

# Detecção de Problemas Respiratórios através de Áudios Pulmonares utilizando Aprendizado de Máquina

Ranna R. F. da Costa<sup>1</sup>, João C. Xavier-Júnior<sup>1</sup>, Arthur C. Gorgônio<sup>2</sup>,  
Cephas A. da S. Barreto<sup>2</sup>, Douglas F. A. Lima<sup>1</sup>, Anne Magaly de P. Canuto<sup>2</sup>

<sup>1</sup>Instituto Metr pole Digital - Universidade Federal do Rio Grande do Norte  
Natal, Rio Grande do Norte – Brasil

<sup>2</sup>Departamento de Inform tica e Matem tica Aplicada  
Universidade Federal do Rio Grande do Norte  
Natal, Rio Grande do Norte - Brasil

ranna.raabe@gmail.com, jcxavier@imd.ufrn.br, arthurgorgonio@ppgsc.ufrn.br

cephasax@gmail.com, douglas.felipelima18@gmail.com, anne@dimap.ufrn.br

**Abstract.** *Respiratory and lung problems affect a high number of people every year . As a result, great ammount of effort has been put in order to provide understanding and diagnosis of these types of diseases leading to an early search for treatment or even an adequate diagnosis of it. In this context, recent research has been using computational techniques over respiratory audios to classify possible breathing problems. This work has similar objective and presents a performance analysis of classifiers over a dataset generated from audios. The results obtained point out that tree-based models, such as Random Forest and Decision Tree, performed better than other models. However there is still room for improvements in terms of better and rubust models.*

**Resumo.** *Problemas respirat rios e pulmonares atingem uma quantidade elevada de pessoas ano ap s ano, inclusive levando   morte. Em virtude disso, muitas iniciativas buscam entender e facilitar o diagn stico desses tipos de doenas para que seja poss vel a busca precoce por tratamento ou mesmo o diagn stico adequado. Olhando para este contexto, pesquisas recentes utilizam t cnicas computacionais sobre  udios respirat rios para a classifica o de poss veis problemas na respira o. Este trabalho tem o mesmo objetivo e apresenta a an lise de alguns classificadores sobre um dataset gerado a partir de  udios em seu formato original. Os resultados obtidos apontam que modelos baseados em  rvores, como Random Forest e Decision Tree, tiveram um desempenho melhor que outros modelos. No entanto, ainda h  espao para melhorias em termos de modelos melhores e de melhor qualidade.*

## 1. Introdu o

Doenas respirat rias s o dist rbios que ocorrem nos pulm es ou vias a reas e que implicam no mau funcionamento do sistema respirat rio, causando incapacidade e at  morte prematura. Segundo [Rocha et al. 2019], as complica es nos pulm es s o um dos problemas de sa de que mais causam mortes e, em geral, s o divididas em tr s tipos: doenas nas vias a reas, doenas no tecido pulmonar e doenas na circula o pulmonar. H  ainda

uma série de doenças pulmonares que envolvem um ou mais desses três tipos. Um grande grupo, os problemas pulmonares, tem os seguintes tipos mais comuns: asma; doença pulmonar obstrutiva crônica (DPOC); pneumonia; bronquite; câncer de pulmão; tuberculose; silicose; dentre outras.

Todos os distúrbios pulmonares podem afetar pessoas de qualquer faixa etária, comumente a partir dos 40 anos de idade, e apesar de suas complicações, as doenças pulmonares podem ser prevenidas. O diagnóstico das doenças é feito por um pneumologista, médico especialista no tratamento das patologias das vias aéreas inferiores, geralmente por meio de consultas médicas com o estetoscópio ou broncoscopia. Por esse motivo, existem muitos casos de doenças pulmonares que não são tratados em razão de os indivíduos não buscarem um especialista, seja por acessibilidade ou condição financeira, o que retarda e dificulta a medicação e, conseqüentemente, o tratamento ou a cura da doença, quando possível.

Dentro desse contexto, diversas pesquisas buscam uma maneira de prever tais doenças utilizando técnicas de Aprendizado de Máquina (AM). Para tal, são utilizadas informações como imagens, dados de exames, áudios respiratórios e anamneses. Então, as informações são tratadas e servem como fonte para métodos computacionais aplicados para auxiliar no diagnóstico tão precoce quanto possível de uma provável doença.

O presente trabalho tem como objetivo analisar as iniciativas de pesquisa que propõem-se a utilizar áudios de respiração para classificação de doenças respiratórias utilizando AM. Após esta análise, também é um objetivo realizar um breve estudo sobre classificadores em um *dataset* gerado com áudios respiratórios. Os direcionamentos obtidos através da análise de iniciativas similares e os resultados obtidos nos experimentos já realizados apontam que é possível a construção de um sistema capaz de coletar áudios de respiração e realizar um diagnóstico preliminar utilizando AM.

## 2. Conceitos Relacionados

### 2.1. Problemas Respiratórios

Os problemas respiratórios abordados neste trabalho, e seus respectivos conceitos, são, de acordo com [Beers et al. 2008]:

- **Asma:** quadro clínico em que as vias aéreas se estreitam, geralmente de forma reversível, em resposta a certos estímulos;
- **Bronquiectasia:** trata-se um alargamento (dilatação) irreversível de partes dos dutos respiratórios ou brônquios resultante de lesão na parede das vias aéreas;
- **Doença Obstrutiva Pulmonar Crônica:** do inglês *Chronic Obstructive Pulmonary Disease* (COPD), trata-se de uma doença incurável, genética ou não, que impõe dificuldades para respirar. Sua principal causa é o consumo de cigarros e suas formas mais comuns de apresentação são através de Bronquite Obstrutiva Crônica ou Enfisema Pulmonar;
- **Infecção no Trato respiratório Inferior:** do inglês *Lower Respiratory Tract Infections* (LRTI), trata-se de infecções de cunho geral no trato respiratório inferior, como o próprio nome define. Pode se apresentar de várias formas, dentre elas com pneumonia ou bronquiolite;

- **Infecção no Trato respiratório Superior:** do inglês *Upper Respiratory Tract Infections* (URTI), trata-se de infecções de cunho geral no trato respiratório superior e que normalmente se apresenta como gripe, friagem e afetam principalmente nariz e garganta;
- **Pneumonia:** infecção profunda nos pulmões que chegou ao nível dos alvéolos.

Além destas doenças, também existe a condição onde não há nenhum problema respiratório aparente, que foi nomeada “saudável (*Healthy*)” para o escopo deste trabalho. Outra característica importante relacionada à doenças respiratórias é a forma de identificação de alguns problemas em áudios de respiração, o que normalmente é feito a partir de observação de três possíveis características:

- **chiado:** citado no trabalho como “*Wheeze*”, se apresenta como um chiado em uma ou mais partes do som da respiração. Está relacionado principalmente aos problemas nas passagens de ar, como bronquites;
- **estalo:** apresentado em inglês como “*Crackle*”, tem sua exposição notada em sons que parecem ser estalos ou estampidos durante a respiração;
- **chiado e estalo:** quando as duas características anteriores estão presentes simultaneamente em um som de respiração.

## 2.2. Aprendizado de Máquina

Segundo [Faceli et al. 2015], em Aprendizado de Máquina “computadores são programados para aprender com a experiência passada.” Desta maneira é possível realizar uma série de tarefas, como agrupamento, regressão e classificação, por exemplo. Na classificação (também chamada de predição), uma instância de determinado problema é apresentada a um método de AM para que este determine a classe (rótulo) para a instância. O método faz isso baseado na experiência passada, ou seja, no conhecimento obtido com as instâncias já rotuladas apresentadas na etapa de treinamento.

Neste trabalho foram utilizados 5 métodos de classificação e também 3 métodos chamados comitês de classificadores, que utilizam um grupo de classificadores para realizar certa tarefa. Os métodos utilizados, juntamente com as abreviações para as implementações usadas, são: **Árvore de Decisão (J48)**; **K-NN (IBK)**; **Naive Bayes (NB)**; **Multi Layer Perceptron (MLP)**; **Support Vector Machine (SVM)** e os comitês de classificadores: **Random Forest (RF)**; e **Boosting (AB)**. Esses métodos foram escolhidos por suas características e ampla utilização [Faceli et al. 2015, Berry and Linoff 2011]. Após a execução dos métodos passa-se à fase de pós processamento, onde os resultados devem ser averiguados na busca do método que conseguiu realizar a tarefa com melhor desempenho.

## 3. Trabalhos Relacionados

Em 2017, na Conferência Internacional sobre Informática para Saúde e Biomédica (*International Conference on Biomedical Health Informatics - ICBHI*), foi proposto um desafio com o objetivo de identificar automaticamente características problemáticas na respiração (*crackle*, *wheeze*, *crackle and wheeze* e *normal*) através de áudios, aplicando metodologias de inteligência computacional. Para isso, foi disponibilizado um *dataset* composto por uma coleção de áudios respiratórios coletado por equipes médicas da Grécia e de Portugal, e um conjunto de arquivos sobre os áudios e pacientes.

A coleção de áudios possui 920 áudios em formato “.wav” provenientes de 126 pacientes. O conjunto de arquivos possui: os registros dos ciclos respiratórios em cada áudio; e dados clínicos dos pacientes. O *dataset* apresentado na ICBHI foi concebido com foco na diversidade, uma vez que os áudios foram coletados em diferentes lugares, com condições climáticas e ambientais diferentes, com aparelhos (microfones ou estetoscópios) diferentes e em diferentes regiões do corpo.

Um dos trabalhos que utilizou o conjunto de áudios mencionado foi o de [Jakovljević and Lončar-Turukalo 2018]. Para a construção da base de dados os autores aplicaram técnicas para tratamento dos áudios e extraíram as melhores características (segundo eles) da seguinte forma: re-amostragem dos áudios para 4000Hz; diminuição do ruído, feita de duas formas, uma com filtro passa baixa com valor variável de acordo com uma função de frequência e outra com um filtro passa alta com frequência 100Hz; supressão de ruído, com um filtro para supressão de ruído aplicado sobre os dois resultados anteriores; e, por fim, foi extraído o coeficiente *Mel Frequency Cepstral Coefficient* (MFCC) para 16 faixas de frequência entre 50Hz e 2000Hz. Este processo gerou, portanto, duas bases de dados.

Para realizar a tarefa de classificação os autores utilizaram o Modelo Oculto de Markov (do inglês, *Hidden Markov Model* - HMM). Foi modelada uma cadeia de Markov com base nas classes dos *datasets* e geradas algumas variações deles com base em seleção de atributos. Os resultados obtidos, foram de até 49.50% no valor de *score*. Uma métrica definida pelo desafio e expressa conforme a Equação 1.

$$Se = \frac{C_c + C_w + C_b}{T_c + T_w + T_b}, Sp = \frac{C_n}{T_n}, Score = \frac{Se + Sp}{2} \times 100 \quad (1)$$

onde,  $C$  significa o número de instâncias corretamente classificadas para certa classe;  $T$  o total de instâncias de certa classe;  $c$ ,  $w$ ,  $b$  e  $n$  são as classes *crackle*, *whezee* e *crackleWhezee* e *normal*, respectivamente; e  $S$  a taxa de acerto para um determinado grupo de classes.

Sobre o mesmo conjunto de áudios (proveniente do ICBHI 2017), o trabalho de [Serbes et al. 2018] tem também forte apelo no pré processamento e extração de características dos áudios. No trabalho é aplicado o seguinte processo: re-amostragem dos áudios para 4000Hz; aplicação de um filtro multi frequência com limites entre 120Hz e 1800Hz; decomposição dos áudios em 3 faixas com duas abordagens: em uma (a), com a Transformada Rápida de Fourier (do inglês *Short Time Fourier Transform* - STFT); já na segunda (b), além da STFT, utilizam um coeficiente de ondas curtas (*Q-factor wavelet*). Resultam deste processo dois grupos distintos de áudios (a e b). Para cada grupo foi então extraída uma série de características definidas pelos autores, formando então os *datasets*.

Sobre os *datasets* foi aplicada a abordagem conhecida como PCA (do inglês *Principal Component Analysis*) com valores de variância de 90%, 95% e 99%. Desta forma, foram construídas, para cada *dataset*, 3 novas versões. Foi Utilizado o *Support Vector Machine* (SVM) para classificação e, como resultados, foi relatado pelos autores *score* máximo de 70.92%. Este valor foi obtido sobre o *dataset* feito pela abordagem (a) e com variância de 99% para o PCA.

Foram analisados, ainda, outros trabalhos sobre classificação de áudios pulmo-

nares, bem como outras iniciativas para criação de bases de dados. Dentre eles, se destacam [Sovijärvi et al. 2000, Riella et al. 2009, Grønnesby 2016, Grønnesby et al. 2017, Pramono et al. 2017, Kim et al. 2019]. Estes trabalhos buscam realizar a classificação de áudios pulmonares ou entender como as pesquisas nesse campo tem sido desenvolvidas. Alguns deles utilizam bases de dados diferentes da disponibilizada pelo ICBHI 2017, mas em todos eles nota-se um grande esforço em buscar o pré processamento mais adequado para tornar a classificação dos áudios o mais precisa possível.

### 3.1. Discussão dos Trabalhos

Em todos os trabalhos, a transformação dos áudios feita com rigor (filtros passa baixa, passa alta, de redução de ruído, transformação do domínio com STFT, entre outros) é justificada pela natureza heterogênea do conjunto de áudios. Apesar disso, retirar ruídos e frequências e transformar demasiadamente os áudios pode causar perda de informação relevante, principalmente quando se trata de um *dataset* tão diverso, o que pode acabar prejudicando o desempenho do classificador.

Nos trabalhos mencionados, após a transformação dos áudios, seguiu a extração de características e, nesse contexto, existe outro aspecto importante: quais características extrair? Em ambos os trabalhos as características são apresentadas sem nenhuma menção ao porquê podem contribuir ou não para o resultado de classificação. Por exemplo, enquanto o trabalho analisado ([Jakovljević and Lončar-Turukalo 2018]) utiliza apenas o coeficiente MFCC, o trabalho de [Grønnesby 2016] realiza uma comparação entre diversas características extraídas comumente para áudios respiratórios e desencoraja o uso do MFCC como principal característica extraída para trabalhos com áudios respiratórios. Desta forma, o MFCC poderia ser usado em conjunto com outras características possivelmente mais representativas.

Outro ponto foi a escolha do classificador, visto que cada trabalho adotou um classificador único, o que acabou concentrando a análise na transformação dos áudios e na extração de características. Seria interessante, então, discutir o desempenho de diversos classificadores sobre um *dataset* formado a partir de áudios respiratórios. Esta avaliação poderia direcionar que tipos de classificadores podem ter melhor resultado para esta tarefa.

## 4. Proposta

Esta seção descreve os experimentos realizados sobre o conjunto de áudios disponibilizado pelo ICBHI 2017.

### 4.1. Dados

O *dataset* é composto por 920 áudios com durações variadas (entre 10 e 90 seg.) e no formato “.wav”. Foram gravados em diversos pontos da cavidade torácica usando microfone ou estetoscópio eletrônico. Cada áudio foi classificado por um especialista em: *Healthy*, *Asthma*, *COPD*, *URTI*, *LRTI*, *Bronchiectasis*, *Pneumonia* e *Bronchiolitis*. Também foi possível subdividir os 920 áudios em 6.898 áudios menores que representam os ciclos respiratórios. Cada ciclo é anotado com uma das classes: *Crackle*, *Whezee*, *Crackle\_Whezee* e *Normal*. Como determinado no desafio da ICBHI 2017, foi usado o conjunto com 6.898 áudios.

## 4.2. Pré processamento de Dados

A transformação dos áudios em um *dataset* foi feita de forma a preservar os áudios originais. Utilizando JAudio [McKay ], foram extraídas de cada um as seguintes características: *Spectral Centroid*; *Spectral Variability*; *Compactness*; *Method of Moments*; *Zero Crossings*; *Beat Sum*; *Strongest Beat*; *Strength Of Strongest Beat*; *Strongest Frequency Via Zero Crossings*; *Strongest Frequency Via FFT Maximum*; e *Strongest Frequency Via Spectral Centroid*. O trabalho de [Grønnesby 2016] cita estas características como mais representativas para a classificação de áudios respiratórios.

Este processo gerou um total de 30 atributos que foram juntados aos dados dos exames (4 atributos) e à classe (1 atributo), perfazendo 35 atributos. Ao final, o *dataset* tinha 6.898 instâncias, 35 atributos e 4 possíveis classes (<http://bit.ly/2vjNHaz> - atributos). A parte final do pré processamento do *dataset* envolveu a normalização de todos os dados numéricos e a padronização dos dados categóricos, além da substituição de valores ausentes por média ou moda.

## 4.3. Configuração do Experimento

Através de seleção randômica de atributos foram criadas 14 versões do *dataset*, perfazendo um total de 15 *datasets* (original e 14 versões). Cada algoritmo foi executado sobre os 15 *datasets* utilizando a metodologia de validação cruzada *10-fold cross validation*. Ao final de cada execução, a matriz de confusão foi analisada e foi calculado o *score* médio. Os experimentos utilizaram os algoritmos da plataforma Weka [Hall et al. 2009] com as configurações padrão e foram executados em um computador com processador Intel(R) Xeon(R) E5-4610 v4 - 1.80GHz, 6 núcleos, e RAM com 6 Gb.

## 5. Resultados Experimentais

Os resultados mostrados na Tabela 1 referem-se aos valores de *score* médio para cada classificador ou comitê sobre os *datasets*. Em negrito estão marcados os melhores resultados obtidos sobre cada *dataset* e a última linha (destacada) traz a média geral de *score* por classificador. Como poder ser visualizado na referida tabela, o *Random Forest* obteve melhor resultado de *score* para todos os *datasets*. Ele também obteve a melhor média geral (72,78%), seguido pelo J48 (69,16%).

Para comprovar a validade estatística dos resultados, foi executado o teste de *Friedman*, modalidade não paramétrica com nível de significância padrão em 5%. Como resultado foi obtido um *p-value* igual a 1,093738E-16, que significa que os resultados são significativamente diferentes. Em seguida foi executado o teste *post-hoc Nemenyi*, que mostrou a diferença estatística entre cada par de classificadores. Como pode ser visualizado na Tabela 2, o *Random Forest* foi estatisticamente melhor que todos os outros classificadores, com exceção do J48 (0,67863) e do IBK (0,29675).

Os resultados obtidos e as análises dos testes estatísticos permitem afirmar que o método *Random Forest* foi estatisticamente superior aos demais, com exceção do J48 e IBK. O J48, por sua vez, ficou como segundo melhor método, à frente de todos os demais com diferença estatisticamente significativa, menos para o IBK e SVM. Além disso, também foi possível observar que os classificadores baseados em árvores (J48 e *Random Forest*) obtiveram os melhores resultados.

**Tabela 1. Scores obtidos em cada um dos datasets.**

	Naive	J48	Ibk	MLP	SVM	AdaBoost	RF
<b>original</b>	17,52%	70,15%	70,85%	54,99%	57,77%	50,00%	<b>74,36%</b>
<b>dataset1</b>	19,13%	68,79%	67,88%	56,39%	56,47%	50,00%	<b>73,61%</b>
<b>dataset2</b>	14,42%	70,02%	68,19%	55,12%	57,65%	50,00%	<b>71,93%</b>
<b>dataset3</b>	17,97%	71,32%	67,71%	61,31%	58,04%	50,00%	<b>74,05%</b>
<b>dataset4</b>	17,21%	69,86%	69,16%	59,89%	57,78%	50,00%	<b>73,90%</b>
<b>dataset5</b>	17,13%	68,23%	67,96%	58,70%	56,57%	50,00%	<b>73,33%</b>
<b>dataset6</b>	18,51%	70,47%	67,59%	56,50%	58,39%	50,00%	<b>74,58%</b>
<b>dataset7</b>	17,45%	67,82%	66,81%	56,13%	55,44%	50,00%	<b>71,19%</b>
<b>dataset8</b>	20,00%	70,11%	69,57%	55,48%	56,11%	52,74%	<b>72,07%</b>
<b>dataset9</b>	18,33%	71,61%	68,38%	56,33%	58,80%	50,00%	<b>73,04%</b>
<b>dataset10</b>	22,32%	69,89%	65,35%	57,21%	57,50%	50,00%	<b>70,98%</b>
<b>dataset11</b>	17,59%	68,46%	68,82%	57,65%	57,03%	53,14%	<b>73,48%</b>
<b>dataset12</b>	17,94%	67,47%	68,49%	54,64%	56,12%	53,48%	<b>72,42%</b>
<b>dataset13</b>	16,50%	65,42%	67,41%	54,73%	56,79%	53,67%	<b>71,10%</b>
<b>dataset14</b>	13,32%	67,81%	64,25%	51,07%	58,90%	50,00%	<b>71,68%</b>
<b>média</b>	17,69%	69,16%	67,89%	56,41%	57,29%	50,87%	<b>72,78%</b>

**Tabela 2. Teste estatístico Nemenyi para todos os classificadores.**

	NB	J48	IBK	MLP	SVM	AB
<b>J48</b>	<b>0,00000</b>					
<b>IBK</b>	<b>0,00000</b>	0,99707				
<b>MLP</b>	<b>0,04860</b>	<b>0,03790</b>	0,17760			
<b>SVM</b>	<b>0,01280</b>	0,11988	0,39651	0,99957		
<b>AB</b>	0,86700	<b>0,00005</b>	<b>0,00069</b>	0,62260	0,34485	
<b>RF</b>	<b>0,00000</b>	0,67863	0,29675	<b>0,00007</b>	<b>0,00048</b>	<b>0,00000</b>

## 6. Conclusão e Trabalhos Futuros

Ao comparar os resultados obtidos neste trabalho com os resultados dos trabalhos vencedores do desafio da ICBHI 2017 (49.50% para [Jakovljević and Lončar-Turukalo 2018] e 70.92% para [Serbes et al. 2018]), foi possível notar que enquanto os trabalhos do desafio tiveram um grande esforço na transformação e “normalização” dos áudios, o presente trabalho obteve resultados ligeiramente superiores (1,86% de ganho no *score*) sem nenhuma manipulação nos áudios. Isso indica que há uma grande influência dos classificadores usados e também do bom conjunto de características extraídas, o que pode ser um norte para futuros trabalhos.

Com os resultados obtidos, acredita-se que um processo de extração de características mais robusto e o uso de classificadores com parâmetros otimizados podem trazer resultados ainda melhores para a classificação de áudios pulmonares. Dessa forma, vislumbramos a criação de um sistema para dispositivos móveis com objetivo de capturar áudios respiratórios e classificar estes áudios de acordo com possíveis doenças pulmonares utilizando modelos de AM.

Neste propósito, seria possível utilizar tal plataforma para construir uma base de dados com características brasileiras para auxílio aos profissionais da área de saúde e também, até para disponibilização à população. Logo, esta aplicação teria utilidade e impacto social ao auxiliar profissionais da saúde, pacientes e pesquisadores no entendimento e enfrentamento à doenças respiratórias.

## Referências

- Beers, M., Fletcher, A., and Jones, T. (2008). Manual merck de saúde para a família. *Merck Research Laboratories*. Disponível em [http://www.msdbrazil.com/msd43/m\\_manual/prefacio.htm](http://www.msdbrazil.com/msd43/m_manual/prefacio.htm).
- Berry, M. J. A. and Linoff, G. S. (2011). *Data Mining Techniques: For Marketing, Sales, and Customer Relationship Management*. John Wiley & Sons, Indianapolis, Indiana, 2 edition. Google-Books-ID: AyQfVTDJypUC.
- Faceli, K., Lorena, A. C., Gama, J., and Carvalho, A. (2015). *Inteligência Artificial: Uma abordagem de aprendizado de máquina*, volume 2. Livros Técnicos e Científicos Editora Ltda., Rio de Janeiro.
- Grønnesby, M. (2016). Automated lung sound analysis. Master's thesis, UiT Norges arktiske universitet.
- Grønnesby, M., Solis, J. C. A., Holsbø, E., Melbye, H., and Bongo, L. A. (2017). Machine learning based crackle detection in lung sounds. *CoRR*, abs/1706.00005:15.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., and Witten, I. H. (2009). The weka data mining software: an update. *ACM SIGKDD explorations newsletter*, 11(1):10–18.
- Jakovljević, N. and Lončar-Turukalo, T. (2018). Hidden Markov Model Based Respiratory Sound Classification. In Maglaveras, N., Chouvarda, I., and de Carvalho, P., editors, *Precision Medicine Powered by pHealth and Connected Health*, volume 66, pages 39–43. Springer Singapore, Singapore.
- Kim, J.-W., Kim, T., Shin, J., Choe, G., Lim, H. J., Rhee, C.-S., Lee, K., and Cho, S.-W. (2019). Prediction of Obstructive Sleep Apnea Based on Respiratory Sounds Recorded Between Sleep Onset and Sleep Offset. *Clinical and Experimental Otorhinolaryngology*, 12(1):72–78.
- McKay, C. Automatic Music Classification with jMIR. page 600.
- Pramono, R. X. A., Bowyer, S., and Rodriguez-Villegas, E. (2017). Automatic adventitious respiratory sound analysis: A systematic review. *PLoS ONE*, 12(5).
- Riella, R., Nohama, P., and Maia, J. (2009). Method for automatic detection of wheezing in lung sounds. *Brazilian Journal of Medical and Biological Research*, 42(7):674–684.
- Rocha, B. M., Filos, D., Mendes, L., Serbes, G., Ulukaya, S., Kahya, Y. P., Jakovljevic, N., Turukalo, T. L., Vogiatzis, I. M., Perantoni, E., Kaimakamis, E., Natsiavas, P., Oliveira, A., Jácome, C., Marques, A., Maglaveras, N., Pedro Paiva, R., Chouvarda, I., and de Carvalho, P. (2019). An open access database for the evaluation of respiratory sound classification algorithms. *Physiological Measurement*, 40(3):035001.
- Serbes, G., Ulukaya, S., and Kahya, Y. P. (2018). An Automated Lung Sound Preprocessing and Classification System Based OnSpectral Analysis Methods. In Maglaveras, N., Chouvarda, I., and de Carvalho, P., editors, *Precision Medicine Powered by pHealth and Connected Health*, IFMBE Proceedings, pages 45–49. Springer Singapore.
- Sovijärvi, A. R. A., Vanderschoot, J., and Earis, J. E. (2000). Standardization of computerized respiratory sound analysis. *European Respiratory Review*, page 65.