

Метод определения типа дыхания человека на базе машинного обучения

А. В. Зубков¹ ✉, А. Р. Донская¹, Я. А. Маренков¹,
Ю. С. Гомазкова¹, Д. А. Болгов¹

¹ Волгоградский государственный технический университет
пр-т им. В. И. Ленина, д. 28, г. Волгоград 400005, Российская Федерация

✉ e-mail: zubkov.alexander.v@gmail.com

Резюме

Целью исследования является повышение эффективности дыхательной реабилитации за счет разработки автоматизированных методов определения типа дыхания на базе машинного обучения.

Методы. После пандемии COVID-19 особую важность приобрела респираторная реабилитация, а также методы домашней (удаленной) реабилитации по средствам, предоставляемым современными технологиями, для осуществления которой стали разрабатываться новые методы и средства, в том числе с использованием беспроводных датчиков или систем захвата движения. Особое внимание в ходе дыхательной реабилитации уделяется типу дыхания человека, а также автоматизированным методам по анализу дыхания. На данный момент встает проблема, что большинство разработанных методов по анализу дыхания не работают с типами дыхания: они либо определяют только один тип, например, диафрагмальный, либо просто анализируют состояние легких. В связи с этим возникает потребность в разработке метода для анализа и определения непосредственно типов дыхания человека.

В данной статье рассматриваются три метода для решения задачи определения типа дыхания человека с помощью системы захвата движений и машинного обучения. Первый метод основывается на статических характеристиках, для которого использовалась модель Random Forest. Второй метод, в основе которого используются временные характеристики, использовал модель Catch22. Третий метод, который определяет тип дыхания с помощью характеристик синусоиды, использовал составную модель, основанную на двух моделях Hist Gradient Boosting.

Результаты. Были разработаны три метода для определения типа дыхания человека. Для каждого из методов были обучены модели машинного обучения для нахождения наилучшего результата точности. После проведения сравнительного анализа разработанных подходов определен подход с наилучшей точностью.

Заключение. Разработан метод определения типа дыхания человека на базе машинного обучения, точность работы которого составляет 0,81.

Ключевые слова: анализ типа дыхания; классификация временных данных; модели машинного обучения для классификации данных.

Финансирование: Исследование выполнено при финансовой поддержке ВолгГТУ в рамках научного проекта № 60/478-22, № 60/473-22.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Метод определения типа дыхания человека на базе машинного обучения / А. В. Зубков, А. Р. Донская, Я. А. Маренков, Ю. С. Гомазкова, Д. А. Болгов // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2023. Т. 13, № 2. С. 8–30. <https://doi.org/10.21869/2223-1536-2023-13-2-8-30>.

Поступила в редакцию 02.04.2023

Подписана в печать 20.04.2023

Опубликована 30.06.2023

A Method for Determining the Type of Human Breathing Based on Machine Learning

Alexander V. Zubkov¹ ✉, Anastasia R. Donskaia¹, Yaroslav A. Marenkov¹,
Yulia S. Gomazkova¹, Dmitry A. Bolgov¹

¹ Volgograd State Technical University
28 V. I. Lenin Ave., Volgograd 400005, Russian Federation

✉ e-mail: zubkov.alexander.v@gmail.com

Abstract

The purpose of research is to increase the effectiveness of respiratory rehabilitation through the development of automated methods for determining the type of breathing based on machine learning.

Methods. After the COVID-19 pandemic, respiratory rehabilitation became particularly important, as well as methods of home (remote) rehabilitation using the means provided by modern technologies, for which new methods and means began to be developed, including using wireless sensors or motion capture systems. Special attention during respiratory rehabilitation is paid to the type of human breathing, as well as automated methods for analyzing breathing. At the moment, the problem arises that most of the developed methods for analyzing breathing do not work with types of breathing: they either determine only one type, for example, diaphragmatic, or simply analyze the condition of the lungs. In this regard, there is a need to develop a method for analyzing and determining directly the types of human respiration.

This article discusses three methods for solving the problem of determining the type of human breathing using a motion capture system and machine learning. The first method is based on static characteristics, for which the Random Forest model was used. The second method, which is based on time characteristics, used the Catch22 model. The third method, which determines the type of respiration using the characteristics of the sinusoid, used a composite model based on two models of Hist Gradient Boosting.

Results. Three methods have been developed to determine the type of human breathing. Machine learning models were trained for each of the methods to find the best accuracy result. After conducting a comparative analysis of the developed approaches, the approach with the best accuracy is determined.

Conclusion. A method for determining the type of human breathing based on machine learning has been developed, the accuracy of which is 0.81.

Keywords: breath type analysis; time data classification; machine learning models for data classification.

Funding: The reported study was funded by VSTU according to the research project No. 60/478-22, 60/473-22.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Zubkov A. V., Donskaia A. R., Marenkov Y. A., Gomazkova Y. S., Bolgov D. A. A Method for Determining the Type of Human Breathing Based on Machine Learning. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2023; 13(2): 8–30. (In Russ.) [https://doi.org/ 10.21869/2223-1536-2023-13-2-8-30](https://doi.org/10.21869/2223-1536-2023-13-2-8-30).

Received 02.04.2023

Accepted 29.04.2023

Published 30.06.2023

Введение

Дыхание является одним из важнейших физиологических процессов человека. Оно осуществляется за счет диафрагмы и межреберных мышц, что приводит к изменению объема грудной полости и дыхательных путей. В данной статье рассматриваются три типа дыхания:

- 1) брюшной;
- 2) грудной;
- 3) смешанный [1; 2; 3].

Одним из общепринятых методов для определения типа дыхания является визуальный анализ, проводимый медицинским персоналом. Пациента сажают или кладут так, чтобы спина находилась в прямом естественном положении. Медицинский работник становится рядом с пациентом и смотрит за отклонениями тела во время дыхания. Если преобладает смещение грудины, у человека преобладает грудной тип дыхания. Если преобладает смещение брюшины, то у человека преобладает брюшной тип дыхания. Если смещение происходит приблизительно синхронно, то у человека смешанный тип дыхания [1].

Нарушение дыхания сигнализирует о развитии заболеваний как в дыхатель-

ной системе человека, так и в других системах организма. Одним из признаков нарушения дыхательной функции является тип дыхания. Неправильный тип дыхания может являться одним из первоисточников кашля, одышки и других симптомов, а также сигнализировать о более серьезных заболеваниях.

Изучение и разработка методов определения типа дыхания могут использоваться, например, для контроля состояния здоровья, повышения эффективности лечения и реабилитации или для диагностики некоторых заболеваний.

В последнее время увеличился интерес к изучению дыхания. Вспышка коронавирусной инфекции в 2019 г. подтолкнула многие сферы к развитию [4; 5], исключением не стала и сфера дыхательной реабилитации. Так в исследовании Brown Ch и др. [6] изучались возможности использования респираторных звуков дыхания человека в качестве диагностических маркеров COVID-19 с последующим определением COVID-19 у людей с кашлем посредством моделей неглубокого обучения. Также исследовалась возможность бесконтактного изучения органов дыхания у пациентов с COVID-19 при помощи инфракрасных датчиков RGB для анализа характера

дыхания с помощью нейронных сетей в исследовании Avuthu B. и др. [7]

Дыхание и его особенности исследовали и до появления COVID-19. Например, B. Schoun и другие [8] изучали возможность бесконтактного определения характеристик дыхания с помощью тепловых данных и последующего применения методов машинного обучения в режиме реального времени.

Также в исследовании Alikhani L. и др. [9] определялась частота дыхания с данных, полученных при ЭКГ (полученная точность – 85%). В исследовании Yanbin Gong и другими [10] определялся только грудной тип дыхания с помощью дыхательных ремней (полученная точность – 95%). В исследовании Adib F. и др. [11] наличие дыхания определялось с помощью радиоволн, а именно роутера Wi-Fi (полученная точность – 99%), но в данном исследовании было всего 14 испытуемых, что является довольно малой выборкой для полномасштабного исследования.

Командой исследователей Hai Anh Tran [12] изучалась возможность упрощенного проведения спирометрического анализа с помощью устройства под управлением Android (средняя ошибка составила 8%), однако в данном исследовании было относительно небольшое число испытуемых – 17 (на 15-ти модель обучалась и на 2-х модель тестировалась).

Однако ни одно исследование до сих пор не затрагивало изучение методов автоматизированного определения

типов дыхания, которые могли бы облегчить лечение дыхательной недостаточности или позволить реализовать реабилитацию, например постковидную, в удаленном формате.

Автоматизация процесса определения типа дыхания может упростить работу медицинскому персоналу, занимающемуся диагностикой, лечением и реабилитацией заболеваний, которые требуют определения типа дыхания. Также автоматизация позволит проводить консультации или лечение, что, как показывает практика пандемии COVID-19, может быть крайне востребованным.

Из всего вышесказанного следует, что существует потребность в разработке единого подхода к определению типов дыхания.

Авторами была поставлена цель – повышение эффективности дыхательной реабилитации за счет разработки автоматизированных методов определения типа дыхания на базе машинного обучения.

План исследования

Для определения типов дыхания с помощью методов машинного обучения необходимо использовать данные, содержащие выделенные типы дыхания (грудной, брюшной, смешанный). На данный момент отсутствуют уже готовые датасеты, поэтому было принято решение о самостоятельном наборе интересных для нас данных.

Для набора данных было приглашено 86 добровольцев. Сбор данных

осуществлялся с помощью системы захвата движения. Предварительно перед началом записи данных с участников собиралась дополнительная информация:

- пол;
- дата рождения;
- факт болезни коронавирусной инфекцией;
- даты заболевания последнего случая коронавирусной инфекции при ее наличии;
- процент поражения легких, при его наличии;
- присутствие респираторных заболеваний на момент замера.

Все данные собирались обезличенно.

Перед началом записи данных обученный ассистент разъяснял, как необходимо правильно дышать для соответствующего типа дыхания, и визуально наблюдал за корректностью дыхания испытуемого. Каждый доброволец мог фиксировать часть туловища ладонью, чтобы ограничить движение мышц, которые не задействованы при измеряемом типе дыхания. Каждая запись длилась 1 минуту.

Таким образом собирались данные о следующих типах дыхания:

- обычном – без специальных требований, привычное для добровольца дыхание;
- грудном – дыхательные движения выполняются за счет сокращения межреберных мышц;
- брюшном – дыхательные движения осуществляются преимущественно с помощью брюшного пресса и диафрагмы;
- смешанном – происходит при одновременном участии межреберных мышц и диафрагмы [1].

Все измерения производились с помощью системы захвата движений, состоящей из трех маркеров, которые фиксировались с помощью поясов на теле испытуемого. Маркеры крепились соответственно на груди в районе мечевидного отростка (точка А), на позвоночнике между 9 и 11 грудными позвонками (точка В), на животе выше пупка (точка С). На рисунке 1 представлена схема расположения маркеров.




Рис. 1. Схема расположения маркеров

Fig. 1. Layout of markers

Каждый отдельный маркер отслеживал свое положение в пространстве и передавал эти данные в программу. Данная программа позволяла фиксировать информацию о добровольце и данные с маркеров. По результатам работы программы получался один файл формата tsv, содержащий данные об изменениях позиций маркеров в пространстве с течением времени и дополнительной информацией, собранной до начала записи данных.

Предобработка данных

Прежде чем приступить к тренировке моделей машинного обучения, данные, полученные в процессе эксперимента, необходимо было предварительно обработать. В ходе проведения предобработки данных учитывались следующие аспекты: количество замеров для каждого испытуемого должно равняться 4 – по одному на каждый тип дыхания; каждый замер должен длиться одну минуту.

При проведении предобработки были выявлены следующие недочеты собранных данных: у некоторых испытуемых имелись лишние замеры, которые дублировали один типа дыхания, – такие записи удалялись; были найдены замеры, длительность которых составляла значительно меньше минуты, – такие замеры рассматривались в качестве статистических выбросов.

Оставшиеся статистические выбросы обнаруживались с помощью метода межквартильного диапазона. Под данным методом подразумевается разность между третьим (Q3) и первым (Q1)

квартилями выборки данных, которая позволяет оценить разброс 50% выборки и исключить статистические выбросы. Под статистическими выбросами понимались записи, для которых значения вычисленных характеристик, а именно частоты и амплитуды были меньше нижней границы или больше верхней границы.

Также все числовые данные были промасштабированы, все категориальные характеристики были приведены к числовому виду, необходимому для обучения, а именно добавлялись колонки, соответствующие каждой категории, единица в совокупности которых означала данную категорию. Полученная выборка была разбита на две – тренировочную (60% исходной выборки) и тестовую (40% исходной выборки) [13].

Материалы и методы

Рассмотрим методы определения типа дыхания с помощью машинного обучения:

1. *Первый метод.* В качестве первого метода авторами было принято решение использовать стандартные модели машинного обучения со статическими характеристиками. В качестве таких характеристик использовались данные, полученные от добровольцев, и вычисленные характеристики – частота и средняя амплитуда дыхания.

Для нахождения амплитуд и частоты вдохов / выдохов использовались минимумы и максимумы функции сезонности изменения расстояний между соответствующими маркерами (например, для грудного дыхания рассматривалось расстояние между маркерами А и В, для

брюшного дыхания – между В и С). Чтобы убрать шумы, содержащиеся в функции, она предварительно сглаживалась с помощью фильтра Савицкого-Голея. Средняя амплитуда находилась как среднее арифметическое всех амплитуд. Частота находилась как отношение количества циклов вдохов / выдохов ко времени замера.

Для данного метода было решено использовать следующие модели классификации: Decision Tree, Random Forest, k-Nearest Neighbors и Hist Gradient Boosting, а также составные модели, основанные на данных классификаторах. Составная модель состоит из двух последовательных классификаторов. Первый определял, смешанный ли это тип дыхания. Вторым, в случае, если первый классификатор опре-

делил, что тип дыхания не является смешанным, относил найденный тип дыхания к грудному или брюшному.

На вход моделям подавались следующие данные: пол, факт болезни коронавирусной инфекцией, факт поражения легких, процент поражения легких, а также средняя амплитуда и частота дыхания.

По итогу использования данного метода наилучший результат показала модель Random Forest.

Random Forest – модель машинного обучения, которая создает набор деревьев решений, каждое дерево строится на основании либо всей выборки, либо на ее случайной части [14]. В таблице 1 приведены гиперпараметры для данной модели.

Таблица 1. Гиперпараметры для Random Forest

Table 1. Hyperparameters for Random Forest

Гиперпараметр Hyperparameter	Краткое описание Short Description	Значение Value
n_estimators	Количество деревьев решений в случайном лесу	10
criterion	Критерий, оценивающий качество разбиения на каждом узле дерева	“gini”
max_depth	Наибольшая глубина деревьев решений	5
min_samples_split	Наименьший объем выборки, необходимый, чтобы выполнить разбиение узла дерева решений	2
min_samples_leaf	Наименьший объем выборки для формирования листа дерева решений	1
max_features	Количество характеристик, которые необходимо учитывать при поиске лучшего разбиения узла; когда “sqrt”, то $\max_features = \sqrt{n_features}$	“sqrt”
bootstrap	Указывает о необходимости разбиения исходной выборки на несколько случайных подвыборок для обучения деревьев решений	True
random_state	Фиксированное значение случайной компоненты	12

Для первого метода в результате работы моделей максимальная точность, которую смогли достичь в процессе обучения, составляла 0,531.

2. *Второй метод.* В связи с недостаточной точностью, полученной моделями, которые работают со статическими данными, авторы решили использовать модели машинного обучения, которые работают непосредственно с временными рядами.

Помимо полученных при замерах координат маркеров дополнительно были вычислены следующие характеристики для каждой единицы времени измерения:

- векторные скорости в проекциях на оси координат маркеров относительно друг друга;
- скалярные скорости маркеров относительно друг друга;
- расстояния между парами трех маркеров.

При этом целесообразно учитывать только скорости маркера А относительно В и С относительно В. Скорости грудного маркера относительно брюшного (А и С) не имеет смысла учитывать, поскольку их движение сонаправлено.

Все вычисленные характеристики получались на основании зафиксированных координат маркеров и изменении этих координат между двумя соседними единицами времени.

Для данного метода использовались следующие классификаторы временных рядов: Catch22Classifier, RocketClassifier, CNNClassifier, FCNClassifier, MLPClassifier, а также составные модели, основанные на данных классификаторах.

На вход моделям подавались временные ряды, включающие координаты маркеров, векторные и скалярные скорости, расстояния между датчиками.

В итоге лучший результат по данному методу показал классификатор Catch22Classifier.

Catch22 – модель машинного обучения, которая использует и отмечает различные характеристики временных рядов с точки зрения их свойств, включая автокорреляцию, последовательные различия, распределения значений и выбросов, масштабирование колебаний и т. д., после чего строит оценку на основании измененных данных [15]. В таблице 2 приведены гиперпараметры для данной модели.

Таблица 2. Гиперпараметры для Catch22

Table 2. Hyperparameters for Catch22

Гиперпараметр Hyperparameter	Краткое описание Short Description	Значение Value
outline_norm	Нормализация каждой последовательности при использовании двух функций Catch22	True
n_jobs	Разделение вычислений на несколько потоков	–1
random_state	Фиксированное значение случайной компоненты	12

Для второго метода в результате работы моделей максимальная точность, которую смогли достичь в процессе обучения, составляла 0,630.

3. Третий метод. Данный метод основывается на том, что изменение расстояний между маркерами может быть приближённо представлено синусоидой. Основной идеей данного подхода является подбор таких синусоид, которые бы повторяли формы исходных графиков.

На рисунке 2 представлены график изменения расстояния между маркерами для грудного типа дыхания и график предполагаемой синусоиды. Видно, что форма синусоиды достаточно точно повторяет форму графика изменения расстояния между маркерами.

Ранее при классификации типов дыхания были замечены трудности в определении смешанного типа. Чтобы улучшить процесс, было принято решение разделить процесс определения типа дыхания на два этапа бинарной классификации.

Первый этап данного процесса должен определить, что полученные данные представляют конкретный (грудной или брюшной) или же смешанный тип дыхания, после чего на втором этапе грудной и брюшной типы дыхания могут быть различены между собой, если в этом есть необходимость. Данное решение позволяет улучшить процесс определения смешанного типа дыхания благодаря использованию специально выделенной для этого модели.




Рис. 2. Графики изменения расстояния между маркерами и предполагаемой синусоиды

Fig. 2. Graphs of the change in the distance between the markers and the assumed sinusoid

Так как был собран сравнительно небольшой датасет, то перед обучением моделей было решено разделить каждый файл на 6 частей по 10 секунд дыхания. Такого временного отрезка вполне достаточно, так как за это время человек совершает как минимум один полный цикл дыхания (вдох и выдох). Такой вывод подтверждается анализом измерений для каждого добровольца.

Были также рассмотрены варианты разбиения на 12 частей (5 секунд дыхания), на 10 частей (6 секунд дыхания), на 5 частей (12 секунд дыхания), на 4 части (15 секунд дыхания), на 3 части (20 секунд дыхания) и на 2 части (30 секунд дыхания). Однако при использовании записей такой длины качество обучения модели было значительно хуже, чем при разбиении на 6 частей. Данный факт отражен на рисунке 3.




Рис. 3. График зависимости средней точности от продолжительности одной части

Fig. 3. Graph of the dependence of the average accuracy on the duration of one part

На рисунке 4 представлен общий алгоритм данного метода. Он состоит из измерения дыхания человека в течение 10 секунд в стоячем положении в привычном темпе. Затем по измеренным данным находится расстояние попарно между маркерами (грудным и брюшным, грудным и спинным, брюшным и спинным) на протяжении всего замера. Далее вычисленные изменения расстояний необходимо сгладить с помощью

фильтра Савицкого-Голея для исключения шумов. Затем необходимо вычислить предполагаемые параметры синусоиды для каждого расстояния. После этого подобрать параметры каждой синусоиды с помощью нелинейного метода наименьших квадратов [16], используя предлагаемые параметры в качестве начальных значений. Далее полученные параметры передаются на вход составной модели, которая и определяет тип дыхания.



Рис. 4. Общий алгоритм определения типа дыхания с помощью подбора синусоиды

Fig. 4. A general algorithm for determining the type of breathing by selecting a sinusoid

На рисунке 5 приведен алгоритм вычисления предполагаемых параметров одной синусоиды. Для начала необходимо задать уравнение синусоиды:

$$y = \sin(\omega t + \varphi) + c,$$

где A – растяжение графика по оси Oy (амплитуда); ω – растяжение графика по оси Ox (циклическая частота); φ – сдвиг графика по оси Ox ; c – смещение графика по оси Oy .

Затем нужно разложить временной ряд в частотный используя дискретное преобразование Фурье [17; 18]. После чего необходимо найти частоту, которая соответствует максимальному пику в

данном преобразовании. Если найденная частота равняется нулю, то найти второй максимальный пик преобразования Фурье, так как пик в нулевой частоте связан со смещением преобразования Фурье. По найденной частоте нужно найти амплитуду $A = \sqrt{2}\sigma$, где σ – стандартное отклонение всех изменений расстояния между двумя маркерами. Далее нужно вычислить циклическую частоту синусоиды $\omega = 2\pi f$, где f – предполагаемая частота. Затем определить сдвиг синусоиды $\varphi = \bar{D}$, где D – изменение расстояния между двумя маркерами, фаза = 0.




Рис. 5. Алгоритм нахождения предполагаемых параметров синусоиды

Fig. 5. Algorithm for finding the expected parameters of the sine wave

На рисунке 6 изображен алгоритм непосредственной логики работы составной модели. Полученные параметры синусоиды передаются первой части модели, которая определяет, является ли

тип дыхания смешанным. Если данная часть модели предсказала, что тип дыхания не является смешанным, то параметры синусоиды передаются второй части модели, которая определяет грудной

и брюшной тип дыхания. После этого если первая часть предсказала смешанный тип дыхания, то модель возвращает

смешанный тип дыхания, иначе результат предсказания второй части.

[Параметры синусоиды]




Рис. 6. Алгоритм логики работы составной модели

Fig. 6. The algorithm of the logic of the composite model

Для обучения первой и второй частей модели был выбран классификатор Hist Gradient Boosting Classifier. Hist Gradient Boosting Classifier – это модель, использующая градиентный бустинг. Градиентный бустинг использует деревья решений как базовый алгоритм. Основной идеей алгоритма является последовательное применение предсказателя таким образом, что каждая последующая модель сводит ошибку предыдущей к минимуму [19; 20].

Также для сравнения было проведено обучение модели с использованием данного классификатора, но с целью выявления всех трех типов дыхания сразу. Препроцессинг данных аналогичен препроцессингу составной модели, так же как и параметры, передаваемые в модель, и ее гиперпараметры. Гиперпараметры для классификаторов описаны в таблице 3.

Таблица 3. Гиперпараметры для компонент HistGradientBoosting составной модели

Table 3. Hyperparameters for the HistGradientBoosting component of the composite model

Гиперпараметр Hyperparameter	Краткое описание Short Description	Значение Value
max_depth	Максимальная глубина деревьев решений	15
random_state	Установка фиксированного состояния случайной составляющей	15
learning_rate	Скорость обучения	1
loss	Функция потерь, которую модель минимизирует в процессе бустинга	“log_loss”

В результате обучения составная модель показала следующие результаты: точность модели, которая определяет смешанный тип дыхания, – 0,76; модели, которая определяет грудной и брюшной, – 0,86; составной модели, определяющей сразу три типа дыхания, – 0,81.

Результаты и их обсуждение

Для оценки полученного результата были выбраны следующие числовые метрики: accuracy score, recall, precision и F1-score. Для иллюстрации результатов предсказаний моделей в качестве метрики использовались матрицы ошибок (confusion matrix), набор кривых Receiver Operating Characteristic (ROC) и

соответствующие им площади под графиками для численной интерпретации метрики.

Данные метрики можно применять как для сбалансированных, так и для несбалансированных данных. Но необходимым условием является возможность определения моделями вероятности предсказания того или иного класса.

На рисунке 7 изображена столбчатая диаграмма соотношения классов в тестовой выборке. Данная диаграмма говорит о сбалансированности классов в тестовой выборке. В связи с этим мы имеем право использовать все из вышеперечисленных метрик.




Рис. 7. Соотношение классов в тестовой выборке

Fig. 7. The ratio of classes in the test sample

Поскольку наши модели представляют собой многоклассовые классификаторы (определяют один из трех типов дыхания), для построения ROC-кривых использовался принцип One-vs-Rest [13], который заключается в том, что каждый класс по очереди рассматривается как положительный, а остальные

классы – как отрицательный. На каждом графике для сравнения присутствует диагональная линия, которая соответствует случайному выбору.

На рисунке 8 приведен набор ROC-кривых, а также матрица ошибок (confusion matrix) для модели RandomForestClassifier.




Рис. 8. Набор ROC-кривых и матрица ошибок для RandomForestClassifier

Fig. 8. A set of ROC curves and an error matrix for RandomForestClassifier

На рисунке 9 приведен набор ROC-кривых, а также матрица ошибок

(confusion matrix) для модели Catch22Classifier.




Рис. 9. Набор ROC-кривых и матрица ошибок для Catch22Classifier

Fig. 9. Set of ROC curves and error matrix for Catch22Classifier

На рисунках 10 изображены набор ROC-кривых и матрица ошибок для составной модели HistGradientBoosting. На

рисунке 10 представлен общий набор для всей составной модели HistGradientBoosting.




Рис. 10. Набор ROC-кривых и матрица ошибок для составной модели HistGradientBoosting

Fig. 10. A set of ROC curves and an error matrix for a composite model HistGradientBoosting

На рисунке 11 представлена ROC-кривая и матрица ошибок для первой

компоненты составной модели HistGradientBoosting.




Рис. 11. ROC-кривая и матрица ошибок для первой компоненты составной модели HistGradientBoosting

Fig. 11. ROC curve and error matrix for the first component of the composite model HistGradientBoosting

На рисунке 12 представлена ROC-кривая и матрица ошибок для второй

компоненты составной модели. В таблице 4 приведены значения метрик.




Рис. 12. ROC-кривая и матрица для второй компоненты составной модели HistGradientBoosting

Fig. 12. ROC curve and matrix for the second component of the composite model HistGradientBoosting

Таблица 4. Оценка качества работы моделей

Table 4. Evaluation of the quality of the modelsB

Модель Model	Accuracy Score	Recall	Precision	F1-score
Random Forest Classifier	0,53	0,54	0,5	0,47
Catch22 Classifier	0,63	0,63	0,65	0,64
Составная модель HistGradientBoosting	0,81	0,82	0,83	0,82

Главными метриками для оценки качества моделей были выбраны accuracy score и recall, а также ROC-кривые. ROC-кривые позволили оценить результаты работы моделей с точки зрения отдельных классов, а также увидеть соотношение истинно положительных и ложноположительных результатов. Так, из графика ROC-кривых для метода, использующего Random Forest,

видно, что она неправильно предсказывает брюшной тип дыхания и сами кривые находятся разрозненно. Для модели, использующей Catch22, из графика ROC-кривых видно, что она предсказывает любой из трех типов дыхания гораздо лучше случайного, при том все кривые располагаются кучно. ROC-кривые составной модели также располагаются кучно, но еще сильнее прибли-

жены к прямому углу (удалены от случайных результатов), что говорит о более качественных результатах предсказания по сравнению с двумя другими моделями. Наилучший результат по всем метрикам показала составная модель HistGradientBoosting.

В ходе исследования были разработаны три метода определения типа дыхания на базе машинного обучения и технологий захвата движения.

В первом методе были использованы статические характеристики, на основе которых проводилось обучение моделей Catch22Classifier, RocketClassifier, CNNClassifier, FCNClassifier, MLPClassifier.

Для первого метода в результате работы моделей максимальная точность была достигнута моделью Random Forest (точность (accuracy score) составляла 0,531).

Во втором подходе использовались модели машинного обучения, которые работают непосредственно с временными рядами. Для второго метода в результате работы моделей максимальная точность была достигнута моделью Catch22Classifier (точность (accuracy score) составляла 0,630).

Третий метод основывался на том, что изменение расстояний между датчиками может быть приближённо представлено синусоидой. Основной идеей данного подхода является подбор таких синусоид, которые бы повторяли формы исходных графиков.

В результате обучения составная модель HistGradientBoosting показала следующие результаты: точность модели, которая определяет смешанный тип дыхания, – 0,76; модели, которая определяет грудной и брюшной, – 0,86; составной модели, определяющей сразу три типа дыхания, – 0,81.

Исследования, касающиеся определения типа человеческого дыхания, имеют довольно широкий спектр целей – от диагностики заболеваний по дыханию человека до измерения частоты дыхания и подсчета количества вдохов в минуту.

Многие исследования, проводившиеся в этой области, были посвящены определению наличия дыхания или определяли всего один тип, что является малоинформативным в разрезе медицинской реабилитации. И хотя Alikhani L. и др. [9], Gong Y. и соавт. [10], Adib F. и др. [11] были достигнуты отличные результаты с точностью, превышающей 85%, данные исследования довольно ограничены в сфере применения.

В то же время Hai Anh Tran [12] возможность упрощенного проведения спирометрического анализа с помощью устройства под управлением Android имела отличные результаты – средняя ошибка составила 8%, однако в данном исследовании было относительно небольшое число испытуемых, что является довольно маленькой выборкой.

Необходимо также отметить, что, согласно [21], разработанные в данном

исследовании методы использует датчики, стоимость которых значительно ниже, чем у конкурирующих методов. Разница может варьироваться в 10–15 раз, что является значительным аргументом в пользу разработанных методов.

Еще одним преимуществом предлагаемого метода является требуемый минимум свободного пространства: для предлагаемой системы требуется всего 3 квадратных метра, в то время как для других систем захвата движения требуется не менее 10–20 квадратных метров, хотя это ограничивает объем анализируемых данных и, следовательно, точность модели, ее можно использовать в домашних условиях, что важно для реабилитации.

Выводы

В заключение можно сделать вывод, что определять тип дыхания с помощью используемой системы захвата и методов машинного обучения возможно, при этом достигая показателей точности

(метрик), имеющих значения гораздо выше случайного предсказания (для которого при трех классах, например, точность (accuracy score) равняется 0,33). Так лучший результат показала составная модель из третьего подхода (accuracy score, равным 0,81). Это говорит о том, что результаты моделей можно считать как минимум удовлетворительными.

Команда авторов планирует в дальнейшем увеличить набор данных и изучить возможность использования методов по комбинированию моделей машинного обучения. Данные планируется увеличивать за счет как минимум двух факторов: увеличения числа замеров (привлечение новых добровольцев), применения методов размножения данных, например, модификации уже собранных данных за счет поворота измеренных координат в пространстве на случайный угол (равный для всех трех маркеров) или добавления случайного смещения (равное для всех трех маркеров).

Список литературы

1. Разработка метода определения доминирующего типа дыхания человека на базе технологий компьютерного зрения, системы захвата движения и машинного обучения / А. В. Зубков, А. Р. Донская, С. Н. Бушенева, Ю. А. Орлова, Г. М. Рыбчиц // Моделирование, оптимизация и информационные технологии. 2022. № 10(4). С. 15. <https://doi.org/10.26102/2310-6018/2022.39.4.016>.
2. Васильев В. И. Влияние диафрагмально-релаксационного типа дыхания на здоровье учащихся средней общеобразовательной школы // Известия Пензенского государственного педагогического университета им. В. Г. Белинского. 2006. № 5. С. 121–123.
3. Subin S., Pravin A. Breathing techniques-A review – 25 different types // International Journal of Physical Education, Sports and Health. 2015. N 2(2). P. 237–241.

4. Разработка автоматизированной системы мониторинга антигенов коронавирусной инфекции на основе иммунохроматографического анализа / С. Н. Костарев, Р. А. Файзрахманов, О. В. Новикова, О. В. Комягина, Т. Г. Серeda // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2022. № 12(3). С. 8–27. <https://doi.org/10.21869/2223-1536-2022-12-3-8-27>.
5. Разработка системы автоматического диагноза на наличие антител иммуноглобулинов IgG и IgM SARS-CoV-2 / С. Н. Костарев, О. В. Кочетова, Н. А. Татарникова, Т. Г. Серeda // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2021. № 11(2). С. 8–24.
6. Exploring Automatic Diagnosis of COVID-19 from Crowdsourced Respiratory Sound Data / Ch. Brown, J. Chauhan, A. Grammenos, J. Han, A. Hasthanasombat, D. Spathis, T. Xia, P. Cicuta, C. Mascolo // KDD '20: Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Association for Computing Machinery, 2020. P. 3474–3484.
7. Exploring Automatic Diagnosis of COVID-19 from Crowdsourced Respiratory Sound Data / B. Avuthu, N. Yenuganti, S. Kasikala, A. Viswanath // IC3-2022: Proceedings of the 2022 Fourteenth International Conference on Contemporary Computing, 2022. P. 367–371. <https://doi.org/10.1145/3549206.3549272>.
8. Schoun B., Transue Sh., Min-Hyung Choi. Real-time Thermal Medium-based Breathing Analysis with Python // PyHPC'17: Proceedings of the 7th Workshop on Python for High Performance and Scientific Computing November. New York: Association for Computing, 2017. Is. 5. P. 1–9. <https://doi.org/10.1145/3149869.3149874>.
9. Spectral fusion-based breathing frequency estimation; experiment on activities of daily living / I. Alikhani, K. Noponen, A. Hautala [et al.] // BioMed Eng OnLine. 2019. N 17. P. 99. <https://doi.org/10.1186/s12938-018-0533-1>.
10. BreathMentor: Acoustic-based Diaphragmatic Breathing Monitor System / Gong Y., Zhang Q., Bobby H. P. NG, Li W // Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies. Association for Computing Machinery, 2022. P. 1–28. <https://doi.org/10.1145/3534595>.
11. Smart Homes that Monitor Breathing and Heart Rate / F. Adib, H. Mao, Z. Kabelac, D. Katabi, R. C. Miller // CHI '15: Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems. Seoul, 2015. P. 837–846. <https://doi.org/10.1145/2702123.2702200>.
12. Hai Anh Tran, Quynh Thu Ngo, Huy Hoang Pham. An application for diagnosing lung diseases on Android phone // SoICT '15: Proceedings of the 6th International Symposium on Information and Communication Technology. Association for Computing Machinery, 2015. P. 328–334. <https://doi.org/10.1145/2833258.2833289>.

13. Machine Learning: A First Course for Engineers and Scientists / A. Lindholm, N. Wahlström, F. Lindsten, T. Schön. Cambridge University Press, 2022.
14. Accuracy and diversity-aware multi-objective approach for random forest construction / El I. K. Nour, A. K. Abdelaziz, A. Ali, S. Hassina, A. Sabeur, D. Wajdi // Expert Systems with Applications. 2023. N 225. P. 20138. <https://doi.org/10.1016/j.eswa.2023.120138>.
15. Catch22: Canonical Time-series Characteristics / C. H. Lubba, S. S. Sethi, P. Knaute [et al.] // Data Min Knowl Disc. 2019. N 33. P. 1821–1852. <https://doi.org/10.1007/s10618-019-00647-x>.
16. Charnes A., Frome E. L., Yu P. L. The Equivalence of Generalized Least Squares and Maximum Likelihood Estimates in the Exponential Family // J. Am. Stat. Assoc. 1976. N 71. P. 169–171.
17. Классификация функционального состояния системы дыхания на основе анализа вариабельности медленных волн VLF-диапазона / А. В. Киселев, А. А. Кузьмин, М. Б. Мяснянкин, А. А. Маслак, С. А. Филист, А. Ф. Рыбочкин // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2022. № 12(1). С. 8–32. <https://doi.org/10.21869/2223-1536-2022-12-1-8-32>.
18. Li C. Discrete Fourier Transform and Fast Fourier Transform // Time Series Data Analysis in Oceanography. Cambridge University Press, 2022. P. 242–266. <https://doi.org/10.1017/9781108697101.015>.
19. Pirayonesi S. M., El-Diraby T. E. Data Analytics in Asset Management: Cost-Effective Prediction of the Pavement Condition Index // Journal of Infrastructure Systems. 2020. N 26(1). P. 1–25. [https://doi.org/10.1061/\(ASCE\)IS.1943-555X.0000512](https://doi.org/10.1061/(ASCE)IS.1943-555X.0000512).
20. Method for Determining the Dominant Type of Human Breathing Using Motion Capture and Machine Learning / Y. Orlova, A. Gorobtsov, O. Sychev, V. Rozaliev, A. Zubkov, A. Donskaia // Algorithms. 2023. N 16(5). P. 249. <https://doi.org/10.3390/a16050249>.
21. Analysis of breathing via optoelectronic systems: Comparison of four methods for computing breathing volumes and thoraco-abdominal motion pattern / C. Massaroni, G. Senesi, E. Schena, S. Silvestri // Comput. Methods Biomech. Biomed. 2017. N 20. P. 1678–1689.

References

1. Zubkov A. V., Donskaia A. R., Busheneva S. N., Orlova Yu. A., Rybchic G. M. Razrabotka metoda opredeleniya dominiruyushchego tipa dykhaniya cheloveka na baze tekhnologii komp'yuternogo zreniya, sistemy zakhvata dvizheniya i mashinnogo obucheniya [Development of a method for determining the dominant type of human respiration based on computer vision technologies, motion capture systems and machine learning]. *Modelirovanie, optimizaciya i informacionnye tehnologii = Modeling, Optimization and Information Technology*, 2022, vol. 10, no. 4, p. 15. <https://doi.org/10.26102/2310-6018/2022.39.4.016>.

2. Vasil'ev V. I. Vliyanie diafragmal'no-relaksatsionnogo tipa dykhaniya na zdorov'e uchashchikhsya srednei obshcheobrazovatel'noi shkoly [Influence of diaphragmatic relaxation type of breathing on the health of secondary school students]. *Izvestija Penzenskogo gosudarstvennogo pedagogicheskogo universiteta im. V. G. Belinskogo = Proceedings of the Penza State Pedagogical University named after V. G. Belinsky*, 2006, no. 5, pp. 121–123.

3. Subin S., Pravin A. Breathing techniques-A review – 25 different types. *International Journal of Physical Education, Sports and Health*, 2015, no. 2(2), pp. 237–241.

4. Kostarev S. N., Fajzrahmanov R. A., Novikova O. V., Komjagina O. V., Sereda T. G. Razrabotka avtomatizirovannoi sistemy monitoringa antigenov koronavi-rusnoi infektsii na osnove immunokhromatograficheskogo analiza [Development of an automated system for monitoring coronavirus infection antigens based on immunochromatographic analysis]. *Izvestija Jugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravlenie, vychislitel'naja tehnika, informatika. Medicinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*, 2022, no. 12(3), pp. 8–27. <https://doi.org/10.21869/2223-1536-2022-12-3-8-27>

5. Kostarev S. N., Kochetova O. V., Tatarnikova N. A., Sereda T. G. Razrabotka sistemy avtomaticheskogo diagnoza na nalichie antitel immu-noglobulinov IgG i IgM SARS-CoV-2 [Development of an automatic diagnosis system for the presence of IgG and IgM immunoglobulin antibodies SARS-CoV-2]. *Izvestija Jugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravlenie, vychislitel'naja tehnika, informatika. Medicinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*, 2021, no. 11(2), pp. 8–24.

6. Brown Ch., Chauhan J., Grammenos A., Han J., Hasthanasombat A., Spathis D., Xia T., Cicuta P., Mascolo C. Exploring Automatic Diagnosis of COVID-19 from Crowdsourced Respiratory Sound Data. *KDD '20: Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. Association for Computing Machinery, 2020, pp. 3474–3484.

7. Avuthu B., Yenuganti N., Kasikala S., Viswanath A. Exploring Automatic Diagnosis of COVID-19 from Crowdsourced Respiratory Sound Data. *IC3-2022: Proceedings of the 2022 Fourteenth International Conference on Contemporary Computing*, 2022, pp. 367–371. <https://doi.org/10.1145/3549206.3549272>

8. Schoun B., Transue Sh., Min-Hyung Choi. Real-time Thermal Medium-based Breathing Analysis with Python. *PyHPC'17: Proceedings of the 7th Workshop on Python for High Performance and Scientific Computing November*. New York, Association for Computing Publ., 2017, is. 5, pp. 1–9. <https://doi.org/10.1145/3149869.3149874>

9. Alikhani I., Noponen K., Hautala A., eds. Spectral fusion-based breathing frequency estimation; experiment on activities of daily living. *BioMed Eng OnLine*, 2019, no. 17, p. 99. <https://doi.org/10.1186/s12938-018-0533-1>

10. Gong Y., Zhang Q., Bobby H. P. NG, Li W. BreathMentor: Acoustic-based Diaphragmatic Breathing Monitor System. *Proceedings of the ACM on Interactive, Mobile, Wearable*

and Ubiquitous Technologies. Association for Computing Machinery Publ., 2022, pp. 1–28. <https://doi.org/10.1145/3534595>

11. Adib F., Mao H., Kabelac Z., Katabi D., Miller R. C. Smart Homes that Monitor Breathing and Heart Rate. CHI '15: Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems. Seoul, 2015, pp. 837–846. <https://doi.org/10.1145/2702123.2702200>

12. Hai Anh Tran, Quynh Thu Ngo, Huy Hoang Pham. An application for diagnosing lung diseases on Android phone. SoICT '15: Proceedings of the 6th International Symposium on Information and Communication Technology. Association for Computing Machinery Publ., 2015, pp. 328–334. <https://doi.org/10.1145/2833258.2833289>.

13. Lindholm A., Wahlström N., Lindsten F., Schön T. B. Machine Learning: A First Course for Engineers and Scientists. Cambridge University Press, 2022.

14. Nour El I. K., Abdelaziz A. K., Ali A., Hassina S., Sabeur A., Wajdi D. Accuracy and diversity-aware multi-objective approach for random forest construction. *Expert Systems with Applications*, 2023, no. 225, p. 20138. <https://doi.org/10.1016/j.eswa.2023.120138>.

15. Lubba C. H., Sethi S. S., Knaute P., eds. Catch22: Canonical Time-series Characteristics. *Data Min Knowl Disc*, 2019, no. 33, pp. 1821–1852. <https://doi.org/10.1007/s10618-019-00647-x>

16. Charnes A., Frome E. L., Yu P. L. The Equivalence of Generalized Least Squares and Maximum Likelihood Estimates in the Exponential Family. *J. Am. Stat. Assoc.*, 1976, no. 71, pp. 169–171.

17. Kiselev A. V., Kuz'min A. A., Mjasnjankin M. B., Maslak A. A., Filist S. A., Rybochkin A. F. Klassifikatsiya funktsional'nogo sostoyaniya sistemy dykhaniya na osnove analiza variabel'nosti medlennykh voln VLF-diapazona [Classification of the functional state of the respiratory system based on the analysis of the variability of slow VLF waves]. *Izvestija Jugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravlenie, vychislitel'naja tehnika, informatika. Medicinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*, 2022, no. 12(1), pp. 8–32. <https://doi.org/10.21869/2223-1536-2022-12-1-8-32>

18. Li C. Discrete Fourier Transform and Fast Fourier Transform. In *Time Series Data Analysis in Oceanography*. Cambridge University Press Publ., 2022, pp. 242–266. <https://doi.org/10.1017/9781108697101.015>

19. Pirayonesi S. M., El-Diraby T. E. Data Analytics in Asset Management: Cost-Effective Prediction of the Pavement Condition Index. *Journal of Infrastructure Systems*, 2020, no. 26(1), pp. 1–25. [https://doi.org/10.1061/\(ASCE\)IS.1943-555X.0000512](https://doi.org/10.1061/(ASCE)IS.1943-555X.0000512)

20. Orlova Y., Gorobtsov A., Sychev O., Rozaliev V., Zubkov A., Donsckaia A. Method for Determining the Dominant Type of Human Breathing Using Motion Capture and Machine Learning. *Algorithms*, 2023, no. 16(5), p. 249. <https://doi.org/10.3390/a16050249>

21. Massaroni C., Senesi G., Schena E., Silvestri S. Analysis of breathing via optoelectronic systems: Comparison of four methods for computing breathing volumes and thoraco-abdominal motion pattern. *Comput. Methods Biomech. Biomed*, 2017, no. 20, pp. 1678–1689.

Информация об авторах / Information about the Authors

Зубков Александр Владимирович, аспирант, Волгоградский технический государственный университет, г. Волгоград, Российская Федерация, e-mail: zubkov.alexander.v@gmail.com, ORCID: 0000-0003-0425-5695

Alexander V. Zubkov, Post-Graduate Student, Volgograd State Technical University, Volgograd, Russian Federation, e-mail: zubkov.alexander.v@gmail.com, ORCID: 0000-0003-0425-5695

Донская Анастасия Романовна, аспирант, Волгоградский технический государственный университет, г. Волгоград, Российская Федерация, e-mail: donsckaia.anastasiya@yandex.ru, ORCID: 0000-0003-3086-4929

Anastasia R. Donsckaia, Post-Graduate Student, Volgograd State Technical University, Volgograd, Russian Federation, e-mail: donsckaia.anastasiya@yandex.ru, ORCID: 0000-0003-3086-4929

Маренков Ярослав Анатольевич, студент кафедры программного обеспечения автоматизированных систем, Волгоградский технический государственный университет, г. Волгоград, Российская Федерация, e-mail: yaroslavmarenkov5@gmail.com

Yaroslav A. Marenkov, Student of the Department of Software of Automated Systems, Volgograd State Technical University, Volgograd, Russian Federation, e-mail: yaroslavmarenkov5@gmail.com

Болгов Дмитрий Александрович, студент кафедры программного обеспечения автоматизированных систем, Волгоградский технический государственный университет, г. Волгоград, Российская Федерация, e-mail: dima-bolgov.02@mail.ru

Dmitry A. Bolgov, Student of the Department of Software of Automated Systems, Volgograd State Technical University, Volgograd, Russian Federation, e-mail: dima-bolgov.02@mail.ru

Гомазкова Юлия Сергеевна, студент кафедры программного обеспечения автоматизированных систем, Волгоградский технический государственный университет, г. Волгоград, Российская Федерация, e-mail: gomazkova19@yandex.ru

Yulia S. Gomazkova, Student of the Department of Software of Automated Systems, Volgograd State Technical University, Volgograd, Russian Federation, e-mail: gomazkova19@yandex.ru