

O'ZBEKISTON RESPUBLIKASI FANLAR AKADEMIYASI
YOSH OLIMLAR KENGASHI

YOSH OLIMLAR
AXBOROTNOMASI

3(4)2024
ILMIY JURNAL



S.S.Gulyamov
bosh muharrir,
yuridik fanlari doktori, professor,
O'zR FA Yosh olimlar kengashi raisi

G.H.Tillayeva
bosh muharrir o'rinbosari,
falsafa fanlari nomzodi, dotsent,
O'zR FA Yosh olimlar kengashi rais o'rinbosari

L.Sh.Saidova
Axborotnomaning mas'ul kotibi,
texnika fanlari bo'yicha falsafa doktori PhD.
O'zR FA Navoiy bo'limi katta ilmiy xodimi,
Yosh olimlar kengashi raisi

Tahrir hay'ati:

B.S.Yuldashev – fizika-matematika fanlari doktori, akademik; **S.Z.Mirzayev** – fizika-matematika fanlari doktori, professor; **M.V.Kremkov** – fizika-matematika fanlari doktori, professor; **B.T.Ibragimov** – kimyo fanlari doktori, akademik; **A.S.TO'rayev** – kimyo fanlari doktori, akademik; **S.Sh.Rashidova** – kimyo fanlari doktori, akademik; **S.S.Gulyamov** – iqtisod fanlari doktori, akademik; **Q.X.Abduraxmonov** – iqtisod fanlari doktori, akademik; **A.Sh.Bekmurodov** – iqtisod fanlari doktori, professor; **G'A.Baxadirov** – texnika fanlari doktori, professor; **I.I.Sadikov** – texnika fanlari doktori, professor; **A.A.Rizaev** – texnika fanlari doktori, professor; **I.R.Rustambekov** – yuridik fanlar doktori, professor; **A.N.Yakubov** – yuridik fanlari doktori; **S.S.Bozarov** – yuridik fanlari doktori; **B.A.Abduxalimov** – tarix fanlari doktori, professor; **M.R.Raximov** – tarix fanlari doktori, professor; **A.Ashirov** – tarix fanlari doktori, professor, **M.M.Qaxxarova** – falsafa fanlari doktori, professor v.b., **N.H.Hakimov** – falsafa fanlari doktori, professor, **B.O.Turayev** – falsafa fanlari doktori, professor.

MUASSIS:

O'zbekiston Respublikasi Fanlar akademiyasi.

Jurnal O'zbekiston Matbuot va axborot
Agentligi tomonidan

24.02.2011 yilda ro'yxatga olingan va
26.03.2018 yilda qayta ro'yxatdan o'tkazilgan.

Guvohnoma raqami № 0598

Tahririyat manzili:

100047, Toshkent,

Yahyo G'ulomov ko'chasi, 70.

Tel.: (8-371) 233-50-33

Mob.: (99893) 594-14-02

Elektron pochta manzillari:

yok_axborotnoma@mail.ru,

smu_us@mail.ru, yok@academy.uz

Web: <http://www.yok.academy.uz>

<http://www.facebook.com/smu.an.ru/uzbekistan>

Yosh olimlar Axborotnomasi O'zbekiston Respublikasi Oliy attestatsiya komissiyasining 2023-yil 31-oktabrdagi №345/10-sonli, 2023-yil 30-noyabrdagi №346/5-sonli va 2024-yil 2-avgustdagi №359/5-sonli rayosat qarorlariga ko'ra fizika-matematika, kimyo, biologiya, yuridik, san'atshunoslik, tarix, siyosiy va falsafa fanlari bo'yicha dissertatsiyalar asosiy ilmiy natijalarini chop etishga tavsiya etilgan ilmiy nashrlar ro'yxatida mavjud.

Mualliflik huquqi O'zbekiston Respublikasi Fanlar akademiyasi Yosh olimlar kengashiga tegishli. Barcha huquqlar himoyalangan. Axborotnoma materiall aridan foydalanish, tarqatish va ko'paytirish O'zbekiston Respublikasi Fanlar akademiyasi Yosh olimlar kengashi ruxsati bilan amalga oshiriladi.

© O'zR FA Yosh olimlar Axborotnomasi tahririyati,

© 2024 yil. №3

ISSN 2181-5186

<p style="text-align: center;">O‘ZBEKISTON RESPUBLIKASI FANLAR AKADEMIYASI YOSH OLIMLAR KENGASHI</p> <p>«Yosh olimlar axborotnomasi» «Вестник молодых ученых» «The bulletin of young scientists»</p> <p style="text-align: center;">НАМКОРЛИК: O‘zbekiston Respublikasi Fanlar Akademiyasi Birlashgan kasaba uyushma qo‘mitasi 100047, Toshkent, Yahyo G‘ulomov ko‘chasi, 70. Tel.: (8-371) 233-67-93 (8-371) 233-42-24 Elektron pochta manzillari: kasaba@academy.uz</p> <p>«Gulyamov, Sadikov and Partners» advokatlik firmasi 100072. O‘zbekiston Respublikasi. Toshkent sh., Bobur ko‘ch., 54. Tel.: (+99871) 254-88-48, Faks: (+99871) 254-88-48. http://www.legality.uz</p> <p>Maqolalar o‘zbek, rus, ingliz tillarida chop etiladi.</p> <p>Muharrir: S.S.Gulyamov Tarjimon: H.Nazirova Elektron sahifalash operatori: N.Tilovov</p> <p>Bichimi 60x84 1/16 Rizograf bosma usuli. Times garniturasini. Shartli bosma tabog‘i: 10.Adadi: 300. Buyurtma: 16.</p> <p>O‘zR FA Axborot texnologiyalarini rivojlantirish markazi (DUK) bosmaxonasida chop etilgan.</p> <p>Jurnalga 2011 yilda asos solingan Har uch oyda bir marta nashr etiladi 3(4)2024</p>	*Ustozlar maktabi * Школа наставников * School of mentors*		
	1.	A.Asqarov, G.Tillayeva. Akademiklar sulolasi vakili Saidasror Saidaxmedovich Gulyamov 70 yoshda	3
	*Fizika-matematika va texnika fanlari * Физико-математические и технические науки* *Physical, mathematical and technical sciences*		
	2.	R.R.Bayozov. Tartibga solinadigan chorahalarida yuzaga kelgan tirbandliklarda transport vositalaridan chiqadigan zararli moddalar miqdorini kamaytirish	6
	3.	T.Bojkoobilov, P.Gaysin, P.Karimov, S.Tursunqulov. HD 338654: кандидат в новую переменную звезду	12
	4.	O.Q.Kamolov. Avtotransport vositalarining yo‘l harakati xavfsizligini oshirishga innovasion yondashuv	17
	5.	M.U.Nosirov, Yu.B.Sobirov, Sh.P.Nurmatov, X.Yu.Rahimov. Методы получения зелёного водорода использованием солнечной энергии	22
	6.	L.Sh.Saidova, U.T.Hakimov, Sh.B.Pulatoва. Анализ технологии ведения открытых горных работ	27
	7.	M.M.Toshmatova. этапы развития проектирования кривых участков железных дорог	32
	8.	M.N.Tursunov, X.Sabirov, R.B.Aliqulov. suvsiz ekstremal iqlim sharoiti uchun yuqori samarali o‘zini sovutadigan fotoisloq batareyani sinovdan o‘tkazish	37
	9.	A.R.Hafizov, O.A.Burxonov, J.A.Boltamurodov. ТУС 3125-278-1 o‘zgaruvchan yulduzi tadqiqotining dastlabki natijalari	44
	10.	Ж.З.Шерматов, О.Т.Ражаматов, М.С.Пайзуллаханов, М.Х.Арипова. Особенности магнитных материалов, синтезированных в солнечной печи	48
	11.	S.Sh.Ergashev, Sh.M.Sanaqulov, R.A.Boymurodova. Maydanak observatoriyasida ekzosayyoralar kuzatuv	53
	*Tabiiy fanlar * Естественные науки * Natural sciences*		
	12.	A.Abulizi, R.M.Xalilov, Z.Jiangyu, B.Zhao, Sh.Sh.Sagdullaev. Rosa rugosa barglaridan kversetin-3-o-soforosid va kempferol-3-o-soforozid flavonoidlarini saqlagan quruq ekstrakt olish texnologiyasi	59
	13.	A.M.Zufarov. Gidrofil stabilizatorlar bilan modifikatsiyalangan cds kvant nuqtalarining sintezi va fizik-kimyoviy xossalari	64
	14.	T.M.Magrupov, H.M.Nurillaeva, M.P.Xidojotova, F.B.Abdumalikova, M.T.Zubaidullaeva. Методы анализа и обработки биомедицинских сигналов при заболеваниях лёгких	71
	15.	M.Sh.Hakimov, A.M.Murodov, D.C.Payzиеva, Ж.К.Матмуродов. Мультидисциплинарный подход к лечению острого калькулезного холецистита в постковидном периоде: причины изменения тактики и объема выполняемых хирургических манипуляций	80
	16.	I.E.Khoshimov, Sh.I.Turdialieva, A.R.Seytnazarov, U.M.Turdialiev, Sh.S.Namazov. The strength of granules of feed monocalcium phosphate based on thermal phosphoric acid and limestone	86
	*Ijtimoiy-gumanitar fanlar * Социально-гуманитарные науки* *Social and humanitarian sciences*		
	17.	R.Abdullayeva. Davlatlararo munosabatlarda xalqaro tashkilotlarning o‘rni: iqtisodiy, ijtimoiy, madaniy va tarixiy tahlil	91
	18.	D.I.Babajanova. Surrogat onalik to‘g‘risidagi shartnoma taraflarning huquq va majburiyatlarini belgilash masalalari	101
	19.	Ж.И.Балкибаева. Международный опыт регулирования использования метаданных в судебных разбирательствах	108
	20.	S.Sh.Djalilov. Inklyuziv ta‘lim - nogironligi bo‘lgan shaxslarning ijtimoiy huquqi sifatida	118
	21.	Z.E.Markayev. Agrohuquq: ilmiy talqinlari va yuridik-regulyativ funksiyalari	124
	22.	R.D.Murodova. Temuriylar davrida shishasozlik san‘ati (Temuriylar tarixi davlat muzeyi shisha buyumlari asosida)	131
	23.	H.Pulatoва. Соматические права в развитых демократических государствах и роль судебных документов в их обеспечении	136
	24.	A.A.Saidov. Probatsiya xizmati to‘g‘risidagi qonunchilikni rivojlantirish yo‘nalishlari va uning qo‘llanilishi bilan bog‘liq tartib-taomillar	143
25.	M.E.Smagini. Анализ методик и практические выводы современных подходов и инструментов проектного управления для консалтинговых компаний узбекистана и казахстана	150	
26.	G.H.Tillayeva. Akmeshaxs ma‘naviy tarbiya mexanizmlarining jamiyat ijtimoiy-iqtisodiy takomillashuvi va ravnaq topishidagi o‘rni	159	
27.	S.M.Tursunboev. Прокуратура organlari tizimida terov tuzilmalari faoliatini huqukiy tartibga solinishi	167	
28.	M.I.Yusupova. “Vatanparvarlik” konseptining lingvistik obyektivlashitirishdagi derivativ munosabatlar	173	

**МЕТОДЫ АНАЛИЗА И ОБРАБОТКИ БИМЕДИЦИНСКИХ СИГНАЛОВ ПРИ
ЗАБОЛЕВАНИЯХ ЛЁГКИХ****Т.М.Магруппов, Н.М.Нуриллаева, М.Р.Хидоятова,
Ф.Б.Абдумаликова, М.Т.Зубайдуллаева***

Ключевые слова: сверточная нейронная сеть, рекуррентная нейронная сеть, модель глубокого обучения.

Keywords: convolutional neural network, recurrent neural network, deep learning model.

Анализ биомедицинских сигналов стал одним из важнейших методов визуализации и интерпретации в биологии и медицине. За последние годы было разработано много новых и мощных инструментов для обнаружения, хранения, передачи, анализа и отображения изображений, что позволяет ученым и врачам получать количественные измерения для поддержки научных гипотез и медицинских диагнозов.

В настоящее время Всемирная организация здравоохранения (ВОЗ) сообщает, что легочные или респираторные заболевания по-прежнему являются одной из самых распространенных причин смерти во всем мире [1,2,3]. По оценкам, более 3 миллионов человек ежегодно умирают от различных респираторных заболеваний [4]. Легочные или дыхательные звуки могут меняться от нормальных до патологических из-за легочных или респираторных заболеваний. Аномальные состояния легких можно выявить и своевременно вмешаться с помощью аускультации легочных звуков. Однако точность диагностики в значительной степени зависит от знаний и опыта врача. Опытный врач может быстро отличить патологические легочные звуки от нормальных и точно составить дальнейшие планы обследования. Однако не всегда удаётся точно диагностировать аускультативные изменения, ввиду воздействия различных факторов. С развитием вычислительной техники и электронных технологий для диагностики патологических легочных звуков становится реальностью использовать компьютеры, с целью специфической идентификации биомедицинских сигналов. Прежде всего, респираторные звуки можно записывать с помощью электронных стетоскопов и сохранять в виде аудиофайлов для дальнейшей обработки. Множество нормальных и патологических легочных звуков можно анализировать с помощью электронного прибора. Собрав достаточно данных, мы можем попытаться разработать модель для классификации нормальных/патологических звуков легких или даже для автоматической диагностики заболеваний легких.

Благодаря развитию компьютерных технологий, особенно модель глубокого обучения, технология компьютерного обнаружения звуков легких достигла быстрого прогресса. Было много работ об обнаружении патологических звуков легких с помощью модели глубокого обучения цифровых платформ. До 2015 года методы машинного обучения, такие как опорные векторные машины (ОВМ), анализ главных компонент (АГК), играли главную роль [5, 6, 7, 8, 9, 10]. А позже, после этого года, в эту область была введена модель глубокого обучения, особенно сверточная нейронная сеть (СНС), и показала свое превосходство над машинным

* Т.М.Магруппов – профессор Ташкентского государственного технического университета, Н.М.Нуриллаева – профессор, Ташкентской медицинской академии, М.Р.Хидоятова – доцент Ташкентской медицинской академии, Ф.Б.Абдумаликова – доцент Ташкентской медицинской академии, М.Т.Зубайдуллаева – доцент Ташкентской медицинской академии.

обучением по точности и способности к обобщению [11 , 12 , 13 , 14, 15, 16]. Для машинного обучения так называемые созданные вручную признаки, а именно особые сигнатуры некоторых патологических/нормальных звуков легких, должны быть заранее извлечены в качестве базовых данных для модели обучения. Различные характеристики, такие как асимметрия и эксцесс временного сигнала или спектральная плотность в частотной области, извлекаются из звуков [10]. Машинное обучение не требует большого количества образцов, но имеет один большой недостаток — ограниченную способность к обобщению.

Глубокое обучение — это сквозной подход, не требующий этапа извлечения признаков. Необработанные образцы напрямую передаются в модели глубокого обучения (МГО). В последние годы он успешно применяется для распознавания речи, распознавания объектов, классификации и других областей [16]. В области биомедицины Alpha Fold of Deep Mind может точно предсказать структуру человеческого протеома (совокупность всех белков, кодируемых человеческим геномом), а полученный набор данных охватывает структурные позиции почти 60% аминокислот в прогнозе человеческого протеома, а результаты прогнозирования имеют высокую степень достоверности [17]. С другой стороны, глубокое обучение широко используется в области диагностики. Как заключили Fourcade и др. [18], МГО «будут способствовать оптимизации рутинных задач и, таким образом, окажут потенциальное положительное влияние на нашу практику».

В ходе нашего исследования мы обнаружили, что электронный стетоскоп, способный производить первичную классификацию звуков легких, был наиболее удобным для врачей. Он мог бы избавить от некоторых недостатков традиционного стетоскопа, передавая звуки на компьютер или даже мобильный телефон. Возможность классификации звуков легких может значительно облегчить бремя врачей. Вопрос, который волнует врачей повсеместно, — это точность и практичность.

За последние 2 десятилетия было много работ о классификации звуков легких с использованием машинного обучения или глубокого обучения. Было представлено множество решений с различными параметрами и уровнями производительности. Параметры были выбраны и установлены эмпирически во многих работах. Есть несколько работ, в которых обсуждается, как производительность зависит от различных параметров.

Модель СНС включает в себя множество параметров, таких как параметры, связанные с признаками и связанные с моделью. По данным Wang Z и авторов перед ее обучением изначально должны выбрать для модели соответствующие параметры. С одной стороны, параметры могут быть разработаны методом проб и ошибок. С другой стороны, можно установить некоторые существующие параметры, эффективность которых доказана другими работами. Целью работы было прояснение связи между производительностью и параметрами СНС. Она привлекла внимание многих исследователей. Длина кадра звуков легких, процент перекрытия (ПП) последовательных кадров и типы признаков выбраны в качестве трех типичных параметров. И связь между этими параметрами и производительностью классификации подробно изучена посредством экспериментов. Это было основой этого исследования. Следует отметить, что модель СНС, использованная в этой работе, была проверена в другой работе [17], поэтому проблема настройки гиперпараметров сети, таких как количество фильтров и слоев, выбор функции активации, выходит за рамки этой работы.

Было много работ об автоматической классификации звуков легких с помощью МГО. Несколько наборов данных респираторных звуков использовались для обучения и тестирования МГО. Сигналы собирались у пациентов и здоровых добровольцев с помощью электронного стетоскопа или микрофона. Некоторые наборы данных находятся в открытом доступе, в то время как другие ограничены для личного использования. Среди этих наборов данных RespiratoryDatabase@TR и ICBHI 2017 являются двумя из самых популярных. Первый был создан Алтаном и др. [20,21,22], включая не только звуковые аудиосигналы, но и рентгеновские снимки грудной клетки и измерения функции легких (PFT) соответствующего субъекта. RespiratoryDatabase@TR широко используется для оценки тяжести хронической

обструктивной болезни легких (ХОБЛ) [23, 24, 26, 27]. Последний был первоначально составлен для решения научной цели, поставленной на Международной конференции по биомедицинской информатике в здравоохранении, и доступен в открытом доступе [19]. На основе этих данных для исследователей есть возможность автоматически различать нормальные и патологические звуки легких с помощью машинного обучения или глубокого обучения. В последние годы модели глубокого обучения более актуальны. Для сравнения мы рассмотрели некоторые работы о классификации звуков легких в соответствии с используемыми наборами данных и моделями классификации.

Анализ показал, что спектрограммоподобные признаки использовались более широко, включая, помимо прочего, спектрограмму, мел-спектрограмму, лог-спектрограмму, скалограмму. Некоторые работы объединяли спектрограмму и мел-частотного кепстрального коэффициента (МЧКК) в качестве признаков для МГО с целью улучшения доступности классификации. Кроме того, количество работ, связанных с глубоким обучением, намного больше, чем связанных с машинным обучением.

Когда ICBNI 2017 использовался в качестве набора данных для обучения и тестирования МГО, Ачарья и др. [30] достигли оценки 71,81% по классификации из четырех классов путем повторного обучения глубокой модели CNN-RNN (рекуррентная нейронная сеть) с данными, специфичными для пациента. Cinyo et al. [27] предложили глубокую остаточную сеть (ResNet) для тройной классификации респираторных звуков с точностью, чувствительностью и специфичностью до 98,79%, 96,27% и 100% соответственно. Сообщалось, что предложенная модель превзошла CNN. Шуво и др. [26] использовали эмпирическую модовую декомпозицию (EMD) и непрерывное вейвлет-преобразование (CWT) для обучения облегченной CNN с оценкой точности 98,92% для классификации из трех классов и 98,70% для патологической классификации из шести классов соответственно, что превзошло некоторые более крупные сети и другие современные облегченные модели. Petmezas et al. [14] выполнили классификацию звуков легких из четырех классов, используя гибридную сеть CNN-LSTM (долговременная кратковременная память) и спектрограмму в качестве признака. Они достигли таких высоких оценок, как чувствительность 52,78%, специфичность 84,26%, оценка 68,52% и точность 76,39%. Cinyo et al. [27] объединили архитектуру CNN с машиной опорных векторов (SVM)/softmax в качестве архитектуры, в которую были включены различные классификаторы. Сообщалось, что наилучшая точность классификации составила 83% с моделью VGG16-CNN-SVM. Jayalakshmy et al. [28] использовали условные генеративные состязательные сети и выполнили классификацию из четырех классов, используя предварительно обученную CNN (ResNet-50) и скалограмму в качестве признака, достигнув точности 92,5%. Asatani et al. [29] использовали улучшенную сверточную RNN в качестве четверного классификатора звуков легких и получили результаты чувствительности 0,63, специфичности 0,83 и оценки 0,72. В некоторых работах МЧКК использовались в качестве признака для обучения/тестирования сети глубокого обучения. Perna [30] использовал глубокую архитектуру СНС с регуляризацией для классификации циклов дыхания на три класса: здоровые, хронические и нехронические, и получили оценки точности 82%. Dhavala и др. [31] провели тройную классификацию звуков легких, используя СНС, и достигли точности теста 86,25%. Saraiva и др. [32] предложили СНС для четверной классификации и получили точность 74,3%. Сеть слияния на основе признаков с тремя признаками, т.е. спектрограммой, МЧКК и хромограммой, была предложена для классификации звуков легких по шести категориям Тариком и др. [33], что привело к наивысшей точности 99,1%. Ришаб и др. [34] получили статистические признаки из МЧКК, мел-спектрограммы, цветового STFT и т.д. звуков легких, и подали их в СНС и получили модель четверной классификации с точностью 75,04%. Тасар и др. [35] предложили смешанную модель для генерации признаков и применили дерево решений ближайших показателей (KNN) для классификации звуков легких. Результаты показали, что KNN превзошел два других классификатора. Ари и др. [36] использовали SVM в качестве

четверного классификатора звуков легких со скалограммой в качестве признака и достигли точности 72,69%. Яковлевич и др. [37] использовали МЧКК в качестве признака и скрытую марковскую модель с моделью гауссовой в качестве четверного классификатора звуков легких, и была зарегистрирована лучшая оценка 39,56%.

В большинстве случаев RespiratoryDatabase@TR использовался для определения тяжести хронических обструктивных заболеваний легких (ХОБЛ). Рой и др. [27] сгенерировали представление фрагмента мел-спектрограммы в качестве входного признака и сравнили производительность двух классификаторов для определения тяжести ХОБЛ. Yu и др. [38] извлекли биспектр звуков легких в качестве признака классификатора СНС для помощи в диагностике ХОБЛ. Альтан и др. [39] применили сети глубоких убеждений (DBN) для разделения звуков легких от разных уровней ХОБЛ с извлечением трехмерного графика разности второго порядка во временной области в качестве признака. В другой их работе [40] статистические признаки частотных модуляций были извлечены с помощью преобразования Гильберта-Хуанга, а затем переданы в DLM. Ахмет и др. [41] извлекли статистические характеристики с помощью алгоритма эмпирического вейвлет-преобразования (EWT), а затем применили их к SVM, AdaBoost и J48 DT соответственно для диагностики ХОБЛ.

Результаты показывают, что использование входных данных спектрограммы позволяет достичь лучшей производительности, чем использование функции МЧКК. И при той же функции производительность классификации может быть сильно затронута параметрами, связанными с функцией. В общем, чем больше длина кадра и чем больше процент перекрытия двух последовательных кадров, тем лучше производительность классификации.

Спектрограмма — это визуальное представление спектра частот сигнала, изменяющегося со временем. Применительно к аудиосигналу спектрограмму иногда называют голосовым отпечатком или голосовой граммой. Она использовалась в качестве индикатора говорящего и применялась для распознавания говорящего. И она была принята в качестве широко используемой функции для классификации нормальных/патологических звуков легких. Для сегмента звука легких, чем больше длина кадра, тем выше разрешение по частоте, но тем ниже временное разрешение. Поэтому мы должны найти компромисс между двумя разрешениями. Из экспериментальных результатов можно сделать вывод, что разрешение по частоте вносит больший вклад в эффективность классификации, чем его аналог. Причина может заключаться в том, что более низкое разрешение по частоте приведет к грубому голосовому отпечатку в некоторой степени. Естественно сказать, что мы не можем добиться большей точности от некоторых грубых голосовых отпечатков.

МЧКК обычно используются в качестве признаков в системах распознавания речи и работают относительно хорошо. К сожалению, они не получают достаточно высокой оценки. Поскольку максимальный порядок МЧКК фиксирован, гранулярность признаков МЧКК ограничена. Различие признаков четырех типов звуков легких может быть не представлено в значительной степени. Поэтому для СНС существует трудность точной классификации звуков легких.

Wang Z. и др. проводили сравнительное исследование с аналогичными современными работами. Чтобы обеспечить сопоставимость, сравнительное исследование было ограничено аналогичными работами с использованием спектрограммоподобных признаков и набора данных ICVNI 2017. Количество классов варьируется между этими классификаторами, например, 2 типа (здоровый/нездоровый, нормальный/ненормальный), 3 типа (хрипы/крепитация/нормальный, здоровый/нехронический/хронические заболевания, крепитация/хрипы/нормальный), 4 типа (нормальный/крепитация/хрипы/крепитация и хрипы) и 6 типов (здоровый/бронхоэктатическая болезнь/бронхиолит/ХОБЛ/пневмония/ОРВИ). Среди них для сравнения были выбраны только работы, включающие 4 типа классификации. Предлагаемый классификатор с рекомендуемыми параметрами может достичь относительно лучшей производительности. Работа фокусируется на ответственной части изображения, а не на точности классификации, особенно при клиническом анализе [42]. В отличие от

медицинских изображений, таких как рентгеновские снимки и КТ-снимки, звуки легких представляют собой акустический сигнал. Врачи обучены ставить диагноз с помощью аускультации. Чтобы использовать сверточные нейронные сети для классификации звуков легких, нужно преобразовать акустические сигналы в спектрограммоподобные изображения. Эти изображения являются промежуточными результатами и не могут быть показаны врачам напрямую. Даже если ответственная часть отмечена каким-либо методом, например GradCam, она не имеет большого значения для руководства диагностикой заболеваний легких из-за сложности восприятия [25].

Заключение. Производительность модели глубокого обучения, а именно сверточная нейронная сеть, при различных комбинациях параметров и двух типах признаков подробно исследована в ходе экспериментов. В сочетании с двумя типами признаков подчеркиваются два параметра: длина кадра и процент перекрытия последовательных кадров. Спектрограмма и мел-частотный кепстральный коэффициент звуков легких используются в качестве признаков для сверточной нейронной сети соответственно. Результаты обучения и тестирования показывают, что существует значительная разница в производительности при различных комбинациях параметров и признаках. Из результатов видно, что процент перекрытия является параметром, чувствительным к производительности. Чем выше процент перекрытия, тем лучше общая производительность. Между тем, для более высокого процента перекрытия требуется больше вычислительных ресурсов и ресурсов хранения. Поэтому процент перекрытия ограничен максимумом 75% для практических целей. Частота дискретизации на уровне 8 кГц не даёт потерь важных характеристик звуков легких, поскольку максимальная частота звуков легких не превышает 3 кГц. Когда размер кадра увеличивается до 128 или более, улучшение производительности незначительно. Мы едва ли можем увидеть существенную разницу между показателями производительности между сверточной нейронной сетью с размером кадра 128 и 256. Однако, когда размер кадра уменьшается со 128 до 64 или даже меньше, производительность сверточной нейронной сети быстро ухудшается. Также можно увидеть, что сверточная нейронная сеть с функцией спектрограммы показывает более превосходную производительность, чем сверточная нейронная сеть с функцией мел-частотный кепстральный коэффициент при той же комбинации параметров. Таким образом, можно сделать вывод, что размер кадра 128, процент перекрытия 75% и вход спектрограммы являются оптимальной настройкой параметров, при которой можно достичь компромисса между производительностью и требованиями к ресурсам.

В дальнейших исследованиях актуальна оценка производительности, включающая больше параметров или другую модель глубокого обучения. Например, использование некоторых других функций и методов дополнения данных. Фоновый шум, записанный в больнице, можно будет вставить в аудиовыборку вместо белого шума. И логарифмическая спектрограмма — еще один выбор для этой функции. Кроме того, можно будет сравнить производительность сверточной нейронной сети с другой моделью глубокого обучения, такой как рекуррентная нейронная сеть. Наиболее идеальной реализацией является обучение и тестирование легкой [26, 42] и запуск ее на электронном стетоскопе, что поможет врачу быстрее различать нормальные и патологические состояния легких.

Литература:

1. World Health Statistics 2022, Technical Report (World Health Organization, Geneva, 2022)
2. Абдумаликова, Ф., М. Гиясова, and X. Усманов. Особенности течения сердечно-сосудистых заболеваний при Covid-19. Diss. Узбекистан, 2021. F. Demir, A. Sengur, V. Bajaj, Convolutional neural networks based efficient approach for classification of lung diseases. Health Inf. Sci. Syst. 8, 4 (2019). <https://doi.org/10.1007/s13755-019-0091-3>
3. Арипов, А. Н., Каюмов, У. К., Иноятова, Ф. Х., & Хидоятова, М. Р. (2021). Роль лёгких в системе гемостаза (обзор литературы). Клиническая лабораторная диагностика, 66(7), 411-416.

4. Q.-H. He, B. Yu, X. Hong, B. Lv, T. Liu, J. Ran, Y.-T. Bi, An improved lung sound de-noising method by wavelet packet transform with PSO-based threshold selection. *Intell. Autom. Soft Comput.* 24(2), 223–230 (2018). <https://doi.org/10.1080/10798587.2016.1261957>
5. M. Gronnesby, Automated lung sound analysis. Master's thesis, The Arctic University of Norway, Norway (2016)
6. S. İçer, S. Gengeç, Classification and analysis of non-stationary characteristics of crackle and rhonchus lung adventitious sounds. *Digit. Signal Process.* 28, 18–27 (2014). <https://doi.org/10.1016/j.dsp.2014.02.001>
7. R. Naves, B.H.G. Barbosa, D.D. Ferreira, Classification of lung sounds using higher-order statistics: a divide-and-conquer approach. *Comput. Methods Programs Biomed.* 129, 12–20 (2016). <https://doi.org/10.1016/j.cmpb.2016.02.013>
8. R. Palaniappan, K. Sundaraj, N.U. Ahamed, Machine learning in lung sound analysis: a systematic review. *Biocybern. Biomed. Eng.* 33(3), 129–135 (2013). <https://doi.org/10.1016/j.bbe.2013.07.001>
9. Zhu, J. Lai, B. Liu, Z. Wen, Y. Xiong, H. Li, Y. Zhou, Q. Fu, G. Yu, X. Yan, X. Yang, J. Zhang, C. Wang, H. Zeng, Automatic pulmonary auscultation grading diagnosis of coronavirus disease 2019 in China with artificial intelligence algorithms: a cohort study. *Comput. Methods Programs Biomed.* 213, 106500 (2022). <https://doi.org/10.1016/j.cmpb.2021.106500>
10. Y. Kim, Y. Hyon, S.S. Jung, S. Lee, G. Yoo, C. Chung, T. Ha, Respiratory sound classification for crackles, wheezes, and rhonchi in the clinical field using deep learning. *Sci. Rep.* 11(1), 17186 (2021). <https://doi.org/10.1038/s41598-021-96724-7>
11. M. Aykanat, Ö. Kılıç, B. Kurt, S. Saryal, Classification of lung sounds using convolutional neural networks. *EURASIP J. Image Video Process.* 2017(1), 1–9 (2017). <https://doi.org/10.1186/s13640-017-0213-2>
12. G. Petmezas, G.-A. Cheimariotis, L. Stefanopoulos, B. Rocha, R.P. Paiva, A.K. Katsaggelos, N. Maglaveras, Automated lung sound classification using a hybrid CNN-LSTM network and focal loss function. *Sensors* 22(3), 1232 (2022). <https://doi.org/10.3390/s22031232>
13. Y. Ma, X. Xu, Y. Li, LungRN+NL: an improved adventitious lung sound classification using non-local block ResNet neural network with Mixup data augmentation, in *Proceedings of the Interspeech 2020* (2020), pp. 2902–2906. <https://doi.org/10.21437/Interspeech.2020-2487>
14. B.M. Rocha, D. Pessoa, A. Marques, P. Carvalho, R.P. Paiva, Automatic classification of adventitious respiratory sounds: A (un)solved problem? *Sensors* 21(1), 57 (2021). <https://doi.org/10.3390/s21010057>
15. K. Tunyasuvunakool, J. Adler, Z. Wu, T. Green, M. Zielinski, A. Židek, A. Bridgland, A. Cowie, C. Meyer, A. Laydon et al., Highly accurate protein structure prediction for the human proteome. *Nature* 596(7873), 590–596 (2021). <https://doi.org/10.1038/s41586-021-03828-1>
16. Fourcade, R.H. Khonsari, Deep learning in medical image analysis: a third eye for doctors. *J. Stomatol. Oral Maxillofac. Surg.* 120(4), 279–288 (2019). <https://doi.org/10.1016/j.jormas.2019.06.002>
17. B.M. Rocha, D. Filos, L. Mendes, I. Vogiatzis, E. Perantoni, E. Kaimakamis, P. Natsiavas, A. Oliveira, C. Jácome, A. Marques, R.P. Paiva, I. Chouvarda, P. Carvalho, N. Maglaveras, A respiratory sound database for the development of automated classification, in *Precision Medicine Powered by pHealth and Connected Health*. ed. by N. Maglaveras, I. Chouvarda, P. Carvalho (Springer, Singapore, 2017), pp.33–37. https://doi.org/10.1007/978-981-10-7419-6_6
18. G. Altan, Y. Kutlu, Y. Garbi, A.O. Pekmezci, S. Nural, Multimedia respiratory database (RespiratoryDatabase@TR): auscultation sounds and chest X-rays (2021). <https://doi.org/10.48550/arXiv.2101.10946>
19. Y. Choi, H. Lee, Interpretation of lung disease classification with light attention connected module. *Biomed. Signal Process. Control* 84, 104695 (2023). <https://doi.org/10.1016/j.bspc.2023.104695>

20. G. Altan, Y. Kutlu, A. Gökçen, Chronic obstructive pulmonary disease severity analysis using deep learning on multi-channel lung sounds. *Turk. J. Electr. Eng. Comput. Sci.* 28(5), 2979–2996 (2020). <https://doi.org/10.3906/elk-2004-68>
21. Roy, U. Satija, A novel melspectrogram snippet representation learning framework for severity detection of chronic obstructive pulmonary diseases. *IEEE Trans. Instrum. Meas.* 72(4003311), 1–11 (2023). <https://doi.org/10.1109/TIM.2023.3256468>
22. J. Acharya, A. Basu, Deep neural network for respiratory sound classification in wearable devices enabled by patient specific model tuning. *IEEE Trans. Biomed. Circuits Syst.* 14(3), 535–544 (2020). <https://doi.org/10.1109/TBCAS.2020.2981172>
23. H. Chen, X. Yuan, Z. Pei, M. Li, J. Li, Triple-classification of respiratory sounds using optimized s-transform and deep residual networks. *IEEE Access* 7, 32845–32852 (2019). <https://doi.org/10.1109/ACCESS.2019.2903859>
24. S.B. Shuvo, S.N. Ali, S.I. Swapnil, T. Hasan, M.I.H. Bhuiyan, A lightweight CNN model for detecting respiratory diseases from lung auscultation sounds using EMD-CWT-based hybrid scalogram. *IEEE J. Biomed. Health Inform.* 25(7), 2595–2603 (2021). <https://doi.org/10.1109/JBHI.2020.3048006>
25. F. Cinyol, U. Baysal, D. Köksal, E. Babaoğlu, S.S. Ulaşlı, Incorporating support vector machine to the classification of respiratory sounds by convolutional neural network. *Biomed. Signal Process. Control* 79, 104093 (2023). <https://doi.org/10.1016/j.bspc.2022.104093>
26. S. Jayalakshmy, G.F. Sudha, Conditional GAN based augmentation for predictive modeling of respiratory signals. *Comput. Biol. Med.* 138, 104930 (2021). <https://doi.org/10.1016/j.combiomed.2021.104930>
27. N. Asatani, T. Kamiya, S. Mabu, S. Kido, Classification of respiratory sounds using improved convolutional recurrent neural network. *Comput. Electr. Eng.* 94, 107367 (2021). <https://doi.org/10.1016/j.compeleceng.2021.107367>
28. D. Perna, Convolutional neural networks learning from respiratory data, in 2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM) (2018), pp. 2109–2113. <https://doi.org/10.1109/BIBM.2018.8621273>
29. Dhavala, A. Ahmed, R. Periyasamy, D. Joshi, An MFCC features-driven subject-independent convolution neural network for detection of chronic and non-chronic pulmonary diseases, in 2022 3rd International Conference for Emerging Technology (INCET) (2022), pp. 1–9. <https://doi.org/10.1109/INCET54531.2022.9824677>
30. A.A. Saraiva, D.B.S. Santos, A.A. Francisco, J.V.M. Sousa, N.M.F. Ferreira, S. Soares, A. Valente, Classification of respiratory sounds with convolutional neural network, in Proceedings of the 13th International Joint Conference on Biomedical Engineering Systems and Technologies (BIOSTEC 2020)—BIOINFORMATICS, INSTICC (SciTePress, Valletta, 2020), pp. 138–144. <https://doi.org/10.5220/0008965101380144>
31. Z. Tariq, S.K. Shah, Y. Lee, Feature-based fusion using CNN for lung and heart sound classification. *Sensors* 22(4), 1521 (2022). <https://doi.org/10.3390/s22041521>
32. D. Rishabh Kumar, Multi spectral feature extraction to improve lung sound classification using CNN, in 2023 10th International Conference on Signal Processing and Integrated Networks (SPIN) (2023), pp. 186–191. <https://doi.org/10.1109/SPIN57001.2023.10116295>
33. Tasar, O. Yaman, T. Tuncer, Accurate respiratory sound classification model based on piccolo pattern. *Appl. Acoust.* 188, 108589 (2022). <https://doi.org/10.1016/j.apacoust.2021.108589>
34. Ari, O.F. Alçin, A. Şengür, A lung sound classification system based on data augmenting using ELM-wavelet-AE. *Turk. J. Sci. Technol.* 17(1), 79–88 (2022). <https://doi.org/10.55525/tjst.1063039>
35. N. Jakovljević, T. Lončar-Turukalo, Hidden Markov model based respiratory sound classification, in Precision Medicine Powered by pHealth and Connected Health. ed. by N. Maglaveras, I. Chouvarda, P. Carvalho (Springer, Singapore, 2018), pp.39–43. https://doi.org/10.1007/978-981-10-7419-6_7

36. Y. Hui, Z. Jing, Q. Zhaoyu, L. Dongyi, C. Zhen, G. Chengxiang, S. Jinglai, Z. Xiaoyun, Diagnosis model of chronic obstructive pulmonary disease based on deep learning. *Chin. J. Biomed. Eng.* 41(5), 558 (2022). <https://doi.org/10.3969/j.issn.0258-8021.2022.05.005>
37. G. Altan, Y. Kutlu, A. Pekmezci, S. Nural, Deep learning with 3d-second order difference plot on respiratory sounds. *Biomed. Signal Process. Control* 45, 58–69 (2018). <https://doi.org/10.1016/j.bspc.2018.05.014>
38. G. Altan, Y. Kutlu, N. Allahverdi, Deep learning on computerized analysis of chronic obstructive pulmonary disease. *IEEE J. Biomed. Health Inform.* 24(5), 1344–1350 (2020). <https://doi.org/10.1109/JBHI.2019.2931395>
39. Gökçen, Computer-aided diagnosis system for chronic obstructive pulmonary disease using empirical wavelet transform on auscultation sounds. *Comput. J.* 64(11), 1775–1783 (2021). <https://doi.org/10.1093/comjnl/bxaa191>
40. G. Altan, DeepOCT: an explainable deep learning architecture to analyze macular edema on OCT images. *Eng. Sci. Technol. Int. J.* 34, 101091 (2022). <https://doi.org/10.1016/j.jestch.2021.101091>.



O‘PKA KASALLIKLARINI BIOTIBIBIY SIGNALLARINI TAHLIL QILISH VA QAYTA ISHLASH USULLARI

O‘pka tovushlarini auskultatsiya qilish orqali o‘pka kasalliklarini aniqlash mumkin. Kompyuter va elektron texnologiyalarning rivojlanishi bilan patologik o‘pka tovushlarini diagnostika qilish uchun kompyuterlardan foydalangan holda biotibbiyot signallarini maxsus aniqlash mumkin bo‘ladi. Asosiysi, nafas olish tovushlarini elektron stetoskoplar yordamida yozib olish va keyinchalik qayta ishlash uchun audio fayllar sifatida saqlash mumkin bo‘ladi. Chuqur o‘rganish modeli ayniqsa konvolyutsion neyron tarmog‘i aniqlik va umumlashtirish qobiliyatida mashinali o‘rganishdan ustun ekanligini ko‘rsatdi. O‘pka tovushlarining birlamchi tasnifini amalga oshirishuvchi elektron stetoskop shifokorlar uchun eng qulay hisoblanadi. Bu tovushlarni kompyuterga yoki hatto uyali telefonga uzatish orqali an‘anaviy stetoskopning ba‘zi kamchiliklarini bartaraf etishi mumkin. O‘pka tovushlarini tasniflash qobiliyati shifokorlarning yukini sezilarli darajada kamaytirishi mumkin.

МЕТОДЫ АНАЛИЗА И ОБРАБОТКИ БИОМЕДИЦИНСКИХ СИГНАЛОВ ПРИ ЗАБОЛЕВАНИЯХ ЛЁГКИХ

Патологические состояния легких можно своевременно выявить и вмешаться с помощью аускультации легочных звуков. С развитием вычислительной техники и электронных технологий для диагностики патологических легочных звуков становится реальностью использовать компьютеры, с целью специфической идентификации биомедицинских сигналов. Прежде всего, респираторные звуки можно записывать с помощью электронных стетоскопов и сохранять в виде аудиофайлов для дальнейшей обработки. Модель глубокого обучения, особенно сверточная нейронная сеть, показала свое превосходство над машинным обучением по точности и способности к обобщению. Электронный стетоскоп, способный производить первичную классификацию звуков легких является наиболее удобным для врачей. Он мог бы избавить от некоторых недостатков традиционного стетоскопа, передавая звуки на компьютер или даже на мобильный телефон. Возможность классификации звуков легких может значительно облегчить бремя врачей.

METHODS FOR ANALYSIS AND PROCESSING OF BIOMEDICAL SIGNALS FOR LUNG DISEASES

Abnormal lung conditions can be screened out and intervened timely with the help of lung sounds auscultation. With the development of computer technology and electronic technologies for the diagnosis of pathological lung sounds, it becomes possible to use computers for the purpose of specifically identifying biomedical signals. First of all, respiratory sounds can be recorded using electronic stethoscopes and saved as audio files for further processing. Deep learning model, especially convolutional neural network, has shown to be superior to machine learning in accuracy and generalization ability. An electronic stethoscope capable of making a primary classification of lung sounds is the most convenient for doctors. It could eliminate some of the shortcomings of a traditional stethoscope by transmitting sounds to a computer or even a cell phone. The ability to classify lung sounds can greatly reduce the burden on physicians.