



Avanços Recentes em Aprendizagem de Máquina Usando Fonocardiogramas na Detecção de Cardiopatias

Recent Developments on Machine Learning Using Phonocardiograms for Cardiology Detection

Avances Recientes en el Aprendizaje Automático Mediante Fonocardiogramas para Detectar Enfermedades Cardíacas

João Vicente Silva Goes¹, Vinícius de Medeiros Hernandez², Hygo Sousa de Oliveira³, Eulanda Miranda dos Santos⁴, Rafael Giusti⁴

RESUMO

Descritores:
Aprendizagem de máquina; Predição de cardiopatias; Fonocardiogramas

Objetivo: Neste trabalho, apresentamos uma visão geral dos avanços recentes da literatura na detecção de cardiopatias utilizando algoritmos de aprendizado de máquina aplicados a sinais cardíacos obtidos por meio de fonocardiograma. **Métodos:** Foi aplicada uma frase de busca em bases de dados digitais, de forma a limitar os artigos entre 2018 e 2020. Os resultados foram filtrados por pertinência e relevância e os artigos mais importantes foram selecionados para discussão. **Resultados:** Selecionamos 12 artigos para serem explorados, observando características como modelo de aprendizagem, taxa de acurácia, base de dados utilizada e outros critérios pertinentes à pesquisa científica. **Conclusão:** Foi possível identificar que o modelo mais utilizado pelos trabalhos são os de redes neurais de convolução, ainda que vários trabalhos utilizando técnicas tradicionais também venham demonstrando sua importância devido ao bom desempenho na tarefa de classificação, empregando principalmente extratores de características baseados em amplitude no domínio tempo-frequência.

ABSTRACT

Keywords: Machine Learning, heart disease prediction, phonocardiograms

Objective: In this work, we present an overview of the recent advances in the literature of heart diseases detection using machine learning algorithms applied to cardiac signals obtained using phonocardiogram. **Method:** One string was applied to search in digital libraries for articles published between 2018 and 2020. Results were filtered by taking into account the relevance of the returned studies. The most relevant articles were selected for discussion. **Results:** We have selected 12 articles to be studied in terms of features, such as the learning model, accuracy rate, dataset used and other criteria relevant to the scientific research. **Conclusion:** It was possible to identify that the learning model most often used in the investigated works is the convolutional neural network. However, several works using traditional techniques have also attained good performance in this classification task, mainly using feature extractors based on amplitude and on time-frequency domain.

RESUMEN

Descriptores:
aprendizaje automático, predicción de cardiopatías, fonocardiograma

Objetivo: En este trabajo presentamos una visión general de los avances recientes en la literatura en la detección de cardiopatías mediante algoritmos de aprendizaje automático aplicados a señales cardíacas obtenidas mediante fonocardiograma. **Métodos:** Se aplicó una frase de búsqueda a bases de datos digitales, con el fin de acotar los artículos entre 2018 y 2020. Los resultados se filtraron por relevancia y se seleccionaron los artículos más importantes para discusión. **Resultados:** Se seleccionaron 12 artículos para ser explorados, observando características como modelo de aprendizaje, tasa de precisión, base de datos utilizada y otros criterios relevantes para la investigación científica. **Conclusión:** Se pudo identificar que el modelo más utilizado por los trabajos son las redes neuronales de convolución, aunque varios trabajos que utilizan técnicas tradicionales también han mostrado buen desempeño en la tarea de clasificación, utilizando principalmente extractores de características basados en amplitud y frecuencia en función del tiempo.

¹ Aluno de Graduação do curso de Engenharia de Computação da Faculdade de Tecnologia, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

² Aluno de Graduação do curso de Ciência da Computação no Instituto de Computação, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

³ Aluno de Mestrado 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

As doenças cardíacas estão entre as principais causas de mortes no mundo. O diagnóstico dessa classe de doenças possui diversos métodos, destacando-se a ausculta como sendo um exame rápido e de baixo custo no qual o som do batimento cardíaco é examinado por um especialista. No entanto, o exame de ausculta exige bastante conhecimento do profissional e pode ser subjetivo. Além disso, em algumas situações, como em áreas rurais, existe baixa disponibilidade do profissional que possa efetuar o diagnóstico.

Torna-se portanto muito conveniente que haja métodos automáticos capazes de auxiliar profissionais da área da saúde e até mesmo os próprios pacientes na detecção de sinais indicativos dessa classe de doenças. A realização rápida do fonocardiograma, por um profissional de saúde ou pelo próprio paciente, pode incentivar a procura por um profissional especializado, capaz de fornecer um diagnóstico definitivo antecipado.

Neste sentido, há diversos artigos publicados que promovem o estudo de métodos de aprendizado de máquina na classificação de doenças ou de sons cardíacos com base em sinais de fonocardiograma. Neste artigo apresentamos os resultados de uma revisão sistemática dessa classe de artigos, coletados a partir de diversas bases de dados com uma frase de busca.

O restante deste artigo está dividido em: métodos, onde explicamos como será desenvolvida a triagem dos artigos da revisão sistemática; resumos, que buscam caracterizar um artigo de maneira sucinta; e conclusão, que exibe o atual estado da área e observações sobre a discussão.

MÉTODOS

Esta pesquisa tem como objetivo uma revisão sistemática da literatura, visando levantar de conferências, periódicos e capítulos de livros, os trabalhos relevantes sobre a utilização de sons de batimentos cardíacos, obtidos via fonocardiograma, na predição de doenças. As etapas da pesquisa foram divididas em definição do tema, definição da frase de busca e das bases de dados a serem consultadas, busca dos artigos nas bases, preenchimento da tabela com as principais informações dos artigos, pré-seleção e seleção

de artigos para leitura e elaboração dos resumos.

O tema foi definido para se alinhar com projetos de pesquisa em execução pelos autores, que envolvem a utilização de técnicas de aprendizado de máquina em tarefas de identificação (segmentação) de sons cardíacos e na predição de doenças com base em sons de batimentos cardíacos obtidos via fonocardiograma.

A frase ou *string* de busca foi definida em diversas iterações. A versão final, estabelecida com base nos termos principais do tema de busca, foi ("*machine learning*" AND ("*pcg*" OR "*sounds*") AND "*heart*"). A frase foi empregada nas principais bases de conhecimento científico utilizadas na literatura das áreas de computação e de computação aplicada à saúde, a saber: *Elsevier*, *IEEE Xplore*, *PubMed* e *ACM*. Ao todo foram obtidos 498 artigos, aos quais foram aplicados os critérios de inclusão e exclusão apresentados no quadro 1, resultando em um subconjunto de 56 artigos relacionados ao tema. Com base na leitura dos resumos desses artigos, os 09 mais relevantes foram selecionados para discussão. A tabela 1 sumariza o processo de seleção dos artigos.

Uma planilha foi desenvolvida promovendo um mapeamento das principais características dos artigos selecionados para análise posterior. Nessa etapa foram levantados critérios como tipo do artigo (revisão, experimento original ou replicação), tipo de base de dados utilizada no trabalho (pública ou não), as especificidades do problema abordado no trabalho (classificação, segmentação etc.), os métodos de aprendizado de máquina empregados ou estudados no trabalho, dentre outros. Esse mapeamento inicial foi utilizado para promover uma visão geral da literatura que influenciou a discussão dos artigos ao longo desta pesquisa.

A etapa final foi a leitura detalhada dos artigos e a confecção de resumos. O produto obtido nessa etapa é apresentado na seção "Discussão" deste *survey*.

Além dos nove artigos selecionados, outros três foram acrescentados por apresentarem relevância na pesquisa. Esses artigos são: Signh et al.⁽¹⁾, Balagopal Unnikrishnan et al.⁽²⁾; e Yongchao Chen et al.⁽³⁾. Dessa forma, a seleção dos artigos para o resumo foi concluída. Finalizada a leitura, foi preenchida uma tabela com as seguintes informações: título, autor, ano de publicação, descrição do problema, base de dados, algoritmos aplicados, métricas e estratégia de validação.

Quadro 1 - Critérios de exclusão e inclusão

Critérios de exclusão	Critérios de inclusão
<ul style="list-style-type: none"> - Artigos que não abordam o uso de fonocardiograma - Artigos que não utilizam classificação por meio de aprendizado de máquina como método principal. - Não utilizar sinais de batimentos cardíacos obtidos via fonocardiograma - Múltiplos sinais de batimentos cardíacos (ex. ECG) 	<ul style="list-style-type: none"> - Utilização de técnicas de aprendizado de máquina na predição de sinais de batimentos cardíacos obtidos a partir de fonocardiograma - Classificação de sons cardíacos ou diagnóstico de doenças

Tabela 1 - Artigos selecionados

Base de artigos	Artigos retornados pela frase de busca	Artigos pré-selecionados	Artigos selecionados
ACM	182	18	2
PubMed	28	7	2
IEEE Xplore	38	8	3
Elsevier	250	23	2
Total	498	56	9

DISCUSSÃO

Huang e Song⁽⁴⁾ propõem um sistema de detecção de problemas cardíacos utilizando ausculta cardíacas. A partir da série temporal do sinal de fonocardiograma (FCG), foram extraídos os coeficientes mel-cepstrais, onde para cada coeficiente foi aplicado um filtro gaussiano. Para a classificação das ausculta foi utilizado o modelo de k-vizinhos próximos (KNN) com distância Hamming, produzindo acurácia de 84,2%, sensibilidade de 77,8% e especificidade de 84,5%.

Wo³k e Wo³k⁽⁵⁾ propõem um sistema de classificação de doenças cardíacas através de uma rede neural convolucional (CNN). Os dados de FCG foram submetidos a um filtro passa-baixa e deles foi extraído o espectro do áudio, a partir do qual uma rede CNN foi utilizada para a classificação dos batimentos como normal ou sob a presença de alguma anomalia pré-estabelecida. Na rede foram utilizadas camadas das redes pré-treinadas *ResNet-34* e *ResNet-50* para facilitar a transferência de aprendizado. Tipicamente, essas redes são treinadas com dados da *ImageNet* (embora os autores não tenham deixado clara essa informação). De modo a determinar a melhor quantidade de épocas e parâmetros para a rede foi utilizada a técnica de gradiente estocástico descendente com reinício. A proposta foi avaliada com uma base de dados do repositório *Kaggle*⁽⁶⁾, que possui dois conjuntos. No denominado *dataset A*, os resultados obtidos foram: 93,18% de acurácia utilizando espectrograma e 90,90% utilizando o áudio; para o *dataset B*, utilizando espectrograma, foi obtida acurácia de 59,78% e 63,04% utilizando o áudio. Finalmente, para a base de dados *PhysioNet Challenge* foi obtida acurácia de 99,66%.

Ali Raza et al.⁽⁷⁾ propuseram um *framework* que classifica anomalias baseando-se em ausculta cardíaca, rotulando os sinais entre normal, murmúrio e extrassístole. Nesse trabalho é feita uma comparação entre modelos clássicos (árvore de decisão, florestas aleatórias e *Linear Support Vector Classifier*) e modelos de redes neurais profundas (*Multi-Layer Perceptron* ou MLP e Rede Neural Recorrente). As amostras de áudio passam por um pré-tratamento que consiste em aplicar filtros para remover ruídos. O modelo proposto no trabalho é uma rede neural recorrente com o seguinte esquema: camada de entrada de dados, camadas de *Long Short-Term Memory* (LSTM), camadas de *dropout*, camadas densas e camadas *softmax*. A base de dados utilizada para treino e teste é a base *Classifying heart sounds PASCAL challenge competition*⁽⁶⁾ especificamente o *dataset B*. Foram utilizados dois protocolos experimentais: (1) *hold-out* de 30% para comparar os diferentes modelos de predição onde os resultados de acurácia obtidos foram: 48,9% para Árvore de Decisão, 71,2% para *Random Forest*, 67,6% para MLP com 6 camadas, 69% para MLP com 16 camadas, e 80,8% para o modelo proposto; (2) uma validação cruzada de 5 divisões, onde os resultados obtidos nas divisões foram: 78,16%, 77,58%, 82,18%, 82,75%, 81,6%, dando em média 80,4%.

Fuad Noman et al.⁽⁸⁾ propõem um *framework* baseado em uma CNN que classifica os sons dos batimentos cardíacos em normais e anormais. A base de

dados utilizada para o experimento foi a “*PhysioNet CinC challenge 2016*”⁽⁹⁾. A partir das amostras de áudio foi executado um pré-processamento que consiste em diminuir a taxa de amostragem das faixas de áudio para 1000Hz e filtrar os sons que não estejam entre as frequências de 25Hz e 400Hz. Os sinais foram ξ -normalizados de modo a terem média zero e desvio padrão 1 antes da extração das características. As amostras foram segmentadas em ciclos de batimentos cardíacos utilizando o gabarito presente na base de dados. O modelo proposto é uma combinação de duas CNNs, a primeira recebe como entrada a faixa de áudio tratada, enquanto a outra rede recebe como entrada coeficientes mel-cepstrais. O *design* experimental utilizado para o teste dos modelos foi a validação cruzada de 5 divisões. As médias de acurácia obtidas foram: máquina de vetores de suporte 84,87%, árvore de decisão 86,20%, modelos ocultos de Markov 87,07%, CNN com a faixa de áudio 87,23%, CNN com coeficientes cepstrais de mel 87,18%, e modelo proposto 89,22%.

Em Anitek Bhattacharya et al.⁽¹⁰⁾ é proposto um dispositivo para detectar anomalias cardíacas. Para isso é feita a classificação de sinais cardíacos a partir de características extraídas de coeficientes mel-cepstrais do sinal original. A base de dados é privada, sendo composta por 120 amostras, das quais 60 apontam para sinais normais e 60 para anormais. Esses sinais foram amostrados utilizando a frequência de 16KHz. São consideradas as características de média, assim como a mediana dos coeficientes, de forma a discriminar entre as classes. Os autores utilizaram máquinas de vetores de suporte (SVM) com *kernel* linear na construção do modelo, sendo obtida acurácia de 97,5% e sensibilidade de 100% na classificação entre as duas classes. O *kernel* linear foi selecionado pelos autores após validação.

El Badlaoui et al.⁽¹¹⁾ propuseram a análise de sinais de FCG empregando coeficientes mel-cepstrais e análise do espectro da frequência para extração de características de sinais obtidos de pacientes clínicos, provenientes de duas bases de dados públicas. Com elas, aplica-se permutação entre as técnicas de normalização e compressão, utilizando a análise das componentes principais (PCA). Após esse pré-processamento, foram avaliados os modelos SVM e kNN sobre os dados. Para a primeira base de dados foi utilizado SVM com *kernel* linear com normalização, produzindo valores de 96,87% para acurácia. Na ausência de normalização, a acurácia foi de 87,5% com o uso de PCA e 96,87% sem PCA.

Neelesh Srivastava et al.⁽¹²⁾ propuseram um método para diagnóstico de anomalias cardíacas a partir do FCG. Os autores utilizaram a base de dados do desafio *Physionet 2016*, composta de 3.923 registros de sons cardíacos, rotulados em sinais normais e anormais, com partições de treino e de teste especificadas pelo próprio desafio. Foram extraídas características desses sinais a partir de uma reamostragem do áudio; passagem do filtro *Butterworth*, com objetivo de remoção de ruídos; e a seleção das características, divididas em: domínio do tempo, espectral, percepção, utilidade e funções de janelamento. Dessa forma, um conjunto de dados é pré-processado,

resultando em um conjunto de características, permitindo a aplicação do modelo de classificação SVM. O modelo obteve acurácia de 95%, 93,3% e 95% entre as classes normais e anormais para três tipos de particionamento de conjuntos de treino e teste, os quais consistem em 60/40, 70/30 e 80/20.

Em Shu Lih Oh et al.⁽¹³⁾ é proposto um sistema de classificação automática de cinco tipos de sons cardíacos. É empregada uma base de dados composta de 1.000 amostras rotuladas com cinco rótulos: normal, estenose aórtica, prolapso de válvula mitral, estenose mitral e regurgitação mitral. As amostras são divididas em 200 para cada rótulo. Os sinais do FCG foram normalizados entre -1 e 1 para garantir uma escala comum entre as amostras. O modelo proposto é composto por seis blocos residuais que foram treinados e construídos utilizando três épocas e *batch size* de três. O treinamento foi realizado com o algoritmo otimizador Adam, com taxa de aprendizagem de 0,0005. A validação cruzada com 10-*folds* foi utilizada para cálculo do desempenho do modelo, sendo que 10% dos dados foram utilizados para teste, 85,5% para treino e 4,5% para validação.

Aplicando o modelo profundo de redes neurais de arquitetura WaveNet, os autores alcançaram acurácia de 97%, sensibilidade de 92,5% e especificidade de 98,1%. O modelo é robusto e pode ser treinado de maneira rápida devido à presença de camadas dilatadas de convolução e permite que uma quantidade grande de dados seja treinada pelo modelo, porém requer grande quantidade de memória para um modelo estável em métricas de resultado.

Ajitkumar Singh et al.⁽¹⁾ apresentam uma classificação automática de sons cardíacos obtidos via FCG. A base de dados utilizada é pública e proveniente do desafio PhysioNet 2016⁽⁹⁾, possuindo 3.240 registros de fonocardiograma. Os primeiros cinco segundos de cada registro foram selecionados para estudo. Ocorreu a filtragem do sinal por meio do filtro passa-baixa, a partir de uma redução de amostragem do sinal bruto. Após isto foi feita a normalização do sinal resultante. A localização e a segmentação são importantes para a análise das atividades cardiovasculares. Alguns sinais de FCG possuíam picos não desejados, sendo então necessária uma remoção a partir da *spike removal approach*. Após isso, os sinais são convertidos na forma do escalograma, sendo esses dados utilizados para validar uma rede neural. Ocorreu a extração de características a partir da transformada contínua de *wavelet*. As imagens do escalograma são utilizadas para treinar e validar redes neurais de convolução baseadas em aprendizado profundo. Obteve-se uma acurácia de 87,96% nas classes normal e anormal.

Balagopal Unnikrishnan et al.⁽²⁾ apresentam um método baseado em 1-*class classification* para detecção de anomalias cardíacas em ambientes de dados restritos. Foi empregado um compilado de abordagens utilizando métodos não supervisionados e semi-supervisionados. A base de dados utilizada foi fornecida pela PhysioNet/CinC 2016⁽⁹⁾ e redes neurais de convolução baseadas em *autoencoders* foram submetidas a extração de características de forma não supervisionada. As anomalias foram

detectadas com SVM de uma classe, obtendo bons resultados sem fazer uso dos dados rotulados. Nas abordagens semi-supervisionadas foi empregada CNN, cujas camadas foram sobrepostas em relação a parâmetros de otimização e fizeram uso, em parte, do rótulo proposto na base de dados.

Em Yongchao Chen et al.⁽³⁾, buscou-se a classificação de sons cardíacos através de cadeias de Markov para encontrar os pontos de sístole e diástole. Os sinais foram segmentados e a transformada de *wavelet* foi usada para extração de características. A base de dados utilizada foi a Physionet 2016⁽⁹⁾. Os dados originais, disponibilizados com taxa 2000 Hz, foram subamostrados para 1000 Hz. Na etapa posterior, a entropia do sinal foi calculada e, em seguida, ocorreu a segmentação para identificar as etapas de sístole e diástole. Dois modelos de CNN foram pré-treinados para recebimento dos dados pré-processados e combinados utilizando entropia simples. O desempenho da classificação foi verificado utilizando validação cruzada com 10-*folds*, sendo obtida então acurácia de 95% entre as classes normal e anormal.

Também utilizando a base Physionet 2016, Li et al.⁽¹⁴⁾ classificaram sons cardíacos. Os sinais foram segmentados em batidas de sístole e diástole e pré-processados por um filtro passa-alta, que permite a remoção de ruídos em baixa frequência. Em seguida, os autores extraíram as características, totalizando 497 amostras com informações de tempo, amplitude, energia, estatística de alta ordem, cepstro, frequência, ciclo-estacionário e entropia. Uma CNN foi treinada com essas características. A CNN possui camadas configuradas em 32, 64 e 128 e cada *kernel* tem tamanho de 3 com *stride* de 3. Os resultados obtidos foram 86,8% de acurácia, 87% de sensibilidade e 86,6% de especificidade médias. O algoritmo de CNN proposto busca um equilíbrio entre sensibilidade e especificidade. Foi utilizada validação cruzada com cinco partições.

CONCLUSÃO

Neste trabalho apresentamos os resultados de uma revisão sistemática da literatura sobre técnicas de aprendizagem de máquina aplicadas em exames de fonocardiograma para a detecção e classificação de doenças cardíacas. Para tal estudo utilizamos como bases de artigos ACM, Elsevier, IEEE e PubMed. Dentre os artigos encontrados levantamos os mais relevantes a partir do ano de 2018, buscando categorizar as abordagens dos artigos baseados na base de dados utilizada, modelo de aprendizagem de máquina, métrica de acurácia e data, de modo a entender a evolução obtida no decorrer destas pesquisas.

Quanto às bases de dados, fizemos a divisão em 3 categorias a partir das bases apontadas pelos artigos como as duas bases públicas *PhysioNet Computing in Cardiology Challenge* de 2016⁽⁹⁾; e *Kaggle (previously PASCAL) Classifying Heart Sounds Challenge*⁽⁶⁾; assim como bases próprias, as quais na maioria das vezes não são disponibilizadas. Há em nosso levantamento apenas um artigo que fez uso de uma base diferente das duas previamente citadas e que disponibilizou a base para uso na plataforma Github⁽¹³⁾.

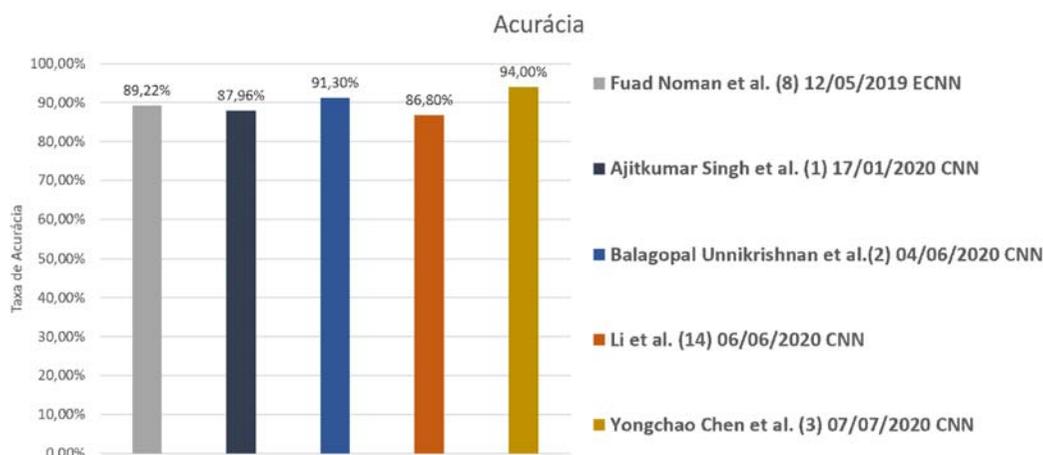


Figura 1 – Comparação da acurácia dos trabalhos sobre a base da PhysioNet⁽⁹⁾.

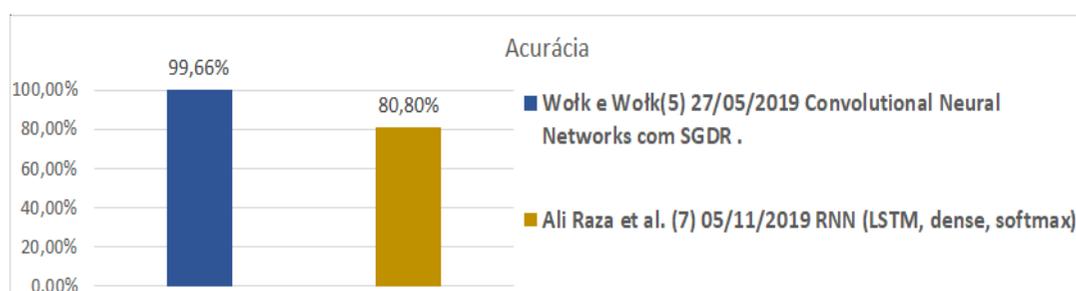


Figura 2 – Comparação da acurácia dos trabalhos sobre a base da base Kaggle/antiga PASCAL⁽⁶⁾.

PhysioNet Computing in Cardiology Challenge 2016

Observamos que a maioria dos artigos levantados utiliza essa base de dados, que foi proposta para o desafio de criar sistemas capazes de separar automaticamente os batimentos entre normais e anormais. Cinco dos seis trabalhos avaliados neste artigo utilizaram esta base e fizeram uso de abordagens de aprendizado profundo com redes neurais de convolução. O sexto recorreu a um modelo baseado em árvores de decisão. Na figura 1, apresenta-se uma comparação da acurácia obtida pelos trabalhos avaliados que utilizam este conjunto de dados. Os trabalhos são ordenados em função do ano de publicação e identificados pelo nome do primeiro autor e a numeração da referência. O modelo de aprendizagem de máquina que obteve a acurácia indicada também é informado na figura.

Kaggle (previously PASCAL) Classifying Heart Sounds Challenge

Dentre os trabalhos analisados tivemos também a presença desta base de dados que consiste em dois *datasets*, A e B. Essa separação dos dados ocorre porque com essa base são propostos dois desafios: o *dataset A* é destinado ao desafio de segmentar corretamente os batimentos cardíacos, identificando a ocorrência de sístole e diástole, enquanto o *dataset B* é destinado à classificação dos batimentos cardíacos em categorias que indicam se é normal ou se possui um dos problemas indicados nas classes pré-estabelecidas. Todos os trabalhos que fizeram uso dessa base de dados utilizaram técnicas de aprendizado

profundo, como CNN, redes neurais de recorrência e redes neurais de propagação retrógrada. Na figura 2 apresenta-se as acurácias de diferentes trabalhos que utilizam esta base.

Bases de dados Próprias

Esta categoria surgiu para separar os casos nos quais as bases de dados utilizadas não foram disponibilizadas para a comunidade e também para um caso específico no qual, apesar de a base estar disponível para uso público, foi utilizada em apenas um trabalho. Como são bases diferentes, não é feita nenhuma comparação do desempenho dos métodos propostos.

De modo geral, tratam-se dos trabalhos mais antigos encontrados durante o processo de revisão. Na leitura individual dos artigos, observou-se que os métodos propostos obtiveram bons resultados e foram influentes nos trabalhos posteriores, especialmente em função de suas técnicas de extração de características. Dentre esses trabalhos, 3 de 4 utilizaram modelos tradicionais e apenas um empregou técnicas de aprendizado profundo⁽¹³⁾.

AGRADECIMENTOS

Este artigo foi produzido no âmbito do Projeto Samsung-UFAM de Ensino e Pesquisa (SUPER), conforme previsto no Artigo 48 do Decreto nº 6.008 / 2006 (SUFRAMA), que foi financiada pela Samsung Eletrônica da Amazônia Ltda., 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.

REFERÊNCIAS

1. Singh, Sinam Ajitkumar, Takhellambam Gautam Meitei, and Swanirbhar Majumder. Short PCG classification based on deep learning. In: *Deep Learning Techniques for Biomedical and Health Informatics*. Academic Press, 2020. p. 141-164.
2. Unnikrishnan, B., Singh, P. R., Yang, X., & Chua, M. C. H. Semi-supervised and Unsupervised Methods for Heart Sounds Classification in Restricted Data Environments. *arXiv preprint arXiv:2006.02610*, 2020.
3. Chen, Yongchao, Shoushui Wei, and Yatao Zhang. Classification of heart sounds based on the combination of the modified frequency wavelet transform and convolutional neural network. *Medical & Biological Engineering & Computing*, v. 58, n. 9, p. 2039-2047, 2020.
4. Huang, Y., & Song, I. A better online method of heart diagnosis. In: *Proceedings of the 3rd International Conference on Biomedical Signal and Image Processing*. 2018. p. 81-86.
5. Wo³k, K., & Wo³k, A. Early and remote detection of possible heartbeat problems with convolutional neural networks and multipart interactive training. *IEEE Access*, v. 7, p. 145921-145927, 2019.
6. Bentley P, Nordehn G, Coimbra M, Mannor S. The PASCAL Classifying Heart Sounds Challenge. 2011 (CHSC2011).
7. Raza, A., Mehmood, A., Ullah, S., Ahmad, M., Choi, G. S., & On, B. W. Heartbeat sound signal classification using deep learning. *Sensors*, v. 19, n. 21, p. 4819, 2019.
8. Noman, F., Ting, C. M., Salleh, S. H., & Ombao, H. Short-segment heart sound classification using an ensemble of deep convolutional neural networks. In: *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2019. p. 1318-1322.
9. Clifford GD, Liu C, Moody B, Springer D, Silva I, Li Q, et al. Classification of normal/abnormal heart sound recordings: The PhysioNet/Computing in Cardiology Challenge 2016. In: *2016 Computing in Cardiology Conference (CinC)*; 2016. p. 609-6.
10. Bhattacharya, A., Mishra, M., Singh, A., & Dutta, M. K. Machine learning based portable device for detection of cardiac abnormality. In: *2017 International Conference on Emerging Trends in Computing and Communication Technologies (ICETCCT)*. IEEE, 2017. p. 1-4.
11. El Badlaoui, O., Benba, A., & Hammouch, A. Novel PCG Analysis Method for Discriminating Between Abnormal and Normal Heart Sounds. *IRBM*, 2019.
12. Srivastava, N., Bhatnagar, M., Yadav, A., Dutta, M. K., & Travieso, C. M. Machine learning based improved automatic diagnosis of cardiac disorder. In: *Proceedings of the 2nd International Conference on Applications of Intelligent Systems*. 2019. p. 1-8.
13. Oh, S. L., Jahmunah, V., Ooi, C. P., Tan, R. S., Ciaccio, E. J., Yamakawa, T., ... & Acharya, U. R. Classification of heart sound signals using a novel deep WaveNet model. *Computer Methods and Programs in Biomedicine*, p. 105604, 2020.
14. Li, F., Tang, H., Shang, S., Mathiak, K., & Cong, F. Classification of Heart Sounds Using Convolutional Neural Network. *Applied Sciences*, v. 10, n. 11, p. 3956, 2020.