



Aprendizagem de Máquina para Classificação de Doenças Respiratórias: Uma Revisão Sistemática

Machine Learning for Classification of Respiratory Diseases: A Systematic Review

Aprendizaje de Máquina para la Clasificación de Enfermedades Respiratorias: Una Revisión Sistemática

Leticia Balbi Silva¹, Fernando Neves Nogueira¹, Jackson Matheus dos Santos², Kevin Gustavo Montero Quise³, Rafael Giusti⁴, Juan Gabriel Colonna⁴

RESUMO

Descritores: Revisão Sistemática; Diagnóstico Precoce; Sons Respiratórios

Objetivo: O objetivo deste trabalho é apresentar uma análise do estado da arte referente ao problema de classificação de sons respiratórios para auxiliar no diagnóstico e monitoramento da saúde respiratória, destacando os métodos de aprendizagem de máquina. **Métodos:** Uma revisão da literatura foi conduzida a partir das seguintes palavras-chaves: *Machine learning, Classification, Diagnosis, Respiratory sounds, Respiratory disease, Lung sounds e Pulmonary disease*. Os bancos de dados de pesquisas utilizados foram IEEE Xplore, PubMed e Scopus. **Resultados:** Ao total 1135 artigos foram coletados, mas apenas 67 atenderam às exigências na primeira etapa de filtro e 14 trabalhos atenderam aos critérios de elegibilidade. Uma taxonomia foi proposta para organizar os trabalhos de acordo com a abordagem de aprendizagem de máquina aplicada. **Conclusão:** Os resultados obtidos pelo estudo apresentam uma perspectiva geral sobre a problemática, além das contribuições para resolução dos desafios presentes na auscultação tradicional, suas limitações e investigações futuras.

ABSTRACT

Keywords: Systematic Review; Early Diagnosis; Respiratory Sounds

Objective: The objective of this work is to present an analysis of the state-of-the-art on the problem of classification of respiratory sounds to assist the diagnostic and monitoring of respiratory health, with emphasis on solutions based on machine learning. **Methods:** A literature review has been conducted based on the following keywords: *Machine learning, Classification, Diagnosis, Respiratory sounds, Respiratory disease, Lung sounds, and Pulmonary disease*. The research databases used were IEEE Xplore, PubMed, and Scopus. **Results:** A total of 1135 articles were collected, but only 67 met the requirements of the first filter stage and 14 papers met the eligibility criteria. A taxonomy was proposed to organize all research articles according to the applied machine learning approach. **Conclusion:** The results obtained by this review present a general perspective on the problem and contributions to solve the challenges present in traditional auscultation, its limitations and future investigations.

RESUMEN

Descriptores: Revisión Sistemática; Diagnóstico Precoz; Ruidos Respiratorios

Objetivo: En este trabajo presentamos un análisis del estado del arte en relación al problema de clasificación de sonidos respiratorios para ayudar en el diagnóstico y monitoreo de las enfermedades respiratorias, destacando los métodos de aprendizaje de máquina automáticos utilizados en las soluciones. **Métodos:** Realizamos una revisión de la literatura basada en las siguientes palabras clave: *Machine learning, Classification, Diagnosis, Respiratory sounds, Respiratory disease, Lung sounds y Pulmonary disease*. Las bibliotecas online utilizadas fueron IEEE Xplore, PubMed y Scopus. **Resultados:** Recolectamos un total de 1135 artículos, pero solamente 67 cumplieron con los requisitos en la primera etapa de filtrado y 14 artículos cumplieron los criterios de elegibilidad. Se propuso una taxonomía para organizar todos los artículos de acuerdo con el enfoque de aprendizaje automático aplicado. **Conclusión:** Los resultados obtenidos por esta revisión presentan una perspectiva general del problema y los aportes para resolver los desafíos presentes en la auscultación tradicional, sus limitaciones y futuras investigaciones.

¹ Aluno de graduação do curso de Ciência da Computação no Instituto de Computação, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

² Aluno de graduação do curso de Engenharia de Software no Instituto de Computação, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

³ Aluno de doutorado do Programa de Pós-Graduação em Informática do Instituto de Computação, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

⁴ Docente do Instituto de Computação, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

INTRODUÇÃO

A auscultação é um dos principais métodos utilizados no diagnóstico de distúrbios respiratórios devido a sua simplicidade, praticidade e baixo custo. Esse processo consiste em escutar os sons internos do corpo humano através de um estetoscópio a fim de verificar a integridade da função pulmonar. Esses sons internos são produzidos pelo fluxo do ar ao longo do tronco respiratório durante o processo de expiração e inspiração⁽¹⁾. O método de ausculta pulmonar requer sua condução por um profissional da área bem treinado para interpretar os sons pulmonares e para prestação do diagnóstico. Por isso, mesmo que seja uma forma eficaz de diagnóstico, a ausculta é um método subjetivo, que está sujeito a falsos diagnósticos. Com o intuito de auxiliar profissionais da saúde nesses desafios, foram desenvolvidas inúmeras pesquisas acerca do processo de monitoramento da saúde pulmonar que utilizam técnicas de aprendizagem de máquina.

Neste trabalho, discutimos artigos que propõem o uso de aprendizagem de máquina para análise da saúde pulmonar e classificação de anomalias respiratórias através da ausculta, explorando a forma de abordagem individual do problema, bem como suas metodologias e base de dados utilizadas.

Sons respiratórios e suas características

As características dos sons respiratórios oferecem informações relevantes a respeito da condição do sistema respiratório do paciente. Os sons respiratórios podem ser classificados em sons normais e anormais, sendo esse último composto de características úteis no estudo e diagnóstico de doenças pulmonares. Os sons respiratórios anormais podem ser classificados em contínuos e não contínuos. Sons respiratórios anormais contínuos são ininterruptos e musicais (sibilos e roncos), enquanto os não contínuos (crepitações finas e grossas) são explosivos e agudos⁽¹⁾. As características dos sons normais e anormais, bem como as suas respectivas doenças respiratórias associadas, estão apresentadas no Quadro 1.

MÉTODOS

A revisão sistemática da literatura foi realizada com

base na recomendação dos principais itens para relatar Revisões sistemáticas e Meta-análises (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses* - PRISMA)⁽³⁾.

Identificação

A busca inicial dos trabalhos foi realizada nas bases de dados IEEE Xplore, PubMed e Scopus. A seguinte *string* de busca foi utilizada na pesquisa de trabalhos pertencentes às bases IEEE Xplore e PubMed: (“classification” OR “diagnosis” OR “detection”) AND (“lung sounds” OR “pulmonary disease” OR “respiratory disease” OR “respiratory sound”). A mesma *string* de busca foi utilizada na pesquisa de trabalhos pertencentes à base Scopus, porém com a adição da expressão AND “machine learning” ao seu final.

Seleção e elegibilidade

Os artigos identificados na etapa anterior foram submetidos à seleção por título e resumo. Além disso, houve a realização da leitura diagonal dos mesmos a fim de identificar rapidamente se as informações contidas eram relevantes para a revisão sistemática em questão. Os critérios de exclusão utilizados para elegibilidade de um artigo incluem a escrita não realizada em língua inglesa, data de publicação anterior ano de 2016, não enfoque na classificação de sons ou doenças respiratórias, não utilização de dados de áudio, informação incompleta e método análogo ao de outro artigo.

Inclusão

Após a elegibilidade, os artigos incluídos na revisão sistemática foram submetidos à extração de dados. Os dados extraídos de cada artigo incluem os sons respiratórios classificados, doenças respiratórias classificadas, abordagens, instrumentação, localização dos sensores, bases de dados utilizadas, características e métodos. Os dados citados estão sintetizados na Tabela 1, Tabela 2 e Tabela 3 e descritos especificamente na seção de resultados.

RESULTADOS

Primeiramente, 1135 artigos foram identificados através da busca nas bases de dados IEEE Xplore, PubMed e

Quadro 1 – Características dos sons respiratórios e doenças respiratórias associadas⁽¹⁻²⁾.

Som respiratório	Faixa de frequência dominante	Intensidade	Duração	Doenças associadas
Normal	100 - 1000 Hz	Alta/Baixa	-	-
Sibilo	> 400 Hz	Alta	> 80 ms	Asma; Doença obstrutiva crônica (DPOC); Pneumonia
Ronco	< 200 Hz	Baixa	> 250 ms	Bronquite crônica
Crepitação grossa	60 - 2000 Hz	Baixa	> 10 ms	Bronquiectasia; Bronquite crônica; Doença obstrutiva crônica (DPOC); Fibrose pulmonar; Insuficiência cardíaca; Pneumonia
Crepitação fina	60 - 2000Hz	Alta	< 10 ms	

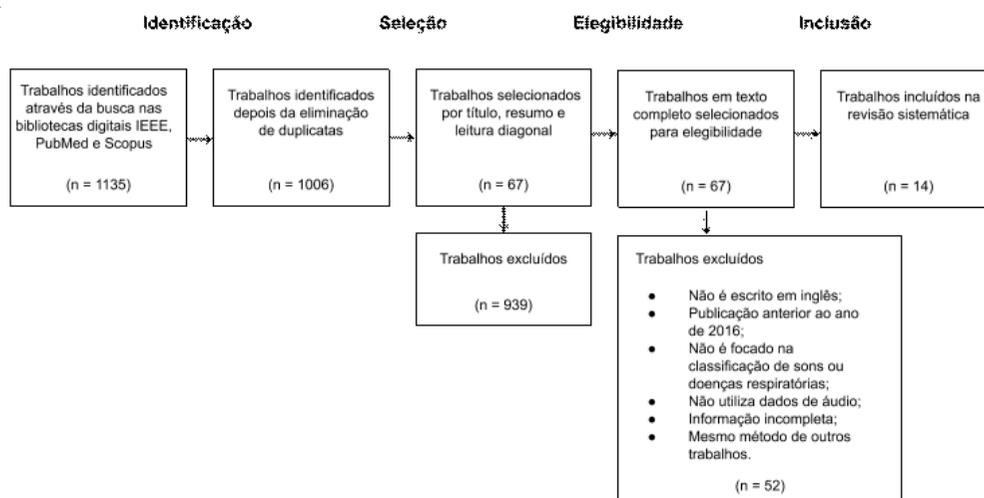


Figura 1 – Diagrama de fluxo das etapas da revisão sistemática.

Scopus. Posteriormente, houve a eliminação de duplicatas e trabalhos indisponíveis, resultando em 1006 artigos identificados. Na etapa de seleção, 939 artigos foram excluídos com base no título, resumo e leitura diagonal. Por fim, 67 artigos em texto completo foram submetidos à elegibilidade, a qual resultou na exclusão de 52 trabalhos. As etapas citadas resultaram na inclusão de 14 artigos elegíveis nesta revisão e estão expostas na Figura 1.

Base de dados

Em geral, os trabalhos revisados utilizam bases de dados adquiridas através de sistemas de aquisições desenvolvidos pelos próprios autores ou disponíveis publicamente. As bases privadas são relativas aos trabalhos de Naqvi et al.⁽⁴⁻⁵⁾, Meng et al.⁽⁶⁾, Aziz et al.⁽⁷⁾ e Vaityshyn et al.⁽⁸⁾. Já as bases públicas são ICBHI 2017* e R.A.L.E**. As bases de dados utilizadas para classificação de doenças e sons respiratórios estão sintetizadas na Tabela 1.

As amostras de sons pulmonares coletadas pelos próprios autores foram adquiridas de pacientes saudáveis e enfermos. As enfermidades presentes incluem asma^(4,8), bronquite^(4,6,8), DPOC⁽⁸⁾, pneumoconiose⁽⁸⁾ e pneumonia⁽⁶⁻⁸⁾. Os sinais de áudio foram coletados na posição da borda medial da escápula⁽⁵⁾, tórax^(5,7) e boca⁽⁴⁾ por meio de

estetoscópio⁽⁵⁻⁸⁾ ou microfone^(4-5,7). A base de dados de Naqvi et al.⁽⁵⁾ consistiu em 737 gravações de 10 s, Meng et al.⁽⁶⁾ em 705 gravações de 44 pacientes, Aziz et al.⁽⁷⁾ em 910 gravações de 85 pacientes, Naqvi et al.⁽⁴⁾ em 1576 gravações de 159 pacientes com duração de 10 s e Vaityshyn et al.⁽⁸⁾ em gravações de 157 pacientes.

A base de dados pública ICBHI 2017 possui 920 gravações, com duração média de 21.5 s, coletadas de 126 pacientes. Os áudios foram adquiridos da traqueia e das posições torácicas anteriores direita e esquerda, posteriores direita e esquerda e laterais esquerda e direita por meio de estetoscópio eletrônico. As amostras de áudio contêm 6898 ciclos respiratórios, dos quais 1864 contêm estertores, 886 contêm sibilos, 506 contêm ambos e o restante não possui nenhum som respiratório patológico.

R.A.L.E. é uma base comercialmente disponível, com mais de 50 amostras de sons pulmonares normais e anormais. Os sons na superfície do tórax ou no pescoço foram registrados com acelerômetros de contato e as gravações na boca foram realizadas com microfone de eletreto. As amostras possuem 10 s de duração.

As abordagens utilizadas pelos trabalhos revisados são divididas em dois grupos: abordagens que resolvem o problema de classificação selecionando manualmente as

Tabela 1 – Bases de dados utilizadas na classificação de doenças e sons respiratórios.

Referência	Base de dados	Instrumentação	Posições	Duração	Amostras	Indivíduos
(5)	Própria	Estetoscópio Microfone	Escápula Tórax	10 s	737	-
(6)	Própria	Estetoscópio Estetoscópio	-	-	705	130
(7)	Própria	Microfone Placa de vídeo	Pulmões direito e esquerdo	10 s	910	85
(4)	Própria	Microfone	Boca	10 s	1576	150
(8)	Própria	Estetoscópio	-	-	157	157
(9-15)	ICBHI 2017	Estetoscópio Microfone	Tórax	21.5 s	920	126
(16-17)	R.A.L.E	Acelerômetro Microfone	Tórax Pescoço Boca	10 s	+50	-

* https://bhichallenge.med.auth.gr/ICBHI_2017_Challenge.

** <http://www.rale.ca/>

características dos dados (*handcrafted features*) e abordagens que propõem o uso de aprendizagem profundo para classificar gravações de auscultas pulmonares (*feature learning*).

Características extraídas manualmente (*handcrafted features*)

As abordagens de características extraídas manualmente são aquelas em que a classificação dos dados acontece por meio de um pré-processamento manual dos dados. Nesse tipo de abordagem, são selecionadas as características mais relevantes sobre os dados a serem passados para o modelo a fim de obter a maior capacidade de generalização possível. Além disso, há a necessidade de um conhecimento prévio sobre os dados, pois as informações extraídas das amostras devem descrevê-las de maneira adequada para que a classificação seja satisfatória. A Figura 2 ilustra as etapas da abordagem de características extraídas manualmente.

As metodologias propostas nos trabalhos desta seção incluem características extraídas manualmente no domínio da frequência e no domínio do tempo. As características relativas ao domínio da frequência, abrangem os coeficientes cepstrais de frequência Mel (*Mel-frequency cepstral coefficients* - MFCCs)^(5, 7, 9, 17), coeficientes cepstrais de Gammatone (*Gammatone cepstral coefficients* - GTCC)⁽⁵⁾ e *Wavelets* (energia *wavelet*, entropia *wavelet* e similaridade)⁽⁶⁾. Já as características relativas ao domínio do tempo abrangem a energia⁽⁷⁾, entropia de Shannon^(4, 7), variância da amplitude⁽⁷⁾, amplitude pico a pico e seu desvio padrão⁽⁴⁾ e o valor eficaz da amplitude⁽⁴⁾. As metodologias foram avaliadas com o método baseado em instâncias *k*-

Nearest Neighbors (kNN)⁽⁴⁻⁷⁾ e os classificadores *Support-Vector Machines* (SVM)⁽⁶⁻⁷⁾, *Artificial Neural Network* (ANN)^(6, 17) e Árvore de decisão⁽⁹⁾. A classificação de auscultas pulmonares ocorreu entre as classes Normal, Pneumonia, Bronquite e Pneumotórax⁽⁵⁾; Normal, Ronco e Crepitações⁽⁶⁾; Normal e Pneumonia⁽⁷⁾; Normal, Bronquite e Asma⁽⁴⁾; Normal e Crepitação⁽⁹⁾; Normal, Crepitações e Sibilos⁽¹⁷⁾.

Naqvi et al.⁽⁵⁾ relatou 99,5% de acurácia, Meng et al.⁽⁶⁾ 85,43% de acurácia com o uso de ANN, Aziz et al.⁽⁷⁾ 99,7% de acurácia com o uso de SVM de kernel polinomial de grau dois, Naqvi et al.⁽⁴⁾ 99,3% de acurácia, Chambres et al.⁽⁹⁾ 85% de acurácia e Sengupta et al.⁽¹⁷⁾ 97% de acurácia.

A Tabela 2 apresenta um resumo geral dos trabalhos revisados que utilizam a abordagem de características extraídas manualmente. Destacam-se os rótulos, os modelos de classificação utilizados, as características extraídas e a quantidade de amostras.

Aprendizagem de características (*feature learning*)

Diferentemente das anteriores, as abordagens conhecidas como aprendizagem de características propõem soluções através do uso de aprendizagem profunda. Nessa abordagem, o processamento dos dados é feito diretamente pelo modelo, a fim de extrair as características mais valiosas para a tarefa de classificação, de modo que não é necessário um conhecimento prévio sobre os dados. No entanto, é essencial entender quais tipos de dados estão sendo empregados no modelo. Os modelos propostos pelos trabalhos que utilizam essa

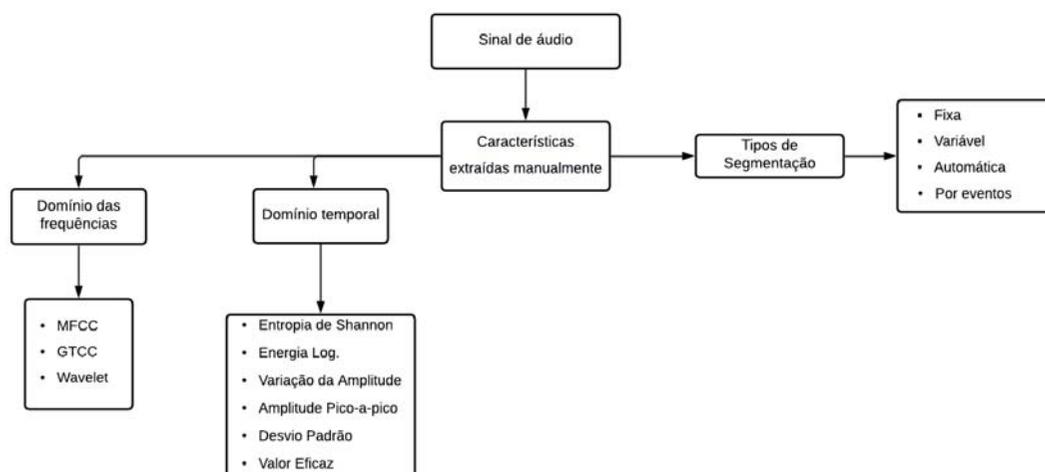


Figura 2 – Esquema de métodos de classificação utilizando a abordagem de características extraídas manualmente (*handcrafted features*).

Tabela 2 – Trabalhos que propõem soluções baseadas em extração manual de características.

Referência	Classes	Modelo	Características	Amostras
(5)	NO, BE, PA e PX	KNN	MFCC, GTCC	737
(6)	NO, CE e RO	SVM, KNN, ANN	Coef. de Wavelet	705
(7)	NO e PA	SVM, KNN	MFCC, VE, ES, EL, SNR	910
(4)	NO, BE e AS	KNN	PAP, ES, SD, VE	986
(9)	NO e CE	Árvore de Decisão	MFCC	920
(17)	NO, CE e SI	ANN	MFCC, Coef. Wavelet	68

Abreviação: **NO**: Normal; **SI**: Sibilos; **CE**: Crepitações; **RO**: Ronco; **AS**: Asma; **BE**: Bronquite; **PA**: Pneumonia; **PX**: Pneumotórax; **VE**: Valor Eficaz; **ES**: Entropia de Shannon; **PAP**: Amplitude Pico-a-pico; **EL**: Energia Log.; **SD**: Desvio Padrão; **SNR**: Relação Sinal-Ruído.

abordagem incluem *Recurrent Neural Network* (RNN)⁽¹¹⁾; *Noise-Masking Recurrent Neural Network* (NMRNN)⁽¹²⁾, uma variação do modelo RNN para redução de ruídos dos sinais de áudio; *Convolutional Neural Network* (CNN)^(8, 13, 14); e variações, como *Alexnet*⁽¹⁶⁾. Há também metodologias que propõem arquiteturas híbridas de ambos modelos (CNN-RNN)⁽¹⁵⁾ e, em casos mais raros, é observada a utilização de *Residual Neural Network* (Resnet)⁽¹⁰⁾. O esquema desse tipo de abordagem está ilustrado na Figura 3.

Neste tipo de abordagem, do mesmo modo ocorre o pré-processamento dos dados. Uma das técnicas de recorrente processamento dos dados é a *Short-term Fourier Transform* (STFT)⁽¹³⁾, por meio da qual é possível realizar a análise espectral dos sinais em relação ao tempo. Através do emprego da STFT, é possível a geração de espectrogramas dos sinais de áudio^(8, 10, 12-15), que permite a análise e visualização do áudio em forma de imagem. Outra forma de representação visual, acontece através dos escalogramas⁽¹⁶⁾, resultado da *Continuous Wavelet Transformation* (CWT).

Em relação aos resultados relatados nos trabalhos que seguem essa proposta de processamento dos dados, temos em Liu et al.⁽¹³⁾ 81,62% de acurácia na classificação dos áudios Normal e Crepitações. Em Chen et al.⁽¹⁰⁾, no qual é proposto um cenário de classificação parecido, com adição do reconhecimento de roncos, foi reportada a acurácia de 98%. Ambos os trabalhos validaram suas propostas utilizando a base de dados ICBHI 2017.

Nos trabalhos de Acharya et al.⁽¹⁵⁾, Demir et al.⁽¹⁴⁾ e Kochetov et al.⁽¹²⁾ foram obtidas acurácias de 71,87%, 71,15% e 65,7%, respectivamente, para o cenário de classificação das amostras em Normal, Crepitações, Sibilos

e Ambos (Sibilos e Crepitações), na base ICBHI 2017.

Ainda em relação à classificação dos sons adventícios, tem-se Jayalakshmy et al.⁽¹⁶⁾, no qual foi reportada uma acurácia de 83,7% na classificação de Normal, Crepitações, Sibilos e Ronco em áudios pertencentes à base de dados R.A.L.E.

Em Vaityshyn et al.⁽⁸⁾, foi obtida acurácia de 80% utilizando como base de dados ICBHI 2017 para classificação de amostras de áudio em: Pneumonia, Asma, Bronquite, Doença Obstrutiva Crônica e Pneumoconiose.

Outra forma de proposta de processamento dos dados é a visualização das amostras através de seus coeficientes MFCC, os quais fornecem informações valiosas sobre as frequências principais que são reconhecidas pelo ouvido humano. Um trabalho no qual essa forma de processamento dos dados foi explorada é o de Perna e Tagarelli⁽¹¹⁾, em que se observa acurácia máxima de 99% na base de dados ICBHI 2017 e que envolve classificar amostras entre patologias não crônicas, como Infecção no trato respiratório inferior e superior, e patologias crônicas, como Doença obstrutiva crônica, Asma e Bronquite.

A Tabela 3 reúne resumidamente os trabalhos que utilizam da abordagem baseada na aprendizagem de característica. Destacam-se os modelos utilizados, as características extraídas, os rótulos e a amostragem dos dados.

DISCUSSÃO

A auscultação tradicional possui limitações. Primeiramente, ela deve ser realizada em um ambiente propício e por um profissional especializado. Quando

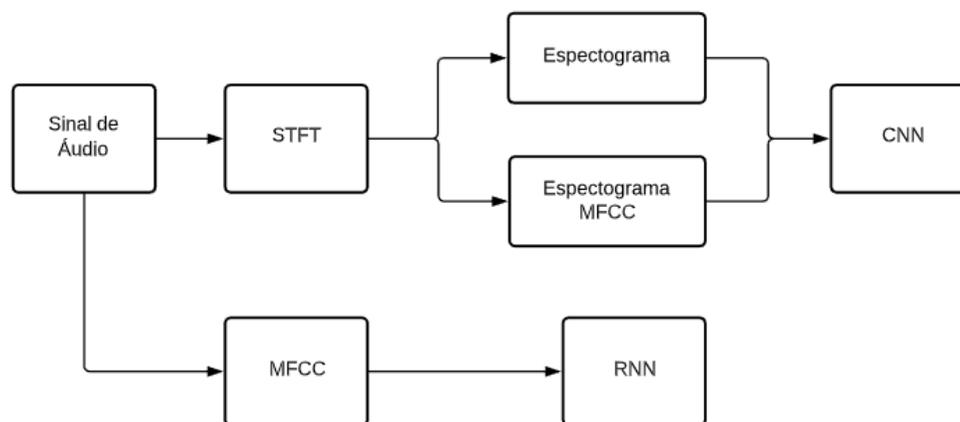


Figura 3 – Esquema de métodos de aprendizagem de características.

Tabela 3 – Trabalhos que propõem soluções baseadas em aprendizagem de características.

Referência	Classes	Modelo	Características	Amostras
(13)	NO e CE	CNN	STFT	920
(10)	NO, CE e RO	ResNet	Espectrograma	920
(15)	NO, CE, SI e SC	CNN-RNN	Espectrograma Mel	920
(14)	NO, CE, SI e SC	CNN	Espectrograma	920
(12)	NO, CE, SI e SC	NMRNN	Espectrograma	920
(16)	NO, CE, SI e RO	CNN (Alexnet)	Escalograma	68
(8)	AS, BE, PE, PA, PD e SA	CNN	Espectrograma	157
(11)	NO, CE, SI e SC DC, NC e SA	RNN	MFCC	920

Abreviação: **NO**: Normal; **SI**: Sibilos; **CE**: Crepitações; **SC**: Sibilos e Crepitações; **RO**: Ronco; **AS**: Asma; **BE**: Bronquite; **PA**: Pneumonia; **PE**: Pneumoconiose; **PD**: Doença Pulmonar Obstrutiva Crônica; **DC**: Doença crônica; **NC**: Doença não crônica; **SA**: saudável.

diferentes regiões do tórax são auscultadas, resultam-se diferentes características sonoras. Além disso, os sons pulmonares são frequentemente sobrepostos por sons de outros órgãos, o que aumenta a complexidade do problema e pode afetar diretamente a sensibilidade auditiva do profissional de saúde, resultando em falsos diagnósticos.

Em geral, os trabalhos revisados propõem soluções de aprendizagem de máquina para o problema de classificação de sons associados a doenças respiratórias. Dentre as técnicas empregadas nesses trabalhos, destacam-se a extração de características no domínio do tempo e frequência e a aprendizagem de características com CNN e RNN.

Dentre os trabalhos incluídos, é possível notar a motivação dos pesquisadores em resolver a seguinte problemática: doenças pulmonares afetam a vida humana e são a terceira maior causa de morte em todo o mundo. A detecção precoce dessas doenças tem sido eficaz em reduzir a alta taxa de mortalidade, em limitar a proliferação das doenças e a aumentar a eficácia do tratamento de pacientes enfermos.

As principais limitações encontradas nessa área de pesquisa incluem a escassez de dados disponíveis para treinar e avaliar classificadores. Grande parte dos trabalhos utilizam bases de dados próprias, o que dificulta a comparação entre as soluções propostas. Trabalhos que utilizam as bases de dados públicas, como ICBHI 2017, e bases disponíveis comercialmente, como R.A.L.E., são comparáveis e estabelecem uma base de referência para pesquisas futuras⁽⁹⁻¹⁵⁾. Além disso, alguns desafios até este momento requerem investigações. Esses desafios são:

REFERÊNCIAS

- Karnath B, Boyars MC. Pulmonary auscultation. *Hospital Physician*. 2002; 38(1), 22-26.
- Sarkar M, Madabhavi I, Niranjana N, Dogra M. Auscultation of the respiratory system. *Ann Thorac Med*. 2015;10(3):158-168.
- Principais itens para relatar Revisões sistemáticas e Meta-análises: A recomendação PRISMA. *Epidemiol. Serv. Saúde* [Internet]. 2015 June [cited 2020 Sep 22]; 24(2): 335-342. Available from: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S2237-96222015000200335&lng=en. <http://dx.doi.org/10.5123/S1679-49742015000200017>.
- Naqvi SZH, Choudhry MA, Khan AZ, Shakeel M. Intelligent System for Classification of Pulmonary Diseases from Lung Sound. In: 2019 13th International Conference on Mathematics, Actuarial Science, Computer Science and Statistics (MACS). IEEE; 2019. p. 1-6.
- Naqvi SZH, Choudhary MA, Tariq Z, Waseem A. Automated Detection and Classification of Multichannel Lungs Signals using EMD. In: 2020 International Conference on Electrical, Communication, and Computer Engineering (ICECCE). IEEE; 2020. p. 1-6.
- Meng F, Shi Y, Wang N, Cai M, Luo Z. Detection of respiratory sounds based on wavelet coefficients and machine learning. *IEEE Access*. 2020;.
- Aziz S, Khan MU, Shakeel M, Mushtaq Z, Khan AZ. An Automated System towards Diagnosis of Pneumonia using Pulmonary Auscultations. In: 2019 13th International Conference on Mathematics, Actuarial Science, Computer Science and Statistics (MACS). IEEE; 2019. p. 1-7.
- Vaityshyn V, Chekhovych M, Poreva A. Convolutional neural networks for the classification of bronchopulmonary system diseases with the use of lung sounds. In: 2018 IEEE 38th International Conference on Electronics and Nanotechnology (ELNANO). IEEE; 2018. p. 383-386.
- Chambres G, Hanna P, Desainte-Catherine M. Automatic detection of patient with respiratory diseases using lung sound analysis. In: 2018 International Conference on Content-Based Multimedia Indexing (CBMI). IEEE; 2018. p. 1-6.
- Chen H, Yuan X, Pei Z, Li M, Li J. Triple-classification of respiratory sounds using optimized s-transform and deep residual networks. *IEEE Access*. 2019;7:32845-32852.
- Perna D, Tagarelli A. Deep auscultation: Predicting respiratory anomalies and diseases via recurrent neural networks. In: 2019 IEEE 32nd International Symposium on Computer-Based Medical Systems (CBMS). IEEE; 2019. p. 50-55.
- Kochetov K, Putin E, Balashov M, Filchenkov A, Shalyto A. Noise masking recurrent neural networks for respiratory sound classification. In: International Conference on Artificial Neural Networks. Springer; 2018. p. 208-217.
- Liu R, Cai S, Zhang K, Hu N. Detection of Adventitious Respiratory Sounds based on Convolutional Neural Network. In: 2019 International Conference on Intelligent Informatics and Biomedical Sciences (ICIBMS). IEEE; 2019. p. 298-303.
- Demir F, Ismael AM, Sengur A. Classification of lung sounds with CNN model using parallel pooling structure. *IEEE Access*. 2020;.
- Acharya J, Basu A. Deep Neural Network for Respiratory Sound Classification in Wearable Devices Enabled by Patient Specific Model Tuning. *IEEE transactions on biomedical circuits and systems*. 2020;14(3):535-544.
- Jayalakshmy S, Sudha GF. Scalogram based prediction model for respiratory disorders using optimized convolutional neural networks. *Artificial Intelligence in Medicine*. 2020;103:101809.
- Sengupta N, Sahidullah M, Saha G. Lung sound classification using cepstral-based statistical features. *Computers in biology and medicine*. 2016;75:118-129.

CONCLUSÃO

Esta revisão sistemática da literatura forneceu uma visão geral sobre a análise de auscultas pulmonares através de técnicas de aprendizagem de máquina, bem como seus resultados e suas limitações, além de possibilitar a melhor visualização dos desafios encontrados e os avanços dentro da área. De modo geral, os resultados referentes ao problema de classificação de sons associados a doenças respiratórias através da rede neural profunda se mostram promissores, com grandes possibilidades de superar os limites da ausculta tradicional, bem como auxiliar os profissionais de saúde que realizam esse tipo de exame na prestação de um diagnóstico com maior precisão.

AGRADECIMENTOS

Esta pesquisa foi financiada pela Samsung Eletrônica da Amazônia Ltda., realizada no âmbito do Projeto Samsung-UFAM de Ensino e Pesquisa (SUPER), conforme previsto no Artigo 48 do Decreto nº 6.008 / 2006 (SUFRAMA), nos termos da Lei Federal nº 8.387 / 1991, através do convênio 001/2020, firmado com a Universidade Federal do Amazonas e a FAEPI, Brasil.