

## МОДЕЛИРОВАНИЕ ФИЗИОЛОГИЧЕСКИХ ПОКАЗАТЕЛЕЙ НА УРОВНЕ ПОРОГА АНАЭРОБНОГО ОБМЕНА С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

**А.Е. Чиков**<sup>1</sup>, [chikov.alexandr@yandex.ru](mailto:chikov.alexandr@yandex.ru), <https://orcid.org/0000-0003-0860-9171>  
**Е.А. Павлов**<sup>2</sup>, [pavlov.e.a.3@gmail.com](mailto:pavlov.e.a.3@gmail.com), <https://orcid.org/0000-0002-7437-6153>  
**Н.А. Егоров**<sup>1</sup>, [e-nikolay78@mail.ru](mailto:e-nikolay78@mail.ru), <https://orcid.org/0000-0001-6578-051X>  
**Д.С. Медведев**<sup>1,3</sup>, [79110982285@yandex.ru](mailto:79110982285@yandex.ru), <https://orcid.org/0000-0001-7401-258X>  
**С.Н. Чикова**<sup>1</sup>, [chikova.svetlana@yandex.ru](mailto:chikova.svetlana@yandex.ru), <https://orcid.org/0000-0002-1696-5101>  
**П.Д. Дробинцев**<sup>2</sup>, [drobintsev\\_pd@spbstu.ru](mailto:drobintsev_pd@spbstu.ru), <https://orcid.org/0000-0003-1116-7765>

<sup>1</sup>Научно-исследовательский институт гигиены, профпатологии и экологии человека  
ФМБА России, Санкт-Петербург, Россия

<sup>2</sup>Санкт-Петербургский политехнический университет Петра Великого, Санкт-Петербурга,  
Россия

<sup>3</sup>Северо-Западный государственный медицинский университет им. И.И. Мечникова,  
Санкт-Петербург, Россия

**Аннотация.** Цель исследования – разработка модели предсказания количественных значений физиологических показателей работы организма на уровне порога анаэробного обмена при выполнении эргоспирометрического нагрузочного тестирования до отказа с использованием алгоритмов машинного обучения. **Материалы и методы.** Обработаны результаты 1273 наблюдений спортсменов в возрасте 18–35 лет. Спортсмены выполняли ступенчато-возрастающую нагрузку на беговой дорожке до отказа. Для определения физиологических показателей на уровне порога анаэробного обмена были разработаны модели на основе алгоритмов машинного обучения из библиотеки Scikit-learn: линейная регрессия, регрессионный случайный лес, градиентный бустинг, регрессионные вектора. **Результаты.** Модель на основе алгоритма регрессионных векторов показывает наилучшие метрики по показателям ЧСС, МОД,  $O_2/ЧСС$  ( $r^2$  составляет 0,82; 0,90; 0,91 соответственно), а по показателям  $VO_2$ ,  $VCO_2$  несколько уступает (–0,76 % и –0,16 % соответственно) алгоритму линейной регрессии ( $r^2$  составляет 0,87; 0,86 соответственно). **Заключение.** Количественные значения показателей точности разработанной модели на основе алгоритма регрессионных векторов сопоставимы с результатами аналогичных работ, что дает возможность использования ее в качестве рекомендательной системы для помощи специалистам в исследованиях, целью которых является определение количественных значений показателей на уровне ПАНУ. Слабым местом модели является использование признаков, зависящих от протокола нагрузки, поэтому дальнейшее совершенствование модели будет направлено на нивелирование этого недостатка.

**Ключевые слова:** порог анаэробного обмена, машинное обучение, ступенчато-возрастающее тестирование, модель

**Для цитирования:** Моделирование физиологических показателей на уровне порога анаэробного обмена с использованием методов искусственного интеллекта / А.Е. Чиков, Е.А. Павлов, Н.А. Егоров и др. // Человек. Спорт. Медицина. 2022. Т. 22, № S2. С. 46–53. DOI: 10.14529/hsm22s206

**ARTIFICIAL INTELLIGENCE MODELING OF PHYSIOLOGICAL PARAMETERS  
AT ANAEROBIC THRESHOLD****A.E. Chikov**<sup>1</sup>, [chikov.alexandr@yandex.ru](mailto:chikov.alexandr@yandex.ru), <https://orcid.org/0000-0003-0860-9171>**E.A. Pavlov**<sup>2</sup>, [pavlov.e.a.3@gmail.com](mailto:pavlov.e.a.3@gmail.com), <https://orcid.org/0000-0002-7437-6153>**N.A. Egorov**<sup>1</sup>, [e-nikolay78@mail.ru](mailto:e-nikolay78@mail.ru), <https://orcid.org/0000-0001-6578-051X>**D.S. Medvedev**<sup>1,3</sup>, [79110982285@yandex.ru](mailto:79110982285@yandex.ru), <https://orcid.org/0000-0001-7401-258X>**S.N. Chikova**<sup>1</sup>, [chikova.svetlana@yandex.ru](mailto:chikova.svetlana@yandex.ru), <https://orcid.org/0000-0002-1696-5101>**P.D. Drobintsev**<sup>2</sup>, [drobintsev\\_pd@spbstu.ru](mailto:drobintsev_pd@spbstu.ru), <https://orcid.org/0000-0003-1116-7765><sup>1</sup>Research Institute of Hygiene, Occupational Pathology and Human Ecology, Saint Petersburg, Russia<sup>2</sup>Peter the Great Saint Petersburg Polytechnic University, Saint Petersburg, Russia<sup>3</sup>North-Western State Medical University named after I.I. Mechnikov, Saint Petersburg, Russia

**Abstract. Aim.** The paper aims to develop a predictive model of quantitative physiological parameters at anaerobic threshold during the exercise test to fatigue by means of artificial intelligence. **Materials and methods.** The study involved 1273 athletes aged from 18 to 35 years. All athletes performed incremental exercise to fatigue. Physiological parameters at anaerobic threshold were obtained with machine learning algorithms from the Scikit-learn library: linear regression, regression random forest, gradient boosting regression, support vector regression. **Results.** The support vector regression algorithm achieves the best results for heart rate, minute respiratory volume, and O<sub>2</sub>/HR ( $r^2$  is 0.82, 0.90, and 0.91, respectively). In terms of VO<sub>2</sub>, VCO<sub>2</sub>, the support vector regression algorithm is inferior in prediction accuracy to the linear regression algorithm ( $r^2$  is 0.87, 0.86, respectively) by  $-0.76\%$  and  $-0.16\%$ , respectively. **Conclusion.** The quantitative accuracy of the model based on the support vector regression algorithm is comparable with the results of similar studies. Thus, it allows us to use it as a recommendation system for measuring quantitative parameters at anaerobic threshold. The weak point of the model is the use of protocol-dependent load attributes, so further improvement of the model will be aimed at correcting this shortcoming.

**Keywords:** anaerobic threshold, machine learning, incremental exercise, model

**For citation:** Chikov A.E., Pavlov E.A., Egorov N.A., Medvedev D.S., Chikova S.N., Drobintsev P.D. Artificial intelligence modeling of physiological parameters at anaerobic threshold. *Human. Sport. Medicine*. 2022;22(S2):46–53. (In Russ.) DOI: 10.14529/hsm22s206

**Введение.** Уровень порога анаэробного обмена (ПАНО) является важным диагностическим критерием для оценки подготовленности спортсмена, является одной из отправных точек планирования и корректировки тренировочного процесса. Концепция анаэробного порога и методы его определения разрабатывались на протяжении всего XX века [4, 21] и по настоящее время [2, 10, 11, 13, 20]. До сих пор в научном сообществе нет единого мнения о самой сути явления «анаэробного порога» и точности методов его определения. Очевидно то, что при некотором уровне нагрузки наблюдается резкое изменение физиологических и биохимических показателей, сигнализирующих о метаболическом ацидозе и увеличении вклада анаэробного лактатного механизма в энергообеспечение мышечной деятельности [6, 21]. Основная тенденция в

развитии методов определения уровня ПАНО заключается в упрощении методики измерения физиологических и биохимических показателей, уменьшении количества необходимых регистрируемых показателей, поиске новых параметров, имеющих высокие корреляты с наблюдаемыми физиологическими изменениями [2, 11, 15, 19, 22]. Самым доступным для измерения является частота сердечных сокращений, в литературе можно найти как минимум три способа определения ПАНО на его основе [3, 9, 16]. Выполняются работы по определению ПАНО на основе изменения показателей поверхностной миографии работающих мышц [8, 9, 16], изменения биомеханической структуры движения спортивной техники при переходе ПАНО [1]. Таким образом, каждая методика имеет свои сильные и слабые стороны. При этом некото-

рые методики основаны на прямых показателях, требующих дорогостоящего оборудования, являются инвазивными и сложными в техническом исполнении, но они достаточно точные, другие используют косвенные показатели, более простые в использовании, но при этом менее точные и требующие дальнейшего изучения. Определение ПАНО с использованием этих методов требует профессионального навыка, поэтому возникает потребность в разработке рекомендательной системы определения ПАНО. В настоящее время это становится реализуемой задачей, чему способствует стремительный рост возможностей цифровых технологий, накопление баз данных. Разработана математическая модель метаболизма лактата при выполнении физических упражнений [17], предложена математическая модель потребления кислорода во время тестирования и восстановления [12]. Авторы U. Etchegaraiа и др. создали модель определения ПАНО с использованием неинвазивных показателей и алгоритмов ML, где удалось достичь точности определения ПАНО у спортсменов 89,52 % ( $r = 0,89$ ) [5]. A. Zignoli и соавторы разработали способ определения вентиляционных порогов легких (VT1 и VT2) на основе рекуррентных нейронных сетей, обученных с помощью базы данных из 228 лабораторных данных [22]. Система была протестирована физиологами по 25 тестам. Нейронная сеть достигла экспертных показателей по всем заданиям (средняя абсолютная ошибка составила 9,5 % ( $r = 0,79$ ) и 4,2 % ( $r = 0,94$ ) для VT1 и VT2 соответственно). Ошибки оценки совместимы с типичной ошибкой текущей визуальной методологии золотого стандарта.

**Цель исследования** – разработка модели предсказания количественных значений физиологических показателей работы организма на уровне порога анаэробного обмена при выполнении эргоспирометрического нагрузочного тестирования до отказа с использованием алгоритмов машинного обучения.

**Материалы и методы.** Для разработки модели предсказания количественных значений были обработаны результаты 1273 наблюдений спортсменов мужского пола в возрасте 18–35 лет ( $24,5 \pm 0,27$  года), длиной тела  $178,4 \pm 0,39$  см, массой тела  $76,7 \pm 0,63$  кг, имеющих спортивный разряд от третьего взрослого до кандидата мастера спорта. Спортсмены выполняли ступенчато-возрастающую нагрузку

на беговой дорожке до отказа по следующему протоколу: первая ступень – 5 км/ч, длина ступени – 2 мин, высота ступени – 1,5 км/ч. Перед тестированием, в состоянии относительного покоя, во время тестирования и в период восстановления (15 минут) фиксировались показатели газообмена, ЧСС с использованием эргоспирометрической системы «OxyconPro» (ErichJaeger, Германия). Критерием остановки являлись отказ спортсмена или достижение предельного максимального расчетного ЧСС по формуле «220 – возраст». Критерием достижения ПАНО считался устойчивый переход дыхательного коэффициента более 1,0.

В качестве исходных показателей, на которых проводилось обучение алгоритмов искусственного интеллекта, использовали частоту сердечных сокращений (ЧСС, уд./мин), минутный объем дыхания (МОД, л), частоту дыхания (ЧД, ед./мин), потребление кислорода ( $VO_2$ , мл/мин/кг), выделение углекислого газа ( $VCO_2$  мл/мин/кг), респираторный коэффициент (RER), эквивалент  $O_2$  ( $EqO_2$ , %) и  $CO_2$  ( $EqCO_2$ , %), пиковую концентрацию  $O_2$  ( $PETO_2$ , мм рт. ст.) и  $CO_2$  ( $PETCO_2$ , мм рт. ст.) перед нагрузкой, на пике нагрузки, в период восстановления в конце 1, 2, 3, 4, 5-й минут, а также рассчитывали объем потребления кислорода, выделения углекислого газа, частоту сердечных сокращений сверх уровня покоя за весь период нагрузки, за двух- и пятнадцатиминутный периоды восстановления. Разрабатываемая модель на основе алгоритмов машинного обучения (ML) предсказывает количественные значения целевых показателей на уровне ПАНО: ЧСС, МОД,  $VO_2$ ,  $VCO_2$ ,  $O_2/ЧСС$ .

Математическая обработка данных и моделирование проводились с использованием библиотек Python 3.7. Для разработки модели использованы четыре алгоритма ML из библиотеки Scikit-learn:

- линейной регрессии (linear regression) – LR;
- регрессионного случайного леса (random forest regression) – RFR;
- градиентного бустинга (Gradient boosting regression) – GBR;
- регрессионных векторов (Support Vector Regression) – SVR.

Стандартная процедура гиперпараметрической оптимизации моделей осуществлялась с помощью случайного подбора (Randomized Search) и подбора параметров по сетке (Grid

Таблица 1  
Table 1

Значения гиперпараметров алгоритмов ML для целевых показателей  
Values of hyperparameters of ML algorithms for target indicators

| Алгоритм<br>Algorithm<br>ML* | Гиперпараметр<br>Hyperparameter | HR    | VE    | VO <sub>2</sub> | VCO <sub>2</sub> | O <sub>2</sub> HR |
|------------------------------|---------------------------------|-------|-------|-----------------|------------------|-------------------|
| RFR                          | n_estimators                    | 900   | 900   | 800             | 800              | 800               |
|                              | max_features                    | auto  | auto  | auto            | auto             | Auto              |
|                              | max_depth                       | 90    | 95    | 80              | 90               | None              |
|                              | min_samples_split               | 5     | 2     | 5               | 2                | 2                 |
|                              | min_samples_leaf                | 2     | 2     | 2               | 2                | 2                 |
| GBR                          | n_estimators                    | 600   | 900   | 800             | 800              | 900               |
|                              | max_features                    | Auto  | auto  | auto            | auto             | Auto              |
|                              | max_depth                       | 85    | 95    | 80              | 90               | 90                |
|                              | min_samples_split               | 5     | 6     | 5               | 3                | 3                 |
|                              | min_samples_leaf                | 4     | 8     | 4               | 2                | 2                 |
| SVR                          | loss                            | huber | huber | huber           | huber            | huber             |
|                              | Ядро                            | rbf   | rbf   | rbf             | rbf              | rbf               |
|                              | C                               | 10500 | 10100 | 10100           | 1100             | 10000             |
|                              | Гамма                           | 0,01  | 0,03  | 0,1             | 0,1              | 0,01              |
|                              | Эпсилон                         | 0,5   | 0,5   | 0,1             | 0,5              | 0,1               |

Search) и, учитывая переобучение, с помощью перекрестной проверки. Перед настройкой и оценкой моделей проводилась нормализация признаков. Полученные количественные значения гиперпараметров используемых алгоритмов ML, полученные в результате Randomized Search и Grid Search, представлены в табл. 1. Для алгоритма линейной регрессии подбор гиперпараметров не проводился, так как в библиотеке Scikit-learn отсутствуют гиперпараметры для данного алгоритма, которые мы можем настроить для текущих исходных данных.

**Результаты исследования.** Средние значения ( $M \pm m$ ) признаков, полученных в рамках нагрузочного тестирования в состоянии покоя, на уровне порога анаэробного обмена и пике нагрузки (табл. 2), являются закономерными и соответствуют литературным данным [18, 20]. Удельная величина макси-

мального потребления кислорода с учетом массы тела ( $76,7 \pm 0,63$  кг) спортсмена составляет  $50,87$  мл/кг, что является средним уровнем для спортсменов-разрядников.

Качество разработанных методов машинного обучения (LR, RFR, GBR, SVR) оценивалось с использованием коэффициента детерминации ( $r^2$ ), количественные значения представлены в табл. 3.

Из табл. 3 видно, что наименее точно на уровне ПАНО предсказывается показатель ЧСС, коэффициент детерминации разных алгоритмов колеблется от 0,66 до 0,82. Показатели МОД, VO<sub>2</sub>, VCO<sub>2</sub>, O<sub>2</sub>/ЧСС предсказываются моделями достаточно хорошо ( $r^2 > 0,8$ ). Наилучшие значения точности ( $r^2 = 0,91$ ) предсказания получены для показателей VO<sub>2</sub>, O<sub>2</sub>/ЧСС методом линейной регрессии и O<sub>2</sub>/ЧСС методом регрессионных векторов. Таким образом, для определения количественных зна-

Таблица 2  
Table 2

Количественные значения показателей в состоянии покоя, ПАНО и пике нагрузки (n=1273)  
Quantitative values at rest, anaerobic threshold and maximal exercise (n = 1273)

| Признаки<br>Parameter                                 | Покой<br>Rest    | ПАНО<br>Anaerobic threshold | Пик нагрузки<br>Maximal exercise |
|---|------------------|-----------------------------|----------------------------------|
| ЧСС, уд./мин / HR, bpm                                | $86,2 \pm 0,35$  | $171,31 \pm 0,43$           | $186,74 \pm 0,31$                |
| МОД, л/мин<br>Respiratory minute volume, l/min        | $14,85 \pm 0,09$ | $95,96 \pm 0,67$            | $132,56 \pm 0,69$                |
| VO <sub>2</sub> , мл/мин / VO <sub>2</sub> , ml/min   | $481 \pm 2,9$    | $3357 \pm 18,61$            | $3902 \pm 16,22$                 |
| VCO <sub>2</sub> , мл/мин / VCO <sub>2</sub> , ml/min | $395 \pm 2,6$    | $3365 \pm 18,53$            | $4323 \pm 19,15$                 |
| O <sub>2</sub> /ЧСС, мл / O <sub>2</sub> /HR, ml      | $5,65 \pm 0,04$  | $19,65 \pm 0,20$            | $20,91 \pm 0,10$                 |

Таблица 3  
Table 3

Коэффициенты детерминации целевых показателей рассматриваемых моделей  
Determination coefficients of the target parameters of the considered models

| Целевые признаки / Targetparameter       | LR   | RFR  | GBR  | SVR  |
|--|------|------|------|------|
| ЧСС / HR                                 | 0,72 | 0,72 | 0,66 | 0,82 |
| МОД / Respiratory minute volume          | 0,89 | 0,82 | 0,86 | 0,90 |
| VO <sub>2</sub>                          | 0,91 | 0,86 | 0,87 | 0,87 |
| VCO <sub>2</sub>                         | 0,90 | 0,86 | 0,85 | 0,86 |
| O <sub>2</sub> /ЧСС / O <sub>2</sub> /HR | 0,91 | 0,86 | 0,79 | 0,91 |

Таблица 4  
Table 4

Количественные значения RMSE показателей ПАНО  
в методах регрессионных векторов и линейной регрессии  
Quantitative values of RMSE atAT in the considered models

| Целевые признаки / Targetparameter                    | LR     | SVR    | Δ, %  |
|---|--------|--------|-------|
| ЧСС, уд./мин / HR, bpm                                | 8,11   | 7,47   | 7,89  |
| МОД, л/мин / Respiratory minute volume, l/min         | 8,04   | 7,18   | 10,70 |
| VO <sub>2</sub> , мл/мин / VO <sub>2</sub> , ml/min   | 201,32 | 202,86 | -0,76 |
| VCO <sub>2</sub> , мл/мин / VCO <sub>2</sub> , ml/min | 210,81 | 211,14 | -0,16 |
| O <sub>2</sub> /ЧСС, мл / O <sub>2</sub> /HR, ml      | 1,28   | 1,18   | 7,81  |

Таблица 5  
Table 5

Исходные и предсказанные значения валидационной выборки на уровне ПАНО  
Baseline and predicted values of the validation sample at anaerobic threshold

| Целевые признаки / Targetfeatures                     | Исходные значения<br>Baselinevalues | Предсказанные значения<br>Predicted values |
|---|-------------------------------------|--|
| ЧСС, уд./мин / HR, bpm                                | 171,40 ± 0,90                       | 172,16 ± 0,80                              |
| МОД, л/мин / Respiratory minute volume, l/min         | 97,75 ± 1,35                        | 97,21 ± 1,26                               |
| VO <sub>2</sub> , мл/мин / VO <sub>2</sub> , ml/min   | 3365 ± 37,78                        | 3377 ± 34,24                               |
| VCO <sub>2</sub> , мл/мин / VCO <sub>2</sub> , ml/min | 3373 ± 37,86                        | 3383 ± 33,88                               |
| O <sub>2</sub> /ЧСС, мл / O <sub>2</sub> /HR, ml      | 19,65 ± 0,20                        | 19,51 ± 0,18                               |

чений ЧСС, МОД, O<sub>2</sub>/ЧСС на уровне ПАНО можно рекомендовать метод регрессионных векторов. Для предсказания показателей VO<sub>2</sub> и VCO<sub>2</sub> – метод линейной регрессии.

Одним из показателей, позволяющих оценивать точность предсказанного значения, является среднеквадратичная ошибка (RMSE) – расстояние между двумя точками: предсказанной и зарегистрированной (табл. 4).

Представленные в табл. 4 значения позволяют заключить аналогичные выводы, сделанные при анализе показателей r<sup>2</sup>. При этом, анализируя изменения качества алгоритма регрессионных векторов относительно алгоритма линейной регрессии, видно, что количественные значения ЧСС, МОД, O<sub>2</sub>/ЧСС предсказываются лучше на 7,89; 10,70 и 7,81 % соответственно, в то же самое время по показателям VO<sub>2</sub> и VCO<sub>2</sub> ухудшение происходит менее 1 % (0,76 и 0,16 % соответственно). Принимая во внимание, что модель, основанная на алгоритме регрессионных векторов,

приводит к незначительному ухудшению по показателям потребления кислорода и выделения углекислого газа, можно рекомендовать его применение для предсказания целевых показателей. Кроме того, минусом линейной регрессии является то, что она хорошо работает только в присутствии линейных связей, однако физиологические процессы, происходящие в организме, в том числе связанные с энергообеспечением, характеризуются нелинейными зависимостями [4, 7]. Таким образом, для определения показателей на уровне ПАНО в дальнейшем представлении материалов мы использовали модель, основанную на алгоритме регрессионных векторов.

Для наглядной демонстрации работы модели на основе алгоритма регрессионных векторов в табл. 5 представлены исходные и предсказанные средние значения и ошибка средней валидационной выборки. Сравнительный анализ полученных значений свидетельствует о том, что данные практически идентичны.

**Заключение.** В ходе выполнения работы разработана модель, предсказывающая количественные значения показатели HR, V'E, VO<sub>2</sub>, VCO<sub>2</sub>, O<sub>2</sub>/HR с точностью r<sup>2</sup>, равной 0,8; 0,9; 0,87; 0,86; 0,91 соответственно, что сопоставимо с результатами аналогичных работ [5], где точность предсказания уровня лактата составила r<sup>2</sup> = 0,89. Одним из недостатков модели является использование признаков, зависящих от протокола нагрузки, такие как: объем потребления кислорода, выделения углекислого газа, частоты сердечных сокращений сверх уровня покоя за весь период нагрузки. Мы предполагаем, что изменение протокола может существенно повлиять на предсказание количественных значений. Необходимость использования различных протоколов обусловлена задачами тестирования и зависит от контингента обследуемых. При этом изменения чаще всего

касаются длительности и высоты ступени, в некоторых протоколах предусматривается не ступенчато-возрастающая, а постепенно возрастающая нагрузка [7, 14]. Несмотря на существующие недостатки, предложенная нами модель может быть использована в разработке рекомендательной системы определения ПАНО. Это имеет важное значение, так как ошибка в определении приводит к некорректному планированию и анализу результатов тренировочного процесса, снижению эффективности подготовки, перетренированности спортсмена [22].

Несмотря на то, что полученная точность достаточно высокая, целесообразно продолжить работу по совершенствованию модели, в частности, предусмотреть коррекцию результатов предсказания количественных значений показателей на уровне ПАНО в зависимости от протокола нагрузки.

#### Список литературы / References

1. Carvalho D.D., Soares S., Zacca R. et al. Anaerobic Threshold Biophysical Characterisation of the Four Swimming Techniques. *Int Journal Sports Medical*, 2020, vol. 41 (5), pp. 318–327. DOI: 10.1055/a-0975-9532
2. Chih-Wei Lin, Chun-Feng Huang, Jong-Shyan Wang et al. Detection of Ventilatory Thresholds Using Near-Infrared Spectroscopy with a Polynomial Regression Model. *Saudi Journal of Biological Sciences*, 2020, vol. 27, pp. 1637–1642. DOI: 10.1016/j.sjbs.2020.03.005
3. Conconi F., Grazze G., Casoni I. et al. The Conconi Test: Methodology After 12 Years of Application. *Int. Journal Sports Medical*, 1996, vol. 17, pp. 509–519. DOI: 10.1055/s-2007-972887
4. Douglas C.G. Coordination of the Respiration and Circulation with Variation in Bodily Activity. *Lancet*, 1927, vol. 312, pp. 213–218. DOI: 10.1016/S0140-6736(01)30762-6
5. Etxegaraia U., Portilloa E., Irazustab J. et al. Estimation of Lactate Threshold with Machine Learning Techniques in Recreational Runners. *Applied Soft Computing*, 2018, vol. 63, pp. 181–196. DOI: 10.1016/j.asoc.2017.11.036
6. Geir S., Robstad B., Skjønberg O.H., Borchsenius F. Respiratory Gas Exchange Indices for Estimating the Threshold. *Journal of Sports Science and Medicine*, 2005, vol. 4, pp. 29–36.
7. Giovanelli N., Scaini S., Billat V., Lazzer S. A New Field Test to Estimate the Aerobic and Anaerobic Thresholds and Maximum Parameters. *European Journal of Sport Science*, 2020, vol. 20 (4), pp. 437–443. DOI: 10.1080/17461391.2019.1640289
8. Joo-ho Ham, Hun-Young Park, Youn-ho Kim et al. Development of an Anaerobic Threshold (HRLT, HRVT) Estimation Equation Using the Heart Rate Threshold (HRT) During the Treadmill Incremental Exercise Test. *Journal Exercise Nutrition Biochemical*, 2017, vol. 21 (3), pp. 43–49. DOI: 10.20463/jenb.2017.0016
9. Kozlov A.V., Vavaev A.V., Yurikov R.V. et al. A Method for the Evaluation of Anaerobic Threshold Based on Heart Rate Dynamics During Incremental Exercise Test and Recovery. *Human Physiology*, 2019, vol. 45 (2), pp. 180–187. DOI: 10.1134/S0362119719020038
10. McGehee J.C., Tanner C.J., Houmard J.A. A Comparison of Methods for Estimating the Lactate Threshold. *Journal of Strength and Conditioning Research*, 2005, vol. 19 (3), pp. 553–558. DOI: 10.1519/15444.1
11. Messias L.H.D., Polisel E.E.C., Machado-Gobatto F.B. Advances of the Reverse Lactate Threshold Test: Non-Invasive Proposal Based on Heart Rate and Effect of Previous Cycling Experience. *Plos ONE*, 2018, vol. 13, pp. 1–20. DOI: 10.1371/journal.pone.0194313

12. Moxnes J.F., Sandbakk Ø. Mathematical Modelling of the Oxygen Uptake Kinetics During Whole-Body Endurance Exercise and Recovery. *Mathematical and Computer Modelling of Dynamical Systems*, 2018, vol. 24 (1), pp. 76–86. DOI: 10.1080/13873954.2017.1348364
13. Najera J., Ortiz G., Lopez A. et al. Non Spirographic or Noninvasive Methods to Estimate Anaerobic Threshold. *Physical Culture*, 2017, vol. 71 (1), pp. 55–62. DOI: 10.5937/fizkul1701055N
14. Nakamura K., Nagasawa Y., Sawaki S., Yokokawa Y. Comparison of Original and Alternative Incremental Sit-to-Stand Exercise Protocol for Anaerobic Threshold Assessment. *Journal Physical Fitness Sports Medical*, 2020, vol. 9 (2), pp. 83–88. DOI: 10.7600/jpfsm.9.83
15. Pallares J.G., Moran-Navarro R., Ortegá J.F. et al. Validity and Reliability of Ventilatory and Blood Lactate Thresholds in Well-Trained Cyclists. *Plos ONE*, 2016, vol. 11 (9), pp. 1–16. DOI: 10.1371/journal.pone.0163389
16. Piucco T., Diefenthaler F., Prosser A., Bini R. Validity of Different EMG Analysis Methods to Identify Aerobic and Anaerobic Thresholds in Speed Skaters. *Journal of Electromyography and Kinesiology*, 2020, vol. 52, 102422. DOI: 10.1016/j.jelekin.2020.102425
17. Proshin A.P., Solodyannikov Yu.V. Mathematical Modeling of Lactate Metabolism with Applications to Sports. *Automation and Remote Control*, 2013, vol. 6, pp. 133–152. DOI: 10.1134/S0005117913060106
18. Ringwood J.V. Anaerobic Threshold Measurement Using Dynamic Neural Network Models Author Links Open Overlay Panel. *Computers in Biology and Medicine*, 1999, vol. 29, pp. 259–271. DOI: 10.1016/S0010-4825(99)00008-6
19. Ringwood J.V., O'Neill J., Tallon P. et al. Non-Invasive Anaerobic Threshold Measurement Using Fuzzy Model Interpolation. *2014 IEEE Conference on Control Applications*, 2014, pp. 1711–1715. DOI: 10.1109/CCA.2014.6981559
20. Vasconcelos G., Canestri R., Prado R.C.R. et al. A Comprehensive Integrative Perspective of the Anaerobic Threshold Engine. *Physiology & Behavior*, 2019, vol. 15, pp. 1–3. DOI: 10.1016/j.physbeh.2019.01.019
21. Wasserman K., Hansen J.E., Sue D.Y. et al. *Principles of Exercise Testing and Interpretation*, 3rd ed. Baltimore: Lipincott Williams & Wilkins, 1999. 551 p.
22. Zignoli A., Fornasiero A., Stella F. et al. Expert-Level Classification of Ventilatory Thresholds From Cardiopulmonary Exercising Test data with Recurrent Neural Networks. *European Journal of Sport Science*, 2019, vol. 19 (9), pp. 1221–1229. DOI: 10.1080/17461391.2019.1587523

#### **Информация об авторах**

**Чиков Александр Евгеньевич**, кандидат биологических наук, доцент, заведующий лабораторией, Научно-исследовательский институт гигиены, профпатологии и экологии человека ФМБА России. Россия, 188663, Ленинградская область, Всеволожский район, г.п. Кузьмоловский, ст. Капитолово, корп. 93.

**Павлов Евгений Алексеевич**, магистр Высшей школы программной инженерии, Санкт-Петербургский политехнический университет Петра Великого. Россия, 195251, Санкт-Петербург, ул. Политехническая, д. 29.

**Егоров Николай Андреевич**, старший научный сотрудник, Научно-исследовательский институт гигиены, профпатологии и экологии человека ФМБА России. Россия, 188663, Ленинградская область, Всеволожский район, г.п. Кузьмоловский, ст. Капитолово, корп. 93.

**Медведев Дмитрий Станиславович**, доктор медицинских наук, профессор, заведующий отделом физиологической оценки и медицинской коррекции, Научно-исследовательский институт гигиены, профпатологии и экологии человека ФМБА России. Россия, 188663, Ленинградская область, Всеволожский район, г.п. Кузьмоловский, ст. Капитолово, корп. 93; профессор кафедры лечебной физкультуры и спортивной медицины, Северо-Западный государственный медицинский университет им. И.И. Мечникова. Россия, 191015, Санкт-Петербург, Кирочная ул., д. 41.

**Чикова Светлана Николаевна**, кандидат биологических наук, доцент, заведующий лабораторией, Научно-исследовательский институт гигиены, профпатологии и экологии человека ФМБА России. Россия, 188663, Ленинградская область, Всеволожский район, г.п. Кузьмоловский, ст. Капитолово, корп. 93.

**Дробинцев Павел Дмитриевич**, кандидат технических наук, доцент, директор Высшей школы программной инженерии, Санкт-Петербургский Политехнический университет Петра Великого, России, 195251, Санкт-Петербург, ул. Политехническая, д. 29.

***Information about the authors***

**Aleksandr E. Chikov**, Candidate of Biological Sciences, Associate Professor, Laboratory Head, Research Institute of Hygiene, Occupational Pathology and Human Ecology, Saint Petersburg, Russia.

**Evgeniy A. Pavlov**, Master's Degree Student, Higher School of Software Engineering, Peter the Great Saint Petersburg Polytechnic University, Saint Petersburg, Russia.

**Nikolay A. Egorov**, Senior Researcher, Research Institute of Hygiene, Occupational Pathology and Human Ecology, Saint Petersburg, Russia.

**Dmitriy S. Medvedev**, Doctor of Medical Sciences, Professor, Head of the Department of Physiological Assessment and Medical Correction, Research Institute of Hygiene, Occupational Pathology and Human Ecology, Saint Petersburg, Russia; Professor of the Department of Exercise Therapy and Sports Medicine, North-Western State Medical University named after I.I. Mechnikov, Saint Petersburg, Russia.

**Svetlana N. Chikova**, Candidate of Biological Sciences, Associate Professor, Laboratory Head, Research Institute of Hygiene, Occupational Pathology and Human Ecology, Saint Petersburg, Russia.

**Pavel D. Drobintsev**, Candidate of Technical Sciences, Associate Professor, Director of the Higher School of Software Engineering, Peter the Great Saint Petersburg Polytechnic University, Saint Petersburg, Russia.

***Статья поступила в редакцию 17.06.2022***

***The article was submitted 17.06.2022***