруевича (193232, Санкт-Петербург, пр. Большевиков д. 22, к. 1), кандидат технических наук, доцент, e-mail: [vlad.litvinov61@gmail.com](mailto:vlad.litvinov61@gmail.com), <https://orcid.org/0000-0002-0664-0186>

*Information about authors:*

**Novikov Egor A.**, assistant of the information systems safety department of the Saint-Petersburg state university of telecommunications them. prof. M.A. Bonch-Bruevich (193232, Saint-Petersburg, Bolshevikov ave. 22, build. 1), e-mail: [egoredmc@gmail.com](mailto:egoredmc@gmail.com), <https://orcid.org/0000-0003-3448-3015>

**Litvinov Vladislav L.**, associate professor of the information systems safety department of the Saint-Petersburg state university of telecommunications them. prof. M.A. Bonch-Bruevich (193232, Saint-Petersburg, Bolshevikov ave. 22, build. 1), candidate of technical sciences, associate professor, e-mail: [vlad.litvinov61@gmail.com](mailto:vlad.litvinov61@gmail.com), <https://orcid.org/0000-0002-0664-0186>