
**СИСТЕМНЫЙ АНАЛИЗ, УПРАВЛЕНИЕ И ОБРАБОТКА ИНФОРМАЦИИ/SYSTEM ANALYSIS,
MANAGEMENT AND PROCESSING OF INFORMATION**

DOI: <https://doi.org/10.60797/IRJ.2026.169.82> EDN: IDDTPW**ИСПОЛЬЗОВАНИЕ ТЕХНОЛОГИИ СТЕКИНГА ДЛЯ ПОВЫШЕНИЯ ТОЧНОСТИ КЛАССИФИКАЦИИ
БРОНХОЛЁГЧНЫХ ПАТОЛОГИЙ ПО АКУСТИЧЕСКИМ ПРИЗНАКАМ**

Научная статья

Родионов А.В.^{1,*}, Королёва Я.А.²¹ORCID : 0000-0003-0451-2655;²ORCID : 0009-0007-5990-4249;¹ Байкальский государственный университет, Иркутск, Российская Федерация² Иркутская городская клиническая больница № 3, Иркутск, Российская Федерация

* Корреспондирующий автор (avr-v[at]yandex.ru)

Предложена: 03.12.2025; Принята: 06.07.2026; Опубликовано: 17.07.2026

Аннотация

В статье исследуется проблема повышения эффективности диагностики бронхолегочных заболеваний посредством анализа акустических признаков дыхания. Авторами предлагается двухуровневая гибридная модель классификации на основе технологии стекинга, интегрирующая возможности классических методов машинного обучения и глубоких нейронных сетей. На первом уровне стекинга можно использовать такие алгоритмы классификации, как Random Forest, Gradient Boosting и XGBoost. Они позволяют получить вероятностные оценки принадлежности сигналов к патологическому классу. Полученные оценки используются для обогащения исходного набора признаков, создавая расширенный датасет для второго уровня стекинга. На этом уровне хорошие результаты показала архитектура CNN+GRU, способная одновременно выявлять локальные спектральные особенности и учитывать временные закономерности дыхательных циклов. Экспериментальная часть работы выполнена на открытом наборе данных ICBHI 2017 Respiratory Sound Database. Исследование предусматривало стратифицированное разбиение выборки, балансировку классов и перекрёстную проверку. Использование предложенного в работе решения позволило значительно улучшить значения метрик качества классификации, снижение количества ложноположительных решений и как следствие, повышение диагностической ценности автоматизированных систем первичного скрининга. Практическая значимость исследования заключается в возможности интеграции предложенной архитектуры в цифровые стетоскопы и мобильные медицинские приложения, что позволит облегчить работу медицинского персонала и ускорить процесс ранней диагностики бронхолегочных патологий.

Ключевые слова: машинное обучение, стекинг, дыхательные шумы, ансамблевое обучение, классификация.**THE USE OF STACKING TECHNOLOGY TO IMPROVE THE ACCURACY OF CLASSIFYING
BRONCHOPULMONARY PATHOLOGIES BASED ON ACOUSTIC TRAITS**

Research article

Rodionov A.V.^{1,*}, Korolyova Y.A.²¹ORCID : 0000-0003-0451-2655;²ORCID : 0009-0007-5990-4249;¹ Baikal State University, Irkutsk, Russian Federation² Irkutsk City Clinical Hospital No. 3, Irkutsk, Russian Federation

* Corresponding author (avr-v[at]yandex.ru)

Suggested: 03.12.2025; Accepted: 06.07.2026; Published: 17.07.2026

Abstract

The article examines the issue of improving the accuracy of diagnosing bronchopulmonary diseases through the analysis of acoustic respiratory traits. The authors propose a two-level hybrid classification model based on stacking technology, which integrates the capabilities of classical machine learning methods and deep neural networks. At the first level of stacking, classification algorithms such as Random Forest, Gradient Boosting and XGBoost can be utilised. These algorithms provide probabilistic estimates of whether signals belong to a pathological class. The obtained estimates are used to enrich the initial feature set, creating an extended dataset for the second level of stacking. At this level, the CNN+GRU architecture demonstrated good results, being capable of simultaneously identifying local spectral traits and accounting for the temporal patterns of respiratory cycles. The experimental part of the research was carried out on the open-access ICBHI 2017 Respiratory Sound Database. The study involved stratified sample division, class balancing and cross-validation. The use of the solution suggested in this work made it possible to significantly improve classification quality metrics, reduce the number of false positives and, as a result, enhance the diagnostic value of automated primary screening systems. The practical significance of this research lies in the potential to integrate the proposed architecture into digital stethoscopes and mobile medical applications, which will make the work of healthcare professionals easier and speed up the process of early diagnosis of bronchopulmonary conditions.

Keywords: machine learning, stacking, breath sounds, ensemble learning, classification.

Введение

Заболевания органов дыхания, такие как хроническая обструктивная болезнь лёгких (ХОБЛ), бронхиальная астма, бронхит и пневмония, остаются одними из самых распространённых и социально значимых патологий в мире [1]. По данным Всемирной организации здравоохранения (ВОЗ), эти заболевания не только занимают лидирующие позиции среди причин смертности, но и являются источниками значительных экономических издержек, связанных с потерей трудоспособности и лечением осложнений. Одним из основных способов раннего выявления бронхолёгочной патологии в клинической практике является традиционная аускультация, то есть выслушивание дыхательных шумов пациента с помощью фонендоскопа. Несмотря на широкое применение, данный метод имеет существенные недостатки, к которым относятся субъективность интерпретации результатов, высокая зависимость от опыта врача и отсутствие количественных критериев оценки состояния пациента [2].

В последние годы активное развитие технологий цифровой медицины и искусственного интеллекта открывает новые возможности для совершенствования методов диагностики респираторных заболеваний. Современные цифровые стетоскопы позволяют получать высококачественные акустические сигналы дыхания, которые содержат ценную диагностическую информацию в виде различных патологических шумов (хрипы, свисты, крепитация) [3], [4]. Однако преобразование этих акустических признаков в объективные диагностические выводы остаётся сложной задачей [5]. В этой связи особый интерес представляет применение методов машинного и глубокого обучения для автоматизированной классификации бронхолёгочной патологии на основе анализа акустических сигналов дыхания.

Одной из наиболее перспективных технологий, способной повысить точность автоматической диагностики, является стекинг (stacking) — метод ансамблевого обучения, объединяющий сильные стороны различных алгоритмов, и позволяющий улучшить обобщающую способность и надёжность прогнозирования [6], [7]. Технология стекинга предполагает многоуровневое обучение, где выходные данные базовых моделей интегрируются с исходными признаками и становятся дополнительной информацией для модели следующего уровня [8]. Несмотря на доказанную эффективность стекинга в ряде прикладных задач машинного обучения, его возможности в области анализа дыхательных шумов изучены недостаточно.

Целью данной работы является исследование возможности и эффективности применения технологии стекинга для повышения точности классификации бронхолёгочной патологии.

Материалы и методы исследования

Данное исследование проводилось на основе публичного датасета звуков дыхания ICBNI 2017 Respiratory Sound Database, включающего 920 аудиофайлов формата .wav и 920 текстовых аннотаций. Датасет имеет ручную разметку интервалов дыхания и ряд особенностей: записи дыхания из нескольких анатомических зон (Trachea, Anterior Left/Right, Posterior Left/Right, Lateral Left/Right), метки наличия хрипов (crackles) и/или свистов (wheezes). Аудиофайлы состоят из записей дыхательных шумов пациентов с различными диагнозами: астма, ХОБЛ, бронхит и др.

Для написания скриптов был использован язык программирования Python. Использовались следующие библиотеки: для предобработки данных librosa и scipy, для визуализации — matplotlib, seaborn, для построения моделей — scikit-learn, xgboost, PyTorch.

Предобработка аудиоданных включала нормализацию всех записей по амплитуде и приведению к единой длине 10 секунд при помощи библиотеки librosa и функции `pr.pad`, где общее количество отсчётов приводится к $sr \times 10$, где sr — частота дискретизации (обычно 22050 Гц); каждая запись была стандартизирована до 220500 отсчётов, что обеспечивает совместимость с моделями и повышает стабильность обучения. Также была применена полосовая фильтрация (bandpass) в диапазоне 100–2000 Гц, характерном для респираторных шумов. Данный диапазон обоснован тем, что ниже нижней границы могут присутствовать низкочастотные артефакты, не связанные с дыханием, такие как звуки движения пациента, фоновые вибрации, удары микрофона и другие механические шумы, а выше верхней границы могут определяться электрические шумы, речевые гармоника и другие посторонние сигналы, не являющиеся частью дыхательного процесса. Хрипы обычно локализируются в диапазоне от 200 до 1200 Гц и имеют короткую длительность (5–30 мс), свисты располагаются между 400 и 1600 Гц и представляют собой синусоидальные сигналы с длительностью от 80 до 250 мс. Таким образом, выбранный диапазон охватывает ключевые спектральные особенности наиболее частых патологических звуков дыхания. Для представления аудиосигнала в виде числовых признаков, пригодных для подачи на вход моделей машинного и глубокого обучения в работе применялись мел-кепстральные коэффициенты (MFCC), а также их первые и вторые временные производные (δ и δ^2), что является стандартным подходом в акустическом анализе. MFCC (Mel Frequency Cepstral Coefficients) моделируют восприятие звука человеком и представляют спектральные характеристики сигнала в логарифмически искажённой частотной шкале, приближённой к физиологии слуха.

Для объективного сравнения различных подходов вначале были протестированы ряд моделей и алгоритмов классификации без предлагаемого механизма стекинга: Random Forest, Gradient Boosting, XGBoost, CNN, Transformer. Все модели обучались на одном и том же наборе признаков, и были настроены с учётом стратифицированного разбиения выборки и балансировки классов. После оценки данных алгоритмов была исследована двухуровневая схема стекинга, в которой на первом уровне рассмотренные модели обучаются на исходном датасете и выдают оценку принадлежности к тому или иному классу (норме/патологии), а сформированные оценки добавляются к исходным данным, формируя расширенный датасет, на основании которого обучались модели второго уровня в схемах [9]: CNN + LSTM, в которой сначала свёрточные слои выделяют локальные спектральные паттерны, затем LSTM анализирует временную динамику дыхательного цикла и CNN + GRU — аналогичная архитектура, но рекуррентную часть реализует более лёгкая GRU, что ускоряет обучение при сопоставимом качестве [10].

Для алгоритма Random Forest использовалось 300 деревьев ($n_estimators$), максимальная глубина дерева — 20, минимальное число образцов для разделения узла — 4, критерий разделения Джини. Для Gradient Boosting задавалось 200 деревьев, скорость обучения ($learning_rate$) 0.05, максимальная глубина — 6. Алгоритм XGBoost обучался со следующими параметрами: $n_estimators = 300$, $learning_rate = 0.05$, $max_depth = 6$, $subsample = 0.8$, $colsample_bytree = 0.8$, $reg_lambda = 1.0$. CNN, Transformer, CNN+LSTM, CNN+GRU обучались с использованием оптимизатора Adam, использовалась функция потерь BCEWithLogitsLoss с весовой коррекцией классов, размер батча 32, число эпох 50. Для предотвращения переобучения использовался dropout с вероятностью 0,3 и L2-регуляризация с коэффициентом 1×10^{-4} . Архитектура CNN включала три свёрточных блока (Conv1D с числом фильтров 32, 64, 128, размером ядра 3, активацией ReLU, BatchNorm и MaxPool с размером 2). В рекуррентной части моделей CNN+LSTM и CNN+GRU использовался один слой LSTM/GRU с 128 скрытыми единицами и двунаправленным режимом. Модель Transformer содержала 4 блока с 8 головами внимания, размерность эмбединга 128. Эксперименты проводились на персональном компьютере с использованием графического ускорителя. Время обучения классических моделей первого уровня не превышало нескольких минут на одну модель; обучение нейросетевых моделей второго уровня на расширенном датасете занимало больше времени, однако в целом оставалось приемлемым.

Для оценки качества применялись стандартные метрики: точность (accuracy), чувствительность (recall), специфичность (specificity), F1-мера и площадь под ROC-кривой (AUC) [11], [12].

Accuracy (Точность классификации) — доля правильно классифицированных объектов от общего числа:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

где: TP (True Positive) — количество истинно положительных предсказаний, TN (True Negative) — количество истинно отрицательных предсказаний, FP (False Positive) — количество ложно положительных предсказаний, FN (False Negative) — количество ложно отрицательных предсказаний.

Recall (Полнота) — доля корректно распознанных положительных событий для каждого класса:

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

F1-мера: взвешенное среднее точности и полноты:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

где: Precision (Точность) — это метрика, которая измеряет, насколько точно модель классифицирует положительные случаи. Она показывает, какая доля объектов, предсказанных моделью как положительные, действительно являются положительными.

Specificity (Специфичность) — способность модели правильно определять отрицательные классы (норму):

$$Specificity = \frac{TN}{TN + FP} \quad (4)$$

Метрика ROC-AUC отражает среднюю площадь под ROC-кривой для классов (One-vs-Rest). Это интегральная характеристика способности модели отделять положительные примеры от отрицательных при различных порогах.

Результаты и их обсуждение

Результаты анализа одиночных классификации представлены в таблице 1. Ряд исследуемых алгоритмов (RandomForest, GradientBoosting и XGBoost) показали достаточно высокую чувствительность ($>0,92$), но низкую специфичность ($\sim 0,22$ – $0,28$). Это означает, что они склонны к «гипердиагностике»: часто ошибочно относили нормальные записи к патологическим (много ложноположительных). Это характерно для несбалансированной выборки, где позитивный класс (патология) доминирует.

Таблица 1 - Метрики качества классификации

DOI: <https://doi.org/10.60797/IRJ.2026.169.82.1>

Модель	Accuracy	Recall	Specificity	F1-score	AUC
RandomForest	0,717	0,929	0,222	0,821	0,656
GradientBoosting	0,717	0,929	0,222	0,821	0,624
XGBoost	0,750	0,952	0,278	0,842	0,594
CNN	0,600	0,821	0,190	0,727	0,470
Transformer	0,667	0,795	0,429	0,756	0,674

Анализ матриц ошибок показал, что все рассмотренные алгоритмы склонны к гипердиагностике патологий — то есть классифицируют нормальные аудиозаписи как патологические. Это подтверждается высоким количеством ложноположительных классификаций (FP) при сравнительно низком уровне истинно отрицательных результатов (TN) (рис. 1-5).




Рисунок 1 - Матрица ошибок RandomForest
DOI: <https://doi.org/10.60797/IRJ.2026.169.82.2>





Рисунок 2 - Матрица ошибок GradientBoosting






Рисунок 4 - Матрица ошибок CNNModel
DOI: <https://doi.org/10.60797/IRJ.2026.169.82.5>




Рисунок 5 - Матрица ошибок TransformerModel
DOI: <https://doi.org/10.60797/IRJ.2026.169.82.6>

Использование технологии стекинга и введение вероятностных выходов базовых алгоритмов в начальный датасет существенно изменило картину. Архитектуры второго уровня CNN+LSTM и CNN+GRU на расширенном датасете показали гораздо более сбалансированный результат и продемонстрировали превосходство над исследуемыми алгоритмами по всем метрикам, таблица 2, рис. 6–7.

Таблица 2 - Метрики качества классификации

DOI: <https://doi.org/10.60797/IRJ.2026.169.82.7>

Модель	Accuracy	Recall	Specificity	F1-score	AUC
CNN+LSTM	0,767	0,714	0,889	0,811	0,938

Модель	Accuracy	Recall	Specificity	F1-score	AUC
CNN+GRU	0,850	0,857	0,833	0,889	0,917




Рисунок 6 - ROC для схемы CNN+LSTM
DOI: <https://doi.org/10.60797/IRJ.2026.169.82.8>




Рисунок 7 - ROC для схемы CNN+GRU
DOI: <https://doi.org/10.60797/IRJ.2026.169.82.9>

Матрицы ошибок гибридных моделей (CNN+LSTM и CNN+GRU) показывают значительное улучшение как по отношению к количеству ложноположительных классификаций (FP), так и по способности правильно распознавать нормальные (TN) и патологические (TP) случаи. Особенно важно, что обе модели обеспечивают сбалансированную чувствительность (Recall) и специфичность, чего не удалось достичь алгоритмам базового уровня. Матрицы ошибок приведены на рис. 8 и рис. 9. Для CNN+LSTM характерно увеличение TN при низком уровне FP, что говорит о способности нейросети эффективно различать норму и патологию. В то же время, показатель FN сохраняется на допустимом уровне, обеспечивая высокую чувствительность. Модель CNN+GRU демонстрирует высокие показатели TP и F1-меры, при минимальном FP и умеренном количестве FN.




Рисунок 8 - Матрица ошибок CNN+LSTM
DOI: <https://doi.org/10.60797/IRJ.2026.169.82.10>




Рисунок 9 - Матрица ошибок CNN+GRU
DOI: <https://doi.org/10.60797/IRJ.2026.169.82.11>

Таким образом, анализ матриц ошибок подтверждает, что гибридные модели, обученные на расширенном датасете, не только превосходят «классические» модели по общим метрикам, но и обеспечивают более надёжную и интерпретируемую диагностику на уровне принятия решений.

Рассмотрим, какие именно акустические признаки оказывают наибольшее влияние на решение модели. Поскольку входными данными моделей являются мел-кепстральные коэффициенты (MFCC) и их временные производные (delta, delta²), решение модели формируется исходя из распределения энергии сигнала по мел-частотным полосам и динамики её изменения во времени. С учётом частотной локализации патологических дыхательных шумов наибольшую диагностическую информативность несут низкие и средние MFCC (примерно со 2-го по 6-й коэффициент), описывающие огибающую спектра в диапазоне 200–1600 Гц, в котором локализуются хрипы (200–1200 Гц) и свисты (400–1600 Гц).

Первые производные (delta) описывают скорость изменения спектральной огибающей и наиболее чувствительны к коротким переходным процессам — таким как крепитация, имеющая длительность 5–30 мс. Вторые производные (delta²) характеризуют ускорение изменений спектра и помогают модели отличать стационарные участки нормального дыхания от нестационарных патологических событий. Свёрточная часть моделей второго уровня (CNN+LSTM,

CNN+GRU) выделяет локальные спектральные паттерны именно в этом признаковом пространстве, а рекуррентная часть (LSTM/GRU) учитывает их повторяемость и расположение в пределах дыхательного цикла, что согласуется с клинической практикой, в которой врач оценивает не только сам факт наличия шума, но и его привязку к фазе вдоха или выдоха.

Дополнительным источником информации для модели второго уровня служат вероятностные оценки базовых классификаторов первого уровня стекинга, добавленные в расширенный датасет. Они выступают своеобразной агрегированной «сводкой» признаков пространства, полученной разными алгоритмами, и позволяют сети опираться не только на исходные акустические дескрипторы, но и на согласованность решений базовых моделей, что обеспечивает наблюдаемый рост специфичности и снижение числа ложноположительных классификаций.

Заключение

В проведённом исследовании представлена двухуровневая стекиговая архитектура, предназначенная для диагностики бронхолёгочных патологий по акустическим признакам дыхательных шумов. Результаты экспериментальных исследований, проведённых на открытом наборе данных ICBHI 2017 Respiratory Sound Database, убедительно подтвердили эффективность предложенного метода. Полученные результаты свидетельствуют о заметном улучшении качества классификации при использовании предложенной в работе схемы стекинга: специфичность возросла практически в четыре раза, при этом чувствительность осталась высокой, а показатель AUC достиг 0,92–0,94. Такой эффект объясняется тем, что вероятностные выходы классических алгоритмов, добавленные к исходным MFCC-признакам, служат своеобразными «контекстными подсказками» для глубоких сетей, что повышает их устойчивость к шуму и улучшает обобщающую способность.

Практическое значение предложенного подхода заключается в возможности его внедрения в медицинскую практику посредством интеграции с цифровыми стетоскопами и телемедицинскими приложениями. Это может снизить нагрузку на медицинский персонал, улучшить доступность первичного скрининга заболеваний дыхательной системы и обеспечить раннее выявление бронхолёгочных патологий.

Дальнейшие исследования могут быть направлены на расширение выборок данных, в том числе за счёт привлечения других открытых наборов записей дыхательных шумов и проведения кросс-датасетной валидации, переход к мультиклассовой постановке задачи с выделением конкретных нозологических форм (астма, ХОБЛ, пневмония, бронхит), применение методов объяснимого искусственного интеллекта для интерпретации решений модели, изучение эффективности предложенного подхода при многоуровневой и мультиклассовой классификации, а также на разработку более гибких и эффективных архитектур нейронных сетей для решения диагностических задач в сфере цифровой медицины.

Конфликт интересов

Не указан.

Conflict of Interest

None declared.

Рецензия

Все статьи проходят рецензирование. Но рецензент или автор статьи предпочли не публиковать рецензию к этой статье в открытом доступе. Рецензия может быть предоставлена компетентным органам по запросу.

Review

All articles are peer-reviewed. But the reviewer or the author of the article chose not to publish a review of this article in the public domain. The review can be provided to the competent authorities upon request.

Список литературы / References

1. Soriano J.B. Prevalence and attributable health burden of chronic respiratory diseases, 1990–2017: a systematic analysis for the Global Burden of Disease Study 2017 / J.B. Soriano, P.J. Kendrick, K.R. Paulson // *Lancet Respiratory Medicine*. — 2020. — Vol. 8. — № 6. — P. 585–596. — DOI: 10.1016/S2213-2600(20)30105-3
2. Kim Y. The coming era of a new auscultation system for analyzing lung sounds: prospects and challenges / Y. Kim, W. Lee // *BMC Pulmonary Medicine*. — 2022. — Vol. 22. — № 1. — DOI: 10.1186/s12890-022-01896-1
3. Liu C. Deep learning-based lung sound analysis for intelligent stethoscope: a systematic review / C. Liu, Y. Yin, X. Zhang // *Military Medical Research*. — 2023. — Vol. 10. — № 1. — DOI: 10.1186/s40779-023-00479-3.
4. Rocha B.M. An open access database for the evaluation of respiratory sound classification algorithms / B.M. Rocha, D. Filos, L. Mendes // *Physiological Measurement*. — 2019. — Vol. 40. — № 3. — DOI: 10.1088/1361-6579/ab03ea
5. Das N. A review on lung disease recognition by acoustic signal analysis using machine learning and deep learning techniques / N. Das, S. Maji // *Journal of Big Data*. — 2023. — Vol. 10. — № 1. — DOI: 10.1186/s40537-023-00762-z
6. Кузнецов М. Использование методов стекинга для повышения точности прогнозных моделей в медицине / М. Кузнецов, С. Сапожников, А. Козлов // *Научно-технический вестник информационных технологий, механики и оптики*. — 2021. — № 2. — С. 345–352. — DOI: 10.17586/2226-1494-2021-21-2-345-352
7. Chatterjee S. Ensemble learning models for medical diagnosis: a review / S. Chatterjee, S. Dey, A. Roy // *Artificial Intelligence in Medicine*. — 2023. — Vol. 144. — URL: <https://www.sciencedirect.com/science/article/pii/S0933365723000893> (accessed: 01.12.25). — DOI: 10.1016/j.artmed.2023.102640
8. Kunapuli G. Ensemble Methods for Machine Learning / G. Kunapuli. — Manning: Simon and Schuster, 2023. — 354 p.
9. Tran D. Combining deep learning with traditional machine learning models for structured biomedical data analysis / D. Tran, D. Nguyen, V. Chandrasekhar // *Artificial Intelligence in Medicine*. — 2023. — Vol. 141. — DOI: 10.1016/j.artmed.2023.102635



10. Hsu F. Benchmarking of eight recurrent neural network variants for breath phase and adventitious sound detection on a self-developed open-access lung sound database-HF_Lung_V1 / F. Hsu, S. Huang, C. Huang // PLoS One. — 2021. — 16(7). — P. e0254134. — DOI: 10.1371/journal.pone.0254134
11. Powers D.M.W. Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation / D.M.W. Powers // Journal of Machine Learning Technologies. — 2011. — Vol. 2. — № 1. — P. 37–63. — DOI: 10.9735/2229-3981
12. Bishop C.M. Pattern Recognition and Machine Learning / C.M. Bishop. — New York: Springer, 2006. — 738 p. doi: 10.1007/978-0-387-45528-0

Список литературы на английском языке / References in English

1. Soriano J.B. Prevalence and attributable health burden of chronic respiratory diseases, 1990–2017: a systematic analysis for the Global Burden of Disease Study 2017 / J.B. Soriano, P.J. Kendrick, K.R. Paulson // Lancet Respiratory Medicine. — 2020. — Vol. 8. — № 6. — P. 585–596. — DOI: 10.1016/S2213-2600(20)30105-3
2. Kim Y. The coming era of a new auscultation system for analyzing lung sounds: prospects and challenges / Y. Kim, W. Lee // BMC Pulmonary Medicine. — 2022. — Vol. 22. — № 1. — DOI: 10.1186/s12890-022-01896-1
3. Liu C. Deep learning-based lung sound analysis for intelligent stethoscope: a systematic review / C. Liu, Y. Yin, X. Zhang // Military Medical Research. — 2023. — Vol. 10. — № 1. — DOI: 10.1186/s40779-023-00479-3.
4. Rocha B.M. An open access database for the evaluation of respiratory sound classification algorithms / B.M. Rocha, D. Filos, L. Mendes // Physiological Measurement. — 2019. — Vol. 40. — № 3. — DOI: 10.1088/1361-6579/ab03ea
5. Das N. A review on lung disease recognition by acoustic signal analysis using machine learning and deep learning techniques / N. Das, S. Maji // Journal of Big Data. — 2023. — Vol. 10. — № 1. — DOI: 10.1186/s40537-023-00762-z
6. Kuzneczov M. Ispol'zovanie metodov stekinga dlya povы'sheniya tochnosti prognozny'x modelej v medicine [Using stacking methods to improve the accuracy of predictive models in medicine] / M. Kuzneczov, S. Sapozhnikov, A. Kozlov // Scientific and Technical Bulletin of Information Technologies, Mechanics and Optics. — 2021. — № 2. — P. 345–352. — DOI: 10.17586/2226-1494-2021-21-2-345-352 [in Russian]
7. Chatterjee S. Ensemble learning models for medical diagnosis: a review / S. Chatterjee, S. Dey, A. Roy // Artificial Intelligence in Medicine. — 2023. — Vol. 144. — URL: <https://www.sciencedirect.com/science/article/pii/S0933365723000893> (accessed: 01.12.25). — DOI: 10.1016/j.artmed.2023.102640
8. Kunapuli G. Ensemble Methods for Machine Learning / G. Kunapuli. — Manning: Simon and Schuster, 2023. — 354 p.
9. Tran D. Combining deep learning with traditional machine learning models for structured biomedical data analysis / D. Tran, D. Nguyen, V. Chandrasekhar // Artificial Intelligence in Medicine. — 2023. — Vol. 141. — DOI: 10.1016/j.artmed.2023.102635
10. Hsu F. Benchmarking of eight recurrent neural network variants for breath phase and adventitious sound detection on a self-developed open-access lung sound database-HF_Lung_V1 / F. Hsu, S. Huang, C. Huang // PLoS One. — 2021. — 16(7). — P. e0254134. — DOI: 10.1371/journal.pone.0254134
11. Powers D.M.W. Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation / D.M.W. Powers // Journal of Machine Learning Technologies. — 2011. — Vol. 2. — № 1. — P. 37–63. — DOI: 10.9735/2229-3981
12. Bishop C.M. Pattern Recognition and Machine Learning / C.M. Bishop. — New York: Springer, 2006. — 738 p. doi: 10.1007/978-0-387-45528-0