

ARTIGO ORIGINAL

Aplicação da internet das coisas e aprendizado de máquina na identificação de doenças cardíacas pelas bulhas: um mapeamento sistemático

Application of the internet of things and machine learning in the identification of heart disease by heart sounds: A systematic mapping

Ivo Sérgio Guimarães Brites ¹, Lídia Martins da Silva ¹, Sandro José Rigo ¹,
Jorge Luis Victória Barbosa ¹

¹Universidade do Vale do Rio dos Sinos – UNISINOS, Programa de Pós-graduação em Computação Aplicada – PPGCA

*ivobrites@edu.unisinos.br; lidiasilva@edu.unisinos.br; rigo@unisinos.br; jbarbosa@unisinos.br;

Recebido: 02/09/2021. Revisado: 10/03/2022. Aceito: 30/03/2022.

Resumo

Este artigo apresenta um mapeamento sistemático de trabalhos relacionados à aplicação de Internet das Coisas e Aprendizado de Máquina para realização de auscultação, com escopo na aquisição, processamento, análise da qualidade do sinal e apoio ao diagnóstico de disfunções cardiovasculares. Esta pesquisa abrange buscas de 2010 até julho de 2021 nas bases *IEEE Xplore*, *PubMed Central*, *ACM Digital Library*, *JMIR – Journal of Medical Internet Research*, *Springer Library* e *Sciencedirect*. A busca inicial resultou em 4.372 artigos e após aplicação dos critérios de inclusão e exclusão foram selecionados 58 artigos para leitura completa com o intuito de responder as questões de pesquisa. Os principais resultados são: dos 58 artigos selecionados foi constatado que 79,31% (46) citam métodos de observação de batimentos cardíacos com sensores vestíveis e estetoscópios digitais e 58,62% (34) fazem menção aos cuidados utilizando algoritmos de aprendizado de máquina. A análise dos artigos demonstrou a tendência do uso de serviços inteligentes no diagnóstico de disfunções cardiovasculares.

Palavras-Chave: Aprendizado de Máquina; Internet das Coisas; Sensores Vestíveis; Computação Ubíqua.

Abstract

This paper presents a systematic mapping of works related to the application of Internet of Things and Machine Learning for auscultation, with scope in the acquisition, processing, analysis of signal quality and support for the diagnosis of cardiovascular dysfunctions. This research covers searches from 2010 to July 2021 in the *IEEE Xplore*, *PubMed Central*, *ACM Digital Library*, *JMIR – Journal of Medical Internet Research*, *Springer Library* and *Sciencedirect* databases. The initial search resulted in 4,372 papers and after applying the inclusion and exclusion criteria, 58 works were selected for full reading in order to answer the research questions. The main results are: of the 58 selected papers, 79.31% (46) cite methods of observing heartbeat with wearable sensors and digital stethoscopes and 58.62% (34) mention care using machine learning algorithms. The analysis of the works demonstrated the trend of using intelligent services in the diagnosis of cardiovascular disjunctions.

Keywords: Internet of Things; Machine Learning; Ubiquitous Computing; Wearable Sensors.

1 Introdução

A auscultação cardíaca é uma prática utilizada na medicina desde o século 4 a.C. A auscultação era realizada colocando-se o ouvido direto no peito do paciente. A partir da invenção do estetoscópio por Laënnec, em 1816, foi possível o desenvolvimento de métodos para análise dos sons cardíacos. Atualmente, devido ao avanço da tecnologia e a descoberta de outros métodos de exames, o método da ausculta permanece como peça-chave no exame clínico não invasivo (Ferraz et al., 2011).

A técnica da auscultação cardíaca depende da prática e habilidades do profissional que a realiza, sendo esta experiência clínica fundamental no objetivo da identificação das disfunções cardíacas. Uma solução computacional, com escopo na aquisição, processamento e análise do sinal pode auxiliar os profissionais da área da saúde na identificação das características dos sons cardíacos.

Na linha de exames que realizam a observação dos sinais sonoros do coração, está o exame de fonocardiograma (PCG), o qual caracteriza-se por ser um método não invasivo e bastante difundido para o diagnóstico de problemas cardíacos, tais como detecção de anormalidades estruturais e defeitos nas válvulas cardíacas devido aos sopros cardíacos (Humayun et al., 2020).

Segundo Chowdhury et al. (2019), as doenças cardiovasculares (DCV) são a principal causa de morte humana em todo o mundo. Com base no *British Heart Foundation*, em 2014, as DCV foram a segunda causa de morte no Reino Unido com mais de 155.000 pessoas, o que causou quase 27% de todas as mortes. Em 2017, essa doença foi responsável por 3,9 milhões de morte na Europa, ou seja, as DCV são responsáveis por 45% de todas as mortes da Europa.

Complementando, Tiwari et al. (2021) informaram por dados da *World Health Organization* (WHO) que as DCV são a principal causa de morte pelo mundo. Estima-se que 17,9 milhões de pessoas morrem anualmente decorrentes de problemas cardiovasculares, representando 32% de todas as mortes globais. Segundo Kobat and Dogan (2021), se houvessem mais facilidades no diagnóstico em estágio inicial do problema, haveria mais possibilidades de sucesso no tratamento para este transtorno.

Segundo Leng et al. (2015), a maioria das doenças cardíacas está associada e relacionada com os sons que o coração produz. A ausculta cardíaca, caracterizada em escutar o som do coração, devido ao ciclo cardíaco, continua sendo um método importante para o diagnóstico precoce da disfunção cardíaca.

Atualmente, devido aos transtornos ocasionados pela pandemia do novo coronavírus (COVID-19), houve melhor aceitação na área da saúde pela automatização, em algumas situações, da assistência médica e monitoramento remoto, termos e procedimentos que caracterizam a tele-saúde. Por meio do uso de tecnologia da informação e Internet das Coisas (IoT - *Internet of Things*) abre-se diversas possibilidades que deverão impactar no futuro na taxa de precisão de diagnóstico e monitoramento remoto (Dong and Yao, 2021). Neste sentido, o uso da IoT e *Cloud Computing* permite o desenvolvimento e implementação de rotinas que atendam à necessidade de atendimento hospitalar e ambulatorial mais humanizado com foco no bem estar do paciente (Ukil et al., 2019).

A IoT possui uma demanda relevante na área médica, principalmente pelos pacientes que requerem maior acompanhamento dos sinais vitais. Os *wearables* podem ser empregados no monitoramento remoto de sinais vitais, gerando redução de tempo de espera nos ambulatorios e salas de emergência, ou seja, produzindo diretamente maior conforto e humanização aos pacientes. Os dispositivos de IoT podem ser utilizados também para rastreamento e localização de ativos, gerenciamento de insumos e medicamentos, controle de doenças crônicas, entre outras rotinas hospitalares (Aranda et al., 2021, 2020).

A utilização da Inteligência Artificial (IA) na medicina tem fomentado o desenvolvimento de diagnósticos mais precisos e tratamentos mais eficientes aos pacientes (Kim et al., 2021). Com a possibilidade do uso de banco de dados com grande volume de informações (*Big Data*), as soluções em IA estão em constante adaptação com objetivo de melhorar seus índices de acurácia (Ahmed et al., 2021).

A ausculta cardíaca baseada em inteligência artificial, no contexto do Aprendizado de Máquina (Usman et al., 2021) utiliza algoritmos de pré-processamento para aquisição do sinal, para que posteriormente se desenvolva o treinamento para detecção de padrões anormais de batimentos cardíacos aplicando modelos, por exemplo, de rede neural convolucional (CNN) (Singh and Singh, 2019).

Em busca de esclarecer o cenário atual de artigos científicos que façam o uso de IoT e Aprendizado de Máquina na interpretação da auscultação cardíaca, foi criado este artigo. O trabalho aplicou a metodologia de um mapeamento sistemático, tendo sido pesquisadas 6 bases de publicações, resultando em 4.372 artigos e após os critérios de inclusão e exclusão, foram selecionados 58 trabalhos para leitura completa e discussão, com objetivo de responder as questões da pesquisa delineadas pelo processo metodológico.

O artigo está organizado em quatro seções. A primeira seção contextualiza o tema e apresenta o cenário atual. Por sua vez, a seção 2 descreve a metodologia de pesquisa. A seção 3 discute os resultados para cada questão de pesquisa. A seção 4 apresenta as considerações finais e, por último, são apresentadas as referências.

2 Metodologia

A observação do estado da arte é estratégica na realização de pesquisas científicas, seja para delinear um novo projeto de pesquisa, escrever uma dissertação/tese ou compor um artigo científico.

A análise dos resultados em um mapeamento sistemático, de acordo com Dermeval et al. (2020), tem como objetivo mostrar a frequência e a quantidade de publicações por categoria dentro de uma determinada área de domínio.

Este artigo utiliza como processo metodológico o mapeamento sistemático, proposto por Petersen et al. (2015), o qual está organizado em: 1) definir as questões de pesquisa; 2) definir o processo de busca; 3) estabelecer os critérios para filtro dos resultados e 4) executar as análises e classificar os resultados.

2.1 Questões de Pesquisa

A Tabela 1 apresenta as questões da pesquisa, as quais estão organizadas em Questões Gerais (QG), Questão Focal (QF) e Questões Estatísticas (QE). A diferenciação entre Questões Gerais (QG) e Questão Focal (QF) ocorre pelo fato das primeiras estarem relacionadas aos mecanismos da captura do sinal biológico e as vantagens almejadas do uso da IoT na área da saúde, por sua vez a Questão Focal (QF) está focada em analisar métodos e técnicas de aprendizado de máquina.

Tabela 1: Questões de pesquisa

ID	Questões de Pesquisa
QG1	Quais recursos de IoT estão sendo utilizados na captura de sinais sonoros do tórax humano?
QG2	Quais são os benefícios almejados para o paciente pelo uso de IoT para cuidados cardíacos?
QG3	Quais métodos atualmente estão sendo utilizados para observação dos batimentos cardíacos?
QF1	Há menção aos cuidados utilizando Aprendizado de Máquina?
QE1	Qual a distribuição de artigos por país?
QE2	Qual a distribuição de artigos por anos e bases?
QE3	Quais artigos abordam atenção básica de saúde e focam em propostas de baixo custo?

2.2 Termos de buscas

Os termos definidos para a pesquisa foram unidos pelas expressões booleanas AND e OR, sendo organizados em quatro conjuntos de interesses (separados por AND). A fim de estabelecer os interesses da pesquisa, foi definida a seguinte string de busca:

(*heart diseases OR cardiac anomalies OR heart pathologies*) AND (*phonocardiography OR heart sounds OR heart murmur*) AND (*IoT OR machine learning OR deep learning OR artificial intelligence*) AND (*smartphone OR smartphones OR mHealth OR m-health OR ubiquitous OR pervasive OR wearable sensors OR digital stethoscope*).

A string foi executada nas seguintes bases de dados: ACM Digital Library, IEEE Xplore, JMIR, PubMed Central, Science Direct e Springer Library.

A Fig. 1 apresenta a distribuição dos 58 artigos mapeados considerando-se as bases pesquisadas. Pode-se observar que a maioria das publicações encontradas foram na base de dados da IEEE Xplore Digital Library¹ (53%), seguida pelas bases PubMed Central² (27%), ScienceDirect³ (12%), ACM Digital Library⁴ (3%), Springer Library⁵ (3%) e JMIR – Journal of Medical Internet Research⁶ (2%).

Os artigos mapeados foram armazenados na ferramenta




Figura 1: Bases de publicações

Mendeley⁷, e posteriormente exportados para análise bibliométrica no VOSviewer⁸.

2.3 Critérios e resultado da filtragem

Neste estudo foram definidos os seguintes Critérios de Inclusão:

- CI1: Publicação em conferência, periódico ou *workshop*;
- CI2: Conteúdo completo à disposição; e as publicações deveriam compreender o uso de Internet das Coisas e Aprendizado de Máquina no auxílio do diagnóstico de disfunções do coração humano.

Em contraponto, os Critérios de Exclusão (CE) foram:

- CE1: Artigos publicados antes de 2010;
- CE2: Idioma diferente do Inglês;
- CE3: Teses, dissertações, livros e revisões e mapeamentos sistemáticos;
- CE4: Artigos não relacionados ao tema; e
- CE5: Artigos duplicados.

A Fig. 2 apresenta o resultado da pesquisa nas bases de dados, o processo de filtragem com aplicação dos critérios de inclusão e exclusão, combinação das bases, remoção dos artigos duplicados e a filtragem dos artigos selecionados para leitura completa.

A filtragem inicial removeu os artigos usando os critérios de exclusão CE1, CE2 e CE3. Em seguida, os textos foram filtrados por CE4 considerando o título e as palavras-chave. Por fim, os estudos foram filtrados de acordo com os resumos usando CE4 e CE5.

A Tabela 2 apresenta a lista dos artigos selecionados, contendo uma identificação numérica, a referência, os países dos autores, as base de dados, ano da publicação e um resumo dos modelos contemplados.

3 Discussão das questões

As próximas seções responderão as perguntas da pesquisa, usando como referência o número de identificação (ID)

¹<https://ieeexplore.ieee.org>

²<https://www.ncbi.nlm.nih.gov>

³<https://www.sciencedirect.com>

⁴<https://dl.acm.org>

⁵<https://link.springer.com>

⁶<https://www.jmir.org>

⁷<https://www.mendeley.com>

⁸<http://www.vosviewer.com>




Figura 2: Busca inicial, aplicação de critérios, junção, remoção e resultado

mostrado na primeira coluna da Tabela 2.

3.1 QG1 – Quais recursos de IoT estão sendo utilizados na captura de sinais sonoros do tórax humano?

Dentre os 58 artigos selecionados, 6,90% (4) (IDs=9, 43, 46, 51) fazem menção do uso de dispositivos de IoT para captura do sinais sonoros. Segundo Santos et al. (2020), no campo da saúde a IoT é conhecida como *Internet of Health Things* (IoHT), sendo um campo de rápido progresso, com vários investimentos relacionados à melhoria e uso da IoT. Estima-se que em 2020, IoHT teve um impacto econômico de US\$ 170 bilhões. Os autores apresentaram diversos componentes de modelos que fazem uso de dispositivos IoHT como monitorar batimento cardíaco, temperatura corporal, pressão sanguínea, oxigenação sanguínea. Eles escrevem sobre exames eletrocardiograma, fotopleismografia através de vestíveis com conectividade sem fio à internet, armazenando em *Cloud* e diagnóstico usando aprendizado de máquina.

Balakrishnand et al. (2020) (ID=51) implementaram uma solução de um sistema integrado para aquisição, armazenamento e análise assíncrona do som cardíaco com algoritmos de aprendizado de máquina.

Deperlioglu et al. (2020) (ID=46) apresentaram o uso do IoHT, evidenciando a necessidade de um processo seguro que deverá estar incluído no modelo devido ao uso da internet. Usaram para treinamento do modelo os sons cardíacos das bases PASCAL B-Training e Physiobank-PhysioNet A-Training e obtiveram taxa de acuracidade superior a 90%. O modelo proposto pelos autores utiliza a arquitetura de estetoscópio digital com conexão *bluetooth* interligado por *beacons* ao servidor com acesso a *Cloud*, com uma CNN

para diagnóstico. Os autores classificaram a solução como sem a necessidade de modelos híbridos complexos para uso em ambiente hospital ou clínico.

Aileni et al. (2017) (ID=9) usaram as unidades de terapia intensiva (UTI) para demonstrar um modelo para aquisição de sinais biomédicos com o objetivo de monitoramento respiratório por sensores flexíveis e vestíveis. O modelo fez uso da prototipagem eletrônica Arduino, interligado por *bluetooth* ao notebook para processamento e análise do sinal pelo software MatLab e *smartphone* Android. O software MatLab foi usado em 24 trabalhos (IDs=2, 3, 7, 8, 9, 11, 16, 17, 18, 24, 26, 27, 30, 35, 37, 39, 42, 46, 48, 54, 55, 56, 57, 58).

Segundo Ukil et al. (2019) (ID=43), o gerenciamento remoto e automatizado da assistência médica tem um potencial de uso significativo na área da saúde. A IoT e o aprendizado de máquina podem auxiliar na triagem com indicações de diagnósticos, minimizando o tempo de atendimento dos pacientes. A proposta dos autores é um modelo preditivo para a presença de anormalidade cardíaca a partir de dados de um PCG, mas com preocupação, devido ao uso de IoT, do sigilo das informações de saúde do paciente.

Conforme observado, a principal ferramenta utilizada para captar sinais foi o estetoscópio digital, mencionando em 44 artigos (IDs=3, 4, 5, 6, 7, 8, 10, 11, 13, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 29, 30, 31, 32, 33, 35, 36, 37, 38, 39, 42, 44, 45, 46, 48, 49, 50, 51, 52, 53, 54, 56). A conectividade dos estetoscópios digitais ocorre, na maioria dos equipamentos, por *bluetooth*, não pela internet e por este motivo não são considerados como dispositivos IoT. No futuro a conexão a internet será incorporada em mais projetos de *smart* estetoscópio. Os protótipos em Arduino e microcontroladores, simulando o estetoscópio, já usam a conexão à Internet e com menor custo de produção.

3.2 QG2 - Quais são os benefícios almejados para o paciente pelo uso de IoT para cuidados cardíacos?

Segundo Balakrishnand et al. (2020) (ID=51), IoT pode contribuir para a expansão do acesso à saúde de qualidade por meio do monitoramento dinâmico do ser humano em seu ambiente. Desta forma, o IoT pode melhorar a eficácia dos tratamentos, prevenir situações de risco e auxiliar na promoção da saúde. No âmbito do monitoramento remoto foram encontrados 12 trabalhos (IDs=5, 9, 10, 17, 27, 36, 38, 40, 43, 44, 51, 55). Além disso, a IoT aumenta a eficiência do gerenciamento de recursos por meio de flexibilidade e mobilidade usando soluções inteligentes. No entanto, isso requer uma transição do tratamento centrado na clínica para o cuidado médico focado no paciente, de modo que o hospital, os pacientes e os serviços, estejam perfeitamente conectados.

Os autores Doshi et al. (2019) (ID=27) propuseram o diagnóstico remoto de doenças cardíacas por meio da telemedicina, que é um campo emergente devido aos avanços da computação móvel. Os autores fizeram uma análise dos sistemas existentes para diagnósticos remotos, e realizaram a implementação de um protótipo de ferramenta para diagnóstico assistido de doenças cardíacas. O protótipo tem como uma das características o baixo custo para fabricação, tendo sido proposto principalmente para diagnóstico remoto de pacientes em áreas rurais ou não acessíveis, e também para acampamentos militares isolados ou locais de acidentes onde o diagnóstico e tratamento especializados são difíceis de serem obtidos.

3.3 QG3 - Quais métodos atualmente estão sendo utilizados para observação dos batimentos cardíacos?

Dentre os 58 artigos selecionados, 45 trabalhos (77.59%, IDs=3, 4, 5, 6, 7, 8, 10, 11, 13, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 29, 30, 31, 32, 33, 35, 36, 37, 38, 39, 42, 41, 44, 45, 46, 48, 49, 50, 51, 52, 53, 54, 56) citam métodos de observação de batimentos cardíacos.

Existem dois métodos amplamente usados para a observação do batimento cardíaco. O primeiro é realizado através de pulsos elétricos capturados por eletrodos nos exames de eletrocardiograma (2 trabalhos, IDs=18, 30), que inclusive atualmente, pode usar sensores da plataforma Arduino para criar soluções de monitoramento de frequências cardíacas. E o segundo método tem como seu principal dispositivo o estetoscópio (44 artigos, IDs=3, 4, 5, 6, 7, 8, 10, 11, 13, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 29, 30, 31, 32, 33, 35, 36, 37, 38, 39, 42, 44, 45, 46, 48, 49, 50, 51, 52, 53, 54, 56). O aparelho funciona encostando-se o auscultador no corpo do paciente, o som é amplificado e chegará às orelhas conectadas no ouvido através dos cabos.

Atualmente com o aumento do uso do *smartwatch*, outro método de observação de batimentos cardíacos está em franca expansão, a fotopletiografia (PPG). Elgendy et al. (2019) (ID=41) apresentaram o uso de PPG, informando que o método é mais comumente usada em oximetria de pulso em ambientes clínicos para medir a saturação de oxigênio, para observação de batimentos cardíacos e pressão

arterial (PA).

3.4 QF1 - Há menção aos cuidados utilizando Aprendizado de Máquina?

Dentre os 58 artigos selecionados, 34 trabalhos (58.62%, IDs=1, 2, 5, 6, 10, 19, 20, 21, 22, 25, 31, 32, 33, 34, 35, 36, 37, 39, 40, 41, 42, 43, 44, 46, 48, 49, 50, 51, 52, 53, 54, 55, 56, 58) fazem menção aos cuidados utilizando Aprendizado de Máquina.

Leng et al. (2015) (ID=36) apresentaram as possíveis interações entre o estetoscópio eletrônico, algoritmo de decomposição de sinais captados pelo sensores, técnicas de aprendizado de máquina e a segmentação do som cardíaco.

Chowdhury et al. (2019) (ID=35) propuseram um sistema portátil para a detecção precoce de doenças cardíacas através de sons produzidos pelo coração. O modelo utilizou para treinamento *dataset PhysioNet-2016* com os algoritmos de aprendizado de máquina no MatLab. O sistema é descrito como um modelo de um sistema inteligente de estetoscópio digital para monitorar os sons cardíacos do paciente e diagnosticar qualquer anormalidade em tempo real. A comunicação seria realizada através de tecnologia sem fio de baixo consumo de energia (*Bluetooth*) entre o estetoscópio e um computador pessoal. Entre os artigos selecionados, 16 trabalhos citam o uso do *Bluetooth* (IDs=1, 3, 4, 6, 9, 14, 21, 22, 31, 35, 36, 38, 41, 44, 46, 51).

Thiyagaraja et al. (2018) (ID=44) apresentaram uma descrição detalhada de um estetoscópio eletrônico baseado em *smartphone* que pode gravar, processar e identificar 16 tipos de sons cardíacos. Segundo os autores, a solução apresentada é portátil, de baixo custo e não requer um médico altamente treinado para operar. O modelo contempla o uso de algoritmos de aprendizado de máquina.

Ren et al. (2018) (ID=2) utilizaram redes neurais convolucionais (CNN) (19 artigos citam CNN ou seja, IDs=1, 2, 10, 19, 23, 31, 32, 33, 39, 41, 43, 46, 47, 49, 51, 52, 54, 55, 58) de classificação de imagens de escalograma de PCG para a tarefa de classificação de sons cardíacos entre normais e anormais. As representações do sinal PCG são obtidas por *dataset* dos seguintes locais: *Massachusetts Institute of Technology (MIT)*, *Aalborg University*, *Aristotle University of Thessaloniki*, *University of Haute Alsace*, *Dalian University of Technology* e *Shiraz University*. A geração das imagens de escalograma nos sons cardíacos é realizada pela *toolbox wavelet* do MatLab 2017.

Liu et al. (2016) (ID=42) criaram um banco de dados com acesso livre / aberto de sons cardíacos para que pesquisadores pudessem utilizar como *dataset* em algoritmos de aprendizado de máquina. Eles relataram que a área da auscultação cardíaca tem sido amplamente estudada, devido ao alto potencial em detectar a patologia com precisão em aplicações clínicas. Entretanto, as análises comparativas de algoritmos na literatura estavam sendo prejudicadas pela falta de bancos de dados abertos com qualidade, rigorosamente validados e padronizados com registros de sons cardíacos.




Figura 3: Artigos organizados cronologicamente por países

3.5 QE1 - Qual a distribuição de artigos por país?

Os artigos foram mapeados de acordo com os países onde encontra-se a instituição do primeiro autor. A Fig. 3 organiza os artigos cronologicamente de acordo com os países. Nota-se que 11 artigos estão vinculados com os países, EUA e Índia, seguido da China com 5, Turquia com 4, Canadá, Bangladesh com 3 artigos, Alemanha, Singapura, México e Suíça com 2 artigos cada e os demais países com uma publicação.

3.6 QE2 - Qual a distribuição de artigos por ano e bases?

A Fig. 4 apresenta o número de estudos por ano de janeiro de 2010 a julho de 2021, enfatizando a identificação do artigo e a base de publicação.

Observa-se na Figura que em 2010 foram publicados 3 artigos, tendo um declínio e estabilidade nos anos de 2011 e 2016, um aumento de publicação em 2017, 2018 e 2019, sendo 13 publicações no ano de 2019. Em 2020 foram 8 publicações e até julho de 2021 ocorreram 10 publicações.

3.7 QE3 - Quais artigos abordam atenção básica de saúde e focam em propostas de baixo custo?

São poucos os países que possuem um sistema de saúde público universal. Talvez por este motivo nenhum artigo usou como referência o termo atenção básica de saúde, regularmente chamado no Brasil de Sistema Único de Saúde (SUS). O termo citado nos artigos para o uso de equipamentos e serviços inteligentes relaciona-se com a triagem dos postos de atendimento de pacientes.

No Brasil, a atenção básica de saúde está relacionada ao primeiro atendimento dos usuários no sistema único de saúde. Seus principais objetivos são em orientar sobre a prevenção de doenças, ajudar em possíveis casos de agravos à saúde coletiva ou individual e direcionar os mais graves para níveis de atendimento superiores, funcionando como um filtro para organizar o fluxo dos serviços mais complexos e custosos a rede de saúde pública.

Deve-se compreender o termo filtro do parágrafo anterior como triagem, realizada com o uso de dispositivos inteligentes de baixo custo financeiro com objetivo de auxiliar no encaminhamento e providências ao pacientes em forma de tratamento ou exames mais sofisticados e onerosos.

Dentre os 58 artigos selecionados, 30 trabalhos (51,72%, IDs=1, 3, 4, 5, 6, 7, 9, 10, 13, 15, 19, 20, 23, 27, 29, 30, 31, 32, 33, 35, 36, 41, 44, 46, 48, 49, 50, 51, 52, 58) informaram a possibilidade do uso de dispositivos de baixo custo para auxiliar na triagem de exames mais sofisticados para constatação de uma disjunção cardíaca.

Os autores Maritsch et al. (2019) (ID=1) informaram o aumento do uso de *smartwatches* para monitoramento cardíaco pela população mundial. Frank and Meng (2017) (ID=4), Szot et al. (2019) (ID=6) e Waqar et al. (2019) (ID=3) propuseram a criação de estetoscópio digital de baixo custo baseado em Arduino. Os artigos dos autores citados apresentam o uso de dispositivos de baixo custo para monitoramento e suporte à análise de sinais produzidos pelo coração humano.

Fattah et al. (2017) (ID=5) propuseram um estetoscópio digital de baixo custo para monitoramento remoto e uso de algoritmos de aprendizado de máquina. O uso deste equipamento destina-se principalmente para acompanhamento de pessoal em locais de difícil acesso. Sinharay et al. (2016) (ID=7) apresentaram uma proposta semelhante,

Legenda e quantidade

- ACM (2)
- IEEE Xplore (32)
- JMIR (1)
- PubMed Central (16)
- ScienceDirect (7)
- Springer (2)

* Numero de Identificação do artigo
mostrado na primeira coluna da tabela 2




Figura 4: Artigos organizados cronologicamente por bases de publicação




Figura 5: Visão global do relacionamento entre termos.

entretanto tentaram adaptar um sensor de baixo custo a um *smartphone*, com objetivo de deixar o equipamento com funcionamento similar ao estetoscópio, auxiliando pacientes com dificuldades de locomoção, idosos, recém operados, inclusive pensando em países em desenvolvimento com baixa fluidez de transporte coletivo.

Gradl et al. (2018) (ID=14), implementaram um modelo utilizando realidade virtual. O experimento foi realizado com a imersão de 14 participantes em ambientes que pudessem provocar alterações comportamentais sendo possível sua visualização em tempo real da atividade cardíaca utilizando sensores vestíveis e *smartphones*, ou seja, apresentando a variação emocional relacionada à atividade cardíaca.

Pode-se destacar artigos que apresentam projetos de *smart* estetoscópios, com comunicação *bluetooth* (Ma et al. (2019) (ID=10), armazenamento de sinais em *cloud* (14 artigos, IDs=5, 19, 32, 36, 40, 41, 43, 44, 46, 48, 49, 51, 55, 56), com objetivo de melhorar a amplificação do sinal (Udawatta et al. (2010) (ID=17)), utilizando o processamento do sinal pelo MatLab (Malek et al. (2013) (ID=18)), viabilizando soluções via computação ubíqua (Swarup and Makaryus (2018) (ID=38), Thiyagaraja et al. (2018) (ID=44)).

Móvel (Mobilab), à Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), a Secretaria de Estado de Saúde de Mato Grosso, o Hospital Metropolitano em Várzea Grande e ao setor de Comissão Permanente para Licença/Dispensa da SES-MT.

4 Considerações Finais

Este artigo apresentou o cenário dos trabalhos científicos que fazem menção a aprendizado de máquina e IoT, no período de janeiro de 2010 à julho de 2021, relacionados a análise e classificação dos sinais produzidos pelo coração humano, com foco maior na auscultação cardíaca.

A Fig. 3 mostra crescimento no número de artigos a partir do ano de 2017, que provavelmente é uma decorrência do aumento da oferta de sensores e *wearables* para a população mundial. Dos 58 artigos selecionados, 34 trabalhos (58.62%) estão relacionados com aprendizado de máquina, apresentando métodos e/ou técnicas, algoritmos, análise e classificação, *dataset* de sons para treinamento, redes neurais e *Big Data*.

A Fig. 5 mostra uma organização de termos através do *software* VOSviewer. A geração do gráfico foi baseada nas palavras obtidas nos títulos e resumos dos 58 artigos selecionados. Segundo a Figura, os termos *deep learning*, *neural networks* e *machine learning*, identificados na cor amarela, foram citados com maior frequência nos artigos publicados no ano de 2020. A análise bibliométrica do VOSviewer evidenciou o foco em descrever modelos para auxiliar nos diagnósticos de disjunções cardiovasculares através do aprendizado de máquina nos trabalhos mais recentes desta revisão.

Em relação a trabalhos futuros pretende-se propor um modelo inteligente para auxiliar no monitoramento, assistência e predição da auscultação cardíaca baseado na análise das informações deste mapeamento sistemático.

Agradecimentos

Os autores agradecem à Universidade do Vale do Rio dos Sinos (Unisinos), o Programa de Pós-Graduação em Computação Aplicada (PPGCA), o Laboratório de Computação

Tabela 2: Relação dos artigos mapeados

Identificação numérica e Referência	País	Base	Resumo de Modelos de Análises/ Serviços Inteligentes
1. Maritsch et al. (2019)	EUA	ACM	Redes Neurais.
2. Ren et al. (2018)	Alemanha/ Reino Unido	ACM	Aprendizado de Máquina e Redes Neurais Convolucionais.
3. Waqar et al. (2019)	Paquistão	IEEE Xplore	Estetoscópio digital de baixo custo.
4. Frank and Meng (2017)	China	IEEE Xplore	Vestível para monitoramento.
5. Fattah et al. (2017)	Bangladesh	IEEE Xplore	Estetoscópio digital de baixo custo para monitoramento remoto e uso de algoritmos de aprendizagem.
6. Szot et al. (2019)	EUA	IEEE Xplore	Estetoscópio digital sem fio em Arduino.
7. Sinharay et al. (2016)	Índia	IEEE Xplore	Estetoscópio digital baseado em Smartphone.
8. Suseno and Burhanudin (2018)	Indonésia	IEEE Xplore	Identificação do som cardíaco por meio de transformada wavelet e rede neural.
9. Aileni et al. (2017)	Romênia/ Bélgica	IEEE Xplore	Aquisição de sinal usando sensor Arduino.
10. Ma et al. (2019)	China	IEEE Xplore	Estetoscópio digital com rede neural.
11. Hall et al. (2018)	EUA	IEEE Xplore	Modelo matemático no sinal sonoro.
12. Haibin et al. (2010)	China	IEEE Xplore	Transformada Wavelet família Daubechies.
13. Aguilera-Astudillo et al. (2016)	México	IEEE Xplore	Estetoscópio digital para armazenamento do sinal sonoro.
14. Gradl et al. (2018)	EUA	IEEE Xplore	Realidade virtual em observação a frequência cardíaca.
15. Deepan et al. (2017)	Índia	IEEE Xplore	Deteção de ruído na sinal.
16. Ayari et al. (2012)	Tunísia/ EUA	IEEE Xplore	Algoritmo de análise de componentes matemáticos para separação do sons cardíacos dos sons pulmonares.
17. Udawatta et al. (2010)	Sri Lanka	IEEE Xplore	Estetoscópio Digital para amplificar o sinal.
18. Malek et al. (2013)	Malásia	IEEE Xplore	Estetoscópio Digital em Arduino, ZigBee e processamento de sinal pelo MatLab.
19. Singh and Singh (2019)	Índia	IEEE Xplore	Redes Neurais Convolucionais.
20. Das et al. (2017)	Índia	IEEE Xplore	Algoritmo para remover ruídos do sinal, independentemente da qualidade do sensor.
21. Gjoreski et al. (2017)	Eslovênia/ Macedônia	IEEE Xplore	Aprendizado de Máquina.
22. Pereira et al. (2011)	Portugal/ Brasil	IEEE Xplore	Aprendizado de Máquina.
23. Banerjee et al. (2017)	Índia	IEEE Xplore	Redes Neurais Convolucionais.
24. Suhn et al. (2019)	Alemanha	IEEE Xplore	Equipamento para auscultação da carótida.
25. Gautam and kumar (2013)	Índia	IEEE Xplore	Rede Neural Artificial de Perceptron Multicamadas de Retropropagação.
26. Zhang et al. (2010)	Singapura	IEEE Xplore	Algoritmo de estimativa de batimentos cardíacos.
27. Doshi et al. (2019)	Índia	IEEE Xplore	Rede Neural Artificial.
28. Prasad et al. (2020)	Suíça	IEEE Xplore	Processamento no domínio do tempo que emprega um filtro passa-baixo.
29. Rao et al. (2018)	Suíça	IEEE Xplore	Rede Neural Artificial.
30. Hui et al. (2020)	EUA	IEEE Xplore	Investiga o movimento transitório e batimentos cardíacos.
31. Humayun et al. (2020)	Bangladesh/ EUA	IEEE Xplore	Uso de rede neural convolucional para detecção anormalidade do som cardíaco com o estetoscópio.
32. Shuvo et al. (2021)	Bangladesh/ Arábia Saudita/ Iémen	IEEE Xplore	Rede Neural Convolucional para detecção automática de diferentes classes de doenças cardiovasculares, direto pelo sinal fonocardiografia.
33. Tiwari et al. (2021)	Índia/ Arábia Saudita	IEEE Xplore	.Modelo híbrido, com processamento de sinal usando a transformada de Q constante e Rede Neural Convolucional.
34. Du et al. (2019)	China	JMIR	Big Data e Aprendizado de Máquina.
35. Chowdhury et al. (2019)	Catar/ Malásia	PubMed Central	Processamento e classificação usando MATLAB.
36. Leng et al. (2015)	Singapura	PubMed Central	Técnicas de Aprendizado de Máquina.
37. Elgendi et al. (2015)	Canadá/ Índia	PubMed Central	Desenvolvido um algoritmo baseado em Wavelet.
38. Swarup and Makaryus (2018)	EUA	PubMed Central	Uso de estetoscópio digital e computação móvel.
39. Raza et al. (2019)	Coreia	PubMed Central	Rede neural recorrente.
40. Amiri et al. (2017)	EUA	PubMed Central	Algoritmo baseado em wavelet.

Continua na próxima página

Tabela 2 – Continuação da tabela

Identificação numérica e Referência	País	Base	Resumo de Modelos de Análises/ Serviços Inteligentes
41. Elgendi et al. (2019)	Canadá/ EUA/ Reino Unido/ Austrália	PubMed Central	Aprendizado de Máquina.
42. Liu et al. (2016)	EUA/ Reino Unido/ Espanha/ Dinamarca/ Grécia/ Iran/ China	PubMed Central	Apresentação de diversos banco de dados de sons cardíacos para uso em Aprendizado de Máquina.
43. Ukil et al. (2019)	Índia / Suíça/ Espanha	PubMed Central	Análise computacional da saúde cardíaca usando IoT.
44. Thiyagaraja et al. (2018)	EUA	PubMed Central	Mobilidade e monitoramento remoto do paciente.
45. Dehkordi et al. (2019)	Canadá/ Itália/ Dinamarca/ EUA	PubMed Central	Investigar e quantificar a confiabilidade das metodologias não invasivas disponíveis com o potencial de serem incorporadas em dispositivos vestíveis.
46. Deperlioglu et al. (2020)	Turquia/ Índia/ Taiwan	PubMed Central/ ScienceDirect	Modelo com IoTH, Cloud e Deep Learning para classificação dos sons cardíacos.
47. Wang et al. (2020)	Taiwan	PubMed Central	Rede Neural Convolutacional para paciente identificação de Defeito do Septo ventricular.
48. Gómez-Quintana et al. (2021)	Irlanda/ Ucrânia	PubMed Central	Aprendizado de Máquina para diagnóstico de Doença Cardíaca Congênita no pré-natal.
49. Chorba et al. (2021)	EUA	PubMed Central	Deep Learning para detectar sopros e estenose aórtica via estetoscópio digital.
50. Soto-Murillo et al. (2021)	México	PubMed Central	Deep Learning para classificar os sons cardíacos em normais e anormais.
51. Balakrishnand et al. (2020)	Índia	Science Direct	IoT e aprendizado de máquina.
52. Levin et al. (2021)	EUA	Science Direct	Aprendizado de Máquina para classificar os tipos de sons cardíacos.
53. Brunese et al. (2020)	Itália	Science Direct	Triagem de pacientes com auxílio de algoritmos de Deep Learning.
54. Bilal (2021)	Turquia	Science Direct	Classificação do sons cardíacos por Deep Learning.
55. Tuncer et al. (2021)	Turquia/ Singapura/ Taiwan	Science Direct	Aprendizado de Máquina para identificação de quadro doenças de válvulas do coração.
56. Kobat and Dogan (2021)	Turquia	Science Direct	Aprendizado de Máquina para diagnosticar doenças das válvulas cardíacas.
57. Yadav et al. (2020)	Índia/ Espanha	Springer Library	Modelo com Aprendizado de Máquina para distúrbios cardíacos.
58. Zeng et al. (2021)	China/ EUA	Springer Library	Híbrido com transformadas e redes neurais.

Fim da tabela

Referências

- Aguilera-Astudillo, C., Chavez-Campos, M., Gonzalez-Suarez, A. and Garcia-Cordero, J. L. (2016). A low-cost 3-d printed stethoscope connected to a smartphone, *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS 2016-October*: 4365–4368. <https://doi.org/10.1109/EMBC.2016.7591694>.
- Ahmed, I., Ahmad, M., Jeon, G. and Piccialli, F. (2021). A framework for pandemic prediction using big data analytics, *Big Data Research* 25: 100190. <https://doi.org/10.1016/j.bdr.2021.100190>.
- Aileni, R. M., Pasca, S., Strungaru, R. and Valderrama, C. (2017). Biomedical signal acquisition for respiration monitoring by flexible analog wearable sensors raluca, *2017 E-Health and Bioengineering Conference, EHB 2017* 1: 81–84. <https://doi.org/10.1109/EHB.2017.7995366>.
- Amiri, A. M., Abtahi, M., Constant, N. and Mankodiya, K. (2017). Mobile phonocardiogram diagnosis in newborns using support vector machine, *Healthcare* 5: 16. <https://doi.org/10.3390/healthcare5010016>.
- Aranda, J. A. S., Bavaresco, R. S., de Carvalho, J. V., Yamin, A. C., Tavares, M. C. and Barbosa, J. L. V. (2021). A computational model for adaptive recording of vital signs through context histories, *Journal of Ambient Intelligence and Humanized Computing* . <https://doi.org/10.1007/s12652-021-03126-8>.
- Aranda, J. A. S., Dias, L. P. S., Barbosa, J. L. V., de Carvalho, J. V., da Rosa Avars, J. E. and Tavares, M. C. (2020). Collection and analysis of physiological data in smart environments: a systematic mapping. journal of ambient intelligence and humanized computing, *Journal of Ambient Intelligence and Humanized Computing* 11: 2883–2897. <https://doi.org/10.1007/s12652-019-01409-9>.
- Ayari, F., Ksouri, M. and Alouani, A. T. (2012). Lung sound extraction from mixed lung and heart sounds fastica algorithm, *Proceedings of the Mediterranean Electrotechnical Conference - MELECON* pp. 339–342. <https://doi.org/10.1109/MELCON.2012.6196444>.
- Balakrishnand, D., Rajkumart, T. D. and Dhanasekaran, S. (2020). An intelligent and secured heart rate monitoring system using iot, *Materials Today: Proceedings* . <https://doi.org/10.1016/j.matpr.2020.11.316>.
- Banerjee, R., Choudhury, A. D., Deshpande, P., Bhattacharya, S., Pal, A. and Mandana, K. M. (2017). A robust dataset-agnostic heart disease classifier from phonocardiogram, *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS* pp. 4582–4585. <https://doi.org/10.1109/EMBC.2017.8037876>.
- Bilal, E. R. M. (2021). Heart sounds classification using convolutional neural network with 1d-local binary pattern and 1d-local ternary pattern features, *Applied Acoustics* 180: 108152. <https://doi.org/10.1016/j.apacoust.2021.108152>.
- Brunese, L., Martinelli, F., Mercaldo, F. and Santone, A. (2020). Deep learning for heart disease detection through cardiac sounds, *Procedia Computer Science* 176: 2202–2211. <https://doi.org/10.1016/j.procs.2020.09.257>.
- Chorba, J. S., Shapiro, A. M., Le, L., Maidens, J., Prince, J., Pham, S., M., M., Barbosa, K. D. N., Currie, C., Brooks, C., White, B. E., Huskin, A., Paek, J., Geocaris, J., Elnathan, D., Ronquillo, R., Kim, R., Alam, Z. H., Mahadevan, V. S., Fuller, S. G., Stalker, G. W., Bravo, S. A., Jean, D., Lee, J. J., Gjergjindrea, M., Mihos, C. G., Forman, S. T., Venkatraman, S., McCarthy, P. M. and Thomas, J. D. (2021). Deep learning algorithm for automated cardiac murmur detection via a digital stethoscope platform, *Journal of the American Heart Association* 10. <https://doi.org/10.1161/JAHA.120.019905>.
- Chowdhury, M. E., Khandakar, A., Alzoubi, K., Mansoor, S., Tahir, A. M., Reaz, M. B. I. and Al-Emadi, N. (2019). Real-time smart-digital stethoscope system for heart diseases monitoring, *Sensors (Switzerland)* 19. <https://doi.org/10.3390/s19122781>.
- Das, D., Banerjee, R., Choudhury, A. D., Bhattacharya, S., Deshpande, P., Pal, A. and Mandana, K. M. (2017). Noise detection in smartphone phonocardiogram, *IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP) 2017* pp. 2–3. <https://doi.org/10.1109/ICASSP.2017.8005305>.
- Deepan, D., Banerjee, R., Choudhury, A. D., Bhattacharya, S., Deshpande, P., Pal, A. and Mandana, K. M. (2017). Novel features from autocorrelation and spectrum to classify phonocardiogram quality, *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS* pp. 4516–4520. <https://doi.org/10.1109/EMBC.2017.8037860>.
- Dehkordi, P., Khosrow-Khavar, F., Rienzo, M. D., Inan, O. T., Schmidt, S. E., Blaber, A. P., Sørensen, K., Struijk, S. J., Zakeri, V., Lombardi, P., 4, M. M. H. S., Borairi, M., Zanetti, J. M. and Tavakolian, K. (2019). Comparison of different methods for estimating cardiac timings: A comprehensive multimodal echocardiography investigation, *Frontiers in Physiology* 10. <https://doi.org/10.3389/fphys.2019.01057>.
- Deperlioglu, O., Kose, U., Gupta, D., Khanna, A. and Sangaiha, A. K. (2020). Diagnosis of heart diseases by a secure internet of health things system based on autoencoder deep neural network, *Information Sciences* 162: 31–50. <https://doi.org/10.1016/j.comcom.2020.08.011>.
- Dermeval, D., de M. Coelho, J. A. P. and Bittencourt, I. I. (2020). *Mapeamento Sistemático e Revisão Sistemática da Literatura em Informática na Educação*, v.2 edn, SBC, Porto Alegre, RS. Série Metodologia de Pesquisa em Informática na Educação.
- Dong, Y. and Yao, Y. D. (2021). Iot platform for covid-19 prevention and control: A survey, *IEEE Access* 9: 49929–49941. <https://doi.org/10.1109/ACCESS.2021.3068276>.

- Doshi, M., Fafadia, M., Oza, S., Deshmukh, A. and Pistolwala, S. (2019). Remote diagnosis of heart disease using telemedicine, *2019 International Conference on Nascent Technologies in Engineering (ICNTE)* pp. 1–5. <https://doi.org/10.1109/ICNTE44896.2019.8945967>.
- Du, Z., Yang, Y., Zheng, J., Li, Q., Lin, D., Lin, D., Fan, J., Cheng, W., Chen, X.-H. and Cai, Y. (2019). Accurate prediction of coronary heart disease for patients with hypertension from electronic health records with big data and machine-learning methods: model development and performance evaluation, *JMIR Medical Informatics* 8. <https://doi.org/10.2196/17257>.
- Elgendi, M., Fletcher, R., Liang, Y., Howard, N., Lovell, N. H., Abbott, D., Lim, K. and Ward, R. (2019). The use of photoplethysmography for assessing hypertension, *npj Digital Medicine* 2: 1–11. <http://dx.doi.org/10.1038/s41746-019-0136-7>.
- Elgendi, M., Kumar, S., Guo, L., Rutledge, J., Coe, J. Y., Zemp, R., Schuurmans, D. and Adatia, I. (2015). Detection of heart sounds in children with and without pulmonary arterial hypertension—daubechies wavelets approach, *PLoS ONE* 10: 1–22. <https://doi.org/10.1371/journal.pone.0143146>.
- Fattah, S. A., Rahmana, N. M., Maksuda, A., Foysal, S. I., Chowdhury, R. I., Chowdhury, S. S. and Shahanaz, C. (2017). Stetho-phone: Low-cost digital stethoscope for remote personalized healthcare, *GHTC 2017 - IEEE Global Humanitarian Technology Conference, Proceedings 2017-Janua*: 1–7. <https://doi.org/10.1109/GHTC.2017.8239325>.
- Ferraz, A. P., Soares, B. S., de Albuquerque Terra, D. A. and Lopes, J. A. (2011). The history of the stethoscope and cardiac auscultation, *Rev Med Minas Gerais* 21: 479–485.
- Frank, P.-W. L. and Meng, M. Q.-H. (2017). A low cost bluetooth powered wearable digital stethoscope for cardiac murmur, *2016 IEEE International Conference on Information and Automation, IEEE ICIA 2016* pp. 1179–1182. <https://doi.org/10.1109/ICInfA.2016.7831998>.
- Gautam, G. and kumar, D. (2013). Biometric system from heart sound using wavelet based feature set, *International Conference on Communication and Signal Processing, ICCSP 2013 - Proceedings* pp. 551–555. <https://doi.org/10.1109/iccsp.2013.6577115>.
- Gjoreski, M., Simjanoska, M., Gradisek, A., Peterlin, A., Gams, M. and Poglajen, G. (2017). Chronic heart failure detection from heart sounds using a stack of machine-learning classifier, *Proceedings - 2017 13th International Conference on Intelligent Environments, IE 2017 2017-Janua*: 14–19. <https://doi.org/10.1109/IE.2017.19>.
- Gómez-Quintana, S., Schwarz, C. E., Shelevytsky, I., Shelevytska, V., Semenova, O., Factor, A., Popovici, E. and Temko, A. (2021). A framework for ai-assisted detection of patent ductus arteriosus from neonatal phonocardiogram, *Healthcare (Switzerland)* 9: 1–19. <https://doi.org/10.3390/healthcare9020169>.
- Gradl, S., Wirth, M., Zillig, T. and Eskofie, B. M. (2018). Visualization of heart activity in virtual reality: a biofeedback application using wearable sensors, *2018 IEEE 15th International Conference on Wearable and Implantable Body Sensor Networks, BSN 2018 2018-Janua*: 152–155. <https://doi.org/10.1109/BSN.2018.8329681>.
- Haibin, W., Yuliang, H., Lihan, L., Yan, W. and Jinbao, Z. (2010). Heart sound analysis based on autoregressive power spectral density, *ICSPS 2010 - Proceedings of the 2010 2nd International Conference on Signal Processing Systems* 2: 582–586. <https://doi.org/10.1109/ICSPS.2010.5555823>.
- Hall, D. L., McTaggart, M. I. and Jenkins, W. K. (2018). Use of adaptive filtering for improved performance in digital stethoscopes, *Conference Record of 51st Asilomar Conference on Signals, Systems and Computers, ACSSC 2017 2017-Octob*: 108–112. <https://doi.org/10.1109/ACSSC.2017.8335147>.
- Hui, X., Conroy, T. B. and Kan, E. C. (2020). Multi-point near-field rf sensing of blood pressures and heartbeat dynamics, *IEEE Access* 8: 89935–89945. <https://doi.org/10.1109/ACCESS.2020.2993994>.
- Humayun, A. I., Ghaffarzagdegan, S., Ansari, M. I., Feng, Z. and Hasan, T. (2020). Towards domain invariant heart sound abnormality detection using learnable filterbanks, *IEEE Journal of Biomedical and Health Informatics* 24: 2189–2198. <https://doi.org/10.1109/JBHI.2020.2970252>.
- Kim, B., Koopmanschap, I., Mehrizi, M. H., Huysman, M. and Ranschaert, E. (2021). How does the radiology community discuss the benefits and limitations of artificial intelligence for their work: A systematic discourse analysis, *European Journal of Radiology* 136: 109566. <https://doi.org/10.1016/j.ejrad.2021.109566>.
- Kobat, M. A. and Dogan, S. (2021). Novel three kernelled binary pattern feature extractor based automated pcg sound classification method, *Applied Acoustics* 179: 108040. <https://doi.org/10.1016/j.apacoust.2021.108040>.
- Leng, S., Tan, R. S., Chai, K. T. C., Wang, C., Ghista, D. and Zhong, L. (2015). The electronic stethoscope, *BioMedical Engineering Online* 14: 1–37. <https://doi.org/10.1186/s12938-015-0056-y>.
- Levin, A. D., Ragazzi, A., Szot, S. L. and Ning, T. (2021). Extraction and assessment of diagnosis-relevant features for heart murmur classification, *Methods* . <https://doi.org/10.1016/j.ymeth.2021.07.002>.
- Liu, C., Springer, D., Li, Q., Moody, B., Juan, R. A., Chorro, F. J., Castells, F., Roig, J. M., Silva, I., Johnson, A. E. W., Syed, Z., Schmidt, S. E., Papadaniil, C. D., Hadjileontiadis, L., Naseri, H., Moukadem, A., Dieterlen, A., Brandt, C., Tang, H., Samieinasab, M., Samieinasab, M. R., Sameni, R., Mark, R. G. and Clifford, G. D. (2016). An open access database for the evaluation of heart sound algorithms, *Physiological Measurement* 37: 2181–2213. <https://doi.org/10.1088/0967-3334/37/12/2181>.

- Ma, Y., Xu, X., Yu, Q., Zhang, Y., Li, Y., Zhao, J. and Wang, G. (2019). Live demo: Lungsys – automatic digital stethoscope system for adventitious respiratory sound detection, *BioCAS 2019 – Biomedical Circuits and Systems Conference, Proceedings* p. 5090. <https://doi.org/10.1109/BioCAS.2019.8918752>.
- Malek, S. N. H., Zaki, W. S. W., Joret, A. and Jamil, M. M. A. (2013). Design and development of wireless stethoscope with data logging function, *Proceedings – 2013 IEEE International Conference on Control System, Computing and Engineering, ICCSCE 2013* pp. 132–135. <https://doi.org/10.1109/ICCSCE.2013.6719946>.
- Maritsch, M., Bérubé, C., Kraus, M., Lehmann, V., Zünger, T., Feuerriegel, S., Kowatsch, T. and Wortmann, F. (2019). Improving heart rate variability measurements from consumer smartwatches with machine learning, *UbiComp/ISWC 2019* pp. 934–938. <https://doi.org/10.1145/3341162.3346276>.
- Pereira, D., Hedayioglu, F., Correia, R., Silva, T., Dutra, I., Almeida, F., Mattos, S. S. and Coimbra, M. (2011). Digiscope – unobtrusive collection and annotating of auscultations in real hospital environments, *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS 2017–Janua*: 1193–1196. <https://doi.org/10.1109/IEMBS.2011.6090280>.
- Petersen, K., Vakkalanka, S. and Kuzniarz, L. (2015). Guidelines for conducting systematic mapping studies in software engineering: An update, *Information and Software Technology* p. 1–18. <https://doi.org/10.1016/j.infsof.2015.03.007>.
- Prasad, R., Yilmaz, G., Chetelat, O. and Magimai.-Doss, M. (2020). Detection of s1 and s2 locations in phonocardiogram signals using zero frequency filter, *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing – Proceedings 2020–May*: 1254–1258. <https://doi.org/10.1109/ICASSP40776.2020.9053155>.
- Rao, A., Chu, S., Batlivala, N., Zetumer, S. and Roy, S. (2018). Improved detection of lung fluid with standardized acoustic stimulation of the chest, *IEEE Journal of Translational Engineering in Health and Medicine* 6. <https://doi.org/10.1109/JTEHM.2018.2863366>.
- Raza, A., Mehmood, A., Ullah, S., Ahmad, M., Choi, G. S. and On, B.-W. (2019). Heartbeat sound signal classification using deep learning, *Sensors (Switzerland)* 19: 1–15. <https://doi.org/10.3390/s19214819>.
- Ren, Z., Cummins, N., Pandit, V., Han, J., Qian, K. and Schuller, B. (2018). Learning image-based representations for heart sound classification, *ACM International Conference Proceeding Series 2018–April*(143): 143–147. <https://doi.org/10.1145/3194658.3194671>.
- Santos, M. A. G., Munoz, R., Olivares, R., Filho, P. P. R., Ser, J. D. and de Albuquerque, V. H. C. (2020). On-line heart monitoring systems on the internet of health things environments: A survey, a reference model and an outlook, *Information Fusion* 53: 222–239. <https://doi.org/10.1016/j.inffus.2019.06.004>.
- Shuvo, S. B., Ali, S. N., Swapnil, S. I., Al-Rakhami, M. S. and Gumaie, A. (2021). Cardioxnet: A novel lightweight deep learning framework for cardiovascular disease classification using heart sound recordings, *IEEE Access* 9: 36955–36967. <https://doi.org/10.1109/ACCESS.2021.3063129>.
- Singh, K. K. and Singh, S. S. (2019). An artificial intelligence based mobile solution for early detection of valvular heart diseases, *2019 IEEE International Conference on Electronics, Computing and Communication Technologies, CONECCT 2019* pp. 1–5. <https://doi.org/10.1109/CONECCT47791.2019.9012937>.
- Sinharay, A., Ghosh, D., Deshpande, P., Alam, S., Banerjee, R. and Pal, A. (2016). Smartphone based digital stethoscope for connected health – a direct acoustic coupling technique, *Proceedings – 2016 IEEE 1st International Conference on Connected Health: Applications, Systems and Engineering Technologies, CHASE 2016* pp. 193–198. <https://doi.org/10.1109/CHASE.2016.23>.
- Soto-Murillo, M. A., Galván-Tejada, J. I., Galván-Tejada, C. E., Celaya-Padilla, J. M., Luna-García, H., Magallanes-Quintanar, R., Gutiérrez-García, T. A. and Gamboa-Rosales, H. (2021). Automatic evaluation of heart condition according to the sounds emitted and implementing six classification methods, *Healthcare (Switzerland)* 9: 1–15. <https://doi.org/10.3390/healthcare9030317>.
- Suhn, T., Sreenivas, A., Mahmoodian, N., Maldonado, I., and Alfredo Illanes, A. B., Bloxton, M. and Friebe, M. (2019). Design of an auscultation system for phonocardiography and monitoring of carotid artery diseases, *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS* pp. 1776–1779. <https://doi.org/10.1109/EMBC.2019.8857169>.
- Suseno, J. E. and Burhanudin, M. (2018). The signal processing of heart sound from digital stethoscope for identification of heart condition using wavelet transform and neural network, *Proceedings – 2017 1st International Conference on Informatics and Computational Sciences, ICI CoS 2017 2018–Janua*: 153–157. <https://doi.org/10.1109/ICICoS.2017.8276354>.
- Swarup, S. and Makaryus, A. N. (2018). Digital stethoscope: technology update, *Medical Devices: Evidence and Research* 11: 29–36. <https://doi.org/10.2147/MDER.S135882>.
- Szot, S., Levin, A., Ragazzi, A. and T, N. (2019). A wireless digital stethoscope design, *International Conference on Signal Processing Proceedings, ICSP 2018–August*: 74–78. <https://doi.org/10.1109/ICSP.2018.8652475>.
- Thiyagaraja, S. R., Dantu, R., Shrestha, P. L., Chitnis, A., Thompson, M. A., Anumandla, P. T., Sarma, T. and Dantu, S. (2018). A novel heart-mobile interface for detection and classification of heart sounds, *Biomedical Signal Processing and Control* 45: 313–324. <https://doi.org/10.1016/j.bspc.2018.05.008>.

- Tiwari, S., Sharma, A. J. A. K. and Almustafa, K. M. (2021). Phonocardiogram signal based multi-class cardiac diagnostic decision support system, *IEEE Access* **PP**: 1–1. <https://doi.org/10.1109/access.2021.3103316>.
- Tuncer, T., Dogan, S., Tan, R. S. and Acharya, U. R. (2021). Application of petersen graph pattern technique for automated detection of heart valve diseases with pcg signals, *Information Sciences* **565**: 91–104. <https://doi.org/10.1016/j.ins.2021.01.088>.
- Udawatta, L., Abeykoon, A. H. S., Prasanga, D. K., Prasad, S., Perera, W. and Perera, K. (2010). Knowledge on heart patients through stethoscopic cardiac murmur identification for e-healthcare, *Proceedings - 2010 8th International Conference on ICT and Knowledge Engineering, ICT and KE 2010* pp. 58–63. <https://doi.org/10.1109/ICTKE.2010.5692915>.
- Ukil, A., Jara, A. J. and Marin, L. (2019). Data-driven automated cardiac health management with robust edge analytics and de-risking, *Sensors* pp. 1–18. <https://doi.org/10.3390/s19122733>.
- Usman, O. L., Muniyandi, R. C., Omar, K. and Mohamad, M. (2021). Advance machine learning methods for dyslexia biomarker detection: A review of implementation details and challenges, *IEEE Access* **9**: 36879–36897. <https://doi.org/10.1109/ACCESS.2021.3062709>.
- Wang, J. K., Chang, Y. F., Tsai, K. H., Wang, W. C., Tsai, C. Y., Cheng, C. H. and Tsao, Y. (2020). Automatic recognition of murmurs of ventricular septal defect using convolutional recurrent neural networks with temporal attentive pooling, *Scientific Reports* **10**: 1–10. <https://doi.org/10.1038/s41598-020-77994-z>.
- Waqar, M., Inam, S., ur Rehman, M. A., Ishaq, M., Afzal, M., Tariq, N., Amin, F. and ul Ain, Q. (2019). Arduino based cost-effective design and development of a digital stethoscope, *15th International Conference on Emerging Technologies, ICET 2019*. <https://doi.org/10.1109/ICET48972.2019.8994674>.
- Yadav, A., Singh, A., Dutta, M. K. and Travieso, C. M. (2020). Machine learning-based classification of cardiac diseases from pcg recorded heart sounds, *Information Sciences* **32**: 17843–17856. <https://doi.org/10.1007/s00521-019-04547-5>.
- Zeng, W., Yuan, J., Yuan, C., Wang, Q., Liu, F. and Wang, Y. (2021). A new approach for the detection of abnormal heart sound signals using tqwt, vmd and neural networks, *Artificial Intelligence Review* **54**: 1613–1647. <https://doi.org/10.1007/s10462-020-09875-w>.
- Zhang, T. T., Ser, W., Daniel, G. Y. T., Zhang, J., Yu, J., Chua, C. and Louis, I. M. (2010). Sound based heart rate monitoring for wearable systems, *2010 International Conference on Body Sensor Networks, BSN 2010* **32**: 139–143. <https://doi.org/10.1109/BSN.2010.25>.