

<https://doi.org/10.32362/2500-316X-2019-7-5-20-29>



УДК 519.248

Модификация алгоритма WaldBoost для повышения эффективности решения задач распознавания образов в реальном времени

А.Н. Чесалин[@],
С.Я. Гродзенский,
М.Ю. Нилов,
А.Н. Агафонов

МИРЭА – Российский технологический университет, Москва 119454, Россия

[@]Автор для переписки, e-mail: chesalin_an@mail.ru

Задачей исследования является совершенствование известных алгоритмов машинного обучения для распознавания образов с использованием минимального количества времени (минимального количества используемых классификаторов) и с заданной достоверностью результатов. Рассматривается реализация алгоритма WaldBoost, в котором объединены два алгоритма: адаптивного усиления слабых классификаторов – AdaBoost (adaptive boosting), обладающего высокой обобщающей способностью, и последовательного критерия отношения правдоподобия – SPRT (критерий Вальда), являющегося оптимальным правилом принятия решения при различении двух гипотез. Отмечается, что при использовании WaldBoost значения фактических вероятностей ошибок классификации, как правило, оказываются меньше заданных из-за используемых приближенных границ SPRT, вследствие чего в процессе классификации используется излишняя серия слабых классификаторов. В связи с этим предлагается модификация алгоритма WaldBoost, основанная на итерационном уточнении границ принятия решения, позволяющая значительно сократить количество используемых слабых классификаторов, необходимых для распознавания образов с заданной точностью. Показана эффективность предложенного алгоритма на конкретных примерах. Результаты работы подтверждаются статистическим моделированием на нескольких наборах данных. Отмечается, что результаты работы могут быть применены при уточнении других каскадных алгоритмов классификации.

Ключевые слова: ансамбли алгоритмов, адаптивный бустинг, AdaBoost, WaldBoost, последовательный анализ.

Для цитирования: Чесалин А.Н., Гродзенский С.Я., Нилов М.Ю., Агафонов А.Н. Модификация алгоритма WaldBoost для повышения эффективности решения задач распознавания образов в реальном времени // Российский технологический журнал. 2019. Т. 7. № 5. С. 20–29. <https://doi.org/10.32362/2500-316X-2019-7-5-20-29>

Modification of the WaldBoost algorithm to improve the efficiency of solving pattern recognition problems in real-time

Alexander N. Chesalin@,
Sergey Ya. Grodzenskiy,
Mikhail Yu. Nilov,
Aleksey N. Agafonov

MIREA – Russian Technological University, Moscow 119454, Russia

@Corresponding author, e-mail: chesalin_an@mail.ru

The implementation of the WaldBoost algorithm is considered, and its modification is proposed, which allows to significantly reduce the number of weak classifiers to achieve a given classification accuracy. The efficiency of the proposed algorithm is shown by specific examples. The paper studies modifications of compositions (ensembles) of algorithms for solving real-time pattern recognition problems. The aim of the study is to improve the known machine learning algorithms for pattern recognition using a minimum amount of time (the minimum number of used classifiers) and with a given accuracy of the results. We consider the implementation of the WaldBoost algorithm, which combines two algorithms: adaptive boosting of weak classifiers – AdaBoost (adaptive boosting), which has a high generalizing ability, and the sequential probability ratio test – SPRT (Wald test), which is the optimal rule of decision-making when distinguishing two hypotheses. It is noted that when using the WaldBoost, the values of the actual probability of classification errors, as a rule, are less than given because of the approximate boundaries of the SPRT, so that the classification process uses an excessive series of weak classifiers. In this regard, we propose a modification of the WaldBoost based on iterative refinement of the decision boundaries, which can significantly reduce the number of used weak classifiers required for pattern recognition with a given accuracy. The efficiency of the proposed algorithm is shown by specific examples. The results are confirmed by statistical modeling on several data sets. It is noted that the results can be applied in the refinement of other cascade classification algorithms.

Keywords: algorithm ensembles, adaptive boosting, AdaBoost, WaldBoost, sequential analysis.

For citation: Chesalin A.N., Grodzenskiy S.Ya., Nilov M.Yu., Agafonov A.N. Modification of the WaldBoost algorithm to improve the efficiency of solving pattern recognition problems in real-time. *Rossiiskii tekhnologicheskii zhurnal* = Russian Technological Journal. 2019;7(5):20-29 (in Russ.). <https://doi.org/10.32362/2500-316X-2019-7-5-20-29>

Введение

Обработка информации часто связана с алгоритмами распознавания образов в реальном времени, позволяющими проводить классификацию объектов за минимальное время с требуемой достоверностью. Одним из наиболее эффективных является метод композиций (ансамблей) алгоритмов, дающий возможность разрабатывать эффективные правила с помощью обучения слабых алгоритмов, имеющих недостаточную точность прогноза. Наиболее известный метод такого обучения – бустинг (англ. *boosting*, – усиление, усиление), а его самая известная реализация – адаптивный бустинг (*AdaBoost*), предложенный Y. Freund и R. Schapire в работе [1] и представляющий мета-алгоритм машинного обучения ансамбля слабых классификаторов.

По сравнению с другими методами статистического обучения *AdaBoost* обладает большей стойкостью к переобучению. Кроме того, он чувствителен к выбросам из-за используемой в нем экспоненциальной функции потерь. К настоящему времени разработаны модификации *AdaBoost* с другими функциями потерь, обеспечивающие большую робастность (устойчивость), например, *BrownBoost*, *RobustBoost* и др. В работе [2] J.Н. Friedman предложил обобщающий предыдущие результаты так называемый градиентный бустинг (*GradientBoosting*) с возможностью использования любой дифференцированной функции потерь. В этом смысле *AdaBoost* является частным случаем *GradientBoosting*.

В технических приложениях, связанных с задачей распознавания образов в реальном времени, таких, как компьютерное зрение, системы обнаружения вторжений и др., особенно актуальна проблема минимизации времени обработки входной информации и принятия решения – выбора одной из конкурирующих гипотез (к примеру, обнаружение/отсутствие аномалии в компьютерном трафике, наличие/отсутствие трещин в исследуемом материале, свой/чужой в радиолокации и др.), с заданными вероятностями ошибок первого и второго рода. Проблема различения гипотез, основанная на анализе последовательности наблюдений, как правило, решается на основе метода статистического последовательного анализа, с использованием последовательного критерия отношения вероятностей (правдоподобия) – *SPRT*, предложенного А. Wald [3], и его модификаций [4, 5]. Алгоритм *SPRT* является оптимальным для различения двух простых конкурирующих гипотез и, как правило, применяется в технических приложениях в предположении независимости наблюдений [6].

В работе [7] описан алгоритм *WaldBoost*, который объединяет *SPRT* и *AdaBoost*, и представлены результаты моделирования, показавшие возможность значительного сокращения количества используемых слабых классификаторов, по сравнению с классификаторами *Viola-Jones*. В *WaldBoost* алгоритм *AdaBoost* используется для отбора признаков и построения классификатора (который является статистикой для *SPRT*), а *SPRT* – для оптимального различения конкурирующих гипотез (в случае классификации, гипотезами являются принадлежность рассматриваемого объекта к каждому из классов). В работе [7] используются границы принятия решений θ_A и θ_B , полученные на основе приближенных границ *SPRT*, а также для оценки плотности распределений используется сильно сглаженная ядерная оценка плотности, что приводит к неоптимальным решениям, при этом, как правило, с более низкими вероятностями ошибок. В работе [8] отмечается, что уточнение границ *SPRT* позволяет значительно (до 25%) сократить количество наблюдений при различении конкурирующих гипотез. В данной работе рассматривается проблема уточнения границ θ_A и θ_B и получения более эффективного алгоритма (модификации *WaldBoost*), позволяющего принимать решения, используя меньшее количество классификаторов, при заданных вероятностях ошибок первого и второго рода.

Постановка задачи

Пусть задан набор исходных данных (обучающая выборка) $\{(x_1, y_1), \dots, (x_n, y_n)\}$, $x \in X, y \in \{-1; +1\}$ (X – множество объектов, y – заданные классы объектов), по результатам обучения на исходном наборе данных необходимо построить алгоритм (классификатор), позволяющий определять значения величины по значениям не только на обучающей выборке, но и на всем пространстве X с учетом заданных величин вероятностей ошибок первого и второго рода за наименьшее время. Ниже кратко приводятся используемые алгоритмы и методы, описывается предлагаемый мета-алгоритм,

проводится статистическое моделирование на разных наборах данных и делаются выводы и рекомендации по применению предлагаемого подхода.

Предлагаемый мета-алгоритм

Предлагаемая модификация алгоритма *WaldBoost* (мета-алгоритм уточнения) приводится в псевдокоде ниже (**Алгоритм 1 – Modified WaldBoost**). Предлагаемый мета-алгоритм используется для уточнения границ $\theta_A^{[t]}, \theta_B^{[t]}$ принятия решения о классе объекта и основан на алгоритме уточнения границ последовательных критериев отношения правдоподобия, предложенном в работе [7].

В предлагаемом мета-алгоритме (**Алгоритм 1 Modified WaldBoost**) используются три под-алгоритма: **Алгоритм 1.1** – Обучение *WaldBoost* [7], **Алгоритм 1.2** – Обучение *Real AdaBoost* [9], **Алгоритм 1.3** – Классификация *WaldBoost* [7], псевдокод которых также приведен ниже. Распознавание (классификация) новых объектов $x \in X$ проводится в соответствии с **Алгоритмом 1.3** с использованием рассчитанного классификатора и границ принятия решения, полученных в результате выполнения **Алгоритма 1**. Дополнительный расчет слабых классификаторов и границ принятия решения проводится при дообучении алгоритма на новых данных.

Алгоритм 1 – Modified WaldBoost

Вход: $\{(x_1, y_1), \dots, (x_n, y_n)\}$, $x \in X, y \in \{-1; +1\}$ – обучающая выборка

$\{(x_1, y_1), \dots, (x_m, y_m)\}$, $x \in X, y \in \{-1; +1\}$ – валидационная выборка

$\{(x_1, y_1), \dots, (x_k, y_k)\}$, $x \in X, y \in \{-1; +1\}$ – тестовая выборка

α, β – вероятности ошибок первого и второго рода

T – количество слабых классификаторов

Выход: $\theta_A^{[t]}, \theta_B^{[t]}$ – уточненные границы *WaldBoost*

H_T – ансамбль слабых алгоритмов (*Real AdaBoost*)

Константы: n_{max} – максимальное количество итераций ($n_{max} = 10$),

λ, k – коэффициенты, определяющие величину изменения границ на каждом шаге ($\lambda = 0.8, k = 0.02$)

1: **Задать** значения границ *SPRT*: $A^{[0]} = \frac{1-\beta}{\alpha}, B^{[0]} = \frac{\beta}{1-\alpha}$

2: **Задать** начальное значение переменной $ASN_{tmp} = +\infty$, определяющей текущую наименьшую среднюю длину серий слабых классификаторов

3: **Для** $i = 0, \dots, n_{max}$ **выполнять:**

3.1: **Рассчитать** H_T и $\theta_{A_i}^{[t]}, \theta_{B_i}^{[t]}$ в соответствии с **алгоритмом 1.1** (Обучение *WaldBoost*) с использованием границ $A^{[i]}, B^{[i]}$.

3.2: **Рассчитать** \hat{y} и среднюю серию используемых слабых классификаторов (*ASN*) для всех объектов тестовой выборки в соответствии с **алгоритмом 1.3** (Классификация *WaldBoost*)

3.3: **Рассчитать** оценки вероятностей ошибок $\hat{\alpha}, \hat{\beta}$:

$$\hat{\alpha} = \sum_{i=1}^{k_+} \mathbb{I}_{[\hat{y}_i \neq y_i]} - \text{доля неправильно классифицированных положительных объектов тестовой выборки}$$

$\hat{\beta} = \sum_{i=1}^{k_-} \mathbb{I}_{[\hat{y}_i = -y_i]}$ – доля неправильно классифицированных отрицательных объектов тестовой выборки

3.4: **Рассчитать** величины невязок оценок $\hat{\alpha}$ и $\hat{\beta}$ от α , β :

$$\Delta_{\alpha}^{[i]} = \hat{\alpha}^{[i]} - \alpha,$$

$$\Delta_{\beta}^{[i]} = \hat{\beta}^{[i]} - \beta.$$

3.5: **Если** $\Delta_{\alpha}^{[i]} \leq 0$, $\Delta_{\beta}^{[i]} \leq 0$ и $ASN \leq ASN_{imp}$ (т. е. если ограничение на вероятности ошибок соблюдено, при этом средняя серия оказалась меньше текущей), **то**:

$$\theta_A^{[t]} = \theta_{Ai}^{[t]};$$

$$\theta_B^{[t]} = \theta_{Bi}^{[t]};$$

$$ASN_{imp} = ASN.$$

3.6: Вычислить уточненные границы :

$$A^{[i+1]} = \exp \left[\log(A^{[i]}) - \frac{\lambda}{(1+ki)} \frac{\Delta_{\beta}^{[i]}}{\hat{\beta}} \right],$$

$$B^{[i+1]} = \exp \left[\log(B^{[i]}) + \frac{\lambda}{(1+ki)} \frac{\Delta_{\alpha}^{[i]}}{\hat{\alpha}} \right].$$

4: Завершить алгоритм

Алгоритм 1.1 – Обучение *WaldBoost* [7]

Вход: $\{(x_1, y_1), \dots, (x_n, y_n)\}$, $x \in X, y \in \{-1; +1\}$ – обучающая выборка

$\{(x_1, y_1), \dots, (x_m, y_m)\}$, $x \in X, y \in \{-1; +1\}$ – валидационная выборка

α, β – вероятности ошибок первого и второго рода

T – количество слабых классификаторов

A, B – значения границ *SPRT*

Выход: H_T – ансамбль слабых алгоритмов (*Real AdaBoost*)

$\theta_A^{[t]}, \theta_B^{[t]}$ – границы принятия решений

Константы:

1: **Инициализировать** веса объектов x_i : $w_i^{[0]} = 1/n$

2: Для $t = 1, \dots, T$ **выполнять**:

2.1: **Выбрать** слабый классификатор h_t (используя Алгоритм 1.2 Обучение слабого классификатора *Real AdaBoost*):

$$h_t = \frac{1}{2} \log \frac{P(y = +1 | x, w^{[t-1]})}{P(y = -1 | x, w^{[t-1]})}$$

2.2: **Вычислить** оценки плотностей $p(H_t | y = +1)$ и $p(H_t | y = -1)$ на валидационном наборе исходных данных с помощью метода Парзенковского окна, используя гауссово ядро и полосу пропускания $h = 1.144\sigma n^{-1/5}$, формирующую сильно сглаженную функцию плотности:

$$p(H_t | y = +1) = \frac{1}{m_+} \sum_{i=0}^{m_+} \frac{1}{\sqrt{2\pi h_+}} \exp \left[-\frac{H_t - H_t(x_i)}{2h_+} \right],$$

$$p(H_t | y = -1) = \frac{1}{m_-} \sum_{i=0}^{m_-} \frac{1}{\sqrt{2\pi h_-}} \exp \left[-\frac{H_t - H_t(x_i)}{2h_-} \right].$$

2.3: **Вычислить** оценку отношения правдоподобия \hat{R}_t :

$$\hat{R}_t = \frac{p(H_t | y = -1)}{p(H_t | y = +1)}$$

2.4: **Вычислить** границы принятия решения $\theta_A^{[t]}, \theta_B^{[t]}$:

$$\theta_A^{[t]} = \arg \max_x \hat{R}_t \geq A,$$

$$\theta_B^{[t]} = \arg \min_x \hat{R}_t \leq B.$$

2.5: **Убрать** из обучающей выборки объекты, для которых:

$$H_t \geq \theta_B^{[t]} \text{ или } H_t \leq \theta_A^{[t]}.$$

2.6: **Добавить** в обучающую выборку новые объекты и нормировать веса $w_i^{[t]}$

3: **Завершить алгоритм**

Алгоритм 1.2 – Обучение слабого классификатора *Real AdaBoost* [9]

Вход: $\{(x_1, y_1), \dots, (x_n, y_n)\}$, $x \in X, y \in \{-1; +1\}$ – обучающая выборка

$\{(x_1, y_1), \dots, (x_m, y_m)\}$, $x \in X, y \in \{-1; +1\}$ – валидационная выборка

H_t – ансамбль слабых алгоритмов (*Real AdaBoost*)

Выход: h_t, w_i

Константы: –

1: **Обучить** слабый классификатор h_t на обучающей выборке используя веса w_i

2: **Вычислить** взвешенные оценки вероятностей классов:

$$P(y = +1 | x, w^{[t-1]})$$

$$P(y = -1 | x, w^{[t-1]})$$

3: **Вычислить** значение t -го слабого классификатора:

$$h_t = \frac{1}{2} \log \frac{P(y = +1 | x, w^{[t-1]})}{P(y = -1 | x, w^{[t-1]})}.$$

4: **Обновить** значения весов $w_i^{[t]}$:

$$w_i^{[t]} = w_i^{[t-1]} \exp \left(-\frac{1}{2} y_i^T \log p^{(m)}(x_i) \right), i = 1, \dots, n$$

5: **Нормировать** веса w_i

6: **Завершить алгоритм**

Алгоритм 1.3 – Классификация *WaldBoost* [7]

Вход: объект $x \in X$

H_T – ансамбль слабых алгоритмов (*Real AdaBoost*)

$\theta_A^{[t]}, \theta_B^{[t]}$ – границы принятия решений

Выход: $y \in \{-1; +1\}$

Константы: –

1: Для $t = 0, \dots, T$ выполнять:

1.1: **Вычислить** значение слабого классификатора h_t

1.2: **Вычислить** значение текущей серии классификаторов $H_t = \sum_{i=1}^t h_i$

1.3: **Если** $H_t \geq \theta_B^t$, то отнести объект x к классу $y = +1$.

1.3.1: **Завершить алгоритм**

1.4: **Если** $H_t \leq \theta_A^t$, то отнести объект x к классу $y = -1$.

1.4.1: **Завершить алгоритм**

2: **Если** $H_T \geq 0$, то отнести объект x к классу $y = +1$, иначе отнести к классу $y = -1$.

3: **Завершить алгоритм**

Статистический эксперимент

Вычислительный эксперимент проводился на различных моделируемых наборах данных $\{(x_1, y_1), \dots, (x_n, y_n)\}$, $x \in X, y \in \{-1; +1\}$, показанных на рис. 1, далее приводятся результаты, полученные при классификации объектов моделируемого набора данных, изображенного на рис. 1а).

На рис. 2 показана кривая обучения классификаторов *Real AdaBoost*, полученная как на обучающих, так и на тестовых данных (обучающие данные из рис. 1б).

На рис. 3 показана средняя серия слабых классификаторов (сравнительная эффективность) алгоритмов *Real Adaboost*, *WaldBoost* и *Modified AdaBoost* для используемого набора данных (на тестовой выборке). При использовании *Improved WaldBoost* потребовалось приблизительно в полтора раза меньше классификаторов, чем в случае *WaldBoost*, и в два раза меньше, чем в случае *Real AdaBoost*, что показывает высокую эффективность алгоритма. Уменьшение количества используемых слабых классификаторов связано с тем, что при использовании *WaldBoost* фактические риски, как правило, значительно ниже заданных (если полученные фактические вероятности ошибок классификации выше заданных, то алгоритм не обеспечивает заданной достоверности), что дает более надежный результат, но при этом теряется скорость классификации. Стоит отметить, что в случае использования *Modified WaldBoost* время, используемое для обучения алгоритма, сильно возрастает, что может быть ограничением для его применения.

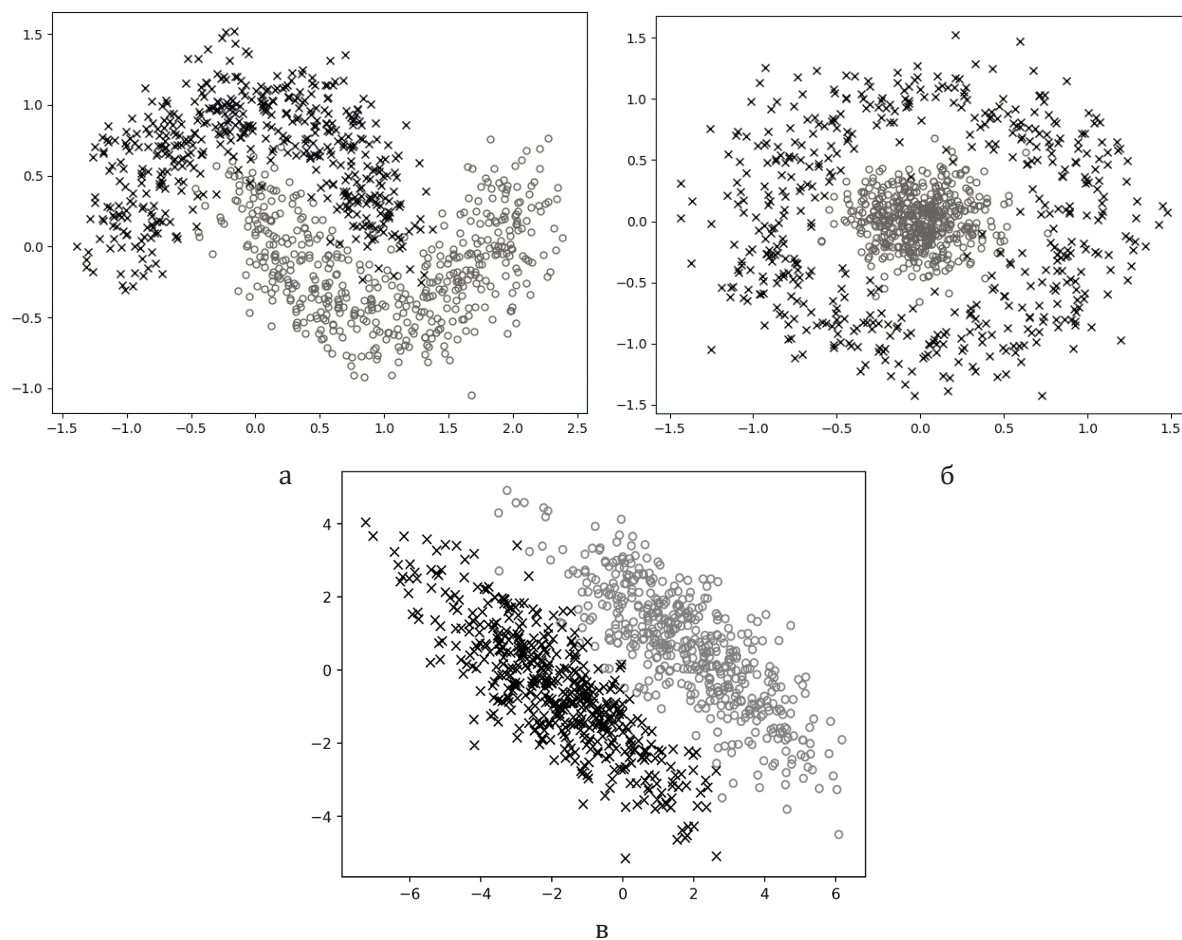


Рис. 1. Моделируемые наборы данных (обучающая выборка):
 “о” соответствует классу $y = +1$, “х” – классу $y = -1$.




Рис. 2. Кривая обучения *Real Adaboost* на моделируемом наборе данных
 (1 – на обучающем наборе данных, 2 – на тестовом наборе данных).




Рис. 3. Средняя серия слабых классификаторов алгоритмов *Real Adaboost*, *WaldBoost* и *Refined AdaBoost* при решении рассматриваемой задачи.

Заключение

Предложен мета-алгоритм *Modified WaldBoost* для уточнения границ принятия решения о классификации объектов при распознавании образов, позволяющий при заданной точности результатов классификации сократить продолжительность вычислений по сравнению с исходным алгоритмом *WaldBoost*. Показана эффективность предложенного алгоритма на некоторых наборах данных.

Авторы надеются, что использование результатов проведенного исследования позволит расширить возможности практического использования ансамблевых методов обучения, основанных на усилении слабых классификаторов и последовательного анализа в технических приложениях.

Результаты работы могут быть применены для уточнения других каскадных классификаторов (не только *AdaBoost*), использующих различные функции потерь, методы отбора признаков и выбора слабых классификаторов.

Список итературы / References:

1. Freund Y., Schapire R. A decision-theoretic generalization of on-line learning and an application to boosting. *J. Comp. & System Sci.* 1997;55(1):119-139. <https://doi.org/10.1006/jcss.1997.1504>
2. Friedman J. Greedy function approximation: A gradient boosting machine. *The Annals of Statistics.* 2001;29(5):1189-1232. <https://doi.org/10.1109/SMRLO.2016.83>.
3. Wald A. *Sequential Analysis*. NY: John Wiley and Sons, 1947. 212 p.
4. Tartakovsky A., Nikiforov I., Basseville M. *Sequential analysis: Hypothesis testing and changepoint detection*. Boca Raton: CRC press/Taylor & Francis, 2015. 579 p.
5. Chesalin A., Grodzenskiy S., Grodzenskiy Ya. About the effectiveness of the statistical sequential analysis in the reliability trials. In: *2016 Second Int. Symp. on Stochastic Models in Reliability Engineering, Life Science and Operations Management (SMRLO)*. Beer Sheva, Israel, February 15–18, 2016. P. 475-480. <https://doi.org/10.1109/SMRLO.2016.83>

6. Yanjing O., Nan C., Michael B. An efficient multivariate control charting mechanism based on SPRT. *Int. J. Production Res.* 2015;53(7):1937-1949. <https://doi.org/10.1080/00207543.2014.925601>
7. Sochman J., Matas J. WaldBoost – Learning for time constrained sequential detection. In: *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*. June 20–25, 2005. P. 150-156. <https://doi.org/10.1109/CVPR.2005.373>
8. Chesalin A., Grodzenskiy S. The algorithm of calculating the refined boundaries of sequential criteria based on the likelihood ratio. In: *Proceed. of the Int. Seminar on Electron Devices Design and Production (SED)*. April 23–24, 2019. Prague, Czech Republic, 2019. 4 p. IEEE Catalog Number: CFP19P59-CDR. <https://doi.org/10.1109/SED.2019.8798445>
9. Zhu J., Rosset S., Zou H., Hastie T. Multi-class AdaBoost. *Statistics and its Interface*. 2006;2(1): 21 p. <https://doi.org/10.4310/SII.2009.v2.n3.a8>

Об авторах:

Чесалин Александр Николаевич, кандидат технических наук, доцент кафедры компьютерной и информационной безопасности Института кибернетики ФГБОУ ВО «МИРЭА – Российский технологический университет» (119454, Россия, Москва, пр-т Вернадского, д. 78). E-mail: chesalin_an@mail.ru

Гродзенский Сергей Яковлевич, доктор технических наук, профессор, профессор кафедры метрологии и стандартизации Физико-технологического института ФГБОУ ВО «МИРЭА – Российский технологический университет» (119454, Россия, Москва, пр-т Вернадского, д. 78). <https://orcid.org/0000-0003-1965-5624>, ResearcherID: AAA-8359-2019

Нилов Михаил Юрьевич, аспирант кафедры метрологии и стандартизации Физико-технологического института ФГБОУ ВО «МИРЭА – Российский технологический университет» (119454, Россия, Москва, пр-т Вернадского, д. 78). <https://orcid.org/0000-0002-3621-4671>

Агафонов Алексей Николаевич, выпускник кафедры компьютерной и информационной безопасности Института кибернетики ФГБОУ ВО «МИРЭА – Российский технологический университет» (119454, Россия, Москва, пр-т Вернадского, д. 78). <https://orcid.org/0000-0001-8312-3265>

About the authors:

Aleksandr N. Chesalin, Cand. of Sci. (Engineering), Associate Professor of the Chair of Computer and Information Security, Institute of Cybernetics, MIREA – Russian Technological University (78, Vernadskogo pr., Moscow 119454, Russia). E-mail: chesalin_an@mail.ru

Sergey Ya. Grodzenskiy, Dr. of Sci., Professor of the Chair of Metrology and Standardization, Institute of Physics and Technology, MIREA – Russian Technological University (78, Vernadskogo pr., Moscow 119454, Russia). <https://orcid.org/0000-0003-1965-5624>, ResearcherID: AAA-8359-2019

Mikhail Yu. Nilov, Postgraduate Student, the Chair of Metrology and Standardization, Institute of Physics and Technology, MIREA – Russian Technological University (78, Vernadskogo pr., Moscow 119454, Russia). <https://orcid.org/0000-0002-3621-4671>

Aleksey N. Agafonov, Master, the Chair of Computer and Information Security, Institute of Cybernetics, MIREA – Russian Technological University (78, Vernadskogo pr., Moscow 119454, Russia). <https://orcid.org/0000-0001-8312-3265>