

**Detection of diseases based on Electrocardiography and
Electroencephalography signals embedded in different devices: An
exploratory study**

**Detecção de doenças baseadas em sinais de eletrocardiografia e
eletroencefalografia incorporados em diferentes dispositivos: um estudo
exploratório**

DOI:10.34117/bjdv6n5-247

Recebimento dos originais: 25/04/2020

Aceitação para publicação: 13/05/2020

Vasco Ponciano

Licenciado em Engenharia Informática pelo Instituto Politécnico de Castelo Branco, Castelo Branco, Portugal

Instituição: R&D Unit in Digital Services, Applications and Content, Polytechnic Institute of Castelo Branco, Castelo Branco, Portugal - Altranportugal, Lisbon, Portugal

Endereço: Av. Pedro Álvares Cabral, nº 12 6000-084 Castelo Branco, Portugal

E-mail: vasco.ponciano@ipcbrcampus.pt

Ivan Miguel Pires

Doutorado em Engenharia Informática pela Universidade da Beira Interior, Covilhã, Portugal

Instituição: Instituto de Telecomunicações, Universidade da Beira Interior, Covilhã, Portugal
- Department of Computer Science, Polytechnic Institute of Viseu, Viseu, Portugal

Endereço: Rua Marquês d'Ávila e Bolama, 6200-001 Covilhã, Portugal

E-mail: impires@it.ubi.pt

Fernando Reinaldo Ribeiro

Doutorado em Tecnologias da Informação e Comunicação pela Universidade do Minho, Portugal

Instituição: - R&D Unit in Digital Services, Applications and Content, Polytechnic Institute of Castelo Branco, Castelo Branco, Portugal

Endereço: Av. Pedro Álvares Cabral, nº 12 6000-084 Castelo Branco, Portugal

E-mail: fribeiro@ipcb.pt

María Vanessa Villasana

Estudante do curso de Mestrado Integrado em Medicina da Universidade da Beira Interior, Covilhã, Portugal

Instituição: Faculdade de Ciências da Saúde, Universidade da Beira Interior, Covilhã, Portugal

Endereço: Rua Marquês d'Ávila e Bolama, 6200-001 Covilhã, Portugal

E-mail: maria.vanessa.villasana.abreu@ubi.pt

Nuno M. Garcia

Doutorado em Engenharia Informática pela Universidade da Beira Interior, Covilhã, Portugal

Instituição: Instituto de Telecomunicações, Universidade da Beira Interior, Covilhã, Portugal

Endereço: Rua Marquês d'Ávila e Bolama, 6200-001 Covilhã, Portugal

E-mail: ngarcia@di.ubi.pt

Valderi Leithardt

Doutorado em Ciência da Computação, Universidade Federal do Rio Grande do Sul, Porto Alegre – RS, Brasil.

Instituição: Laboratório de Sistemas Embarcados e Distribuídos (LEDS), Programa de Mestrado em Computação Aplicada (MCA), Universidade do Vale do Itajaí – Univali, Itajaí, Santa Catarina, Brasil.

- Departamento de Informática, Universidade da Beira Interior, Covilhã, Portugal.

- COPELABS, Universidade Lusófona de Humanidades e Tecnologias, Lisboa, Portugal.

Endereço: Rua Uruguai, 458 - Centro, Itajaí-SC, Brasil - CEP: 88302-901

E-mail: valderi@univali.br

ABSTRACT

Nowadays, cardiac and brain disorders are dispersed over the world, where an early detection allows the treatment and prevention of other related healthcare problems. Technologically, this detection is difficult to perform, and the use of technology and artificial intelligence techniques may automate the accurate detection of different diseases. This paper presents the research on the different techniques and parameters for the detection of diseases related to Electrocardiography (ECG) and Electroencephalography (EEG) signals. Previously experiments related to the performance of the Timed-Up and Go test with elderly people acquired different signals from people with different diseases. This study identifies different parameters and methods that may be used for the identification of different diseases based on the acquired data.

Keywords: Elderly people; Diseases; Electrocardiography; Electroencephalography; Artificial intelligence.

RESUMO

Atualmente, os distúrbios cardíacos e cerebrais estão dispersos pelo mundo, onde uma detecção precoce permite o tratamento e a prevenção de outros problemas de saúde relacionados. Tecnicamente, essa detecção é difícil de executar, e o uso de tecnologia e técnicas de inteligência artificial pode automatizar a detecção precisa de diferentes doenças. Este artigo apresenta a pesquisa sobre as diferentes técnicas e parâmetros para a detecção de doenças relacionadas aos sinais de eletrocardiografia (ECG) e eletroencefalografia (EEG). Experiências anteriores relacionadas à realização do teste Timed-Up and Go com idosos adquiriam sinais diferentes de pessoas com diferentes doenças. Este estudo identifica diferentes parâmetros e métodos que podem ser utilizados para a identificação de diferentes doenças com base nos dados adquiridos.

Palavras-chave: Idosos; Doenças; Eletrocardiografia; Eletroencefalografia; Inteligência artificial.

1 INTRODUÇÃO

Os sensores de Eletroencefalografia (EEG) e de Eletrocardiografia (ECG) estão geralmente associados a equipamentos dispendiosos, utilizados por profissionais de saúde em centros hospitalares, para ajudar na identificação de vários tipos de doenças tais como: arritmias, doença de Parkinson, epilepsia, e doença de Alzheimer [1], [2].

No entanto, atualmente, estes sensores também já estão disponíveis em equipamentos de baixo custo, como é o caso o Bitalino [3] e, embora com menor fiabilidade, permitem fazer as aquisições destes sinais. Estes equipamentos possibilitam que centros de investigação, com menores recursos, possam realizar trabalhos nesta área, podendo assim contribuir para o desenvolvimento de soluções que permitam ajudar na detecção e identificação de determinadas doenças. A conjugação destes equipamentos com os dispositivos móveis, atualmente embebidos de diversos sensores [4], com grandes capacidades de comunicação e processamento, aliados à facilidade do desenvolvimento de aplicações móveis, originam novas oportunidades para o desenvolvimento de soluções inovadoras envolvendo estes sensores. Os dispositivos móveis, quando associados a estes sensores, permitem-nos fazer a aquisição dos dados via Bluetooth em qualquer lugar, a qualquer momento e com pacientes de diferentes condições.

A principal motivação deste estudo é demonstrar que é possível identificar doenças com os dados recolhidos através de sensores de ECG e EEG ligados a uma placa Bitalino e enviados para um smartphone, permitindo a validação dos dados obtidos, a identificação das doenças previamente referenciadas e estabelecendo padrões para as doenças detectadas.

Previamente foram adquiridos vários dados, durante a realização do teste *Timed-Up and Go* em idosos, usando os sensores de ECG e de EEG e os sensores acelerômetro e magnetômetro disponíveis no smartphone [5], [6]. Os problemas de saúde, de cada idoso que realizou o teste, foram identificados pelos profissionais de saúde foram posteriormente relacionados com os dados adquiridos. Este artigo apresenta também uma investigação de quais são as doenças passíveis de serem identificadas com os sensores de ECG e EEG, de modo a avaliar a capacidade da solução desenhada em relação à possibilidade de ajudar a identificar doenças relacionadas com estes sensores, além das já previamente identificadas com acelerômetro e magnetômetro. Este artigo científico mostra que é possível detectar algumas doenças com os sensores de ECG e EEG, de baixo custo, associados a dispositivos móveis, sendo que arritmia e contração ventricular prematura são as mais detectadas com

ECG, epilepsia e doença de Alzheimer são as mais detectadas com ECG. A maior parte destas doenças encontram-se presentes na amostra em análise.

As restantes secções deste artigo científico estão distribuídas da seguinte forma: A secção 2 apresenta o enquadramento do estudo. A secção 3 contém uma descrição de alguns métodos de detecção automática de doenças com ECG e EEG. A secção 4 apresenta uma discussão sobre a metodologia utilizada para detecção automática e a sua comparação com outros trabalhos analisados. Concluindo-se com a secção 5, onde se apresentam as conclusões do estudo.

2 ENQUADRAMENTO

A fácil identificação automática de doenças do foro cardíaco e neurológico é importante por ser um grupo de doenças cada vez mais presente. Estas doenças têm uma predominância mais significativa na população idosa [7], [8], sendo uma das causas de morte mais comuns [9]. É, por isso, importante promover a existência de mecanismos menos dispendiosos e de fácil utilização no dia-a-dia que permitam uma identificação mais precoce destas doenças. Neste contexto, a utilização de dispositivos de baixo custo, para conseguir ter uma grande dispersão e facilidade de implementação no estudo nos idosos em grande número, é essencial.

Nesta secção descreve-se um estudo realizado durante a execução do teste *Timed-Up and Go* em que durante a execução do teste os participantes foram monitorizados usando sensores de um dispositivo móvel (acelerômetro e magnetômetro de um smartphone) e sensores de pressão, eletrocardiografia (ECG) e eletroencefalografia (EEG) ligados em uma placa Bitalino.

A. Características da população estudada

A população estudada está presente em algumas instituições sociais, tais como Centro Comunitário das Lameiras, Lar Aldeia de Joanes, Lar das Minas, Lar da Misericórdia, e Lar Nossa Senhora de Fátima, situados nos concelhos do Fundão e da Covilhã, Portugal [5], [6]. Dos diferentes participantes do estudo, eles correspondem a 40 voluntários com idades compreendidas entre os 60 e os 90 anos.

A Tabela 1 apresenta as doenças encontradas separadas por número de ocorrências, sendo que a doença mais comum nos idosos institucionalizados é a hipertensão arterial,

seguida de diabetes, depressão e osteoartrite, e arritmias cardíacas, osteoporose e câncer da próstata.

Tabela 1. Doenças Identificadas Na População Estudada

Doenças	Número de Ocorrências
Hipertensão arterial.	15
Diabetes.	8
Depressão; osteoartrite.	5
Arritmia cardíaca; osteoporose; câncer da próstata.	4
Artrose; doença renal crônica; insuficiência cardíaca congestiva; escoliose.	3
Anemia; gonartrose bilateral; bronquite crônica; doença de obstrução pulmonar crônica; insuficiência cardíaca; hiperuricemia; amputação da perna direita; hérnia umbilical; síndrome de vertigem.	2
Infarto agudo do miocárdio; doença coronariana arteriosclerótica; anemia crônica; dores de cabeça crônicas; insuficiência venosa crônica dos membros inferiores; cirrose; demência de etiologia vascular; úlcera gástrica; gastroenterite; hernioplastia; hipocoagulado; hérnia inguinal; hérnias lombares; lesão nas costas osteoporótica; doença de Parkinson; estresse pós-traumático; prótese no úmero direito; fibrose pulmonar; sarcoidose; sequelas de cirurgia para lesão cerebral.	1

B. Realização do teste

Durante a fase de preparação dos participantes para a realização do teste *Timed-Up and Go*, o sensor de EEG foi colocado na região occipital do participante e o sensor de ECG é colocado na região direita do peito, na zona do coração, do participante. Estes sensores estavam ambos ligados a uma placa Bitalino que envia os dados recolhidos por Bluetooth para um smartphone. Estes equipamentos, sensores, placa Bitalino e smartphone, estavam acoplados ao participante que o transportava durante a realização do teste.

Embora os sinais capturados pelos sensores ECG e EEG sejam similares eles apresentam algumas diferenças. Uma das diferenças está relacionada com os intervalos de tensão dos dados capturados, em que os dados de ECG estão entre -1000mV e +1000mV (ver Figura 2), e os dados de EEG estão entre -20mV e +20mV (ver Figura 3). Ambos os sinais apresentam ruído após a aquisição, pelo que foi necessário aplicar o filtro Savitzky-Golay [10] para posteriormente permitir a extração das diferentes características.

O cálculo da frequência cardíaca e outras características relativas aos sinais de ECG pode ser conseguido usando o complexo QRS [11]. O número de complexos QRS, as diferenças entre intervalos R-R, os segmentos P-R e S-T ou os intervalos P-R e Q-T, são algumas das grandezas com relevância e que podem ser usadas para identificação de possíveis anomalias.

A figura 1 mostra um exemplo da posição dos picos no complexo QRS.




Figura 1. Exemplo de posicionamento dos picos no complexo QRS.

O complexo QRS é caracterizado da seguinte forma:

- As ondas P correspondem à despolarização atrial, sendo a primeira relativa à aurícula direita e a segunda relativa à aurícula esquerda;
- O complexo QRS corresponde à despolarização ventricular, sendo que é maior que a onda P;
- A onda T corresponde à repolarização ventricular que é perpendicular e arredondada;
- O segmento P-R é o intervalo que corresponde ao início da onda P e o início do complexo QRS, sendo indicativo da velocidade de fluxo entre os átrios e os ventrículos;
- O segmento S-T é o intervalo entre o fim da despolarização e o início da repolarização ventricular;
- Por fim, o intervalo Q-T inclui o conjunto da despolarização e repolarização dos ventrículos;
- Entre outros.

A figura 2 mostra o sinal recolhido através do sensor ECG de um dos participantes. Na figura superior é apresentado o sinal original adquirido, na figura do meio é apresentado o sinal após usar o filtro e eliminar a componente DC do sinal. Na figura inferior é mostrado a ECG com os picos R e S assinalados.




Figura 2. Dados de ECG tratados.

A figura 3 mostra o sinal recolhido através do sensor EEG de um dos participantes. Na figura superior é apresentado o sinal original adquirido, na figura do meio é apresentado o sinal após usar o filtro e eliminar a componente DC do sinal. Na figura inferior é mostrado a EEG com os picos R e S assinalados.

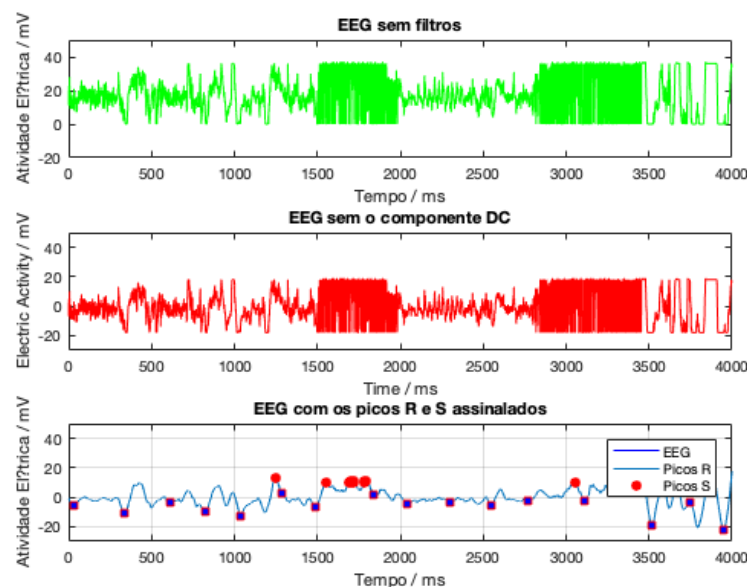


Figura 3. Dados de EEG tratados.

Com o passar dos anos e o crescimento da competição no desporto em geral, e no de alta competição em particular, a tecnologia tornou-se cada vez mais importante. Sistemas que ajudem a monitorar, organizar, analisar atletas adversários, fazer o acompanhamento de lesões, tornaram-se fundamentais para a evolução dos atletas e o sucesso em competições. Em [12] é apresentada uma revisão de alguns aspetos, ferramentas e parâmetros fundamentais de um software deste tipo, apresentadas razões para monitorar o treinamento, bem como as vantagens deste acompanhamento.

A principal razão para a adoção desta tecnologia é logo ter uma quantificação real e específica de cada atleta, com esta quantificação é possível estabelecer metas de evolução, gerir estados de forma física, e em esporte coletivos, como o futebol, escolher os atletas, que a dado momento, apresentam garantias de sucesso ao treinador [13]. Existem muitas variáveis ou parâmetros essenciais quando estamos fazendo uma análise deste tipo, ou projetamos um software adequado a este tipo de atividade. Ao nível individual devemos sempre ter em conta

aspectos como a frequência de treinamentos num determinado período de tempo, uma base de dados com tempos de cada um dos exercícios em treinamentos anteriores, assim como uma forma de os calcular, medição do nível de intensidade, o tipo de treinamento, modalidade, ambiente, o esforço máximo, o número de repetições, o volume de treinamento, uma percepção do esforço, percepção da fadiga e do tempo de recuperação, fatores ate como o sono são essenciais neste tipos de software e também para monitorar atletas deste tipo [14], [15].

Por fim, é essencial que estes aplicativos sejam projetados por uma equipe multidisciplinar que agregue não só engenheiros, como treinadores e médicos na sua construção. Fatores como a parte de compreensão do funcionamento do corpo humano, batimento cardíaco, peso são essenciais para se perceber o que podemos quantificar como estado ótimo da forma física e também porque determinados modelos para organização do treinamento, assim como modelos essenciais para um treinador organizar o treinamento não podem ser colocados como parte destes aplicativos [16]. Outra questão essencial quando nos referimos a estes aplicativos refere-se a capacidade de criação de um treinamento individual e particular para cada atleta, porque cada um tem a sua própria particularidade e nenhum é igual ao outro [17].

Cada esporte possui uma individualidade nos aspectos que para ele é importante para ajudar a aumentar o rendimento, sendo que no futebol é essencial a resistência e velocidade em pequenas distâncias para fazer a diferença [18]. No que se refere ao handebol, voleibol e basquetebol é essencial o trabalho com as mãos e a impulsão, a força de braços associada ao lançamento do peso, entre outros [19].

Nos esportes motorizados é hoje utilizada tecnologia de ponta que permite, com o uso de telemática e sensores, acompanhar os problemas mecânicos e a definição de utilização de volumes de potência nos motores, em diferentes alturas, durante as provas [20].

3 MÉTODOS PARA IDENTIFICAÇÃO AUTOMÁTICA DE DOENÇAS

A identificação automática de doenças com os dados adquiridos pelos sensores de ECG e EEG é possível tendo em conta diversos parâmetros. Baseado em vários estudos presentes na literatura, pode-se enumerar as doenças passíveis de serem identificadas, os parâmetros utilizados e os sensores utilizados.

A. Eletrocardiograma (ECG)

Os autores de [21] realizam a detecção de arritmias com a ajuda de um dispositivo móvel para a captura. Para a detecção, os autores realizam uma sequência de passos, tais como captura dos dados com os sensores, aplicação de um filtro passa-baixo, aplicação de um filtro passa-alto, o sinal é diferenciado com uma função de transferência, o sinal é elevado ao quadrado, obtenção de informações relativas à forma da onda, ao ajuste do limite dos dados e ao cálculo do batimento cardíaco [21]. A bradicardia é identificada por um ritmo cardíaco menor que 60bpm [21]. No que lhe concerne, a taquicardia é identificada se o batimento cardíaco detectado é maior que 100bpm [21]. Assim, a contração ventricular prematura é detectada por uma largura maior que 120ms do complexo QRS [21]. Quando não é considerado taquicardia ou um único batimento cardíaco prematuro, a contração atrial prematura é detectada por um ritmo cardíaco que não esteja entre 60 e 100bpm [21]. Por fim, a apneia do sono é detectada após remoção dos *outliers*, processando os dados em janelas de 40 segundos, aplicando a transformada de Hilbert e o filtro pela mediana, detectando a apneia se, pelo menos, 15 janelas consecutivas tiverem tempos diferentes [21].

Em [22], os autores desenvolveram um método que detecta várias doenças relacionadas com ECG, tais como ritmo sinusal normal, batida atrial prematura, fibrilação atrial, taquiarritmia supraventricular, pré-excitação, contração ventricular prematura, bigêmeo ventricular, trigêmeo ventricular, taquicardia ventricular, ritmo idioventricular, fusão ventricular, batida de bloco do ramo esquerdo, batida de bloco do ramo direito, entre outros. Estas doenças são detectadas com o uso de 1D-CNN (Rede neural convolucional de uma dimensão) com grupos de 13, 15 e 17 doenças [22]. As características utilizadas são 16 e são relacionadas com a normalização do lote, *pooling* máximo, achatamento, densidade, entre outras, relativas a várias janelas de deslizamento [22].

Por sua vez, os autores de [23] afirmam que o tamanho dos intervalos P-R e QRS, e a frequência cardíaca, são indicadores de risco significativo de morte cardiovascular. Por outro lado, outro estudo [24] apresentou diferentes parâmetros, tais como amplitude da onda P na II derivação, eixo médio frontal do complexo QRS, duração do complexo QRS, desvios das ondas R e S nas derivações I e V6 e as configurações da onda T nas derivações precordiais, sendo que a melhor correlação foi obtida com o valor do eixo médio frontal do complexo QRS. Estes parâmetros foram utilizados para medições relacionadas com hipertensão pulmonar primária e secundária, não referindo os respectivos métodos de detecção [24].

Assim, o estudo [25] apresenta um método de detecção de estado de fibrilação arterial com base em 3 grandes grupos de características, tais como ausência de onda P, irregularidades

na frequência cardíaca e variáveis relativas à atividade atrial, apresentando resultados com uma especificidade de 96,09%. Outro estudo [26] apresentou a extração das características no domínio do tempo e da frequência para a implementação do algoritmo *Pan Tompkins* para a detecção de arritmias no ritmo cardíaco e ritmo cardíaco normal, apresentando uma exatidão de 93,35%.

Em [27] é apresentada a detecção da doença arterial coronariana baseada na grande amplitude do intervalo QRS em conjunto com as depressões S-T e T, embora este método só seja válido em repouso, devendo ser aplicados outros métodos para as diferentes situações de realidade.

Os autores de [28] projetaram um sistema para detecção de várias doenças baseado em redes neurais artificiais. As redes neurais artificiais são suportadas pelas durações de P, S, T e QRS, intervalos P-R e Q-T, amplitudes de P, R e T, novel do segmento S-T e área do intervalo QT. O método desenvolvido permite a detecção de bloqueio do ramo esquerdo, bloqueio do ramo direito, contração ventricular prematura, síndrome de *Wolff-Parkinson-White*, isquemia miocárdica e lesão miocárdica [28].

A doença de Parkinson é detectada pelos autores de [29] com base nos intervalos R-R, P-R, QRS, e Q-T, e o batimento cardíaco corrigido com base em Q-T, tendo sido analisado com base no coeficiente de correlação de *Spearman*.

Por fim, os autores de [30] usam os valores da frequência cardíaca, amplitudes de P, T e QRS, durações de P e intervalos P-R, QRS, Q-T e Q-T corrigido, tempo de ativação ventricular e valor do eixo do plano frontal para a detecção de hipertrofias ventriculares esquerda e direita.

B. Eletroencefalograma (EEG)

Os autores de [31] usaram os cumulantes de 2.^a ordem (média \pm desvio padrão) extraído dos coeficientes da *wavelet* e aplicaram o método *Support Vector Machine* (SVM) para a detecção de sintomas de epilepsia. Igualmente para a detecção de epilepsia, em [32] são extraídas duas características estatísticas, a assimetria e a curtose, e uma característica baseada em *wavelets*, que é o coeficiente de variação normalizado, tendo sido aplicado um classificador linear. No que lhe concerne, para a detecção de epilepsia, os autores de [33] extraíram diversas categorias de entropias, tais como espectral, de *Renvi*, *Kalmogorov-Sinai* e aproximada, aplicando o sistema de inferência *neurofuzzy* adaptável. Igualmente para a detecção de

epilepsia, os autores de [34] utilizaram a variância, energia e os valores máximo e mínimo da densidade espectral de potência para a aplicação do método SVM.

Para a detecção da doença de Alzheimer, os autores de [35] usaram o método de análise discriminante linear com base na potência do sinal, potência do sinal em janela e entropia da amostra. Outros autores [36] extraíram 39 características do sinal de EEG relacionadas com os valores de *sigma*, *phi*, *omega*, potência absoluta total nas bandas de frequência e, para cada uma das sete bandas de frequência, cinco características relativas à amplitude global absoluta e relativa, duas coordenadas do centroide e um valor de sincronização de campo global, sendo aplicados vários métodos para comparação, são eles componente principal de análise linear discriminante (PC LDA), PC LDA com variáveis de seleção, análise discriminante linear mínima quadrática parcial, regressão logística de componentes principais, regressão logística quadrática com mínimos quadrados, *bagging*, *random forest*, SVM e rede neural artificial.

Para a detecção de anomalias cerebrais, os autores de [37] usaram o classificador *K-means* com várias características do domínio do tempo, nomeadamente: média, mediana, moda, desvio padrão, máximo e mínimo, e do domínio da frequência, são elas, potência da banda, dimensão fractal e energia.

Para a detecção de acidente vascular cerebral isquêmico agudo, os autores de [38] calcularam os valores das densidades do espectro de potência para os diversos canais de recolha.

Por fim, um estudo realiza a detecção de situações de depressão, mas os detalhes de implementação não são divulgados [39].

4 DISCUSSÃO

Baseado na literatura sobre o EEG, a doença mais detectada pelos diferentes autores é a Epilepsia (4 estudos), seguido de Alzheimer (2 estudos). No caso do ECG, as diferentes doenças pelos diferentes estudos são muito variadas, mas a arritmia e a contração ventricular prematura são as mais detectadas (2 estudos). Na Tabela II é mostrada a distribuição das diferentes doenças pelos diferentes estudos.

Tabela 2. Distribuição do número de doenças detectadas na literatura

Doenças	Número de estudos
<i>ECG</i>	

Várias categorias de arritmias (<i>i.e.</i> , arritmia, batida prematura atrial, fibrilação atrial, taquiarritmia supraventricular, pré-excitação, bigêneo e trigêneo ventricular, taquicardia ventricular, ritmo idioventricular, batida de bloco dos ramos esquerdo e direito, bloqueio dos ramos esquerdo e direito, e síndrome de Wolff-Parkinson-White)	4
Contração ventricular prematura	2
Fusão ventricular; hipertensão pulmonar primária e secundária; doença arterial coronariana; isquemia miocárdica; lesão miocárdica; doença de Parkinson; hipertrofias ventriculares esquerda e direita	1
<i>EEG</i>	
Epilepsia	4
Alzheimer	2
Anomalias cerebrais; acidente vascular cerebral isquêmico agudo; depressão	1

Tendo em conta os valores das doenças que caracterizam população estudada, e que foram apresentados na secção 2, na Tabela 3 é apresentada a relação entre as doenças encontradas nos diferentes estudos e as doenças que caracterizam a população estudada.

Verifica-se que a hipertensão arterial é a mais presente na população estudada (15 participantes), mas só se encontra estudada num dos estudos analisados. A depressão, presente em 5 participantes do estudo, é apenas apresentada apenas num dos estudos analisados. No que lhe concerne, a arritmia cardíaca está, presente em 7 participantes do estudo, é estudada em 4 dos trabalhos analisados. Embora com menos frequência, foram encontradas outras doenças como a doença arterial coronariana e a doença de Parkinson.

Tabela 3. Relação das doenças encontradas na população estudada com as doenças identificadas nos estudos apresentados

Doenças	Número de Ocorrências	Número de estudos
Hipertensão arterial	15	1
Depressão	5	1
Arritmia cardíaca (ou Taquicardia ventricular)	7	4
Doença arterial coronariana	1	1
Parkinson	1	1

Como podemos observar, a doença mais presente na população estudada, que é Hipertensão arterial, só consta em um dos estudos analisado, mas tal mostra que pode ser detectada com recurso aos sensores de ECG. Do mesmo modo, verifica-se que a depressão, arritmia cardíaca, e doença arterial coronariana podem ser detectadas com recurso aos sensores de ECG. No que lhe concerne, estabelecendo a relação entre as doenças detectadas na literatura com sensores de EEG e a população estudada, somente a doença de Parkinson pode ser detectada, sendo identificada em 1 estudo.

A detecção automática de doenças é um tema ainda não muito estudado, mas que pode melhorar os tratamentos em medicina com um diagnóstico prévio com sensores de baixo custo. A sua fiabilidade pode não equivalente dos equipamentos mais dispendiosos existentes nos ambientes hospitalares, mas possibilitam um primeiro diagnóstico para posterior avaliação médica.

Uma das limitações deste estudo consiste na existência de pequeno número de estudos relacionados com a identificação automática de doenças com sensores de EEG e ECG, sendo que nenhuma delas é realizada com sensores de baixo custo, sendo somente realizada com sensores de meio hospitalar. Contudo, com este estudo conseguiu-se verificar que é possível identificar, com alguma fiabilidade, padrões de doenças relacionadas com os dados recolhidos com sensores de ECG e EEG, sendo que as doenças do foro cardíaco são as mais estudadas e detectadas.

5 CONCLUSÃO

Os sensores de EEG e ECG disponíveis nos diferentes nichos de mercado podem ser usados para identificar diferentes doenças do foro neurológico e cardíaco com a aplicação de técnicas de inteligência artificial. No entanto, a utilização de sensores de baixo custo, e o recurso a equipamentos que possam ser facilmente usados no dia-a-dia, é importante para que estes testes possam ser realizados em qualquer lugar, a qualquer momento e com pacientes de diferentes condições. Mesmo alguns sensores de baixo custo, associados a dispositivos móveis, podem permitir adquirir diversos parâmetros físicos e fisiológicos que, após analisados, podem ajudar a tirar diversas conclusões relacionadas com a população estudada.

Anteriormente, tinha sido feita a recolha em diferentes instituições de dados relacionados com os sensores do dispositivo móvel, tais como acelerômetro e magnetômetro, e sensores de pressão, ECG e EEG ligados a uma placa Bitalino. Tendo em conta as diversas limitações destes dispositivos foram usadas técnicas para melhorar a qualidade da captura dos dados e torná-la mais eficiente. A existência de diversas patologias do foro neurológico e cardíaco, que caracterizam a população em estudo, condicionam a sua mobilidade, mas também permitirá obter mais relações entre os dados recolhidos e as patologias. As doenças mais comuns na população estudada são: hipertensão arterial, depressão, arritmia cardíaca, taquicardia ventricular, doença arterial coronariana e doença de Parkinson e, a análise de trabalhos relacionados permitiu verificar que algumas delas podem ser identificadas usando sensores de EEG e ECG. A utilização dos sensores de EEG e ECG permitirá tirar conclusões sobre a população em estudo, relacionando-as também com as várias medidas de execução do teste *Timed-Up and Go*.

Este estudo apresenta os métodos possíveis para identificação de doenças baseado em sinais de ECG e EEG, sendo que no futuro será continuada a investigação relacionada com o uso dos sensores disponíveis no dispositivo Bitalino para o desenvolvimento de um método automático para a detecção de doenças. Este estudo teve por objetivo conhecer os métodos mais comuns, apresentando uma análise prévia aos dados recolhidos.

A identificação automática de doenças será incluída na finalização do projeto relacionado com o teste *Timed-Up and Go*, podendo ser a ponte para outros estudos da mesma área.

AGRADECIMENTOS

This work is funded by FCT/MEC through national funds and when applicable co-funded by FEDER-PT2020 partnership agreement under the project UIDB/EEA/50008/2020. (*Este trabalho é financiado pela FCT/MEC através de fundos nacionais e cofinanciado pelo FEDER, no âmbito do Acordo de Parceria PT2020 no âmbito do projeto UIDB/EEA/50008/2020*). This article is based upon work from COST Action IC1303-AAPELE—Architectures, Algorithms and Protocols for Enhanced Living Environments and COST Action CA16226-SHELD-ON—Indoor living space improvement: Smart Habitat for the Elderly, supported by COST (European Cooperation in Science and Technology). COST is a funding agency for research and innovation networks. Our Actions help connect research initiatives across Europe and enable scientists to grow their ideas by sharing them with their peers. It boosts their research, career and innovation. More information in www.cost.eu.

REFERÊNCIAS

- [1] J. Liu, Y. Chen, Y. Zhou, Q. Wu, T. R. Qiao, and B. Sun, “Survey of wearable EEG and ECG acquisition technologies for body area network,” in *Proceedings: IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society*, Dec. 2018, pp. 5911–5915, doi: 10.1109/IECON.2018.8591077.
- [2] W. Zhang, L. Yu, L. Ye, W. Zhuang, and F. Ma, “ECG Signal Classification with Deep Learning for Heart Disease Identification,” in *International Conference on Big Data and Artificial Intelligence, BDAI 2018*, Nov. 2018, pp. 47–51, doi: 10.1109/BDAI.2018.8546681.
- [3] D. Batista, H. Silva, and A. Fred, “Experimental characterization and analysis of the BITalino platforms against a reference device,” in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, Sep. 2017, pp. 2418–2421, doi: 10.1109/EMBC.2017.8037344.
- [4] T. Choudhury *et al.*, “The mobile sensing platform: An embedded activity recognition system,” *IEEE Pervasive Computing*, vol. 7, no. 2, pp. 32–41, Apr. 2008, doi: 10.1109/MPRV.2008.39.
- [5] V. Ponciano *et al.*, “Smartphone-based automatic measurement of the results of the

Timed-Up and Go test,” in *ACM International Conference Proceeding Series*, 2019, doi: 10.1145/3342428.3343035.

[6] V. Ponciano *et al.*, “Is The Timed-Up and Go Test Feasible in Mobile Devices? A Systematic Review,” *Electronics*, vol. 9, no. 3, p. 528, Mar. 2020, doi: 10.3390/electronics9030528.

[7] L. Ceder, D. Elmqvist, and S.-E. Svensson, “Cardiovascular and neurological function in elderly patients sustaining a fracture of the neck of the femur,” *The Journal of bone and joint surgery. British volume*, vol. 63, no. 4, pp. 560–566, 1981.

[8] K. Phabphal, A. Geater, K. Limapichat, P. Sathirapanya, and S. Setthawatcharawanich, “Risk factors of recurrent seizure, co-morbidities, and mortality in new onset seizure in elderly,” *Seizure*, vol. 22, no. 7, pp. 577–580, 2013.

[9] I. Oztürk, S. Toker, E. Ertürer, B. Aksoy, and F. Seckin, “Analysis of risk factors affecting mortality in elderly patients (aged over 65 years) operated on for hip fractures,” *Acta Orthop Traumatol Turc*, vol. 42, no. 1, pp. 16–21, 2008.

[10] R. W. Schafer, “What is a savitzky-golay filter?,” *IEEE Signal Processing Magazine*, vol. 28, no. 4, pp. 111–117, 2011, doi: 10.1109/MSP.2011.941097.

[11] S. Kadambe, R. Murray, and G. Paye Boudreaux-Bartels, “Wavelet transform-based QRS complex detector,” *IEEE Transactions on Biomedical Engineering*, vol. 46, no. 7, pp. 838–848, 1999, doi: 10.1109/10.771194.

[12] S. L. Halson, “Monitoring Training Load to Understand Fatigue in Athletes,” *Sports Medicine*, vol. 44, no. 2. Springer International Publishing, pp. 139–147, Nov. 01, 2014, doi: 10.1007/s40279-014-0253-z.

[13] S. Dixon, M. Batt, and A. Collop, “Artificial Playing Surfaces Research: A Review of Medical, Engineering and Biomechanical Aspects,” *International Journal of Sports Medicine*, vol. 20, no. 04, pp. 209–218, May 1999, doi: 10.1055/s-2007-971119.

[14] J. L. Mayhew, C. D. Kerksick, D. Lentz, J. S. Ware, and D. L. Mayhew, “Using repetitions to fatigue to predict one-repetition maximum bench press in male high school athletes,” *Pediatric Exercise Science*, vol. 16, no. 3, pp. 265–276, Aug. 2004, doi: 10.1123/pes.16.3.265.

[15] J. P. Ahtiainen and K. Häkkinen, “Strength Athletes Are Capable to Produce Greater Muscle Activation and Neural Fatigue During High-Intensity Resistance Exercise Than Nonathletes,” *Journal of Strength and Conditioning Research*, vol. 23, no. 4, pp. 1129–1134, Jul. 2009, doi: 10.1519/JSC.0b013e3181aa1b72.

- [16] A. E. Aubert, B. Seps, and F. Beckers, "Heart Rate Variability in Athletes," *Sports Medicine*, vol. 33, no. 12. Springer, pp. 889–919, Sep. 04, 2003, doi: 10.2165/00007256-200333120-00003.
- [17] J. B. Morin and P. Samozino, "Interpreting power-force-velocity profiles for individualized and specific training," *International Journal of Sports Physiology and Performance*, vol. 11, no. 2. Human Kinetics Publishers Inc., pp. 267–272, Mar. 01, 2016, doi: 10.1123/ijsp.2015-0638.
- [18] F. Pareja-Blanco *et al.*, "Effects of velocity loss during resistance training on athletic performance, strength gains and muscle adaptations," *Scandinavian Journal of Medicine & Science in Sports*, vol. 27, no. 7, pp. 724–735, Jul. 2017, doi: 10.1111/sms.12678.
- [19] F. L. de Koning, R. A. Binkhorst, J. A. Vos, and M. A. van 't Hof, "The force-velocity relationship of arm flexion in untrained males and females and arm-trained athletes," *European Journal of Applied Physiology and Occupational Physiology*, vol. 54, no. 1, pp. 89–94, May 1985, doi: 10.1007/BF00426305.
- [20] A. W. S. Watson, "Sports injuries: incidence, causes, prevention," *Physical Therapy Reviews*, vol. 2, no. 3, pp. 135–151, Sep. 1997, doi: 10.1179/ptr.1997.2.3.135.
- [21] A. N. Patel, Abhilasha M.; Gakare, Pankaj K.; Cheeran, "Real Time ECG Feature Extraction and Arrhythmia Detection on a Mobile Platform," *International Journal of Computer Applications*, vol. 44, no. 23, pp. 40–45, 2012, doi: 10.5120-6432-8840.
- [22] Ö. Yıldırım, P. Pławiak, R. S. Tan, and U. R. Acharya, "Arrhythmia detection using deep convolutional neural network with long duration ECG signals," *Computers in Biology and Medicine*, vol. 102, pp. 411–420, 2018, doi: 10.1016/j.combiomed.2018.09.009.
- [23] R. Deo *et al.*, "Electrocardiographic measures and prediction of cardiovascular and noncardiovascular death in CKD," *Journal of the American Society of Nephrology*, vol. 27, no. 2, pp. 559–569, 2016, doi: 10.1681/ASN.2014101045.
- [24] G. S. Ahearn, V. F. Tapon, A. Rebeiz, and J. C. Greenfield, "Electrocardiography to define clinical status in primary pulmonary hypertension and pulmonary arterial hypertension secondary to collagen vascular disease," *Chest*, vol. 122, no. 2, pp. 524–527, 2002, doi: 10.1378/chest.122.2.524.
- [25] R. Couceiro, P. Carvalho, J. Henriques, M. Antunes, M. Harris, and J. Habetha, "Detection of Atrial Fibrillation using model-based ECG analysis," *Proceedings - International Conference on Pattern Recognition*, pp. 1–5, 2008, doi: 10.1109/icpr.2008.4761755.

- [26] B. Subramanian, "ECG signal classification and parameter estimation using multiwavelet transform," *Biomedical Research (India)*, vol. 28, no. 7, pp. 3187–3193, 2017.
- [27] H. LINDERHOLM, G. OSTERMAN, and D. TEIEN, "Detection of Coronary Artery Disease by Means of Exercise ECG in Patients with Aortic Stenosis," *Acta Medica Scandinavica*, vol. 218, no. 2, pp. 181–188, 1985, doi: 10.1111/j.0954-6820.1985.tb08845.x.
- [28] M. Y. Yang, W. C. Hu, and L. Y. Shyu, "ECG events detection and classification using wavelet and neural networks," *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings*, vol. 1, no. C, pp. 280–281, 1997.
- [29] H. Mochizuki, N. Ishii, K. Shiomi, and M. Nakazato, "Clinical features and electrocardiogram parameters in Parkinson's disease," *Neurology International*, vol. 9, no. 4, pp. 82–83, Dec. 2017, doi: 10.4081/ni.2017.7356.
- [30] S. C. Saxena, V. Kumar, and S. T. Hamde, "Feature extraction from ECG signals using wavelet transforms for disease diagnostics," *International Journal of Systems Science*, vol. 33, no. 13, pp. 1073–1085, 2002, doi: 10.1080/00207720210167159.
- [31] U. R. Acharya, S. V. Sree, and J. S. Suri, "Automatic detection of epileptic eeg signals using higher order cumulant features," *International Journal of Neural Systems*, vol. 21, no. 5, pp. 403–414, 2011, doi: 10.1142/S0129065711002912.
- [32] Y. U. Khan, "Automatic Detection of Seizure ONSET in Pediatric EEG," *International Journal of Embedded Systems and Applications*, vol. 2, no. 3, pp. 81–89, 2012, doi: 10.5121/ijesa.2012.2309.
- [33] N. Kannathal, M. L. Choo, U. R. Acharya, and P. K. Sadasivan, "Entropies for detection of epilepsy in EEG," *Computer Methods and Programs in Biomedicine*, vol. 80, no. 3, pp. 187–194, 2005, doi: 10.1016/j.cmpb.2005.06.012.
- [34] R. Shantha Selva Kumari and J. Prabin Jose, "Seizure detection in EEG using time frequency analysis and SVM," *2011 International Conference on Emerging Trends in Electrical and Computer Technology, ICETECT 2011*, pp. 626–630, 2011, doi: 10.1109/ICETECT.2011.5760193.
- [35] W. L. Woon, A. Cichocki, F. Vialatte, and T. Musha, "Techniques for early detection of Alzheimer's disease using spontaneous EEG recordings," *Physiological Measurement*, vol. 28, no. 4, pp. 335–347, 2007, doi: 10.1088/0967-3334/28/4/001.
- [36] C. Lehmann *et al.*, "Application and comparison of classification algorithms for recognition of Alzheimer's disease in electrical brain activity (EEG)," *Journal of Neuroscience Methods*, vol. 161, no. 2, pp. 342–350, 2007, doi:

10.1016/j.jneumeth.2006.10.023.

[37] M. Kalaivani, V. Kalaivani, and V. A. Devi, “Analysis of EEG Signal for the Detection of Brain Abnormalities,” *International Journal of Computer Applications (ijca)*, vol. 1, no. 2, pp. 1–6, 2014.

[38] S. K. Wijaya, C. Badri, J. Misbach, T. P. Soemardi, and V. Sutanno, “Electroencephalography (EEG) for detecting acute ischemic stroke,” in *Proceedings - 2015 4th International Conference on Instrumentation, Communications, Information Technology and Biomedical Engineering, ICICI-BME 2015*, 2016, doi: 10.1109/ICICI-BME.2015.7401312.

[39] A. C. Merzagora, S. Bunce, M. Izzetoglu, and B. Onaral, “Wavelet analysis for EEG feature extraction in deception detection,” *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings*, pp. 2434–2437, 2006, doi: 10.1109/IEMBS.2006.260247.