

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA SUPERIOR DE EDUCAÇÃO FÍSICA, FISIOTERAPIA E DANÇA
CURSO DE FISIOTERAPIA

Lucas de Liz Alves

**COMPARAÇÃO ENTRE DOIS MÉTODOS DE AVALIAÇÃO DE MARCHA EM ÁGUA
RASA: ANÁLISE CINEMÁTICA CONVENCIONAL E REDE NEURAL DE
APRENDIZAGEM PROFUNDA**

Porto Alegre - RS
2022

Lucas de Liz Alves

Comparação entre dois métodos de avaliação de marcha em água rasa: análise cinemática convencional e rede neural de aprendizagem profunda

Trabalho de Conclusão de Curso apresentado como requisito parcial à obtenção do título de Bacharel em Fisioterapia da Escola de Educação Física da Universidade Federal do Rio Grande do Sul.

Orientadora: Profa. Dra. Flávia Gomes Martinez.

Porto Alegre - RS
2022

Lucas de Liz Alves

Comparação entre dois métodos de avaliação de marcha em água rasa: análise cinemática convencional e rede neural de aprendizagem profunda

Conceito Final:

Aprovado em: ____ de _____ de 2022.

BANCA EXAMINADORA:

Profa Dra. Clarice Sperotto dos Santos Rocha

Prof. Dr. Leonardo Alexandre Peyre Tartaruga

Profa. Dra. Flávia Gomes Martinez.

Agradecimentos

O conhecimento e a ciência não se constroem sozinhos, por isso agradeço aos que estiveram ao meu lado ao longo dessa jornada. À minha família, que sempre se empenhou e se dedicou para que eu pudesse estudar longe de casa e do conforto de morar com a família, mas sempre com muito amor e confiança no processo; sem eles nada poderia ter sido feito. Juntamente a ela, minha companheira Claudia, que sempre me apoiou e me incentivou a ser centrado e buscar o conhecimento como maior ferramenta de mudança das nossas vidas.

Agradeço a minha orientadora a Profa. Flávia Gomes Martínez que me acolheu em um momento em que me sentia perdido e sem muita direção no curso, me apresentou o mundo da água como terapia e me deu a abertura e liberdade para que eu pudesse sempre aprender e pesquisar, fomentando o espírito curioso que existe em todos nós, e que no meu caso me introduziu ao mundo da pesquisa.

Por fim, agradeço ao doutorando André Ivaniski Melo do grupo Locomotion e GPCOMFA, que sempre me apoiou e auxiliou durante a realização de todos os processos de produção desse trabalho, desde a descoberta do assunto, ao processo de digitalização e a ajuda com os mais diversos erros que alunos da fisioterapia poderiam encontrar na programação.

RESUMO

A análise cinemática de caminhada em água rasa (CAR) tem sido utilizada há mais de duas décadas. Todavia, diversas dificuldades são enfrentadas, como o uso de marcadores reflexivos em ambiente aquático, o dispêndio de tempo para a digitalização, entre outros. A inteligência artificial pode ser uma alternativa confiável para digitalizar movimentos subaquáticos. Nosso objetivo foi comparar as respostas espaço-temporais e angulares durante a caminhada humana em água rasa, calculada por dois métodos de digitalização: digitalização manual convencional com *Skillspector* (DMC) e digitalização sem marcadores com inteligência artificial, usando o *DeepLabCut* (DLC). Treze homens adultos saudáveis realizaram caminhadas em água rasa a 0,4 m/s no nível de imersão do xifoide. Para análise 2D, uma câmera GoPro™ (60Hz) registrou o plano sagital de caminhada. Para o DMC, foi utilizado o software Skillspector™. Para o DLC, uma rede neural profunda foi treinada, usando o método de código aberto *DeepLabCut* com 500 imagens durante 300 mil interações. Em seguida, essa rede treinada foi utilizada para digitalizar os vídeos de caminhada. Um teste de *Bland Altman* e um teste T de student dependente foram usados para comparar os dois métodos. Não foram encontradas diferenças significativas entre os métodos para todas as variáveis espaço-temporais estudadas: média de velocidade ($p = 0,90$), frequência de passada ($p = 0,73$) e comprimento da passada ($p = 0,21$), bem como para a amplitude de movimento do tornozelo ($p = 0,55$) e quadril ($p = 0,04$). Já a amplitude de movimento do joelho e do tronco foi maior no método DLC ($p < 0,001$). O tempo médio de digitalização por passada foi muito maior no DMC (20 horas no total) do que no DLC (14 minutos no total). O presente estudo mostra resultados promissores para o uso da inteligência artificial no movimento humano subaquático, reduzindo expressivamente o tempo de digitalização, apresentando repetibilidade na maior parte das variáveis estudadas. Mais pesquisas são necessárias para corrigir diferenças nas avaliações angulares, sobretudo da articulação do joelho e tronco durante a marcha humana.

Palavras chave: locomoção, cinemática, movimento subaquático, rede neural profunda.

SUMÁRIO

1. CAPA.....	1
2. CONTRACAPA.....	2
3. FOLHA DE CONCEITO	3
4. AGRADECIMENTOS.....	4
5. RESUMO.....	5
6. SUMÁRIO.....	6
7. APRESENTAÇÃO DO ARTIGO	7
8. ARTIGO COMPLETO.....	8
7.1. Introdução	9
7.2. Materiais e Métodos.....	11
7.3. Resultados	13
7.4. Discussão.....	16
7.5. Referências.....	19
9. ANEXO (normas da revista)	21

APRESENTAÇÃO DO ARTIGO:

O artigo destinado para a conclusão de curso se trata de um estudo *post facto* comparativo, onde foram comparadas duas formas de digitalização para a análise de variáveis espaço temporais e angulares da caminhada em água com imersão ao nível de xifoide. O artigo surgiu como a partir da leitura do artigo de Cronin et al., (2018), em que os pesquisadores avaliavam o número de interações necessárias para uma rede neural de aprendizagem profunda reconhecer de maneira autônoma pontos de interesse para a avaliação da caminhada em água funda. O tema do trabalho surgiu então como uma possibilidade de testar a comparação dessa forma de análise com a que se rotineiramente utilizávamos no nosso grupo de pesquisa para o mesmo tipo de análise, o *Skillspector*. O programa conta com uma digitalização mais demorada, pois é necessário marcar os pontos *frame a frame*, despendendo muitas horas por parte dos pesquisadores para digitalização dos vídeos, realizada manualmente. Assim, o *DeepLabCut* surge como uma possibilidade de acelerar o processo, valendo-se de redes neurais de aprendizagem profunda para desonerar o trabalho humano de digitalização lenta desses tipos de avaliação. Em razão da pandemia de Covid 19, decidimos utilizar um banco de dados previamente coletado pelo doutorando do grupo de pesquisa Locomotion e Gpcomfa, André Ivaniski Mello. A partir desse banco de dados, que tinha a caminhada em água rasa em diferentes profundidades e diferentes velocidades de sujeitos jovens e saudáveis, realizamos alguns estudos-piloto com as digitalizações, e, em acordo com a orientadora Flávia Martinez, decidimos realizar com a velocidade controlada de 0,4 m/s e a profundidade do processo xifoide, que nos daria uma velocidade controlada, facilitando a comparação em uma profundidade que nos desse dados angulares de maior quantidade de segmentos.

O trabalho de conclusão de curso está formatado de acordo com um *template* disponibilizado pela revista escolhida, em inglês, seguindo assim as normas completas para a submissão do mesmo, conforme consta no ANEXO.

O trabalho de conclusão de curso será submetido a revista científica *Sensors*, uma revista de acesso aberto sobre a ciência e tecnologia de sensores, sendo muito prestigiada na área da biomecânica e estudo da locomoção. Com *impact factor* de 3,576 e ISSN: 1424-8220.

Artigo

Comparação entre dois métodos de avaliação de marcha em água rasa: análise cinemática convencional e rede neural de aprendizagem profunda

Lucas de Liz Alves, André Ivaniski-Mello e Flavia Gomes Martinez

Laboratório de Pesquisa do Exercício, Escola de Educação Física, Fisioterapia e Dança,
Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil
Correspondência: fla.gmartinez@gmail.com; Tel.: (+55 51 98146 8536; Flavia Martinez)

Resumo: A análise cinemática de caminhada em água rasa (CAR) tem sido utilizada há mais de duas décadas. Todavia, diversas dificuldades são enfrentadas, como o uso de marcadores reflexivos em ambiente aquático, o dispêndio de tempo para a digitalização, entre outros. A inteligência artificial pode ser uma alternativa confiável para digitalizar movimentos subaquáticos. Nosso objetivo foi comparar as respostas espaço-temporais e angulares durante a caminhada humana em água rasa, calculada por dois métodos de digitalização: digitalização manual convencional com SkillSpector (DMC) e digitalização sem marcadores com inteligência artificial, usando o DeepLabCut (DLC). Treze homens adultos saudáveis realizaram caminhadas em água rasa a 0,4 m/s no nível de imersão do xifoide. Para análise 2D, uma câmera GoPro™ (60Hz) registrou o plano sagital de caminhada. Para o DMC, foi utilizado o software SkillSpector™. Para o DLC, uma rede neural profunda foi treinada, usando o método de código aberto DeepLabCut com 500 imagens durante 300 mil interações. Em seguida, essa rede treinada foi utilizada para digitalizar os vídeos de caminhada. Um teste de Bland Altman e um teste T de student dependente foram usados para comparar os dois métodos. Não foram encontradas diferenças significativas entre os métodos para todas as variáveis espaço-temporais estudadas: média de velocidade ($p = 0,90$), frequência de passada ($p = 0,73$) e comprimento da passada ($p = 0,21$), bem como para a amplitude de movimento do tornozelo ($p = 0,55$) e quadril ($p = 0,04$). Já a amplitude de movimento do joelho e do tronco foi maior no método DLC ($p < 0,001$). O tempo médio de digitalização por passada foi muito maior no DMC (20 horas no total) do que no DLC (14 minutos no total). O presente estudo mostra resultados promissores para o uso da inteligência artificial no movimento humano subaquático, reduzindo expressivamente o tempo de digitalização, apresentando repetibilidade na maior parte das variáveis estudadas. Mais pesquisas são necessárias para corrigir diferenças nas avaliações angulares, sobretudo da articulação do joelho e tronco durante a marcha humana.

Citation: Lastname, F.; Lastname, F.;
Lastname, F. Title. *Sensors* **2022**, *22*, x.
<https://doi.org/10.3390/xxxxx>

Academic Editor: FirstnameLastname

Received: date

Accepted: date

Published: date

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2022 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Palavras-chave: locomoção, cinemática, movimento subaquático, redes neurais de aprendizagem profunda.

1. Introdução

O uso da água como forma terapêutica, remonta ao início de 1500 a.C., no oriente. A cultura greco-romana utilizava esta forma de terapia através de banhos de imersão em diferentes temperaturas [1]. Dentro de suas possibilidades terapêuticas, temos melhorias significativas para patologias cardiopulmonares e cardiovasculares, artrites, lesões causadas por traumas, entre outras [2]. Os diversos benefícios dos exercícios aquáticos podem ser descritos resumidamente pela redução do risco de quedas em idosos [3], redução de dores musculoesqueléticas relacionadas à postura [4] e melhora da mobilidade e equilíbrio [5]. Além disso, o ambiente aquático serve como ferramenta para reabilitação e fisioterapia, para as mais diversas patologias: cardiopulmonar, cardiovascular, doenças reumáticas, neurológicas, fibromialgia, obesidade e manejo de dores crônicas ou agudas, entre outras afecções [2]. A água tem sido utilizada para a prática de outras modalidades de exercícios além da natação e fisioterapia aquática, como corrida em águas profundas e caminhada em águas rasas (CAR) [6]. A CAR é apreciada para o treinamento complementar e ganho de condicionamento físico, sem a necessidade de flutuadores, sendo mais acessível para quem tem medo de águas com maiores profundidades [7]. Além disso, serve para treino de marcha para pacientes que não suportam o próprio peso, considerando a força de empuxo no auxílio da redução do peso hidrostático, o que permite treino de marcha precoce para pacientes com déficit de força muscular (Becker e Cole).

A CAR e a corrida em água funda se destacam por estarem mais próximas da mecânica da caminhada e em ambiente seco. Quando comparada à caminhada em ambiente seco, a caminhada em água rasa apresentou similaridades quanto aos parâmetros de consumo máximo de oxigênio e frequência cardíaca máxima [7]. A caminhada em água rasa, no entanto, é pouco estudada no âmbito cinemático, quando comparada a outras modalidades de atividade em imersão no meio líquido, devido à dificuldade em coletas e análises cinemáticas soba água [6]. Sua relação com a marcha em ambiente seco parece seguir o mesmo padrão, porém com menor velocidade, menor comprimento do passo e aumento da frequência do passo, em velocidades auto selecionadas na profundidade xifoide [8].

Estudos cinemáticos ajudam a analisar e compreender os torques e ângulos de um determinado sujeito durante o movimento, entre outros aspectos [9]. Para a análise, geralmente são utilizados marcadores anatômicos de referência, por meio de aplicação de pontos reflexivos, permitindo a melhor captação de imagem dos movimentos articulares [10]. No passado, pesquisadores normalmente usavam dispositivos e aparelhos fixados em grande parte do membro, o que poderia limitar o movimento

[11]. O uso da análise sem marcadores tem sua história mais recente, por meio de sistemas e câmeras próprias (infravermelho), que geralmente formam um ambiente de câmeras ao redor da amostra ou objeto e desenvolvem um modelo computacional do que está sendo filmado. Contudo, esse tipo de método requer um ambiente bastante controlado, pois é altamente sensível a interferências externas [12]. Coletas de dados em ambiente externo aos laboratórios de biomecânica são muitas vezes necessárias, a exemplo de investigações realizadas em ambiente aquático. Além disso, a digitalização de vídeos exige longo tempo de observação e ações manuais do pesquisador, o que aumenta o risco de erros e onera muito o tempo de tratamento dos dados. Embora sensores inerciais também sejam uma promessa para minimizar as dificuldades de estudos cinemáticos [13], a utilização de filmagens ainda é segura e contemporânea. Nesse sentido, o treinamento de redes neurais de aprendizagem profunda para análise da marcha parece ser uma estratégia animadora, pois auxilia e acelera o processo de pesquisa.

A rede neural de aprendizagem profunda é um ramo da inteligência artificial, que utiliza treinamento guiado, onde o pesquisador orienta o ponto correto para a marcação da rede e o *software* realiza um grande número de interações repetidas da rede, marcando os próprios pontos e comparando com os *frames* pré definidos. Os primeiros estudos cinemáticos com esta metodologia foram utilizados em modelos animais, incluindo insetos e roedores [14]. Com esta sistemática, a rede pode aprender o padrão guiado correto e reproduzir os pontos de marcação com precisão, utilizando *software* de estimativa de posição do animal, como o DeepLabCut™ [15]. Para o meio aquático, as vantagens tornam-se maiores, dado o elevado tempo de trabalho humano que seria necessário para realizar a marcação do mesmo ponto, além do dispêndio de tempo para tratamento dos dados. Com a rede neural profunda, basta ter uma boa definição dos pontos que se deseja rastrear, para que o modelo treine, por meio de repetições com sucessos e falhas, além de refinar o algoritmo para que se torne mais preciso e acurado [14]. Cronin et al. (2019) demonstraram que 300 a 400 *frames* são necessários para treinar uma rede neural a fim de que reconheça parâmetros cinemáticos da corrida em água profunda, reduzindo o tempo de digitalização em comparação ao rastreamento manual [16].

Considerando as dificuldades da análise da CAR e o advento da digitalização sem marcadores com inteligência artificial, o presente estudo tem como objetivo comparar as variáveis espaço-temporais e angulares dos membros inferiores da CAR por digitalização convencional manual e rastreamento sem marcadores por uma rede neural, durante a marcha de jovens saudáveis em ambiente aquático.

2. Materiais e Métodos

Um total de 13 participantes se voluntariaram para o estudo e assinaram um termo de consentimento informado. O estudo foi aprovado pelo comitê de ética da Universidade Federal do Rio Grande do Sul (nº 37928/CEP/UFRGS). Os testes foram realizados de acordo com a declaração mais recente do acordo de Helsinque.

Uma câmera *GoPro Hero 5™* (60Hz) foi usada para gravar os testes, posicionada no centro do percurso de 5 metros de distância, a 4 metros de distância do referido percurso, no plano sagital de movimento. Um volume de dimensões conhecidas (2,1 x 1,6 m) foi utilizado para calibração da área de teste (calibrador). A altura total, altura do joelho, massa corporal e idade dos sujeitos foram mensurados previamente. Para as duas formas de análise, foram utilizados seis marcadores anatômicos, sendo marcados com um batom sobre a pele nas seguintes regiões: quinto metatarso, tuberosidade calcânea, maléolo lateral, epicôndilo lateral do fêmur, trocanter maior do fêmur e região lateral torácica, ao nível do apêndice xifoide.

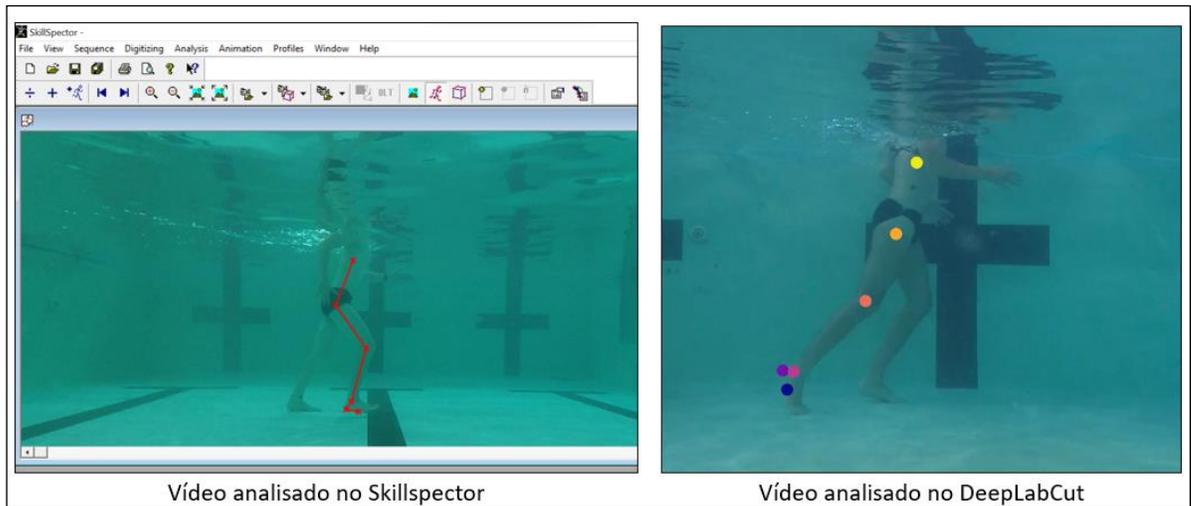
Os participantes foram orientados a caminharem em uma piscina rasa (16 metros comprimento, 6 metros largura e profundidade entre 90 cm e 150 cm de altura de água) com a água na altura do xifoide, com velocidade selecionada de 0,4 m/s durante 3 minutos. A velocidade foi controlada com um metrônomo, que informava os participantes do momento em que deveriam estar alinhados com marcadores espaciais colocados na borda da piscina (cones de referência). Foi realizado um período prévio de 5 minutos de familiarização em meio aquático, quando os participantes caminharam na velocidade auto selecionada (considerada confortável) e na velocidade arbitrária do teste. Em seguida, iniciou-se a gravação e os sujeitos caminharam livremente com o balanço do membro superior dentro da água. Posteriormente, por meio do programa *FFmpeg™*, foram selecionadas 10 passadas de cada sujeito para as análises biomecânicas. Para a digitalização convencional, foi utilizado o *software Skillspector™* (*Video4Coach*, Dinamarca). Para tanto, os pontos foram marcados manualmente quadro a quadro, sendo posteriormente marcado um quadro do calibrador. Posteriormente, o *software* gerou uma matriz com a posição espacial dos pontos através do tempo.

A digitalização sem marcadores com inteligência artificial foi realizada usando o *software DeepLabCut™* (*MathisLaboratory, Harvard, USA*). A rede neural foi desenvolvida de acordo com as instruções de Mathis et al. [13]. A rede foi treinada com 5 passos de 10 sujeitos, totalizando 50 passos. De cada passo, foram registrados 10 *frames*, totalizando 500 *frames* para treinamento da rede neural. O restante dos passos (80 passos) fora separado para o teste de comparação. Os quadros foram marcados manualmente no mesmo local

utilizados pelo método de análise convencional. O processo foi inicializado com o modelo *ResNet*, com treinamento baseado na rede *ImageNet* [17]. Para a realização do treinamento, foi necessária a utilização de um computador com GPU potente, a fim de alcançar eficiência mínima para suportar o tempo necessário para o treinamento da rede. Assim, o treinamento foi feito com 300.000 interações, utilizando um computador com GPU *Nvidia GeForce RTX™* (Dell Corporation, Texas, USA) através de código fonte em *Python* (*Python Software Foundation*; v.3.5) e banco de dados *TensorFlow* [18]. Após o processo de treinamento, 4 novos passos de 2 participantes foram utilizados para o teste de rede neural, confirmando a precisão da marcação através de um vídeo plotado pelo *software*, onde os pontos foram marcados automaticamente ao longo de toda a passada (Figura 1).

Assim, o conjunto final de dados foi composto por 130 passadas. Desse total, 50 passadas foram destinadas ao treinamento da rede neural de aprendizado profundo com *DeepLabCut* e 80 passadas foram para o teste comparativo, provenientes de 13 participantes coletados que foram analisados nas duas formas de análise. A distribuição das passadas ocorreu da seguinte forma: 10 sujeitos tiveram suas passadas divididas em 2 partes, 5 foram para treino de rede e 5 para teste, os outros 3 sujeitos tiveram os 10 passos coletados exclusivamente para o teste.

Figura 1. Figura ilustrativa dos *outputs* dos dois modos de digitalização.



Na figura à esquerda, a digitalização pelo *Skillspector*, na figura à direita pelo *DeepLabCut*.

Foram calculadas 10 variáveis: velocidade de caminhada (m/s), frequência de passo (Hz), comprimento de passo (m), duração de passo (s), amplitude de movimento (ADM) das articulações: tornozelo (°), joelho (°),

quadril (°) e tronco (°). O *duty factor* (%), que resumidamente é a duração de um ciclo de passada em que cada pé está no chão, também foi calculado.

O tempo médio de digitalização dos pontos pelo método *Skillspector* foi registrado a cada passo. O tempo total para treinamento da rede neural também foi registrado, assim como o tempo para digitalização e avaliação dos passos.

O *software Skillspector* apresenta a possibilidade de ajustar o objeto calibrador. Após marcar os pontos em todos os quadros de interesse, o calibrador é determinado, gerando um gráfico com a posição pelo tempo e exportando a posição em um arquivo .txt. O *software DeepLabCut* exporta os mesmos dados de posição em uma planilha com os mesmos dados de posição por tempo com distância em *pixels*. Para isso, treinamos uma rede neural para marcar os pontos do calibrador, por meio de uma Transformação Linear Direta [19] no programa *MatLab* (MathWorks Inc. USA) depois calculamos a posição em unidade métrica, como no *software SkillSpector*.

Os dados exportados do *Skillspector* e do *DeepLabCut* foram posteriormente processados em uma rotina do *MatLab* para cálculo das seguintes variáveis: velocidade de caminhada, frequência de passada, comprimento da passada e amplitude total de movimento dos segmentos do pé, perna, coxa e tronco, a fim de determinar as amplitudes de movimento respectivamente, tornozelo, joelho, quadril e tronco. O tempo médio de avaliação das passadas dentro dos dois métodos também foi comparado. Para verificar a normalidade dos dados obtidos, um teste de *Shapiro-Wilk* foi realizado. Um teste *Bland Altman* e o teste T de Student dependente foram feitos para comparar os resultados obtidos pelos dois métodos de digitalização no programa SPSS (v. 26, IBM, EUA). Para o teste de *Bland Altman* para concordância do método, todas as variáveis que apresentaram similaridade estatística no teste T pareado foram calculadas, caso suas diferenças nos valores obtidos pelos dois métodos de análise apresentassem valores estatisticamente diferentes de zero.

3. Resultados

Os dados antropométricos e de caracterização da amostra foram classificados dentro da distribuição normal dos dados, assim como as demais variáveis do teste que apresentaram normalidade em sua distribuição dos dados dentro da classificação da classe.

A amostra foi composta por 13 indivíduos saudáveis com estatura média de 175,2 cm ($\pm 6,04$ cm) e massa média de 72,9 kg ($\pm 5,4$ kg). O tempo total de análise manual convencional com o *software Skillspector* foi de 20

horas e 7 minutos, com tempo médio de análise de 15 ($\pm 3,5$) minutos por passo (Tabela 1). O tempo de análise total dos 80 passos pela rede neural foi de 14 minutos, um tempo médio de 10,5 segundos por passos. Essa diferença supera em 90 vezes aproximadamente a velocidade de processamento do *Skillspector* quando comparada com o *DeepLabCut*.

Tabela 1. Dados antropométricos da amostra.

	Média	Desvio Padrão
Altura total (cm)	175,27	6,04
Altura joelho (cm)	41,45	4,39
Massa (kg)	72,94	5,41

Os valores médios das variáveis espaço-temporais de velocidade de caminhada (DMC: = $0,445 \pm 0,060$ m/s; DLC: = $0,446 \pm 0,066$ m/s; $p = 0,9$), frequência de passo (DMC: = $0,409 \pm 0,041$ Hz; DLC : = $0,409 \pm 0,041$ Hz; $p = 0,73$), comprimento de passo (DMC: = $1,146 \pm 0,225$ m; DLC: = $1,137 \pm 0,220$ m; $p = 0,21$) duração da passada (DMC: = $2,552 \pm 0,629$ s ; DLC: = $2,552 \pm 0,629$ s; $p = <0,01$) e duração da fase de contato (DMC: = $1,589 \pm 0,424$ s; DLC: = $1,589 \pm 0,424$ s, $p = <0,01$) foram semelhantes de acordo com o resultado do teste T pareado (Tabela 2).

Tabela 2. Tabela com as variáveis descritivas espaço-temporais dos dois métodos avaliados.

Variavel	Método	Sujeitos	Mínimo	Maximo	Média	Desv. Padrão	<i>p</i>
Velocidade de caminhada (m/s)	DMC	80	0,247	0,643	0,445	0,060	0,9*
	DLC	80	0,324	0,653	0,446	0,066	
Frequência de Passo (Hz)	DMC	80	0,348	0,560	0,409	0,041	0,73*
	DLC	80	0,349	0,563	0,409	0,041	
Comprimento de passo (m)	DMC	80	0,486	1,620	1,146	0,255	0,21*
	DLC	80	0,680	1,546	1,137	0,220	
Duração de passo (s)	DMC	80	1,500	3,550	2,552	0,629	
	DLC	80	1,500	3,550	2,552	0,629	
Tempo de contato do passo (s)	DMC	80	0,817	2,367	1,589	0,424	
	DLC	80	0,817	2,367	1,589	0,424	

*Valores estatisticamente similares entre as medias para um teste T pareado. As estatísticas descritivas das variáveis espaço-temporais estão distribuídas na tabela 1. Apresentando médias semelhantes para as variáveis velocidade de caminhada, frequência de passo e comprimento de passo.

A amplitude de movimento articular (ADM) do tornozelo (DMC: = $112,19 \pm 61,21^\circ$; DLC: = $116,73 \pm 60^\circ$; $p = 0,55$) e o *Duty factor* (DMC: = $62,85 \pm 1,07\%$; DLC: = $62,85 \pm 1,07\%$; $p = 0,14$) apresentaram valores estatisticamente semelhantes de acordo com o teste T pareado (Tabela 2). A variável ADM do quadril (DMC: = $59,06 \pm 9,78^\circ$; DLC: = $70,89 \pm 33,54^\circ$; $p = 0,04$) apresentou valor de p dentro do início do intervalo de médias estatisticamente diferentes, enquanto as variáveis de ADM do joelho (DMC: = $47,60 \pm 16,93^\circ$; DLC: = $67,28 \pm 43,02^\circ$; $p < 0,01$) e ADM do tronco (DMC: = $17,13 \pm 4,83^\circ$; DLC: = $19,85 \pm 5,87^\circ$; $p < 0,01$) apresentaram valores estatisticamente diferentes entre os dois métodos de análise, quando comparados por meio do teste T pareado (Tabela 3).

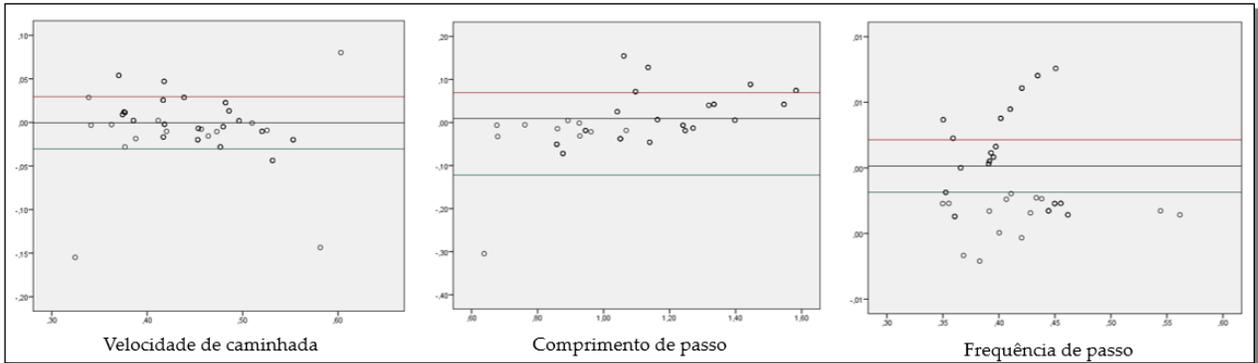
Tabela 3. Tabela com as variáveis descritivas angulares dos dois métodos avaliados.

Variável	Método	Sujeitos	Mínimo	Máximo	Média	Desv. Padrão	P
ADM Tornozelo (°)	DLC	80	29,67	179,88	116,73	60,00	0,55*
	DMC	80	29,67	179,62	112,19	61,21	
ADM Joelho (°)	DLC	80	23,16	179,68	67,28	43,02	<0.01
	DMC	80	27,92	85,68	47,60	16,93	
ADM Quadril (°)	DLC	80	37,52	174,74	70,89	33,54	0,04
	DMC	80	38,98	78,34	59,06	9,78	
ADM Tronco (°)	DLC	80	6,09	28,80	19,85	5,87	<0.01
	DMC	80	8,41	27,92	17,13	4,83	
Duty Factor (%)	DLC	80	61,98	65,85	62,82	1,03	0,14*
	DMC	80	62,01	65,85	62,85	1,07	

*Valores estatisticamente semelhantes para um teste t pareado. As variáveis angulares com o fator de serviço na tabela 2 por método, com os valores de ADM de tornozelo, quadril e o *duty factor* apresentando valores de média semelhantes.

Para o teste de *Bland Altman*, apenas as variáveis espaço-temporais de velocidade, comprimento do passo e frequência de passo apresentaram valores estatisticamente diferentes ($p = 0,90$; $p = 0,21$; $p = 0,73$, respectivamente). Os gráficos de suas distribuições das médias das diferenças (eixo X) pelos valores das diferenças (eixo Y) estão representados na Figura 2. Posteriormente, foi realizada uma regressão linear simples com os valores das variáveis para avaliar possíveis vieses de proporção nas distribuições. Os valores de p obtidos foram: média de velocidade $p = 0,072$, média de comprimento de passo $p = 0,056$ e média de frequência de passo $p = 0,443$, todos apresentando valores acima do mínimo significativo ($<0,05$) para definir a presença ou não de viés de distribuição.

Figura 2. Figura da representação em gráfico do teste de *Bland Altman*.



Os eixos X representam a distribuição média da variável e os eixos Y representam a diferença entre as medidas calculadas em cada passo.

4. Discussão

As redes neurais de aprendizado profundo são estimativas de posição que dispensam a utilização de marcadores anatômicos para estudos biomecânicos. Essas alternativas tiveram sua popularização e crescimento recentemente [14]. Os dados obtidos no presente estudo corroboram, em sua maioria, para a consolidação dessa prática avaliativa em diferentes tipos de estudos biomecânicos com investigação cinemática. Os resultados obtidos das variáveis espaço-temporais apresentaram valores muito próximos e covalentes entre os dois métodos de tratamento dos dados, tanto no teste T pareado quanto no teste de *Bland Altman*, demonstrando ausência de viés de distribuição, para cima ou para baixo dos valores de média encontrados. Nossos resultados corroboram com o estudo de Johnson e colaboradores [19], que compararam os ângulos de tornozelo e joelho durante a corrida, utilizando a rede DLC e um programa para digitalização manual. Além disso, os dados referentes à variável tempo apresentaram valores semelhantes entre os dois métodos, por meio da utilização de contagem de *frames* para obtenção dos valores finais de comparação entre os dois métodos.

Um diferencial do nosso estudo em relação aos anteriores, foi o uso da rede neural de aprendizagem profunda com a utilização das variáveis espaço-temporais em ambiente aquático. Artigos previamente publicados trabalharam em sua maioria com as variáveis angulares, tanto em solo quanto em ambiente aquático [16], [20]–[22]. O presente estudo valeu-se das associações da rede neural com a utilização de modelos de transformação linear direta, em que a coleta dos dados pelos *software* posteriormente foi trabalhada por uma rotina no *software MatLab* para que as variáveis espaço-temporais pudessem ser mensuradas também [19]. A comparação entre os

dois métodos de análise nas suas variáveis espaço-temporais foi previamente apresentada pelo trabalho de Kanko e colaboradores (2021), onde foram estudados parâmetros de velocidade de caminhada, comprimento de passo e de passada, tempo de passo, tempo do ciclo e tempo das fases de apoio e de balanço [23]. O presente estudo associou o mesmo modelo de análise dos dados, aplicando aos movimentos realizados em ambiente aquático, o que inaugura estratégias de estudo inovadoras e aplicáveis em diferentes tipos de investigações transversais e longitudinais com humanos em meio líquido.

Na modelagem baseada em contagem de *frames*, os valores numéricos dos *frames* de *take down* (TD) e *take off* (TO) - primeiro *frame* que o pé toca o solo e o último *frame*, que apresenta o pé tocando no solo antes do TO, respectivamente - são utilizados para calcular os tempos [24]. A rede neural treinada neste estudo não apresentou a possibilidade de exportar essa variável, por se tratar de uma rede que exporta as variáveis de posição de pontos pré-determinados em uma planilha de posição x tempo em pixels. A interpretação e tratamento desses dados necessitou de realização posterior, utilizando-se outro *software* (*MatLab*) para torná-lo viável [21]. A partir deste modelo de tratamento de dados, foi possível incluir no nosso estudo a investigação acerca de variáveis espaço-temporais da marcha, refinando a capacidade de obtenção de informações do estudo da locomoção em ambiente aquático.

Os dados angulares, por sua vez, não apresentaram valores estatisticamente semelhantes em metade das variáveis analisadas. Isso pode ter sido devido ao número de interações para as quais a rede foi treinada [13]. A especificidade do movimento e a qualidade do meio em que a gravação ocorreu podem ter exigido um número maior de interações do que as 300 mil em que a rede foi treinada [14]. A sobreposição dos membros superiores sobre os pontos em determinados momentos da passada, pode ser outro problema decorrente do treinamento, pois a rede tenta buscar outro ponto quando o principal não é encontrado, já que a o programa tende a marcar a posição e a cor dos pixels onde o ponto foi marcado com pré-treinamento. A limitação supracitada poderia ser dirimida com a ampliação do número de interações, a fim de que a rede fosse capaz de reconhecer e aprender a transposição de um segmento sobre o outro durante os movimentos sincronizados dos membros superiores e inferiores na locomoção [17]. Nesse contexto, pode se observar que a ADM do tornozelo e joelho foram as que apresentaram melhores resultados de semelhanças entre as médias, uma vez que tais regiões não sofriam a interferência do cruzamento do membro superior sobre os pontos de referência durante alguns momentos do ciclo de passo. Outra possibilidade que explica esses

resultados foi a qualidade das imagens subaquáticas, já que a redução da transparência da água devido a utilização de produtos químicos para o tratamento da mesma pode dificultar a nitidez da captação de imagens obtidas por filmagem subaquática. Assim, para estudos futuros, seria recomendável a garantia da transparência da água para permitir maior nitidez nas imagens obtidas.

O estudo da caminhada em água rasa tem sua significância relacionada aos benefícios que a atividade pode gerar como atividade física profilática e terapêutica [25]. A análise da caminhada em meio líquido pode ser facilitada com a introdução de novas tecnologias de análise, como a rede neural de aprendizado profundo. O presente estudo corroborou achados recentes na literatura sobre o uso desta tecnologia [14] [26]. Mais estudos devem ser realizados para aprofundar o conhecimento e refinar o uso da tecnologia em diferentes atividades que requerem análise cinemática em sua avaliação. Consideramos esta tecnologia inovadora como uma forma promissora de ampliar estudos exploratório-descritivos, mecânicos e ensaios clínicos randomizados em ambiente aquático, entre outras possibilidades.

Materiais Suplementares: Os materiais suplementares e as informações sobre a forma de treinamento, bem com um vídeo com a digitalização pelo DeepLabCut e os dados calculados em uma planilha podem ser vistos e baixados em:

https://drive.google.com/drive/folders/1F5dbTJI4AL_2KCcqAxb73V9z1co0t_wye?usp=sharing

Declaração do Conselho de Revisão Institucional: O estudo foi conduzido de acordo com a Declaração de Helsinque e aprovado pelo Conselho de Revisão Institucional de UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL (nº 37928/CEP/UFRGS).

Conflitos de interesse: Os autores declaram não haver conflito de interesse. Os financiadores não tiveram nenhum papel no desenho do estudo, na coleta, análise ou interpretação dos dados, na redação do manuscrito, ou na decisão de publicar os resultados.

Referências

- [1] R. G. Ruoti, D. M. Morris, and A. J. Cole, *Reabilitação Aquática*, 1ª. São Paulo: Manole, 2001.
- [2] B. E. Becker, "Aquatic Therapy : Scientific Foundations and Clinical Rehabilitation Applications," *PMRJ*, vol. 1, no. 9, pp. 859–872, 2009, doi: 10.1016/j.pmrj.2009.05.017.
- [3] R. Chintamani, A. Rayjade, and T. Yadav, "Effect of Hydrokinesia in Elderly Subjects with Backward Disequilibrium : A Systematic Review," *J. Ecophysiol. Occup. Heal.*, vol. 20, no. June, pp. 82–94, 2020, doi: 10.18311/jeoh/2020/25201.
- [4] M. Ariyoshi *et al.*, "Efficacy of Aquatic Exercises for Patients with Low-back Pain," *Kurume Med. J.*, vol. 46, no. September, pp. 91–96, 1999.
- [5] A. M. Iliescu *et al.*, "Evaluating the effectiveness of aquatic therapy on mobility , balance , and level of functional independence in stroke rehabilitation : a systematic review and meta-analysis," *Clin. Rehabil.*, vol. 34, pp. 56–68, 2020, doi: 10.1177/0269215519880955.
- [6] E. M. da Silva and L. F. M. Krueel, "Caminhada em Ambiente Aquático e Terrestre : Revisão de Literatura Sobre a Comparação das Respostas Neuromusculares e Cardiorrespiratórias Walking on Land and in Water : a Review Study About the Comparison of Neuromuscular and Cardiorespiratory Responses," *Rev. Bras. Med. do Esporte*, vol. 14, no. 6, pp. 500–504, 2008.
- [7] C. N. Dowzer, T. Reilly, N. T. Cable, and A. Nevill, "Maximal physiological responses to deep and shallow water running," *Ergonomics*, vol. 42, no. 2, pp. 275–281, Feb. 1999, doi: 10.1080/001401399185649.
- [8] A. M. F. Barela, S. F. Stolf, and M. Duarte, "Biomechanical characteristics of adults walking in shallow water and on land," *J. Electromyogr. Kinesiol.*, vol. 16, no. June, pp. 250–256, 2006, doi: 10.1016/j.jelekin.2005.06.013.
- [9] D. A. Winter, *BIOMECHANICS AND MOTOR CONTROL OF Fourth Edition*, 4th ed. New Jersey: JOHN WILEY & SONS, INC., 2009.
- [10] M. Bruce E. Becker and M. Andrew J. Cole, *Comprehensive Aquatic Therapy*, 3ª Edition. Washington, USA: Washington State University Publishing, 2010.
- [11] R. Baker, "The history of gait analysis before the advent of modern computers," *Gait Posture*, vol. 26, no. 3, pp. 331–342, 2007, doi: 10.1016/j.gaitpost.2006.10.014.
- [12] S. L. Colyer, M. Evans, D. P. Cosker, and A. I. T. Salo, "A Review of the Evolution of Vision-Based Motion Analysis and the Integration of Advanced Computer Vision Methods Towards Developing a Markerless System," *Sport. Med. - Open*, vol. 4, pp. 1–15, 2018, doi: <https://doi.org/10.1186/s40798-018-0139-y>.
- [13] S. Fantozzi, A. Giovanardi, D. Borra, and G. Gatta, "Gait Kinematic Analysis in Water Using Wearable Inertial Magnetic Sensors," *PLoS One*, vol. 14, no. September, pp. 1–12, 2015, doi: 10.1371/journal.pone.0138105.
- [14] T. Nath, A. Mathis, A. C. Chen, A. Patel, M. Bethge, and M. W. Mathis, "Using DeepLabCut for 3D markerless pose estimation across species and behaviors," *Nat. Protoc.*, vol. 14, no. July, 2019, doi: 10.1038/s41596-019-0176-0.
- [15] A. Mathis *et al.*, "DeepLabCut: markless pose estimation of user-defined body parts with deep learning," *Nat. Neurosci.*, vol. 21, no. September, pp. 1281–1289, 2018, doi: 10.1038/s41593-018-0209-y.
- [16] N. J. Cronin, T. Rantalainen, J. P. Ahtiainen, E. Hynynen, and B. Waller, "Markerless 2D kinematic analysis of underwater running : A deep learning approach," *J. Biomech.*, vol. 87, pp. 75–82, 2019, doi: 10.1016/j.jbiomech.2019.02.021.
- [17] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition."
- [18] M. Abadi *et al.*, *TensorFlow : Large-Scale Machine Learning on Heterogeneous Distributed Systems*. 2015.
- [19] H. M. Abdel-Aziz, Y. I. & Karara, "Direct linear transformation into object space coordinates in close- range photogrammetry," *Proc. Symp. Close-Range Photogramm.*, p. p 1-18, 1971.
- [20] A. Schmitz, M. Ye, G. Boggess, R. Shapiro, R. Yang, and B. Noehren, "The measurement of in vivo joint angles during a squat using a single camera markerless motion capture system as compared to a marker based system," *Gait Posture*, vol. 41, no. 2, pp. 694–698, 2015, doi: 10.1016/j.gaitpost.2015.01.028.
- [21] J. K. De Witt, "Determination of toe-off event time during treadmill locomotion using kinematic data," *J. Biomech.*, vol. 43, no. 15, pp. 3067–3069, Nov. 2010, doi: 10.1016/j.jbiomech.2010.07.009.
- [22] H. Tamura, R. Tanaka, and H. Kawanishi, "Reliability of a markerless motion capture system to measure the trunk, hip and knee angle during walking on a flatland and a treadmill," *J. Biomech.*, vol. 109, p. 109929, 2020,

doi: <https://doi.org/10.1016/j.jbiomech.2020.109929>.

- [23] R. M. Kanko *et al.*, "Assessment of spatiotemporal gait parameters using a deep learning algorithm-based markerless motion capture system," *J. Biomech.*, vol. 122, p. 110414, 2021, doi: <https://doi.org/10.1016/j.jbiomech.2021.110414>.
- [24] C. D. Johnson, J. Outerleys, and I. S. Davis, "Agreement Between Sagittal Foot and Tibia Angles During Running Derived From an Open-Source Markerless Motion Capture Platform and Manual Digitization.," *J. Appl. Biomech.*, vol. 38, no. 2, pp. 111–116, Apr. 2022, doi: 10.1123/jab.2021-0323.
- [25] M. Evans, S. Colyer, D. Cosker, and A. Salo, "Foot contact timings and step length for sprint training," in *Proceedings - 2018 IEEE Winter Conference on Applications of Computer Vision, WACV 2018*, May 2018, vol. 2018-January, pp. 1652–1660. doi: 10.1109/WACV.2018.00184.
- [26] A. Ivaniski-Mello, M. Zimmermann Casal, R. R. Costa, C. L. Alberton, F. G. Martinez, and L. A. Peyré-Tartaruga, "Quantifying physiological and biomechanical responses of shallow water walking: a systematic review and meta-analysis," *Res. Sport. Med.*, pp. 1–15, Jan. 2022, doi: 10.1080/15438627.2021.2020786.

Manuscript Preparation

General Considerations

- **Research manuscripts** should comprise:
 - **Front matter:** Title, Author list, Affiliations, Abstract, Keywords
 - **Research manuscript sections:** Introduction, Materials and Methods, Results, Discussion, Conclusions (optional).
 - **Back matter:** Supplementary Materials, Acknowledgments, Author Contributions, Conflicts of Interest, **References**.
- **Review manuscripts** should comprise the **front matter**, literature review sections and the **back matter**. The template file can also be used to prepare the front and back matter of your review manuscript. It is not necessary to follow the remaining structure. Structured reviews and meta-analyses should use the same structure as research articles and ensure they conform to the **PRISMA** guidelines.
- **Graphical Abstract:**

A graphical abstract (GA) is an image that appears alongside the text abstract in the Table of Contents. In addition to summarizing the content, it should represent the topic of the article in an attention-grabbing way. Moreover, it should not be exactly the same as the Figure in the paper or just a simple superposition of several subfigures. Note that the GA must be original and unpublished artwork. Any postage stamps, currency from any country, or trademarked items should not be included in it.

The GA should be a high-quality illustration or diagram in any of the following formats: PNG, JPEG, TIFF, or SVG. Written text in a GA should be clear and easy to read, using one of the following fonts: Times, Arial, Courier, Helvetica, Ubuntu or Calibri.

The minimum required size for the GA is 560 × 1100 pixels (height × width). The size should be of high quality in order to reproduce well.
- **Acronyms/Abbreviations/Initialisms** should be defined the first time they appear in each of three sections: the abstract; the main text; the first figure or table. When defined for the first time, the acronym/abbreviation/initialism should be added in parentheses after the written-out form.
- **SI Units** (International System of Units) should be used. Imperial, US customary and other units should be converted to SI units whenever possible.
- **Accession numbers** of RNA, DNA and protein sequences used in the manuscript should be provided in the Materials and Methods section. Also see the section on **Deposition of Sequences and of Expression Data**.
- **Equations:** If you are using Word, please use either the Microsoft Equation Editor or the MathType add-on. Equations should be editable by the editorial office and not appear in a picture format.
- **Research Data and supplementary materials:** Note that publication of your manuscript implies that you must make all materials, data, and protocols associated with the publication available to readers. Disclose at the submission stage any restrictions on the availability of materials or information. Read the information about **Supplementary Materials** and Data Deposit for additional guidelines.
- **Preregistration:** Where authors have preregistered studies or analysis plans, links to the preregistration must be provided in the manuscript.
- **Guidelines and standards:** MDPI follows standards and guidelines for certain types of research. See https://www.mdpi.com/editorial_process for further information.

Front Matter

These sections should appear in all manuscript types

- **Title:** The title of your manuscript should be concise, specific and relevant. It should identify if the study reports (human or animal) trial data, or is a systematic review, meta-analysis or replication study. When gene or protein names are included, the abbreviated name rather than full name should be used. Please do not include abbreviated or short forms of the title, such as a running title or head. These will be removed by our Editorial Office.
- **Author List and Affiliations:** Authors' full first and last names must be provided. The initials of any middle names can be added. The PubMed/MEDLINE standard format is used for affiliations: complete address information including city, zip code, state/province, and country. At least one author should be designated as corresponding author, and his or her email address and other details should be included at the end of the affiliation section. Please read the [criteria to qualify for authorship](#).
- **Abstract:** The abstract should be a total of about 200 words maximum. The abstract should be a single paragraph and should follow the style of structured abstracts, but without headings: 1) Background: Place the question addressed in a broad context and highlight the purpose of the study; 2) Methods: Describe briefly the main methods or treatments applied. Include any relevant preregistration numbers, and species and strains of any animals used. 3) Results: Summarize the article's main findings; and 4) Conclusion: Indicate the main conclusions or interpretations. The abstract should be an objective representation of the article: it must not contain results which are not presented and substantiated in the main text and should not exaggerate the main conclusions.
- **Keywords:** Three to ten pertinent keywords need to be added after the abstract. We recommend that the keywords are specific to the article, yet reasonably common within the subject discipline.

Research Manuscript Sections

- **Introduction:** The introduction should briefly place the study in a broad context and highlight why it is important. It should define the purpose of the work and its significance, including specific hypotheses being tested. The current state of the research field should be reviewed carefully and key publications cited. Please highlight controversial and diverging hypotheses when necessary. Finally, briefly mention the main aim of the work and highlight the main conclusions. Keep the introduction comprehensible to scientists working outside the topic of the paper.
- **Materials and Methods:** They should be described with sufficient detail to allow others to replicate and build on published results. New methods and protocols should be described in detail while well-established methods can be briefly described and appropriately cited. Give the name and version of any software used and make clear whether computer code used is available. Include any pre-registration codes.
- **Results:** Provide a concise and precise description of the experimental results, their interpretation as well as the experimental conclusions that can be drawn.
- **Discussion:** Authors should discuss the results and how they can be interpreted in perspective of previous studies and of the working hypotheses. The findings and their implications should be discussed in the broadest context possible and limitations of the work highlighted. Future research directions may also be mentioned. This section may be combined with Results.
- **Conclusions:** This section is not mandatory but can be added to the manuscript if the discussion is unusually long or complex.
- **Patents:** This section is not mandatory but may be added if there are patents resulting from the work reported in this manuscript.

Back Matter

- **Supplementary Materials:** Describe any supplementary material published online alongside the manuscript (figure, tables, video, spreadsheets, etc.). Please indicate the name and title of each element as follows Figure S1: title, Table S1: title, etc.
- **Funding:** All sources of funding of the study should be disclosed. Clearly indicate grants that you have received in support of your research work and if you received funds to cover publication costs. Note that some funders will not refund article processing charges (APC) if the funder and grant number are not clearly and correctly identified in the paper. Funding information can be entered separately into the submission system by the authors during submission of their manuscript. Such funding information, if available, will be deposited to FundRef if the manuscript is finally published.
Please add: "This research received no external funding" or "This research was funded by [name of funder] grant number [xxx]" and "The APC was funded by [XXX]" in this section. Check carefully that the details given are accurate and use the standard spelling of funding agency names at <https://search.crossref.org/funding>, any errors may affect your future funding.
- **Acknowledgments:** In this section you can acknowledge any support given which is not covered by the author contribution or funding sections. This may include administrative and technical support, or donations in kind (e.g., materials used for experiments).
- **Author Contributions:** Each author is expected to have made substantial contributions to the conception or design of the work; or the acquisition, analysis, or interpretation of data; or the creation of new software used in the work; or have drafted the work or substantively revised it; AND has approved the submitted version (and version substantially edited by journal staff that involves the author's contribution to the study); AND agrees to be personally accountable for the author's own contributions and for ensuring that questions related to the accuracy or integrity of any part of the work, even ones in which the author was not personally involved, are appropriately investigated, resolved, and documented in the literature.
For research articles with several authors, a short paragraph specifying their individual contributions must be provided. The following statements should be used "Conceptualization, X.X. and Y.Y.; Methodology, X.X.; Software, X.X.; Validation, X.X., Y.Y. and Z.Z.; Formal Analysis, X.X.; Investigation, X.X.; Resources, X.X.; Data Curation, X.X.; Writing – Original Draft Preparation, X.X.; Writing – Review & Editing, X.X.; Visualization, X.X.; Supervision, X.X.; Project Administration, X.X.; Funding Acquisition, Y.Y.", please turn to the [CRediT taxonomy](#) for the term explanation. For more background on CRediT, see [here](#). **"Authorship must include and be limited to those who have contributed substantially to the work. Please read the section concerning the [criteria to qualify for authorship](#) carefully"**.
- **Institutional Review Board Statement:** In this section, please add the Institutional Review Board Statement and approval number for studies involving humans or animals. Please note that the Editorial Office might ask you for further information. Please add "The study was conducted according to the guidelines of the Declaration of Helsinki, and approved by the Institutional Review Board (or Ethics Committee) of NAME OF INSTITUTE (protocol code XXX and date of approval)." OR "Ethical review and approval were waived for this study, due to REASON (please provide a detailed justification)." OR "Not applicable" for studies not involving humans or animals. You might also choose to exclude this statement if the study did not involve humans or animals.
- **Informed Consent Statement:** Any research article describing a study involving humans should contain this statement. Please add "Informed consent was obtained from all subjects involved in the study." OR "Patient consent was waived due to REASON (please provide a detailed justification)." OR "Not applicable" for studies not involving humans. You might also choose to exclude this statement if the study did not involve humans.
Written informed consent for publication must be obtained from participating patients who can be identified (including by the patients themselves). Please state "Written informed consent has been obtained from the patient(s) to publish this paper" if applicable.
- **Data Availability Statement:** In this section, please provide details regarding where data supporting reported results can be found, including links to publicly archived datasets analyzed or generated during the study. Please refer to suggested Data Availability Statements in section "[MDPI Research Data Policies](#)". You might choose to exclude this statement if the study did not report any data.

- **Conflicts of Interest:** Authors must identify and declare any personal circumstances or interest that may be perceived as influencing the representation or interpretation of reported research results. If there is no conflict of interest, please state "The authors declare no conflict of interest." Any role of the funding sponsors in the choice of research project; design of the study; in the collection, analyses or interpretation of data; in the writing of the manuscript; or in the decision to publish the results must be declared in this section. *Sensors* does not publish studies funded partially or fully by the tobacco industry. Any projects funded by industry must pay special attention to the full declaration of funder involvement. If there is no role, please state "The sponsors had no role in the design, execution, interpretation, or writing of the study". For more details please see [Conflict of Interest](#).
- **References:** References must be numbered in order of appearance in the text (including table captions and figure legends) and listed individually at the end of the manuscript. We recommend preparing the references with a bibliography software package, such as [EndNote](#), [ReferenceManager](#) or [Zotero](#) to avoid typing mistakes and duplicated references. We encourage citations to data, computer code and other citable research material. If available online, you may use reference style 9. below.
- Citations and References in Supplementary files are permitted provided that they also appear in the main text and in the reference list.

In the text, reference numbers should be placed in square brackets [], and placed before the punctuation; for example [1], [1–3] or [1,3]. For embedded citations in the text with pagination, use both parentheses and brackets to indicate the reference number and page numbers; for example [5] (p. 10). or [6] (pp. 101–105).

The reference list should include the full title, as recommended by the ACS style guide. Style files for [Endnote](#) and [Zotero](#) are available.

References should be described as follows, depending on the type of work:

Journal Articles:

1. Author 1, A.B.; Author 2, C.D. Title of the article. *Abbreviated Journal Name* **Year**, *Volume*, page range.

Books and Book Chapters:

2. Author 1, A.; Author 2, B. *Book Title*, 3rd ed.; Publisher: Publisher Location, Country, Year; pp. 154–196.

3. Author 1, A.; Author 2, B. Title of the chapter. In *Book Title*, 2nd ed.; Editor 1, A., Editor 2, B., Eds.; Publisher: Publisher Location, Country, Year; Volume 3, pp. 154–196.

Unpublished materials intended for publication: