



SimBraRedes

III Simpósio Brasileiro de Teoria  
e Ciência de Redes

## APLICAÇÃO DE REDES DE VISIBILIDADE NO ESTUDO DE PADRÕES DE SONS ADVENTÍCIOS CAPTADOS NA AUSCULTA PULMONAR

**Dirceu de Freitas Piedade Melo<sup>1</sup>; Hernane Borges de Barros Pereira<sup>2</sup>**

<sup>1</sup> Doutor em Difusão do Conhecimento, Instituto Federal da Bahia, dirceu@ifba.edu.br

<sup>2</sup> Doutor em Engenharia Multimídia, Centro Universitário Senai Cimatec & Universidade do Estado da Bahia, hbbpereira@gmail.com;

### RESUMO

Este trabalho apresenta o estudo do reconhecimento de padrões para dois tipos de sons pulmonares adventícios utilizando redes de visibilidade e modularidade. Foram geradas 220 redes de visibilidade usando o algoritmo de mapeamento *visibility graphs* sobre as séries de desvio-padrão extraídas de 220 gravações de sons de auscultação pulmonar rotuladas em dois grupos (crackles e wheezes). Os resultados da comparação entre as modularidades das redes de visibilidade dos dois grupos, sugere que estes podem ser distinguidos através da modularidade, e que esta distinção pode estar associada às suas características sonoras de maior ou menor percussividade.

**PALAVRAS-CHAVE:** sons pulmonares adventícios, redes de visibilidade, modularidade

<http://doi.org/10.55664/simbraredes2024.002>

### 1 INTRODUÇÃO

A auscultação pulmonar é uma técnica médica extremamente antiga, utilizada há séculos para a detecção de distúrbios respiratórios. Apesar de sua longevidade, essa prática continua sendo amplamente empregada nos dias de hoje devido à sua simplicidade, praticidade e baixo custo. A técnica envolve a escuta dos sons internos do corpo, especificamente os produzidos pelo fluxo de ar através do sistema respiratório, tanto durante a expiração quanto na inspiração. Esses sons são captados pelo ouvido humano com a ajuda de um estetoscópio, um instrumento clássico e indispensável na prática clínica.

Durante o processo de auscultação, o profissional de saúde analisa os sons captados e os interpreta para classificá-los, o que auxilia na formulação de um diagnóstico clínico. No entanto, como esse procedimento depende da interpretação subjetiva do som pelo profissional, existe um grau significativo de subjetividade envolvido. Essa subjetividade pode, em alguns casos, levar a interpretações incorretas ou equívocos no diagnóstico<sup>1</sup>. Portanto, a habilidade e a experiência do profissional são cruciais, mas também são possíveis fontes de erro, o que sublinha a importância de métodos auxiliares na prática diagnóstica.

Com o avanço da tecnologia, novas ferramentas têm sido desenvolvidas para a classificação automática de sons de auscultação pulmonar. Essas inovações têm o potencial de proporcionar um apoio valioso aos profissionais de saúde, ajudando-os a tomar decisões mais precisas e reduzir a margem de erro nos diagnósticos. Entre os sons adventícios, ou sons anormais, mais comumente observados durante a auscultação pulmonar estão os wheezes e os crackles.

Os wheezes são caracterizados por um som contínuo, sibilante e musical, enquanto os crackles têm uma natureza sonora descontínua, explosiva e não musical. Esses sons não são apenas indicadores genéricos de problemas respiratórios, mas estão também associados a condições clínicas específicas. Os wheezes, por exemplo, estão frequentemente relacionados a doenças como asma, Doença Pulmonar Obstrutiva Crônica (DPOC) e obstrução por corpo estranho nas vias respiratórias. Por outro lado, os crackles são observados em condições como pneumonia, insuficiência cardíaca congestiva, fibrose pulmonar e bronquite crônica<sup>2</sup>.

Nos últimos anos, o interesse pelo estudo de sons de auscultação pulmonar com o auxílio de tecnologias digitais tem crescido significativamente. Isso se deve, em grande parte, ao avanço das técnicas de extração de características em sinais de áudio e ao aperfeiçoamento de algoritmos de aprendizagem de máquina. Essas ferramentas permitem uma análise mais detalhada e precisa dos sons, facilitando sua classificação automática<sup>3</sup>.



SimBraRedes

III Simpósio Brasileiro de Teoria  
e Ciência de Redes

Entre os atributos comumente utilizados em sistemas de classificação de sons de ausculta pulmonar estão os MFCCs (Mel-frequency cepstral coefficients), GTCC (Gammatone Cepstral Coefficients) e técnicas baseadas em wavelets, como energia wavelet, entropia wavelet e similaridade. Além disso, descritores como entropia de Shannon, variância da amplitude, amplitude pico a pico e seu desvio padrão, e o valor eficaz da amplitude também são amplamente utilizados<sup>4</sup>.

É interessante notar que muitos dos descritores usados para reconhecimento de fala e recuperação de informações musicais também são aplicados na classificação de sons pulmonares. Isso reflete a universalidade de certos métodos de análise de áudio, que podem ser adaptados para diferentes campos, incluindo a medicina. Recentemente, novas formas de extração de características de sinais de áudio têm sido propostas, como a metodologia de Melo, Fadigas e Pereira<sup>5</sup>, que utiliza redes de visibilidade para esse propósito.

Neste trabalho essa mesma metodologia foi aplicada em sinais de ausculta pulmonar provenientes da Respiratory Sound Database<sup>6</sup>, seguindo uma série de etapas. Primeiro, foram selecionados arquivos com padrões adequados de duração e taxa de amostragem para aplicar o método proposto. Em seguida, foram calculadas as séries de desvios-padrão de cada sinal de áudio<sup>7</sup> e, por fim, essas séries foram transformadas em grafos de visibilidade<sup>8</sup>. Depois disso foi calculada a modularidade dessas redes e realizados o teste ANOVA, o teste TUCKEY, e a análise de homogeneidade de variâncias. De posse dos resultados foi realizada a análise e extraídas as conclusões.

Dentre os trabalhos correlatos, configuram uma maioria que estuda sons pulmonares utilizando métodos consagrados no estudo do processamento de sinais<sup>2,4</sup>. Jakovljević e Lončar-Turukalo<sup>9</sup> utilizam MFCC (Mel Frequency Cepstral Coefficients) e Modelo de Markov para classificar as classes de sons pulmonares Normal, Crackle e Wheeze, enquanto Chambres, Hanna, e Desainte-Catherine<sup>10</sup> fazem detecção de padrões em sinais respiratórios adventícios usando STFT (Short-Time Fourier Transform) e Wavelets em um classificador baseado em SVM (Support Vector Machine).

Alguns experimentos recentes têm estudado sons pulmonares adventícios utilizando propriedades de redes obtidas através do mapeamento de séries temporais com base em correlação de Pearson<sup>11,12</sup>.

## 2 MATERIAIS E MÉTODOS

### 2.1 Preparação dos dados e pré-processamento

Para realizar esse experimento foram utilizados 220 arquivos de áudio no formato WAVE, obtidos do Respiratory Sound Database<sup>6</sup>, sendo 110 arquivos da classe Wheeze e 110 da classe Crackle. Cada um dos arquivos possui trechos de sons respiratórios que constituem ciclos respiratórios de distintas partes do tórax. Diferentemente de outros autores<sup>8,13,14</sup>, neste trabalho não foram separados os ciclos respiratórios, e optou-se por trabalhar com um cenário mais condizente à realidade do ato da ausculta vivenciado pelo profissional de saúde.

A Classe Crackle é composta de arquivos com pelo menos um ciclo com ocorrência de Crackle e sem ocorrência de wheeze. Enquanto a classe wheeze é composta de arquivos com pelo menos um ciclo com ocorrência de Wheeze e sem ocorrência de Crackle.

Todos os arquivos possuem taxa de amostragem 44,1khz, comprimento do áudio de 19s, taxa de quantização de 24 bit. Cada série de desvio-padrão foi calculada, subdividindo a série original do sinal de áudio de  $N = 19s \times 44.100 = 837.900$  samples e calculando o desvio-padrão populacional em janelas fixas de 441 samples, obtendo uma subsérie de 1900 pontos ( $837.900 \div 441$ ). Desse modo foram calculadas 220 séries de desvio-padrão.

### 2.2 Mapeamento da série em uma rede de visibilidade

Em seguida cada uma dessas séries foram mapeadas em redes de visibilidade onde os vértices são os pontos de cada série e as arestas são ligações entre vértices que obedecem ao critério de visibilidade. Esse critério de ligação é estabelecido pelo algoritmo *visibility graph*. Os *visibility graphs* (grafos de



SimBraRedes

III Simpósio Brasileiro de Teoria  
e Ciência de Redes

visibilidade) são uma metodologia que converte séries temporais em grafos, permitindo a análise estrutural dos dados através do uso de propriedades de redes complexas.

Desenvolvida por Lacasa et al. (2008)<sup>15</sup>, essa técnica tem se mostrado extremamente útil na identificação de padrões ocultos em séries temporais complexas. O processo de construção de um *visibility graph* é baseado no seguinte princípio geométrico: cada ponto da série temporal é tratado como um nó no grafo, e dois nós são conectados por uma aresta se, ao traçar uma linha reta entre eles, essa linha não interceptar nenhum outro ponto intermediário.

Para ser mais específico, considere uma série temporal dada como uma sequência de valores numéricos. Sejam  $y_i$  e  $y_j$  os valores correspondentes às posições temporais  $i$  e  $j$  na série, com  $i < j$ . Esses dois pontos estão conectados no grafo se, para qualquer ponto intermediário  $y_k$  com  $i < k < j$ , a condição geométrica da Equação 1 for satisfeita.

$$y_C < (y_A - y_B) \frac{t_B - t_C}{t_B - t_A} \quad (1)$$

Essa condição garante que a linha de visibilidade direta  $y_i$  e  $y_j$  não é obstruída por qualquer outro ponto da série temporal. Essa técnica de construção cria um grafo que preserva as propriedades temporais e estruturais da série original, permitindo a aplicação de ferramentas de teoria dos grafos para analisar a modularidade e outras propriedades topológicas. Neste experimento a modularidade de Blondel foi utilizada para investigar uma característica estrutural das séries crackle e wheeze através das Redes de Visibilidade associadas às séries geradas através do mapeamento descrito nessa seção.

### 2.3 Cálculo da Modularidade de Blondel

De posse das Redes de Visibilidade, foi calculada a modularidade usando o método proposto por Blondel et al.<sup>16</sup>. Esse método é também conhecido como método de Louvain, e consiste em uma metodologia amplamente utilizada na detecção de comunidades em redes complexas. Essa abordagem se destaca por sua eficiência computacional e capacidade de lidar com redes de grande escala. O método busca maximizar a modularidade, uma medida que quantifica a qualidade de uma divisão em comunidades dentro de uma rede.

O processo é iterativo e hierárquico, começando com cada nó sendo considerado uma comunidade isolada. Em cada etapa, o algoritmo avalia se mover um vértice para uma comunidade vizinha aumenta a modularidade. Se sim, o movimento é realizado. Após essa fase, as comunidades formadas são agregadas em "supervértices", criando uma nova rede de menor escala, e o processo é repetido.

A modularidade de Blondel é amplamente reconhecida pela sua capacidade de revelar a estrutura modular de redes complexas, facilitando a compreensão de como grupos de vértices se organizam e interagem.

### 2.4 Aplicação dos testes ANOVA, LEVENE e TUCKEY

Após determinar as modularidades das Redes de Visibilidade associadas aos sinais de ausculta pulmonar dos grupos Crackle e Wheeze, foram calculadas as médias de cada agrupamento e aplicados três testes para avaliar e validar estatisticamente se esses agrupamentos são distinguíveis do ponto de vista da comparação das suas médias.

#### 2.4.1 Teste de Comparação entre Médias (ANOVA)

A Análise de Variância (ANOVA) é uma ferramenta estatística amplamente utilizada para comparar as médias de três ou mais grupos e identificar se há diferenças significativas entre eles. Esta técnica foi introduzida por Fisher<sup>17</sup> e é fundamental em estudos experimentais para decompor a variabilidade total



SimBraRedes

III Simpósio Brasileiro de Teoria  
e Ciência de Redes

observada em componentes atribuíveis a diferentes fontes, como a variabilidade entre grupos e a variabilidade dentro dos grupos. A estatística F resultante é usada para testar a hipótese nula de que todas as médias dos grupos são iguais. Neste estudo, foi adotado um nível de significância de 5% para determinar se as diferenças observadas entre os sons pulmonares classificados como "Crackles" e "Wheezes" são estatisticamente significativas.

O resultado da ANOVA pode influenciar a escolha da técnica de classificação. Se as diferenças entre as classes forem significativas, métodos de classificação baseados em distância ou probabilidade (como k-NN ou Naive Bayes) podem ser mais eficazes. Se as diferenças forem pequenas, pode ser necessário utilizar técnicas mais complexas, como Support Vector Machines (SVM) ou redes neurais, que podem capturar nuances mais sutis.

A utilização da ANOVA pode, portanto, melhorar a eficiência do modelo ao priorizar características que contribuem significativamente para a distinção entre as classes, reduzindo o risco de overfitting e aumentando a precisão do classificador<sup>18</sup>.

#### 2.4.2 Teste de Homogeneidade de Variâncias (LEVENE)

O teste de homogeneidade de variâncias é crucial para garantir a validade da ANOVA, já que uma das principais suposições desse teste é que as variâncias dos grupos comparados sejam homogêneas. O Teste de Levene, proposto por Levene<sup>19</sup>, é uma técnica robusta que verifica essa suposição comparando a variância dos desvios absolutos em relação à mediana (ou média) dos grupos. Neste estudo, foi aplicado o Teste de Levene para verificar a homogeneidade das variâncias entre os grupos "Crackles" e "Wheezes". Um p-valor maior que 0,05 indica que as variâncias podem ser consideradas homogêneas.

#### 2.4.3 Teste de TUCKEY

Após a aplicação da ANOVA, o teste de Tukey é frequentemente utilizado para realizar comparações múltiplas entre os grupos, fornecendo uma análise detalhada sobre quais grupos diferem entre si. Este método foi desenvolvido por Tukey<sup>20</sup> e é particularmente útil em estudos onde a ANOVA indica a existência de diferenças significativas entre as médias, mas não especifica quais grupos são diferentes. O teste ajusta os p-valores para múltiplas comparações, minimizando a taxa de falsos positivos.

### 3 RESULTADOS E DISCUSSÃO

As modularidades das 220 Redes de Visibilidade associadas a 220 sons de ausculta pulmonar classificados em Crackles e Wheezes foram calculadas. Também foram computadas as médias das 110 modularidades de cada classe. Para o conjunto Crackle foi encontrado o valor  $\langle Q \rangle = 0.86324 \pm 0.038$  e para o conjunto Wheeze  $\langle Q \rangle = 0.84898 \pm 0.0489$ .

A ANOVA foi realizada para determinar se há diferenças estatisticamente significativas entre as médias desses agrupamentos. O nível de significância adotado foi de 5%. Os resultados da ANOVA indicaram uma F-statistic de 5,8315 com um p-valor de 0,0166. Como o p-valor é menor que 0,05, rejeitamos a hipótese nula de que as médias dos dois grupos são iguais, concluindo que há uma diferença significativa entre os grupos Crackles e Wheezes.

Para validar os resultados da ANOVA, o teste de Levene foi realizado para verificar a homogeneidade das variâncias entre os grupos. O teste de Levene resultou em uma estatística F de 2,6511 com um p-valor de 0,1049. Como o p-valor é maior que 0,05, não foi rejeitada a hipótese nula de que as variâncias dos grupos são iguais. Isso indica que as variâncias entre "Crackles" e "Wheezes" são homogêneas, o que valida a suposição de homogeneidade necessária para a ANOVA.

Após identificar uma diferença significativa com a ANOVA, foi realizado o Teste de Tukey para determinar quais grupos específicos diferem entre si. O Teste de Tukey apresentou um p-valor ajustado de 0,0166 para a comparação entre as médias de "Crackles" e "Wheezes". Esse p-valor, sendo inferior ao nível de significância de 5%, confirma que a diferença entre as médias dos dois grupos é estatisticamente



SimBraRedes

III Simpósio Brasileiro de Teoria  
e Ciência de Redes

significativa. Além disso, o intervalo de confiança para a diferença média (-0,0259 a -0,0026) não incluiu zero, reforçando a evidência de uma diferença real entre as médias.

De posse desses resultados pode-se inferir que, uma vez que o som Wheeze é sibilante, melódico e contínuo, e o Crackle, por outro lado, possui característica sonora rítmica, percussiva e explosiva<sup>2</sup>, as suas respectivas séries de desvio-padrão são influenciadas por essas características, já que estas são representantes do espectro do sinal sonoro capturado<sup>7</sup>.

Segundo Melo et al.<sup>21</sup> essas características impactam na modularidade das Redes de Visibilidade geradas a partir dessas séries, de modo que séries de desvio-padrão de sons musicais mais rítmicos e percussivos (como hip-hop ou samba), tendem a gerar Redes de Visibilidade com maior modularidade que aquelas geradas a partir de sons de estilos musicais menos percussivos e mais melódicos como a música clássica. Assim, as séries Crackle tendem a criar Redes com estruturas mais modulares do que aquelas geradas pelas séries Wheeze.

#### 4 CONCLUSÃO

Neste estudo, foram analisados os sons pulmonares classificados como "Crackle" e "Wheeze". Esses sons pulmonares foram transformados em Redes de Visibilidade e, após calcular a modularidade dessas redes, foram feitos testes estatísticos para avaliar se essas classes podem ser separáveis do ponto de vista das suas médias.

As estatísticas descritivas indicaram que a média de "Crackle" é maior do que a de "Wheeze". A ANOVA revelou uma diferença significativa entre as médias dos dois grupos ao nível de significância de 5%. O Teste de Tukey confirmou que essa diferença é estatisticamente significativa, com a média de "Crackle" sendo maior do que a de "Wheeze". O Teste de Levene indicou que as variâncias dos grupos são homogêneas, reforçando a validade dos resultados obtidos pela ANOVA.

Pode-se concluir que o método aplicado foi capaz de identificar diferenças significativas entre as classes de sons pulmonares adventícios Crackle e Wheeze, e indica grande potencial de ser uma ferramenta útil e promissora em sistemas de classificação que usam aprendizagem de máquina, já que os resultados apontam que o método conferiu separabilidade às classes ao observar a computação das suas modularidades.

Já se encontra em andamento, com resultados bastante animadores, um trabalho que utiliza a modularidade juntamente com outras propriedades de redes, como atributos na extração de características para classificação de quatro classes de sons pulmonares adventícios, em um sistema de classificação baseado em árvore logística.

Por fim o método proposto também veio ratificar em sons pulmonares, o que as redes de visibilidade haviam observado na caracterização de classes de sons musicais.

#### 5 REFERÊNCIAS

<sup>1</sup> WELSBY, P., PARRY, G., & SMITH, D. (2003). The stethoscope: some preliminary investigations. **Postgraduate medical journal**, 79, 695–698.

<sup>2</sup> PRAMONO, Renard Xaviero Adhi; BOWYER, Stuart; RODRIGUEZ-VILLEGAS, Esther. Automatic adventitious respiratory sound analysis: A systematic review. **PloS one**, v. 12, n. 5, p. e0177926, 2017.

<sup>3</sup> CHAMBRES, Gaëtan; HANNA, Pierre; DESAINTE-CATHERINE, Myriam. **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.

<sup>4</sup> SILVA, L. B., NOGUEIRA, F. N., DOS SANTOS, J. M., QUISPE, K. G. M., GIUSTI, R., & COLONNA, J. G. Aprendizagem de máquina para classificação de doenças respiratórias: Uma revisão sistemática. **Journal of Health Informatics**, 2021.

<sup>5</sup> MELO, D. d. F. P., Fadigas, I., & Pereira, H. Graph-based feature extraction: A new proposal to study the classification of music signals outside the time-frequency domain. **PlosOne**, 15, e0240915. 2020.

<sup>6</sup> ROCHA, B. M. et al. An open access database for the evaluation of respiratory sound classification algorithms. **Physiological measurement**, IOP Publishing, v. 40, n. 3, p. 035001, 2019.



SimBraRedes

III Simpósio Brasileiro de Teoria  
e Ciência de Redes

- <sup>7</sup> JENNINGS, H. D., IVANOV, P. C., MARTINS, A. d. M., DA SILVA, P., & Viswanathan, G. Variance fluctuations in nonstationary time series: a comparative study of music genres. ***Physica A: Statistical Mechanics and its Applications***, 336, 585–594, 2004.
- <sup>8</sup> 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***, 14, 535–544, 2020.
- <sup>9</sup> JAKOVLJEVIĆ, N. and LONČAR-TURUKALO, T., **Hidden Markov model based respiratory sound classification**. Proceedings of International Conference Biomedic Health Inform. (pp. 39–43). Springer, 2018.
- <sup>10</sup> CHAMBRES, Gaëtan; HANNA, Pierre; DESAINTE-CATHERINE, Myriam. 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.
- <sup>11</sup> RAJ, Vimal; SWAPNA, M. S.; SANKARAMAN, S. Bioacoustic signal analysis through complex network features. *Computers in Biology and Medicine*, v. 145, p. 105491, 2022.
- <sup>12</sup> RENJINI, A. et al. Graph-based feature extraction and classification of wet and dry cough signals: a machine learning approach. *Journal of Complex Networks*, v. 9, n. 6, p. cnab039, 2021.
- <sup>13</sup> DEMIR, F., Ismael, A. M., & SENGUR, A. Classification of lung sounds with cnn model using parallel pooling structure. ***IEEE Access***, 8, 105376– 105383, 2020.
- <sup>14</sup> KOCHETOV, K., PUTIN, E., BALASHOV, M., FILCHENKOV, A., & SHALYTO, A. **Noise masking recurrent neural network for respiratory sound classification**. In *International Conference on Artificial Neural Networks* (pp. 208–217). Springer, 2018.
- <sup>15</sup> LACASA, L., Luque, B., Ballesteros, F., Luque, J., & Nuno, J. C. **From time series to complex networks: the visibility graph**. *Proceedings of the National Academy of Sciences*, 105, 4972–4975, 2008.
- <sup>16</sup> BLONDEL, Vincent D.; GUILLAUME, Jean-Loup; LAMBIOTTE, Renaud; LEFEBVRE, Etienne. Fast unfolding of communities in large networks. ***Journal of Statistical Mechanics: Theory and Experiment***, v. 2008, n. 10, p. P10008, 2008.
- <sup>17</sup> FISHER, R.A. **Statistical Methods for Research Workers**. Edinburgh: Oliver and Boyd, 1925.
- <sup>18</sup> BALDI, P.; BRUNAK, S.; CHAUVIN, Y.; ANDERSEN, C.A.; NIELSEN, H. Assessing the accuracy of prediction algorithms for classification: an overview. ***Bioinformatics***, v. 26, n. 10, p. 1193-1200, 2010.
- <sup>19</sup> LEVENE, H. **Robust Tests for Equality of Variances**. In: Contributions to Probability and Statistics: Essays in Honor of Harold Hotelling. Stanford University Press. p. 278-292, 1960.
- <sup>20</sup> TUKEY, J.W. Comparing Individual Means in the Analysis of Variance. ***Biometrics***, v. 5, n. 2, p. 99-114, 1949.
- <sup>21</sup> MELO, D. d. F. P., Fadigas, I., & Pereira, H. (2016). **Community detection in visibility networks: an approach to categorize percussive influence on audio musical signals**. In: International Workshop on Complex Networks and their Applications. Cham: Springer International Publishing, 2016. p. 321-334.