

UNIVERSIDADE FEDERAL DE MINAS GERAIS
Engenharia Mecânica
Programa de Pós-Graduação em Engenharia Mecânica

Diego Henrique Antunes Nascimento

**Avaliação da Marcha humana Utilizando Palmilhas Sensorizadas e Algoritmo
de Aprendizado de Máquina**

Belo Horizonte
2022

Diego Henrique Antunes Nascimento

**Avaliação da Marcha humana Utilizando Palmilhas Sensorizadas e Algoritmo
de Aprendizado de Máquina**

Versão Final

Tese apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Doutor em Engenharia Mecânica.

Orientador: Claysson Bruno Santos Vimieiro
Coorientadora: Maria Lúcia Machado Duarte

Belo Horizonte
2022

N244d	<p>Nascimento, Diego Henrique Antunes. Avaliação da Marcha humana Utilizando Palmilhas Sensorizadas e Algoritmo de Aprendizado de Máquina [recurso eletrônico] / Diego Henrique Antunes Nascimento. - 2022. 1 recurso online (168 f. : il., color.) : pdf.</p> <p>Orientador: Claysson Bruno Santos Vimieiro. Coorientadora: Maria Lúcia Machado Duarte. Tese (doutorado) - Universidade Federal de Minas Gerais, Escola de Engenharia.</p> <p>Apêndices: f. 117-168. Anexos: f. 110-116. Bibliografia: f. 100-109. Exigências do sistema: Adobe Acrobat Reader.</p> <p>1. Engenharia mecânica - Teses. 2. Aprendizado do computador - Teses. 3. Biomecânica - Teses. 4. Marcha Humana - Teses. 5. Mineração de dados (Computador) - Teses. I. Vimieiro, Claysson Bruno Santos. II. Duarte, Maria Lúcia Machado. III. Universidade Federal de Minas Gerais. Escola de Engenharia. IV. Título.</p>
	CDU: 621(043)

Ficha catalográfica elaborada pela Bibliotecária Ângela Cristina Silva CRB/6 2361
 Biblioteca Prof. Mário Werneck, Escola de Engenharia da UFMG



UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

FOLHA DE APROVAÇÃO

"AVALIAÇÃO DA MARCHA HUMANA UTILIZANDO PALMILHAS SENSORIZADAS E ALGORITMO DE APRENDIZADO DE MÁQUINA"

DIEGO HENRIQUE ANTUNES NASCIMENTO

Tese submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Minas Gerais, constituída pelos Professores: Dr. Claysson Bruno Santos Vimieiro (Orientador - Departamento de Engenharia Mecânica/UFMG), Drª. Maria Lucia Machado Duarte (Coorientadora - Departamento de Engenharia Mecânica/UFMG), Dr. Antônio Augusto Torres Maia (Departamento de Engenharia Mecânica/UFMG), Dr. Luciano Luporini Menegaldo (Universidade Federal do Rio de Janeiro/UFRJ), Dr. Alisson Marques da Silva (Centro Federal de Educação Tecnológica/CEFET-MG) e Drª. Vanessa Lara de Araujo (Universidade Federal de Minas Gerais), como parte dos requisitos necessários à obtenção do título de "Doutor em Engenharia Mecânica", na área de concentração de "Bioengenharia".

Tese aprovada no dia 16 de dezembro de 2022.



Documento assinado eletronicamente por **Claysson Bruno Santos Vimieiro, Professor do Magistério Superior**, em 20/12/2022, às 15:03, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Maria Lucia Machado Duarte, Professora do Magistério Superior**, em 21/12/2022, às 10:32, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Alisson Marques da Silva, Usuário Externo**, em 21/12/2022, às 14:10, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Vanessa Lara de Araújo, Professora do Magistério Superior**, em 21/12/2022, às 19:09, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Antonio Augusto Torres Maia, Professor do Magistério Superior**, em 22/12/2022, às 13:28, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Luciano Luporini Menegaldo**, Usuário Externo, em 28/12/2022, às 16:06, conforme horário oficial de Brasília, com fundamento no art. 5º do Decreto nº 10.543, de 13 de novembro de 2020.



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1976959** e o código CRC **3CBF35F0**.

Referência: Processo nº 23072.274054/2022-85

SEI nº 1976959

Dedico essa tese a todo aquele que utiliza o conhecimento para transformar a vida de quem precisa

Agradecimentos

Primeiramente, gostaria de agradecer a Deus por ter me proporcionado sustento e oportunidades que me trouxeram até aqui. Essa tese de doutorado é o resumo de um pouco mais de 4 anos de dedicação. Ela carrega consigo um enorme carinho, diversas histórias e a impressão digital de muitos anjos enviados por Deus para me ajudar a escrever essa parte da minha vida.

Obrigado Claysson (orientador) por acreditar em mim mesmo sem me conhecer. Você me abriu as portas do doutorado e me conduziu nesse caminho. Obrigado Maria Lúcia (coorientadora), que embarcou nessa jornada e se empenhou mais do que eu poderia esperar, nas inúmeras correções de texto da tese e dos artigos. Vocês, muitas vezes, abriram mão do seu tempo pessoal para dedicar a esse trabalho e isso deixa marcas de gratidão. Obrigado George Sabino por me mostrar a fisioterapia, se tornando para mim um mentor, amigo e sócio. Você trilhou comigo esse caminho e dividiu os sucessos e fracassos até alcançarmos o resultado. Obrigado Physicode (George, Raffi, Raphael e Fabrício) por me acolher, participar e financiar parte desse trabalho.

Sem dúvida nenhuma, esse trabalho representa muito para os meus pais, que me transmitiram valores e garantiram acesso à educação. Vocês possibilitaram que eu alcançasse o título de primeiro doutor da família e consolidasse todo o esforço empregado por vocês. Quem poderia imaginar que o neto de um sapateiro e uma lavadeira (avós paternos), um padeiro e uma dona de casa (avós maternos) se tornaria doutor em engenharia pela UFMG, uma das mais renomadas universidades do país? Gostaria que meu avô, José Carlos, estivesse vivo para presenciar esse momento, pois eu seria capaz de apostar que mesmo acamado, como foi seus últimos dias, o bairro todo saberia desse feito.

Finalmente, um agradecimento especial a minha maravilhosa esposa Corine, que me acompanha desde 2002. Durante essa jornada, a Corine foi o meu motivo, meu refúgio, minha apoiadora, minha intercessora, minha confessora. Obrigado Corine por mais de 20 anos de história e que tudo isso sirva para que a nossa filha, Aurora, possa ver que é possível chegar mais longe que os olhos humanos podem ver.

“A tarefa não é tanto ver aquilo que ninguém viu, mas pensar o que ninguém ainda pensou sobre aquilo que todo mundo vê.”
(Arthur Schopenhauer)

Resumo

A análise da marcha humana pode ser uma importante fonte de informações para identificar e prever patologias e lesões. Nesse aspecto, as palmilhas instrumentadas apresentam potencial para a extração de características da marcha. No entanto, existem dificuldades técnicas e comerciais que podem limitar a difusão dessa tecnologia. As palmilhas instrumentadas, disponíveis no mercado, possuem custo elevado e *software* fechado. Por outro lado, os protótipos acadêmicos de baixo custo não apresentam informações suficientes sobre os parâmetros de projeto, técnicas de fabricação e diretrizes para o desenvolvimento. Além disso, o processamento de dados é complexo e requer um conhecimento específico por parte do usuário. O presente estudo propõe o desenvolvimento de um sistema baseado na aquisição da pressão plantar (PP) com palmilha instrumentadas que utilizam um algoritmo de aprendizado de máquina para identificar diferentes padrões de PP e extrair características biomecânicas que podem auxiliar na avaliação clínica. Para isso, foi desenvolvida uma palmilha instrumentada de baixo custo, com sensores customizados que são capazes de estimar a componente vertical da Força de Reação do Solo (vFRS) e que foi validada utilizando uma esteira instrumentada de dupla cinta (Bertec, 1000 Hz, EUA) como “padrão ouro”, atingindo uma correlação de Pearson de 0,73. Durante o processo de validação, foi desenvolvida uma nova metodologia de calibração, que aumentou em até 12% (em alguns casos) a correlação com a plataforma de força em relação ao método usual de calibração, aumentando a correlação média para 0,78 (Pearson). O estudo contou com a participação de 32 voluntários (18 homens e 14 mulheres) para a validação do sistema. Cada voluntário caminhou na esteira instrumentada usando uma palmilha instrumentada experimental. Os dados adquiridos foram processados por meio de algoritmos baseados em aprendizado de máquina responsáveis por identificar diferentes padrões de PP e extrair características biomecânicas que podem auxiliar na avaliação clínica. Os dados foram agrupados por um Algoritmo Imunológico (AI) baseado em PP durante a marcha, onde a correlação de Pearson interna do grupo foi estabelecida superior a 0,90. Esses grupos passaram por um processo de mineração de dados utilizando o algoritmo *Classification and Regression Tree* (CART), onde foram extraídas as características biomecânicas (coordenadas do centro de pressão, duração de cada fase, picos de pressão) de cada grupo e criadas algumas regras para classificação para cada tipo de marcha encontrada. Como resultado, o sistema conseguiu elencar uma lista de variáveis que definem cada um dos grupos de forma a realizar uma classificação da marcha em 86% dos casos. Após a aplicação dos algoritmos AI e CART, foram encontrados seis grupos. Foi verificado um potencial

do sistema em coletar e processar o comportamento biomecânico da marcha, oferecendo pontos de verificação que podem auxiliar no foco durante uma avaliação clínica.

Palavras-chave: biomecânica na marcha, mineração de dados, análise da marcha, aprendizado de máquina, palmilha inteligente, otimização da calibração da palmilha

Abstract

Human gait analysis can provide an excellent source for identifying and predicting pathologies and injuries. In this respect, instrumented insoles also have a great potential for extracting gait information. However, there are technical and commercial difficulties that can limit the diffusion of this technology. The insoles available on the market have a high cost and closed software. On the other hand, the low-cost academic prototypes do not present enough information about the design parameters, manufacturing techniques, and guidelines for developing. In addition, data processing is highly complex and requires a high degree of user knowledge. The present study proposes a proof-of-concept of a system based on vertical ground reaction force (vGRF) acquisition with a sensorized insole that uses a machine learning algorithm to identify different patterns of vGRF and extract biomechanical characteristics that can help during clinical evaluation. For this, a low-cost instrumented insole was developed, with customized sensors that was validated using a double-belt instrumented treadmill (Bertec, 1000 Hz, USA) as the “gold standard”. A new calibration methodology was developed, which increased by 12% the correlation with the force plate in relation to the usual calibration method. The study had the participation of 32 volunteers (18 men and 14 women). Each volunteer walked on the instrumented treadmill while wearing an experimental resistive sensorized insole. The acquired data are processed using algorithms based on machine learning responsible to to identify different patterns of vGRF and extract biomechanical characteristics that can help during clinical evaluation. The data was clustered by an Immunological Algorithm (IA) based on vGRF during gait. These clusters underwent a data mining process using the Classification and Regression Tree algorithm (CART), where the main characteristics of each group were extracted, and some rules for gait classification were created. As a result, the system proposed was able to collect and process the biomechanical behavior of gait. After the application of IA and CART algorithms, six groups were found. The characteristics of each of these groups were extracted and verified the capability of the system to collect and process the biomechanical behavior of gait, offering verification points that can help focus during a clinical evaluation.

Keywords: biomechanics on gait, data mining, gait analysis, machine learning, smart insole, optimization of insole calibration.

Lista de Figuras

2.1	Fases da marcha.	24
2.2	Momento do contato inicial. O joelho deverá estar levemente flexionado.	25
2.3	a) Queda pélvica, b) Deslocamento lateral.	26
2.4	a) Plano sagital, b) Plano transverso c) Plano frontal.	26
2.5	Diagrama que representa um sistema de captação óptico.	28
2.6	Captura de movimento utilizando videogrametria.	29
2.7	a) Movimentos do plano sagital, b) Movimento do plano frontal, c) Movimentos do plano transverso.	30
2.8	Gráfico variação cinemática média esperada em relação aos: a) Movimentos do plano sagital do quadril b) Movimentos do plano frontal da coxa.	30
2.9	Gráfico da variação cinemática média esperada em relação aos: a) Movimentos do plano sagital do joelho b) Movimentos do plano frontal do joelho.	31
2.10	Gráfico da variação cinemática média esperada em relação aos: a) Movimentos do plano sagital do tornozelo b) Movimentos do plano frontal da tornozelo. . .	32
2.11	Plataforma de força UFMG-LAM associada a esteiras para captação das Forças de Reação do Solo (FRS) durante a marcha.	33
2.12	Esquema representando a construção de um sensor FRS.	35
2.13	Gráfico mostrando os pontos estratégicos de análise da curva de FRS.	36
2.14	Representação de um processo de decisão da CART.	43
3.1	Etapas de Desenvolvimento do Sistema de Análise da FRS.	45
3.2	Os sensores de forças foram posicionados de forma a coincidir com as regiões anatômicas (hálux, cabeça de cada metatarso, mediopé lateral e medial e calcâneo). A figura mostra a ligação esquemática dos sensores.	46
3.3	Palmilha Sensorizada utilizando sensores comerciais com conexões soldadas. .	47
3.4	O diâmetro do sensor (D) delimita a área de captação de cada sensor. A espessura da trilha (T) determina quantos segmentos paralelos o sensor irá possuir, influenciando na sensibilidade total do sensor assim como o espaçamento das trilhas (E).	48
3.5	Segundo a normativa ISO 9407, a figura indica a forma correta de se medir a largura da palmilha.	49
3.6	Posição de cada um dos sensores, que estão posicionados nas seguintes regiões anatômicas.	50
3.7	Dispositivos para teste dos parâmetros construtivos dos sensores de força. . .	52

3.8	Aplicação dos espaçadores na placa de teste.	53
3.9	Síntese do processo de fabricação da Palmilha Sensorizada: a) Máscara vinílica adesiva, b) Aplicação da máscara vinílica, c) Corrosão do circuito e d) Circuito flexível finalizado e pronto para a montagem.	54
3.10	Montagem simplificada para leitura do sensor de força resistivo a)circuito de teste b)diagrama de ligação.	56
3.11	Mapa de testes para avaliação dos parâmetros do circuito de aquisição de dados	57
3.12	Protótipo do <i>hardware</i> de aquisição de dados a) Circuito eletronico b) Invólucro do circuito eletrônico; 1- <i>Display</i> Mostrador do nível de bateria; 2- Conector para a Palmilha Sensorizada; 3- Microcontrolador ESP-32; 4- Bateria de lítio 3,7V.	58
3.13	Tipos de conectores testados.	59
3.14	a)Envólucro do dispositivo e sua b) Fixação durante os testes.	59
3.15	Protocolos de comunicação WiFi testados para comunicação do sistema: a) TCP/UDP b) ESPNOW.	60
3.16	Software de aquisição de dados.	63
3.17	Dispositivo para realizar a calibração estática	64
3.18	Posicionamento dos marcadores para a captura de movimento: a) Referência para o posicionamento dos marcadores e b) Marcadores posicionados durante os testes.	65
3.19	Gráfico de FRS e seus principais pontos de análise.	68
3.20	Curva de resposta do sensor com base no carregamento aplicado a) Dispositivo A; b) Dispositivo B; c) Dispositivo C.	70
3.21	Variação da inércia dos sensores em cada tipo de espaçador.	71
3.22	Ganho de rigidez da PS após a laminação com Poliseal: a)Circuito após o processo de corrosão, b) Laminação a quente com Poliseal e c) Circuito laminado com ganho de rigidez.	72
3.23	Regiões críticas de quebra da palmilha devido ao excesso de rigidez da palmilha.	73
3.24	Aplicação de uma camada vinílica de proteção da parte superior da PS; 1) PS com cobertura; 2) PS sem cobertura.	74
3.25	Palmilha Sensorizada com circuito fabricado em tinta condutível de grafeno e base em Acetato.	74
3.26	Defeitos de fabricação das palmilhas utilizando tinta condutiva e descartadas durante os testes. a) Trincas e interrupções da trilhas. b) Trilhas desprendendo-se por baixa adesão.	75
3.27	Resultado dos testes de aplicação da PS em cobre e PS em tinta condutiva. .	78
3.28	Mudança do design das PS com a inclusão de redundância do circuito para evitar interrupção do funcionamento caso ocorram quebras durante os testes.	79

3.29 Comparação qualitativa do ganho de correlação proporcionado pela calibração dinâmica	81
5.1 Diagrama sintético do processamento do AI	89
5.2 Variação no número de grupos com a redução da taxa de erro máxima admitida.	92
5.3 Grupos formados pela AI	95
5.4 Estrutura decisória da CART	96
5.5 Exemplo de classificação cinemática da marcha em relação a pronação, supinação e neutro.	96

Lista de Tabelas

3.1	Largura interna dos calçados levando em consideração o tamanho padrão norte-americano.	50
3.2	Área em cm ² de cada região da Palmilha Sensorizada.	51
3.3	Parâmetros construtivos dos sensores a serem testados.	52
3.4	Critérios qualitativos para avaliação das palmilhas fabricadas com uso de tinta condutiva.	55
3.5	Resumo do resultado de cada um dos sensores testados.	70
3.6	Resumo do resultado de cada um dos espaçadores testados.	71
3.7	Resumo de todas as características definidas em relação ao <i>layout</i> preliminar da Palmilha Sensorizada.	72
3.8	Resumo dos testes utilizando a tinta condutiva de grafeno e sua interação com cada material: Acetato (A), Poliéster (B), Poliseal (C).	75
3.9	Resumo dos resultados obtidos de coeficiente de variação (média considerando os carregamentos) com base nas variações da taxa de aquisição em cada ADC.	76
3.10	Resumo da significância estatística segundo do coeficiente de variação por meio da ANOVA bifatorial.	76
3.11	Resumo do efeito da aplicação de filtro na significância estatística do coeficiente de variação segundo ANOVA.	77
3.12	Resumo do efeito da aplicação de filtro na significância estatística da média amostra segundo Teste t.	77
3.13	Tabela comparativa entre calibração estática e calibração dinâmica.	80
3.14	Tabela de resultados comparativos de Coeficiente de Variação e IC95% entre e aplicação de calibração estática antes e após calibração dinâmica complementar.	80
3.15	Validação das variáveis cinéticas.	82
3.16	Validação das variáveis temporais	82
5.1	Tabela Resumo dos Parâmetros do AI.	89
5.2	Grupos gerados após a fusão dos grupos com alta correlação.	93

*

Sumário

1	Introdução	19
1.1	Aspectos Invovativos	22
1.2	Objetivo	22
2	Revisão Bibliográfica	24
2.1	Marcha Humana	24
2.2	Avaliação Cinética	32
2.3	<i>Machine Learning</i>	37
3	Desenvolvimento do Sistema de Aquisição	45
3.1	Desenvolvimento da Palmilha Sensorizada	46
3.2	Círculo de Aquisição de Dados	56
3.3	Hardware de Aquisição de Dados	58
3.4	Testes Preliminares	61
3.5	Testes Experimentais e Validações	63
3.6	Resultados do Desenvolvimento da Palmilha Sensorizada	69
3.7	Fabricação da Palmilha Sensorizada	72
3.8	Círculo de Aquisição de Dados	75
3.9	Testes Preliminares do Círculo de Aquisição	78
3.10	Calibração Dinâmica	79
3.11	Verificação Cinética	81
3.12	Verificação Temporal	82
4	Discussão	83
4.1	Desenvolvimento da Palmilha	83
5	Processamento dos dados e Aplicação de <i>Machine Learning</i>	87
5.1	Metodologia	87
5.2	Resultados	92
5.3	Aplicação da CART	93
6	Discussão	97
6.1	Implementação do ML	97
7	Conclusão	99

Referências Bibliográficas	100
8 Anexo 1: Referência de preço de uma plataforma de força	110
9 Anexo 2: Parecer Consustanciado do Concelho de Ética e Pesquisa - UFMG	112
A Artigo Publicado	117
B Artigo Publicado	137
C Artigo Aceito	148
D Artigo Submetido	159
E Termo de Consentimento Livre e Esclarecido e Direito de Imagem	165

Estrutura do Trabalho

O presente trabalho segue as orientações propostas pelas Diretrizes para Normalização de Trabalhos Acadêmicos da UFMG (2019) e cumpre os requisitos da Resolução N° 001/2022, de 29 DE abril DE 2022 do Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Minas Gerais. A presente tese foi estruturada da seguinte forma:

- 1) **Introdução:** apresentar o objeto de estudo juntamente com os objetivos e os aspectos inovadores alcançados.
- 2) **Revisão Bibliográfica:** apresentar os principais conceitos e referências para construção e discussão do trabalho.
- 3) **Desenvolvimento da Palmilha Sensorizada:** apresentar o desenvolvimento, calibração, tratamento de dados, validação, durabilidade e melhorias introduzidas para a construção da Palmilha Sensorizada e o sistema de aquisição de dados.
- 4) **Processamento dos dados e aplicação de *machine learning*:** apresenta a construção dos algoritmos, parametrização, aplicação e os resultados encontrados em uma aplicação clínica.
- 8) **Discussão:** discute os resultados e limitações encontradas em cada etapa do projeto em três momentos: construção do sistema, validação e aplicação do algoritmo baseado em *machine learning*.
- 9) **Conclusão:** apresenta a verificação do cumprimento dos objetivos e as perspectivas futuras.

O presente trabalho teve um total de quatro artigos produzidos (três publicados e um submetido - em análise), que se encontram formatados de acordo com as normas dos periódicos que foram submetidos e estão disponíveis no Apêndice. Cada um dos pontos críticos e inovadores desta tese foram transformados em artigos, discutidos e validados pela comunidade científica de forma a construir uma tese robusta e devidamente embasada.

Deseja-se com o presente trabalho contribuir, em parte, no entendimento da funcionalidade humana, de forma colaborativa com a Fisioterapia para que cada vez mais haja uma difusão tecnológica aplicada na área da saúde. Recomenda-se a todos uma boa leitura.

Capítulo 1

Introdução

O avanço tecnológico é um dos principais agentes para o desenvolvimento da área da saúde. Novos instrumentos e sistemas são a base para a melhoria do diagnóstico e, por consequência, maior efetividade no tratamento. Haigh *et al.* [1] afirmam que a aquisição de dados quantitativos acerca do quadro clínico de um paciente é fundamental para um diagnóstico eficaz. O desenvolvimento de aparelhos com aplicação na saúde possibilita justamente a quantificação de alguns parâmetros do paciente que, por vezes, são usados no entendimento geral do quadro clínico, como indicadores para dosagem e resposta do paciente ao tratamento [1]. A Fisioterapia é uma das áreas que se beneficia de instrumentos capazes de quantificar variáveis e promover o direcionamento de práticas clínicas. Um exemplo onde se faz necessário a aplicação de instrumentos na Fisioterapia é na análise de marcha. A análise de marcha é normalmente executada com base na observação, contando com a experiência do profissional [2]. Esse profissional observa a movimentação dos segmentos corporais no espaço (análise cinemática), buscando padrões de comportamento que possam orientar sua conduta clínica [2]. Essa técnica de observação, embora amplamente empregada, possui uma série de limitações. Por mais treinado que o profissional seja, ele não será capaz de avaliar pequenas alterações angulares durante o movimento nem de quantificá-las a ponto de se obter um perfil de comportamento ao longo do tempo. Outra limitação da análise observacional é a impossibilidade de avaliação das forças envolvidas na marcha (análise cinética). Nesses casos, a aplicação de instrumentos para captação de movimento e mensuração de força são capazes de fornecer informações quantitativas acerca da marcha.

A Fisioterapia possui sistemas e equipamentos para análises de movimento compostas por sistemas de captação de movimento e Força de Reação do Solo (FRS). Esses equipamentos, geralmente, estão restritos em laboratórios acadêmicos devido à sua alta complexidade de utilização, alto custo de aquisição e manutenção. Apesar de atender à demanda de quantificação das variáveis biomecânicas e fornecer informações de alta qualidade, a difusão dessa estrutura é comprometida devido à inflação médica [3] e complexidade de operação[4]. A inflação médica é um termo utilizado para representar o aumento dos custos com as despesas médicas [3]. A inflação médica está relacionada com diversos fatores, mas o custo da tecnologia aplicada é um componente importante. Esse

custo pode se tornar expressivo a ponto de inviabilizar a aplicação do recurso tecnológico. Já a complexidade operacional está relacionada com a dificuldade de manusear o instrumento. Essa dificuldade de interação com o recurso tecnológico pode causar insegurança do profissional e desviar sua atenção do paciente [5]. O profissional nessa situação tira o foco do quadro clínico do paciente e preocupa-se em manusear o instrumento da forma necessária. Essa conduta acaba contribuindo para resultados opostos ao propósito da inserção de tecnologia, de compreender melhor o paciente [5]. Ao reduzir o foco no paciente, uma série de variáveis passam a ser desconsideradas, criando uma dependência profissional no instrumento, não considerando, então, a complexidade total do paciente.

O avanço da microeletrônica promoveu o surgimento e difusão dos *smartphones*. Estes vêm se mostrando como possíveis alternativas para vencer a barreira da complexidade e inflação médica. A microeletrônica proporcionou a compactação e incorporação de recursos como câmeras, processadores, sensores de aceleração, inclinação, permitindo o surgimento de aparelhos com grande poder de processamento. O *smartphone*, atualmente, pode ser considerado um computador de bolso e possui uma série de recursos que o torna um potencial instrumento de quantificação de variáveis na prática clínica. Garcia-Barrientos *et al.* [6] apresentam em seu trabalho, uma *toolbox* para aplicativos que estão sendo utilizadas como instrumentos para obtenção de medidas clínicas. Esses aplicativos utilizam das câmeras e sensores disponíveis no *smartphone* para realizar mensurações. Alguns aplicativos, como *Physiocode Posture* [7], *Runmatic* [8], *Spark Motion Pro* [9], são capazes de filmar a marcha de uma pessoa e, por meio de inteligência artificial, rastrear os segmentos corporais e fornecer relatórios com análises cinemáticas rudimentares. Entretanto, os aplicativos estão limitados aos recursos disponíveis nos *smartphones*, onde a qualidade e a precisão dos sensores variam a cada modelo, dificultando a previsibilidade e tratamento dos erros de medida características de cada aparelho.

Outra alternativa é o desenvolvimento de dispositivos vestíveis. Esses dispositivos são projetados para uma aplicação específica, com objetivo de acompanhar o paciente e adquirir dados para o direcionamento clínico. A Palmilha Sensorizada (PI), por exemplo, é um instrumento desenvolvido para captação da pressão plantar durante o movimento. De posse da informação de pressão plantar é possível obter uma aproximação da componente vertical da força de reação do solo (vFRS) com uma alta correlação com uma plataforma de força [10], podendo substitui-la em certas aplicações. A PI ainda não foi capaz de romper a barreira da inflação médica. Apesar de custarem uma fração do preço das plataformas de força, ainda sim, apresentam elevados custos para serem amplamente utilizadas na prática clínica. Os custos relacionados a aplicação de uma PS tem sido alvo de vários estudos que buscam baratear essa tecnologia. Klimiec, E., *et al.* [11] em seu trabalho, relatam diversas estratégias para o desenvolvimento de palmilhas sensorizadas buscando encontrar modelos otimizados de dispositivos que conciliem baixo custo, validade e confiabilidade dos dados.

A medida que a tecnologia vai sendo aplicada, independente do dispositivo utilizado, surge uma nova preocupação que é a abundância de informação. O crescente volume de informações geradas pode contribuir para o entendimento da complexidade do corpo humano, mas cria a necessidades do desenvolvimento de metodologias de análise dessas informações. O corpo humano é considerado um sistema complexo, ou seja, a interação entre os fatores pode gerar diversos desfechos de forma não linear [12]. Essa complexidade limita a previsibilidade e aumenta a dificuldade de construção de modelos matemáticos. Como resposta a esse problema, diversos estudos vêm propondo a utilização de técnicas de *machine learning* (ML) para agrupamento e classificação desses dados [13]. Sistemas baseados em ML têm a capacidade de se adaptar a um conjunto de dados e criar estruturas capazes de agrupar dados devido a suas similaridades e correlações ou realizar classificações e previsões baseadas em probabilidade [13]. Slijepcevic *et al.* [14] apresentam em seu trabalho um crescente número de estudos que aplicam ML e o seu potencial para lidar com grandes quantidades de dados. Entretanto, sistemas baseados em ML possuem algumas limitações que devem ser pontuadas. A maior parte de sistemas baseados em ML atuam como “caixas pretas” [13], ou seja, não é possível auditar quais são os critérios adotados para o processamento de dados e construção da resposta oferecida pelo sistema. As técnicas de ML mais utilizadas para avaliação clínica são baseadas em um processo de treinamento supervisionado. Nesse tipo de treinamento, o algoritmo de ML necessita receber uma base de dados conhecida, onde se tem o controle sobre as variáveis de entrada e seja conhecido o desfecho para cada uma das amostras contidas na base de treinamento. Por meio dessa base de dados, o algoritmo de ML irá “aprender” como realizar o processamento de dados desejado [15]. Esse processo traz consigo outra limitação que é o conhecimento prévio dos dados. Caso haja a presença de erros ou viés na atribuição dos desfechos às amostras, por qualquer motivo que seja, o treinamento será comprometido e, consequentemente, o resultado oferecido pode não atender às necessidades às quais o sistema se propõe. Para tentar escapar dos erros durante a aquisição e o processamento dos dados, são aplicadas métricas de desempenho que buscam atestar a validade e confiabilidade dos instrumentos e sistemas de análise.

Desta forma, a busca por instrumentos/tecnologias para a quantificação de variáveis para auxiliar no diagnóstico e intervenção clínica passa a ser guiada, conforme apresentado, pelo custo de implementação, complexidade de operação, capacidade de processamento de dados, metodologias e protocolos para a análise de dados, maneiras de auditar o processamento dos dados, sua confiabilidade e validade.

1.1 Aspectos Invovativos

Durante o desenvolvimento desse trabalho, alguns pontos de inovação formaram a base para a construção do sistema de aquisição e análise da marcha utilizando *machine learning*. Cada aspecto foi devidamente apresentado durante o desenvolvimento do trabalho. Entretanto, o autor decidiu apresentar os principais pontos, previamente, para direcionar o leitor durante a leitura.

A começar pela construção do *hardware*, que abrange a Palmilha Sensorizada e o sistema de aquisição de dados. A palmilha teve o número de sensores reduzidos, o que impactou no aumento da taxa de aquisição, e sua área superficial foi aumentada em comparação aos modelos de referência, garantindo uma boa interface com o usuário mesmo durante a movimentação.

O protocolo de transmissão de dados WiFi utilizado garantiu alta disponibilidade e baixa taxa de latência em uma rede própria que permitiu parear e sincronizar os dados a uma alta velocidade sem perda de informações. Todo esse sistema de aquisição foi desenvolvido visando o baixo custo com um potencial de atingir uma fração do preço dos produtos similares disponíveis no mercado.

A principal contribuição deste trabalho para a literatura na área de biomecânica e análise do movimento de marcha humana foi proposta uma nova metodologia de processamento dos dados feita utilizando dois algoritmos de *machining learning* de forma colaborativa. Essa interação garantiu ao sistema um processamento autônomo de identificação de padrões, agrupamento e verificação de correlação entre as variáveis, sem que haja a necessidade de interferência do usuário nesse processamento. Acrescenta-se o desenvolvimento de um novo método de calibração não linear, utilizando otimização computacional de parâmetros dinâmicos que aumentou em cerca de 12% a correlação do sistema proposto em relação ao “padrão ouro” de validação utilizado na literatura.

1.2 Objetivo

O objetivo desse trabalho foi desenvolver um sistema de avaliação dinâmica da marcha composto por um instrumento de medição da pressão plantar (Palmilha Sensorizada) e um sistema de armazenamento e processamento de dados baseado em ML, podendo ser utilizado como instrumento de pesquisa e também como instrumento de suporte ao diagnóstico clínico.

1.2.1 Objetivos Específicos

1. Criar um sistema para coletar dados cinéticos (FRS e Pressão Plantar) da marcha humana a partir de uma Palmilha Sensorizada customizada ao usuário.
2. Executar a calibração e validação do sistema por meio da correlação dos dados adquiridos com dados de uma plataforma de força (padrão ouro).
3. Aplicar algoritmos para processamento e tratamento dos dados baseado em *machine learning*, capaz de identificar padrões de comportamento baseados na correlação estatística entre as curvas e extrair as principais variáveis biomecânicas que prevalecem no agrupamento formado (*data mining*).

Capítulo 2

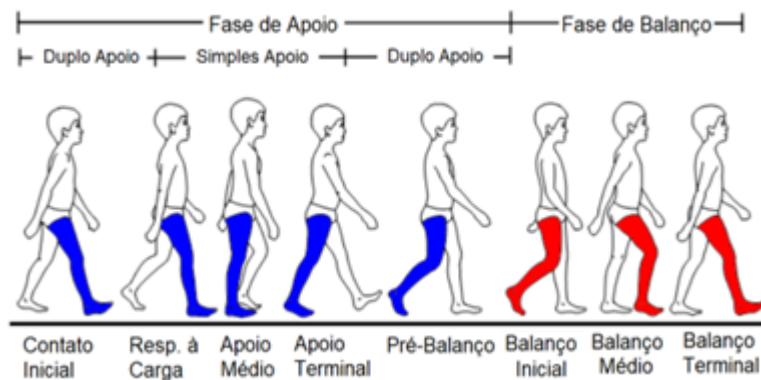
Revisão Bibliográfica

2.1 Marcha Humana

A marcha humana é uma forma de deslocamento decorrente de uma sequência de movimentos sincronizados dos membros inferiores e superiores. Para compreender esse deslocamento, diferentes abordagens para análise podem ser empregadas e três são as mais comuns [16]. A primeira divide, de forma simples, a marcha em duas etapas de acordo com o contato dos pés com o solo: simples apoio e duplo apoio. A segunda utiliza fatores temporais e distância da passada. A terceira, por sua vez, foca em aspectos funcionais do movimento, considerando ação ou intenção da ação durante a marcha. A sobreposição desses métodos, pode oferecer uma melhor compreensão do movimento.

Partindo dessa premissa, o ciclo da marcha foi estratificado em oito etapas: Contato Inicial, Resposta à Carga, Apoio Médio, Apoio Terminal, Pré-Balanço, Balanço Inicial, Balanço Médio e Balanço Terminal [17]. Cada uma dessas fases da marcha cumpre uma função e apresenta suas peculiaridades. A Figura 2.1 mostra todas as etapas de forma esquemática.

Figura 2.1: Fases da marcha.

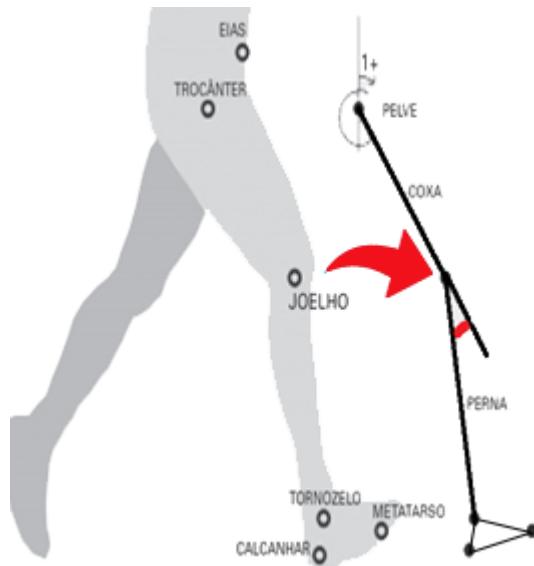


Fonte: Adaptado de Viel [17].

O Contato Inicial é o momento em que o pé toca o solo para o início do ciclo da marcha. Nesse momento, os segmentos do membro inferior à frente estão posicionados

para iniciar o apoio e o rolamento do calcanhar. Nessa fase já é possível detectar alguns indicativos de marchas patológicas (marchas alteradas). No momento do toque do calcanhar no solo, o posicionamento angular relativo dos segmentos perna e coxa (ângulo do joelho no plano sagital – Figura 2.2) podem indicar hiperextensão do joelho, flexão excessiva ou outra perturbação que podem ser indicativos de fraqueza muscular ou outras patologias.

Figura 2.2: Momento do contato inicial. O joelho deverá estar levemente flexionado.



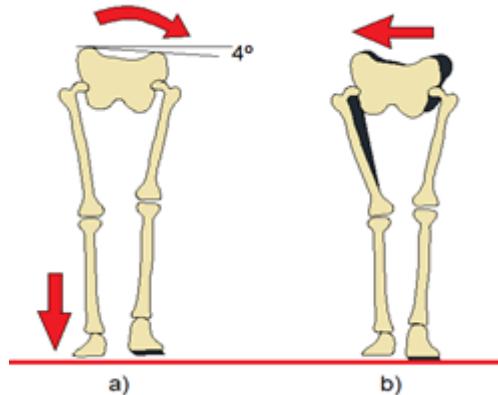
Fonte: Adaptado de Cristopoliski *et al.* [18].

A Resposta à Carga é momento subsequente ao Contato Inicial, e corresponde ao período de duplo apoio, em que ocorre a absorção do choque proveniente da recepção do peso, para preservação da progressão do movimento. Essa transferência de peso entre os membros inferiores acontece de forma abrupta em que cerca de 60% do peso é acelerado por 0,02s à queda livre [16]. Esse impacto é absorvido, primeiramente, pelos movimentos do tornozelo (no caso do plano sagital, a flexão plantar), seguido da flexão do joelho. O movimento dessas articulações, quando mapeadas de forma assertiva, podem indicar sobrecargas (por exemplo, em caso de hiperextensão de joelho), fraqueza muscular (por exemplo, em caso de flexão aumentada) entre outras alterações que podem ser foco de tratamentos.

O Apoio Médio inicia a partir do momento em que o pé contralateral inicia o balanço e continua até que o peso do corpo seja alinhado sobre o antepé. Nessa fase é observada a estabilidade do tronco ao manter a progressão. O centro de gravidade é deslocado lateralmente e verticalmente devido à extensão do joelho. Nesse momento é possível observar uma queda pélvica de cerca de quatro graus para minimizar o deslocamento do centro de gravidade e conservar energia (Figura 2.3).

O Apoio Terminal completa a fase de apoio simples, elevando o calcanhar e avançando sobre o rolamento do antepé. Nessa etapa é observada a extensão máxima do joelho para

Figura 2.3: a) Queda pélvica, b) Deslocamento lateral.



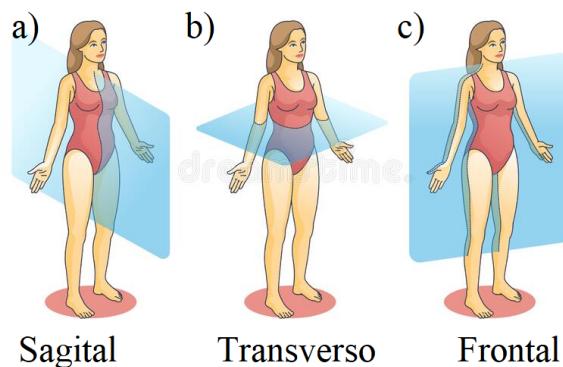
Fonte: Adaptado de Perry [16].

projetar o corpo a frente.

O Pré-Balanço é o segundo momento em que acontece o apoio duplo, começando com o contato inicial do membro oposto e terminando com o desprendimento ipsilateral dos dedos [16]. Durante essa fase, o peso sobre o membro é liberado e transferido para o membro oposto, deixando o membro em Pré-Balanço, livre para se preparar para o balanço. O Apoio Terminal e o Pré-Balanço foram agrupados nesse trabalho e denominado de fase de Impulsão, pois é responsável por projetar o corpo na direção do movimento.

O Balanço Inicial, Médio e Terminal são subdivisões relativamente simétricas dentro da fase de balanço de uma forma geral. Iniciando com a elevação do pé, passando pelo pé de apoio (fim do Balanço Inicial), seguindo pela posição onde o pé está anterior e a tibia na vertical (fim do Apoio Médio) e finalizando com o deslocamento da tibia para uma posição anterior à coxa. Todas essas fases da marcha estão ocorrendo em um espaço tridimensional e que pode ser decomposto em três planos ortogonais de observação: sagital, frontal e transverso (Figura 2.4).

Figura 2.4: a) Plano sagital, b) Plano transverso c) Plano frontal.



Fonte: disponível em repositório de imagens (Dreamstime). ¹

Tomando por base os planos ortogonais anatômicos, cada segmento corporal des-

creve uma trajetória angular ao longo do tempo, tendo como restrições aspectos de sua própria fisiologia. A análise do deslocamento, posição e orientação ao longo do tempo fica a cargo da análise cinemática. Entretanto, as diversas movimentações e posturas desempenhadas durante a marcha estão relacionadas com as forças envolvidas para sustentação, aceleração e desaceleração de cada um dos segmentos. Essa parte da análise compreende a análise cinética.

2.1.1 Análise de Marcha

O interesse pelo movimento humano data a partir do século XVII, onde cientistas como Aristóteles, Da Vinci, Galileu, introduziram conceitos de centro de massa e outros importantes parâmetros para a análise da marcha [19]. Apesar dos muitos esforços da ciência, foi somente no século XIX que um fotógrafo americano conseguiu, por meio de sucessivas fotografias, registrar a marcha humana [19] e a partir do século XX Schwartz iniciou estudos sobre pressões e forças envolvidos na marcha [19]. Portanto, a análise de marcha pode ser considerada uma área de estudos recente.

A análise de marcha pode ser dividida em três áreas: eletromiografia dinâmica, análise cinemática e análise cinética. A eletromiografia dinâmica estuda o padrão de ativação muscular durante a marcha [19]. Durante a contração, o músculo emite pequenos pulsos elétricos, que são responsáveis por desencadear a atuação muscular [16]. A intensidade desse sinal elétrico pode ser medida por meio de eletrodos estrategicamente posicionados [20]. A análise cinemática estuda o deslocamento dos segmentos corporais no espaço ao longo do tempo [16]. Esse estudo é realizado utilizando abordagens qualitativas e quantitativas [20]. A abordagem qualitativa é exercida por meio da observação de um profissional que busca por padrões de movimento ou posturais na tentativa de encontrar algum comportamento característico que auxilie em sua conduta clínica [21]. Já a abordagem quantitativa é feita utilizando instrumentos capazes de realizar a captura de movimentos e informar, com precisão, a posição e orientação de cada segmento corporal analisado ao longo do tempo [20]. Finalmente, a análise cinética estuda as forças e pressões envolvidas durante a marcha. Esse tipo de análise é realizada utilizando equipamentos capazes de medir a FRS durante a marcha [16]. A FRS é, posteriormente, utilizada em conjunto com modelos matemáticos biomecânicos para o cálculo estimado das forças e momentos articulares atuantes em cada segmento analisado.

Apesar desse trabalho focar na análise cinética, a análise cinemática é essencial para compreensão do movimento. A análise cinética e cinemática estão diretamente relacionadas com a maior parte dos estudos de diagnóstico, tratamento, prognóstico e prevenção

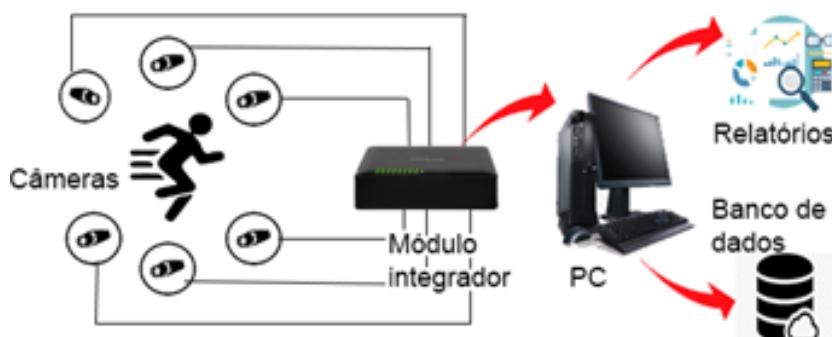
de lesões.

Avaliação Cinemática

Instrumentos

A avaliação cinemática quantitativa está baseada na utilização de dois recursos tecnológicos, captura óptica e captura inercial de movimento. A captura óptica de movimento consiste na utilização de uma câmera que registra o movimento e é capaz de extrair a variação da posição de objetos ao longo do tempo [22]. Para indicar qual o objeto que se deseja rastrear (*track*), são utilizados, na maioria dos sistemas, marcadores, que são posicionados em localizações estratégicas (protuberâncias ósseas e articulações). Esses marcadores são acompanhados quadro a quadro (*frame-by-frame*) para a extração de sua posição em relação ao tempo. Esses marcadores podem ser reflexivos ou não, ativos ou passivos, dependendo da técnica escolhida. Sistemas optoeletrônicos de captação 3D utilizam marcadores reflexivos ativos ou passivos. Os marcadores passivos são feitos de um material que reflete luz infravermelha emitida pelas câmeras de captação. Estas estão espacialmente dispostas para possibilitar a triangulação do ponto e, por consequência, sua localização ao longo do tempo. Os marcadores ativos são capazes de emitir luz infravermelha diretamente para as câmeras de captação, entretanto acaba aumentando o tamanho e peso dos marcadores, o que pode dificultar o posicionamento dos mesmos. A Figura 2.5 representa um diagrama de uma sala em que possui um sistema óptico 3D.

Figura 2.5: Diagrama que representa um sistema de captação óptico.



Fonte: Próprio autor.

Já no caso da videogrametria (outra técnica de rastreamento de pontos), os marcadores não precisam ser reflexivos, mas apenas apresentar um certo destaque em relação ao plano de fundo no qual será aplicado, conforme mostrado na Figura 2.6. Essa técnica funciona reconhecendo uma região de píxeis semelhantes e realizando capturas de movimento em 2D, fornecendo variações angulares e até deslocamentos caso o sistema seja calibrado com uma referência dimensional [22].

Os sistemas ópticos eletrônicos são, geralmente, muito precisos e não há limitação de marcadores, sendo que o posicionamento de marcadores é flexível [23]. Os equipamentos

de captura óptica são considerados os mais caros disponíveis e dependem de um ambiente com iluminação controlada e área de captação específica. Os sistemas ópticos 3D também são caros do ponto de vista computacional (alta carga de processamento) e sua calibração pode levar dias [22]. Do ponto de vista clínico, somente o tempo gasto para a colocação dos marcadores inviabiliza seu uso no dia-a-dia.

Figura 2.6: Captura de movimento utilizando videogrametria.



Fonte: Próprio autor.

Movimento articular durante a marcha

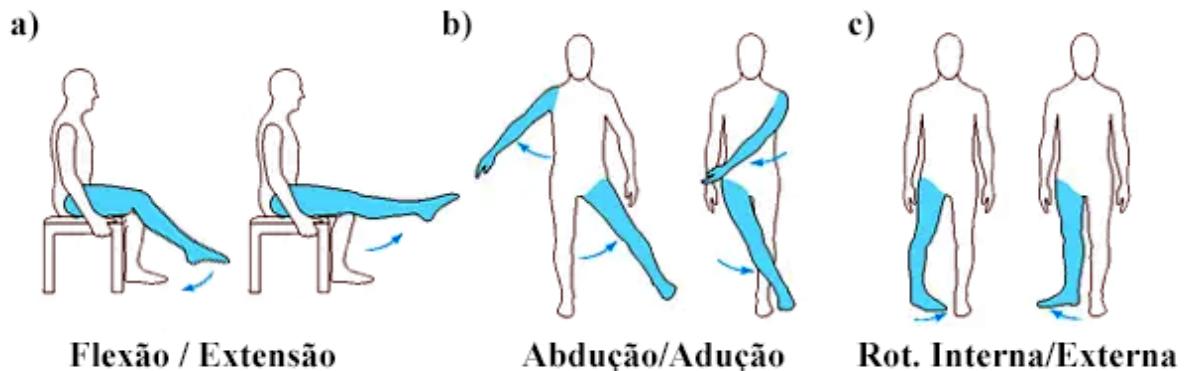
Cintura Pélvica e Quadril

A pelve é constituída pelo sacro, cóccix, e pelos dois ossos formados por uma fusão do ilíio, ísquio e púbis. A articulação do fêmur, em contato com o quadril, possui uma liberdade, ainda que limitada, pode se movimentar em todos os planos anatômicos, sendo o maior exemplo de enartrose do corpo humano. No plano sagital, os movimentos são o de extensão e flexão (Figura 2.7a), no frontal observa-se a adução e abdução (Figura 2.7b) e no plano transverso a rotação medial/interna e lateral/externa (Figura 2.7c).

Em ambiente clínico é comum definir o movimento principal da articulação como pertencente ao plano em que ocorre o maior deslocamento (sagital em maior quantidade) [16]. O movimento do quadril no plano sagital é composto por dois arcos de movimento em uma marcha considerada saudável: extensão durante o apoio e flexão durante o balanço. Tendo a postura ereta como referência inicial, observa-se que o movimento possui dois picos: extensão e flexão. No contato inicial, a coxa se encontra fletida em cerca de 30° para receber parte do impacto. Durante o início do apoio, o quadril se estende progressivamente, fazendo com que a coxa atinja um pico de extensão do quadril de 10°. Durante o Pré-Balanço o quadril inverte sua direção, alcançando 0° no fim do período de apoio. A flexão ocorre durante o Balanço Inicial e Balanço Médio, onde atinge seu pico que é mantido durante o Balanço Terminal. A Figura 2.8 mostra o gráfico do quadril no

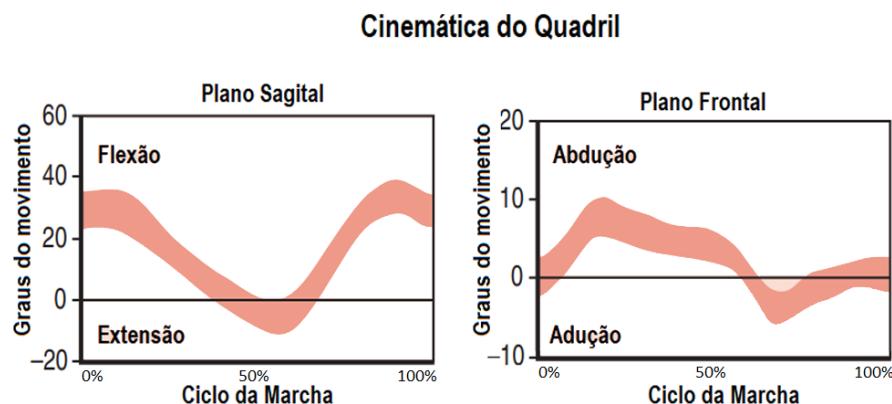
plano sagital. Entretanto, a influência da pelve em uma marcha pode diferenciar esses movimentos de forma significativa. Portanto, é importante separar esses movimentos, já que correspondem a tipos diferentes de patologia.

Figura 2.7: a) Movimentos do plano sagital, b) Movimento do plano frontal, c) Movimentos do plano transverso.



Fonte: Próprio autor.

Figura 2.8: Gráfico variação cinemática média esperada em relação aos: a) Movimentos do plano sagital do quadril b) Movimentos do plano frontal da coxa.



Fonte: Adaptado de King [20].

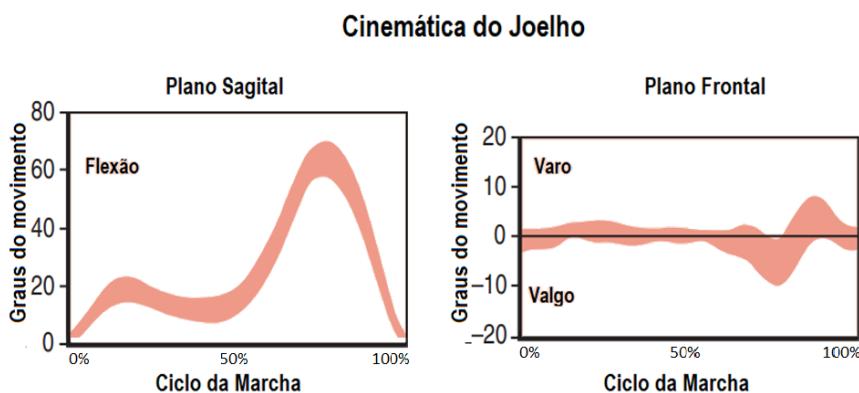
Joelho

O joelho é uma articulação composta formada pelo fêmur, a tíbia e a patela. Para manter suas funções de movimento e estabilidade, o joelho conta com outros componentes articulares, como os meniscos (estruturas cartilaginosas). Os meniscos são estruturas elásticas que conseguem absorver impacto e aumentar a congruência entre os ossos, funcionando como amortecedores que protege a cartilagem articular e a estrutura óssea [24].

A articulação do joelho apresenta dois graus de liberdade: flexão/extensão e rotação medial/lateral. Na marcha, o movimento de flexão e extensão apresentam uma amplitude maior e, assim, são mais facilmente identificados na avaliação clínica. Os movimentos de rotação podem ser detectados e avaliados por meio de instrumentação.

O movimento no plano sagital, por sua vez, pode ser dividido em quatro arcos com flexão e extensão em momentos alternados dentro de uma amplitude máxima de 71° como mostrado na Figura 2.9 [16]. Cada um dos arcos está relacionado com uma etapa específica. O primeiro arco está relacionado com o contato inicial Resposta à Carga. O segundo arco está relacionado com extensão do joelho, passando pelo Apoio Médio e encerrando no Apoio Terminal. No terceiro arco inicia-se a flexão, passando pelo Pré-Balanço, Balanço Inicial e finalizando no Balanço Médio, onde se inicia o quarto e último arco. Este arco é marcado pela extensão do joelho durante o Balanço Terminal e preparação para o Contato Inicial, reiniciando assim o ciclo.

Figura 2.9: Gráfico da variação cinemática média esperada em relação aos: a) Movimentos do plano sagital do joelho b) Movimentos do plano frontal do joelho.



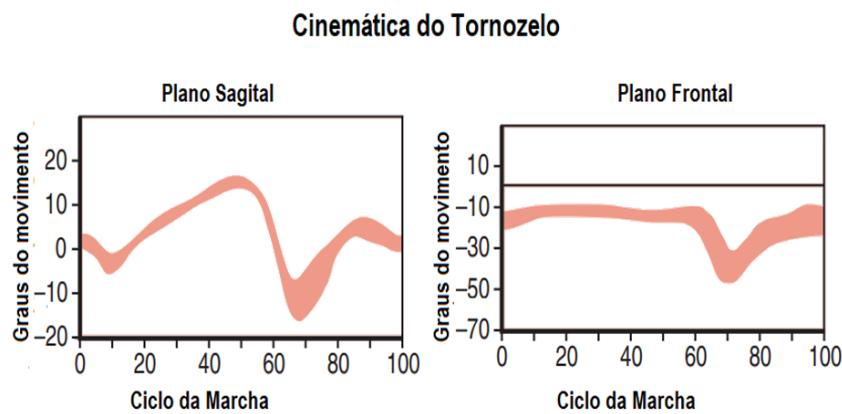
Fonte: Adaptado de King [20].

Tornozelo

O pé é um sistema composto por diversas articulações e eixos de movimentos, sendo que o tornozelo é a interface de ligação entre pé e perna (tibia e fíbula). A articulação do tornozelo pode ser considerada uniaxial, do tipo gínglimo, em dobradiça. Ela realiza movimentos de dorsiflexão e flexão plantar, envolvendo a extremidade inferior da tibia (maléolo lateral), extremidade inferior da fíbula (maléolo lateral) e o tálus. Embora a amplitude angular do movimento do tornozelo não seja alta, esta é crítica quanto a progressão e absorção de impacto durante a fase de apoio. O movimento articular do tornozelo pode ser estudado de acordo com as fases do ciclo da marcha. O primeiro momento compreende a Resposta à Carga (0%-10% do ciclo da marcha). Logo após o

Contato Inicial, o tornozelo realiza a flexão plantar para absorção de impactos ao mesmo tempo que permite o rolamento articular para garantir a progressão do movimento. Em seguida, o segundo momento, compreende a dorsiflexão (Apoio Médio) que permite a progressão do movimento de forma a garantir a estabilidade do movimento (10%-30% do ciclo da marcha). O terceiro momento compreende o Apoio Terminal (30%-50% do ciclo da marcha), onde ocorre a elevação do calcanhar. Nesse momento o vetor de força está situado no antepé com o pé travado pelo gastrocnêmio e pelo sóleo. O quarto momento compreende o Pré-Balanço (50%-60% do ciclo da marcha), seguido do Balanço Inicial (60%-73% do ciclo da marcha), onde ocorre o segundo arco de flexão plantar, tendo o avanço do membro inferior sem carga impulsionada pelo sóleo e o gastrocnêmio iniciando o segundo arco de dorsiflexão. O Balanço Terminal encerra o ciclo da marcha tendo a função de reposicionar o membro para o contato inicial [20]. A Figura 2.10 mostra o movimento do tornozelo visto do plano sagital e frontal.

Figura 2.10: Gráfico da variação cinemática média esperada em relação aos: a) Movimentos do plano sagital do tornozelo b) Movimentos do plano frontal da tornozelo.



Fonte: Adaptado de King [20].

2.2 Avaliação Cinética

2.2.1 Instrumentos

A avaliação cinética está baseada, na maior parte dos casos, na medição da FRS e da pressão plantar [25]. A medição da FRS é realizada por meio de plataformas de força,

que podem ou não, estar associadas a uma esteira ergométrica (esteira instrumentada) [25]. O modelo mais usual de plataforma de força consiste em duas superfícies rígidas, uma superior e uma inferior, posicionadas de maneira paralelas e separadas por sensores de força chamados de células de carga. Há várias maneiras de construção da plataforma conforme o posicionamento e quantidade dos sensores: plataforma com um único sensor no seu centro; plataforma triangular com sensores nos seus três cantos; e plataforma retangular com sensores nos seus quatro cantos. Esse último modo de construção é o mais utilizado comercialmente para análise da marcha. A plataforma de força é, normalmente, instalada no chão, de tal forma que a sua superfície superior esteja nivelada com o chão, possibilitando que o usuário a ser monitorado caminhe por cima dela sem oferecer nenhuma irregularidade que interfira no movimento. Outra forma mais sofisticada de utilização de plataformas de força é quando estas são montadas em conjunto com esteiras ergométricas (Figura 2.11), permitindo a aquisição de dados de ambos os pés de forma contínua durante toda a marcha.

Figura 2.11: Plataforma de força UFMG-LAM associada a esteiras para captação das Forças de Reação do Solo (FRS) durante a marcha.



Fonte: Próprio Autor.

As plataformas de força são utilizadas para medição da FRS durante uma passada. Ela consegue registrar o vetor de forças resultantes incidente no pé durante o movimento. Essa informação pode ser utilizada em alguns modelos biomecânicos para se extrair a propagação de forças em membros, momentos aplicados em articulações e sobrecargas musculares. Recursos como esse conseguem ampliar significativamente o entendimento acerca do movimento humano e suas sobrecargas. As plataformas de força são equipamentos que possuem uma ampla gama de preços, variando conforme sua taxa de aquisição de informações, precisão de medida, tamanho, número de sensores, número de eixos de medição, sistema de aquisição e monitoramento dos dados. Quando se trata de marcha, os modelos mais simples de plataforma de força costumam atender as necessidades da atividade. Em uma pesquisa realizada no painel de preços do governo federal no ano de

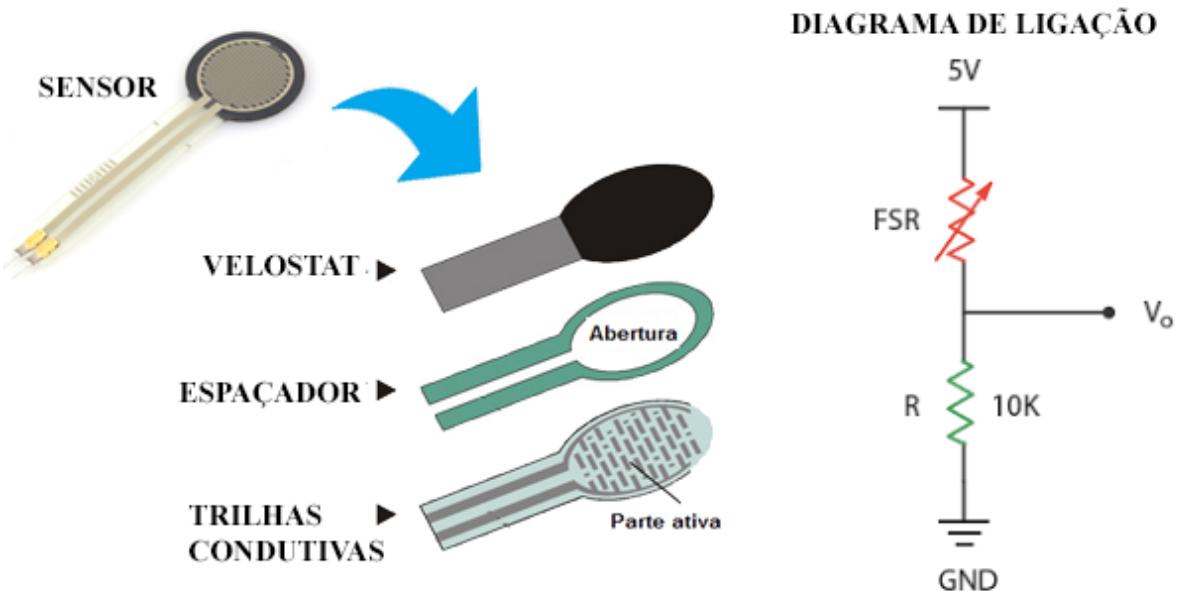
2019², o preço de aquisição desse tipo de equipamento foi de R\$84.000,00. Esse valor pode ser considerado alto quando se trata de avaliações em clínicas de fisioterapia, devendo ser adicionados valores de instalação, manutenção e calibração. Outro fator que deve ser considerado é que esse equipamento é estacionário, ou seja, deve ser instalado em um lugar fixo, com condições ambientais preestabelecidas, dificultando a avaliação da marcha em diferentes cenários.

A medição da pressão plantar, por sua vez, é realizada por meio de plataformas de sensores de pressão dispostos em uma superfície que está em contato com a planta do pé durante a marcha [26]. Os sensores mais usuais são os resistivos e os piezoeléctricos, sendo dispostos em uma plataforma fixa (baropodometria) [26] e tapetes sensorizados [27] ou plataforma flexível (palmilhas sensorizadas). Os equipamentos de baropodometria, por sua vez, são empregados, normalmente, em análises estáticas da pressão plantar. Isso porque apresentam uma superfície reduzida, dificultando a aplicação em análise de marcha. Castro, Soares e Machado [28] apresentam a utilização da baropodometria em estudos de análise de marcha, entretanto, o voluntário tem que dar diversas passadas de maneira a coincidir as superfícies do pé e o instrumento. Esse procedimento deve ser repetido em cada um dos membros, despendendo um tempo considerável para a realização dos testes. Essa dificuldade de alinhar a posição do pé com o instrumento abre margens para inserção de erros sistêmicos e viés dos dados durante a aquisição da marcha. Uma forma de contornar essa dificuldade é a utilização de tapetes sensorizados. Entretanto, ambos os sistemas ainda são dependentes de uma superfície regular para sua utilização. Já a Palmilha Sensorizada (PS), é introduzida no calçado e em contato permanente com a superfície do pé, reduzindo problemas de alinhamento durante o movimento e não apresentando nenhuma dependência da regularidade da superfície durante o movimento.

Conforme mencionado anteriormente, a medição da pressão plantar é realizada por meio de dois tipos de sensores de pressão, piezoeléctricos e resistivos. Os sensores piezoeléctricos são construídos com camadas de cristais que conseguem produzir uma pequena carga elétrica quando pressionados. O sensor absorve as cargas resultantes e sua deformação gera uma diferença de potencial que pode ser amplificada e medida por um circuito eletrônico microprocessado. Esse tipo de sensor apresenta uma medição baseada na variação da carga aplicada, tendo dificuldades em mensurar carregamentos estáticos ou que não apresente uma variação considerável em um curto espaço de tempo. Já os sensores resistivos permitem detectar pressão física em situações estáticas e dinâmicas. Isso porque o sensor de força resistivo é composto por trilhas condutoras interligadas por um polímero semicondutor (Figura 2.12) capaz de alterar a sua condutividade conforme é pressionado. Devido ao seu funcionamento, seu uso se torna simples, sem a necessidade de circuitos de aquisição complexos. Entretanto, sua precisão pode variar em torno de 10% segundo fabricante.

²Resultado com o valor da compra no Anexo 1

Figura 2.12: Esquema representando a construção de um sensor FRS.



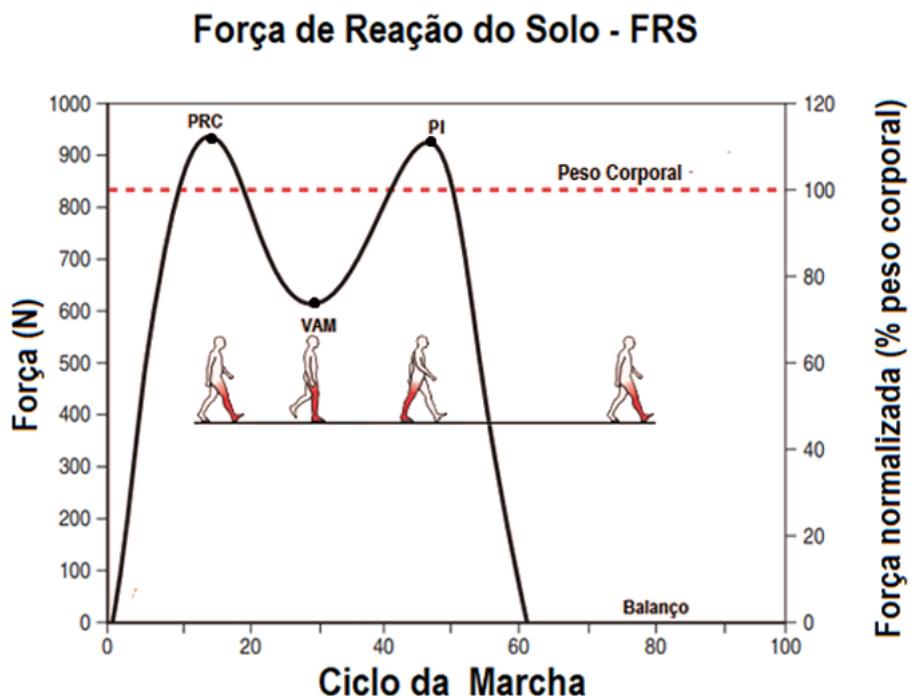
Fonte: Próprio Autor.

A PS geralmente é apresentada como uma alternativa ao uso de plataformas de força (PF) [10] para registro da FRS durante a marcha humana. Isso ocorre porque, apesar das PF serem consideradas “padrão ouro” no registro da FRS, elas apresentam um alto custo de aquisição, um amplo espaço para instalação do equipamento, alto custo de operação, calibração, manutenção e mão-de-obra qualificada para operar o equipamento. Essa dificuldade de acesso às PF impulsiona o estudo e desenvolvimento de alternativas como as PS, que somam inúmeras publicações contendo estudos de diferentes modelos e tecnologias [29]. Atualmente, já existem alguns modelos comerciais de PS como *F-Scan*[30], *Dinafoot*[31], *Medica Flexinfit* [32], que vêm sendo amplamente empregados em estudos relacionados à marcha humana. Entretanto, os modelos comerciais não possuem o código aberto para uma interação diferente da proposta pelo fabricante, restringindo o uso aos *softwares* e recursos por eles oferecidos, dificultando um maior controle dos dados em um ambiente acadêmico. Esse fator impulsiona o surgimento de inúmeros trabalhos propondo PS de baixo custo. Entretanto, foi verificado que a maioria dos artigos publicados tratam apenas de protótipos, muitas vezes sem uma preocupação com acabamento, falhas no processo de aquisição de dados, metodologia de calibração incompletas, baixa correlação com as plataformas de força (a maioria não apresenta esse tipo de verificação), baixa frequência de aquisição de dados (inferior a 100 Hz) [33] [34] [35] [36][37], ausência de informações técnicas e de construção do equipamento. Esse conjunto de motivos fez com que esse trabalho não adotasse nenhum modelo comercial de PS nem reproduzisse algum modelo de PS proposto na literatura, partindo para um modelo autoral.

Avaliação da FRS durante a marcha

A análise cinética está baseada na aquisição da FRS, seja por meio da captação direta ou indireta (com base na pressão plantar). A curva de FRS durante a marcha é estudada de forma isolada ou em conjunto com a cinemática, por meio da biomecânica inversa [38], que utiliza modelos biomecânicos para os cálculos das forças e momentos em cada articulação. Portanto, o entendimento da FRS durante a marcha é importante quando o objetivo é obter uma boa avaliação cinética.

Figura 2.13: Gráfico mostrando os pontos estratégicos de análise da curva de FRS.



Legenda: PRC: Pico de Resposta à Carga; VAM: Vale do Apoio Médio; PI: Pico de Impulsão.

Fonte: Adaptado de King [20].

A FRS possui três momentos característicos que são pontos de atenção durante uma análise cinética (Figura 2.13): pico de Resposta à Carga, vale do Apoio Médio e pico de Impulsão. O pico de Resposta à Carga está relacionado com a absorção dos impactos envolvidos na marcha [39]. Nesse momento a FRS pode chegar a 120% do peso corporal [39]. Pessoas com algum tipo de dor durante a marcha devido a alguma condição clínica, como artrose de joelho [40] ou dor patelofemural [40], tentam minimizar esse impacto alterando a marcha para a redução desse carregamento. O vale do Apoio Médio é o ponto mais baixo entre o pico de Resposta à Carga e o pico de Impulsão. Nesse momento, a FRS pode chegar a 80% do peso corporal [39] devido ao comportamento biomecânico de pêndulo invertido [39]. Nesse momento, também ocorre o pico de eversão do calcâneo e o máximo contato da superfície plantar com maior distribuição de cargas [20] e a anatomia do pé (normal, plano ou cavo) pode interferir nessa distribuição plantar [41]. Finalmente,

o pico de Impulsão é o momento em que o corpo é projetado na direção do movimento, atingindo 120% do peso corporal em média. Nesse momento, a FRS está distribuída na porção anterior do pé, concentrando esforços, principalmente, na cabeça dos metatarsos [16]. Em quadros inflamatórios como metatarsalgia [16] ou neuroma de Morton [16], o indivíduo pode apresentar alterações na curva de FRS como reflexo da alteração da marcha para redução da dor.

Desta forma, a FRS está intimamente correlacionada com o quadro clínico do paciente, podendo servir como fonte de alterações biomecânicas ou como reflexo delas, estabelecendo uma via de mão dupla de causa e efeito. A teoria da complexidade de sistemas aplicado a análise de marcha [42] defende que o quadro clínico de um paciente é fruto da interação de diversos fatores e podem apresentar desfechos distintos, mesmo quando, aparentemente, possuem as mesmas premissas. Entretanto, apesar da complexidade da marcha, estudos apontam o potencial da aplicação de algoritmos de ML para a criação de grupos e modelos matemáticos que possibilitam o estudo, prognóstico e prevenção de lesões [14].

2.3 Machine Learning

Machine learning é um ramo da inteligência computacional que apresenta um conjunto de técnicas implementadas em formas de algoritmos probabilísticos que buscam imitar a maneira que os humanos aprendem. Esse campo da ciência vem crescendo cada vez mais, impulsionados pelo aumento do poder de processamento dos computadores. Existem várias técnicas de aprendizado de máquina que podem adotar estratégias diferentes para realizar o aprendizado dos algoritmos, sendo o aprendizado supervisionado e não supervisionado os mais usuais [14].

A técnica de *machine learning* baseado em aprendizagem supervisionada é um dos métodos mais populares e amplamente utilizados para resolver problemas de classificação e regressão. De acordo com Cunningham *et al.* [43], o aprendizado supervisionado é um dos dois principais tipos de aprendizado de máquina. Esta técnica envolve o uso de algoritmos de aprendizado de máquina que são treinados em conjuntos de dados, onde as saídas são conhecidas e predefinidas. O objetivo é que, após o treinamento, o modelo possa prever as saídas para novos conjuntos de dados não apresentados durante a fase de treinamento. Existem vários algoritmos que utilizam essa técnica, como: o algoritmo de regressão linear [44] o algoritmo de árvore de decisão [45] e o algoritmo de *k-means* [46]. Cada um desses algoritmos possui suas próprias vantagens e desvantagens e é importante avaliar qual é o mais adequado para o problema em questão.

Khera & Kumar [13] apresentam, em seu trabalho, o emprego de algoritmos supervisionados de ML para o reconhecimento de padrões na marcha. Esses padrões encontrados podem ser tratados de duas formas: agrupados ou classificados. O agrupamento de padrões promove a formação de grupos baseados em características comuns entre as amostras de dados [47]. Segundo Slijepcevic *et al.* [14] os principais algoritmos aplicados em análise de marcha são *Support Vector Machine* (SVM) e *Multi Layer Perceptron* (MLP).

O *Support Vector Machine* (SVM) é baseado no conceito de encontrar uma margem máxima entre classes, o que o torna robusto para dados de alta dimensão e com ruído [48]. O SVM utiliza o conceito de hiperplano de separação para encontrar uma linha que divide os dados em duas classes. Esse hiperplano é encontrado para maximizar a margem entre as classes, o que é chamado de margem máxima. Para isso, são utilizados vetores de suporte, que são os pontos mais próximos ao hiperplano e que determinam sua posição [48]. Uma vantagem do SVM é que ele possui uma boa generalização, ou seja, ele tem um bom desempenho em conjuntos de dados desconhecidos [49]. Além disso, ele é eficiente em termos de tempo de treinamento e utilização de memória [49]. Um estudo de 2005 [50] utilizou SVMs para reconhecimento automático de tipos de marcha de jovens a idosos a partir de seus respectivos padrões de marcha. As características da marcha foram extraídas e usadas para treinar o SVM, atingindo resultados do teste de validação cruzada em média 83,3% para reconhecer padrões de marcha de jovens e idosos. Khandoker *et al.* [51] utilizaram SVMs para prever o risco de quedas em idosos com base na análise da marcha. Os autores utilizaram uma SVM para treinar um modelo de previsão de quedas e o modelo conseguiu prever com precisão o risco de queda em até 100% em alguns casos usando um kernel polinomial ($d = 4$) com $C = 10$ e ROC máximo = 1,0. Ilias, Suryani, et al. [52] utilizaram uma SVM para analisar padrões de marcha em indivíduos com transtorno do espectro autista (TEA). Os autores utilizaram os parâmetros espaço-temporais, cinéticos e cinematicos da marcha de quarenta e quatro indivíduos, sendo, trinta e dois indivíduos normais e doze crianças autistas. O SVM, usando um kernel polinomial, obteve uma taxa de precisão de 95%.

No entanto, o SVM possui alguns problemas, como a escolha do kernel e dos parâmetros de regularização, que podem afetar significativamente o desempenho do modelo [49]. Além disso, ele não fornece uma explicação detalhada do processo de tomada de decisão, o que pode ser um problema em alguns casos. Essa falta de clareza durante a construção do modelo matemático faz com que esse tipo de algoritmo seja chamado de “caixa preta” [14].

O MLP é um tipo de rede neural artificial que consegue aprender padrões em dados de entrada e realizar classificações ou previsões. Ao ser aplicado na análise de marcha, o MLP pode ser utilizado para detectar anomalias ou desvios na forma como uma pessoa anda, o que pode ser sinal de problemas de saúde, como dificuldades motoras

ou dores nas articulações [52]. Alaskar, Haya, and Abir Hussain [53] utilizaram MLP em seu trabalho para avaliar a marcha de pacientes com doenças neurodegenerativas, como o Mal de Parkinson. Os resultados mostraram que o MLP conseguiu detectar alterações na marcha desses pacientes com alta precisão (91,19%), o que pode ser útil no diagnóstico e tratamento dessas doenças. Entretanto, a MLP partilha das mesmas desvantagens do algoritmo SVM, mencionado anteriormente.

Uma forma de contornar os pontos negativos dos algoritmos supervisionados é a adoção dos algoritmos não supervisionados. Os algoritmos de aprendizado não supervisionado são uma classe de técnicas de *machine learning* que buscam encontrar padrões ou relações em conjuntos de dados sem a utilização de rótulos, ou classificações prévias, agrupando-os em subgrupos (*clusters*) de dados similares.

O *K-means* é um exemplo de algoritmo não supervisionado recorrente na literatura. Esse algoritmo de agrupamento de dados é baseado em distância euclidiana, para classificar os movimentos da marcha em diferentes grupos ou clusters. Este método tem sido amplamente utilizado na análise de marcha humana, pois permite a classificação precisa e rápida de diferentes padrões de movimento [54] [55]. O *K-means* funciona dividindo os dados em *K clusters*, onde *K* é um número pré-definido pelo usuário. Cada cluster é representado por um centroide, o ponto médio dos dados dentro do cluster. O algoritmo então atribui cada amostra de dados ao cluster mais próximo do centroide, recalculando os centroides após cada atribuição. Este processo é repetido até que os centroides não mudem mais [56]. Na análise de marcha humana, o *K-means* pode ser utilizado para classificar diferentes tipos de movimentos, como caminhada, corrida e saltos, ou para identificar padrões de movimento anormais, como dificuldade de equilíbrio [57]. Além disso, o *K-means* pode ser utilizado em conjunto com outras técnicas de análise, como a análise de frequência, para obter uma compreensão mais completa da marcha humana [58]. No entanto, é importante lembrar que o *K-means* é um algoritmo sensível ao ponto de partida inicial e pode produzir resultados diferentes em cada execução. Portanto, é importante realizar várias execuções e comparar os resultados para garantir a precisão dos mesmos [56].

Entretanto, ao utilizar algoritmos como *K-means*, é necessário um conhecimento prévio da base de dados durante a fase de treinamento [14] referente ao número de agrupamentos que deverão ser encontrados após o processamento. Devido à complexidade da análise de marcha, que envolve múltiplos sistemas e processos fisiológicos, nem sempre é possível obter essas informações.

Para o desenvolvimento de um sistema de análise de marcha é desejável que ele identifique padrões de comportamento, agrupe os dados e os classifique de forma a não depender do conhecimento do usuário, mas que permita o usuário verificar as etapas ou características de processamento para compreender e avaliar a qualidade da análise. Infelizmente não foi encontrado um único algoritmo que reúna as características de treinamento

não supervisionado que não seja uma “caixa preta”, sendo necessária uma associação de algoritmos para se obter o resultado desejado.

Um algoritmo que possui um potencial pouco explorado na literatura para análise de marcha é o Algoritmo Imunológico. Esse é um tipo de algoritmo bio-inspirado baseado no sistema de defesa do organismo humano para solucionar problemas complexos [47]. Esse algoritmo não necessita nenhuma informação prévia sobre classificação ou delimitação da base de dados e consegue agrupar os dados em grupos similares e realizar o reconhecimento de padrões [47]. Esse algoritmo, associado com o algoritmo *Classification Regression Tree*, recorrente na literatura em aplicação de análise de marcha [59], predição de lesão [60] e conhecido por criar uma estrutura de separação binária que permite ser auditada, podem compor uma solução interessante para o problema apresentado.

2.3.1 Algoritmo Imunológico

O AI é um algoritmo bioinspirado no sistema imunológico humano [47]. Esse algoritmo, apesar de pouco explorado na análise da marcha, é considerado uma ferramenta eficaz para reconhecimento de padrões [61]. O AI considera os dados de entrada como análogos aos antígenos. Dessa forma, o algoritmo irá criar um conjunto de anticorpos, que, por sua vez, buscam se ligar aos antígenos mediante a uma função de afinidade [62]. A função de afinidade é importante para o funcionamento do AI: ela permite selecionar os anticorpos mais eficientes para combater os antígenos. Isso é feito por meio da seleção dos anticorpos com as constantes de afinidade mais elevadas, garantindo uma resposta imune mais eficaz e rápida.

O processo de treinamento de um AI é chamado sensibilização do sistema [62]. Durante a sensibilização, são selecionados conjuntos de anticorpos que apresentem melhores índices de afinidade e descartados os demais [62], técnica essa chamada de elitismo. O elitismo é uma estratégia utilizada em algoritmos evolutivos que consiste em preservar os melhores indivíduos da população atual para a próxima geração. Isso é feito para garantir que os resultados mais eficientes não sejam perdidos durante a evolução do algoritmo [47]. Esses anticorpos são clonados e pequenas modificações são inseridas (mutação) e uma nova rodada de verificações é iniciada. O AI desempenha sucessivas rodadas de verificação, seleção, clonagem e mutação até que sejam alcançados os índices de afinidade desejados ou atinja-se um número máximo de rodadas (critério de parada). Caso os índices de afinidade sejam alcançados, é possível dizer que o algoritmo convergiu. O Algoritmo 1 apresenta um pseudocódigo da implementação de um AI.

O AI é considerado não supervisionado e não apresenta problemas com expansão

Algorithm 1 Algoritmo – Algoritmo Imunológico (adaptado de [47])

Dados de Entrada (Antígenos): S

Tamanho da população (Anticorpos): SizeS

Método de seleção: Como serão escolhidos os anticorpos com maior afinidade

Estratégia de Reprodução e Mutação: Como serão gerados os novos anticorpos

Função FIT: Função que calcula a afinidade entre os抗ígenos e anticorpos

Método

- 1: Gerar uma população inicial P, de tamanho SizeS
 - 2: Calcule a afinidade FIT para cada interação P e S
 - 3: Determine os N melhores indivíduos da população P baseado na medida de afinidade
 - 4: Reproduza (processo de clonagem e mutação) estes n melhores indivíduos, gerando uma população temporária de clones (C). A quantidade de filhos de cada indivíduo é proporcional a sua afinidade
 - 5: Substitua uma parcela da população S (com baixa afinidade) pelos melhores anticorpos da população C, mantendo o tamanho SizeS
 - 6: Repita o processo até atingir o grau de afinidade desejado
-

da base de dados. Uma vez definida a função de similaridade, o algoritmo consegue buscar por padrões presentes na base de dados e agrupá-los sem que haja a necessidade da classificação prévia de toda a base de dados. Essa função de afinidade pode ser definida utilizando funções conhecidas [62] como: medida de corelação (Pearson, Coeficiente de Múltiplas Correlações), medidas de erro (Erro Quadrático Médio, Erro Médio Absoluto) ou testes estatísticos (Teste T, Qui Quadrado).

Durante a sensibilização, o AI irá desenvolver anticorpos para o maior número de抗ígenos possível. Uma vez que todos os抗ígenos possuam seus respectivos anticorpos, o sistema é considerado convergente e sensibilizado. Caso seja apresentado uma amostra de dados não sensibilizada, o AI, após falhar na tentativa de encontrar um antícorpo que possua afinidade com o抗ígeno apresentado, poderá produzir novos anticorpos sem prejuízos aos padrões já encontrados, fazendo com que sua base de reconhecimento seja expansível.

Um dos principais problemas que o Algoritmo Imunológico enfrenta é a convergência, ou seja, a capacidade de encontrar uma solução ótima de maneira eficiente e precisa. Uma das principais razões para a falta de convergência no Algoritmo Imunológico é a utilização de uma população inicial pequena. O tamanho da população é um fator crítico na eficiência do algoritmo, pois quanto maior a população, mais possibilidades de encontrar uma solução ótima. No entanto, o tamanho da população também pode afetar o tempo de execução do algoritmo, pois quanto maior a população, mais tempo é necessário para processar as informações. Esse parâmetro é normalmente ajustado de forma empírica, variando conforme os dados utilizados [47]. Outro problema de convergência do Algoritmo Imunológico é a falta de diversidade genética na geração da população de anticorpos. O algoritmo utiliza técnicas de mutação para gerar novas soluções e promover a evolução da população. No entanto, se a população é muito homogênea, o algoritmo

pode entrar em um ciclo de mutações que não leva a nenhuma melhora significativa na solução. Por fim, outro problema de convergência do Algoritmo Imunológico é a falta de um mecanismo de seleção adequado. O algoritmo utiliza técnicas de seleção natural para selecionar as soluções mais aptas para a clonagem. No entanto, se o mecanismo de seleção não for apropriado, o algoritmo pode ficar preso em soluções subótimas ou em uma região do espaço de busca [63]. Uma forma de evitar que o algoritmo fique preso em soluções subótimas é a utilização da estratégia de *multi-start*. Essa técnica consiste em iniciar o algoritmo várias vezes com diferentes populações iniciais, a fim de aumentar a chance de encontrar a solução ótima. A ideia é que, quanto mais diferentes pontos de partida são utilizados, maior é a chance de encontrar a solução ótima. Existem diversas formas de selecionar os pontos de partida para a técnica de *multi-start*. Algumas delas incluem a utilização de pontos aleatórios, a utilização de pontos próximos a soluções já encontradas ou a utilização de pontos próximos a pontos críticos da solução.

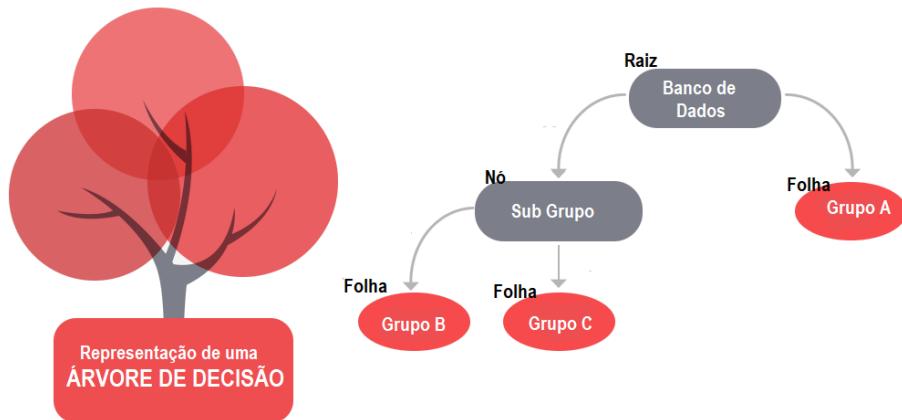
2.3.2 Árvore de Decisão (*Classification Regretion Tree - CART*)

Classification and Regression Tree (CART) é uma técnica de aprendizado de máquina supervisionado que permite a construção de modelos de predição em forma de árvore. A ideia principal por trás da CART é dividir o conjunto de dados em subconjuntos mais homogêneos a cada nível da árvore, de forma que os dados sejam separados conforme as suas características. A CART, também conhecida como Árvore de Decisão, é um algoritmo computacional utilizado para classificação de dados ou modelagem preditiva para obter conclusões a respeito de observações [45]. A segunda utilização é a mais apropriada para a construção de um sistema auditável. Isso porque a CART, durante o treinamento, constrói uma sequência lógica de divisões binárias, que permitem a construção de um fluxograma de tomada de decisões baseada nos parâmetros de entrada. Essa sequência de decisões é explícita e pode ser verificada ponto a ponto por ferramentas estatísticas. A CART permite encontrar correlações entre as variáveis de entrada e os desfechos, apresentados como variáveis de resposta, utilizada na mineração de dados [45].

O funcionamento da CART inicia-se com um conjunto de amostras, cada uma com seus atributos, apresentadas ao algoritmo como variáveis de entrada, onde cada amostra tem um desfecho conhecido. O algoritmo calcula a dispersão estatística dos dados de entrada por meio de dois indicadores, o Coeficiente de Impureza Gini [64] ou Entropia [64]. A partir desse momento, o algoritmo deve selecionar um atributo e um ponto de corte para realizar a divisão binária dos dados, conhecido como nó. O primeiro nó é

denominado raiz. A CART, então, simula a escolha de cada um dos atributos para o nó e realiza o cálculo da nova dispersão estatística dos dados. Por se tratar de dois conjuntos de dados, fruto da divisão binária, a nova dispersão dos dados é a média da dispersão dos conjuntos [45]. A escolha do nó será realizada com base no atributo que promover a maior redução da dispersão. O processo então é repetido em cada conjunto de dados até que não seja possível realizar divisões (não há mais atributos a serem utilizados) ou não haja mais dispersão dos dados. No final do processamento da CART estarão diversos conjuntos de dados classificados como respostas (folhas). Durante o treinamento, a CART irá tentar conciliar a escolha dos nós com maior redução da dispersão e a resposta desejada (gabarito). O desempenho geral da CART pode ser verificado por métricas relacionadas à dispersão final dos dados (Impureza Gini [64] ou Entropia [64]), índice de acerto (Matriz de confusão [65]) ou consistência das folhas (Coeficiente de Silhouette [66]). A Figura 2.14 apresenta uma representação de CART.

Figura 2.14: Representação de um processo de decisão da CART.



Fonte: Próprio Autor.

Um dos principais benefícios da utilização da CART na análise de marcha é a sua capacidade de lidar com abundância de dados e a variedade de atributos que podem ser incluídos no modelo [67], podendo trabalhar com informações qualitativas (dados ordinais, nominais e intervalares) em conjunto com informações quantitativas (dados discretos e contínuos) [67]. Além disso, a CART permite a seleção de atributos relevantes para a classificação da marcha, o que pode ser útil para a identificação de fatores de risco para lesões e implementação de intervenções para tratamento preventivo [60].

O Algoritmo 2 apresenta um pseudocódigo de implementação de uma CART

No entanto, a CART também possui algumas desvantagens. Uma delas é que ela pode ser propensa ao *overfitting*, ou seja, pode ser muito precisa com os dados de treinamento, mas ter desempenho ruim com os dados de teste [67]. Esse *overfitting* pode ocorrer devido ao crescimento excessivo da CART, tornando o modelo gerado excessi-

Algorithm 2 Algoritmo -Árvore de Decisão (adaptado de [68])

DadosTreinamento: $S = (x_1, y_1), (x_2, y_2) \dots (x_n, y_n)$; %% os valores utilizados para o treinamento

Atributos : $A = a_1, a_2 \dots a_n$

Método de seleção de atributos: procedimento para determinar o critério de partição dos dados.

Método

1: Cria o nó N

2: **if** amostras de S são todas da mesma classe, C **then**

3: **return** N como sendo folha com o rótulo classe C

4: **end if**

5:if A=null, or o valor do atributo de S é o mesmo, then

6: **return** N como um nó folha com rótulo da maioria presente em S

7: **end if**

8: encontre o melhor atributo em A para realizar a divisão utilizando o método de seleção de atributos

9: **for** cada valor de A

10: nomear o nó N com base no critério de divisão, separar o subconjunto S_v de S

11: **if** $S_v = \text{null}$ **then**

12: inserir um nó folha rotulado pela maioria da classe em S no nó N

13: **else**

14: inserir o nó retornado pela função GerarArvore() no nó N

15: **end if**

16: **end for**

Saída: Árvore de Decisão

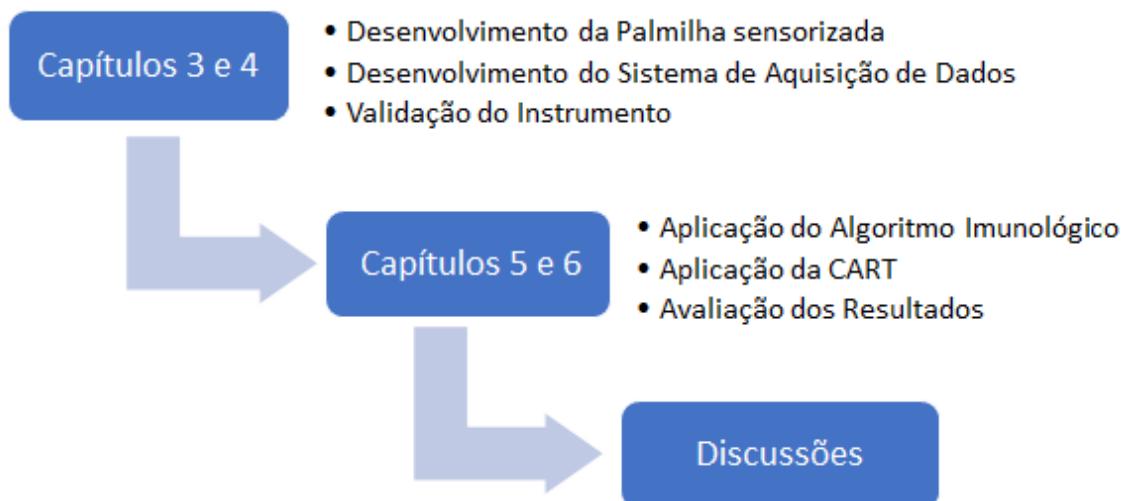
vamente ajustado sobre o conjunto de treinamento e com baixo poder de generalização. Nesse caso, a complexidade da CART pode ser medida pela quantidade de nós gerados, fazendo com que seja necessários métodos de poda para redução da complexidade. A poda é realizada depois que a árvore é criada e consiste em remover os nós folhas ou subárvores inteiras. Isso é feito de forma iterativa, avaliando o impacto da remoção de cada nó na precisão da árvore. Se a precisão da árvore não for afetada de forma significativa após a remoção de um nó, esse nó permanece removido. Esse processo é repetido até que a precisão da árvore atinja um máximo ou até que a árvore atinja um tamanho mínimo aceitável.

Capítulo 3

Desenvolvimento do Sistema de Aquisição

Para que os objetivos desse trabalho fossem alcançados, uma sequência de desenvolvimentos, testes e validações são necessários. A Figura 3.1 apresenta, de forma simplificada, cada uma das etapas necessárias que formam realizadas.

Figura 3.1: Etapas de Desenvolvimento do Sistema de Análise da FRS.



Fonte: Próprio Autor.

3.1 Desenvolvimento da Palmilha Sensorizada

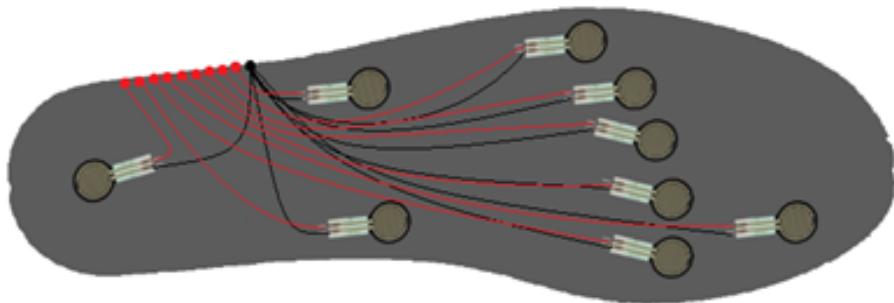
3.1.1 Escolha da Tecnologia

Como mencionado anteriormente (Seção 2.3), as principais tecnologias empregadas na construção de palmilhas sensorizadas são sensores piezoeléctricos e sensores resistivos. O presente trabalho optou pela utilização de sensores resistivos devido a algumas características que ofereciam vantagens em comparação ao piezoeléctrico. Dentre elas, os insumos para fabricação dos sensores resistivos são mais fáceis de serem encontrados, apresentam menores custos e menor complexidade de fabricação.

3.1.2 Posição dos Sensores

O desenvolvimento da PS começou com a escolha arbitrária do número de sensores e a posição de cada um deles. Um primeiro protótipo foi fabricado contendo nove sensores (Figura 3.2).

Figura 3.2: Os sensores de forças foram posicionados de forma a coincidir com as regiões anatômicas (hálux, cabeça de cada metatarso, mediopé lateral e medial e calcâneo). A figura mostra a ligação esquemática dos sensores.



Fonte: Próprio Autor.

Foram utilizados sensores de força comerciais para verificar o melhor posicionamento dos mesmos (Sensor de Força Resistivo FSR402), visto que na literatura é sugerido que o posicionamento dos sensores coincide com regiões anatômicas [69]. Os nove senso-

res foram colados em uma palmilha de EVA (Acetato de Vinila) de maneira a coincidir com regiões: hálux, cabeças dos cinco metatarsos, mediopé medial (osso navicular), mediopé lateral (osso cubóide) e calcâneo. Pequenos ajustes foram feitos na posição dos sensores com a ajuda de um voluntário, que permaneceu na posição ortostática e, de maneira empírica, eram deslocados os sensores individualmente com objetivo de maximizar a captação do estímulo de cada sensor. Após a definição da melhor posição de cada um dos sensores foi observado algumas características que inviabilizaram a utilização de sensores comerciais para a confecção da PS. O primeiro fator é a presença de conexões soldadas ao longo da palmilha. Estas conexões apresentavam incômodo durante os pré-testes, além do fato de apresentarem sucessivas quebras, seja nas próprias conexões ou nos fios que realizam a interligação dos sensores ao circuito. Esse tipo de construção, apesar de encontrada na literatura [70] (Figura 3.3) não se mostrou adequada, direcionando o desenvolvimento para a construção de um circuito flexível com o sensor de força integrado.

Figura 3.3: Palmilha Sensorizada utilizando sensores comerciais com conexões soldadas.



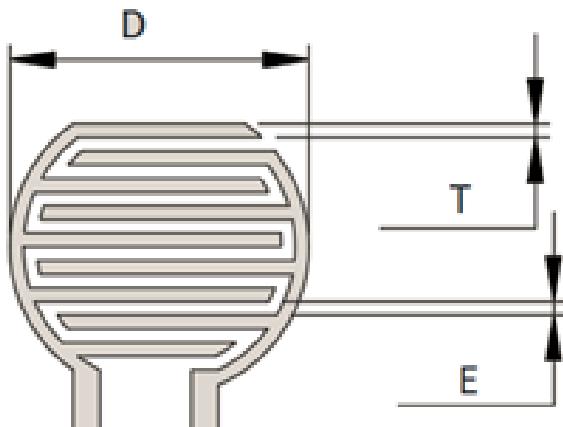
Fonte: Adaptado de Ivanov *et al.* [33].

3.1.3 Parametrização dos sensores de força

Como apresentado anteriormente (Seção 2.3), o sensor de força resistivo é composto por duas trilhas de circuitos entrelaçados de forma paralela feitas de material condutivo

onde é adicionado um espaçador logo acima, com um polímero semicondutor. Para o desenvolvimento de um circuito flexível com os sensores integrados, alguns parâmetros tiveram que ser definidos (Figura 3.4), como tipo de material condutivo a ser empregado nas trilhas, a espessura das trilhas (T), distanciamento das trilhas (E) e diâmetro dos sensores (D).

Figura 3.4: O diâmetro do sensor (D) delimita a área de captação de cada sensor. A espessura da trilha (T) determina quantos segmentos paralelos o sensor irá possuir, influenciando na sensibilidade total do sensor assim como o espaçamento das trilhas (E).



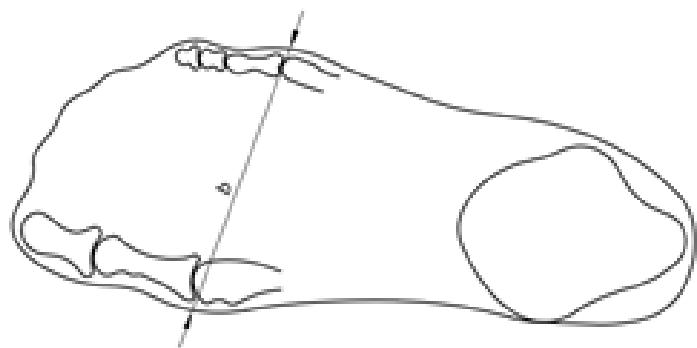
Fonte: Próprio Autor.

Para a determinação dos parâmetros construtivos dos sensores de força foram adotados os seguintes critérios: faixa de peso do usuário, número de sensores, fator de simultaneidade, limiar de leitura e o espaço disponível nos calçados. Segundo IBGE (2008 - última pesquisa realizada), a média de peso da população brasileira varia de 57,8 kg até 74,6 kg considerando público feminino e masculino entre 20 e 74 anos, sendo que durante a marcha, os valores dos picos de força podem chegar até 120% em relação ao peso próprio [39]. Desta forma, em um dimensionamento inicial, os sensores deverão atender a um intervalo entre 55 kg a 100 kg como requisito mínimo para compensar os picos de força de um indivíduo de 74,6 kg. O número de sensores irá influenciar na distribuição de esforços durante a captação, podendo adotar a estratégia de utilizar mais de um sensor em uma determinada região para distribuir o carregamento. O fator de simultaneidade está relacionado diretamente com o movimento e o número de sensores utilizados. Isso porque durante a marcha, diferentes partes do pé estão em contato com o solo em diferentes momentos. O número de sensores sob pressão em um determinado momento da marcha, pode não ser o suficiente para registrar a pressão real aplicada, uma vez que esta pode ultrapassar a capacidade individual dos sensores. O limiar de leitura está relacionada à pressão mínima de ativação de cada sensor. Por mais que seja tentadora a ideia de ter um sensor responsivo, essa característica pode gerar falsas leituras devido à movimentação do pé, ainda que não haja contato com o solo ou até disparos provenientes da deformação da própria palmilha. Todos esses fatores devem ser harmonizados

para proporcionar uma palmilha que conserve as características construtivas mesmo com a diversidade de numeração.

O processo de definições dos parâmetros construtivos dos sensores de força iniciou-se definindo quais seriam as numerações de palmilha a serem desenvolvidas. Um fabricante nacional de palmilhas ortopédicas (Pé sem Dor, [71]) com mais de 13 anos de mercado, publicou em seu site oficial uma série de dados a respeito do consumo de calçados pelos brasileiros. Segundo ele, as numerações compreendidas entre o tamanho 35 e 43 atendem 91,4% e 94% os públicos feminino e masculino. Segundo a normativa ISO 9407, a largura de um calçado deve ser medida na região anterior do pé (Figura 3.5), entretanto não está estabelecido, para o mercado brasileiro, qual deve ser o valor da largura do calçado para cada numeração, cabendo ao fabricante estabelecer seus padrões.

Figura 3.5: Segundo a normativa ISO 9407, a figura indica a forma correta de se medir a largura da palmilha.



Fonte: Adaptado de ISO 9407.

O parâmetro de largura é importante, pois delimita qual é o tamanho máximo dos sensores que estarão dispostos para captação das pressões plantares vindas das cabeças dos metatarsos (Figura 3.5), região essa que terá o maior número de sensores alinhados. Para definir a largura média dos calçados, foi considerada a classificação norte-americana, já que não foi encontrado nenhuma referência nacional. A Tabela 3.1 apresenta a relação entre a numeração do calçado e a largura do mesmo.

Observando a anatomia do pé, é perceptível que a cabeça do 1º metatarso é maior que a dos demais. Visando a utilização de um sensor que abranja toda a área da cabeça do 1º metatarso e que esse sensor seja padronizado para facilitar o processo de calibração futuro, foi decidido por utilizar apenas três sensores alinhados, agrupando o 2º e 3º metatarsos em um único sensor e o 4º e 5º em outro sensor (Figura 3.6). Considerando que o calçado de número 35 possui, em média, 8,26 cm de largura, cada sensor poderá ter no máximo 2,75 cm de diâmetro. Ao preparar o layout do circuito, foi observado que o diâmetro máximo possível é de 2,5 cm. Isso porque parte do espaço foi utilizado para passagem de trilhas elétricas e, devido algumas limitações no processo de fabricação que

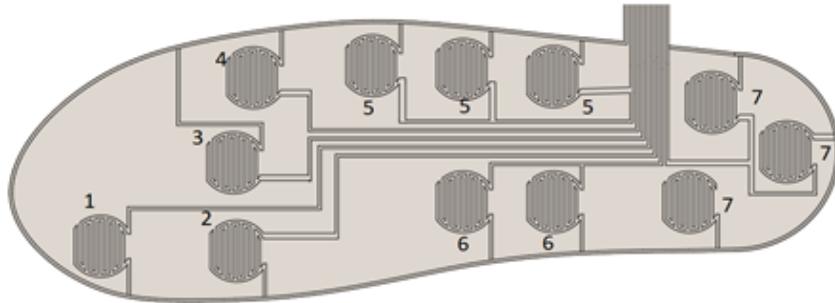
serão discutidas mais adiante, o resultado foi um sensor com 2,5 cm de diâmetro.

Tabela 3.1: Largura interna dos calçados levando em consideração o tamanho padrão norte-americano.

Numeração		Largura		
EUA	BRA	Feminino (mm)	Masculino (mm)	Média (mm)
5,5	35	82,55	-	82,55
6	36	84,14	88,90	86,52
7	37	87,31	92,08	89,69
7,5	38	88,90	93,66	91,28
8	39	90,49	95,25	92,87
8,5	40	92,08	95,25	93,66
9,5	41	95,25	100,10	97,63
10,5	42	98,43	104,78	101,60
11	43	103,19	104,78	103,98

Legenda: EUA: Estados Unidos da América; BRA: Brasil.

Figura 3.6: Posição de cada um dos sensores, que estão posicionados nas seguintes regiões anatômicas.



Legenda: 1- Hálux; 2- 1º Metatarso; 3- 2º e 3º Metatarsos; 4- 4º e 5º Metatarsos; 5- Mediopé Lateral; 6- Mediopé Medial e 7- Calcâneo.

Fonte: Próprio Autor.

Uma vez definido o tamanho dos sensores foi avaliado a área de cobertura de cada uma das regiões anatômicas desejadas. A Equação 3.1 define a área de cobertura da PS (Ac) como sendo a razão entre a área das regiões anatômicas (Ara) e a área dos sensores (As) de cada região.

$$Ac = \frac{Ara}{As} \quad (3.1)$$

Em seguida, foi realizada a definição da espessura e espaçamento das trilhas (Figura 3.6). Devido algumas limitações no processo de fabricação (precisão do equipamento de produção), a espessura mínima das trilhas é de 1,0 mm. Esse valor foi o ponto de partida, tanto para a espessura da trilha quanto para o espaçamento entre elas. Ao se propor os primeiros *layouts*, já eram conhecidas as regiões de interesse para inserção dos sensores e também a limitação do processo de fabricação. Nesse caso, já nos primeiros *layouts* o

resultado alcançou uma versão bem próxima do que seria a versão final da PS. A versão final foi fruto de algumas atualizações do modelo inicial devido a algumas dificuldades na fase de teste discutidas nas Seção 3.3.

Ao observar a região do calcâneo, região onde ocorre picos de força durante a marcha, foram alocados três sensores de força, cada um deles abrangendo uma área de cerca de $4,9 \text{ cm}^2$. Tendo em vista que a região do calcâneo da palmilha de número 35 possui 27 cm^2 , é possível estimar que os sensores têm o potencial de medição de cerca de 55% da pressão plantar durante os pivôs de força. A Tabela 3.2 apresenta a área anatômica de cada uma das regiões cobertas pela palmilha.

Tabela 3.2: Área em cm^2 de cada região da Palmilha Sensorizada.

Numeração	Calc.	MM	ML	1 ^a CM	2 ^a CM	3 ^a CM	4 ^a CM	5 ^a CM	Hx
35	27,0	21,0	25,0	14,0	7,5	7,5	7,5	7,5	8,0
36	27,5	22,2	25,8	16,3	7,5	7,5	7,5	7,5	10,0
37	29,2	22,0	29,0	16,0	7,5	7,5	7,5	7,5	10,6
38	34,0	24,0	30,0	16,3	7,5	7,5	7,5	7,5	10,6
39	38,0	25,0	31,0	16,5	8,2	8,2	8,2	8,2	10,8
40	38,6	25,7	31,5	17,0	8,2	8,2	8,2	8,2	11,0
41	40,0	26,0	32,0	17,9	9,6	9,6	9,6	9,6	11,0
42	41,0	28,0	32,8	19,2	9,6	9,6	9,6	9,6	11,0
43	44,0	28,3	33,0	20,0	10,0	10,0	10,0	10,0	11,1

Legenda: Calc: Calcâneo; MM: Mediopé Medial; ML: Mediopé Lateral; CM: Cabeça do Metatarso; Hx: Hálux.

Para verificar qual seria a espessura da trilha e do espaçamento a ser utilizado, foi fabricado um dispositivo com nove configurações de sensores segundo a Tabela 3.3. Esses dispositivos foram fabricados utilizando uma placa PCB (*Printed Circuit Board*) com um circuito simplificado para leitura de cada sensor (Figura 3.7)

Cada um dos dispositivos (Figura 3.7) foi posicionado em cima de uma balança de precisão (Balança SF-400, carga máxima 10 kg/1g, China) e aplicado um carregamento constante de 2 kg, 4 kg, 6 kg e 8 kg (80% da capacidade da balança) e observado o valor registrado pelo sensor. Com as informações levantadas, foi possível construir, por meio de uma regressão linear, uma equação para resposta do sensor. Utilizando essa equação foi possível estimar a força máxima que o sensor conseguiria registrar.

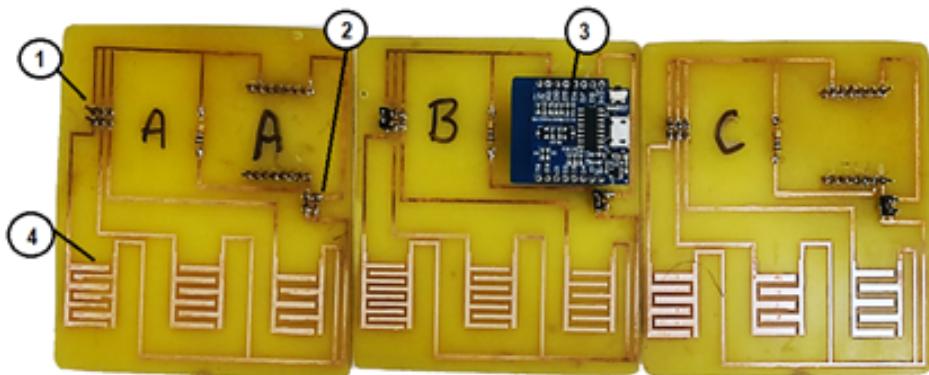
Para cada um dos sensores testados foi estimada qual seria a capacidade de medição máxima (CMM) considerando a aplicação na Palmilha Sensorizada. Isso porque, devido à área de cobertura não ser total, a palmilha registrará apenas uma parte da pressão plantar, proporcionalmente a área de cobertura em cada região anatômica. A Equação 3.2 define a capacidade de medição máxima estimada durante a Resposta à Carga e Impulsão (momentos de pico da FRS), considerando a área de cobertura (Ac), número de sensores (Ns) e capacidade do sensor (Cs).

$$CMM = \frac{Ns.Cs}{(1,2.Ac)} \quad (3.2)$$

Tabela 3.3: Parâmetros construtivos dos sensores a serem testados.

Placa Ref. (Figura 3.6)	Configuração	Espessura da Trilha	Dist. entre Trilhas
A	1	1 mm	1 mm
	2	1 mm	2 mm
	3	1 mm	3 mm
B	4	2 mm	1 mm
	5	2 mm	2 mm
	6	2 mm	3 mm
C	7	3 mm	1 mm
	8	3 mm	2 mm
	9	3 mm	3 mm

Figura 3.7: Dispositivos para teste dos parâmetros construtivos dos sensores de força.



Legenda: 1- *Jumper* de seleção do sensor a ser testado; 2- *Jumper* de seleção da tensão se teste (3,3v ou 5v); 3- Microcontrolador; 4- Trilha condutiva do sensor.

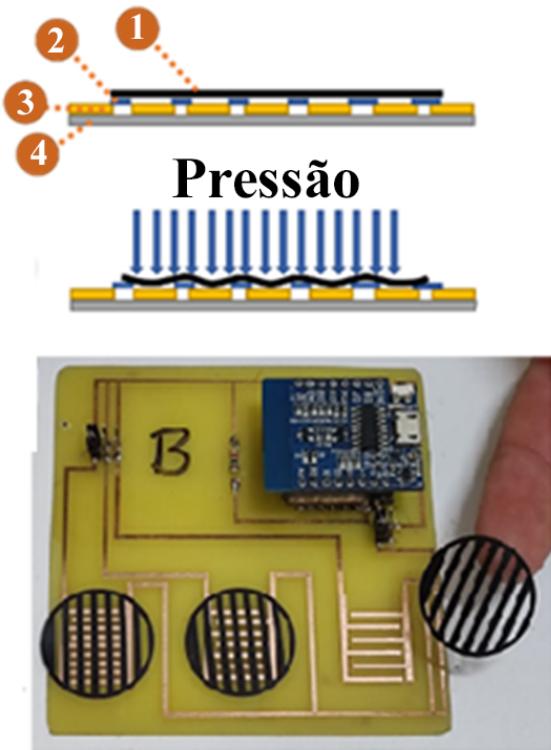
Fonte: Próprio Autor.

3.1.4 Espaçadores

Os sensores resistivos de pressão possuem um espaçador responsável por manter o Velostat afastado da trilha condutiva, evitando falsas leituras devido a eventuais deformações da palmilha durante a movimentação sem que haja descarga de peso. Na fase de Balanço, por exemplo, o pé se movimenta sem que haja o contato com o chão (sem descarga de peso). Para desempenhar a função de espaçador foi utilizado um adesivo vinílico (Figura 3.8). Quando pressionado, o Velostat se molda ao espaçador e inicia a

medição (Figura 3.8). Quanto menores as aberturas do espaçador, maior a dificuldade do Velostat se adequar ao espaçador e iniciar a medição, aumentando o limiar de leitura da palmilha (carga necessária para acionar os sensores). Foi verificado a influência de nove configurações de espaçadores aplicadas ao sensor escolhido para integrar a PS (resultado dos testes descritos na Seção 3.5). Os espaçadores, assim como os sensores, sofreram variações quanto a espessura (E_{esp}) e distanciamento (D_{esp}) das faixas de espaçamento. As configurações utilizadas foram de 1 mm, 2 mm e 3 mm para E_{esp} e D_{esp} (nove combinações). Em cada um dos casos foi verificado o limiar de leitura para os diferentes espaçadores.

Figura 3.8: Aplicação dos espaçadores na placa de teste.



Legenda: 1: Velostat; 2: Espaçador; 3:Trilha condutiva; 4: Base em Poliamida.

Fonte: Próprio Autor.

Para cada um dos espaçadores testados foi estimado qual seria a capacidade de medição mínima (CM_{min}), influenciado pelo limiar de leitura de cada sensor, aplicado na Palmilha Sensorizada. Durante o Apoio Médio a FRS atinge cerca de 80% do peso corporal [39], além de ser o momento em que a pressão plantar está distribuída em toda superfície do pé e a palmilha registrará apenas uma parte da pressão plantar, proporcionalmente a área de cobertura em cada região anatômica. Portanto, nesse momento, serão registrados as menores FRS. A Equação 3.3 define a capacidade de medição mínima estimada no Apoio Médio, com base na área de cobertura do sensor (Ac), número de sensores (Ns) e

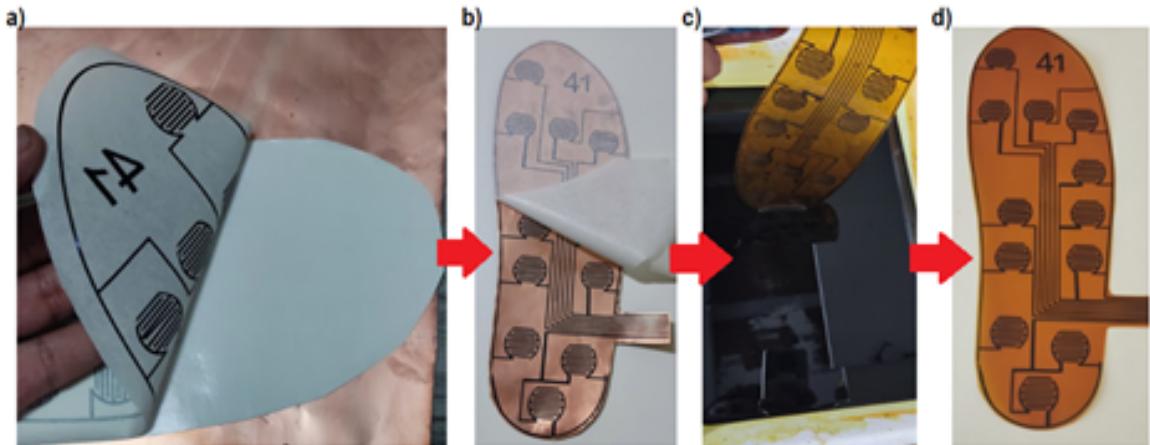
inércia do sensor (I_s).

$$CM_{min} = \frac{Ns.I_s}{(0,8.Ac)} \quad (3.3)$$

3.1.5 Fabricação da Palmilha Sensorizada

Uma vez determinado o design da PS, o próximo passo foi a escolha dos materiais, com isso, o processo de fabricação. Um sucessor comercial análogo à placa de PCB utilizado nos testes de parametrização dos sensores é uma lâmina de cobre depositada em uma camada de Poliamida. Esse material permite a utilização dos processos convencionais de fabricação de placas de PCB por meio de corrosão química. Para a fabricação da PS foi produzida uma máscara de proteção em vinil (Figura 3.9a), aplicada à superfície da lâmina de cobre (Figura 3.9b) e em seguida corroída utilizando o ácido perclórico ($HClO_4$), onde as trilhas são formadas (Figura 3.9c).

Figura 3.9: Síntese do processo de fabricação da Palmilha Sensorizada: a) Máscara vinílica adesiva, b) Aplicação da máscara vinílica, c) Corrosão do circuito e d) Circuito flexível finalizado e pronto para a montagem.



Fonte: Próprio Autor.

Durante a fabricação da máscara de vinil foi observado que o equipamento (Silhouette Cameo 3, Silhouette America Inc., EUA) não permitia a produção de trilhas menores que 1 mm. Essa limitação do equipamento acabou direcionando o design das palmilhas.

Outra alternativa para a fabricação da PS é a utilização de uma tinta condutiva a base de grafeno [72]. Outras tintas condutivas, como a base de prata, são caras e não atem ao propósito de baixo custo. A mesma máscara de vinil utilizada para fabricação

da palmilha em cobre foi utilizada para a aplicação de uma tinta condutiva em uma superfície polimérica (flexível). Para a prototipagem, utilizando tinta condutiva, foi testada a tinta com base em grafeno ($0,1$ a $0,3$ KOhms/cm 2) em lâminas de Acetato (20 micras), Poliéster (20 micras) e Poliseal (20 micras). Esses polímeros foram todos os materiais que apresentaram potencial para se tornarem a base do circuito e que estavam disponíveis para compra no mercado brasileiro, com maior facilidade. Antes de realizar a confecção do protótipo, alguns testes preliminares foram realizados para verificar: afinidade da tinta com cada tipo de polímero, fixação e resistência da tinta ao movimento, poder de cobertura da tinta. Na afinidade da tinta foi verificada se a tinta, ao entrar em contato com o polímero, iria apresentar adesão ou não e, ao secar, manteria a cobertura uniforme ou iria se retrair apresentando trincas ou descontinuidades. Na fixação e resistência ao movimento da tinta foi verificado se a lâmina pintada, ao ser levemente atritada (teste manual) ou curvada, se desprenderia da lâmina. Já o poder de cobertura da tinta pode variar conforme o polímero aplicado. Esse teste irá verificar quantas camadas de tinta são necessárias para o completo recobrimento do material. Para garantir uma camada mais uniforme na aplicação da tinta, foi utilizado um aerógrafo (*Wimpel*, 12V, com caneta de dupla ação e bico 0,30 mm, reservatório de 7 cm 3 , BRA) onde foi borrifado algumas camadas (de uma a cinco camadas) de tinta em cada um dos polímeros em teste. A Tabela 3.4 resume os critérios para a avaliação qualitativa das palmilhas fabricadas com uso de tinta condutiva.

Tabela 3.4: Critérios qualitativos para avaliação das palmilhas fabricadas com uso de tinta condutiva.

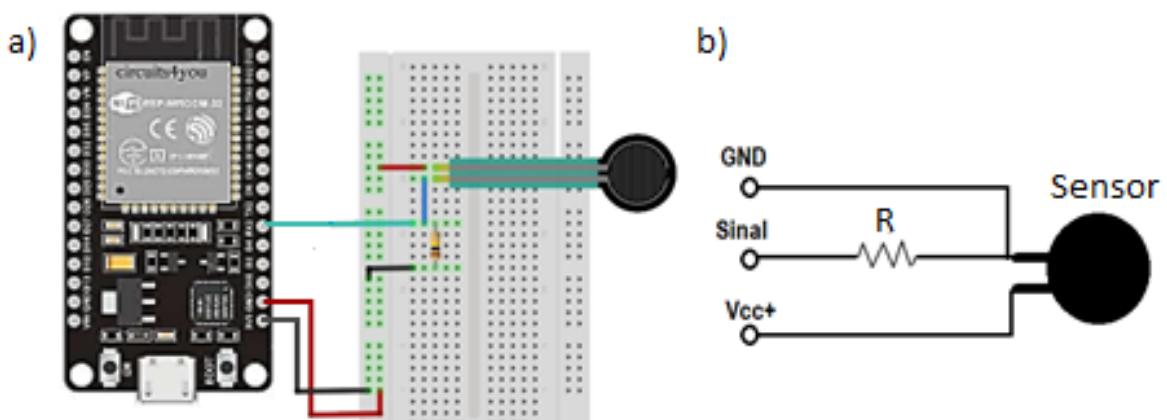
Critérios	Afinidade	Fixação	Resiliência
Bom	Quando a tinta se espalha sobre o material de forma uniforme. Ao secar, a tinta não apresenta trincas e regiões de falha.	Quando a tinta se mantém aderida após o material ser flexionado simulando o movimento do pé durante a marcha.	Quando a tinta se mantém aderida após atritado uma superfície de algodão exercendo uma força de aproximadamente 5kgf.
Ruim	Quando a tinta encontra dificuldade de aderir e espalhar tinta sobre o material. Ao secar, a tinta não apresenta uma camada uniforme, aparecendo trincas e regiões de falha.	Quando a tinta se desprende ou apresenta trincas após o material ser flexionado simulando o movimento do pé durante a marcha.	Quando a tinta se desprende da base após atritado uma superfície de algodão exercendo uma força de aproximadamente 5kgf.

3.2 Circuito de Aquisição de Dados

Considerando a escolha do microcontrolador, foi observado a superioridade do ESP-32 em relação ao Projeto Arduino. O ESP-32 foi escolhido para o processamento de sinais vindos da PS. Entretanto, o *software* de programação foi mantido o do Arduino, por ser gratuito, fácil aprendizado, elevado número de bibliotecas e possuir uma ampla comunidade de usuários.

Já a construção dos sensores localizados na PS são do tipo resistivo, portanto, são sensores passivos, ou seja, precisam ser energizados para seu funcionamento e a sua leitura baseia-se na variação da tensão disponível na porta de entrada. Desta forma, para realizar a leitura da PS se fez necessário a elaboração de um circuito para a interligação dos sensores ao microcontrolador. A Figura 3.10 demonstra o funcionamento básico para leitura dos sensores.

Figura 3.10: Montagem simplificada para leitura do sensor de força resistivo a)círculo de teste b)diagrama de ligação.

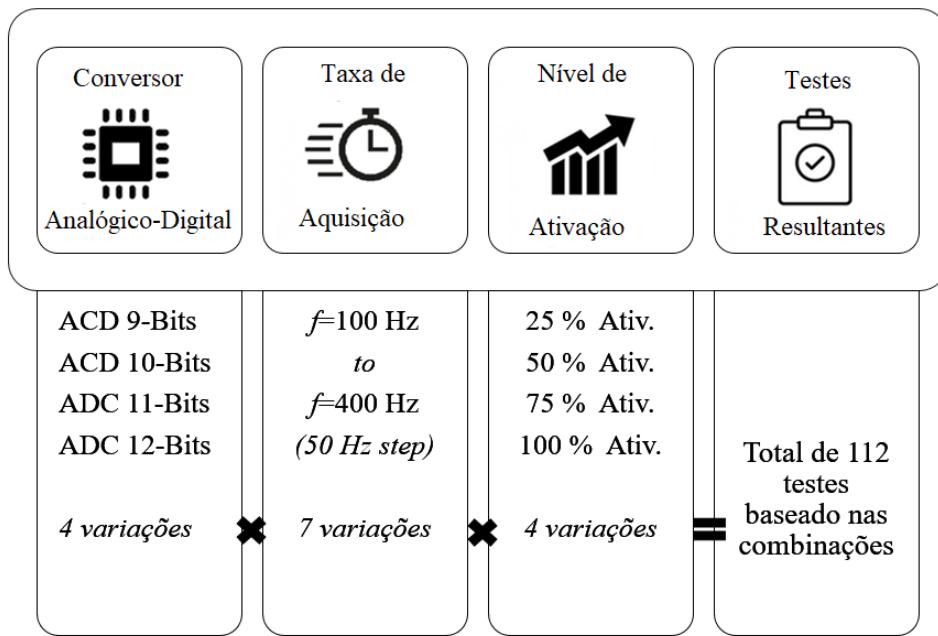


Fonte: Próprio Autor.

Com base na Figura 3.10, pode-se compreender que enquanto o sensor não é ativado, a porta de medição está aterrada (marcando 0 V), à medida que o sensor de força é acionado, permite-se uma passagem de uma corrente elétrica controlada pela intensidade da ativação do mesmo e a presença dessa corrente elétrica é percebida pela porta de leitura. Por meio de um conversor analógico-digital (ADC - *analog-digital converter*), essa informação é traduzida para a leitura e processamento do sinal por parte do microcontrolador. O ADC consegue representar um sinal analógico em uma escala de valores adimensionais que pode variar entre 0-256 (9 Bits ADC), 0-1024 (10 Bits ADC), 0-2048(11 Bits ADC) e 0-4096 (12 Bits ADC). Quanto maior a resolução do ADC, mais sensível ele se torna para efetuar a leitura dos sensores. Entretanto, o aumento da sensibilidade do

ADC pode trazer consigo o aumento da captação de ruídos, fazendo com que seja necessário a incorporação de filtros durante o processamento do sinal que podem influenciar no desempenho e velocidade do sistema. Para verificação do ACD mais apropriado, foi realizado um conjunto de medições utilizando um potenciômetro para simular diferentes faixas de saturação do sensor (25%, 50%, 75% e 100% da medição máxima da porta analógica) de maneira a manter a resistência do sistema constante e efetivar a medição do ruído de fundo. Outro fator que pode impactar nos ruídos registrados é a velocidade de leitura (taxa de aquisição). Os ruídos podem aumentar conforme se aumente a taxa de aquisição. Para a medição dos ruídos foi conduzido um experimento de 112 testes, composto por quatro variações no nível de atuação dos sensores (faixa de saturação), quatro tipos de ADC e sete diferentes taxas de aquisição, compreendendo o intervalo mínimo e máximo esperado pelo sistema. A Figura 3.11 mostra, de forma esquemática, as variações estabelecidas para os experimentos.

Figura 3.11: Mapa de testes para avaliação dos parâmetros do circuito de aquisição de dados



Fonte: Próprio Autor.

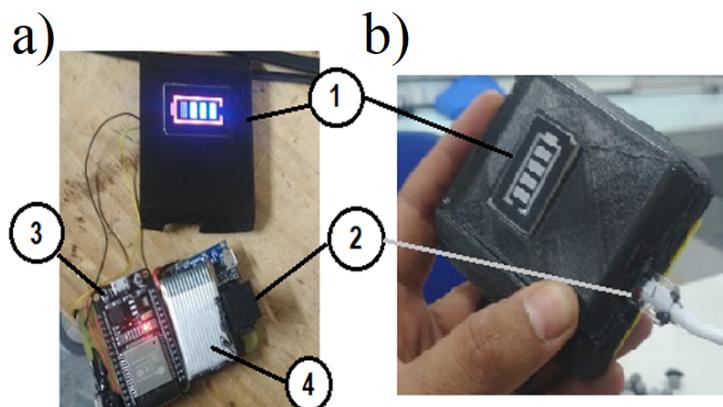
Para cada um dos testes foi registrado 1.000 leituras consecutivas. Esse conjunto de 1.000 dados configura uma amostra. Após a aquisição das amostras, foi aplicado um filtro para remoção de ruídos. A fim de restringir a complexidade dos testes e o número de experimentos, foi avaliado a influência de um filtro de média móvel, por se tratar de um filtro simples e recorrente na literatura [73] [74], tendo como parâmetro apenas o número de períodos. Cada uma das amostras foi submetida ao filtro de média móvel com períodos que variaram de dois a 10 (com incremento unitário). Para a análise, o ruído foi definido como sendo o coeficiente de variação amostral e, com essa série de experimentos,

foi avaliado as seguintes interações: influência da taxa de aquisição e o carregamento do sensor em cada ADC em relação ao coeficiente de variação e a média do sinal registrado, sem aplicação de filtro; a influência da aplicação de cada filtro nas amostras, variando os períodos do filtro. A fim de verificar o impacto em cada caso, foi utilizando o teste t pareado, bicaudal com intervalo de confiança de 95%. Após finalizar os testes com os ADCs, foi realiza uma ANOVA bifatorial sem repetições, variando a carga do sensor e a taxa de aquisição, para cada um dos filtros, considerando o coeficiente de variação como resposta. Os resultados dos testes serão apresentados no item 3.6 e de forma mais detalhada no Anexo 3 [REF - Artigo 3 a ser publicado].

3.3 Hardware de Aquisição de Dados

Uma vez definidos os requisitos do sistema (sensores, processador, ADC, circuitos), um protótipo do *hardware* foi fabricado, como mostra a Figura 3.12.

Figura 3.12: Protótipo do *hardware* de aquisição de dados a) Circuito eletrônico b) Invólucro do circuito eletrônico; 1- *Display* Mostrador do nível de bateria; 2- Conector para a Palmilha Sensorizada; 3- Microcontrolador ESP-32; 4- Bateria de lítio 3,7V.



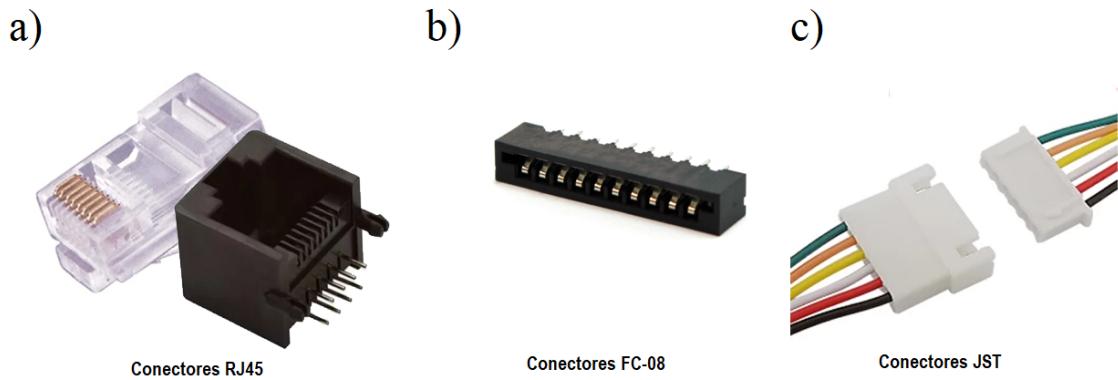
Fonte: Próprio Autor.

Para a interligação da placa de aquisição com a palmilha se faz necessário um conector que permita substituir a palmilha por diferentes numerações. Para isso, foram encontradas algumas opções de conectores disponíveis no mercado: RJ45 (Figura 3.13a), FC-08 (Figura 3.13b) e JST(Figura 3.13c).

Cada um dos conectores foi implementado na prática e testado quanto a sua funcionalidade e praticidade, sendo selecionado, com base nos testes, o mais adequado. O conector JST se demonstrou frágil após sucessivas trocas, apresentando quebra dos fios.

Já o conector FC-08 começou a danificar a palmilha após sucessivas trocas, além do fato de permitir situações de inversão de posição e mau posicionamento. O conector RJ45 se mostrou robusto em sucessivas trocas, portanto, mais apropriado para a aplicação.

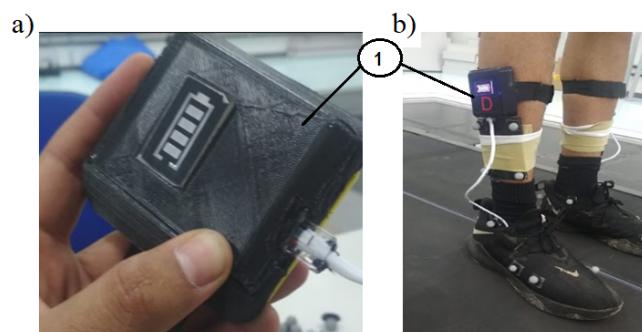
Figura 3.13: Tipos de conectores testados.



Fonte: Próprio Autor.

Para realizar os testes laboratoriais da PS, foi desenvolvida uma capa protetora para o circuito utilizado uma impressora 3D de filamento (PLA) com objetivo de acomodar o circuito e possibilitar a fixação do dispositivo ao corpo (Figura 3.14).

Figura 3.14: a)Envólucro do dispositivo e sua b) Fixação durante os testes.

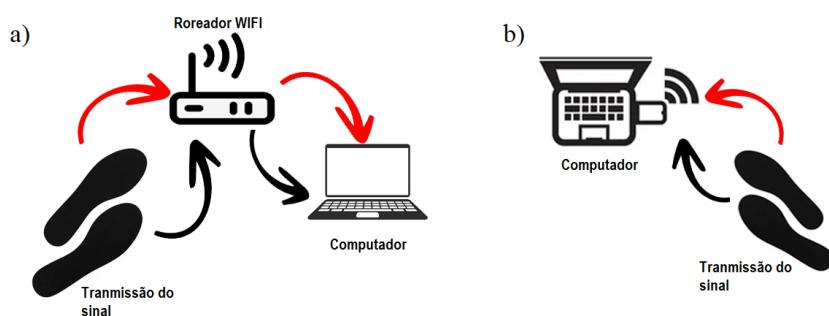


Fonte: Próprio Autor.

3.3.1 Desenvolvimento do *Firmware*

Uma vez finalizado o desenvolvimento do conjunto de *hardware* (sistema de aquisição e palmilhas sensorizadas) foi realizada a programação do microcontrolador (*firmware*), onde serão implementadas as rotinas de leitura e processamento de sinal, bem como a escolha e implementação do protocolo de comunicação entre o *hardware* e *software*. Essa comunicação pode ser realizada de duas formas diferentes: direta ou indireta. A comunicação direta realiza a conexão de cada uma das placas de aquisição (direita e esquerda) diretamente com o computador central (Figura 3.15) utilizando um protocolo TCP (*Transmission Control Protocol*), que permite a uma maior segurança na transmissão dos dados e uma confirmação de recebimento de cada pacote de informação. Essa característica é importante para a sincronização entre os lados por parte do sistema. Outros protocolos, como UDP (*User Datagram Protocol*) por exemplo, não garantem a entrega dos pacotes de dados [75] e, a cada pacote perdido, o sistema passa por uma progressiva perda de sincronia entre os lados. A comunicação indireta utiliza um módulo intermediário entre as placas de aquisição e o computador central (Figura 3.15). Esse módulo é responsável por manter a sincronia entre as placas de aquisição e pré-processar os sinais, formatando e entregando os dados de forma mais eficiente ao computador central por meio da entrada USB (comunicação serial).

Figura 3.15: Protocolos de comunicação WiFi testados para comunicação do sistema: a) TCP/UDP b) ESPNOW.



Fonte:Próprio Autor.

Para o desenvolvimento do *firmware*, foi selecionada a comunicação indireta por apresentar uma série de características favoráveis: facilidade de sincronia, configuração da rede e portabilidade do sistema. O microcontrolador ESP-32 possui um protocolo de comunicação WiFi próprio, o ESPNOW. Esse protocolo é similar ao protocolo *wireless* de baixa energia (2,4 GHz) amplamente utilizado em *mouses* e teclados sem fio. Esse protocolo permite comunicação *peer-to-peer*, permitindo maior facilidade a sincronização entre

as placas de aquisição. Esse protocolo não depende de uma rede WiFi existente, podendo manter uma configuração fixa de fábrica e operar em qualquer ambiente. Portanto, para cumprir a função de modem intermediário, foi utilizado uma placa de desenvolvimento contendo o ESP-32 e estabelecido uma comunicação serial com o computador central para a entrega dos dados. Um teste de velocidade foi realizado e o sistema atingiu uma taxa de aquisição máxima de 375 Hz.

3.4 Testes Preliminares

Após o desenvolvimento do *hardware* e *firmware*, o sistema já pode ser testado. Foi utilizado um *software* dedicado desenvolvido em C# para aquisição e armazenamento dos dados. Nessa etapa o sistema foi testado para verificar a repetibilidade das medições e durabilidade.

3.4.1 Consistência das medições

O processo de verificação de repetibilidade é uma das etapas de validação do instrumento de medição e exige um criterioso processo estatístico. Entretanto, como teste preliminar, deve-se: 1) verificar o potencial do sistema em realizar sucessivas medidas, sem que haja uma grande discrepância (maior que dois desvios padrão) entre as medições e 2) implementar ajustes e melhorias antes de proceder o procedimento de validação do instrumento. Nessa etapa foram verificados os dois tipos de palmilhas desenvolvidos na Seção 3.5, a primeira foi a PS com trilhas em tinta condutiva com base de Acetato (material que apresentou melhores resultados – Seção 5.2) e a segunda com as trilhas em cobre e com a base de Poliamida. Ambas as palmilhas não passaram por nenhum processo de calibração para esse teste. Os testes foram realizados utilizando três caminhadas de 1 min cada, com um voluntário do sexo masculino, 34 anos com IMC de 30,6 kg/m², sem histórico de lesões nos membros inferiores nos últimos 6 meses. O voluntário utilizou uma palmilha de cada tipo durante os testes (direita: PS em tinta condutiva, esquerda: PS em cobre).

3.4.2 Durabilidade

Para construção de um sistema de aquisição de dados baseado em palmilhas sensorizadas, um dos atributos desejados é a durabilidade. Como parâmetro de durabilidade, foi estipulado que a utilização média do instrumento seria de 1-2 min em uma consulta clínica. Como alvo, foi estabelecido que a duração mínima da PS seria de 4,5 h (uma média de seis atendimentos por dia, durante 30 dias em um tempo médio de 1,5 min por atendimento), atingindo cerca de 15.120 acionamentos por sensor (56 acionamentos por minuto, com base na cadência de 108 passos/min [76]). As palmilhas fabricadas foram expostas a um teste de caminhada durante 9 dias, com caminhadas de 0,5 h/dia (total de 4,5h de uso). Ao término de cada caminhada, foi feita uma verificação da integridade e funcionalidade da palmilha.

3.4.3 *Softwares de Aquisição*

O *software* de aquisição foi desenvolvido em C# (Figura 3.16), utilizando o Visual Studio 2019. A comunicação com o hardware é a Serial por meio da porta USB utilizando a biblioteca *MathNet.Numerics* [77] para o processamento dos dados, como aplicação de filtros e análise espectral no domínio da frequência com base na transformada de Fourier. A função do *software* é permitir a verificação do funcionamento de cada sensor, registrar as leituras da palmilha durante um tempo determinado, salvar os dados em um arquivo de texto (.txt) e exibir os dados visualmente.

Os dados gerados pelas palmilhas sensorizadas são armazenados em um arquivo de texto (.txt) e pode ser utilizado em diversos programas de análises, como MatLab, Excel, Minitab. O programa disponibiliza um relatório integrado ao Excel com um compilado de informações como: centro de pressão, tempo de duração e força média em cada fase da marcha, picos de força. Essas informações, além de serem importantes na caracterização da marcha, foram usadas na validação do equipamento (Seção 3.4) e utilização de técnicas de aprendizado de máquina (Capítulo 4).

Figura 3.16: Software de aquisição de dados.



Fonte: Próprio Autor.

3.5 Testes Experimentais e Validações

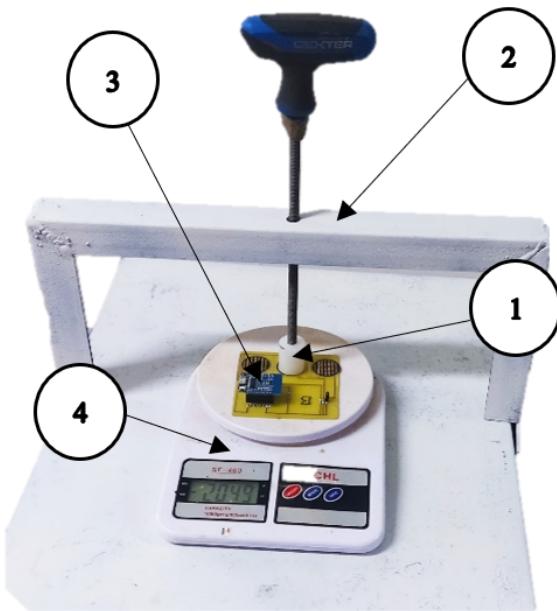
3.5.1 Calibração Estática

Foram fabricados dois conjuntos de palmilha para realização de testes. Cada um deles contém 9 pares, variando do número 35 ao 43, segundo a numeração brasileira. Cada uma das palmilhas foi colocada sobre uma balança de precisão (Balança SF-400, carga máxima 10 kg/1 g, China) onde cada sensor foi pressionado por um dispositivo (Figura 3.17) que permite a aplicação de uma força constante, aplicada em um intervalo de 0-8 kgf (com incremento de 2 kgf)[30].

Esse procedimento foi repetido três vezes para obtenção de um valor médio. Para cada sensor foi calculado um coeficiente de calibração utilizando uma regressão linear para relacionar o sinal elétrico obtido a uma carga em kgf [78].

Após a calibração estática das palmilhas, foi proposto um teste com 32 voluntários com objetivo de verificar a validade do instrumento, utilizando como referência uma esteira instrumentada com plataforma de força.

Figura 3.17: Dispositivo para realizar a calibração estática



Legenda: 1: Embolo para ativação dos sensores; 2: Estrutura para aplicação da força em cada sensor; 3: Sensores a serem calibrados; 4: Balança de precisão.

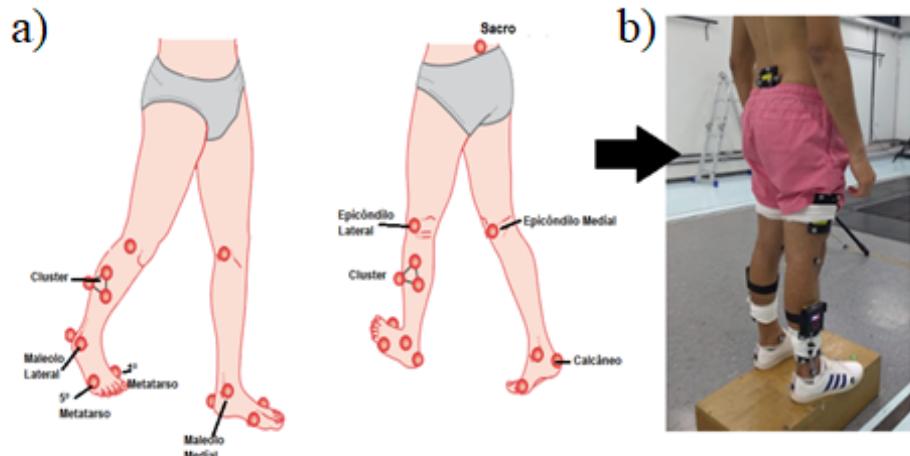
Fonte: Próprio Autor.

3.5.2 Teste com Voluntários

Este estudo foi aprovado pelo Comitê do Conselho Institucional de Pesquisa (CAAE 00890818.8.000.5149) (Anexo 2) e todos os voluntários assinaram um termo de consentimento livre e esclarecido para participação no estudo. Para a validação da PS foi proposto um teste utilizando um sistema optoeletrônico (SOE) (7 Oqus 5+ cameras, 100 Hz, Qualisys MEDICAL AB, Sweden) sincronizado com uma esteira bipartida, instrumentada com uma plataforma de força (Bertec at 1000Hz, Bertec Corp, Columbus, OH). O objetivo foi obter dados cinéticos e cinemáticos dos voluntários. Os voluntários realizaram uma caminhada de um minuto na esteira instrumentada utilizando, aleatoriamente, uma PS conforme sua numeração com marcadores reflexivos para captação de informações cinemáticas do complexo pé-tornozelo. Foram utilizados marcadores retros refletivos passivos de 14 mm, afixados em cada participante, sete no membro inferior de cada indivíduo. Os marcadores foram posicionados: na região central do calcâneo, cabeça do primeiro metatarso, cabeça do quinto metatarso, sobre o epicôndilo lateral do fêmur, sobre o epicôndilo medial do fêmur, sobre o maléolo lateral e o maléolo medial. Além disso, um cluster rígido com quatro marcadores retro refletivos passivos foi posicionado na região posterolateral no terço distal da perna, utilizando-se um elástico e fitas dupla face (Figura 3.18). Os posicionamentos dos marcadores foram definidos com base no modelo biomecânico de cones

rígidos para membros inferiores pré definido pelo *software* de captura de movimento.

Figura 3.18: Posicionamento dos marcadores para a captura de movimento: a) Referência para o posicionamento dos marcadores e b) Marcadores posicionados durante os testes.



Fonte: Próprio Autor.

Uma aquisição de dados em ortostatismo foi realizada por cinco segundos como base para criação do modelo biomecânico e servir como referência para as variações angulares. Posteriormente, os marcadores anatômicos nos epicôndilos foram removidos e realizada a aquisição da marcha. Os marcadores foram rastreados no programa *Qualisys Track Manager* (versão 2019.3, Qualisys MEDICAL AB, Suécia) e processados no programa *Visual3D™ x64 Professional* (v2020.02.04, C-Motion, EUA). O segmento do pé foi modelado como um cone rígido, definido anteriormente pelas marcas do metatarso e posteriormente pela marca do calcâneo. A perna foi modelada como um cilindro rígido, definido proximalmente pelas marcas dos epicôndilos e distalmente pelas marcas do maléolo. Para análise do movimento do complexo tornozelo-pé, foi considerado o plano frontal.

Foi calculado o tamanho da amostra usando um teste normal bivariado, bicaudal com coeficiente de Cohen $d=0,5$, $\alpha=0,05$ e poder igual a 0,80 usando o *software G-Power* (Versão 3.1), que resultou em um tamanho mínimo de amostra de 29 voluntários. Trinta e dois participantes foram recrutados para evitar prejuízos caso haja qualquer perda de dados durante os testes e pós-processamento. Foram empregados os seguintes critérios de inclusão: idade entre 18-45 anos, índice de massa corporal (IMC) entre 20 e 34,9 kg/m², sem qualquer distúrbio neurológico ou história de cirurgia recente (6 meses) lombar ou de membros inferiores. Como critério de exclusão foi adotado a prática de atividade física extenuante no dia de coleta ou alguma lesão que resultasse em dor no momento da avaliação, todavia, nenhum voluntário foi excluído por esses motivos. Esses participantes realizaram três repetições de caminhada de 1 minuto na esteira usando um conjunto de palmilhas sensorizadas, totalizando 192 amostras (três repetições de 64 testes, 32 considerando cada lado). A velocidade da marcha foi auto selecionada (média (DP): 1,0

(0,2) m/s). Antes dos testes, foi realizada uma caminhada de familiarização de 1 minuto. Os voluntários que relataram desconforto ou dificuldade na realização dos testes foram excluídos. Caso algum equipamento falhasse durante a medição ou tivesse alguma perda de dados durante o armazenamento das informações também seria removido segundo o critério de exclusão.

3.5.3 Calibração Dinâmica

A calibração dinâmica foi um método desenvolvido para complementar a calibração estática [79]. Para isso, foram utilizados os dados referentes ao teste com voluntários. Foi calculada uma curva média da vFRS com base em 30 passadas registradas pela PS e esteira instrumentada durante o teste. Essa curva média de reação do solo foi normalizada com base no peso corporal de cada indivíduo. A curva média da vFRS da PS é composta por sete séries temporais (X_i) relacionadas às sete regiões anatômicas fornecidas pela PS, somadas para calcular a vFRS, considerando os coeficientes de calibração estática (w_s) usando a Equação 3.4, onde é calculada a vFRS corrigida pela calibração estática (vFRSs):

$$\text{vFRSs} = \sum w_{si} X_i \quad (3.4)$$

Para a calibração dinâmica foi proposta a inclusão de um segundo coeficiente w_d responsável por ponderar a medida das forças e favorecer a correlação com a plataforma de força (Equação 3.5), resultando em uma vFRS corrigida dinamicamente (vFRSd). A calibração dinâmica foi aplicada considerando a numeração das palmilhas sensorizadas, sem diferenciar os lados direito e esquerdo ou os diferentes conjuntos de palmilhas utilizados durante os testes.

$$\text{vFRSd} = \sum w_{si} w_{di} X_i \quad (3.5)$$

Para obter w_d , foi utilizada uma técnica de otimização: Heurística de escalada com base no primeiro de melhora (*First Improvement Hill Climbing Heuristic*- Apêndice 2) [80] [81]. Essa técnica de otimização requer algumas parametrizações, como a definição de um espaço de busca, uma estrutura de dados para representar a resposta do algoritmo e um critério de avaliação que irá comparar as respostas obtidas e escolher a melhor. O espaço de busca foi arbitrariamente limitado entre 0,5 e 2. Isso significa que w_d pode assumir qualquer valor entre 0,5 e 2 enquanto o algoritmo busca um conjunto de valores que maximize a correlação com plataforma de força. Se os valores de w_d estiverem entre 0,5-1,0, a força registrada está sendo reduzida, e w_d entre 1,0-2,0 significa que a

força registrada está aumentando. O w_d pode corrigir situações em que a deformação do sensor tende a aumentar a medição do sensor, sendo necessário um w_d entre 0,5-1,0 para minimizar este efeito ou situações em que o centro de pressão não esteja perfeitamente alinhado com o sensor, exigindo um w_d entre 1,0 -2,0 a compensar as regiões cegas da palmilha. Um vetor de coeficientes $S = \{w_{d1}, w_{d2}, w_{d3}, w_{d4}, w_{d5}, w_{d6}, w_{d7}\}$ foi construído para representar as sete regiões de captura da palmilha. O algoritmo de otimização gera uma série de diferentes soluções (S) em seu processamento de dados. Cada uma dessas soluções foi utilizada na Equação 3.5 sendo obtido um possível resultado de calibração dinâmica. Cada amostra (com a mesma numeração) foi submetida à calibração proposta por esta solução S , e o resultado da vFRS modificada foi comparado com a plataforma de força. Essa comparação foi realizada por meio do EQM (Erro Quadrado Médio) entre as curvas de vFRS buscando minimizar o EQM. Uma estratégia *multi-start* foi adotada para diminuir a probabilidade do algoritmo ser limitado a encontrar ótimos locais [80] [81].

Cada solução S encontrada, que apresenta redução no valor de EQM, é armazenada pelo algoritmo até que seja impossível encontrar outra solução S que promova a redução do EQM, encerrando o processamento. Após o processamento do algoritmo, a solução encontrada foi aplicada na Equação 3.5 e corrigida a vFRS de todas as amostras e comparada com a plataforma de força. Foi utilizando os coeficientes de Pearson [82][83][84] e o Coeficiente de Múltiplas Correlações (CMC) [85] [86]. Para comparar a diferença entre os métodos de calibração estática e dinâmica, aplicou-se o teste t pareado para a média dos coeficientes CMC, Pearson e EQM [87] [88].

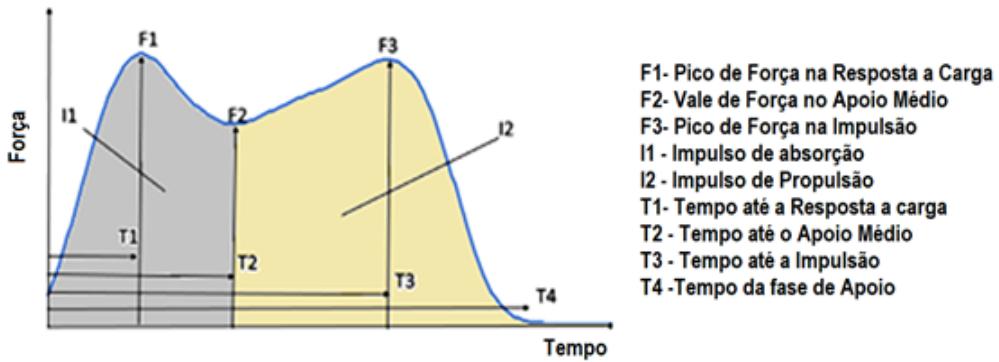
3.5.4 Verificação Cinética

A verificação cinética foi baseada na diferença estatística entre os instrumentos PS e esteira instrumentada e sua correlação. A diferença estatística foi verificada em três pontos da vFRS média (30 passadas) registradas pela PS e plataforma de força (Figura 3.19): I) pico de Resposta à Carga, II) pico de Impulsão e III) no vale do Apoio Médio. Foi utilizado o EQM como variável de verificação e aplicado o teste t pareado com nível de significância de 95%. A correlação dos dados foi realizada considerando toda a curva média da vFRS em 30 passadas registradas pela PS e plataforma de força. Foi utilizado o coeficiente de Pearson, Coeficiente de Múltiplas Correlações (CMC) e RMSE como estatísticas de validação.

3.5.5 Validação Temporal

A verificação temporal foi baseada na diferença estatística entre os instrumentos PS e plataforma de força. A diferença estatística foi verificada em três pontos da vFRS média (30 passadas) registradas pela PS e plataforma de força (Figura 3.19): I) Resposta à Carga, II) Apoio Médio e III) Impulsão (Apoio Terminal e Pré-Balanço). Foi utilizado o EQM como variável de verificação e aplicado o teste t pareado com nível de significância de 95%.

Figura 3.19: Gráfico de FRS e seus principais pontos de análise.



Fonte: Próprio Autor.

3.5.6 Verificação do Centro de Pressão (COP)

O centro de pressão é a posição média virtual da FRS atuando na planta do pé [89]. Geralmente começa um pouco longe da extremidade posterior do calcâneo [90] e viaja na sola do pé durante a fase de apoio em direção à cabeça do segundo metatarso [91]. Este caminho pode ser calculado com base nas Equações 3.6 e 3.7 [92].

$$COP_x(t) = \frac{\sum_{i=1}^{i=7} X_i Px_i}{\sum_{i=1}^{i=7} X_i} \quad (3.6)$$

$$COP_y(t) = \frac{\sum_{i=1}^{i=7} X_i Py_i}{\sum_{i=1}^{i=7} X_i} \quad (3.7)$$

Essas equações utilizam médias ponderadas com base na posição dos sensores (Px e Py) e das forças registradas pelos sensores (X_i), considerando o centro do calcâneo como origem do sistema de coordenadas [89]. Assim, foi possível verificar a posição inicial e

final do COP em cada fase, fornecendo informações quantitativas para avaliações clínicas. Por exemplo, a medialização ou lateralização do COP pode ser usada como indicador de pronação ou supinação do pé, respectivamente [66].

A verificação da validade do COP foi feita de duas formas distintas: discreta e contínua. A verificação pontual foi aplicada em três momentos: Resposta à Carga, Apoio Médio e Impulsão (Apoio Terminal e Pré-Balanço). Foi calculada a média do COP no eixo X (médio-lateral) utilizando os dados obtidos de 30 passadas registradas pela PS e plataforma de força. Foi utilizado o EQM como variável de validação e aplicado o teste t pareado com intervalo de confiança de 95%. A validação contínua foi realizada também no Eixo X, utilizando a curva média de 30 passadas registradas pela PS e plataforma de força. Foi utilizado o coeficiente de Pearson, Coeficiente de Múltiplas Correlações (CMC) e EQM como variáveis de validação (conforme foi apresentado mais adiante na Tabela 3.10).

3.6 Resultados do Desenvolvimento da Palmilha Sensorizada

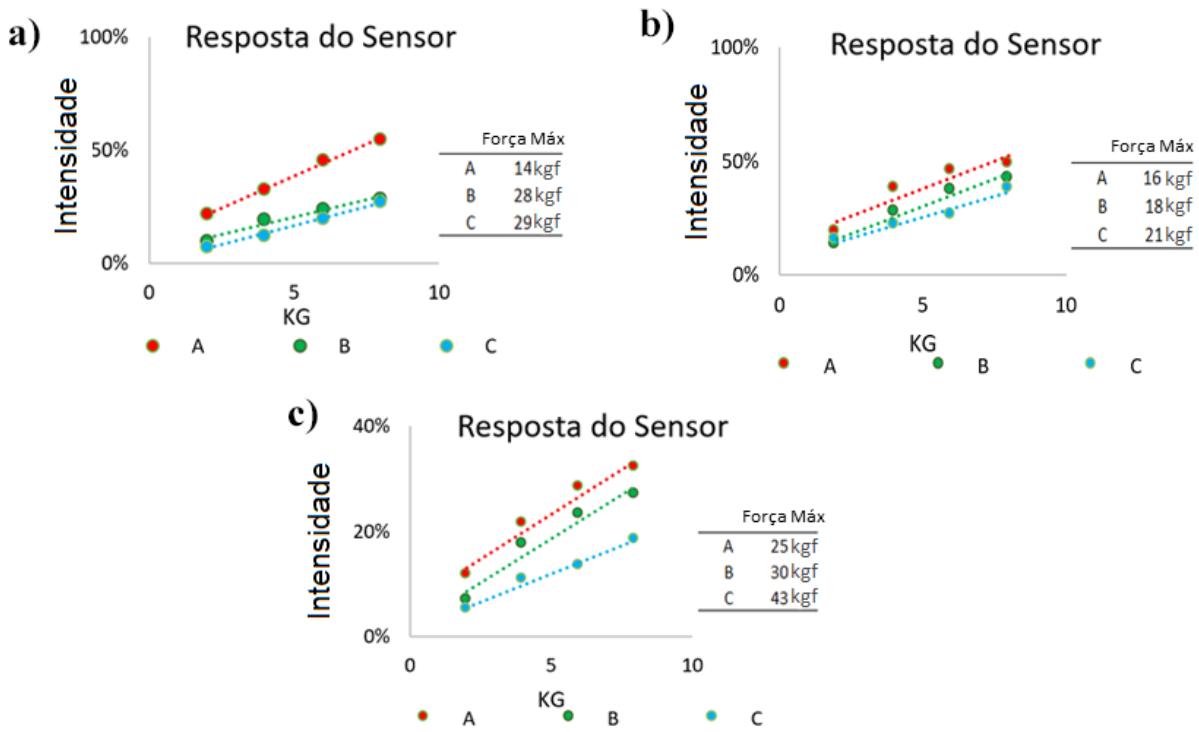
3.6.1 Parametrização dos Sensores de Força

Após a realização dos testes propostos anteriormente, foram encontrados os comportamentos mostrados pela Figura 3.20 a respeito da variação dos parâmetros construtivos dos sensores.

A Tabela 3.5 apresenta os resultados estimados da capacidade de medição máxima de cada um dos sensores considerando a aplicação nas PS de menor (35) e maior numeração (43).

Com base nesses indicadores, os sensores A das placas A e C e todos os sensores da placa B não poderiam ser utilizados, pois não oferecem cobertura para a faixa de peso desejado. Os sensores B e C da placa C apresentam elevada capacidade de medição durante a Impulsão. Essa característica pode reduzir a sensibilidade dos sensores durante a Impulsão, subestimando as cargas e por isso foram descartadas essas configurações. Os sensores B e C da placa B são sensores de comportamento semelhante e ambos são boas escolhas para integrar a PS. Dessa forma, a escolha do sensor B da placa A foi realizada arbitrariamente.

Figura 3.20: Curva de resposta do sensor com base no carregamento aplicado a) Dispositivo A; b) Dispositivo B; c) Dispositivo C.



Fonte: Próprio Autor.

Tabela 3.5: Resumo do resultado de cada um dos sensores testados.

Placa	Sensor	AC	Resp. Carga		Impulsão
			CMM (kgf)	AC	
A	A		39-64		76-104
	B		79-128		152-207
	C		82-133		157-215
B	A		45-73		87-119
	B	89%-55% (n35-n43)	51-83	62%-45% (n35-n43)	98-133
	C		59-96		114-156
C	A		70-115		135-185
	B		84-138		163-222
	C		121-197		233-318

Legenda: AC: Área de Cobertura; CMM: Capacidade de Medição Máxima.

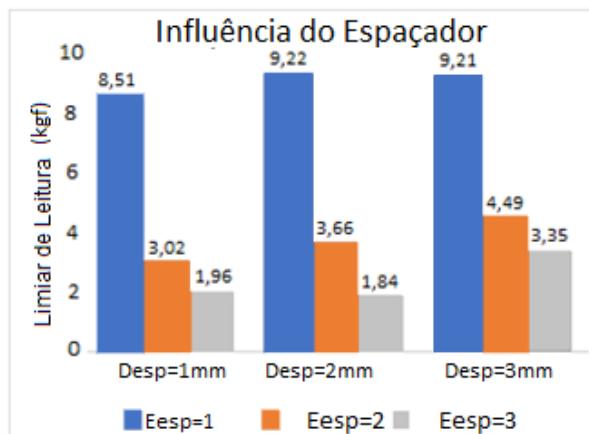
3.6.2 Espaçadores

Após a realização dos testes propostos na Seção 3.1.4, foram encontradas as informações sobre a influência dos espaçadores em relação ao limiar de leitura dos sensores (Figura 3.21). O limiar de leitura dos sensores pode influenciar a mensuração da vFRS durante o Apoio Médio. Nessa fase, a descarga de peso tem a distribuição máxima da carga na superfície plantar, reduzindo o carregamento em cada um dos sensores. Somado

a esse fator, durante o Apoio Médio, a vFRS pode chegar a 80% do peso corporal devido ao movimento [39]. Caso o limiar de leitura dos sensores seja alta, pode não ocorrer seu acionamento durante o Apoio Médio.

A Tabela 3.6 apresenta os resultados estimados da capacidade de medição mínima de cada um dos espaçadores considerando a aplicação nas PS de menor (35) e maior numeração (43).

Figura 3.21: Variação da inércia dos sensores em cada tipo de espaçador.



Legend: E_{esp} : Espessura do espaçador; D_{esp} : Distância interna entre os espaçadores.

Fonte: Próprio Autor.

Tabela 3.6: Resumo do resultado de cada um dos espaçadores testados.

Apoio Médio			
E_{esp}	D_{esp}	AC	CMmin (kgf)
1.0 mm	1.0 mm		166-235
2.00mm	1.0 mm		59-83
3.00mm	1.0 mm		38-54
1.0 mm	2.00mm		180-254
2.00mm	2.00mm	77%-55% (n35-n43)	71-101
3.00mm	2.00mm		36-51
1.0 mm	3.00mm		180-254
2.00mm	3.00mm		88-124
3.00mm	3.00mm		65-92

Legenda: E_{esp} : Espessura o espaçador; D_{esp} : Distância ente os Espaçadores; AC: Área de Cobertura; CM_{min}: Capacidade de Medição Mínima.

Com base na Tabela 3.6 e na média do peso populacional (IBGE), os únicos espaçadores que não promoveriam perda da capacidade de registrar a vFRS durante o Apoio Médio são os com espessura de 3,0 mm e distanciamento de 1,0 mm ou espessura de 3,0 mm e distanciamento de 2,0 mm. Foi adotada a primeira opção por apresentar menores valores de limiar de leitura.

Tabela 3.7: Resumo de todas as características definidas em relação ao *layout* preliminar da Palmilha Sensorizada.

Tabela Resumo dos Parâmetros da Palmilha

Tipo de Sensor:	Resistivo	N. de Sensores:	12
Diâm. Sensor:	22,5 mm	Carga Máx. por sensor:	28 kgf
Esp. da Trilha:	1,00 mm	Numeração	35-43
Dist. entre Trilhas:	2,00 mm	Faixa de operação:	38 kg – 133 kg
Esp. do Espaçador:	3,00 mm		
Dist. do Espaçador:	2,00 mm		

A Tabela 3.7 apresenta um resumo dos parâmetros de construção das PS definidos: tipo de tecnologia a ser utilizada; intervalo de numeração; quantidade de sensores; posição dos sensores; diâmetro dos sensores; espessura das trilhas; espaçamentos das trilhas; capacidade de carga por sensor; capacidade estimada de carga;

3.7 Fabricação da Palmilha Sensorizada

Após o processo de fabricação, foi observado que a PS em cobre apresentou uma alta flexibilidade, a ponto de comprometer a utilização do circuito, dificultando a inserção no calçado e manuseio do equipamento (Figura 3.22a). Como tentativa de solução desse problema, foi realizado um processo de lamination polimérica a quente utilizando Poliseal, onde o circuito passa a ser envelopado pelo Poliseal e atingiu a rigidez necessária para inserção no calçado com facilidade (Figura 3.22b).

Figura 3.22: Ganho de rigidez da PS após a lamination com Poliseal: a)Circuito após o processo de corrosão, b) Lamination a quente com Poliseal e c) Circuito laminado com ganho de rigidez.

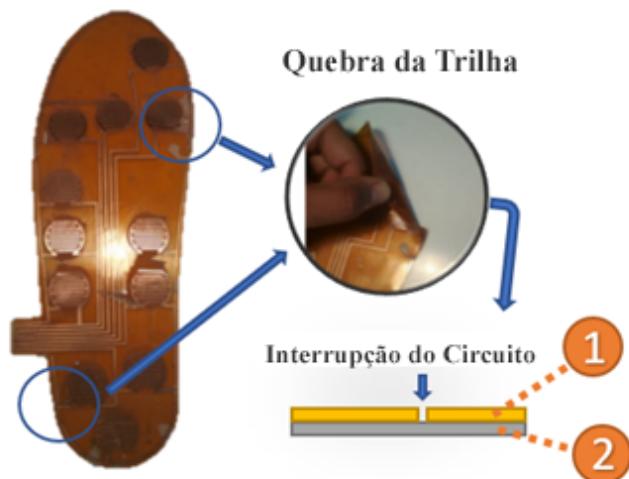


Fonte: Próprio Autor.

Entretanto, esse protótipo apresentou uma série de problemas que inviabilizam essa solução. Um grande desconforto durante os primeiros testes devido à dificuldade

de conformação da palmilha no calçado, criando regiões de dobra que, além de gerar desconforto, acabou forçando as trilhas e as levando à quebra (Figura 3.23). Além disso, a superfície lisa fez com que ocorressem deslizamentos do pé em relação à palmilha, levando a instabilidades durante o movimento.

Figura 3.23: Regiões críticas de quebra da palmilha devido ao excesso de rigidez da palmilha.



Legenda: 1: Trilha condutora em cobre; 2:Base em Poliamida.

Fonte: Próprio Autor .

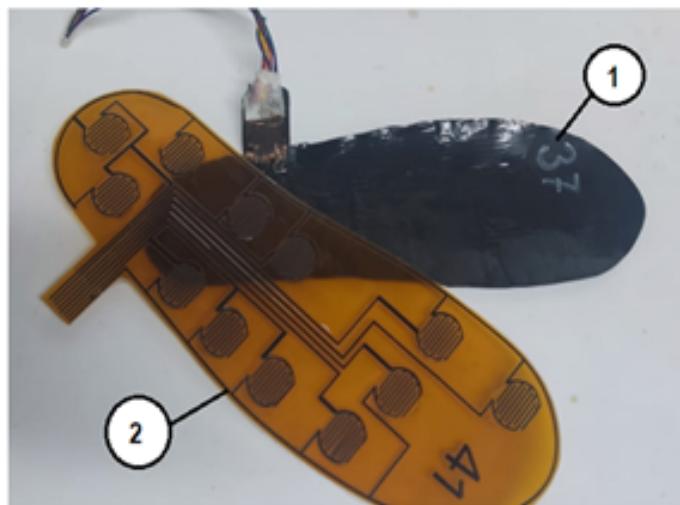
Esses fatores fizeram com que uma nova solução para rigidez fosse proposta, adicionando uma camada de EVA de 3,0 mm com dureza ShoreA 30 na parte inferior da palmilha em substituição a própria palmilha do calçado. Segundo Klimiec *et al.* [11], essa camada rígida adicional é uma “solução técnica para evitar o estiramento do filme para garantir a medição correta das forças contra o substrato”. Essa solução garantiu a rigidez necessária para fácil inserção e remoção do calçado, além da padronização da interface pé/calçado, uma vez que cada calçado apresentava uma palmilha com diferentes materiais. Na parte superior foi adicionada uma camada de vinil (Figura 3.24) para isolar o contato entre as trilhas com o usuário, sendo que o vinil não apresentou o deslizamento do pé como relatado anteriormente com o Poliseal. Esse modelo foi encaminhado para os testes preliminares de durabilidade e efetividade.

Já a PS em tinta condutiva não apresentou essa alta flexibilidade semelhante a PS em cobre. A Figura 3.25 mostra a PS em tinta condutiva.

Conforme proposto, foram testadas as bases em Acetato (20 micras), Poliéster (20 micras) e Poliseal (20 micras) e avaliados quanto a: afinidade da tinta com cada tipo de polímero, fixação e resistência da tinta ao movimento, poder de cobertura da tinta. A Tabela 3.8 apresenta o resultado dos testes qualitativos propostos.

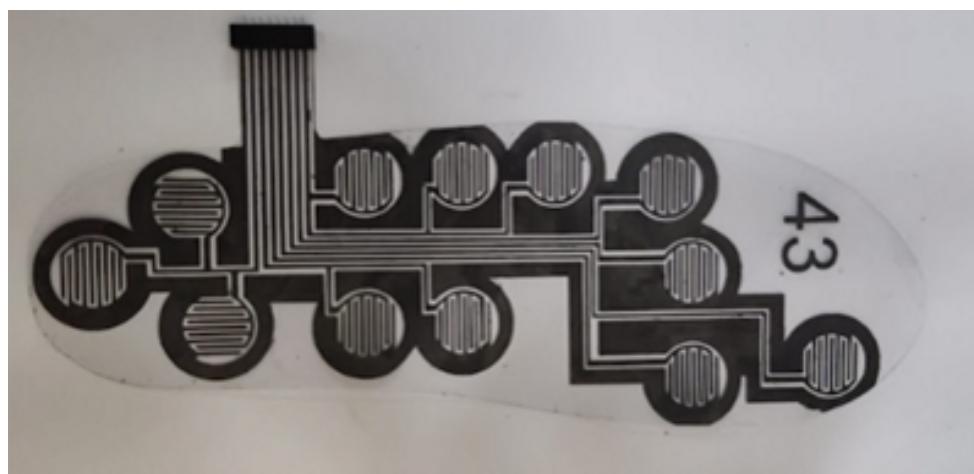
Com base nos testes relatados na Tabela 3.8, apenas o teste envolvendo o Acetato

Figura 3.24: Aplicação de uma camada vinílica de proteção da parte superior da PS; 1) PS com cobertura; 2) PS sem cobertura.



Fonte: Próprio Autor.

Figura 3.25: Palmilha Sensorizada com circuito fabricado em tinta condutível de grafeno e base em Acetato.



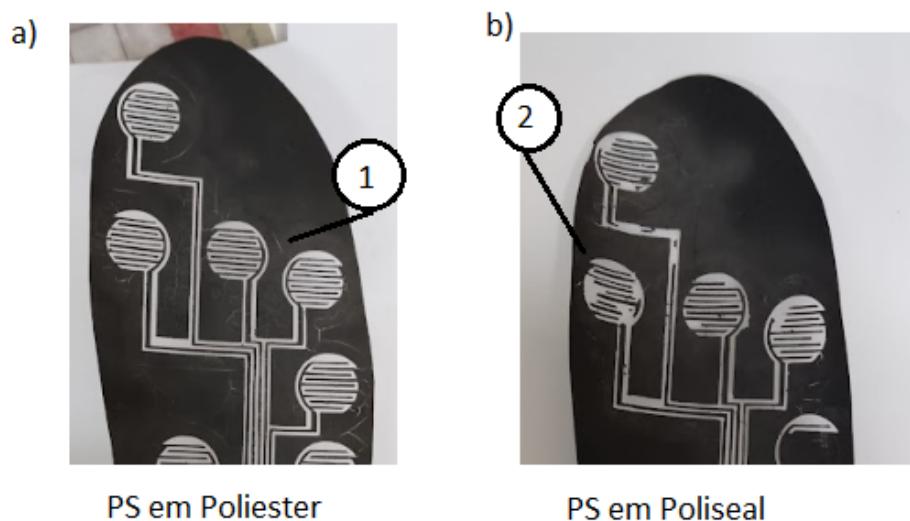
Fonte: Próprio Autor.

mostrou-se promissor e avançou para confecção da palmilha protótipo sendo encaminhado para os testes preliminares de durabilidade e efetividade, que estão descritos na Seção 3.8. A Figura 3.26 mostra os defeitos encontrados nas palmilhas com base em Poliseal e Poliéster.

Tabela 3.8: Resumo dos testes utilizando a tinta condutiva de grafeno e sua interação com cada material: Acetato (A), Poliéster (B), Poliseal (C).

N. de Camadas	Afinidade			Fixação			Resistência a Abrasão		
	A	B	C	A	B	C	A	B	C
1	Bom	Bom	Ruim	Bom	Ruim	Bom	Bom	Ruim	Ruim
2	Bom	Bom	Ruim	Bom	Ruim	Bom	Bom	Ruim	Ruim
3	Bom	Bom	Ruim	Bom	Ruim	Bom	Bom	Ruim	Ruim
4	Bom	Bom	Ruim	Bom	Ruim	Bom	Bom	Ruim	Ruim
5	Bom	Bom	Ruim	Bom	Ruim	Bom	Bom	Ruim	Ruim

Figura 3.26: Defeitos de fabricação das palmilhas utilizando tinta condutiva e descartadas durante os testes. a) Trincas e interrupções da trilhas. b) Trilhas desprendendo-se por baixa adesão.



Legenda: 1: Aprecimento de trincas; 2: Destacamento da tinta por falta de adesão.
Fonte: Próprio Autor.

3.8 Circuito de Aquisição de Dados

Após a realização dos testes propostos, foram avaliados os níveis de ruído em diferentes carregamentos do sensor (25%, 50%, 75% e 100% do limite de medição). A Tabela 3.9 apresenta uma síntese dos resultados obtidos considerando um valor médio do coeficiente de variação nos diferentes carregamentos, variando a taxa de aquisição em cada ADC.

Após finalizar os testes com os ADCs foi realizado um teste de ANOVA bifatorial sem repetições (filtros e carga dos sensores), considerando o coeficiente de variação (baseado no teste f). A Tabela 3.10 apresenta os valores f obtidos na ANOVA. Em todos os casos, o coeficiente de variação do nível de carregamento dos sensores apresentou $f > f_{\text{crítico}}$. Isso significa que as médias do grupo são maiores que a variabilidade das

observações nos grupos, portanto as médias não são iguais, indicando uma significativa variação do coeficiente de variação (que nesse trabalho foi associado como ruído). Ou seja, o ruído é influenciado pelo nível de ativação dos sensores. Os ADC de 11-Bits e 12-Bits apresentaram $f < f$ -crítico. Esse resultado indica que ADCs com maior resolução passam a não influenciar significativamente no ruído (Apêndice 3 - Artigo submetido).

Tabela 3.9: Resumo dos resultados obtidos de coeficiente de variação (média considerando os carregamentos) com base nas variações da taxa de aquisição em cada ADC.

	9-Bits	10-Bits	11-Bits	12-Bits
$f=100\text{Hz}$	0.65%	0.62%	0.62%	0.62%
$f=150\text{Hz}$	0.59%	0.53%	0.54%	0.48%
$f=200\text{Hz}$	0.54%	0.52%	0.51%	0.54%
$f=250\text{Hz}$	0.56%	0.50%	0.51%	0.50%
$f=300\text{Hz}$	0.54%	0.53%	0.47%	0.47%
$f=350\text{Hz}$	0.55%	0.52%	0.51%	0.58%
$f=400\text{Hz}$	0.52%	0.51%	0.60%	0.53%

Tabela 3.10: Resumo da significância estatística segundo do coeficiente de variação por meio da ANOVA bifatorial.

	C_{sensor}		f	
	f	f crítico	f	f crítico
9-Bits	96.15	3.16	5.05	2.66
10-Bits	88.42	3.16	11.15	2.66
11-Bits	39.02	3.16	2.60	2.66
12-Bits	10.39	3.16	1.13	2.66

Legenda: C_{sensor} :Carga do sensor.

Com a aplicação do filtro de média móvel, houve uma mudança do comportamento dos dados, alterando os resultados encontrados na Tabela 3.11. Foi encontrado um período (P) mínimo para o filtro de média móvel de forma que os todos os ADCs apresentem $f < f$ -crítico considerando o nível de ativação dos sensores e a resolução dos ADCs. A Tabela 3.11 apresenta um resumo da aplicação dos filtros com os períodos mínimos.

Uma das preocupações do uso de filtros para redução de ruídos é o impacto na leitura nominal dos valores, de forma que quanto maior a atuação do filtro (maiores valores de P), maior será essa influência. A Tabela 3.12 apresenta um resumo do impacto da atuação dos filtros nas medições do sistema por meio do teste t pareado (Apêndice 3). Foi medido os valores médios registrados em cada nível de carregamento dos sensores (25%, 50%, 75% e 100%) antes e depois da aplicação dos filtros. Apesar de observado uma queda dos valores médios devido atenuação (QA), o p-valor se manteve inferior a 0,05.

Tabela 3.11: Resumo do efeito da aplicação de filtro na significância estatística do coeficiente de variação segundo ANOVA.

		Sem Filtro			Com Filtro		
		f	f-critico	P	f	f-critico	
9-Bits	f	5.05	2.66	8	1.57	2.66	
	C_{sensor}	96%	3.16		0.88	3.16	
10-Bits	f	11.15	2.66	7	0.59	2.66	
	C_{sensor}	88.42	3.16		2.01	3.16	
11-Bits	f	2.6	2.66	6	1.04	2.66	
	C_{sensor}	39.02	3.16		2.07	3.16	
12-Bits	f	1.13	2.66	4	1.05	2.66	
	C_{sensor}	10.39	3.16		0.92	3.16	

Legenda: C_{sensor} : Carga do Sensor.

Tabela 3.12: Resumo do efeito da aplicação de filtro na significância estatística da média amostra segundo Teste t.

	C_{sensor}	MM sem Filtro (mV)	MM com filtro (mV)	QA	p-valor
9-Bits	0,25	754	753	-0,11%	p<0,05
	0,5	1482	1481	-0,11%	p<0,05
	0,75	2256	2253	-0,11%	p<0,05
	1	2972	2969	-0,11%	p<0,05
10-Bits	0,25	750	750	-0,04%	p<0,05
	0,5	1503	1502	-0,04%	p<0,05
	0,75	2241	2240	-0,04%	p<0,05
	1	2986	2984	-0,04%	p<0,05
11-Bits	0,25	756	754	-0,28%	p<0,05
	0,5	1496	1491	-0,28%	p<0,05
	0,75	2250	2244	-0,28%	p<0,05
	1	2963	2955	-0,28%	p<0,05
12-Bits	0,25	761	760	-0,08%	p<0,05
	0,5	1502	1501	-0,08%	p<0,05
	0,75	2257	2255	-0,08%	p<0,05
	1	2970	2967	-0,08%	p<0,05

Legenda: C_{sensor} : Carga do Sensor; MM: Medição Média; QA: Queda por Atenuação.

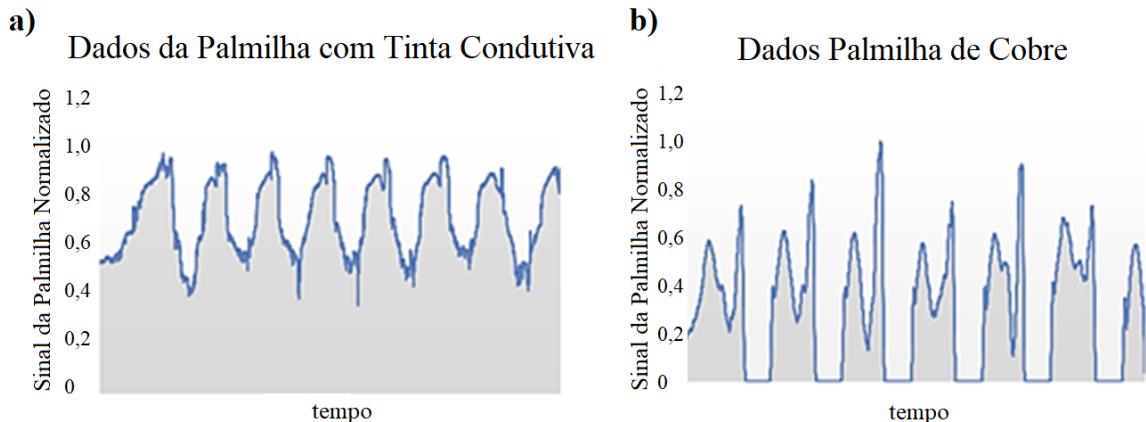
Com base nos resultados obtidos, foi escolhido o ADC de 12-Bits, com filtro de média móvel de quatro períodos, porque apresenta menor uso de filtros e maior sensibilidade de medição.

3.9 Testes Preliminares do Circuito de Aquisição

3.9.1 Consistência das medições

Após realizado o teste preliminar proposto, foi descartada a PS em tinta condutiva, pois ela apresentou uma resposta que pouco refletia a vFRS se comparado com a PS em cobre. Esse resultado fez com que a PS em tinta condutiva fosse descartada e fosse adotada a PS em cobre para a continuidade do desenvolvimento (Figura 3.27).

Figura 3.27: Resultado dos testes de aplicação da PS em cobre e PS em tinta condutiva.



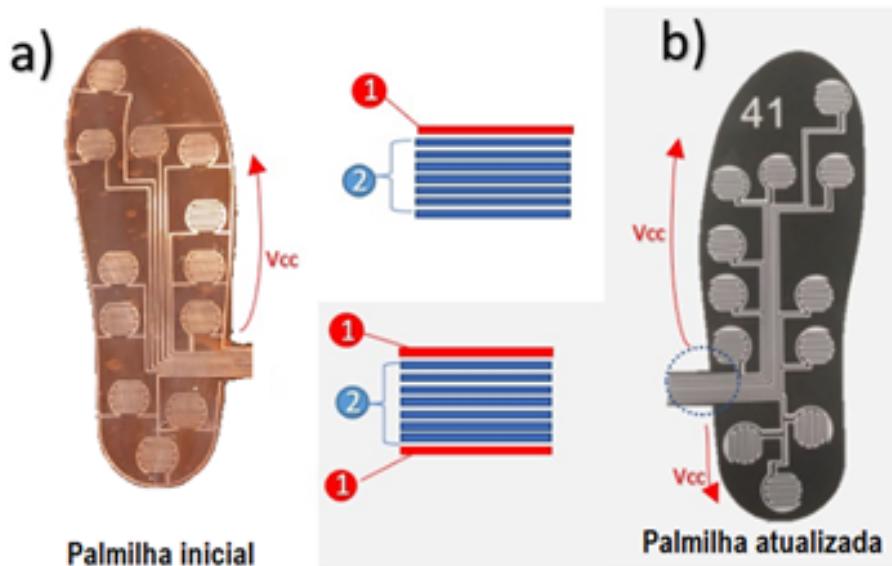
Fonte: Próprio Autor.

3.9.2 Durabilidade

Após realizados os testes propostos foi verificado que as PS alcançaram uma duração média inferior a 60 min. Isso ocorreu devido a sucessivas quebras nas trilhas de alimentação do circuito na região do calcâneo e cabeça do quinto metatarso (Figura

3.23) interrompendo o funcionamento da palmilha. Para corrigir esse problema foram propostas duas soluções: aumento da espessura das trilhas e criação de redundância nas trilhas de alimentação. A Figura 3.28 mostra o resultado do processo de melhoria da palmilha.

Figura 3.28: Mudança do design das PS com a inclusão de redundância do circuito para evitar interrupção do funcionamento caso ocorram quebras durante os testes.



Legenda: Vcc: *Voltage at the Common Collector* (Polo Positivo)
Fonte: Próprio Autor .

O novo modelo da PS foi testado em esteira ergométrica durante 9 dias utilizando 3 voluntários (homem de 34 anos e IMC de 30,6 kg/m², mulher de 35 anos e IMC de 23,71 kg/m², homem de 44 anos e IMC de 33,95 kg/m²) sem histórico de lesões nos membros inferiores nos últimos 6 meses. Em cada teste foi ajustado uma velocidade de conforto para marcha conforme o voluntário. Foi realizada uma caminhada de 30 min por dia e ao fim de cada teste a palmilha teve seu funcionamento verificado. Nenhuma palmilha apresentou interrupção quanto ao funcionamento, sendo encerrado os testes ao atingir 4,5 h de funcionamento.

3.10 Calibração Dinâmica

Após a realização dos procedimentos propostos, foi obtida uma curva de vFRS corrigida dinamicamente, com a correlação otimizada com a plataforma de força. A Tabela 3.13 mostra a distribuição dos participantes e o resultado da aplicação da calibração

estática e dinâmica para os dados de vFRS. A Tabela 3.13, também permite calcular a diferença dos coeficientes CMC, Pearson e EQM após calibração dinâmica.

Durante o processamento dos dados, algumas amostras adquiridas durante o teste da plataforma de força tiveram que ser descartadas por falha na aquisição dos dados: quebra da palmilha (6 amostras) e falha na transmissão dos dados (8 amostras), totalizando uma perda de 7,81% no banco de dados, restando 177 amostras das 192 iniciais (32 voluntários com 3 caminhadas de 1 min cada – pé esquerdo e direito). Essa perda não foi expressiva a ponto de invalidar os resultados ou haver necessidade de refazer os testes.

Tabela 3.13: Tabela comparativa entre calibração estática e calibração dinâmica.

Numeração	Amostras	Calibração Estática			Calibração Dinâmica		
		Pearson	CMC	EQM	Pearson	CMC	EQM
36	35	0,65	0,80	0,36	0,73	0,92	0,34
37	20	0,81	0,85	0,28	0,86	0,84	0,25
38	45	0,73	0,85	0,32	0,77	0,87	0,30
39	13	0,72	0,94	0,34	0,76	0,91	0,32
40	17	0,75	0,88	0,31	0,84	0,79	0,25
41	24	0,70	0,88	0,33	0,75	0,88	0,30
42	18	0,85	0,90	0,23	0,86	0,89	0,22
43	5	0,65	0,84	0,34	0,66	0,85	0,33
Média	-	0,73	0,87	0,31	0,78	0,88	0,29
Desv. Padrão		0,07	0,04	0,04	0,07	0,04	0,04

Legenda: CMC: Coeficiente de Multiplas Correlações; EQM: Erro Quadrático Médio.

Tabela 3.14: Tabela de resultados comparativos de Coeficiente de Variação e IC95% entre e aplicação de calibração estática antes e após calibração dinâmica complementar.

Numeração	Coeficiente de Variação			IC95%		
	EI	PSCE	PSCD	EI	PSCE	PSCD
36	0,11	0,06	0,06	0,105-0,117	0,058-0,062	0,058-0,062
37	0,03	0,09	0,07	0,022-0,038	0,088-0,092	0,067-0,073
38	0,02	0,08	0,08	0,013-0,027	0,078-0,082	0,078-0,082
39	0,03	0,07	0,08	0,022-0,038	0,067-0,073	0,077-0,083
40	0,03	0,06	0,05	0,022-0,038	0,058-0,062	0,048-0,052
41	0,02	0,06	0,07	0,013-0,027	0,058-0,062	0,067-0,073
42	0,03	0,05	0,06	0,023-0,037	0,047-0,053	0,057-0,063
43	0,03	0,05	0,06	0,022-0,038	0,048-0,053	0,057-0,063
Média	0,04	0,07	0,07	-	-	-
Desv. Padrão	0,03	0,01	0,01	-	-	-

Legenda: EI: Esteira Instrumentada; PSCE: Palmilha Sensorizada com Calibração Estática; PSCD: Palmilha Sensorizada com Calibração Dinâmica; IC: Índice de Confiabilidade.

A Tabela 3.14 apresenta os resultados do Coeficiente de Variação e IC95% (Índice de Confiabilidade de 95%) em cada numeração da PS. Pode-se observar que o Coeficiente

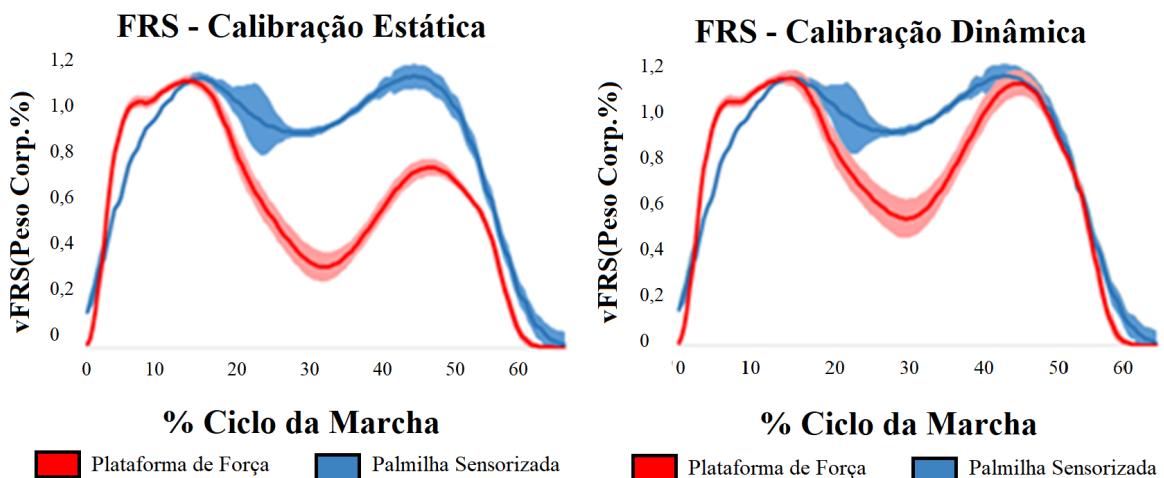
de Variação e IC95% não foram alterados, considerando ambas as calibrações, indicando que a calibração dinâmica não aumentou a variabilidade dos dados.

A Figura 3.29 mostram uma comparação qualitativa entre a plataforma de força e a PS usando calibração estática e calibração dinâmica, demonstrando a melhora da correlação entre as curvas.

3.11 Verificação Cinética

A Tabela 3.15 apresenta os resultados das verificações propostas na Seção 3.4.4. A Tabela 3.15 apresenta os resultados médios obtidos com base nas 177 amostras obtidas em todos os testes realizados com voluntários. Foi observado diferença estatística relevante no vale da vFRS no Apoio Médio, pico de força na Impulsão, COPx no Apoio Médio e Impulsão. Isso significa que a média dos valores registrados entre PS e plataforma de força apresentam diferenças significativas. Qualquer análise realizada utilizando a PS, nesses pontos, deverão ser conduzidas com cuidado, pois não poderão ser associadas a um comportamento de uma plataforma de força.

Figura 3.29: Comparação qualitativa do ganho de correlação proporcionado pela calibração dinâmica



Fonte: Próprio Autor.

Tabela 3.15: Validação das variáveis cinéticas.

Verificação Discreta (Pontos de Interesse)		RMSE	p-valor
Pico de força na Resp. a Carga (F1)	2,34	0,0165	
Vale de força no Apoio Médio(F2)	6,08	0,0760	
Pico de Força na Impulsão (F3)	5,38	0,095	
COPx (Resposta à Carga)	0,057	0,0432	
COPx (Apoio Médio)	0,118	0,0821	
COPx (Impulsão)	0,214	0,3123	
Verificação Contínua (Toda a Curva)			
		Pearson	EQM
COP X		0,82	0,21
FRS		0,78	0,29
			0,93
			0,88

Legenda: COPx:Centro de pressão em X (Medio-lateral); EQM: Erro Quadrático Médio; CMC: Coeficiente de Multiplas Correlações.

3.12 Verificação Temporal

A Tabela 3.16 apresenta os resultados das verificações propostas na Seção 3.4.5, referentes às variáveis temporais com base nas 177 amostras obtidas em todos os testes realizados com voluntários. Observando a Tabela 3.16 foi verificada uma diferença estatística relevante no Apoio Médio e Impulsão. Isso significa que a média dos valores registrados entre PS e plataforma de força apresentam diferenças significativas. Qualquer análise realizada utilizando a PS nesses pontos deverá ser conduzida com cuidado, pois não poderão ser associadas a um comportamento de uma plataforma de força.

Tabela 3.16: Validação das variáveis temporais

	EQM	p-valor
Duração da Resp. a Carga (T1)	0,01	0,04
Duração do Apoio Médio(T3-T1)	0,02	0,08
Duração da Impulsão (T4-T3)	0,01	0,31

Legenda: EQM: Erro Quadrático Médio.

Capítulo 4

Discussão

4.1 Desenvolvimento da Palmilha

4.1.1 Palmilha e Sistema de Aquisição

Sistematicamente, o presente trabalho desenvolveu um sistema de avaliação cinética baseado em palmilhas sensorizadas. Foram avaliados diversos parâmetros construtivos de um sensor resistivo, sua durabilidade e algumas particularidades do tratamento de sinal deste tipo de sensor. Esse conjunto de resultados possibilitou avaliar o desempenho da palmilha e discutir suas limitações e possibilidades de melhoria.

A PS alcançou uma durabilidade superior a 4,5h. Low *et al.* [93] realizaram um teste de durabilidade em sensores de força baseado no acionamento repetido dos sensores por 1.000 ciclos. A PS desenvolvida no presente trabalho obteve valores de 15.120 ciclos sem apresentar falha. Esse tempo de vida alcançado contribui para redução dos custos de manutenção do sistema. A PS desenvolvida conseguiu desenvolver sensores integrados à palmilha, sem a presença de cabos e conexões ao longo da palmilha, reduzindo desconfortos durante o seu uso. O objetivo de uma taxa de aquisição superior a 100Hz também foi alcançado (375Hz).

Referente à aplicação da PS durante a marcha, foi verificado que os momentos de maior carga são a Resposta à Carga e a Impulsão (Pré-balanço e Apoio Terminal) [16]. Nesses momentos, a vFRS concentra-se na parte posterior ou anterior do pé, respectivamente. Assim, a soma das saturações do sensor não deve ser menor que a carga aplicada. Na palmilha desenvolvida são observados três sensores na região posterior e quatro sensores na região anterior. Considerando o conjunto de especificações desta palmilha, houve uma limitação do peso do usuário em 133 kg, já considerando os picos de força durante a marcha. Essa limitação de peso máximo não foi um fator de limitação desse estudo. Entretanto, pode ser um limitador em outros tipos de estudo que avaliam os impactos do sobrepeso na marcha por exemplo [94] ou estudos que avaliam o impacto em saltos, pois a

vFRS pode chegar a três vezes o peso próprio. Segundo Grivas *et al.* [41], o peso corporal tende a aumentar conforme o tamanho do pé e isso pode se tornar uma limitação do uso dessa configuração de sensor em palmilhas de numerações maiores.

Outra limitação da palmilha foi a captação de forças durante o Apoio Médio. Baseado nas especificações de projeto da palmilha, o peso mínimo para utilização da palmilha foi de 38 kg. Entretanto, essa especificação foi realizada considerando uma pressão plantar uniformemente distribuída, o que não ocorre na prática. Foi observado que a anatomia do pé, somado com as fases e variações da marcha, produziram regiões com baixa pressão plantar, fazendo com que alguns dos sensores não fossem ativados durante o Apoio Médio, gerando uma queda da vFRS e uma menor correlação com a plataforma de força, como no Grupo 2. Segundo Chuckpaiwong [95], o tipo de pé (considerando variações no arco plantar) influencia diretamente na distribuição da pressão plantar. Essa característica não comprometeu esse estudo porque, ainda que a vFRS fosse subdimensionada nessa fase, ainda sim, esse comportamento é uma característica que diferencia esse grupo de amostra.

O sistema de aquisição da palmilha desenvolvida utiliza o ADC (*analog-digital converter*) de 12 Bits e possui uma taxa de aquisição de 375Hz. O presente estudo não mostrou nenhuma perda ao aumentar a resolução do ADC de 9 Bits para 12 Bits. Contrariando às expectativas, este aumento resultou na diminuição dos níveis de ruído e reduziu a necessidade de aplicação de filtros em comparação com os outros ADCs. A taxa de aquisição é superior a maioria dos estudos que propõem o desenvolvimento de palmilhas similares. A construção do sistema possibilitou utilizar uma alta taxa de aquisição e resolução do ADC sem que impactasse no ruído durante a aquisição de dados, podendo ser filtrado por um filtro simples de média móvel. A facilidade de filtrar os sinais acaba apresentando vantagens na utilização do sistema em pesquisas acadêmicas, reduzindo a complexidade dos algoritmos de pós-processamento. A alta taxa de aquisição permite obter mais informações durante a marcha e podendo estender o uso da palmilha para atividades mais velozes que a marcha.

Entretanto, apesar do instrumento apresentar uma forte correlação com a plataforma de força na média dos testes realizados e, também, na maioria dos cados observados, houve situações em que ocorreu uma defasagem na medição de força em casos de supinação aumentada na fase de Impulsão em alguns voluntários. Esse comportamento biomecânico fez com que os picos de força registrados durante a Impulsão fossem subestimados. Embora essa observação, teoricamente, deponha contra o instrumento desenvolvido, essa situação pode ser facilmente corrigida inserindo sensores nas regiões “cegas”. Entretanto, estrategicamente, esses sensores não foram inseridos, pois esse comportamento serviu como gatilho na identificação dos padrões de marcha, trabalhados no Capítulo 5. Devido a essa escolha metodológica de explorar as características construtivas da palmilha para extração dos padrões de marcha, a medição da palmilha sensorizada será tratada como

Força de Reação do Solo Registrada (FRSR) ao invés de FRS ou vFRS, ainda que, na maior parte dos cados, haverá uma equivalência. Desta forma, a FRSR pode abranger as exceções geradas pelo *layout* escolhido para construção do instrumento.

4.1.2 Calibração e Validações

O presente estudo propôs uma rotina de calibração composta por duas etapas: estática e dinâmica. Esse método mostrou uma melhora na correlação entre a PS e a plataforma de força, mostrando um aumento geral de correlação de cerca de 6,8% (p -valor = 0,0035) considerando a média de Pearson entre os dois processos de calibração, atingindo um índice médio de $p=0,78$, considerado alta correlação positiva [96]. A calibração dinâmica utilizou uma técnica de otimização computacional durante o processo de calibração e que dialoga com a recomendação de Eguchi e Takahashi [34], que sugerem em seu artigo o uso de abordagens não lineares como forma de melhorar os resultados obtidos em seu processo de calibração. Essa visão é sustentada pela revisão sistemática apresentada por Wong *et al.* [97], que apresenta melhores resultados de calibração ao utilizar modelos não lineares. As características da marcha influenciaram diretamente no desempenho da calibração dinâmica. Marchas com característica de pronação aumentada apresentam redução nos valores de vFRS (PS) durante o Apoio Médio em relação à plataforma de força dependendo do peso corporal. Esse comportamento, em alguns casos, reduziu a carga dos sensores laterais do mediopé, chegando ao ponto da pressão plantar não conseguir superar a inércia de medição do sensor e não registrar pressão. Uma maneira de contornar essa defasagem é ajustar a sensibilidade dos sensores do mediopé. Marchas com características de supinação apresentam deslocamento lateral do centro de pressão plantar, levando a vFRS para uma região sem sensores (extremidade lateral anterior da palmilha). Essa característica ocasionou reduções da vFRS durante a Impulsão, afetando a capacidade de ajuste de calibração dinâmica. Uma maneira de contornar esse atraso é adicionar sensores nessa região.

De acordo com Seiberl *et al.*[98] a quantidade e o posicionamento dos sensores afetam diretamente a qualidade da mensuração das FRS. No entanto, de acordo com Ngueleu *et al.* [99], não há consenso sobre o número mínimo de sensores a serem utilizados ou suas posições. Segundo Fuchs *et al.* [69], com 11 sensores, é possível alcançar a relação ideal entre simplificação e desempenho de medição. O desenvolvimento da PS com 12 sensores tem uma distribuição semelhante à proposta por Fuchs *et al.* [69], e, talvez por isto, foi possível alcançar uma correlação geral de Pearson de 0,78%, CMC de 0,88% e EQM de 0,29%. Esses níveis de correlação (Pearson, CMC) somados a uma baixa

dispersão dos dados (EQM) permitem concluir a validade e repetibilidade do instrumento [96]. Cada uma das principais variáveis extraídas do instrumento para realização das análises cinemáticas também foram verificadas.

Capítulo 5

Processamento dos dados e Aplicação de *Machine Learning*

5.1 Metodologia

Com base no banco de dados construído no Capítulo 3, uma nova etapa de análise dos dados pode ser implementada utilizando ML (*Machine Learning*). O objetivo da implementação de inteligência computacional é de buscar um maior entendimento do movimento de forma quantitativa (FRSR), buscando relações entre parâmetros numéricos e comportamentos clínicos observados durante a marcha, como pronação e supinação. Para isso foram aplicadas duas técnicas de aprendizado de máquina: Algoritmo Imunológico e CART. A primeira técnica tem o objetivo de agrupar os dados em grupos (*clusters*) com padrões de comportamento similares. Já a CART é uma técnica utilizada como extratora de características. Essa técnica utiliza um conjunto de variáveis de entrada e uma resposta desejada como saída desejada, criando um conjunto de regras que permite fazer a ponte entre as variáveis de entrada e saída.

5.1.1 Algoritmo Imunológico

O Algoritmo Imunológico foi empregado com objetivo de buscar padrões semelhantes de dados e agrupá-los. Diferentemente do algoritmo *K-means* (frequentemente utilizado para agrupamento), que utiliza a distância entre centroides para estabelecer diferenciação entre grupos [54], o Algoritmo Imunológico mimetiza um conceito biológico de “chave-fechadura” para estabelecer afinidade entre as amostras e criar grupos. De uma forma simplificada, o Algoritmo Imunológico construído inicia gerando uma série de estruturas aleatórias chamadas anticorpos, formando uma população inicial. Esses

anticorpos são forçados a interagir com uma amostra de dados apresentada (antígeno), sendo calculado um parâmetro de afinidade entre eles (função de afinidade). Os anticorpos com maior afinidade são clonados e inseridas pequenas modificações em sua estrutura (CLONALG [100]). Uma parte da população inicial dos anticorpos é descartada (menor afinidade) sendo substituídos por anticorpos que formam clonados, mantendo uma parcela da população inicial que apresenta maior afinidade com os抗ígenos (elitismo). Quando a relação de afinidade entre os anticorpos e antígenos atinge um valor satisfatório (taxa de erro), uma nova amostra é selecionada para interagir com os anticorpos e o processo de adaptação contínua, aumentando o conjunto de dados. Assim que não for possível adicionar mais nenhuma amostra de dado e satisfazer a condição de afinidade, o grupo é finalizado. Os抗ígenos desse grupo são removidos da base de dados inicial, os anticorpos são salvos em um arquivo a parte e o processo reinicia até que todos aos dados sejam agrupados. Desta forma, cada conjunto de anticorpos gerados consegue reconhecer um grupo de抗ígenos específicos, criando os padrões necessários para agrupamento de diferentes marchas. Uma vantagem desse tipo de algoritmo é que o aprendizado se dá de forma incremental. Cada vez que uma nova marcha é apresentada ao algoritmo, ele buscará entre os grupos existentes o que mais se adapta e, caso não seja possível, um novo grupo será iniciado, ampliando a capacidade de reconhecimento do algoritmo. Cada uma das etapas desse algoritmo será discutida com mais detalhes de forma apresentar sua construção e aplicação.

Modelagem do problema

A busca por padrões foi restringida às informações da FRSR provida pela PS. Os dados adquiridos de cada voluntário foram desmembrados em dois: pé direito e pé esquerdo. Foi realizado uma média de cerca de 30 passadas para se obter uma passada média e normalizada, utilizando o peso corporal de cada voluntário. Essa passada média normalizada varia de acordo com cada voluntário de forma única, dificultando a comparação entre diferentes indivíduos por meio de séries com base temporal. Por isso foi aplicada a Transformada de Fourier para trabalhar os dados quanto ao domínio da frequência. Com essa mudança de domínio são obtidas as principais frequências que compõem o sinal e suas magnitudes. Segundo Chockalingam, Healy e Needham [101], a análise no domínio da frequência é estendida para toda a forma de onda, tornando mais útil a identificação de anormalidades da marcha [101]. A modelagem dos dados de entrada foi realizada com base na transformada de Fourier aplicada, onde foram observadas as 30 primeiras frequências. Esse corte foi realizado em aproximadamente 11Hz, frequência essa que garante uma alta correlação estatística com o sinal original ($p=0,87$).

O algoritmo de seleção escolhido foi o Elitismo a uma taxa de 0,6, com a técnica CLONALG para realização da reprodução e mutação durante o treinamento. Conforme apresentado anteriormente, o AI foi pouco explorado na literatura para o reconheci-

Tabela 5.1: Tabela Resumo dos Parâmetros do AI.

Parâmetros do AI			
N. de Anticorpos:	500	Algoritmo de Seleção:	CLONALG*
Taxa de Mutação:	15%	Erro Admitido (EA):	10-1%
Máximo de Gerações:	3000	Afinidade Mínima:	1 - EA
Elitismo:	60%		

*Um tipo de algoritmo de treinamento e seleção .

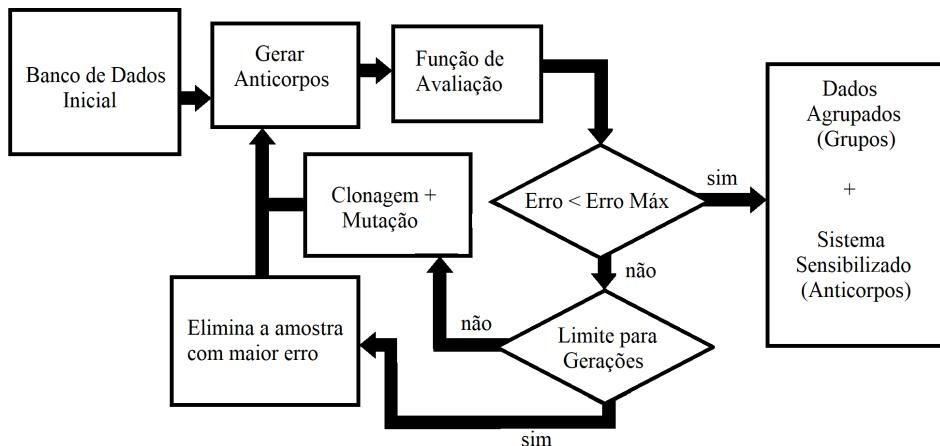
mento de padrões de marcha. Entretanto, com base em um algoritmo similar (Algoritmo Genético), a estratégia de seleção com base no elitismo se mostrou adequada [102]. A técnica para reprodução e mutação é uma técnica clássica para implementação do AI [47] por apresentar simplicidade de implementação e uma convergência eficiente.

Treinamento do Algoritmo Imunológico

Para a inicialização do Algoritmo Imunológico, foi necessário definir uma série de parâmetros apresentados na Tabela 5.1.

A definição do tamanho da população, taxa de mutação e taxa de substituição foram ajustadas de forma empírica, onde o valor foi sendo incrementado até que não houvesse mais a convergência do algoritmo dentro do critério máximo de gerações arbitrado. O critério de parada do treinamento (convergência) do Algoritmo Imunológico foi definido como sendo um valor mínimo de afinidade média. Isso significa que quando o anticorpo atinge o valor desejado de afinidade com um determinado antígeno, um novo antígeno é colocado para interagir e a afinidade geral passa a ser a média das afinidades. Esse critério é repetido até que não seja possível inserir nenhum novo antígeno ao grupo. A Figura 5.1 mostra como se dá o processamento do Algoritmo Imunológico. Toda a implementação computacional do algoritmo foi desenvolvida em C#, utilizando o Visual Studio 2019.

Figura 5.1: Diagrama sintético do processamento do AI.



Fonte: Próprio Autor.

O valor máximo de erro médio interno ao agrupamento foi verificado de forma empírica, entre 10%-1%, decrementando em 1%. Essa verificação gerou um total de 10 testes de agrupamento. Para cada um dos valores adotados foi verificado a quantidade de grupos formados. Entretanto, é esperado que valores baixos para o limite de afinidade implicam numa maior quantidade de grupos formados. Uma vez que o número ideal de grupos não é conhecido, foi aplicado um critério de verificação da diversidade entre grupos. Para isso foi calculado o coeficiente de correlação de Pearson médio e o Coeficiente de Múltiplas Correlações médio entre os membros de cada grupo, utilizando a mesma FRSR média no domínio do tempo. Uma vez que os grupos alcancem um Pearson superior a 90% serão unificados devido a sua alta correlação [96]. O objetivo é identificar qual o valor mínimo tolerado para afinidade média, de forma que os grupos formados não apresentem altas correlações, garantindo a diversidade entre grupos formados.

5.1.2 Explorando os Grupos Formados Utilizando CART para Mineração de Dados (*Data Mining*)

O Algoritmo Imunológico realizou o agrupamento das amostras com base no espectro das curvas de FRSR, adicionando ao banco de dados uma nova informação: número de identificação do grupo. Após realizado esse agrupamento, torna-se necessário a caracterização de cada grupo, elencando atributos que permitam as análises clínicas mais adiante. O conjunto de atributos (bioindicadores) que foi utilizado para a caracterização de cada grupo é o mesmo conjunto de variáveis validadas na Seção 3.4: pico de força durante a Resposta à Carga e Impulsão, posição do COP durante a Resposta à Carga e Impulsão, vale da força durante o Apoio Médio e a duração da fase de Resposta à Carga, Apoio Médio e Impulsão. Essas variáveis foram utilizadas como entrada (preditores) para o treinamento do algoritmo CART. Este algoritmo é baseado em uma árvore de decisão [45], sendo usualmente utilizado na literatura como algoritmo de classificação [64]. Uma característica desse algoritmo é que, após o treinamento, ele consegue criar um processo de decisões binárias [45] para explicitar o processo classificatório estabelecido pelo algoritmo, podendo ser aplicado em qualquer conjunto de dados. Por se tratar de um algoritmo supervisionado [64], ele necessita, além dos dados de entrada, uma resposta prévia de classificação. De posse desses dados, o algoritmo estabelece diversos pontos de corte para criar um conjunto de regras que permitirá classificar os dados de entrada para obter os mesmos padrões de saída apresentados.

Como mencionado anteriormente, foi apresentado um conjunto de bioindicadores como entrada do algoritmo e, como resposta de classificação, foi apresentado os grupos

estabelecidos pelo Algoritmo Imunológico. O objetivo é permitir que a CART estabeleça pontos de corte (limites) entre os bioindicadores que permitam identificar gatilhos que diferenciem os grupos formados pelo Algoritmo Imunológico, utilizando atributos diferentes da FRSR (utilizado no treinamento do Algoritmo Imunológico). É esperado que após o treinamento da CART sejam estabelecidas correlações potenciais entre os bioindicadores e o comportamento da FRSR e que poderão ser tema de estudos de verificação futuros.

Aplicação da CART

A implementação da CART foi realizada no *software WEKA* (versão 3.8.5, *University of Waikato, New Zealand*). Os bioindicadores relacionados à força (pico de força durante a Resposta à Carga e Impulsão e vale da força durante o Apoio Médio) foram normalizados com base no peso corporal de cada voluntário, os bioindicadores relacionados com o tempo (duração da fase de Resposta à Carga, Apoio Médio e Impulsão) foram normalizadas com base na duração média da passada e o COP foi normalizado tendo como referência a largura da palmilha. Para a extração dos bioindicadores, as três repetições do teste de caminhada na plataforma de força foram condensados em uma única amostra. Com isso o número máximo de amostras reduziu de 192 (32 voluntários, 3 repetições, esquerdo e direito) para 64 amostras (32 voluntários, esquerdo e direito). O resultado de classificação da CART foi avaliado utilizando a taxa de acerto e o coeficiente de Silhouette. A taxa de acerto tem por objetivo medir a proximidade da resposta produzida pela CART e a resposta desejada (gabarito). Já o coeficiente de Silhouette tem por objetivo medir a coesão dos grupos resultantes da classificação da CART.

5.1.3 Aplicação do Sistema – Estudo de Caso

Após desenvolvimento, calibração e validação do instrumento, implementação e aplicação das técnicas de ML, foi realizado um estudo de caso com os dados disponíveis para verificar a aplicabilidade do sistema. Para isso, foi avaliado o comportamento de pronação e supinação aumentado durante a fase de Impulsão. A pronação/supinação podem estar relacionadas com tendinite tibial posterior [103], bursite ou tendinite de Aquiles [104], distúrbios femoropatelares, sendo objetos de estudo para prevenção de lesões. Primeiramente, foi avaliado deslocamento do tornozelo no plano frontal utilizando os dados cinemáticos obtidos pelo sistema de captura de movimento. Segundo Perry [16], a amplitude do movimento articular no plano frontal é de 10°. Dessa forma, com base no ângulo articular, foram considerados valores menores que -5° na fase de Impulsão para pronação aumentada, entre -5° e 5° para comportamento neutro e maior que 5° para supinação. O

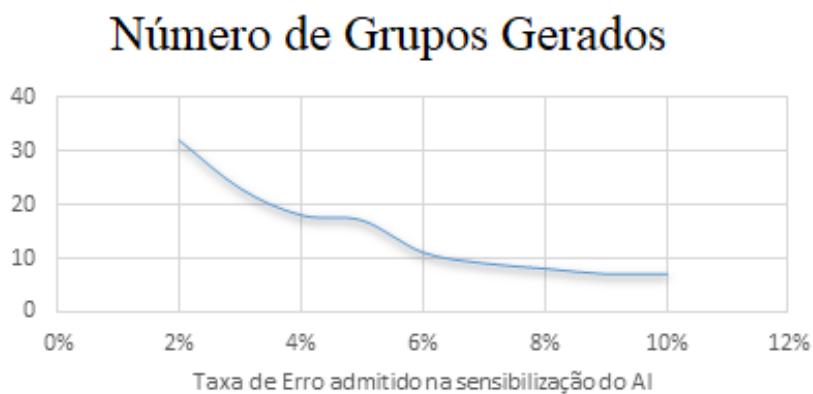
ponto zero foi tomado como referência a posição de ortostatismo. Após a classificação dos dados quanto a pronação/supinação, foi verificado se o sistema conseguia identificar correlações entre o comportamento cinemático (movimento articular) e cinético (FRSR) e se esse comportamento pode ser mapeado utilizando as variáveis: pico de força durante a Resposta à Carga e Impulsão, posição do COP durante a Resposta à Carga e Impulsão, vale da força durante o Apoio Médio e a duração da fase de Resposta à Carga, Apoio Médio e Impulsão.

5.2 Resultados

5.2.1 Algoritmo Imunológico

Após ser implementado o AI, foram realizados os testes de agrupamento, variando-se o valor máximo do erro médio interno ao grupo. A medida que a margem de erro se tornou mais estreita, aumentou-se o número de grupos disponíveis. A Figura 5.2 apresenta a curva de crescimento da quantidade dos grupos conforme redução erro médio interno máximo permitido.

Figura 5.2: Variação no número de grupos com a redução da taxa de erro máxima admitida.



Fonte: Próprio Autor.

Conforme discutido anteriormente, uma vez que o número ideal de grupos não é conhecido, foi aplicado um critério de verificação da diversidade entre grupos com base no coeficiente de Pearson, unificando os grupos com valores superiores a 90%. A Tabela

[5.2](#) apresenta o resultado dessa verificação, sendo possível observar que o maior número de grupos distintos é sete grupos.

Após a verificação de similaridade, foi observado que a taxa de erro máxima admitida ótima é 5%, resultando em sete grupos. Isso porque erros menores que 5% não apresentam ganhos em relação à diferenciação de grupos e implica em um maior custo computacional. Caso fosse adotado um valor de taxa de erro máxima admitida de 2%, por exemplo. O Algoritmo Imunológico gastaria mais tempo de processamento e, após a formação dos grupos, os 32 grupos formados seriam reduzidos novamente a sete grupos. Também foi verificado os coeficientes de variação para cada grupo, resultando em uma média de 0,11%. Esse resultado apresenta uma boa coesão dos grupos. A distribuição de amostras nos grupos foi: 18 no Grupo 1, 8 no Grupo 2, 6 no Grupo 3, 6 no Grupo 4, 12 no Grupo 6, 7 no Grupo 6 e 7 no Grupo 7.

Tabela 5.2: Grupos gerados após a fusão dos grupos com alta correlação.

% Erro Admitido	N. Grupos Gerados	Grupos fundidos	N. Grupos Finais
10%	7	2	5
9%	7	1	6
8%	8	2	6
7%	9	3	6
6%	11	5	6
5%	17	10	7
4%	18	11	7
3%	23	16	7
2%	32	25	7

Os grupos formados pelo AI foram apresentados na Seção 5.3 na Figura [5.4](#). Os grupos formados apresentam uma forte correlação interna referente a FRSR, entretanto, não apresentam valor clínico, pois não foi associado ou analisado nenhuma característica biomecânica ao grupo formado. Exposição dos grupos formados, com as análises cabíveis, só foram possíveis após a implementação da CART.

5.3 Aplicação da CART

Após ser implementada a CART, o algoritmo classificou corretamente as amostras a uma taxa de 86% de acerto e foi considerado um bom resultado em comparação com os modelos de previsão de lesão que utilizam ML [\[105\]\[15\]](#). Isso significa que 86% das amostras possuem um conjunto exclusivo de recursos que permite ao sistema identificar um comportamento específico ao caminhar usando os bioindicadores. Durante o processo

de treinamento do algoritmo CART, o Grupo 7 foi excluído porque todos os membros do Grupo 7 foram considerados erros sendo encontrados dispersos em outros grupos e, por isso, foram removidos da análise (podados). Isso significa que o Grupo 7 não conseguiu identificar um comportamento específico na caminhada utilizando os bioindicadores apresentados.

Portanto, seis grupos entraram nos resultados, com 57 amostras (total sem o Grupo 7).

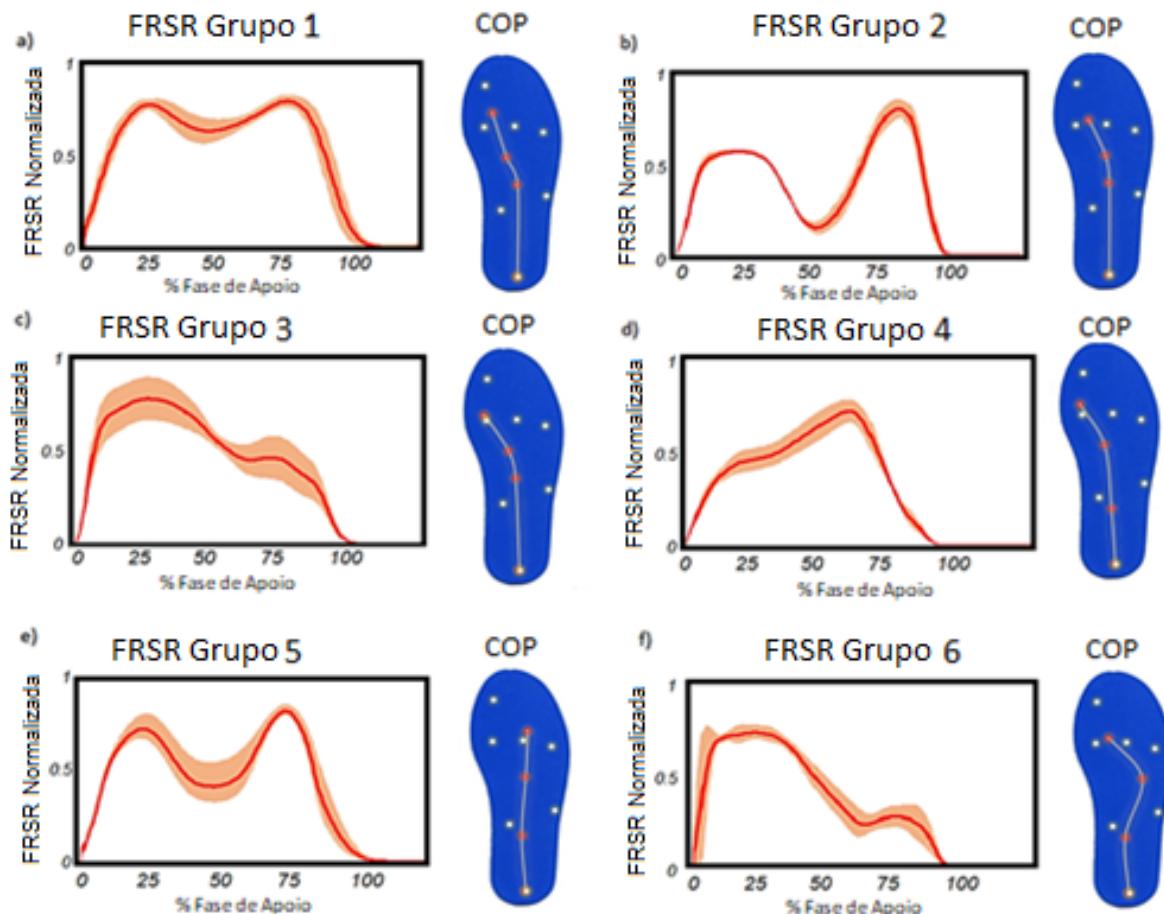
A Figura 5.3 mostra todos os seis grupos obtidos após o processamento dos dados. O Grupo 1 (Figura 5.3a) foi considerado o grupo típico, pois o formato da curva FRSR é semelhante ao esperado com base na literatura para a vFRS[16]. Ao analisar os membros do grupo, em média, o COP teve uma medialização em torno de 22,5% no Apoio Médio. Forças alteradas durante a Resposta à Carga foram encontradas nos Grupos 2, 3 e 4. O Grupo 2 (Figura 5.3b) foi caracterizado por um maior impulso (27,4%) e força média registrada (21,2%) durante a Impulsão. O Grupo 3 (Figura 5.3c) foi caracterizado por um menor impulso (19,76%), força média registrada (5,2%) e duração da resposta de carga aumentada (12,7%). O Grupo 4 (Figura 5.3d) foi caracterizado por uma redução na duração da Resposta à Carga (15,7%). Esta diminuição da duração da resposta à carga foi acompanhada por uma diminuição da duração do Apoio Médio (8,5%) e uma redução da força média registrada (20,1%). Forças alteradas durante a Impulsão foram encontradas nos Grupos 5 e 6. O Grupo 5 (Figura 5.3e) teve um aumento da duração da Impulsão (18,7%). O Grupo 6 (Figura 5.3f) caracterizou-se por um impulso reduzido (44%) e força média registrada (37,8%), bem como força de pico diminuída (28,5%). A Figura 5.4 mostra a estrutura decisória extraída do CART após a poda e exclusão do Grupo 7.

5.3.1 Aplicação do Sistema – Estudo de Caso

Após a classificação das amostras quanto a pronação (Figura 5.5a), neutro (Figura 5.5b) e supinação (Figura 5.5c), foi verificado qual foi a predominância de cada uma das características nos grupos formados.

O Grupo 1 teve prevalência de pronação (55,5%), mas ainda teve presença significativa de comportamento de supinação (27,7%) e neutro (16,8%). No Grupo 2 houve prevalência de pronação (75%) e pequena presença de comportamento de supinação (12,5%) e neutro (12,5%). O Grupo 3 apresentou a prevalência de pronação (66,7%) e pequena presença de supinação (16,7%) e comportamento neutro (16,7%). No Grupo 4 não foi registrado comportamento de pronação e pequena presença de supinação (16,7%). O

Figura 5.3: Grupos formados pela AI.

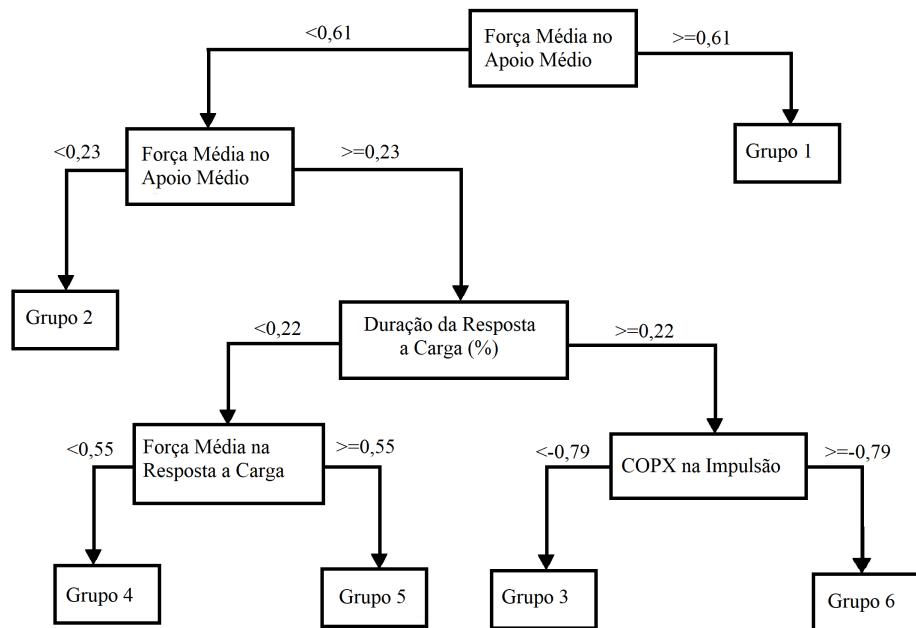


Fonte: Próprio Autor.

comportamento neutro (83,3%) domina este grupo. Nos Grupos 5 e 6 não foi detectado comportamento de pronação ou supinação.

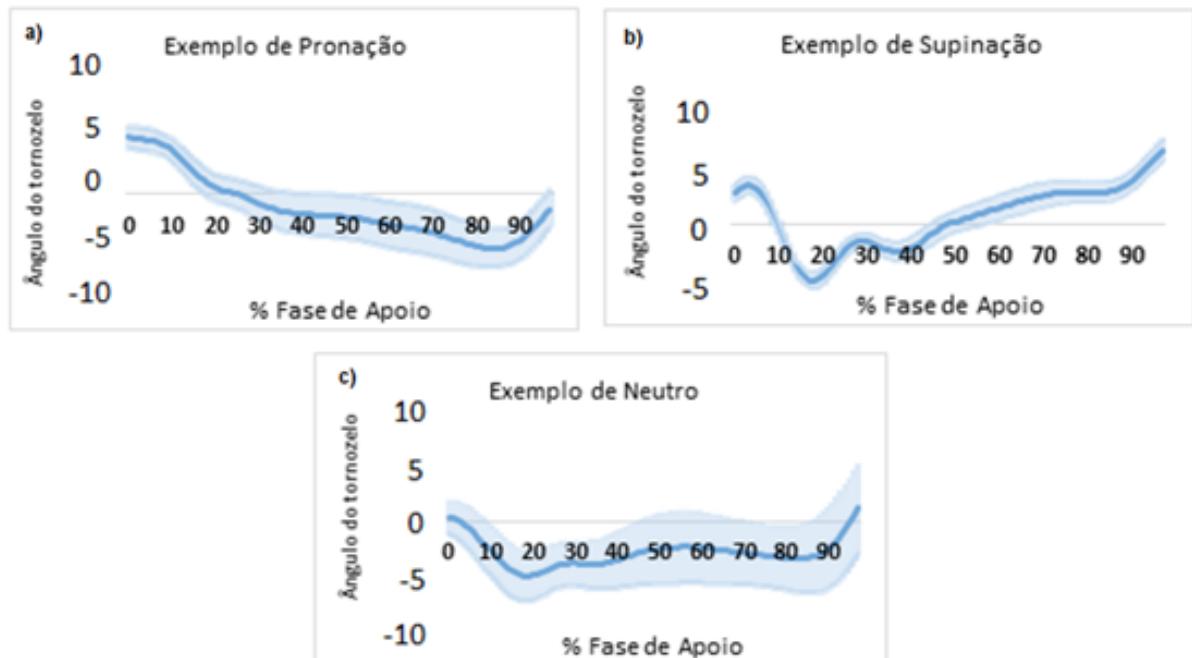
Com base na dispersão dos comportamentos de pronação e supinação nos grupos avaliados, não foi possível estabelecer nenhuma correlação determinante entre esse movimento e a FRSR.

Figura 5.4: Estrutura decisória da CART.



Fonte: Próprio Autor.

Figura 5.5: Exemplo de classificação cinemática da marcha em relação a pronação, supinação e neutro.



Fonte: Próprio Autor.

Capítulo 6

Discussão

6.1 Implementação do ML

O objetivo foi desenvolver um sistema para medir o vFRS e identificar diferentes padrões de sinais de vFRS para extrair características biomecânicas por meio de algoritmos de ML. Como resultado, seis grupos emergiram apresentando comportamentos particulares que ajudariam os examinadores a focar sua atenção, como a ativação de sensores mediais do mediopé (Grupo 1) e aumento ou diminuição de forças durante a Resposta à Carga (Grupos 2, 3 e 4) e Impulsão (Grupos 5 e 6). Cada um desses agrupamentos pode representar determinadas condições, conforme discutido a seguir.

A ativação dos sensores mediais do mediopé (Grupo 1) pode representar, por exemplo, pronação excessiva do pé ou mesmo uma anatomia plana do pé. Em estudo sobre a trajetória do COP em idosos, observou-se desvio medial do COP, indicador de pronação [106]. Os Grupos 1, 2 e 3 têm predominância do comportamento de pronação e corroboram essa relação entre COP e pronação excessiva do pé, embora nem sempre o aumento da força média durante o Apoio Médio ativa os sensores mediais do mediopé. O fluxograma do CART mostra a relação oposta entre os valores da força média durante Apoio Médio no Grupo 2 e o comportamento de pronação. Assim, a simplificação de causa e efeito, onde uma relação de aumento da força média do mediopé ou ativação dos sensores mediais do mediopé equivale à pronação excessiva do pé, é imprudente e não se confirma na prática.

Forças alteradas ou duração na fase de Resposta à Carga (Grupos 2, 3 e 4) podem estar relacionadas às estratégias de marcha para absorver impactos, uma vez que forças crescentes durante a resposta ao carregamento podem sobrecarregar cartilagens e articulações [106].

Além disso, as forças alteradas durante a Impulsão encontradas nos Grupos 5 e 6 podem ser decorrentes do desempenho dos flexores plantares do tornozelo [107]. Embora isso não tenha sido verificado no presente estudo, esses músculos são considerados os que mais contribuem para o impulso em termos de intensidade de força e tempo de duração.

Portanto, qualquer alteração nesses parâmetros pode estar relacionada à fraqueza dos flexores plantares do tornozelo ou à compensação do movimento [107].

Os algoritmos de ML conseguiram extrair comportamentos típicos da série temporal utilizando bioindicadores da marcha humana com base em um banco de dados. Expandir esse banco de dados com mais amostras pode aumentar o número de grupos e encontrar diferentes padrões de reconhecimento, possibilitando um processo contínuo e uma melhoria adaptativa. Embora o estudo tenha incluído apenas voluntários saudáveis, foram incluídos voluntários que possam ter marcha alterada devido a outros fatores, como pronação e supinação excessivas ou fraqueza muscular, ou encurtamento. Mesmo em voluntários saudáveis, há a presença de diferentes padrões de marcha que podem ser usados como preditores de lesão [15]. Identificar padrões de marcha em voluntários saudáveis pode ser considerado um desafio para o sistema [105], uma vez que as alterações na marcha não são tão evidentes quanto em pacientes com distúrbios neurológicos, por exemplo. Às vezes, esses diferentes padrões podem se apresentar em diferentes intensidades e combinações, dificultando a análise da marcha. Assim, o sistema demonstra sensibilidade suficiente para distinguir diferentes padrões, estabelecer limites de corte entre eles e pode ser usado para investigar como esses padrões afetariam a funcionalidade, expondo, por exemplo, os indivíduos ao risco.

Capítulo 7

Conclusão

O presente trabalho concluiu o seu objetivo de desenvolver um sistema de avaliação cinética da marcha composto por um instrumento de medição da pressão plantar (com a PS) e um sistema de armazenamento e processamento de dados baseado em ML. Esse sistema foi validado com base em uma plataforma de força e apresentou um Pearson de 0,78 e um CMC de 0,88. O sistema também apresenta diversas possibilidades de interação por parte do usuário. É possível ter acesso aos dados brutos gerados pela palmilha por meio de um arquivo de texto, ter acesso aos dados processados pelo sistema, fornecendo um conjunto de bioindicadores, a curva média de FRSR. Esse conjunto simplificado de informações, juntamente como seu baixo custo, favorece a utilização do instrumento, tanto na pesquisa acadêmica, quanto prática clínica, auxiliando na tomada de decisão em diferentes níveis. As implementações das técnicas de ML permitem classificar o comportamento da marcha de acordo com grupos de similares sem conhecimento prévio. Nesse estudo foi apresentado seis grupos onde a correlação interna é de 0,95 e a taxa de previsibilidade na identificação e classificação da marcha é de 0,86 com base no coeficiente de Silhouette. Esses padrões resultantes após a análise da marcha podem ser usados para pesquisas e correlacionados com outro estudo para prevenir futuras lesões e direcionar tratamentos.

O presente trabalho, apesar de contar com um número significativo de voluntários (32 voluntários) para o desenvolvimento e validação do sistema, não possui informações suficientes para sustentar, de forma significativa, conclusões relacionando quadros clínicos a um comportamento de FRS ou a um conjunto de bioindicadores. Apesar do sistema apontar para possíveis correlações, as confirmações das hipóteses devem ser respondidas por estudos dirigidos. Como trabalhos futuros são propostos estudos multicêntricos direcionados para o aprimoramento do sistema e ampliação da base de dados, uma vez que o sistema foi concebido para haver a expansão da base de dados e capacidade de reconhecimento de padrões e acompanhar as descobertas futuras sem que, obrigatoriamente, se torne obsoleto.

Referências Bibliográficas

- [1] Rachel Haigh, Alan Tennant, Fin Biering-Sorensen, Gunnar Grimby, Crt Marincek, Suzanne Phillips, Haim Ring, Luigi Tesio, and Jean-Louis Thonnard. The use of outcome measures in physical medicine and rehabilitation within europe. *Journal of rehabilitation medicine*, 33(6):273–278, 2001.
- [2] SJ Hall. *Biomecânica básica. 7a edição*. Rio de Janeiro: Guanabara Koogan, 2016.
- [3] Silvia Regina Secoli, Marcelo Eidi Nita, Suzane Kioko Ono-Nita, and Moacyr Nobre. Avaliação de tecnologia em saúde: II. a análise de custo-efetividade. *Arquivos de Gastroenterologia*, 47:329–333, 2010.
- [4] Gordon H Guyatt, Andrew D Oxman, Regina Kunz, Yngve Falck-Ytter, Gunn E Vist, Alessandro Liberati, and Holger J Schünemann. Going from evidence to recommendations. *Bmj*, 336(7652):1049–1051, 2008.
- [5] Dawn Stacey, France Légaré, Krystina Lewis, Michael J Barry, Carol L Bennett, Karen B Eden, Margaret Holmes-Rovner, Hilary Llewellyn-Thomas, Anne Lyddiatt, Richard Thomson, et al. Decision aids for people facing health treatment or screening decisions. *Cochrane database of systematic reviews*, (4), 2017.
- [6] Abel Garcia-Barrientos, Raul Balderas-Navarro, Sharon Macias-Velasquez, Jose Antonio Hoyo-Montaña, Mario Alberto Garcia-Ramírez, Daniel Espejel-Blanco, and Jairo Plaza-Castillo. Gait analysis using the physics toolbox app. *IEEE Access*, 10:31732–31739, 2022.
- [7] George Schayer Sabino, Luís Augusto Ferraz de Souza, Tainá Ribeiro, Diego Henrique Antunes Nascimento, Claysson Bruno Santos Vimieiro, and Renan Alves Resende. Validity and reliability of a smartphone application for knee posture quantification and the effects of external markers on the precision of this measure. *Journal of Bodywork and Movement Therapies*, 28:42–48, 2021.
- [8] Carlos Balsalobre-Fernández, Hovannes Agopyan, and Jean-Benoit Morin. The validity and reliability of an iphone app for measuring running mechanics. *Journal of applied biomechanics*, 33(3):222–226, 2017.
- [9] Natália Silva Amaral. Validação e confiabilidade de aplicativos de avaliação do movimento para smartphones: uma revisão narrativa. Universidade Federal de Minas Gerais, 2018.

- [10] Adin Ming Tan, Franz Konstantin Fuss, Yehuda Weizman, Ydwer Woudstra, and Olga Troynikov. Design of low cost smart insole for real time measurement of plantar pressure. *Procedia Technology*, 20:117–122, 2015.
- [11] E Klimiec, B Jasiewicz, J Piekarski, K Zaraska, P Guzdek, and G Kołaszczyński. Measuring of foot plantar pressure—possible applications in quantitative analysis of human body mobility. *Measurement Science and Technology*, 28(5):054008, 2017.
- [12] Leslie M Decker, Fabien Cignetti, and Nicholas Stergiou. Complexity and human gait. *Revista Andaluza de Medicina del Deporte*, 3(1):2–12, 2010.
- [13] Preeti Khera and Neelesh Kumar. Role of machine learning in gait analysis: a review. *Journal of Medical Engineering & Technology*, 44(8):441–467, 2020.
- [14] Djordje Slijepcevic, Fabian Horst, Sebastian Lapuschkin, Brian Horsak, Anna-Maria Raberger, Andreas Kranzl, Wojciech Samek, Christian Breiteneder, Wolfgang Immanuel Schöllhorn, and Matthias Zeppelzauer. Explaining machine learning models for clinical gait analysis. *ACM Transactions on Computing for Healthcare (HEALTH)*, 3(2):1–27, 2021.
- [15] Hanna Sigurdson and Jonathan H Chan. Machine learning applications to sports injury: A review. *icSPORTS*, pages 157–168, 2021.
- [16] Jacquelín Perry, Aletháea Gomes Nardini Araújo, Cíntia Domingues de Freitas, and Bill Schoneberger. *Análise de marcha*. SLACK, 2005.
- [17] Eric Viel. *Marcha Humana, a Corrida e o Salto*. Editora Manole Ltda, 2001.
- [18] Fabiano Cristopoliski, Thiago Augusto Sarraf, Valério Henrique Dezan, Cléver Luiz Gregolin Provensi, and André Luiz Félix Rodacki. Efeito transiente de exercícios de flexibilidade na articulação do quadril sobre a marcha de idosas. *Revista Brasileira de Medicina do Esporte*, 14:139–144, 2008.
- [19] Marcelo Saad, Linamara Rizzo Battistella, and Danilo Masiero. Técnicas de análise de marcha. *Acta fisiátrica*, 3(2):23–26, 1996.
- [20] Andrew King. *Clinical Gait Analysis: Theory and Practice*, Chris Kirtley, Churchill Livingstone, ISBN 0-4431-0009-8. Elsevier, 2007.
- [21] T Bedirhan Üstün, Somnath Chatterji, Jerome Bickenbach, Nenad Kostanjsek, and Margie Schneider. The international classification of functioning, disability and health: a new tool for understanding disability and health. *Disability and rehabilitation*, 25(11-12):565–571, 2003.

- [22] Elif Surer and Alper Kose. Methods and technologies for gait analysis. In *Computer analysis of human behavior*, pages 105–123. Springer, 2011.
- [23] Anita Maria da Rocha Fernandes, Eros Comunello, and Fábio Duarte Machado. Análise do movimento humano por videogrametria. *Anais do IX Simpósio de Excelência em Gestão e Tecnologia*, 2012.
- [24] Anderson Maciel. Modelagem de articulações para humanos virtuais baseada em anatomia. Master’s thesis, 2001.
- [25] Ana Maria Forti Barela and Marcos Duarte. Utilização da plataforma de força para aquisição de dados cinéticos durante a marcha humana. *Brazilian Journal of Motor Behavior*, 6(1):56–61, 2011.
- [26] Claudia Giacomozzi. Hardware performance assessment recommendations and tools for baropodometric sensor systems. *Annali dell’Istituto superiore di sanita*, 46:158–167, 2010.
- [27] Javier Martinez-Cesteros, Carlos Medrano-Sanchez, Inmaculada Plaza-Garcia, Raul Igual-Catalan, and Sergio Albiol-Pérez. A velostat-based pressure-sensitive mat for center-of-pressure measurements: A preliminary study. *International Journal of Environmental Research and Public Health*, 18(11):5958, 2021.
- [28] Lars St and Svante Wold. Analysis of variance (anova). *Chemometrics and intelligent laboratory systems*, 6(4):259–272, 1989.
- [29] Ibrahim Almuteb, Rui Hua, and Ya Wang. Smart insoles review over the last two decade: Applications, potentials, and future. *Smart Health*, page 100301, 2022.
- [30] Anas M Tahir, Muhammad EH Chowdhury, Amith Khandakar, Sara Al-Hamouz, Merna Abdalla, Sara Awadallah, Mamun Bin Ibne Reaz, and Nasser Al-Emadi. A systematic approach to the design and characterization of a smart insole for detecting vertical ground reaction force (vgrf) in gait analysis. *Sensors*, 20(4):957, 2020.
- [31] Lefan Wang, Dominic Jones, Graham J Chapman, Heidi J Siddle, David A Russell, Ali Alazmani, and Peter Culmer. A review of wearable sensor systems to monitor plantar loading in the assessment of diabetic foot ulcers. *IEEE Transactions on Biomedical Engineering*, 67(7):1989–2004, 2019.
- [32] Sensor Products Inc. Tactilus r wireless foot insole sensor system. url`https://www.sensorprod.com/dynamic/foot-insole.php`, July 2022.

- [33] Kamen Ivanov, Zhanyong Mei, Ludwig Lubich, Nan Guo, Deng Xile, Zhichun Zhao, Olatunji Mumini Omisore, Derek Ho, and Lei Wang. Design of a sensor insole for gait analysis. In *International Conference on Intelligent Robotics and Applications*, pages 433–444. Springer, 2019.
- [34] Ryo Eguchi, Ayanori Yorozu, Takahiko Fukumoto, and Masaki Takahashi. Ground reaction force estimation using insole plantar pressure measurement system from single-leg standing. In *2016 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI)*, pages 109–113. IEEE, 2016.
- [35] Wei-Chun Hsu, Tommy Sugiarto, Jun-Wen Chen, and Yi-Jia Lin. The design and application of simplified insole-based prototypes with plantar pressure measurement for fast screening of flat-foot. *Sensors*, 18(11):3617, 2018.
- [36] Ashutosh Tiwari and Deepak Joshi. Template-based insoles for the center of pressure estimation in different foot sizes. *IEEE Sensors Letters*, 4(8):1–4, 2020.
- [37] Rui Guo, Xiang Cheng, Zong-Chen Hou, Jing-Zhong Ma, Wen-Qiang Zheng, Xiao-Ming Wu, Dong Jiang, Yu Pan, and Tian-Ling Ren. A shoe-integrated sensor system for long-term center of pressure evaluation. *IEEE Sensors Journal*, 21(23):27037–27044, 2021.
- [38] Adriana Simone Lopes Santa Maria. *Aspectos metodológicos para a determinação de cargas internas na coluna vertebral*. PhD thesis, Interunidades em Bioengenharia - Universidade de São Paulo, 2001.
- [39] Johnny Nilsson and Alf Thorstensson. Adaptability in frequency and amplitude of leg movements during human locomotion at different speeds. *Acta Physiologica Scandinavica*, 129(1):107–114, 1987.
- [40] Diego José A Telarolli, Débora B Grossi, Ana Cristina C Cervi, Paulo Roberto P Santiago, Tenysson W Lemos, and Renan A Resende. Comparison of foot kinematics and foot plantar area and pressure among five different closed kinematic tasks. *Journal of the American Podiatric Medical Association*, 110(5), 2020.
- [41] Theodoros B Grivas, Constantinos Mihas, Angeliki Arapaki, and Elias Vasiliadis. Correlation of foot length with height and weight in school age children. *Journal of forensic and legal medicine*, 15(2):89–95, 2008.
- [42] Natalia FN Bittencourt, WH Meeuwisse, LD Mendonça, Alberto Nettel-Aguirre, JM Ocarino, and ST Fonseca. Complex systems approach for sports injuries: moving from risk factor identification to injury pattern recognition—narrative review and new concept. *British journal of sports medicine*, 50(21):1309–1314, 2016.

- [43] Pádraig Cunningham, Matthieu Cord, and Sarah Jane Delany. Supervised learning. In *Machine learning techniques for multimedia*, pages 21–49. Springer, 2008.
- [44] Vladimir Nasteski. An overview of the supervised machine learning methods. *Horizons. b*, 4:51–62, 2017.
- [45] Marcin Derlatka and Mikhail Ihnatouski. Decision tree approach to rules extraction for human gait analysis. In *International Conference on Artificial Intelligence and Soft Computing*, pages 597–604. Springer, 2010.
- [46] Mohiuddin Ahmed, Raihan Seraj, and Syed Mohammed Shamsul Islam. The k-means algorithm: A comprehensive survey and performance evaluation. *Electronics*, 9(8):1295, 2020.
- [47] Jano COTTA, Carlos; HEMERT. *Evolutionary Computation in Combinatorial Optimization (7 conf.)*. 2007.
- [48] Ingo Steinwart and Andreas Christmann. *Support vector machines*. Springer Science & Business Media, 2008.
- [49] Shan Suthaharan. *Machine learning models and algorithms for big data classification*, volume 36. Springer, 2016.
- [50] Rezaul K Begg, Marimuthu Palaniswami, and Brendan Owen. Support vector machines for automated gait classification. *IEEE transactions on Biomedical Engineering*, 52(5):828–838, 2005.
- [51] Ahsan H Khandoker, Daniel Lai, Rezaul K Begg, and Marimuthu Palaniswami. A wavelet-based approach for screening falls risk in the elderly using support vector machines. In *2006 Fourth International Conference on Intelligent Sensing and Information Processing*, pages 184–189. IEEE, 2006.
- [52] Suryani Ilias, Nooritawati Md Tahir, Rozita Jailani, and Che Zawiyah Che Hasan. Classification of autism children gait patterns using neural network and support vector machine. In *2016 IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE)*, pages 52–56. IEEE, 2016.
- [53] Haya Alaskar and Abir Hussain. Prediction of parkinson disease using gait signals. In *2018 11th International Conference on Developments in eSystems Engineering (DeSE)*, pages 23–26. IEEE, 2018.
- [54] Adam Rozumalski and Michael H Schwartz. Crouch gait patterns defined using k-means cluster analysis are related to underlying clinical pathology. *Gait & posture*, 30(2):155–160, 2009.

- [55] Anjali Kaushik and Gurpreet Kaur. Review on: Gait recognition technique using svm and k-means with gait pal and pal entropy. *(IJCSIT) International Journal of Computer Science and Information Technologies*, 5(3):3699–3702, 2014.
- [56] Junjie Wu. *Advances in K-means clustering: a data mining thinking*. Springer Science & Business Media, 2012.
- [57] Matthew Martinez, Phillip L De Leon, and David Keeley. Bayesian classification of falls risk. *Gait & posture*, 67:99–103, 2019.
- [58] Akash Kumar Bhoi. Classification and clustering of parkinson’s and healthy control gait dynamics using lda and k-means. *International Journal Bioautomation*, 21(1):19, 2017.
- [59] Kodai Kitagawa, Yu Taguchi, and Nobuyuki Toya. Proposal and evaluation of the gait classification method using arm acceleration data and decision tree. In *Proceedings of The 2017 International Conference on Artificial Life and Robotics*, pages 104–107, 2017.
- [60] Jon L Oliver, Francisco Ayala, Mark BA De Ste Croix, Rhodri S Lloyd, Greg D Myer, and Paul J Read. Using machine learning to improve our understanding of injury risk and prediction in elite male youth football players. *Journal of science and medicine in sport*, 23(11):1044–1048, 2020.
- [61] Leandro N de Castro and Jon Timmis. *Artificial immune systems: a novel approach to pattern recognitio*, ISBN 84-95721-22-8, pages 67–84. University of Paisley, 2002.
- [62] Dipankar Dasgupta and Fernando Nino. *Immunological computation: theory and applications*. Auerbach Publications, 2008.
- [63] Kunkun Peng, Quan-Ke Pan, Liang Gao, Xinyu Li, Swagatam Das, and Biao Zhang. A multi-start variable neighbourhood descent algorithm for hybrid flowshop rescheduling. *Swarm and Evolutionary Computation*, 45:92–112, 2019.
- [64] Leszek Rutkowski, Maciej Jaworski, Lena Pietruczuk, and Piotr Duda. The cart decision tree for mining data streams. *Information Sciences*, 266:1–15, 2014.
- [65] Sofia Visa, Brian Ramsay, Anca L Ralescu, and Esther Van Der Knaap. Confusion matrix-based feature selection. *MAICS*, 710(1):120–127, 2011.
- [66] Julio-Omar Palacio-Niño and Fernando Berzal. Evaluation metrics for unsupervised learning algorithms. *arXiv preprint arXiv:1905.05667*, 2019.
- [67] Oded Z Maimon and Lior Rokach. *Data mining with decision trees: theory and applications*, volume 81. World scientific, 2014.

- [68] Yajing Zhang, Guotai Chi, and Zhipeng Zhang. Decision tree for credit scoring and discovery of significant features: an empirical analysis based on chinese microfinance for farmers. *Filomat*, 32(5):1513–1521, 2018.
- [69] Philip X Fuchs, Chang-Hsin Hsieh, Wei-Han Chen, Yen-Shan Tang, Nicholas J Fiolo, and Tzyy-Yuang Shiang. Sensor number in simplified insole layouts and the validity of ground reaction forces during locomotion. *Sports Biomechanics*, pages 1–14, 2022.
- [70] Changwon Wang, Young Kim, and Se Dong Min. Soft-material-based smart insoles for a gait monitoring system. *Materials*, 11(12):2435, 2018.
- [71] Pe sem dor. Os pes brasileiros. url`https://www.pessem dor.com.br/pesquisas/os-pes-brasileiros/`, July 2022.
- [72] Yancong Qiao, Xiaoshi Li, Thomas Hirtz, Ge Deng, Yuhong Wei, Mingrui Li, Shourui Ji, Qi Wu, Jimming Jian, Fan Wu, et al. Graphene-based wearable sensors. *Nanoscale*, 11(41):18923–18945, 2019.
- [73] Quan Hu and Ping Cai. Insole-based estimation of complete ground reaction force with gaussian kernel regression and data expansion. *Journal of Mechanics in Medicine and Biology*, 22(01):2250001, 2022.
- [74] L Atallah, A Wiik, B Lo, JP Cobb, AA Amis, and GZ Yang. Gait asymmetry detection in older adults using a light ear-worn sensor. *Physiological measurement*, 35(5):N29, 2014.
- [75] Fahad Taha AL-Dhief, Naseer Sabri, NM Abdul Latiff, NNNA Malik, Musatafa Abbas, Abbood Albader, Mazin Abed Mohammed, Rami Noori AL-Haddad, Yasir Dawood Salman, Mohd Khanapi, et al. Performance comparison between tcp and udp protocols in different simulation scenarios. *International Journal of Engineering & Technology*, 7(4.36):172–176, 2018.
- [76] Janet Adams. *Observational gait analysis: a visual guide*. SLACK Incorporated, 2018.
- [77] Jack Xu. *Practical Numerical Methods with C*. UniCAD, 2019.
- [78] AL Reiff. *Different in-shoe devices for partial weight bearing*. PhD thesis, Faculty of Science and Engineering - University of Groningen, 2016.
- [79] Diego Nascimento, Fabrício Magalhães, George Sabino, Renan Resende, Maria Lúcia Duarte, and Claysson Vimieiro. New optimized dynamic calibration proposition for discretized sensorized insoles with resistive force sensor: A descriptive and comparative study. 2022.

- [80] Robin M Queen, Nathan A Mall, James A Nunley, and Bavornrit Chuckpaiwong. Differences in plantar loading between flat and normal feet during different athletic tasks. *Gait & posture*, 29(4):582–586, 2009.
- [81] Bart Selman and Carla P Gomes. Hill-climbing search. *Encyclopedia of cognitive science*, 81:82, 2006.
- [82] Simona Crea, Marco Donati, Stefano Marco Maria De Rossi, Calogero Maria Oddo, and Nicola Vitiello. A wireless flexible sensorized insole for gait analysis. *Sensors*, 14(1):1073–1093, 2014.
- [83] Philip S Dyer and Stacy J Morris Bamberg. Instrumented insole vs. force plate: A comparison of center of plantar pressure. In *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 6805–6809. IEEE, 2011.
- [84] K Kanithika and K Soo Chan. Pressure sensor positions on insole used for walking analysis. In *The 18th IEEE International Symposium on Consumer Electronics (ISCE 2014)*, pages 1–2. IEEE, 2014.
- [85] Kimberly A Fournier, Shinichi Amano, Krestin J Radonovich, Tana M Bleser, and Chris J Hass. Decreased dynamical complexity during quiet stance in children with autism spectrum disorders. *Gait & posture*, 39(1):420–423, 2014.
- [86] Mohammad Al-Amri, Kevin Nicholas, Kate Button, Valerie Sparkes, Liba Sheeran, and Jennifer L Davies. Inertial measurement units for clinical movement analysis: Reliability and concurrent validity. *Sensors*, 18(3):719, 2018.
- [87] Georgina Kate Barratt, Clint Bellenger, Eileen Yule Robertson, Jason Lane, and Robert George Crowther. Validation of plantar pressure and reaction force measured by moticon pressure sensor insoles on a concept2 rowing ergometer. Technical Report 7, 2021.
- [88] Ryu Nagahara and Jean-Benoit Morin. Sensor insole for measuring temporal variables and vertical force during sprinting. *Proceedings of the Institution of Mechanical Engineers, Part P: Journal of Sports Engineering and Technology*, 232(4):369–374, 2018.
- [89] Renan A Resende, Larissa SP Pinheiro, and Juliana M Ocarino. Effects of foot pronation on the lower limb sagittal plane biomechanics during gait. *Gait & Posture*, 68:130–135, 2019.
- [90] JJ Collins and MW Whittle. Impulsive forces during walking and their clinical implications. *Clinical Biomechanics*, 4(3):179–187, 1989.

- [91] Charles Bark, Kabalan Chaccour, Rony Darazi, Amir Hajjam El Hassani, and Emmanuel Andres. Design and development of a force-sensing shoe for gait analysis and monitoring. In *2017 Fourth International Conference on Advances in Biomedical Engineering (ICABME)*, pages 1–4. IEEE, 2017.
- [92] Elena Martini, Tommaso Fiumalbi, Filippo Dell’Agnello, Zoran Ivanić, Marko Munih, Nicola Vitiello, and Simona Crea. Pressure-sensitive insoles for real-time gait-related applications. *Sensors*, 20(5):1448, 2020.
- [93] Jen-Hahn Low, Pei-Song Chee, Eng-Hock Lim, and Vinod Ganesan. Design of a wireless smart insole using stretchable microfluidic sensor for gait monitoring. *Smart Materials and Structures*, 29(6):065003, 2020.
- [94] Shirley Aparecida Fabris de Souza, Joel Faintuch, Antonio Carlos Valezi, Antonio Fernando Sant’Anna, Joaquim José Gama-Rodrigues, Inês Cristina de Batista Fonseca, Roger Burgo Souza, and Roger Christian Senhorini. Gait cinematic analysis in morbidly obese patients. *Obesity Surgery*, 15(9):1238–1242, 2005.
- [95] Bavornrit Chuckpaiwong, James A Nunley, Nathan A Mall, and Robin M Queen. The effect of foot type on in-shoe plantar pressure during walking and running. *Gait & posture*, 28(3):405–411, 2008.
- [96] Mavuto M Mukaka. A guide to appropriate use of correlation coefficient in medical research. *Malawi medical journal*, 24(3):69–71, 2012.
- [97] Charence Wong, Zhi-Qiang Zhang, Benny Lo, and Guang-Zhong Yang. Wearable sensing for solid biomechanics: A review. *IEEE Sensors Journal*, 15(5):2747–2760, 2015.
- [98] Wolfgang Seiberl, Elisabeth Jensen, Josephine Merker, Marco Leitel, and Ansgar Schwirtz. Accuracy and precision of loadsol insole force-sensors for the quantification of ground reaction force-based biomechanical running parameters. *European journal of sport science*, 18(8):1100–1109, 2018.
- [99] Armelle M Ngueleu, Andréanne K Blanchette, Laurent Bouyer, Désirée Maltais, Bradford J McFadyen, Hélène Moffet, and Charles S Batcho. Design and accuracy of an instrumented insole using pressure sensors for step count. *Sensors*, 19(5):984, 2019.
- [100] Jason Brownlee. Clonal selection theory & clonalg—the clonal selection classification algorithm (csca). *Swinburne University of Technology*, 38, 2005.
- [101] N Chockalingam, A Healy, and R Needham. Interpreting ground reaction forces in gait. *Handbook of Human Motion*, pages 1–5, 2016.

- [102] Faezeh Tafazzoli, George Bebis, Sushil Louis, and Muhammad Hussain. Improving human gait recognition using feature selection. In *International Symposium on Visual Computing*, pages 830–840. Springer, 2014.
- [103] B Hintermann. Tibialis posterior dysfunction: a review of the problem and personal experience. *Foot and Ankle Surgery*, 3(2):61–70, 1997.
- [104] DB Clement, JE Taunton, and GW Smart. Achilles tendinitis and peritendinitis: etiology and treatment. *The American journal of sports medicine*, 12(3):179–184, 1984.
- [105] Aibin Zhu, Ying Li, Yuexuan Wu, Mengke Wu, and Xiaodong Zhang. Locomotion mode recognition based on foot posture and ground reaction force. In *2018 15th International Conference on Ubiquitous Robots (UR)*, pages 125–129. IEEE, 2018.
- [106] Min-Chi Chiu, Hsin-Chieh Wu, Li-Yu Chang, and Min-Huan Wu. Center of pressure progression characteristics under the plantar region for elderly adults. *Gait & posture*, 37(3):408–412, 2013.
- [107] Salam M Elhafez, Ahmed A Ashour, Naglaa M Elhafez, Ghada M Elhafez, and Azza M Abdelmohsen. Percentage contribution of lower limb moments to vertical ground reaction force in normal gait. *Journal of Chiropractic Medicine*, 18(2):90–96, 2019.

Capítulo 8

Anexo 1: Referência de preço de uma plataforma de força

MÉDIA	MEDIANA	MENOR
R\$ 84.000,00	R\$ 84.000,00	R\$ 84.000

Quantidade total de registros: 1

Registros apresentados: 1 a 1

FILTROS APLICADOS

Descrição Complementar	Ano da Compra
PLATAFORMA - AEREA TRABALHO, PLATAFORMA - AEREA TRABALHO, PLATAFORMA DE FORÇA; PLATAFORMAS DE FORÇA 50 X 50 CM DE CÉLULAS DE CARGA; COM UTILIZAÇÃO DE TRANSDUTORES DO TIPO STRAIN GAUGE, QUE É UM DISPOSITIVO ELÉTRICO QUE TEM SUA RESISTÊNCIA ELÉTRICA VARIADA EM FUNÇÃO DA DEFORMAÇÃO MECÂNICA DO MESMO; COM 4 SENSORES QUE REGISTREM AS FORÇAS APLICADAS NAS DIREÇÕES MÉDIO-LATERAL (X), ANTERO-POSTERIOR (Y) E VERTICAL (Z);	2019

RESULTADO 1

DADOS DA COMPRA

Identificação da Compra: 00015/2019

Número do Item: 00020

Objeto da Compra: Pregão Eletrônico - Aquisição de equipamentos médico-hospitalares para o Hospital Universitário da Universidade Federal do Amapá.

Quantidade Ofertada: 2

Valor Proposto Unitário: R\$84.000,00

Valor Unitário do Item: R\$ 84.000,00

Código do CATMAT: 112828

Descrição do Item: PLATAFORMA - AEREA TRABALHO, PLATAFORMA - AEREA TRABALHO

Descrição Complementar: PLATAFORMA - AEREA TRABALHO, PLATAFORMA - AEREA TRABALHO, PLATAFORMA DE FORÇA; PLATAFORMAS DE FORÇA 50 X 50 CM DE CÉLULAS DE CARGA; COM UTILIZAÇÃO DE TRANSDUTORES DO TIPO STRAIN GAUGE, QUE É UM DISPOSITIVO ELÉTRICO QUE TEM SUA RESISTÊNCIA ELÉTRICA VARIADA EM FUNÇÃO DA DEFORMAÇÃO MECÂNICA DO MESMO; COM 4 SENSORES QUE REGISTREM AS FORÇAS APLICADAS NAS DIREÇÕES MÉDIO-LATERAL (X), ANTERO-POSTERIOR (Y) E VERTICAL (Z);

Unidade de Fornecimento: UNIDADE

Modalidade da Compra: Pregão

Forma de Compra: SISPP

Marca: BTS BIOENGINEERING

Data do Resultado: 31/12/2019

DADOS DO FORNECEDOR

Nome do Fornecedor: KT COMERCIO DE EQUIPAMENTOS E PRODUTOS PARA SAUDE LTDA

CNPJ/CPF: 23160805000106

Porte do Fornecedor: Micro Empresa

DADOS DO ÓRGÃO

Número da UASG: 154215 - FUNDACAO UNIVERSIDADE FEDERAL/AP

Relatório gerado dia: 13/07/2020 às 19:35

Fonte: paineldeprecos.planejamento.gov.br

Capítulo 9

**Anexo 2: Parecer Consubstanciado
do Concelho de Ética e Pesquisa -
UFMG**

PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: Validade e Confiabilidade de um Instrumento para Avaliação Clínica do Movimento Humano

Pesquisador: Renan Alves Resende

Área Temática:

Versão: 1

CAAE: 00890818.8.0000.5149

Instituição Proponente: Escola de Educação Física, Fisioterapia e Terapia Ocupacional

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 3.006.449

Apresentação do Projeto:

Avaliações precisas e detalhadas são importantes para tomada de decisões na prática diária do fisioterapeuta. Assim, o objetivo do presente estudo é validar e empregar um Sistema de Baixo Custo para Análise de Movimento (SBCAM) capaz de mensurar parâmetros cinemáticos e cinéticos no ambiente clínico. O SBCAM consiste em uma esteira ergométrica comum, instrumentada com uma plataforma de força e um sistema de análise de movimento tridimensional, composto por um sensor de movimento, semelhante ao encontrando em celulares e que medem inclinações ou acelerações. A confiabilidade intra e inter-examinador do instrumento, bem como a validade será avaliada por medidas repetidas, realizadas por dois avaliadores treinados e com experiência em análise de marcha. Após a validação para análise de suas propriedades de medida, o sistema será empregado clinicamente em testes rotineiros realizados na Fisioterapia para agrupar dados e favorecer o entendimento do movimento humano. O estudo contará com a participação de indivíduos adultos saudáveis, que deverão comparecer 2 vezes ao laboratório de movimento.

Objetivo da Pesquisa:

Objetivo Primário:

Verificar a validade e a confiabilidade de um instrumento clínico prático e acessível para a análise do movimento.

Endereço: Av. Presidente Antônio Carlos, 6627 2º Ad SI 2005

Bairro: Unidade Administrativa II

CEP: 31.270-901

UF: MG

Município: BELO HORIZONTE

Telefone: (31)3409-4592

E-mail: coep@prpq.ufmg.br

Continuação do Parecer: 3.006.449

Objetivo Secundário:

Verificar o emprego desse recurso simplificado de análise do movimento na clínica.

Avaliação dos Riscos e Benefícios:

Segundo os autores:

"Riscos:

Esta pesquisa causa risco mínimo à integridade dos participantes, isto é, o mesmo risco existente em atividades esportivas usuais. O principal risco é a queda do participante enquanto ele estiver andando ou correndo na esteira. Para reduzir esse risco, apenas participantes com experiência prévia em caminhada e/ou corrida na esteira serão incluídos no estudo e a velocidade de caminhada e corrida será aumentada de maneira gradual, pelo próprio participante sob supervisão do avaliador e o participante será solicitado a caminhar e correr apenas na velocidade que considerar mais confortável para ele.

Benefícios:

Todos os participantes receberão um relatório fisioterapêutico detalhado com os dados de sua avaliação e orientações, caso necessário. Se comprovado a validade do sistema por meio desta pesquisa, os participante, bem como toda a população, poderão se beneficiar de análises fisioterapêuticas mais apuradas no futuro.

Comentários e Considerações sobre a Pesquisa:

Pesquisa de validação de um instrumento de avaliação clínica do movimento. Procedimentos bem descritos e viáveis.

Considerações sobre os Termos de apresentação obrigatória:

Todos os termos de apresentação obrigatória foram apresentados.

Recomendações:

Sou a favor, S.M.J., de aprovação do projeto.

Conclusões ou Pendências e Lista de Inadequações:

1- Rever a seguinte seção no TCLE: "Não haverá nenhum gasto por sua participação nessa pesquisa, além dos relacionados com seu deslocamento, bem como, não haverá nenhum pagamento pela sua participação." - as despesas com deslocamento devem ser realizadas pelos pesquisadores, não devendo, os participantes, arcar com nenhuma despesa.

Endereço: Av. Presidente Antônio Carlos, 6627 2º Ad SI 2005

Bairro: Unidade Administrativa II

CEP: 31.270-901

UF: MG

Município: BELO HORIZONTE

Telefone: (31)3409-4592

E-mail: coep@prpq.ufmg.br

Continuação do Parecer: 3.006.449

2- Incluir campo para rubrica do pesquisador e do participante em todas as páginas do TCLE.

Esse COEP confia que os pesquisadores farão a modificação solicitada.

Considerações Finais a critério do CEP:

Tendo em vista a legislação vigente (Resolução CNS 466/12), o CEP-UFMG recomenda aos Pesquisadores: comunicar toda e qualquer alteração do projeto e do termo de consentimento via emenda na Plataforma Brasil, informar imediatamente qualquer evento adverso ocorrido durante o desenvolvimento da pesquisa (via documental encaminhada em papel), apresentar na forma de notificação relatórios parciais do andamento do mesmo a cada 06 (seis) meses e ao término da pesquisa encaminhar a este Comitê um sumário dos resultados do projeto (relatório final).

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJECTO_1212741.pdf	04/10/2018 18:26:52		Aceito
Declaração de Instituição e Infraestrutura	Parecer.pdf	04/10/2018 17:40:08	George Schayer Sabino	Aceito
Projeto Detalhado / Brochura Investigador	PFinal.pdf	04/10/2018 17:38:13	George Schayer Sabino	Aceito
Folha de Rosto	Folha_rosto_George.pdf	11/09/2018 17:01:59	George Schayer Sabino	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLEv2.docx	11/09/2018 16:59:52	George Schayer Sabino	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

UNIVERSIDADE FEDERAL DE
MINAS GERAIS



Continuação do Parecer: 3.006.449

BELO HORIZONTE, 07 de Novembro de 2018

Assinado por:
Eliane Cristina de Freitas Rocha
(Coordenador(a))

Endereço: Av. Presidente Antônio Carlos, 6627 2º Ad SI 2005
Bairro: Unidade Administrativa II **CEP:** 31.270-901
UF: MG **Município:** BELO HORIZONTE
Telefone: (31)3409-4592

E-mail: coep@prpq.ufmg.br

Apêndice A

Artigo Publicado



Article

Development of a Human Motion Analysis System Based on Sensorized Insoles and Machine Learning Algorithms for Gait Evaluation

Diego Henrique Antunes Nascimento ¹, Fabrício Anicio Magalhães ², George Schayer Sabino ³, Renan Alves Resende ³, Maria Lúcia Machado Duarte ¹ and Claysson Bruno Santos Vimieiro ^{1,*}

¹ Bioengineering Laboratory (LABBIO), Graduate Program in Mechanical Engineering (PPGMEC), Universidade Federal de Minas Gerais (UFMG), Belo Horizonte 31270-901, MG, Brazil

² Department of Biomechanics, College of Education, Health, and Human Sciences, University of Nebraska at Omaha, Omaha, NE 68182, USA

³ Graduate Program in Rehabilitation Sciences, School of Physical Education, Physical Therapy and Occupational Therapy (EEFFTO), Universidade Federal de Minas Gerais (UFMG), Belo Horizonte 31270-901, MG, Brazil

* Correspondence: claysson@gmail.com; Tel.: +55-(31)-3409-6677



Citation: Nascimento, D.H.A.; Magalhães, F.A.; Sabino, G.S.; Resende, R.A.; Duarte, M.L.M.; Vimieiro, C.B.S. Development of a Human Motion Analysis System Based on Sensorized Insoles and Machine Learning Algorithms for Gait Evaluation. *Inventions* **2022**, *7*, 98. <https://doi.org/10.3390/inventions7040098>

Academic Editor: Anastasios Doulamis

Received: 23 August 2022

Accepted: 11 October 2022

Published: 21 October 2022

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



Copyright: © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract: Human gait analysis can provide an excellent source for identifying and predicting pathologies and injuries. In this respect, sensorized insoles also have a great potential for extracting gait information. This, combined with mathematical techniques based on machine learning (ML), can potentialize biomechanical analyses. The present study proposes a proof-of-concept of a system based on vertical ground reaction force (vGRF) acquisition with a sensorized insole that uses an ML algorithm to identify different patterns of vGRF and extract biomechanical characteristics that can help during clinical evaluation. The acquired data from the system was clustered by an immunological algorithm (IA) based on vGRF during gait. These clusters underwent a data mining process using the classification and regression tree algorithm (CART), where the main characteristics of each group were extracted, and some rules for gait classification were created. As a result, the system proposed was able to collect and process the biomechanical behavior of gait. After the application of IA and CART algorithms, six groups were found. The characteristics of each of these groups were extracted and verified the capability of the system to collect and process the biomechanical behavior of gait, offering verification points that can help focus during a clinical evaluation.

Keywords: biomechanics on gait; data mining; gait analysis; machine learning; smart insole

1. Introduction

The number of studies about biometric parameters in humans has significantly increased in the last years, mainly because of the advances in microelectronics and wearable devices. For example, the ground reaction forces (GRF) during human gait can be obtained by force plates [1], instrumented treadmills [2,3], or sensorized mats [4] or insoles [5–8]. Amongst these technologies, the sensorized insoles allow the measurement of the plantar pressures and a posteriori estimate the calculation of the GRF's vertical component (vGRF) [9,10] and how these pressures are distributed in the foot's sole during movement [11,12]. This approach permits the investigation of different movement patterns [13], and it is portable and simpler to operate than the usual force plates.

Although there are commercial options for sensorized insoles (F-scan [14], Dynafoot2 [15], Flexinfit [16]), the acquisition costs are still a factor that limits the diffusion of this technology. Another factor is that commercial insoles have a closed system by the manufacturer, making integration with other software difficult, and it is impossible to modify the insole in terms of the number, position and size of sensors. These factors encourage the development of academic prototypes [5,11,17–19] to reduce costs and have greater control

during data acquisition tests. These academic prototypes also seek to optimize the insoles' layouts [20] to improve the correlation with force plates (the "gold standard") by proposing different sensor configurations and varying the position and size of the sensors in the search for better results. However, the most academic prototypes use commercial force sensors [11,14,17,19], making the level of insole customization remain limited to the types of sensors available. In addition, some studies about the academical prototypes have poor documentation regarding the manufacturing process [17], data acquisition and processing system [15,17], and some of them do not have validation based on force plates [14,17]. Therefore, it was decided to develop a sensor that would fulfill the needs of this study. The insole developed did not use any commercial sensor, and all sensors used were customized and optimized for the application. This customization of the sensors prioritized the demands of the study, the durability of the insole and the costs of the equipment which added a degree of novelty to the equipment.

Sensorized insoles can provide gait kinetic information. Based on this information, machine learning techniques have been used to identify gait patterns for injury prevention [21,22]. The study of pattern recognition based on machine learning has already been used in kinematics [23,24], which can be referenced for applications in kinetics. Several clinical dysfunctions and overload-related injuries, such as patellofemoral syndrome or rupture of the knee's anterior cruciate ligament, have been associated with abnormal movements in the frontal plane of the foot-ankle complex [25]. Either standard or abnormal foot pronation/supination movements can be identified using mathematic techniques based on machine learning (ML) [21,26] and can be used to predict future injuries [22].

According to Slijepcevic, Djordje, et al. [27], support-vector machines (SVM) and multi-layer perceptrons (MLP) are relevant ML techniques applied to gait analysis. These algorithms have two sensitive points: supervised training and they are considered a "black box" [27]. Supervised training requires prior knowledge of the gait patterns to be recognized or classified, and this knowledge is not always available. Human movement is considered a complex system [28], and it is not always clear to define a restricted number of initial patterns based on limited variables for training the algorithm. In this case, there is a risk of adding a tendency to the algorithm and restricting the generalization ability. After training the ML algorithms (SVM and MLP), it is not possible to directly evaluate the criteria adopted to perform the classification of data, and, therefore, they are called a "black box" solution.

Therefore, this work aims to present the development of a system for measuring and analyzing the vGRF through sensorized insoles. The sensorized insole proposed has an optimized layout, presenting increased sensor area, increased acquisition rate, and a low cost. The system analysis is based on an ML algorithm to identify different patterns of vGRF's signals to extract biomechanical characteristics autonomously, without prior knowledge of the data. This work proposes implementing an unsupervised machine learning algorithm (immunological algorithm, IA) that will perform clustering of gait patterns without needing prior knowledge of the data. The response of this algorithm was used as a basis for training another algorithm (classification and regression tree, CART), from which it is possible to extract the criteria adopted to perform the classification. The interaction between IA and CART makes it possible to create a self-sufficient processing funnel capable of identifying and classifying gait patterns, providing a structured flow that underlies this answer. Hence, coaches, clinicians, and researchers can benefit from a low-cost, accurate, and user-friendly system for the clinical evaluation of walking.

2. Materials and Methods

A low-cost sensorized insole with resistive sensors was developed to obtain the gait information and build a database. An ML algorithm uses this database to seek similarities between an individual's gait characteristics to cluster them and to construct a list of rules about this classification to explore potential relations. The typical algorithm for gait clustering and classification are K-nearest neighbors [29] and support-vector machines [29].

However, these algorithms must have supervised training [30]. Because of that, the immunological algorithm (IA) was chosen to perform the previous classification to overcome this limitation. The IA [26] is an ML algorithm based on unsupervised learning. This means that prior classification knowledge of the database is not required [22]. Once the algorithm adapts to the database, it becomes convenient to use it in a complex system of limited predictability [31]. After solving the problem of identifying the initial data, the classification and regression trees (CART) algorithm was chosen to extract features (i.e., data mining) [32] and explicitly show how the clusters differ themselves considering gait's biomechanical characteristics. The CART is different from other classification algorithms such as MLP and SVM because the classification process is structured, allowing further exploration.

2.1. Insole Construction

The most popular sensorized insoles use two types of sensors: piezoelectric [33,34] and resistive [35]. Piezoelectric sensors record the pressure variation during activation, which compromises the assessment of static situations (i.e., constant pressure). Resistive sensors, on the other hand, use a conductive polymeric membrane capable of changing their conductivity when pressed. The sensorized insoles of the present study were built using resistive sensors, an electronic circuit was printed into a copper-coated polyamide blade (Figure 1a), and a conductive polymeric film was added to the pressure sensor regions (Figure 1a). In the literature, the regions of sensors' positioning (plantar mask) may vary according to the purpose of the study and are usually numbered to represent the points of interest [22].

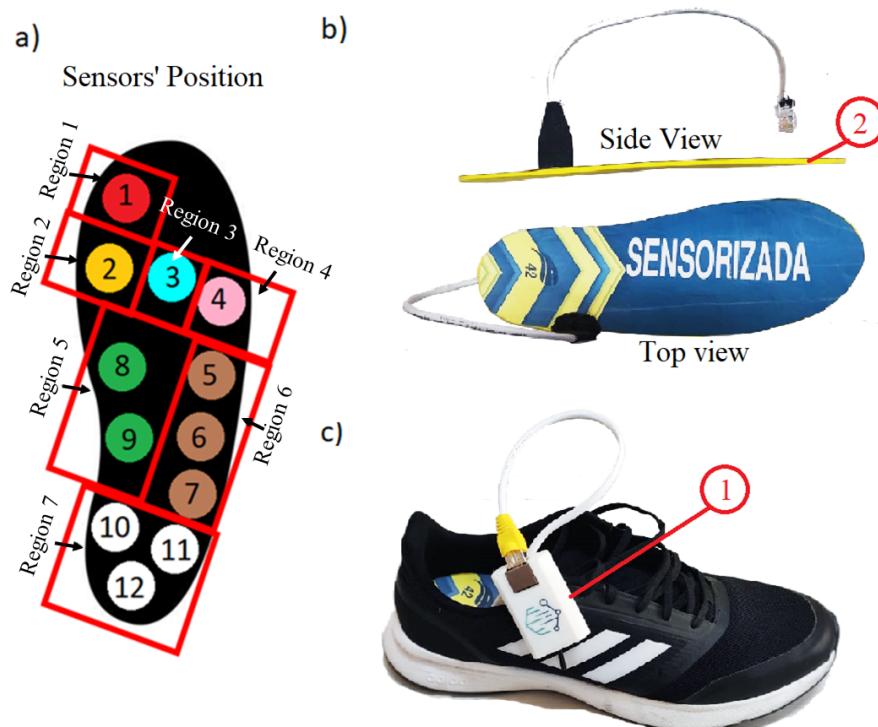


Figure 1. (a) Visualization of the seven regions of sensors with 12 sensors in total. (b) Visualization of the finished sensorized insole. The picture also shows the EVA base of the insole (2). (c) Visualizing the compact sender device (1) that connects with a sensorized insole using an RJ45 connector.

Seven regions were chosen to include the sensors according to the foot anatomy [20,36], and each region also has a relationship with the gait phases and their positions, which permits us to observe some behaviors of the following regions: posterior calcaneus (three sensors)—this region is the most important region to record loading response (first phase of gait); medial midfoot (navicular bone, two sensors) and lateral midfoot (cuboid bone,

three sensors)—these regions can indicate medialization of plantar pressure and may be an indicator of flat feet or increased pronation; lateral forefoot (5th metatarsal head, one sensor), central forefoot (between the second and third metatarsals heads, one sensor) and medial forefoot (1st metatarsal head, one sensor)—these regions are responsible for recording terminal support and pre-swing. The balance between these three regions indicates medialization or lateralization of plantar pressure. Finally, the last region is the hallux (1st proximal phalangeal head, one sensor). This region marks the end of the stance phase and the beginning of the swing phase.

Each insole weighs 25 g with 2.0 mm of thickness and 12 sensors. Each one has 8.05 cm² of area. Saidani and Salma et al. [37] report satisfactory results using insoles with 6–12 sensors, and according to Fuchs and Philip et al. [20], with 11 sensors, it is possible to achieve the "optimal compromise between simplification and measurement performance." In addition, there is a layer of EVA (ethyl vinyl acetate) shore 30 of hardness on the bottom face to protect the insole from breaking, replacing the shoes' insole and standardizing the contact between the sensorized insole and the shoe (Figure 1c). According to Klimiec et al. [26], this additional rigid layer is a "technical solution to prevent film stretching to ensure the correct measurement of forces against the substrate."

A micro-controlled circuit was built to perform the reading of each sensor through an analog port, sending a small voltage signal (3.3 V), recording and interpreting the voltage drops from their activation. The circuit was based on the ESP-32 microcontroller from the manufacturer Expressif because it has excellent processing power. The system was configured to acquire both foot data at a 375 Hz frequency, more significant than most insoles verified (Table 1), ensuring higher resolution during data acquisition. The sensor area was also bigger than usual (Table 1), helping the alignment of the anatomical regions of the foot on the sensor, a point presented as critical in the literature [20]. Both collected signals were synchronized by a router using a particular WIFI protocol from ESP-32 called espnow [38]. This protocol permits a peer-to-peer synchronization between sensors without losing the data package. After the synchronization, a router sent the information to the main computer using a serial connection to perform the data registration and post-processing using a custom-built software using C#. Table 1 shows the most popular resistive sensorized insoles in the market used for gait analysis compared to the proposed one in this study. However, the commercial systems show a high acquisition cost, stimulating many academic prototypes with novel sensor technology. Table 1 also shows some resistive instrumented insoles used for academic purposes.

Table 1. Comparison among the most popular resistive sensorized insoles.

Insoles	Number of Sensors	Freq. (Hz)	Thickness (mm)	Sensor Area (cm ²)
Proposed Insole ²	12	375	2.00	8.05
F-Scan ¹ [14]	960	750/100 (Wi-fi)	1.50	-
Dynafoot ¹ [15]	58	100	-	-
Medica Flexifit ¹ [39]	214	25–50	0.30	2.27
Medilogic ¹ [16]	240	50–100	1.60	-
R. Eguchi ² [11]	14	80	-	-
Wei-Chun Hsu ² [17]	5	100	0.45	1.27
Ivanov ² [5]	9	25–50	0.80	0.71
A. Tiwari and D. Joshi ² [18]	16	88	2.50	-
Guo et al. ² [19]	8	100	-	2.62

¹—Commercial insoles ²—Academical insoles.

2.2. Insole Calibration

Each sensorized insole was calibrated on a bench using a precision scale (Scale SF-400, max load 10 kg/1 g, China). First, they were placed on the scale, and every single sensor was pressed using a pre-established weight of 1 kgf to 8 kgf, increasing by 1 kgf per

measurement [6]. Each measurement was performed three times to obtain an average of the measurements. Next, each cell was calibrated using linear regression to relate the captured values to the measured kgf [11] using Excel fit regression (Appendix C). Although the non-linear behavior of the electrical resistance drops of force resistive sensors is documented in the literature [40], it was observed that several authors used only the linear calibration functions [41–43], or they used the linear function as a reference for comparison, and they concluded that the linear calibration function produced superior results to non-linear functions [44,45]. This is because the acquisition system cannot measure the resistance drops directly but instead measures the generated voltage drops, which is the inverse of the resistance [40]. These voltage drops have a behavior that is nearly linear in a specific operating range that ignores very low pressures (at the beginning of deformation, where the non-linear behavior is predominant) and very high pressures (close to the sensor limit). According to the sensor calibration manual of the company TECKSCAN, the manufacturer of the (F-Scan), used as a reference, the proposed calibration function is a linear function [46]. Finally, each linear coefficient was used after calibration to adjust each sensor's time series during gait tests presented forward.

2.3. Ethical Approval

The present study was approved by the Institutional Research Ethics Committee (CAAE 00890818.8.000.5149) and conducted according to the Declaration of Helsinki.

2.4. Sample Size Calculation

To guarantee an appropriate sample size calculation and power analysis, we used G-Power (v.3.1.9.7) software [47]. The statistical test chosen on G-Power was the bivariate normal test with two tails using as a parameter Cohen's $d = 0.6$, $\alpha = 0.05$ and power equal to 0.95 [47]. The sample size necessary was calculated to be 30 participants.

2.5. Participants

Participants with the following inclusion criteria were recruited: between 18 and 45 years old, body mass index (BMI) between 20 and 34.9 kg/m², no surgery on the lower limbs and lumbar spine in the last six months, and no reported neurological disorders. A total of 32 participants (18 men) were recruited during this study. Discomfort or difficulty in performing the tests was considered an exclusion criterion. Failure of equipment or data loss was also considered an exclusion criterion. All 32 participants were considered healthy. Most studies involving the validation of sensorized insoles use healthy volunteers [48] to avoid significant variations in the ground reaction curves due to a pathology that may mask or interfere with any error that the instrument may present.

2.6. Testing and Validation Process

After the calibration and signing of a free and informed consent form, each participant wore a pair of insoles and walked on the treadmill at a self-selected speed for 60 s to get used to the insole and then added 60 s for data collection.

The validity analysis was performed empirically by performing a concurrent validity analysis, in which the result of a developed instrument is compared with a "gold standard" [49]. In this way, the sensorized insoles' force estimations were compared against those from a double-belted instrumented treadmill containing two force plates (TFP) and a walking surface of 1.75 × 1 m (Bertec at 1000 Hz, Bertec Corp, Columbus, OH, USA [50]) to verify the validation of the insoles' sensors. However, there is no consensus in the literature regarding the calculation of validity [51]. The Pearson coefficient [39,52,53] is one of the most used coefficients and can be complemented with the coefficient of multiple correlations (CMC) [54,55]. According to Mukaka [56], correlation values above 0.7 are considered high correlation and, in this study, were the minimum value necessary for validation. For the validity calculation, 30 steps from all recorded steps were considered (selected by the central part, excluding the extremes), and arithmetic mean was performed to obtain a

single mean step representing the volunteer's gait. The average curves were synchronized starting based on the initial contact phase of the gait, and the acquisition frequency of the instrumented treadmill (force plate) was adjusted to the same as the sensorized insole. The raw data was filtered with a 4th order low pass Butterworth filter with a cut-off at 6 Hz for the kinematic data and 15 Hz for the kinetic data.

2.7. Pronation/Supination Classification

The kinematics were tracked in the Qualisys Track Manager program (Version 2019.3, Qualisys MEDICAL AB, Göteborg, Sweden) and processed in the Visual3D x64 Professional program (v2020.02.04, C-Motion, Germantown, MD, USA) to verify pronation and supination on the ankle joint in the frontal plane during gait (Appendix B).

2.8. Immunological Algorithm (IA)

The data collected in each trial were composed of seven time series from the insoles' sensors arrangements with one minute each. Then, the vGRF could be estimated at each moment by summing all signals and applying the calibration curve (Section 2.2). In sequence, the vGRF estimated data of each lower limb (left and right) were input to the IA. This way, it was initially analyzed in 64 different walking trials (32 participants' both feet). After the tests, the IA processed the data and automatically grouped them. Each group contains samples of vGRF normalized by the maximum value (i.e., data variation was between 0 and 1). This study's magnitude of vGRF was not considered, focusing only on the waveform.

The input data underwent Fourier transform to change the domain from time to frequency. Prasanth and Hari et al. [57] reported in a systematic review that less than 5% of data analysis occurs in the frequency domain, justified by simplicity, intuitiveness, and computational complexity. Frequency domain analysis has already been applied in recognition of kinematic gait patterns [58], and it was possible to detect biometric patterns. However, according to Chockalingam, Healy, and Needham [1], the time-domain analysis is limited to the selected points on force-time graphs. However, in the frequency domain, the analysis is extended to the entire waveform, making the identification of gait abnormalities more useful [17]. Additionally, this was an attempt to represent the temporal data, decrease dimensionality to reduce the time for data processing, and standardize the problem to improve the IA results [59]. The generated Fourier coefficients represent the chromosomes of the antigens to be recognized by the immune system [30]. The silhouette criterion and the clonal selection (CLONALG) were used with a random mutation operator to evaluate the interactions based on antigen-antibody. The silhouette coefficients are the most common metric in unsupervised learning algorithms, being able to concentrate cohesion and separation metrics in a single indicator [60]. More information about this procedure is detailed in [59,61]. The IA was an authorial implementation in Visual Studio (2019, Microsoft, Redmond, WA, USA) using the open-source MathNet.Numerics package (<https://numerics.mathdotnet.com/> accessed on 8 January 2022). Figure 2 presents a diagram of the grouping process.

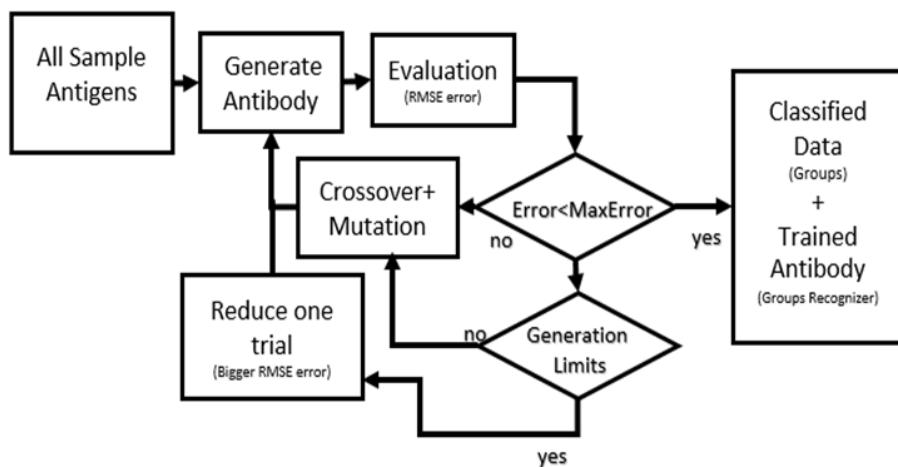


Figure 2. Data flowchart steps using IA. Each antigen-antibody interaction is evaluated using root-mean-square error to quantify this interaction sample by sample. After the evaluation process, a new group of samples is created if the mean of all RMSE is satisfactory. If the mean of all RMSE does not achieve the goal, one sample would be removed from the database, and the process is restarted until a new group is achieved. All removed samples were submitted again to the same process separately until all samples were grouped.

2.9. Classification and Regression Trees (CART)

The IA grouped the samples with similar curve shapes (based on the frequency spectrum), adding to the database new information: group classification number. After grouping, an investigative process was started to identify common characteristics that may facilitate the clinical interpretation of possible relevant issues of each group (Data Mining). In other words, a set of bioindicators used in pronation studies involving GRF was calculated for each walking phase (as described ahead), which are: mean force (MF) [62], impulse (Im) [62], the mid-lateral center of pressure axis (COPx) [63], and time duration percentage (DP) [63]. These bioindicators were extracted from the same database and were used as predictors for the training of the CART algorithm. They were statistically validated with TFP using a Student's *t*-test (paired two-sample), and the results indicated no significant difference between SI and TFP. In this process, the CART was not used to predict results but to find the bioindicator's cut-off points to define a specific group. Mean force (kgf) was calculated as the arithmetic average of vGRF registered, while impulse (kgfs) was the product of force by time on each walking phase. During walking, the impulse is related to force absorption [64]. The center of pressure (COP, in mm) was the GRF's virtual mean position acting on the foot's sole [65]. It generally starts slightly away from the posterior end of the calcaneus [66] and travels on the foot's sole during the stance phase towards the second metatarsal head [60]. This path can be calculated based on Equations (1) and (2) [7,65].

$$COP_x(t) = \frac{\sum_{i=1}^{i=7} X_i P x_i}{\sum_{i=1}^{i=7} X_i} \quad (1)$$

$$COP_y(t) = \frac{\sum_{i=1}^{i=7} X_i P y_i}{\sum_{i=1}^{i=7} X_i} \quad (2)$$

These equations use weighted averages of the sensors' positions (P_x and P_y) and the forces registered by the sensors (X_i), considering the center of the calcaneus as the origin of the coordinate system [65]. Thus, the COP's initial and final position in each phase could be verified, giving quantitative information for clinical assessments. For example, COP's medialization or lateralization can be used as an indicator of foot pronation or supination [30]. Finally, time duration (in percentage) was the mean time spent on each walking phase.

In sequence, the group's information from the IA was used as an outcome for the CART analysis, and the bioindicators were used as predictors. Each bioindicator was analyzed at four different moments, following the specific walking phases presented in Figure 3: loading response, midstance, propulsion (terminal stance and pre-swing), and swing [67]. These walking phases could be identified through the sequence of combined active sensors [67,68], as depicted in Figure 3. First, the loading response phase was detected when the calcaneus area achieves 2.0 kg after a period without loading (swing phase). Next, the midstance phase begins when the anterior region (central forefoot, medial forefoot, lateral, and hallux) achieves 2.0 kg and the calcaneus is still recording loading. Next, when the calcaneus stops recording, loading begins the propulsion phase (terminal stance and pre-swing). Finally, when all sensors detect no loading, the swing phase begins.

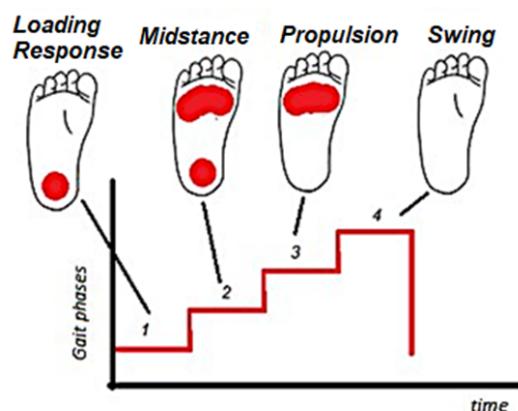


Figure 3. Walking phase identification based on activation sensor sequence. “Loading response” is based on calcaneus activation, “midstance” is based on calcaneus, lateral forefoot (5th metatarsal head), central forefoot (between the 2nd and 3rd metatarsals heads), and calcaneus activation, “Propulsion” is based on lateral forefoot (5th metatarsal head) and central forefoot (between the 2nd and 3rd metatarsals heads) activation, and “Swing” is based on no activation.

After the CART training, a decision tree was generated, and a cascade of decision rules was constructed to relate the predictors to the outcome [69,70]. This algorithm can deal with multiclass classifications and regressions and is widely used as a data extractor [1]. The attributes and similarities used to separate the groups and detect the cut-off point for each group could be identified. The CART was performed on WEKA software (version 3.8.5, University of Waikato, New Zealand). Figure 4 presents the step-by-step sequence of the data processing from the participants’ test to the CART algorithm.

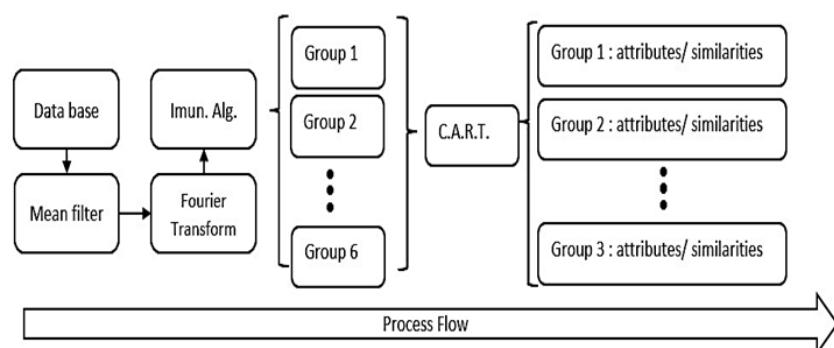


Figure 4. Data pipeline steps. All data were filtered, and a Fourier transform was applied before using the IA. As a result of IA, each sample would receive a group number based on Fourier spectrum similarities (result from IA processing). The group information was used as an outcome for the CART. After CART processing, the result was a list of N groups with similar gait behaviors.

3. Results

3.1. Insole Verification

The Person's correlation coefficient between the insoles and the scale was 0.95 (ranging from 0.93 and 0.97) for the calibration and 0.94 (ranging from 0.90 to 0.98) compared with the force plate after applying the correction factors. The smaller standard deviation was 0.15, and the greater was 0.45. Figure 5 shows two GRF's vertical components time series (insoles vs. force plate). The insole-based system had the worst performance in estimating the midstance amplitude (approximately 50% of the cycle).

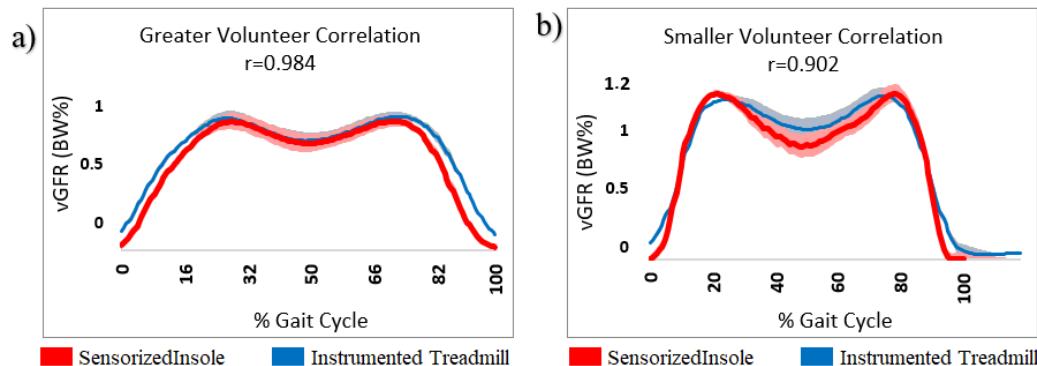


Figure 5. vGRF normalized curves dividing by maximum value during 1-min walk using the sensorized insole (red line) and the force plate (blue line) as reference. The shadows are the respective standard deviations. (a) Greater correlation sample and (b) smaller correlation sample. r : Pearson correlation coefficient.

3.2. Kinematics Evaluation

The kinematics of each sample (64 samples—32 participants, both feet) were tracked and verified on the frontal plane to classify the data into three groups: pronation, supination, and neutral on impulse phase. Figure 6 shows the normalized ankle's angle on the frontal plane representing each behavior. The pronation behavior was defined arbitrarily for analysis purposes as when the ankle's angle was smaller than -0.5 (Figure 6a) during the push-off. The supination behavior was defined as when the ankle's angle was bigger than 0.5 (Figure 6b), and the neutral was defined as when the ankle's angle was between -0.5 and 0.5 (Figure 6c).

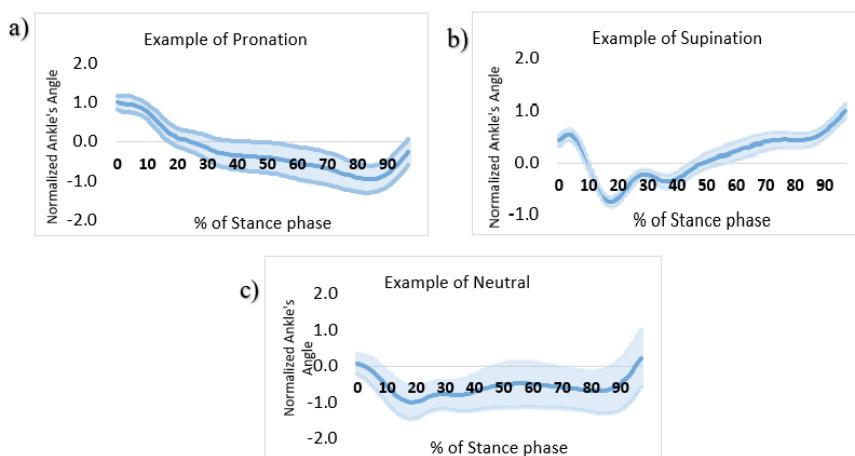


Figure 6. Normalized Ankles' Angle on the frontal plane on time, during stance phase, and with the zero references on orthostatic position. Figure (a) shows an example of pronation, (b) supination, and (c) neutral.

3.3. Data Processing

After applying the IA, the silhouette coefficients achieved a maximum value of 0.74 for seven groups with the following distribution of vGRF samples: 18 in Group 1, 8 in Group 2, 6 in Group 3, 6 in Group 4, 12 in Group 6, 7 in Group 6 and 7 in Group 7. The CART algorithm correctly classified samples at a rate of 86% and was considered a good result compared with the usual ML injury prediction models [21,22]. This means that 86% of samples have a unique set of features that allows the system to identify a specific behavior on walking using the bioindicators. During the training process of the CART algorithm, Group 7 was excluded because all members of Group 7 were considered errors and were removed from the analysis. This means that Group 7 could not identify a specific behavior in walking using the bioindicators.

Therefore, six groups entered the final results, with 57 trials (total without Group 7). Figure 7 shows all six groups obtained after the data processing.

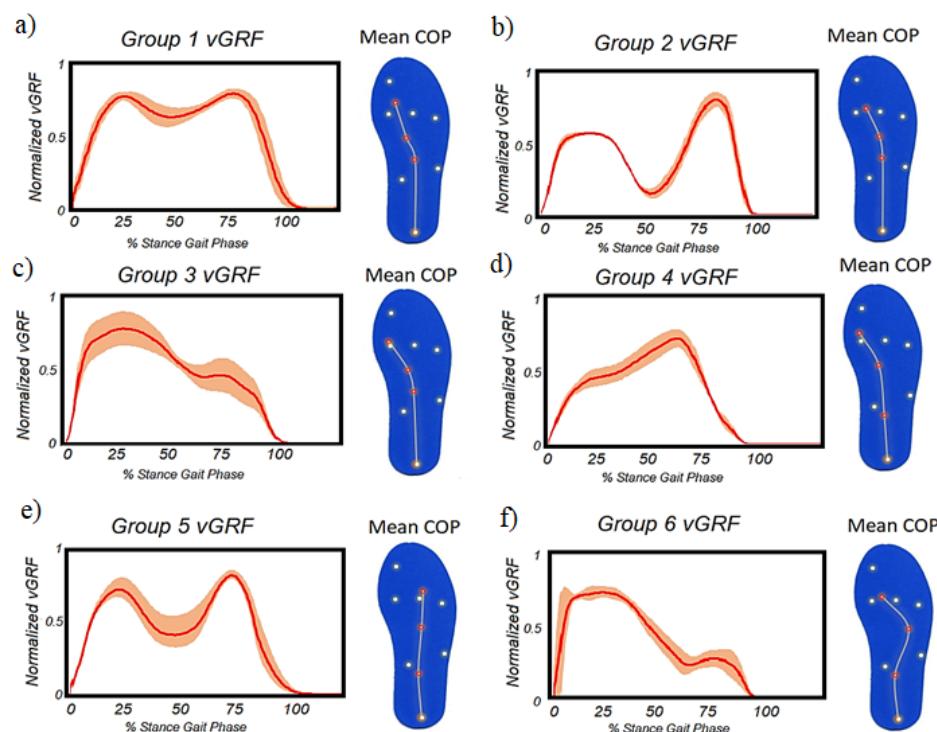


Figure 7. vGRF and COP average of each group. The continuous line is the mean of the one-minute test, and the shadows are one standard deviation of the group. The COP chart is marked with the transition of each gait: (a) Group 1, (b) Group 2, (c) Group 3, (d) Group 4, (e) Group 5, and (f) Group 6. GRF: Ground reaction force. COP: Center of pressure.

Group 1 (Figure 7a) was considered the typical group because the shape of the curve (vGRF) is similar to what is expected based on the literature [71]. In this group, an increase in the average forces during midstance (18.5%) as well as in the midstance duration (6.9% as the database average) were found. When analyzing the group members, on average, the COP had a medialization of around 22.5% in midstance. Group 1 had a prevalence of pronation (55.5%) but still had an expressive presence of supination (27.7%) and neutral (16.8%) behavior. Altered forces during the loading response were found in Groups 2, 3, and 4. Group 2 (Figure 7b) was characterized by a bigger impulse (27.4%) and average force (21.2%) during propulsion. Group 2 had a prevalence of pronation (75%) and a small presence of supination (12.5%) and neutral (12.5%) behavior. Group 3 (Figure 7c) was characterized by a decreased impulse (19.76%), mean force (5.2%), and increased loading response duration (12.7%). Group 3 had a prevalence of pronation (66.7%) and a small presence of supination (16.7%) and neutral (16.7%) behavior. Group 4 (Figure 7d) was characterized by a reduced loading response

duration (15.7%). This decreased loading response duration was accompanied by a decreased midstance duration (8.5%) and a reduced average force (20.1%). Group 4 had no pronation behavior recorded and a small presence of supination (16.7%). Neutral (83.3%) behavior dominated this group. Altered forces during the propulsion were found in Groups 5 and 6. Group 5 (Figure 7e) had an increased propulsion duration (18.7%). Group 6 (Figure 7f) was characterized by a reduced impulse (44%) and average force (37.8%), as well as decreased peak force (28.5%). In Groups 5 and 6, pronation or supination behavior was not detected. Figure 8 shows the decision-making structure extracted from CART after the pruning and exclusion of Group 7.

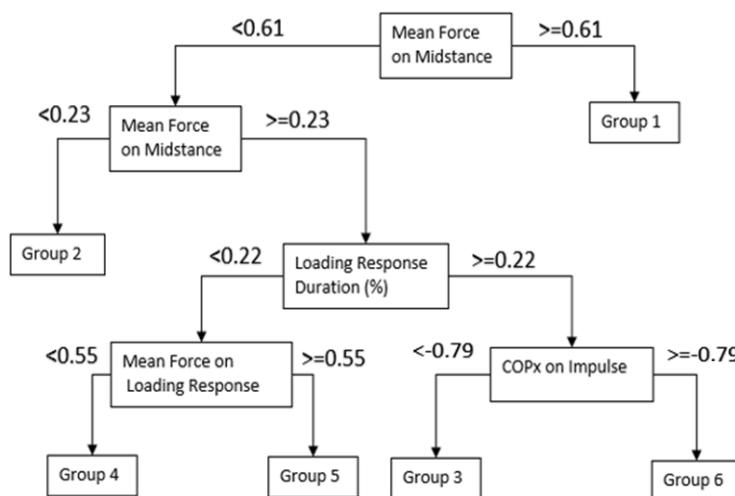


Figure 8. A flowchart of the decision-making structure extracted from CART after the pruning and exclusion of Group 7. Values of force and duration were normalized between 0 and 1, and values of COPx were normalized between -1 and 1.

4. Discussion

The aim was to develop a system to measure the vGRF and identify different patterns of vGRF signals to extract biomechanical characteristics. As a result, six groups emerged, showing particular behaviors that would help examiners to focus their attention, such as the activation of medial midfoot sensors (Group 1) and increased or decreased forces during the loading response (Groups 2, 3, and 4) and propulsion (Groups 5 and 6). Each one of these groupings may represent certain conditions, as discussed below.

The activation of medial midfoot sensors (Group 1) can represent, for example, excessive foot pronation or even the severity of flat feet. In a study about the COP path in elderly adults, a medial deviation of COP was observed, an indicator of pronation [72]. Groups 1, 2, and 3 have a predominance of pronation behavior and corroborate this relationship between COP and excessive foot pronation, although the increase in midstance mean force or activation of the medial midfoot sensors was not always present. The CART flowchart shows the opposite relationship between values of midstance mean force on Group 2 and pronation behavior. Thus, simplifying cause and effect, where a relationship of increased midstance mean force or activation of the medial midfoot sensors indicates excessive foot pronation, is reckless and is not confirmed in practice.

Altered forces or duration on the loading response phase (Groups 2, 3, and 4) can be related to gait strategies to absorb impact since increasing forces during the loading response can overload cartilages and joints [73]. Moreover, the altered forces during propulsion found in Groups 5 and 6 can result from the ankle plantar flexors' performance [73]. Although this could not be verified in the present study, these muscles are considered the most significant contributor to impulse in terms of force intensity and time duration. Therefore, any alteration in these parameters may be related to ankle plantar flexors' weakness or movement compensation [74].

Some methodological limitations could be identified, and they will be implemented in the future. Firstly, the developed sensorized insoles, similar to the commercial ones, could measure only the vertical component of GRF. The most used GRF component in the gait analysis, the anteroposterior and mediolateral axes, are crucial for quantifying the torsional forces in the lower limbs. Secondly, the system could not measure the kinematics, thus providing a complete solution for human motion analysis. Initially, it was developed to measure only the foot kinetics as their sensors, but, in the future, other devices like the inertial sensors will be added to the system. Thirdly, the sensorized insoles had the lowest accuracy in registering the plantar pressure during midstance. In this phase, the foot has a high area in contact with the ground during the gait cycle, so the area with no sensor increases its contribution to the vGRF calculations, which must be compensated for in future versions. However, even with these characteristics, the sensorized insole achieved a mean Pearson superior to 0.90, a very high positive correlation [56]. Finally, the appearance of a group of GRF patterns (Group 7) during the IA processing, for which CART could not identify patterns that differentiate them, draws attention once again to the complexity of human movement. This situation was caused by the limited amount of bioindicators available as predictors for CART, causing no related behavior patterns to be found. Different behavior patterns, such as Group 7, can be found if the number of volunteers increases or the employment of other biomarkers and, with this, a better approach will be possible.

Likewise, other factors may have impacted the results, such as the architecture of the foot arches, how tight the shoes were, and the correct placement of the insoles into the shoes. Differences in foot arches were expected, so they were not used as exclusion rules and were not considered in the analysis. A sequence of pre-tests were performed to control the tightness of shoes and correct placement of the insole. Additionally, the developed system could not identify or rank possible causes for the bioindicators' variation found in those six groups, since it was not within the scope of this study. However, it could be used to identify patterns to be deeply investigated.

The system developed could extract typical behaviors from the time series based on bioindicators from the human gait based on a database. Expanding this database with more samples can increase the number of groups to find different recognition patterns, enabling a continuous process and adaptive improvement. Although the study included only healthy volunteers, based on the inclusion, only people with neurological disorders and with a history of recent surgery were excluded, including volunteers who may have altered gait due to other factors, such as excessive pronation and supination or muscle weakness or shortening. Even in healthy volunteers, there is a presence of different gait patterns that can be used as predictors of injury [22]. Identifying gait patterns in healthy volunteers can be considered a challenge for the system [21] since the changes in gait are not as evident as in patients with neurological disorders. Sometimes, these different patterns can present themselves in different intensities and combinations, making gait analysis difficult. Therefore, the system demonstrates enough sensibility to distinguish different patterns and establish cut-off limits between different standards and can be used to investigate the potential risk of injury.

5. Conclusions

In summary, the system offered a portable and compact solution with hardware and software integration that can collect and accurately process the vGRF during walking and classify the walking behavior according to clinical groups without prior knowledge. The work's main objective was achieved. During the execution of the work, the decision to develop an authorial sensorized insole proved to be a good decision. This is because it was possible to achieve a high correlation with a force plate and high acquisition frequency using Wi-Fi data transmission to fully control the hardware and software architecture, allowing a continuous improvement of the equipment and the system. It was also possible to obtain a good finish of the product that puts the insole prototype at an advanced stage compared

to other academic prototypes regarding serial production and commercialization without depending on third-party equipment. The results of the cooperative application of machine learning techniques presented good results. The use of IA allowed a prior grouping of data based on the behavior of the vGRF without the need for prior knowledge on the researcher's part, self-regulating the number of groups that presented different characteristics from each other. The CART applied afterward allowed relating spatial-temporal variables and bioindicators to the vGRF patterns, allowing to sketch potential relationships of kinetic and kinematic behaviors. The system presented great exploratory potential and proved to be an excellent tool to improve the understanding of gait and its complexities. Furthermore, the measured biomechanical characteristics may help the foot's functional evaluation by offering quantitative parameters (bioindicators) without requiring extensive motion laboratory infrastructure and exhaustive calibration and preparation routines.

Author Contributions: Conceptualization, D.H.A.N. and G.S.S.; methodology, D.H.A.N. and G.S.S.; software, D.H.A.N.; validation, G.S.S.; formal analysis, G.S.S., D.H.A.N. and F.A.M.; investigation, D.H.A.N. and F.A.M.; writing—original draft preparation, D.H.A.N.; writing—review and editing, G.S.S., F.A.M., R.A.R., M.L.M.D. and C.B.S.V.; supervision, R.A.R., M.L.M.D. and C.B.S.V.; project administration, M.L.M.D. and C.B.S.V. All authors have read and agreed to the published version of the manuscript.

Funding: This study was financed in part by the Pró-Reitoria de Pesquisa (PRPq) from Universidade Federal de Minas Gerais (UFMG) and the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior—Brasil (CAPES).

Institutional Review Board Statement: The present study was approved by the Institutional Research Ethics Committee (CAAE 00890818.8.000.5149).

Informed Consent Statement: Informed consent was obtained from all subjects involved in the study.

Data Availability Statement: Not applicable.

Acknowledgments: This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior—Brasil (CAPES)—Finance Code 001 and the Pró-Reitoria de Pesquisa (PRPq) from Universidade Federal de Minas Gerais (UFMG).

Conflicts of Interest: The authors declare no conflict of interest.

Appendix A

The validation of the variables used during the study was performed using the sensorized insole together with the treadmill force platform. Each gait was collected following the same parameters adopted in the methodology. Figure A1 presents the identification of each of the variables used. Tables A1 and A2 shows the results.

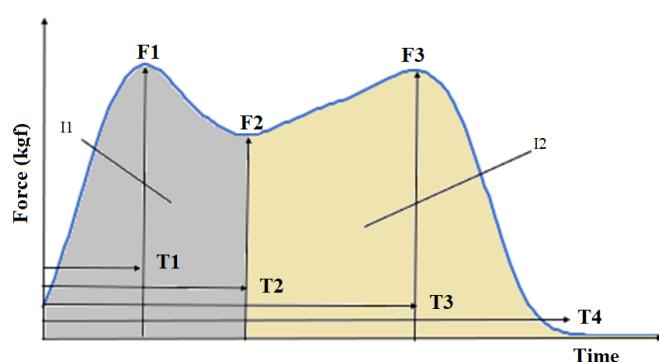


Figure A1. Identification of each of the variables used for statistical verification. Legend: I1: impulse during load absorption; F1: peak force of loading response; F2: low force of midstance; F3: peak force of push-off (impulsion); T1: time into loading response; T2: time into midstance; T3: time into impulsion; T4: total time to stance phase.

Table A1. Kinetic verification.

Localized Verification		
	RMSE	p-Value
Peak force of loading response (F1)	2.34	0.0165
Low force of midstance (F2)	6.08	0.0760
Peak force of push-off (F3)	5.38	0.095
COPx (load response)	0.057	0.0432
COPx (midstance)	0.118	0.0821
COPx (push-off)	0.214	0.3123
Curve Correlation		
	Pearson	RMSE
COP X	0.82	0.21
GRF	0.94	0.29

Legend: GRF: ground reaction force; COPx: center of pressure (Axis X); RMSE: root-mean-square error; CMC: coefficient of multiple correlations.

Table A2. Time Variables Verification.

	RSME	p-Value
Time of Loading Response (T1)	0.01	0.04
Time of Midstance (T3-T1)	0.02	0.08
Time of Push-off (T4-T3)	0.01	0.31

Legend: RMSE: root-mean-square error.

Appendix B

For kinetic and kinematic data acquisition, 14 mm passive retro-reflective markers were fixed to each participant, seven on each individual's lower limb. The markers were positioned in the: central region of the calcaneus, head of the first metatarsal, head of the fifth metatarsal, over the lateral epicondyle of the femur, over the medial epicondyle of the femur, over the lateral malleolus, and over the medial malleolus. In addition, a rigid cluster with four passive retro-reflective markers was positioned in the posterolateral region on the distal third of the leg using an elastic band and double-sided tapes (Figure A2b—Appendix B). Data acquisition in a standing position was performed for five seconds, which was later used to create the biomechanical model and served as a biomechanical reference for the angular variations (Figure A2c—Appendix B). Subsequently, the anatomical markers on the epicondyles were removed, and gait acquisition was performed. The markers were tracked in the Qualisys Track Manager program (Version 2019.3, Qualisys MEDICAL AB, Sweden) and processed in the Visual3D x64 Professional program (v2020.02.04, C-Motion, USA). The raw data were filtered with a 4th-order low-pass Butterworth filter with a cut-off at 6 Hz for the kinematic data and 15 Hz for the kinetic data. The foot segment was modeled as a rigid cone, defined anteriorly by the metatarsal marks and posteriorly by the calcaneus mark. The leg was modeled as a rigid cylinder, defined proximally by the marks of the epicondyles and distally by the marks of the malleolus. For analysis of the movement of the ankle-foot complex, the frontal plane was considered.

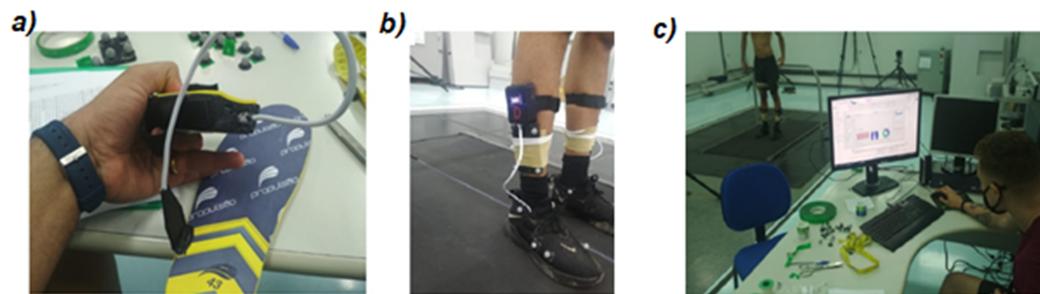


Figure A2. (a) Sensorized insole system for research (bigger battery). (b) Preparation of the participants for data acquisition with the joint use of the sensorized insole and the treadmill force plate TFP. (c) Data collection in a motion analysis laboratory.

As a result of data processing (vGRF and kinematics of ankle in the frontal plane), pronation behavior was considered values smaller than 0.33 in the push-off phase using the normalized ankle's angle, 0.33–0.66 was considered neutral behavior, and values greater than 0.66 were considered supination behavior. Therefore, the normalization process was conducted by dividing the values by the maximum value during the stance phase.

Appendix C

The calibration of the sensors was performed with a static load. A structure was mounted on a precision scale (Scale SF-400, max load 10 kg/1 g, Global Mix) to allow constant pressure on the sensors on the scale (Figure A3). A piston contained in the device was responsible for pressing the sensors against the scale (8 kgf maximum force), recording the simultaneous readings of the sensors and the scale and verifying the repeatability of the results and establishing a correlation equation between the signals. Figure A4 shows the calibration results for one place (the calcaneus area from an insole). Function $f(x)$ represents the conversion of the percent of voltage drops read by the microcontroller and the load applied (X) on each sensor. Each insole had its own calibration curve. All cells were tested three times, and the average was used to calibration process.

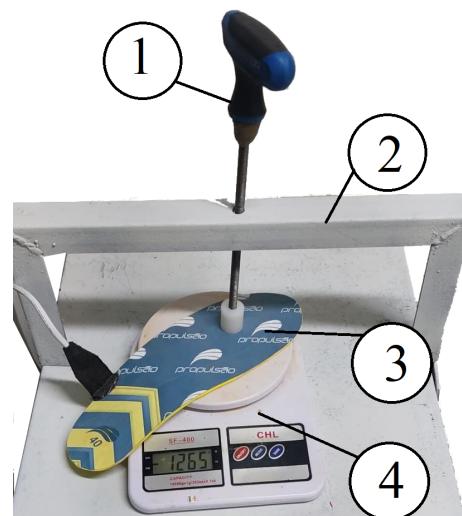


Figure A3. Device used for force dosing: 1—pressure lever; 2—fixing structure; 3—insole to be calibrated; 4—precision scale.

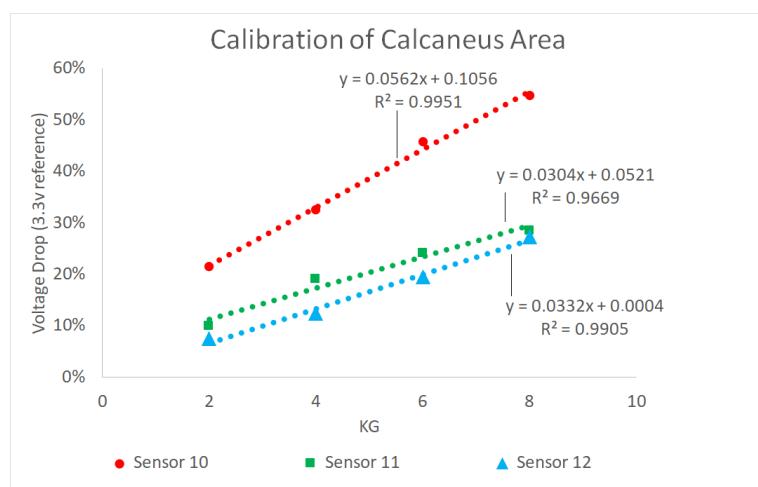


Figure A4. Calibration curve for calcaneal region sensors.

References

- Chockalingam, N.; Healy, A.; Needham, R. Interpreting Ground Reaction Forces in Gait. In *Handbook of Human Motion*; Springer: Berlin/Heidelberg, Germany, 2016; pp. 1–5.
- Bagesteiro, L.B.; Gould, D.; Ewins, D.J. Esteira instrumentada para medição da força de reação vertical do solo para análise de membros com próteses. *Res. Biomed. Eng.* **2011**, *27*, 3–11.
- Vimieiro, C.; Andrada, E.; Witte, H.; Pinotti, M. A computational model for dynamic analysis of the human gait. *Comput. Methods Biomed. Eng.* **2015**, *18*, 799–804. [[CrossRef](#)] [[PubMed](#)]
- Middleton, L.; Buss, A.A.; Bazin, A.; Nixon, M.S. A floor sensor system for gait recognition. In Proceedings of the Fourth IEEE Workshop on Automatic Identification Advanced Technologies (AutoID’05), Buffalo, NY, USA, 17–18 October 2005; pp. 171–176.
- Ivanov, K.; Mei, Z.; Lubich, L.; Guo, N.; Xile, D.; Zhao, Z.; Omisore, O.M.; Ho, D.; Wang, L. Design of a sensor insole for gait analysis. In Proceedings of the International Conference on Intelligent Robotics and Applications, Shenyang, China, 8–11 August 2019; Springer: Berlin/Heidelberg, Germany, 2019; pp. 433–444.
- Malvade, P.S.; Joshi, A.K.; Madhe, S.P. In-sole Shoe Foot Pressure Monitoring for Gait Analysis. In Proceedings of the 2017 International Conference on Computing, Communication, Control and Automation (ICCUBEA), Pune, India, 17–18 August 2017; pp. 1–4.
- Martini, E.; Fiumalbi, T.; Dell’Agnello, F.; Ivanić, Z.; Munih, M.; Vitiello, N.; Crea, S. Pressure-sensitive insoles for real-time gait-related applications. *Sensors* **2020**, *20*, 1448. [[CrossRef](#)] [[PubMed](#)]
- Asmussen, M.J.; Kaltenbach, C.; Hashlamoun, K.; Shen, H.; Federico, S.; Nigg, B.M. Force measurements during running on different instrumented treadmills. *J. Biomech.* **2019**, *84*, 263–268. [[CrossRef](#)] [[PubMed](#)]
- Jung, Y.; Jung, M.; Lee, K.; Koo, S. Ground reaction force estimation using an insole-type pressure mat and joint kinematics during walking. *J. Biomech.* **2014**, *47*, 2693–2699. [[CrossRef](#)] [[PubMed](#)]
- Fong, D.T.P.; Chan, Y.Y.; Hong, Y.; Yung, P.S.H.; Fung, K.Y.; Chan, K.M. Estimating the complete ground reaction forces with pressure insoles in walking. *J. Biomech.* **2008**, *41*, 2597–2601. [[CrossRef](#)]
- Eguchi, R.; Yorozu, A.; Fukumoto, T.; Takahashi, M. Ground reaction force estimation using insole plantar pressure measurement system from single-leg standing. In Proceedings of the 2016 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI), Baden, Germany, 19–21 September 2016; pp. 109–113.
- Peebles, A.T.; Ford, K.R.; Taylor, J.B.; Hart, J.M.; Sands, L.P.; Queen, R.M. Using force sensing insoles to predict kinetic knee symmetry during a stop jump. *J. Biomech.* **2019**, *95*, 109293. [[CrossRef](#)] [[PubMed](#)]
- Hamacher, D.; Bertram, D.; Fölsch, C.; Schega, L. Evaluation of a visual feedback system in gait retraining: A pilot study. *Gait Posture* **2012**, *36*, 182–186. [[CrossRef](#)] [[PubMed](#)]
- Tahir, A.M.; Chowdhury, M.E.; Khandakar, A.; Al-Hamouz, S.; Abdalla, M.; Awadallah, S.; Reaz, M.B.I.; Al-Emadi, N. A systematic approach to the design and characterization of a smart insole for detecting vertical ground reaction force (vGRF) in gait analysis. *Sensors* **2020**, *20*, 957. [[CrossRef](#)] [[PubMed](#)]
- Wang, L.; Jones, D.; Chapman, G.J.; Siddle, H.J.; Russell, D.A.; Alazmani, A.; Culmer, P. A review of wearable sensor systems to monitor plantar loading in the assessment of diabetic foot ulcers. *IEEE Trans. Biomed. Eng.* **2019**, *67*, 1989–2004. [[CrossRef](#)]
- T&T Mediologic Medizintechnik GmbH, Mediologic WLAN Insole, Schonefeld, Germany. Available online: <https://medilogic.com/en/mediologic-wlan-insole/> (accessed on 23 June 2022).
- Hsu, W.C.; Sugiarto, T.; Chen, J.W.; Lin, Y.J. The design and application of simplified insole-based prototypes with plantar pressure measurement for fast screening of flat-foot. *Sensors* **2018**, *18*, 3617. [[CrossRef](#)] [[PubMed](#)]
- Tiwari, A.; Joshi, D. Template-based insoles for the center of pressure estimation in different foot sizes. *IEEE Sens. Lett.* **2020**, *4*, 1–4. [[CrossRef](#)]

19. Guo, R.; Cheng, X.; Hou, Z.C.; Ma, J.Z.; Zheng, W.Q.; Wu, X.M.; Jiang, D.; Pan, Y.; Ren, T.L. A Shoe-Integrated Sensor System for Long-Term Center of Pressure Evaluation. *IEEE Sens. J.* **2021**, *21*, 27037–27044. [[CrossRef](#)]
20. Fuchs, P.X.; Hsieh, C.H.; Chen, W.H.; Tang, Y.S.; Fiolo, N.J.; Shiang, T.Y. Sensor number in simplified insole layouts and the validity of ground reaction forces during locomotion. *Sport. Biomech.* **2022**, *1*–14. [[CrossRef](#)] [[PubMed](#)]
21. Zhu, A.; Li, Y.; Wu, Y.; Wu, M.; Zhang, X. Locomotion mode recognition based on foot posture and ground reaction force. In Proceedings of the 2018 15th International Conference on Ubiquitous Robots (UR), Honolulu, HI, USA, 26–30 June 2018; pp. 125–129.
22. Sigurdson, H.; Chan, J.H. Machine Learning Applications to Sports Injury: A Review. In Proceedings of the 9th International Conference on Sport Sciences Research and Technology Support (icSPORTS 2021), Valletta, Malta, 28–29 October 2021; pp. 157–168.
23. Makihara, Y.; Nixon, M.S.; Yagi, Y. Gait recognition: Databases, representations, and applications. *Comput. Vis. Ref. Guide* **2020**, *1*–13. [[CrossRef](#)]
24. Bouchrika, I.; Nixon, M.S. Exploratory factor analysis of gait recognition. In Proceedings of the 2008 8th IEEE International Conference on Automatic Face & Gesture Recognition, Amsterdam, The Netherlands, 17–19 September 2008; pp. 1–6.
25. Telarolli, D.J.A.; Grossi, D.B.; Cervi, A.C.C.; Santiago, P.R.P.; Lemos, T.W.; Resende, R.A. Comparison of Foot Kinematics and Foot Plantar Area and Pressure Among Five Different Closed Kinematic Tasks. *J. Am. Podiatr. Med. Assoc.* **2020**, *110*. [[CrossRef](#)]
26. Novak, D.; Reberšek, P.; De Rossi, S.M.M.; Donati, M.; Podobnik, J.; Beravs, T.; Lenzi, T.; Vitiello, N.; Carrozza, M.C.; Munih, M. Automated detection of gait initiation and termination using wearable sensors. *Med. Eng. Phys.* **2013**, *35*, 1713–1720. [[CrossRef](#)]
27. Slijepcevic, D.; Horst, F.; Lapuschkin, S.; Horsak, B.; Raberger, A.M.; Kranzl, A.; Samek, W.; Breiteneder, C.; Schöllhorn, W.I.; Zeppelzauer, M. Explaining machine learning models for clinical gait analysis. *ACM Trans. Comput. Healthc. (HEALTH)* **2021**, *3*, 1–27. [[CrossRef](#)]
28. Fonseca, S.T.; Souza, T.R.; Verhagen, E.; Van Emmerik, R.; Bittencourt, N.F.; Mendonça, L.D.; Andrade, A.G.; Resende, R.A.; Ocarino, J.M. Sports injury forecasting and complexity: A synergetic approach. *Sport. Med.* **2020**, *50*, 1757–1770. [[CrossRef](#)]
29. Potluri, S.; Chandran, A.B.; Diedrich, C.; Schega, L. Machine learning based human gait segmentation with wearable sensor platform. In Proceedings of the 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Berlin, Germany, 23–27 July 2019; pp. 588–594.
30. Palacio-Niño, J.O.; Berzal, F. Evaluation metrics for unsupervised learning algorithms. *arXiv* **2019**, arXiv:1905.05667.
31. Decker, L.M.; Cignetti, F.; Stergiou, N. Complexity and human gait. *Rev. Andal. Med. Deporte* **2010**, *3*, 2–12.
32. Khera, P.; Kumar, N. Role of machine learning in gait analysis: A review. *J. Med. Eng. Technol.* **2020**, *44*, 441–467. [[CrossRef](#)] [[PubMed](#)]
33. Sunarya, U.; Sun Hariyani, Y.; Cho, T.; Roh, J.; Hyeong, J.; Sohn, I.; Kim, S.; Park, C. Feature analysis of smart shoe sensors for classification of gait patterns. *Sensors* **2020**, *20*, 6253. [[CrossRef](#)]
34. Jasiewicz, B.; Klimiec, E.; Młotek, M.; Guzdek, P.; Duda, S.; Adamczyk, J.; Potaczek, T.; PiekarSKI, J.; Kołaszczyński, G. Quantitative analysis of foot plantar pressure during walking. *Med. Sci. Monit. Int. Med. J. Exp. Clin. Res.* **2019**, *25*, 4916. [[CrossRef](#)]
35. Dai, Y.; Xie, Y.; Chen, J.; Kang, S.; Xu, L.; Gao, S. A lamination-based piezoelectric insole gait analysis system for massive production for Internet-of-health things. *Int. J. Distrib. Sens. Netw.* **2020**, *16*, 1550147720905431. [[CrossRef](#)]
36. Klimiec, E.; Jasiewicz, B.; PiekarSKI, J.; Zaraska, K.; Guzdek, P.; Kołaszczyński, G. Measuring of foot plantar pressure—possible applications in quantitative analysis of human body mobility. *Meas. Sci. Technol.* **2017**, *28*, 054008. [[CrossRef](#)]
37. Saidani, S.; Haddad, R.; Mezghani, N.; Bouallegue, R. A survey on smart shoe insole systems. In Proceedings of the 2018 International Conference on Smart Communications and Networking (SmartNets), Yasmine Hammamet, Tunisia, 16–17 November 2018; pp. 1–6.
38. Pasic, R.; Kuzmanov, I.; Atanasovski, K. ESP-NOW communication protocol with ESP32. *J. Univers. Excell.* **2021**, *6*, 53–60. [[CrossRef](#)]
39. Dyer, P.S.; Bamberg, S.J.M. Instrumented insole vs. force plate: A comparison of center of plantar pressure. In Proceedings of the 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Boston, MA, USA, 30 August–3 September 2011; pp. 6805–6809.
40. Dzedzickis, A.; Sutinys, E.; Bucinskas, V.; Samukaitė-Bubniene, U.; Jakstys, B.; Ramanavicius, A.; Morkvenaitė-Vilkonciene, I. Polyethylene-carbon composite (Velostat®) based tactile sensor. *Polymers* **2020**, *12*, 2905. [[CrossRef](#)]
41. Athavale, O.N.; Paskaranandavadivel, N.; Angeli, T.R.; Avci, R.; Cheng, L.K. Design of pressure sensor arrays to assess electrode contact pressure during in vivo recordings in the gut. In Proceedings of the 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), Montreal, QC, Canada, 20–24 July 2020; pp. 4204–4207.
42. Lowe, B.; Kong, Y.; Han, J. Development and application of a hand force measurement system. In Proceedings of the Proceedings of the XVIth Triennial Congress of the International Ergonomics Association, Maastricht, The Netherlands, 10–14 July 2006.
43. Ahmed, T.; Rahman, N.A.; Alam, M.K. Validation and reliability of a prototype orthodontic bracket debonding device equipped with force-sensitive resistor (FSR): A novel method of measuring orthodontic bracket debonding force in vivo. *Prog. Orthod.* **2019**, *20*, 26. [[CrossRef](#)]
44. Hopkins, M.; Vaidyanathan, R.; McGregor, A.H. Examination of the performance characteristics of velostat as an in-socket pressure sensor. *IEEE Sens. J.* **2020**, *20*, 6992–7000. [[CrossRef](#)]

45. Wilson, D.C.; Niosi, C.A.; Zhu, Q.A.; Oxland, T.R.; Wilson, D.R. Accuracy and repeatability of a new method for measuring facet loads in the lumbar spine. *J. Biomech.* **2006**, *39*, 348–353. [CrossRef] [PubMed]
46. Tekscan, Inc. Pressure Mapping, Force Measurement & Tactile Sensors, MA , USA. Available online: <https://www.tekscan.com/sites/default/files/FLX-QS-Calibration-RevG.pdf> (accessed on 7 September 2022).
47. Kang, H. Sample size determination and power analysis using the G* Power software. *J. Educ. Eval. Health Prof.* **2021**, *18*. [CrossRef] [PubMed]
48. Ngueleu, A.M.; Blanchette, A.K.; Bouyer, L.; Maltais, D.; McFadyen, B.J.; Moffet, H.; Batcho, C.S. Design and accuracy of an instrumented insole using pressure sensors for step count. *Sensors* **2019**, *19*, 984. [CrossRef] [PubMed]
49. Gopalakrishna, G.; Mustafa, R.A.; Davenport, C.; Scholten, R.J.; Hyde, C.; Brozek, J.; Schünemann, H.J.; Bossuyt, P.M.; Leeflang, M.M.; Langendam, M.W. Applying Grading of Recommendations Assessment, Development and Evaluation (GRADE) to diagnostic tests was challenging but doable. *J. Clin. Epidemiol.* **2014**, *67*, 760–768. [CrossRef] [PubMed]
50. Bertec Corporation, Instrumented Treadmills, Columbus, OH, USA. Available online: <https://www.bertec.com/products/instrumented-treadmills> (accessed on 7 September 2022).
51. Ferrari, A.; Cutti, A.G.; Cappello, A. A new formulation of the coefficient of multiple correlation to assess the similarity of waveforms measured synchronously by different motion analysis protocols. *Gait Posture* **2010**, *31*, 540–542. [CrossRef] [PubMed]
52. Crea, S.; Donati, M.; De Rossi, S.M.M.; Oddo, C.M.; Vitiello, N. A wireless flexible sensorized insole for gait analysis. *Sensors* **2014**, *14*, 1073–1093. [CrossRef]
53. Kanithika, K.; Chan, K.S. Pressure sensor positions on insole used for walking analysis. In Proceedings of the The 18th IEEE International Symposium on Consumer Electronics (ISCE 2014), Jeju, Korea, 22–25 June 2014; pp. 1–2.
54. Fournier, K.A.; Amano, S.; Radonovich, K.J.; Bleser, T.M.; Hass, C.J. Decreased dynamical complexity during quiet stance in children with autism spectrum disorders. *Gait Posture* **2014**, *39*, 420–423. [CrossRef]
55. Al-Amri, M.; Nicholas, K.; Button, K.; Sparkes, V.; Sheeran, L.; Davies, J.L. Inertial measurement units for clinical movement analysis: Reliability and concurrent validity. *Sensors* **2018**, *18*, 719. [CrossRef]
56. Mukaka, M.M. A guide to appropriate use of correlation coefficient in medical research. *Malawi Med. J.* **2012**, *24*, 69–71. [PubMed]
57. Prasanth, H.; Caban, M.; Keller, U.; Courtine, G.; Ijspeert, A.; Vallery, H.; Von Zitzewitz, J. Wearable sensor-based real-time gait detection: A systematic review. *Sensors* **2021**, *21*, 2727. [CrossRef]
58. Mowbray, S.D.; Nixon, M.S. Automatic gait recognition via fourier descriptors of deformable objects. In Proceedings of the International Conference on Audio-and Video-Based Biometric Person Authentication, Guildford, UK, 9–11 June 2003; Springer: Berlin/Heidelberg, Germany, 2003; pp. 566–573.
59. Wurdeaman, S.R.; Huisenga, J.M.; Filipi, M.; Stergiou, N. Multiple sclerosis affects the frequency content in the vertical ground reaction forces during walking. *Clin. Biomech.* **2011**, *26*, 207–212. [CrossRef] [PubMed]
60. Bark, C.; Chaccour, K.; Darazi, R.; El Hassani, A.H.; Andres, E. Design and development of a force-sensing shoe for gait analysis and monitoring. In Proceedings of the 2017 Fourth International Conference on Advances in Biomedical Engineering (ICABME), Beirut, Lebanon, 19–21 October 2017; pp. 1–4.
61. Cotta, C.; Hemert, J. *Evolutionary Computation in Combinatorial Optimization (7 Conf.)*; Springer: Berlin/Heidelberg, Germany, 2007.
62. Zgolli, F.; Henni, K.; Haddad, R.; Mitiche, A.; Ouakrim, Y.; Hagemeister, N.; Vendittoli, P.A.; Fuentes, A.; Mezghani, N. Kinematic data clustering for healthy knee gait characterization. In Proceedings of the 2018 IEEE Life Sciences Conference (LSC), Montreal, QC, Canada, 28–30 October 2018; pp. 239–242.
63. Brownlee, J. *Clonal Selection Theory & Clonalg—The Clonal Selection Classification Algorithm (CSCA)*; Swinburne University of Technology: Melbourne, Australia, 2005; Volume 38.
64. Farahpour, N.; Jafarnezhad, A.; Damavandi, M.; Bakhtiari, A.; Allard, P. Gait ground reaction force characteristics of low back pain patients with pronated foot and able-bodied individuals with and without foot pronation. *J. Biomech.* **2016**, *49*, 1705–1710. [CrossRef] [PubMed]
65. Resende, R.A.; Pinheiro, L.S.; Ocarino, J.M. Effects of foot pronation on the lower limb sagittal plane biomechanics during gait. *Gait Posture* **2019**, *68*, 130–135. [CrossRef] [PubMed]
66. Collins, J.; Whittle, M. Impulsive forces during walking and their clinical implications. *Clin. Biomech.* **1989**, *4*, 179–187. [CrossRef]
67. Valentina, A.; Gabriella, B.; Marco, K. Segmentation and Classification of Gait Cycles. *IEEE Trans. Neural Syst. Rehabil. Eng.* **2014**, *22*, 946–952.
68. De Rossi, S.M.; Crea, S.; Donati, M.; Reberšek, P.; Novak, D.; Vitiello, N.; Lenzi, T.; Podobnik, J.; Munih, M.; Carrozza, M.C. Gait segmentation using bipedal foot pressure patterns. In Proceedings of the 2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics (BioRob), Rome, Italy, 24–27 June 2012; pp. 361–366.
69. DeCann, B.; Ross, A.; Culp, M. On clustering human gait patterns. In Proceedings of the 2014 22nd International Conference on Pattern Recognition, Stockholm, Sweden, 24–28 August 2014; pp. 1794–1799.
70. Cutler, A.; Cutler, D.R.; Stevens, J.R. Random forests. In *Ensemble Machine Learning*; Springer: Berlin/Heidelberg, Germany, 2012; pp. 157–175.
71. Perry, J.; Araújo, A.G.N.; de Freitas, C.D.; Schoneberger, B. *Análise de Marcha; Marcha: Sistemas de Análise de Marcha—Volume 3*; Manole: Barueri, Brazil, 2005; pp 58–61.
72. Tajima, T.; Tateuchi, H.; Koyama, Y.; Ikezoe, T.; Ichihashi, N. Gait strategies to reduce the dynamic joint load in the lower limbs during a loading response in young healthy adults. *Hum. Mov. Sci.* **2018**, *58*, 260–267. [CrossRef]

-
73. Chiu, M.C.; Wu, H.C.; Chang, L.Y.; Wu, M.H. Center of pressure progression characteristics under the plantar region for elderly adults. *Gait Posture* **2013**, *37*, 408–412. [[CrossRef](#)]
74. Elhafez, S.M.; Ashour, A.A.; Elhafez, N.M.; Elhafez, G.M.; Abdelmohsen, A.M. Percentage contribution of lower limb moments to vertical ground reaction force in normal gait. *J. Chiropr. Med.* **2019**, *18*, 90–96. [[CrossRef](#)]

Apêndice B

Artigo Publicado

New Optimized Dynamic Calibration Proposition for Discretized Sensorized insoles with Resistive Force Sensor: A Descriptive and Comparative Study

Diego Henrique Antunes Nascimento

Universidade Federal de
Minas Gerais (UFMG)
Bioengineering Laboratory (LABBIO)
Mechanical Engineering (PPGMEC)
Avenida Antônio Carlos 6627
Campus Pampulha
Belo Horizonte, MG – Brazil.

Fábricio Aniceto Magalhães

College of Education, Health
and Human Sciences, Department of
Biomechanics, University of Nebraska
at Omaha, 6160 University
Drive South, Omaha, NE, USA

George Schayer Sabino

Universidade Federal de
Minas Gerais (UFMG)
School of Physical Education,
Physical Therapy and
Occupational Therapy (EEFFTO)
Graduate Program in
Rehabilitation Sciences,
Department of Physical Therapy,
Avenida Antônio Carlos 6627
Campus Pampulha,
Belo Horizonte, MG – Brazil.

Renan Alves Resende

Universidade Federal de
Minas Gerais (UFMG)
School of Physical Education,
Physical Therapy and
Occupational Therapy (EEFFTO)
Graduate Program in
Rehabilitation Sciences,
Department of Physical Therapy,
Avenida Antônio Carlos 6627
Campus Pampulha,
Belo Horizonte, MG – Brazil.

Maria Lúcia Machado Duarte

Universidade Federal de
Minas Gerais (UFMG)
Bioengineering Laboratory (LABBIO)
Mechanical Engineering (PPGMEC)
Avenida Antônio Carlos 6627
Campus Pampulha
Belo Horizonte, MG – Brazil.

Claysson Bruno Santos Vimieiro

Universidade Federal de
Minas Gerais (UFMG)
Bioengineering Laboratory (LABBIO)
Mechanical Engineering (PPGMEC)
Avenida Antônio Carlos 6627
Campus Pampulha
Belo Horizonte, MG – Brazil.

ABSTRACT

Sensorized insoles have been used as a wearable instrument to study human gait and have the potential to identify and predict pathologies and injuries. However, most of these sensorized insoles are only statically calibrated, relying on a scale and known weights to establish a relationship between electrical signals and the load applied on laboratory benches while ignoring the dynamic interaction between person and instrument. The present study proposes and verifies a calibration method complementary to static calibration to compensate for different dynamic interactions between the insole and the individual during gait. In order to perform this comparison, a laboratory test was proposed with 32 volunteers (18 men and 14 women). Each volunteer walked on a double-belt instrumented treadmill (Bertec, 1000 Hz, USA) while wearing an experimental resistive sensorized insole (SI). The SI data was compared with the instrumented treadmill and adjusted using an optimization algorithm to create a dynamic coefficient to complement and optimize the results. This study also verifies the impact of the method considering

three different types of gait: pronated, neutral, and supinated. After using this technique and considering static calibration, the Pearson correlation coefficient between the SI and the instrumented treadmill improved by 12%.

Keywords: supplementary calibration; pressure sensor insole, optimization of insole calibration

1 Introduction

Human gait analysis is usually done using the kinematic and kinetic approaches [1]. Kinematic analysis consists of each joint angle and temporal segment displacements, whereas kinetic analysis is based on the forces during movement [1] [2]. Motion capture systems or clinical observation with qualitative visual analysis can perform kinematic analysis [3]. However, it is impossible to evaluate kinetics without equipment such as pressure sensors or force plates. The equipment considered the “gold standard” for kinetic gait assessment is the force plate, which is based on precision scales placed on a flat surface where it is possible to walk on it and thus obtain the reaction force of the gait while walking. Furthermore, the ground reaction force (GRF), together with the kinematics, can be used to calculate the force and moment in each joint of the lower limbs during gait using mathematical models of inverse dynamics [4]. This information allows a detailed investigation of the relationship between motion patterns and kinetic responses that can clarify the occurrence and progression of musculoskeletal injuries in different populations [5].

Despite being considered the “gold standard” to measure the GRF during gait, force plates have high acquisition and maintenance costs; thus, their widespread implementation in clinics is impractical [6]. In order to install force plates, it is also necessary to construct a controlled environment, which raises the cost and necessitates ample space. An alternative to force plates is the sensorized insoles (SI) [7] [8] [9], which are electronic devices with force sensors positioned in strategic anatomical regions to record the plantar pressure exerted on each sensor during gait [10]. These devices are introduced inside the shoes and can be used in different environments at a lower cost than force platforms. However, the costs of acquiring SI, such as Medica Flexifit (Guidonia Montecelio (RM), Italy) and F-Scan (Tekscan, South Boston, US), remain high for general clinical use.

TAHIR, Anas M. et al. [6] presented different approaches to the construction and characterization of SI, varying the number and types of sensors and their positioning. Fuchs, Philip X., et al. [11] investigated different SI layouts, changing the number and position of sensors along the SI. It was verified that reducing the number of sensors leads to a decrease in measurement quality. They also concluded that the “optimal compromise between simplification and measurement performance” is possible with 11 sensors. However, they used only static calibration of these devices. The static calibration is performed on a laboratory bench with the SI placed on a precision balance, and pre-established forces are applied to each sensor. There is a relationship between the scale’s measurements and the electrical signal recorded by the SI [6] [7]. This static calibration strategy presents good results in laboratory settings. However, the static calibration may be insufficient when gait patterns vary due to anatomical conditions (planus or cavus foot) or even kinematics behaviors (excessive supination or pronation). The plantar pressure distribution would change with different gait patterns and foot shapes, which affect readings [12].

Another point of interest is the deformation of sensors caused by the application of plantar pressure and foot motion. When forces are applied on a flat surface while walking, unlike on a test bench, the sensor tends to conform to the surface of the foot and may suffer some deformation, affecting sensor readings. This situation would lead to an under or over-scaling of the results.

Therefore, the objective of the present study was to propose and verify the validity of a calibration method complementary to static calibration to compensate part of different dynamic interactions between the insole and the individual during gait. This methodology aims to improve the correlation of vertical GRF estimation using SI compared with force pates (“golden standard”) and minimize the influence of gait patterns (neutral, pronation, and supination) on SI with a smaller number of sensors.

2 Methodology

2.1 Sensorized Insole (SI)

In this study, 16 pairs of SIs (PhysioCode [13]) were used (Figure 1a), divided into eight foot sizes (6, 6.5, 8.5, 9, 10, 10.5, 11.5, and 12 using US standard men’s shoe sizes). Each foot size had two pairs of SI. These insoles contain 11 resistive force sensors arranged in seven anatomical regions (Figure 1b). This feature was designed to reduce manufacturing costs and increase cost-effectiveness to spread the clinical use of this technology. Each sensor has the same area (4.90 cm^2) and the system data acquisition rate of 375 Hz. Each sensor data was recorded using a custom-built software developed in C# for converting the analog signal (GRF) based on each sensor’s resistance variation (V_{out}), into digital information using Equations 1, and a 12-bit analog-to-digital converter. Each insole weighs 25 g on average, and they are 2.0 mm thick.

$$FRS = 3.3V \cdot \frac{3.7k\Omega}{V_{out}} \quad (1)$$

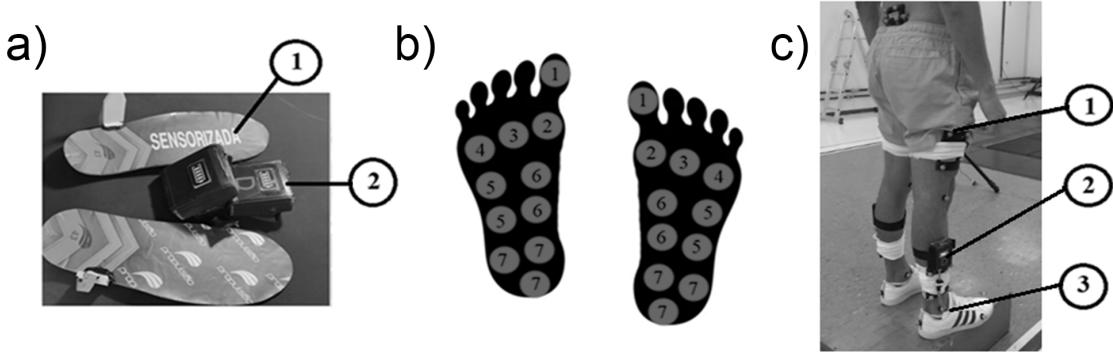


Fig. 1. Figure 1 a) Sensorized insole (1) with data transmission via WiFi 433MHz (2). b) location of the sensors' placement: Hallux (1), 1st Metatarsal Head (2), intermediate Forefoot Region (3), 5th Metatarsal Head (4), lateral Midfoot (5), medial Midfoot (6), and calcaneus region (7). c) track marks are mentioned (1), equipment placed on the participant with data transmission, (2) the insole inside the shoes (3), and replacing the shoe's factory insole.

2.2 Static Calibration

Each SI was calibrated on a bench using a precision scale (Scale SF-400, max load 10 kg/1g, China). First, the SIs were placed on the scale, and each sensor was pressed using a pre-established weight (1–8 kgf), increasing by 1 kgf per measurement [6]. Each measurement was performed three times to obtain an average of the measurements. Considering each sensor (kgf), a linear fit regression was performed using the average of the measures to relate the electrical signal to scale values [14]. Each linear coefficient was used to adjust the time series of each sensor during all gait tests, which will be presented later in the text. The results of gait tests will be compared with an instrumented treadmill (IT) using the most commonly used correction metrics Pearson coefficient [15] [16] [17] and Coefficient of Multiple Correlations (CMC) [18] [19] to provide a measure of the strength of linear association between two variables and root mean square error (RMSE) to compare the performance [20].

2.3 Experimental Procedures

Dynamic calibration is a proposed method for optimizing the correlation between IT and SI after static calibration. For this, a test was proposed using an optoelectronic system (OES) (7 Oqus 5+ cameras, 100 Hz, Qualisys MEDICAL AB, Sweden), synchronized with an IT with double-belt and two built-in force plates (Bertec at 1000 Hz, Bertec Corp, Columbus, OH). The objective was to obtain kinetic data using IT for validating and comparing calibration methods. The OES was then used to perform a kinematic evaluation of each participant and categorize them into three groups based on ankle angle in the frontal plane during the push-off phase: pronation, neutral, and supination (Appendix B), and verify the influences of each group on calibration methods. The OES markers were tracked using the Qualisys Track Manager program (Version 2019.3, Qualisys MEDICAL AB, Sweden) and were processed using the Visual3D program™ x64 Professional (v2020.02.04, C-Motion, USA).

The data from the SI is transferred through WiFi to a receiver responsible for synchronizing the left and right sides and stored in a text file without any data processing. After finishing the tests, all databases were post-processed using Microsoft Excel® (Excel Version in Microsoft Office 2016 for Windows) for statistical treatment and MatLab® (v.2017b) to perform dynamic calibration (presented later in the text).

G-Power (v.3.1.9.7) software was used to ensure an appropriate sample size calculation and power analysis [21]. The statistical test chosen on G-Power was the bivariate normal test with two-tailed using as a parameter Cohen's $d = 0.5$, $\alpha = 0.05$, and power equal to 0.80 [21]. The sample size required was calculated to be 29 volunteers. Thirty-two volunteers (18 male and 14 female) were recruited to prevent any data loss during tests and post-processing with the following inclusion criteria: age 18–45 years, body mass index (BMI) between 20 and 34.9 kg/m², no neurological disorder or history of recent (six months) lumbar or lower limb surgery. The ankle kinematics on each sample's frontal plane was tracked and divided into four quartiles based on the amplitude of foot inversion and eversion movement. According to Perry [1], the expected amplitude of eversion and inversion of the foot in a healthy person is about 10°. Applying this to classification in the last value of the impulsion phase (terminal stance and pre-swing): the first quartile was defined as values between -10° and -5°, the second quartile between -5° and 0°, the third quartile between 0° and 5° and the fourth quartile, between 5° and 10°. The first quartile was classified as pronators, the second and third quartiles as neutral, and the fourth quartile as supinators. Both sides of the volunteers were analyzed independently, yielding 64 samples. The database included 32 participants: nine with increased pronation during impulsion, eight with increased supination during impulsion, and 15 without amplified movements (eversion and inversion) on gait.

These participants completed 192 trials by walking on the treadmill three times for 1 minute while wearing a set of

SI (three repetitions of 64 samples). The gait speed was self-selected [mean (SD): 1.0 (0.2) m/s]. Before recording the test, each volunteer performed a 1-minute walk on IT to familiarize themselves with the equipment (Figures 2c and 2d). Discomfort or difficulty in performing the tests was considered an exclusion criterion. Failure of equipment or data loss was also considered an exclusion criterion. This study was approved by the Institutional Research Board Committee (CAAE 00890818.8.000.5149).

After performing the tests, the static calibration factors were applied, and the corrected vGRF curve was found. Next, this corrected curve was normalized based on each volunteer's BMI and compared with data from the IT. This comparison separated 30 steps from all recorded steps, and arithmetic means were performed to obtain a single mean step representing the volunteer's gait. The following metrics were used to compare static calibration and IT: Pearson coefficient [15] [16] [17], the CMC [18] [19], and RMSE.

2.4 Dynamic Calibration

The dynamic calibration coefficients were calculated using the corrected vGRF curve (static calibration). The data from the SI are composed of seven-time series (X_i) corresponding to the seven anatomical regions provided by the SI. Considering static calibration coefficients (ω_s), Equation 2 was used to sum these seven-time series in order to determine the static vertical GRF (vGRF). Equation 2 defines the vertical ground force reaction updated by static calibration (vGRFs)

$$vGRF_s = \sum_{i=1}^7 \omega_{s_i} \cdot X_i \quad (2)$$

The proposed dynamic calibration consists of adding a weighting coefficient (ω_d) to each sensor, adjusting the measurements, and presenting a better correlation with IT. This coefficient (ω_d) represents the dynamic interactions between volunteers and SI during the movement. All insoles have already gone through calibration processes, where the correlation between the electrical signal and known weights was established. This process ensures that all sensors respond similarly to the same load and all variation in materials and manufacturing process would be compensated during this calibration process. However, with the application of dynamic calibration, this equivalence was affected to adjust the measurements. Because the sensors suffer small deformations during walking that influence the sensor's sensitivity. This effect was not observed in the static calibration bench, so dynamic calibration was proposed to compensate for this effect.

Unlike static calibration applied on all insoles individually, dynamic calibration was proposed by foot size to reduce costs regarding the calibration process. Each foot size SI has the same layout (size and positioning of sensors) and has been grouped into the same calibration group. Thus, the proposed dynamic calibration has a complementary character and it cannot be applied in isolation. The dynamic calibration establishes a transfer function relating the data from an already calibrated (standardized) insole and a force plate. With this, it was possible to find a single set of coefficients ω_{di} that best fits in different insoles of the same number, avoiding having to carry out tests with a force platform every time a new sensorized insole is manufactured. Equation 3 defines the vertical ground force reaction updated by dynamic calibration (vGRFd), where ω_{sd} represents the product of ω_d and ω_s .

$$vGRF_d = \sum_{i=1}^7 \omega_{sd_i} \cdot X_i \quad (3)$$

The First Improvement Hill Climbing Heuristic (Appendix A) [22] [23] was used as an optimization technique to obtain ω_d . This optimization technique required some parameterization, such as the definition of a search space, a data structure to represent the algorithm's response, and an evaluation criterion that will compare the responses obtained and choose the best one. The search space was arbitrarily limited between 0.5 and 2, implying that ω_d can assume any value between 0.5 and 2 when the algorithm searches for a set of values that maximizes the correlation with IT. The registered force is reduced if the ω_d values are 0.5–1.0 and increased if ω_d values are 1.0–2.0. The ω_d can correct situations where the sensor deformation tends to increase the sensor measurement, requiring a ω_d between 0.5 and 1.0 to minimize this effect or situations where the center of pressure is not perfectly aligned with the sensor, necessitating a ω_d between 1.0 and 2.0 to compensate for the blind regions of the insole. A vector of coefficients $S = \{\omega_{d1}, \omega_{d2}, \omega_{d3}, \omega_{d4}, \omega_{d5}, \omega_{d6}, \omega_{d7}\}$ was developed to represent the seven capture regions of the insole. The optimization algorithm generates a series of different solutions (S) in its data processing. Each one of these solutions was used in Equation 3 to produce a possible dynamic calibration result. Each trial (with the same foot size) was submitted to the calibration proposed by the S solution, and the modified vGRF result was compared with the IT. This comparison was performed using RMSE between vGRF curves to minimize the RMSE. A multi-start strategy was adopted to reduce the probability of the algorithm being limited to finding local optima [22] [23].

Table 1. Description of static calibration and complementary dynamic calibration

Size Foot (USA)	Number of Trials	Static Calibration			Dynamic Calibration		
		Pearson	CMC	RMSE	Pearson	CMC	RMSE
6	35	0.65	0.80	0.36	0.73	0.92	0.34
6.5	20	0.81	0.85	0.28	0.86	0.84	0.25
8.5	45	0.73	0.85	0.32	0.77	0.87	0.3
9	13	0.72	0.94	0.34	0.76	0.91	0.32
10	17	0.75	0.88	0.31	0.84	0.79	0.25
10.5	24	0.70	0.88	0.33	0.75	0.88	0.3
11.5	18	0.85	0.90	0.23	0.86	0.89	0.22
12	5	0.65	0.84	0.34	0.66	0.85	0.33
Mean	-	0.73	0.87	0.31	0.78	0.88	0.29
SD		0.07	0.04	0.04	0.07	0.04	0.04

Table 2. Description of static calibration and complementary dynamic calibration considering the three groups

Group	Static Calibration			Dynamic Calibration		
	Pearson	CMC	RMSE	Pearson	CMC	RMSE
Pronation	0.70	0.87	0.10	0.80	0.88	0.07
Neutral	0.73	0.83	0.10	0.76	0.85	0.10
Supination	0.77	0.88	0.08	0.83	0.89	0.06
Mean	0.73	0.86	0.09	0.80	0.88	0.08
SD	0.04	0.03	0.02	0.03	0.02	0.02

Each solution S found that presents a reduction in the value of RMSE, is stored by the algorithm until it is impossible to find another solution S that promotes the reduction of RMSE, ending the process. After processing the algorithm, the solution found was applied in Equation 3 and corrected for the vGRF of all trials, and compared with the IT using Pearson coefficients [15] [16] [17] and the CMC [18] [19]. To compare the difference between static and dynamic calibration methods, the Paired t-test was applied using the mean values of CMC, Pearson, and RMSE coefficients [24] [25].

3 Results

Some of the trials had to be discarded due to data capture failures: insole breakage (six trials) and data transmission failure (nine trials), comprising a 7.8% loss in the database.

Table 1 depicts the distribution of participants and the result of applying static and dynamic calibration for vGRF data. Furthermore, Table 1 allows calculating the difference between CMC, Pearson, and RMSE coefficients after dynamic calibration. An increase in the Pearson coefficient was observed in all groups, showing an increase in the correlation between SI and IT. Conversely, the CMC remained constant considering the groups' average, and the RMSE showed a reduction in all groups, indicating a reduced distance between SI and IT.

Table 2 shows the results of applying static and dynamic calibration for the vGRF data considering three groups pronation, neutral, and supination. An increase in the Pearson coefficient was observed in all groups, showing an increase in the correlation between SI and IT. Conversely, the CMC and RMSE remained constant considering the groups' average.

Table 3 presents the coefficient of variation and 95% Confidence Interval (CI95%) in each size foot. It can be seen that both coefficient of variation and CI95% did not change for both calibrations. Furthermore, it indicates that the dynamic calibration did not increase data variation, even considering the group of pronation, neutral, and supination (Table 4). Figures 2a, 2d, and 2g show a qualitative comparison between TFP and SI using only static calibration. Figures 2b, 2e, and 2h present the result of the dynamic calibration with the application of ω_d , demonstrating the improvement of the adhesion between the

Table 3. Comparative results of coefficient of variation and CI95% between and application of static calibration before and after complementary dynamic calibration

Size Foot (USA)	Coefficient of Variation			CI95%		
	TFP	SISC	DC	TFP	SISC	DC
6	0.11	0.06	0.06	0.105–0.117	0.058–0.062	0.058–0.062
6.5	0.03	0.09	0.07	0.022–0.038	0.088–0.092	0.067–0.073
8.5	0.02	0.08	0.08	0.013–0.027	0.078–0.082	0.078–0.082
9	0.03	0.07	0.08	0.022–0.038	0.067–0.073	0.077–0.083
10	0.03	0.06	0.05	0.022–0.038	0.058–0.062	0.048–0.052
10.5	0.02	0.06	0.07	0.013–0.027	0.058–0.062	0.067–0.073
11.5	0.03	0.05	0.06	0.023–0.037	0.047–0.053	0.057–0.063
12	0.03	0.05	0.06	0.022–0.038	0.048–0.053	0.057–0.063
Mean	0.04	0.07	0.07	-	-	-
SD	0.03	0.01	0.01	-	-	-

Table 4. Comparative results of coefficient of variation and CI95% from the groups, between and application of static calibration before and after complementary dynamic calibration

Group	Coefficient of Variation			CI95%		
	TFP	SISC	SIS + DC	TFP	SISC	DC
Pronation	0.07	0.05	0.06	0.064–0.076	0.048–0.052	0.058–0.062
Neutral	0.09	0.07	0.08	0.083–0.097	0.068–0.072	0.078–0.083
Supination	0.09	0.06	0.05	0.084–0.096	0.058–0.062	0.048–0.052
Mean	0.08	0.06	0.06	-	-	-
SD	0.03	0.01	0.01	-	-	-

curves, considering pronated (Figure 2c), neutral (Figure 2f), and supinated (Figure 2i) gaits.

4 Discussion

The present study proposed a complementary calibration to the static one. The dynamic coefficient (ω_{di}) represents the adjustment based on interactions between humans and instruments, isolating the static effect and representing only the relationship between forces and electrical signals.

The study showed an improvement in the correlation between the SI and the IT, implying an overall correlation increase of about 6.8% ($p = 0.0035$) by considering the average Pearson between the two calibration processes (Table 1) and reaching a mean index of $p = 0.78$, with a high positive correlation. [26]. When evaluating groups separated by gait types, it was possible to verify a Pearson increase of 10% ($p = 0.0035$) for pronators, 12% ($p = 0.026$) for neutral, and 7% for supinators ($p = 0.19$), between the two calibration processes considering the Pearson of each group (Table 2). In the pronator and neutral subgroups, the positive effect of the dynamic calibration was observed despite the different types of gait evaluated. The supinators did not show differences between methods based on the T-Student test. The present work used a computational optimization technique during the calibration process based on the recommendation of Eguchi and Takahashi [27]. Their article suggests the use of non-linear approaches to improve the results obtained in its calibration process, corroborating the systematic review presented by Wong et al. [28], which presents better calibration results when using non-linear models.

Despite some groups presenting an increase in the coefficient of variation (Table 3) when applying dynamic calibration, there was no change in the general mean coefficient of variation considering both calibration methods. The CV remains equal to 0.07 in both cases. Even when considering the pronators 20% ($p = 0.036$), neutral 14% ($p = 0.025$), and supinators

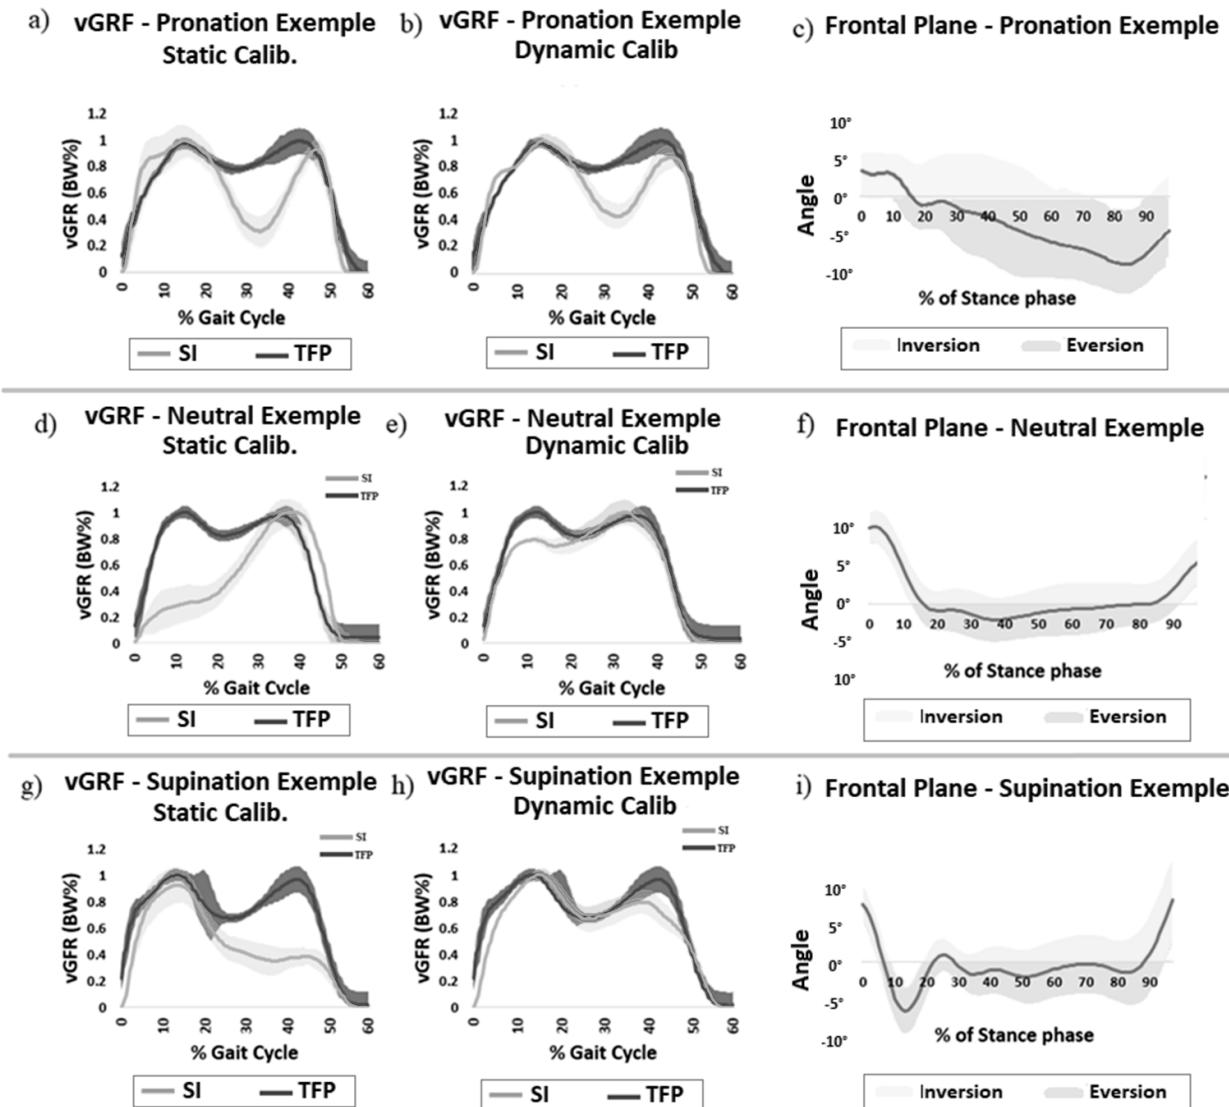


Fig. 2. The application of static (a, d and g) and dynamic calibration (b, e and h) on a trial collected during the study. a) Pearson = 0.92, CMC = 0.93 and RMSE=0.03, b) Pearson = 0.96, CMC = 0.95 and RMSE=0.02, d) Pearson = 0.84, CMC = 0.93 and RMSE=0.07, e) Pearson = 0.98, CMC = 0.91 and RMSE=0.01, g) Pearson = 0.89, CMC = 0.95 and RMSE=0.04 and h) Pearson = 0.97, CMC = 0.96 and RMSE=0.01.

14% ($p = 0.011$) groups, the change in Table 4 is not statistically significant. For the analysis of three experimental groups, the pronators present a small qualitative variation in mid-stance, decreasing the difference between SI and IT (Figures 2a and 2b). However, this qualitative variation in mid-stance did not present a statistical relevance. The other groups (neutrals and supinators) showed qualitative and quantitative gains in correlation (17% and 9% increase in Pearson's coefficient). In these last cases (neutral and supination), the static calibration was insufficient to ensure high correlation rates between the insole and the force platform.

The constructive characteristics of the insole directly influenced the performance of dynamic calibration. The pronator group shows a reduction in vGRF (SI) values during mid-stance compared to IT (Figures 2a and 2b), which is related to the medialization of the center of plantar pressure. This behavior reduced the loading of the lateral midfoot sensors, and in some cases, they cannot overcome the sensor's measurement inertia and record no pressure. One way to get around this lag is to adjust the sensitivity of the midfoot sensors. In the supinator group, it is the opposite. The previous one, the lateral displacement of the plantar pressure center caused a detachment between the curves for the gait cycle greater than 30% (Figures 2g and 2h). Because the insole does not have sensors on the lateral ends of the fingers (only in the Hallux), this factor causes the push-off forces to be undersized and affects dynamic calibration adjustment capacity. One way to get around this lag is to add sensors in this region.

According to Bittencourt et al. [29], sports injuries are multifactorial and present complex relationships that are difficult

to predict, especially with minimum information. This concept can be expanded to the interactions between an individual and the SI. This study demonstrated that static calibration might not be enough to meet the various interactions that an individual may have with the SI. Even in neutral gaits, the interaction's complexity can result in lower correlation based on static calibration. Conversely, altered gaits in the case of pronation can present higher correlations with the gold standard, with no differences between the calibration methods. Based on the findings, dynamic calibration proved better suited to dealing with the complexity caused by human interaction with the instrument during gait.

The insole used during the tests has a reduced number of sensors (11 sensors). This feature favored the increase of non-capturing regions, called blind regions. According to Seiberl et al. [30], the quantity and positioning of the sensors directly affect the quality of ground reaction forces captured. However, Ngueleu et al. [31] showed no consensus on the minimum number of sensors used or their positions. Despite the limitation in the number of sensors, the present study showed that the proposed method (dynamic calibration) is capable of improving the correlation of SI and IT (Pearson) without increasing the dispersion of values (RMSE) and decreasing precision and repeatability (CV).

Finally, the present study also has some limitations. For example, some insoles showed failures in capturing data, a common problem in this type of study. However, the number of data lost was negligible, considering that the number of participants at the beginning was higher than necessary, and the study was not compromised. Furthermore, the study was conducted based on healthy volunteers, and it was possible to verify the influence of the type of gait (pronated, neutral, and supine) on the quality of the vGRF measurement by the SI. This influence may be more significant in cases of pathological gait. However, the impact of gait was restricted in the SI data acquisition, regardless of the calibration method tested (static and dynamic). Even though the recorded data vGRF by the SI was impacted, it was found that dynamic calibration improved the quality of the SI measurement, bringing the result closer to IT. Future research involving dynamic calibration in pathological gaits will be necessary to confirm the impact on the correlation between SI and IT.

5 Conclusion

The proposed dynamic calibration methodology was applied to a SI with fewer sensors, which improved the results. This strategy proved to be better suited to the complexities of the individual's interaction with the instrument, ensuring a more significant correlation with the results of TFP. This method can help improve low-cost SIs, contributing to the improvement of biomechanical analyses performed with this instrument.

Acknowledgements

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001

References

- [1] Perry, J., Araújo, A. G. N., de Freitas, C. D., and Schoneberger, B., 2005. *Análise de marcha*.
- [2] Robertson, G., Caldwell, G., Hamill, J., Kamen, G., and Whittlesey, S., 2013. Research methods in biomechanics human kinetics.
- [3] Osoba, M. Y., Rao, A. K., Agrawal, S. K., and Lalwani, A. K., 2019. "Balance and gait in the elderly: A contemporary review". *Laryngoscope investigative otolaryngology*, **4**(1), pp. 143–153.
- [4] Vimieiro, C., Andrada, E., Witte, H., and Pinotti, M., 2015. "A computational model for dynamic analysis of the human gait". *Computer Methods in Biomechanics and Biomedical Engineering*, **18**(7), pp. 799–804.
- [5] Tan, A. M., Fuss, F. K., Weizman, Y., and Troynikov, O., 2015. "Development of a smart insole for medical and sports purposes". *Procedia Engineering*, **112**, pp. 152–156.
- [6] Tahir, A. M., Chowdhury, M. E., Khandakar, A., Al-Hamouz, S., Abdalla, M., Awadallah, S., Reaz, M. B. I., and Al-Emadi, N., 2020. "A systematic approach to the design and characterization of a smart insole for detecting vertical ground reaction force (vgrf) in gait analysis". *Sensors*, **20**(4), p. 957.
- [7] Ivanov, K., Mei, Z., Lubich, L., Guo, N., Xile, D., Zhao, Z., Omisore, O. M., Ho, D., and Wang, L., 2019. "Design of a sensor insole for gait analysis". In International Conference on Intelligent Robotics and Applications, Springer, pp. 433–444.
- [8] Malvade, P. S., Joshi, A. K., and Madhe, S. P., 2017. "In-sole shoe foot pressure monitoring for gait analysis". In 2017 International Conference on Computing, Communication, Control and Automation (ICCUBEA), IEEE, pp. 1–4.
- [9] Martini, E., Fiumalbi, T., Dell'Agnello, F., Ivanić, Z., Munih, M., Vitiello, N., and Crea, S., 2020. "Pressure-sensitive insoles for real-time gait-related applications". *Sensors*, **20**(5), p. 1448.
- [10] Eguchi, R., Yorozu, A., Fukumoto, T., and Takahashi, M., 2016. "Ground reaction force estimation using insole plantar pressure measurement system from single-leg standing". In 2016 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI), IEEE, pp. 109–113.

- [11] Fuchs, P. X., Hsieh, C.-H., Chen, W.-H., Tang, Y.-S., Fiolo, N. J., and Shiang, T.-Y., 2022. “Sensor number in simplified insole layouts and the validity of ground reaction forces during locomotion”. *Sports Biomechanics*, pp. 1–14.
- [12] Chuckpaiwong, B., Nunley, J. A., Mall, N. A., and Queen, R. M., 2008. “The effect of foot type on in-shoe plantar pressure during walking and running”. *Gait & posture*, **28**(3), pp. 405–411.
- [13] PhysioCode, 2022. Physiocode company, minas gerais; bra. <https://www.physiocode.com.br>. Accessed: 2022-08-12.
- [14] Reiff, A., 2016. “Different in-shoe devices for partial weight bearing”. PhD thesis, Faculty of Science and Engineering.
- [15] Crea, S., Donati, M., De Rossi, S. M. M., Oddo, C. M., and Vitiello, N., 2014. “A wireless flexible sensorized insole for gait analysis”. *Sensors*, **14**(1), pp. 1073–1093.
- [16] Dyer, P. S., and Bamberg, S. J. M., 2011. “Instrumented insole vs. force plate: A comparison of center of plantar pressure”. In 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, IEEE, pp. 6805–6809.
- [17] Kaniththika, K., and Chan, K. S., 2014. “Pressure sensor positions on insole used for walking analysis”. In The 18th IEEE International Symposium on Consumer Electronics (ISCE 2014), IEEE, pp. 1–2.
- [18] Ferrari, A., Cutti, A. G., and Cappello, A., 2010. “A new formulation of the coefficient of multiple correlation to assess the similarity of waveforms measured synchronously by different motion analysis protocols”. *Gait & posture*, **31**(4), pp. 540–542.
- [19] Al-Amri, M., Nicholas, K., Button, K., Sparkes, V., Sheeran, L., and Davies, J. L., 2018. “Inertial measurement units for clinical movement analysis: Reliability and concurrent validity”. *Sensors*, **18**(3), p. 719.
- [20] Sorrentino, I., Andrade Chavez, F. J., Latella, C., Fiorio, L., Traversaro, S., Rapetti, L., Tirupachuri, Y., Guedelha, N., Maggiali, M., Dussoni, S., et al., 2020. “A novel sensorised insole for sensing feet pressure distributions”. *Sensors*, **20**(3), p. 747.
- [21] Kang, H., 2021. “Sample size determination and power analysis using the g* power software”. *Journal of educational evaluation for health professions*, **18**.
- [22] Selman, B., and Gomes, C. P., 2006. “Hill-climbing search. encyclopedia of cognitive science”. *Encyclopedia of Cognitive Science*.
- [23] Queen, R. M., Mall, N. A., Nunley, J. A., and Chuckpaiwong, B., 2009. “Differences in plantar loading between flat and normal feet during different athletic tasks”. *Gait & posture*, **29**(4), pp. 582–586.
- [24] Barratt, G. K., Bellenger, C., Robertson, E. Y., Lane, J., and Crowther, R. G., 2021. “Validation of plantar pressure and reaction force measured by moticon pressure sensor insoles on a concept2 rowing ergometer”. *Sensors*, **21**(7), p. 2418.
- [25] Nagahara, R., and Morin, J.-B., 2018. “Sensor insole for measuring temporal variables and vertical force during sprinting”. *Proceedings of the Institution of Mechanical Engineers, Part P: Journal of Sports Engineering and Technology*, **232**(4), pp. 369–374.
- [26] Giacomozi, C., Caravaggi, P., Stebbins, J., and Leardini, A., 2016. “Integration of foot pressure and foot kinematics measurements for medical applications”. *Handbook of Human Motion*, pp. 1–22.
- [27] Eguchi, R., and Takahashi, M., 2018. “Accessible calibration of insole force sensors using the wii balance board for kinetic gait analysis”. In 2018 IEEE SENSORS, IEEE, pp. 1–4.
- [28] Wong, C., Zhang, Z.-Q., Lo, B., and Yang, G.-Z., 2015. “Wearable sensing for solid biomechanics: A review”. *IEEE Sensors Journal*, **15**(5), pp. 2747–2760.
- [29] Bittencourt, N. F., Meeuwisse, W., Mendonça, L., Nettel-Aguirre, A., Ocarino, J., and Fonseca, S., 2016. “Complex systems approach for sports injuries: moving from risk factor identification to injury pattern recognition—narrative review and new concept”. *British journal of sports medicine*, **50**(21), pp. 1309–1314.
- [30] Seiberl, W., Jensen, E., Merker, J., Leitel, M., and Schwirtz, A., 2018. “Accuracy and precision of loadsol® insole force-sensors for the quantification of ground reaction force-based biomechanical running parameters”. *European journal of sport science*, **18**(8), pp. 1100–1109.
- [31] Ngueleu, A. M., Blanchette, A. K., Bouyer, L., Maltais, D., McFadyen, B. J., Moffet, H., and Batcho, C. S., 2019. “Design and accuracy of an instrumented insole using pressure sensors for step count”. *Sensors*, **19**(5), p. 984.

Appendix A

The processing of the First Improvement Hill Climbing algorithm is represented by the pseudocode below and takes place in 3 steps:

First step: the definition of the input variables takes place, where in lines 1 and 2 are defined the matrices that store the vGRF data of the SI (Sensors[Z,n]) and IT (Plataform[Z]), where Z represents each trial and n the number of each sensor. Each Solution S is generated by the new_sol() function and stored in the array S[n](lines 3 and 19).

Second step: After generating a solution S, the vGRF is calculated considering this new solution (lines 8-10) and evaluated by fit(), which receives as input the vGRF applied to Solution S (vGRF[Z]) and the vGRF of the IT (Platform [Z]) (line 15)

Third step: the algorithm compares the result of the evaluation of each solution S (line 14) and stores the best solutions

(lines 15 and 16)

This cycle is maintained until it is not possible to find a solution that reduces the RMSE

Algorithm 1 First Improvement Hill Climbing

```
Sensors [Z,n]= each sensor data from SI                                ▷ n = sensor Z= nº volunteer
Plataform [Z]= data from IT
S[n]=new sol();
RMSE best= 1;
while RMSEbest > Goal do
    vGRF [Z]=0;
    for each Z in time
        for ( doi=0;i<7;i++)
            vGRF [Z]= vGRF [Z] + S[i]* Sensors [Z,i]
        end for
        RMSE =fit(vGRF [Z], Plataform [Z]);
        if ( thenRMSEstart < RMSE)
            RMSE best = RMSE;                                         ▷ record the best solution
            R[n]=S[n] ;
        else
            S[n]=R[n] ;                                         ▷ returns the last solution
        end if
        S[n]=new sol();                                         ▷ generates a new solution
    end while
    return R[n] e RMSE best;
```

Appendix B

For kinetic and kinematic data acquisition, 14mm passive retroreflective markers were affixed to each participant, seven on each individual's lower limb. The markers were positioned: in the central region of the calcaneus, head of the first metatarsal, head of the fifth metatarsal, over the lateral epicondyle of the femur, over the medial epicondyle of the femur, over the lateral malleolus, and the medial malleolus. In addition, a rigid cluster with four passive retroreflective markers will be positioned in the posterolateral region on the distal third of the leg, using an elastic band and double-sided tapes. Data acquisition in the orthostatic position was performed for five seconds, which was used to identify the markers and create the biomechanical model. The markers' position was the reference for the angular variations and motion tracking. After creating the biomechanical model, the anatomical markers on the epicondyles were removed. At this moment, those markers are no longer needed and can become detached while walking and interfere with the test.

The markers were tracked in the Qualisys Track Manager program (Version 2019.3, Qualisys MEDICAL AB, Sweden) and processed in the Visual3D™ x64 Professional program (v2020.02.04, C-Motion, USA). The raw data was filtered with a fourth-order low pass Butterworth filter with a cutoff at 6Hz for the kinematic data and 15Hz for the kinetic data. The foot segment was modeled as a rigid cone, defined anteriorly by the metatarsal marks and posteriorly by the calcaneus mark. The leg was modeled as a rigid cylinder, defined proximally by the marks of the epicondyles and distally by the marks of the malleolus. For analysis of the movement of the ankle-foot complex, the frontal plane will be considered. On this plane, the ankle's angle smaller than -5° in the push-off phase was considered pronation behavior, 5° until 5° neutral behavior greater than 5° a supination behavior.

Apêndice C

Artigo Aceito

Design a custom resistive force sensors to optimize sensorized insoles

Diego Henrique Antunes Nascimento, Fabrício Anicio Magalhães, George Schayer Sabino,
Renan Alves Resende, Maria Lúcia Machado Duarte, Claysson Bruno Santos Vimieiro.

Abstract

Purpose: Currently, several studies have been published using sensorized insoles for estimating ground reaction force using plantar pressure. However, information on design parameters, manufacturing techniques, and guidelines for developing insoles is scarce, often leaving gaps that do not allow reproducing the insole. The present work empirically investigated the main parameters of constructing a sensorized insole for application in human gait.

Design/methodology/approach: Two devices were built to evaluate the force sensors. The first focuses on the construction of the sensors with different settings: the density of the sensor's conductive trails (thickness and distance of the trails) and the inertia of the sensors (use of spacers to prevent unwanted readings). The second device focuses on the data capture and processing system: resolution of the analog-digital converter, acquisition rate, sensor activation level.

Findings: The resolution increase of the analog-digital converter and acquisition rate do not contribute to noise increase. Reducing the sensors' coverage area can increase sensorized insole capacity. The inertia of the sensors can be adjusted using spacers without changing the electrical circuit and acquisition system.

Originality/value: Most sensorized insoles use commercial sensors. For this reason, it is not possible a full customization. This paper maps the main variables to manufacture custom sensors and data acquisition systems. This work also presents a case study where it is possible to see the influence of the parameters in the correlation between the sensorized insole and an instrumented treadmill with a force platform.

Index Terms— sensorized insole parameters, development of smart insoles, force-sensitive resistors; pressure measurement

I. INTRODUCTION

THE advancement of microelectronics in embedded systems, together with the internet of things, has developed wearable devices to obtain bio-feedback. An example is sensorized insoles to measure plantar pressure during gait [1]. The plantar pressure is captured by pressure sensors arranged at strategic points along with an insole to coincide with the anatomical structures of the foot [2]. These sensors are responsible for dynamically recording the loads applied during walking or running, processing and transforming them into information such as ground reaction force [3] [5] or Spatio-temporal variables, such as cadence [1] [6], step length [1] [6] or even stratification of gait phases through event detection models [7]. Currently, several publications are about prototypes of sensorized insoles that use resistive sensors to capture data [2] [8]. This type of sensor can be purchased commercially and used for instrumentation of conventional insoles [9] [10], or they can be made using printed circuit manufacturing techniques on flexible circuits [11]. Many studies that propose different designs for sensorized insoles use commercial force sensors, limiting

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001

Diego Henrique Antunes Nascimento, Maria Lúcia Machado Duarte and Claysson Bruno Santos Vimieiro belong to Universidade Federal de Minas Gerais (UFMG), Bioengineering Laboratory (LABBIO), Graduate Program in Mechanical Engineering (PPGMEC), MG – Brazil. (e-mail: engdiegohenrique@ufmg.br).

customization for application [12],[13][14]. This paper propose a full customization, by manufacturing the resistive force sensors. This choose allows greater autonomy for customizing a sensorized insole and can be manufactured as a single circuit, without wires or solders connections. However, the fabrication of a sensorized insole in a flexible circuit, although simple, requires a series of attention that are generally not discussed in the literature. This work examines the main components and parameters of a resistive pressure sensor (made in a flexible circuit) and its influence on applying a sensorized insole.

II. MATERIAL AND METHODS

Although several data acquisition systems are using sensorized insoles based on resistive sensors [1][9][10], the same structure can be observed in all of them, where a sensor is subjected to a load and has its electrical resistance changed inversely proportional to loading [1]. An electronic circuit records this resistance change where an analog-digital converter (ADC) transforms the signal into binary information, and then the microcontroller can filter and

Fabrício Anicio Magalhães belongs to the University of Nebraska at Omaha, College of Education, Health, and Human Sciences, Department of Biomechanics, Omaha, NE 68182, USA.

George Schayer Sabino belongs to Universidade Federal de Minas Gerais (UFMG), School of Physical Education, Physical Therapy and Occupational Therapy (EEFFTO), Graduate Program in Rehabilitation Sciences, MG – Brazil.

process the data. The first element of the system that was studied is the resistive sensor. Resistive sensors are composed of three main parts (Figure 1): the conductive trails, the semiconductor polymer (velostat), and a spacer [1]. The conductive trails integrate the data acquisition circuit, the spacer prevents accidental contact between the tracks, and the semiconductor polymer (velostat) varies its resistance according to the applied load. Each of these components was evaluated to quantify their influence during data acquisition.

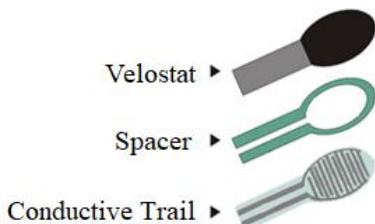


Fig. 1. The resistive sensor has three main components: the conductive trail, the semiconductor polymer (velostat) and a spacer.

The second element studied was the application of the noise removal filter, which is a sensitive step in data acquisition processing and should be used with attention. A prototype of an acquisition system with a sensorized insole from the company PhysioCode [15] was used as a reference. Each insole has 11 sensors in this system, divided into seven anatomical regions (Figure 2). Each sensor is 2.5 cm in diameter, and the sensorized insole was manufactured using a laminated polyamide sheet with a copper printed circuit. The data acquisition system uses the ESP-32 microcontroller (Espressif Systems) and a 12-bit ADC with an acquisition rate of 375Hz.



Fig. 2.: a) sensorized insole used as a reference b) anatomical regions covered by the reference insole: Hallux (1), first metatarsal head (2), second and third metatarsals heads (3), fourth and fifth metatarsal head (4), lateral midfoot (5), medial midfoot (6) and calcaneus (7).

Based on the constructive parameters of the provided insole, a series of experiments were conducted to simulate and quantify the influence of the main variables that constitute the data acquisition system: the composition of the sensors and the application of filters to reduce noise.

A. Sensors: Effect of Conductive Trails

Resistive pressure sensors have two isolated circuits arranged in parallel, which are joined by a semiconductive polymer (velostat) (Figure 1). This velostat allows the passage of electric current between these circuits when pressed. The greater the thickness of the trails (T_{tr}) of each of the circuits, the greater the contact surface between the circuit and the velostat (higher conductivity), and the greater the distance between the trail (D_{tr}), the lower the conductivity of the system. Considering the limitations of the manufacturing process available in the Laboratory, three test plates were manufactured, containing three variations of sensors each (Figure 3). Each plate shown in Figure 3 was connected to a circuit with the ESP-32 microcontroller. The same analog port was used to perform all measurements to minimize the influence on the noise level.

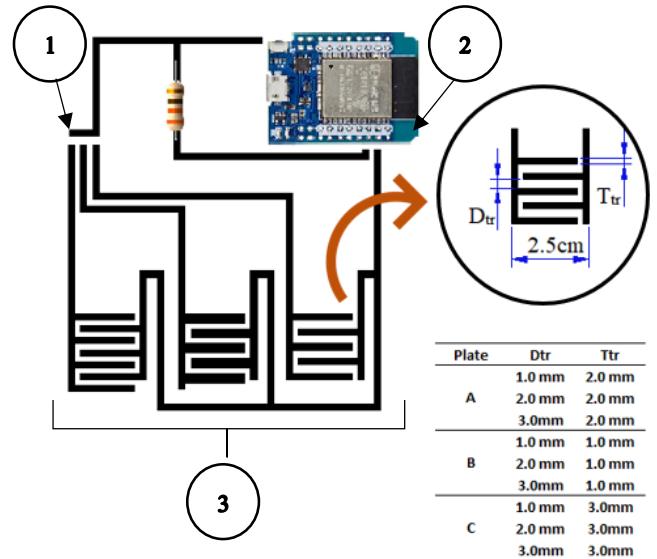


Fig. 3.: Test plates manufactured with the conductive trails' variation. 1) jumper for selecting the sensor to be tested; 2) Wemos D1 mini Esp32 plate (Espressif Systems); 3) sensors with constructive variations for testing.

Each test plate sensor was placed on a precision scale (Scale SF-400, max load 10kg/1g, China) and loaded with determined weights ranging from 1kg to 10kg (2kg increment) to record the voltage drop caused by each of the sensors. The values were recorded in millivolts between 0 to 3000mV (maximum value of the circuit power supply) and repeated three times to obtain an average. For example, the sensor is saturated if the circuit registers a voltage drop of 3000mV. At this moment,

the velostat resistance tends to zero due to compression, and the sensor loses the ability to react to higher loads. The results will be analyzed to quantify the influence of T_{tr} and D_{tr} on the sensor's voltage drop using ANOVA [13].

B. Sensors: Effect of Spacers

The resistive pressure sensors have a spacer responsible for keeping the velostat away from the conductive trail, avoiding false readings during eventual deformations of the insole. This feature prevents the foot's movement from recording during the Swing Phase during gait. A vinyl adhesive was used (Figure 4b). When pressed, the velostat molds to the spacer and starts the measurement (Figure 4a). The smaller the spacer openings, the greater the difficulty for the velostat to conform to the spacer and start the measurement, increasing the insole's inertia (load needed to activate the sensors).

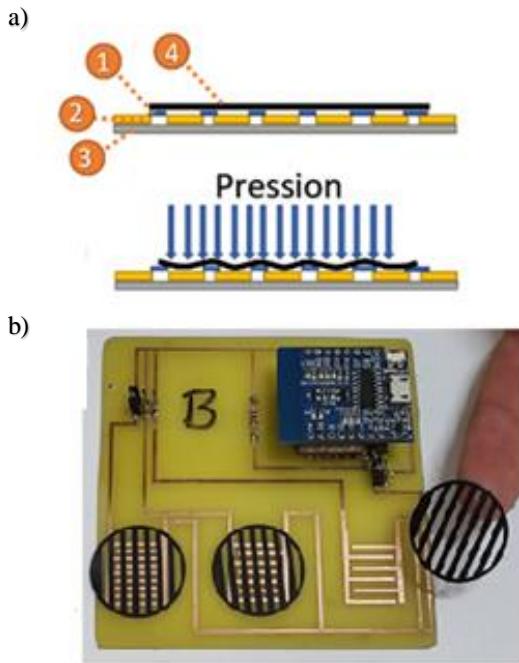


Fig. 4.: Action of the spacers with the system. a) sensor working; (1) Spacer; (2) conductive trails, (3) base of the sensor; and (4) Velostat; b) vinyl spacer used in the tests.

Each sensor used to verify the previous Section had the activation threshold tested for nine different types of spacers. As with the conductive trails, the spacer opening (O_{sp}) was varied from 1mm to 3mm (with 1mm increment) and the distance between the openings (D_{sp}) from 1mm to 3mm (with 1mm increment). The greater the D_{sp} , the greater the inertia of each sensor, and the greater the O_{sp} , the smaller the inertia. This way, each of the sensors (together with the spacer) was placed on the same precision balance and pressed using a mechanical device (Figure 5) until the pressure sensor started recording.

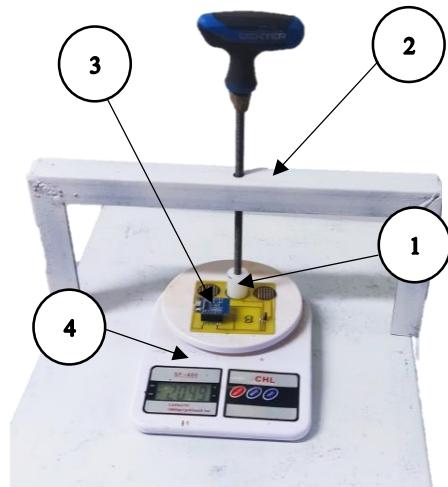


Fig. 5.: Device for constant load application consisting of: load application rod (1), fixing structure (2), sensor test plate (3), and precision balance (4)

Each test was repeated three times to obtain an average of the results. A voltage drop of 6mV was defined as the activation threshold (minimum value detectable by a 9-bit analog-to-digital converter, which is the lowest setting available in the ESP-32). The load required for each sensor's activation (in kg) was recorded. The results were analyzed to evaluate O_{sp} and D_{sp} 's influence concerning the minimum load for sensor activation using two-way ANOVA [16].

C. Signal Treatment

The voltage drops caused by the activation of the sensors are measured continuously using an analog signal, discretized, and converted into a digital signal using an ADC. The ESP-32 microprocessor has four converters: 9-bits, 10-bits, 11-bits, and 12-bits. These ADCs interfere with the signal reading, generating noise, which can be influenced by the acquisition rate (f) and the sensor loading (L_{sensor}). To attenuate these noises inherent to the system, filters are designed. In this work, a set of experiments was carried out to evaluate the influence of different ADCs and their interactions with resistive sensors and the application of filters. A circuit composed of a microcontroller (ESP-32) and a $1k\Omega$ potentiometer was manufactured to simulate a resistive sensor's activation (Appendix A). The potentiometer was set to simulate four values for L_{sensor} : 25%, 50%, 75%, and 100%, to represent the entire measurement range of a resistive sensor, divided into four quartiles. The acquisition rate (f) was defined between 100 and 400Hz (with an increment of 50Hz), a range that encompasses the highest operating range of resistive insoles found in the literature [1]. Figure 6 schematically shows the variations established for the experiments. For each test, 1,000 consecutive readings were acquired. This set of 1,000 data forms a sample.

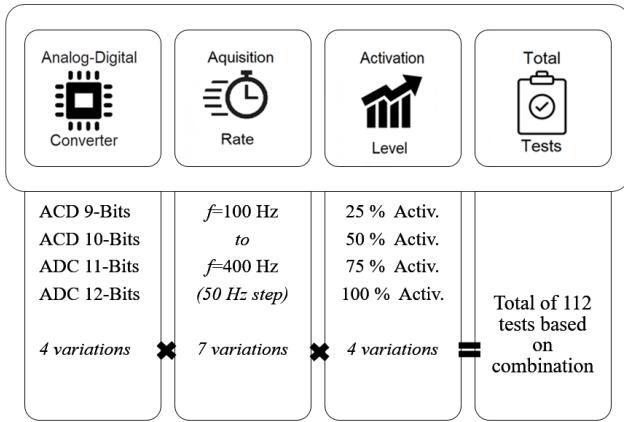


Fig. 6.: Diagram of tests performed. Each analog to digital converter was tested separately, varying the acquisition rate ($f=100\text{-}400\text{Hz}$) and sensor activation between 25%-100%.

After acquiring the samples, a noise removal filter was applied. To restrict the complexity of this work and the number of experiments, the influence of a moving average filter was evaluated, as it is a simple and recurrent filter in the literature [17] [18], having as a parameter only the number of periods (P). Each sample was submitted to the moving average filter with periods ranging from two to 10 (with unit increment). For the analysis, the noise was defined as the sampling coefficient of variation (CV) and, with this series of experiments, the following interactions were evaluated: influence of f and the L_{sensor} in each ADC concerning the CV and the average of the recorded signal, no filter application; the effect of the application of each filter on the samples, varying the periods of the filter to verify the impact in each case using the paired, two-tailed T-Test with a confidence interval of 95%.

D. Reference Insole Evaluation

Eight insole pairs were provided between 6 and 11.5 using U.S. standard men's shoe sizes. All insoles supplied as a reference were disassembled to measure the parameters of the resistive sensors (T_{tr} , D_{tr} , O_{sp} , and D_{sp}) using an analog caliper with a resolution of 0.05mm. The insole was divided into three regions based on the placement of the sensors: anterior (covers regions one to four of the insole), middle (covers regions five and six of the insole), and posterior (covers region seven of the insole). Each of the three regions had its surface area estimated using geometric approximations (Appendix B).

The gait of a male volunteer, 34 years old, body mass index (BMI) of 32.5kg/m^2 (110kg), without any neurological disorder or history of recent (six months) lower limb surgery, foot size number 12. The test was performed to obtain a sample of the insole performance and verify the compatibility between the parameters tested and mapped on the bench and the application of the instrument. The participant performed a minute walking on the instrumented treadmill with a double-belt and two built-in force plates (Bertec at 1000Hz, Bertec Corp, Columbus, OH) wearing sensorized insoles. The gait speed was self-selected (mean (SD): 1.2 m/s). After

performing the test, the data from the sensorized insole was compared with instrumented treadmill using 30 steps to obtain a single mean step representing the volunteer's gait.

III. RESULTS

A. Sensors: Effect of Conductive Trails

Despite being marketed as force sensors, resistive sensors measure the applied pressure. Once the area is known, the force becomes tangible. Therefore, the results were presented based on the force measured in the tests (kgf). Figure 7 shows a linear regression based on the values found. Based on linear regression, an estimate was found for the saturation value in each sensor variation.

An ANOVA was performed to verify the statistical significance of T_{tr} and D_{tr} variations. The values found for F (F-critical) were: 14.78 (3.00) and 12.19 (3.14). The values found show a significant difference between the variations of T_{tr} and D_{tr} .

B. Sensors: Effect of Spacers

After completing the tests with the spacers, a two-way ANOVA (O_{sp} and D_{sp}) was performed with nine repetitions (each of the nine sensors was considered a repetition). No significant difference was found between repetitions ($F=1.60$ and $F\text{-critical}=3.12$), and no significant difference was found in the variation of D_{sp} ($F=1.60$ and $F\text{-critical}=3.12$). The O_{sp} was the only statistically relevant variable to differentiate the sensors' activation inertia. Figure 8 shows the relationship between activation inertia and O_{sp} , considering an average of the nine sensors tested¹.

¹ complete results in Complementary material Section A

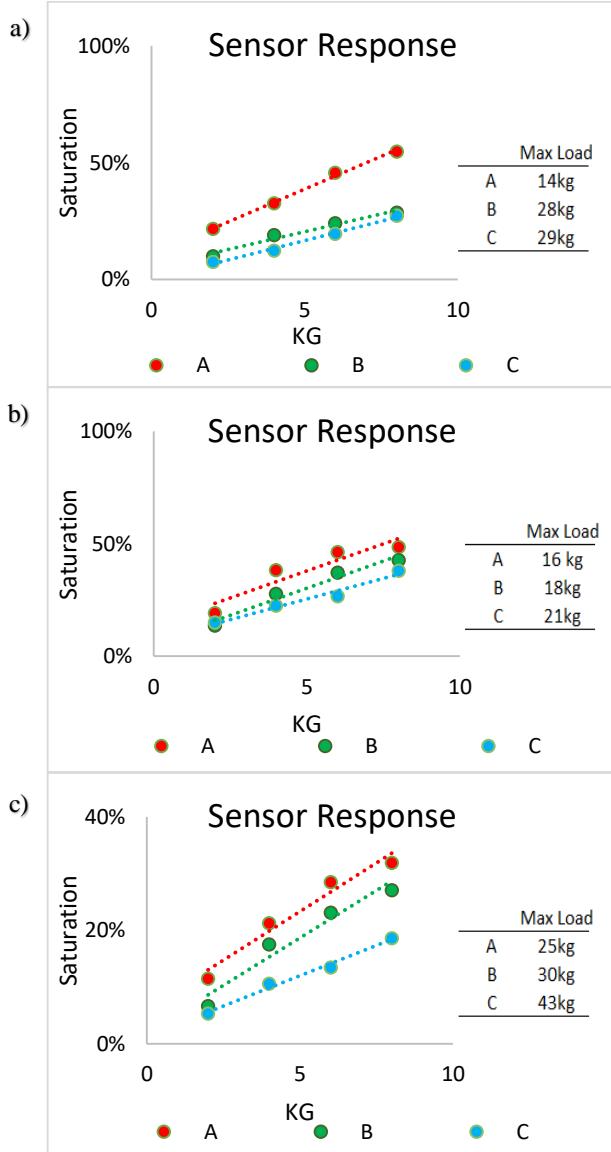
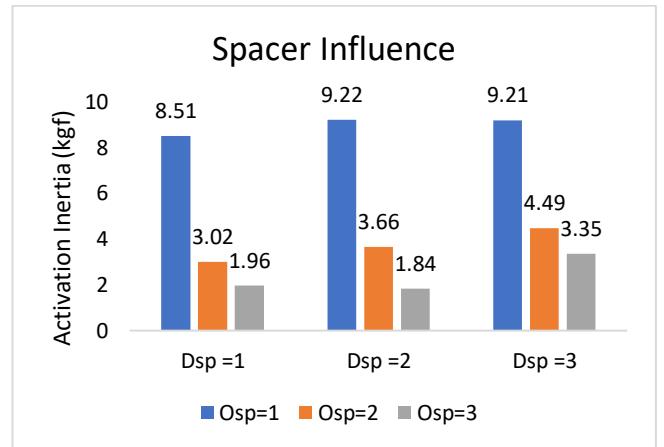


Fig. 7.: Behavior curve of each sensor when applied load; a) Sensors with $T_{tr}=2\text{mm}$; b) Sensors with $T_{tr}=1\text{mm}$; c) Sensors with $T_{tr}=3\text{mm}$.



Legend: D_{sp} : Distance between the openings; O_{sp} : Spacer opening

Fig. 9.: Average inertia of sensors activation in a different configuration of spacers.

C. Signal Treatment

Figure 9 summarizes the results obtained from CV (average considering the L_{sensor}) based on the variations of f and ADC^2 .

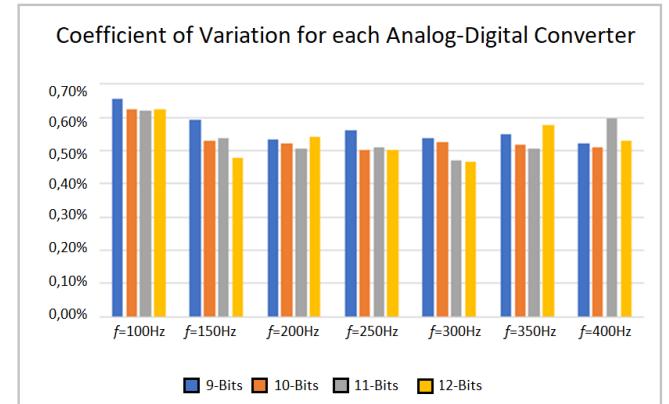


Fig. 9.: Average noise in each simulated ADC related to f .

After finishing the tests with the ADCs, a two-way ANOVA (f and L_{sensor}) was performed without repetitions for each filter, considering the CV. Table I presents a summary of the ANOVAs performed, and it was verified that the L_{sensor} is a statistically relevant variable and that f becomes irrelevant for the 11-Bit and 12-Bit ADC³.

² complete results in Complementary material Section B

³ complete results in Complementary material Section C

TABLE I
SUMMARY OF STATISTICAL SIGNIFICANCE ACCORDING TO COEFFICIENT OF VARIATION USING TWO-WAY ANOVA.

	L_{sensor}	f			
		F	F-crítico	F	F-crítico
9-Bits	96.15	3.16	5.05	2.66	
10-Bits	88.42	3.16	11.15	2.66	
11-Bits	39.02	3.16	2.6	2.66	
12-Bits	10.39	3.16	1.13	2.66	

As discussed earlier, the moving average filter can reduce noise. This reduction has its intensity regulated by the number of periods. Table II presents a summary of the application of the filters so that there is no longer any significant difference between the CV concerning f and L_{sensor} , and P represents the filter order.

TABLE II
SUMMARY OF THE EFFECT OF FILTER APPLICATION ON THE STATISTICAL SIGNIFICANCE OF COEFFICIENT OF VARIATION ACCORDING TO ANOVA.

	f	without filter		with filter	
		F	F-critic	P	F
9-Bits	f	5.05	2.6	8	1.57
	L_{sensor}	96.15	3.16	8	0.88
10-Bits	f	11.15	2.66	7	0.59
	L_{sensor}	88.42	3.16	7	3.16
11-Bits	f	2.6	2.66	6	1.04
	L_{sensor}	39.02	3.16	6	3.16
12-Bits	f	1.13	2.66	4	1.05
	L_{sensor}	10.39	3.16	4	0.92

The application of noise reduction filters impacts the nominal reading of values so that the greater the performance of the Filter (P), the greater this influence. Table III summarizes the impact of filter actuation on system measurements using the Paired T-Test⁴.

TABLE III
SUMMARY OF THE EFFECT OF APPLYING A FILTER ON THE STATISTICAL SIGNIFICANCE OF THE SAMPLE MEAN ACCORDING TO THE T-TEST.

	L_{sensor}	MM		Δ	p-value
		without filter (mV)	MM with filter (mV)		
9-Bits	25%	754	753	-0.11%	4.00E-13
	50%	1482	1481	-0.11%	1.00E-12
	75%	2256	2253	-0.11%	7.00E-13
	100%	2972	2969	-0.11%	1.50E-14
10-Bits	25%	750	750	-0.04%	1.20E-09
	50%	1503	1502	-0.04%	3.60E-10
	75%	2241	2240	-0.04%	2.20E-10
	100%	2986	2984	-0.04%	2.90E-11
11-Bits	25%	756	754	-0.28%	1.80E-14
	50%	1496	1491	-0.28%	1.10E-13
	75%	2250	2244	-0.28%	6.40E-13
	100%	2963	2955	-0.28%	6.40E-13
12-Bits	25%	761	760	-0.08%	2.10E-11
	50%	1502	1501	-0.08%	2.20E-12
	75%	2257	2255	-0.08%	4.30E-10
	100%	2970	2967	-0.08%	3.40E-12

MM- Mean of Measurements

D. Reference Insole Evaluation

After disassembling each insole, it was observed that the constructive parameters were maintained in all numbers: $T_{\text{tr}}=2.0$ mm, $D_{\text{tr}}=2.0$ mm, $O_{\text{sp}}=1.9$ mm, and $D_{\text{sp}}=1.7$ mm. The surface area of each of the three proposed regions was measured, presenting an average of 73.70cm^2 (+/-11%) for the anterior region, 78.44cm^2 (+/-10%) for the middle region, and 42.90cm^2 (+/-19%) for the posterior region. The relationship between the surface area of the sensors concerning the total area of the insole was verified, reaching an average of 23% (+/- 12%) (coverage area) (Appendix B)

Figure 10 shows the correlation between the sensorized insole (SI) and the instrumented treadmill (TFP - treadmill with a force plate). Pearson's coefficient was used to quantify the correlation between the instruments, with the TFP as the gold standard.

⁴ complete results in Complementary material Section D

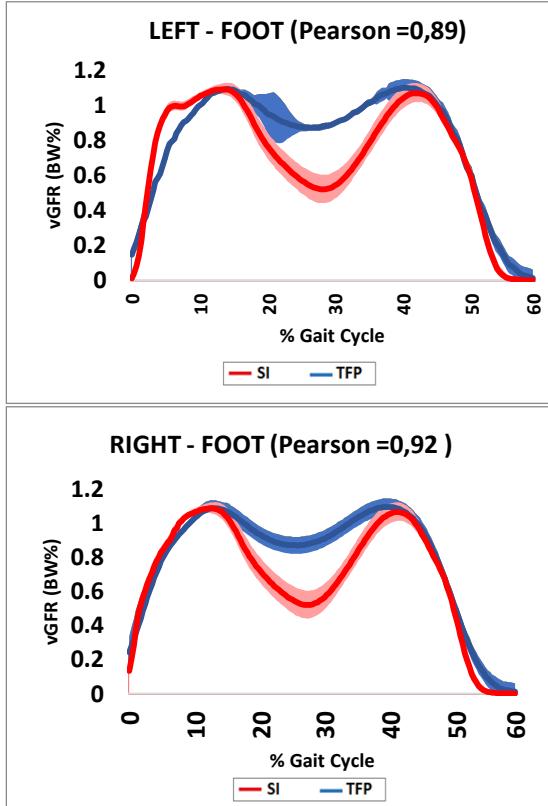


Fig. 10.: Result of data collection carried out to exemplify the application of the sensorized insole.

IV. DISCUSSIONS

Systematically, the current work presented several constructive parameters of a resistive sensor and some particularities of the signal treatment of this type of sensor. This set of results makes it possible to evaluate the reference insole to discuss its limitations and possibilities for improvement. During gait, the moments of most considerable loading are the Load Response and the impulsion (Pre-Swing and Terminal Stance) [2]. At these moments, the ground reaction force is concentrated on the front or back of the foot, respectively. Thus, the sum of the sensor saturations must not be less than the applied load. When evaluating the reference insole, three sensors are observed in the posterior region and four sensors in the anterior region. Considering the set of specifications of this insole, it can be estimated that its maximum capacity would be close to 84kfg (based on the posterior region with three sensors of 28kfg capacity), restricting its application to individuals weighing less than 70kg since the force peaks can reach 1.2 times body weight [2][19]. According to Grivas et al. [20], body weight tends to increase according to foot size and may become a limitation of using this sensor configuration in larger numbered insoles. However, there is something to consider about the insole capacity. Since resistive sensors do not have a 100% coverage capacity concerning the plantar pressure region, this capacity may be greater than 70 kg because the sensors must register only a part of the acting pressure. The sensors placed on the posterior region cover only 19.12% (Appendix B), considering the insole with foot size 12 (volunteer). This fact contributed

to the distribution of part of the load without extrapolation of the measurement capacity of the sensors in the evaluated insole.

The reference insole presents lower loads recording during mid-stance. This is because the sensor configuration offers measurement inertia of 3.66kg for its activation (based on the test results). This feature can make measurements during mid-stance difficult. This is because, during mid-stance, the most significant plantar distribution occurs [2]. Considering the 11 sensors present, with an inertia of 40.26kgf, individuals weighing less than 57.51kg may present the non-activation of sensors during the mid-stance because the ground reaction force may reduce by 30% during the mid-stance [21]. In this case, the blind areas have an opposite effect during mid-stance if compared to load response and impulsion. The distribution of loads in the blind regions helps absorb forces during load response and impulsion, increasing the total load capacity of the insole. This is because the sensorized insole registers only part of the load. However, during mid-stance, this spread of forces difficulties the sensor's activation due to the system's inertia.

Another point is the non-uniformity of the plantar region and the anatomy of the foot, which has a different impact on each sensor. According to Chuckpaiwong [22], the type of foot (considering variations in the plantar arch) directly influences plantar pressure distribution. This aspect can affect the load reduction on some of the sensors and result in their non-activation, impacting the result with the same safeguard regarding the sensors' actuation coverage. One way to reduce this effect is using different sensors and spacers configurations along the sensorized insole, especially in the midfoot region. This region presents lower concentrations of plantar pressure [24] during gait; therefore, spacers with the lowest possible inertia and sensors with greater sensitivity should be adopted. This modification must be considered during calibration, and the loads may change during this process so that loads that exceed the capacity of the sensors are not used.

The reference insole uses 12-Bit ADC, which is not influenced by noise during f variation. This feature allows greater flexibility to the system when it is necessary to adjust the f to carry out a comparative study with other instruments, such as a force platform. The present study did not show any loss when increasing the ADC resolution from 9-Bits to 12-Bits. Contrary to expectations, this increase of resolution on ADC resulted in decreased noise levels and reduced the need to apply filters compared to the other ADCs. This effect may be related to the use of the ESP32 microcontroller. According to Cameron [25], ESP32 has a standard noise attenuation system for ADC already implemented in its architecture, which can contribute to stabilizing readings with higher ADC resolution and higher f .

The number of periods (P) required to apply the moving average filter reduced as the ADC resolution increased. By using filters of lower P , the attenuation effect on the nominal reading of the values is smaller, making the system more sensitive to recording the measurements' peaks. If high, this peak attenuation effect may mask some gait behavior. The company did not provide information on the treatment of

signals performed on the reference insole. However, based on the results and configurations presented, if a moving average filter were used, it would be with a period greater than four due to 12-Bit ADC. Since smaller filters cannot remove the noise generated by the acquisition system.

Finally, this study is not free of limitations. As all sensors' tests were performed on a bench, effects such as sensor deformation during movement were not evaluated. This was evidenced in a gait test with a volunteer. Although the test has only a qualitative effect, comparing the behaviors recorded on the bench and in the real application was possible. To minimize the deformation during movement, the sensors used in the reference insole were laminated together with conductive trails, spacers, and velostat, composing a unison piece. This fact can avoid relative displacements between the parts, which lessens part of the effects of movement, and the spacer will prevent accidental readings during the deformation of the sensors without load. In addition, the sensors will be supported on a flat surface (ground) during activation, avoiding deformations during the measurement.

V. CONCLUSION

The present work showed relevant parameters for designing sensorized insoles using resistive sensors and aspects of recording and experimentally processing the sensor signals. It can be seen from the results presented that a sensorized insole can be optimally designed to capture different load ranges, and the selected constructive parameters will also limit its performance and define its behavior upon the applied load. Furthermore, this presented compilation of information considers a current microcontroller and ADC. Therefore, it will help develop sensing surfaces for capturing biofeedback, not only for gait and running.

APPENDIX A

According to the datasheet [23], the velostat has a resistance of $500 \Omega/\text{cm}$, with the maximum dimension of the sensor being 2 cm. Therefore, it was decided to build the test circuit using a resistor of $1\text{k}\Omega$. A type B potentiometer (linear response) was chosen to simulate the activation level of the sensors. This eliminates any external mechanical noise source, focusing on the characterization of the acquisition system. Figure A1 shows how the test circuit was built.

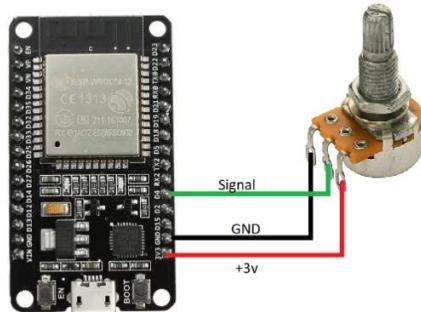


Fig. A1.: Test circuit wiring diagram

The software for programming the microcontroller was written using ARDUINO IDE (information), and the acquisition frequency was adjusted using a delay function. Figure A2 shows the code used.

```
AnalogInput
int sensorPin = 4; // select the input pin for the potentiometer
int sensorValue = 0; // variable to store the value coming from the sensor

void setup() {
  pinMode(sensorPin, INPUT);
  Serial.begin(115200);
  analogSetWidth(12); //define the ADC to be used
}

int i=0;
void loop() {
  if(i<1000*) {
    // read the value from the sensor:
    sensorValue = analogRead(sensorPin);
    Serial.println(sensorValue);

    if(i>=0){delayMicroseconds(2432);} //f=400
    if(i>=1000){delayMicroseconds(400);} //f=350
    if(i>=2000){delayMicroseconds(400);} //f=300
    if(i>=3000){delayMicroseconds(540);} //f=250
    if(i>=4000){delayMicroseconds(1250);} //f=200
    if(i>=5000){delayMicroseconds(1250);} //f=150
    if(i>=6000){delayMicroseconds(3500);} //f=100
    i++;
  }else{Serial.print("*");Serial.println(sensorValue);}
}
```

Fig. A2.: Programming the microcontroller on the Arduino IDE platform

Figure A2 shows a sequence of conditional (if) structures combined with varying the acquisition frequency during the test.

APPENDIX B

According to the American male pattern, a set of insoles with eight numbers was provided, from 6 to 11.5. The insoles had their surface area measured by discretization using basic geometric shapes (Figure B.1b). The insoles were divided into three regions of interest (Figure B.1a): anterior, middle, and posterior. These regions were divided, considering sensors from one to four (anterior), five and six (middle), and seven (posterior). These divisions coincide with the forefoot, midfoot, and calcaneus regions.

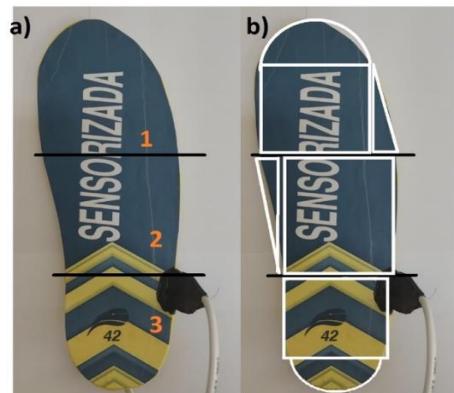


Fig. 5.: a) the division of the insole into three parts: anterior (1), middle (2), and posterior (3). The division was performed at the midpoint between the closest sensors to the boundary; b)

discretization of the insole to estimate the surface area

Table 1 shows the result of the measurement of the surface area of each insole and the ratio between the area of the sensors and the surface area of the region in which they are located, which was called the sensory coverage index of the insole. No variation in the size of the sensors was observed for different foot sizes. Therefore, the area of the sensors remains constant,

decreasing the coverage area as the numbering increases.

ACKNOWLEDGMENT

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001

TABLE I
SUMMARY OF THE REFERENCE INSOLE'S CONSTRUCTIVE PARAMETERS.

Foot Size	Anterior		Middle		Posterior		Total	
	Area (cm ²)	Covering Sensor						
6	64.62	25.32%	64.50	25.36%	34.25	35.82%	163.37	27.54%
6.5	64.71	25.28%	70.78	23.11%	36.13	33.96%	171.62	26.21%
8.5	67.56	24.22%	76.45	21.40%	36.96	33.20%	180.97	24.86%
9	71.53	22.87%	79.36	20.61%	39.17	31.32%	190.06	23.67%
10	77.2	21.19%	80.3	20.37%	40.63	30.20%	198.13	22.71%
10.5	79.05	20.70%	82.34	19.87%	48.65	25.22%	210.04	21.42%
11.5	79.41	20.60%	86.73	18.86%	53.08	23.12%	219.22	20.52%
12	85.55	19.12%	87.10	18.78%	54.32	22.59%	226.97	19.82%

REFERENCES

- [1] Razak, Abdul Hadi Abdul, et al. "Foot plantar pressure measurement system: A review." Sensors 12.7 (2012): 9884-9912.
- [2] Perry, Jacqueline, and Judith M. Burnfield. "Gait analysis. Normal and pathological function 2nd ed." California: Slack (2010).
- [3] Ivanov, Kamen, et al. "Design of a sensor insole for gait analysis." International Conference on Intelligent Robotics and Applications. Springer, Cham, (2019).
- [4] Malvade, P. S., Joshi, A. K., & Madhe, S. P. (2017, August). In-sole Shoe Foot Pressure Monitoring for Gait Analysis. In 2017 International Conference on Computing, Communication, Control and Automation (ICCUBEA) (pp. 1-4). IEEE.
- [5] Martini, E., Fiumalbi, T., Dell'Agnello, F., Ivanić, Z., Munih, M., Vitiello, N., & Crea, S. (2020). Pressure-sensitive insoles for real-time gait-related applications. Sensors, 20(5), 1448.doi:10.3390/s20051448.
- [6] Müller, B., Wolf, S. I., Brüggemann, G. P., Deng, Z., McIntosh, A. S., Miller, F., & Selbie, W. S. (Eds.). (2018). Handbook of human motion. Cham, Switzerland: Springer.
- [7] Novak, D., Reberšek, P., De Rossi, S. M. M., Donati, M., Podobnik, J., Beravs, T., ... & Munih, M. (2013). Automated detection of gait initiation and termination using wearable sensors. Medical engineering & physics, 35(12), 1713-1720. doi:10.1016/j.medengphy.2013. 07.003.
- [8] Sunarya, U., Sun Hariyani, Y., Cho, T., Roh, J., Hyeong, J., Sohn, I., ... & Park, C. (2020). Feature analysis of smart shoe sensors for classification of gait patterns. Sensors, 20(21), 6253.doi:10.3390/s20216253.
- [9] IVANOV, Kamen et al. design of a sensor insole for gait analysis. In: International Conference on Intelligent Robotics and Applications. Springer, Cham, (2019). p. 433-444
- [10] SILVA, Patricia MM et al. Building Pressure-Sensitive Foot Insoles for Public Health Evaluation in Smart Cities. In: 2017 IEEE First Summer School on Smart Cities (S3C). IEEE, 2017. p. 153-156
- [11] Lucken, Markus, et al. "Evaluation and Application of a Customizable Wireless Platform: A Body Sensor Network for Unobtrusive Gait Analysis in Everyday Life." Sensors 20.24 (2020): 7325.
- [12] Subramaniam, Sophini, et al. "Insole-based systems for health monitoring: Current solutions and research challenges." Sensors 22.2 (2022): 438.
- [13] Hsu, Wei-Chun, et al. "The design and application of simplified insole-based prototypes with plantar pressure measurement for fast screening of flat-foot." Sensors 18.11 (2018): 3617.
- [14] HEGDE, Nagaraj; SAZONOV, Edward. Smartstep: A fully integrated, low-power insole monitor. Electronics, v. 3, n. 2, p. 381-397, 2014.
- [15] PhysioCode Company, (2022). website: <https://www.physicode.com.br/>. [accessed in: 15-05-2022]
- [16] TABACHNICK, Barbara G.; FIDELL, Linda S. Experimental designs using ANOVA. Belmont, CA: Thomson/Brooks/Cole, (2007).
- [17] HU, Quan; CAI, Ping. INSOLE-BASED Estimation of Complete Ground Reaction Force with Gaussian Kernel Regression and Data Expansion. Journal of Mechanics in Medicine and Biology, v. 22, n. 01, p. 2250001, (2022).
- [18] ATALLAH, L. et al. Gait asymmetry detection in older adults using a light ear-worn sensor. Physiological measurement, v. 35, n. 5, p. N29, (2014).
- [19] NILSSON, J., & THORSTENSSON, A. (1989). Ground reaction forces at different speeds of human walking and running. Acta Physiologica Scandinavica, 136(2), 217–227. doi:10.1111/j.1748-1716.1989.tb08655.x
- [20] Grivas, T. B., Mihas, C., Arapaki, A., & Vasiliadis, E. (2008). Correlation of foot length with height and weight in school age children. Journal of Forensic and Legal Medicine, 15(2), 89–95. doi:10.1016/j.jflm.2007.05.007
- [21] ADAMS, Janet (Ed.). Observational gait analysis: a visual guide. SLACK Incorporated, (2018).

- [22] CHUCKPAIWONG, Bavornrit et al. The effect of foot type on in-shoe plantar pressure during walking and running. *Gait & posture*, v. 28, n. 3, p. 405-411, (2008).
- [23] Farnell Company, Datasheet website: <https://www.farnell.com/datasheets/1815591.pdf> [accessed in: 15-05-2022]
- [24] King, Andrew. "Clinical Gait Analysis: Theory and Practice, Chris Kirtley, Churchill Livingstone (2006), 328 pages, £ 39.99, ISBN 0-4431-0009-8." (2007): 84.
- [25] Cameron, Neil. "Microcontrollers." *Electronics Projects with the ESP8266 and ESP32*. Apress, Berkeley, CA, (2021). 611-639.

Apêndice D

Artigo Submetido

Low-cost Sensorized Insole with Custom Resistive Force Sensor: design, validity and reliability

George S Sabino, Souza, Pollyana HV Costa, Fernanda Oliveira Madaleno, *Student Member, UFMG*, Claysson BS Vimieiro, Thales R, Diego HA Nascimento, Renan A Resende*, *Senior Member, UFMG*

Abstract— Goal: To develop a low-cost and durable sensorized insole and assess its concurrent validity and test-retest reliability. **Methods:** This is a methodological study of development and assessment of measurement properties, structured in two phases. In the first phase, we developed and assessed the durability of a sensorized insole; its development, materials, and costs were detailed. The second phase comprised the assessment of measurement properties. For validity analysis, we assessed the correlation between vertical ground reaction force (vGRF) of the sensorized insole and data obtained using a split-belt instrumented treadmill with two force plates (FP treadmill). Measures were repeated after one week to assess the test-retest reliability. **Results:** We observed wearing and manufacturing problems and presented solutions to the obstacles faced by researchers. The mean cost of the sensorized insole was \$6.27 per foot. The Pearson's correlation coefficient between vGRF and FP treadmill was 0.83 (95% confidence interval [95%CI] 0.79 to 0.87), while the multiple correlation coefficient was 0.88 (95%CI 0.85 to 0.90). Despite a good validity, the curves of the sensorized insole and FP treadmill were distant during the mid-stance phase of gait. Intraclass correlation coefficient for the reliability of the sensorized insole was 0.87 (95%CI 0.84 to 0.90). **Conclusion:** The sensorized insole presented excellent concurrent validity and test-retest reliability. However, data obtained during the mid-stance phase of gait must be interpreted with caution. **Significance:** The proposed method can contribute to the production of durable and low-cost sensorized insoles.

Index Terms— Kinetics, Gait Analysis, Methods.

I. INTRODUCTION

SENSORIZED insoles are tools inserted into shoes to analyze plantar pressure during walking [1]. Plantar pressure is frequently used to prescribe biomechanical insoles or indicate surgery [2]. In addition, from the plantar pressure data, it is possible to estimate the vertical component of the ground reaction force (vGRF). The vGRF acts under the foot and may infer the overload of different lower limb joints during closed kinetic chain exercises [3]. Spatio-temporal parameters of a given task (e.g., gait) are also analyzed using data recorded by sensorized insoles, such as stance and swing time and displacement of the center of pressure during a stride [4][5].

Portability is another advantage of sensorized insoles compared with other instruments that measure vGRF applied

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001. We are also thankful to the State of Minas Gerais Funding Agency FAPEMIG [grant number APQ-01017-17] and to the Brazilian Funding Agency CNPQ [grant number 428735/2018-5].

during movement, mainly because it allows the analysis of performance of a given task in the usual environment of the individual [6]. Besides, the longitudinal monitoring of spatio-temporal phenomena (e.g., gait) is possible using the internet of things, which enables data acquisition for an extended time [7]. However, the high acquisition cost and low durability still restrict its use in clinical settings [8][9][10]. Thus, the development and analysis of wearing device with a low-cost sensorized insole may contribute to increasing the technology accessibility and use it in clinical settings, improving the quality of movement assessment in individuals with different health conditions, and allowing the grouping of these data for scientific purposes [1][11].

Several types of sensorized insoles with different properties can be found on the market; piezoelectric and piezoresistive sensors are the most common [6][12]. Piezoelectric sensors record pressure variation, which affects the force reception in static situations. On the other hand, resistive sensors use conductive polymeric membranes that change the conductivity when pressed[13]. Sensorized insoles available on the market may also have 5 to 960 pressure sensors and a sampling frequency between 25 and 100 Hz [6]. In this sense, new sensorized insoles should present similar or superior characteristics. Therefore, this study aimed to develop a low-cost and highly-durable sensorized insole and assess its concurrent validity and test-retest reliability.

II. METHODS

This is a methodological study for the development and assessment of measurement properties [14][15]. We recruited individuals aged between 18 and 45 years; with body mass index between 20 and 34.9 kg/m²; without foot deformities (e.g., amputations or malformation), pain, or neurological disorders; and with shoe numbers between 6 and 11 U.S. standard men's shoe sizes. Exclusion criteria were physical exercise on the day of data acquisition and difficulty performing the study procedures; no individuals were excluded.

This study was approved by the research ethics committee (CAAE 00890818.8.000.5149) and conducted according to the Declaration of Helsinki. Data were collected between August and December 2021 at the Motion Analysis Laboratory of the

The authors' current affiliations are from the department of Rehabilitation Sciences and Bioengineering at the Federal University of Minas Gerais (UFMG), MG, Brazil (correspondence e-mail: renan.aresende@gmail.com).

School of Physical Education, Physical Therapy, and Occupational Therapy of the Federal University of Minas Gerais. All individuals signed the informed consent form

A. First phase: development of sensorized insoles

We used a polyimide sheet coated with copper to develop the sensorized insole, in which an electronic circuit was printed. Twelve pressure sensors using a conductive polymer were incorporated in seven regions of the foot (calcaneus, medial midfoot, lateral midfoot, medial forefoot, central forefoot, lateral forefoot, and hallux) [16][17]. These regions were chosen according to foot anatomy and study objectives [18], while the number of sensors was selected based on previous studies to minimize costs, potentiate the acquisition frequency, and obtain relevant information for estimating forces on foot during gait [1][6][12]. At the end of its development, each sensorized insole weighed an average of 25 g and was 2 mm thick; the mean acquisition frequency for bilateral data acquisition was 230 Hz. fig.1 shows the sensorized insole initially developed in the study.

1) Voltage variation

A micro-controlled circuit was developed using an ESP-32 microcontroller (Expressif®) to read the voltage variation during activation of each sensor. Signals were synchronized and sent to a computer to be read and recorded using software developed in C#.

2) Static calibration of the sensorized insole

Sensors were calibrated by applying and recording known static loads (2, 4, 6, 8, and 10 kg) on a structure assembled on a precision balance (Scale SF-400, max load 10 kg/1 g – Global Mix) (fig.1). A linear regression calculated associations between the recorded voltage and applied load, and the coefficients obtained were used to analyze signals [16].

3) Durability analysis

We used three different shoe numbers (7, 9.5 and 11) for the durability test, in which three individuals (weights of 64, 98, and 102 kg, respectively) performed nine walks of 30 minutes, totaling 4.5 hours of test. The test duration was arbitrarily determined to allow recurrent data acquisition using the same sensorized insole without extending study procedures. The complete functioning of the sensorized insole was verified after each 30-minute walk. If the sensorized insole did not reach the minimum time established for testing, its design was reviewed, and tests were restarted. This procedure was repeated three times until developing a final sensorized insole that reached the proposed goal. All problems observed during the development of the initial version were considered.

B. Second phase: assessment of measurement properties of sensorized insoles

1) Instruments

Kinetic data were measured simultaneously using the sensorized insole and a split-belt instrumented treadmill with two force plates (FP treadmill) (Bertec at 1000Hz, Bertec Corp, Columbus, OH).



Fig.1. First version and calibration of the sensorized insole.

2) Data acquisition

Each set of sensors positioned under the foot sole of sensorized insoles recorded seven temporal series; the total vGRFS was obtained at each time by summing these signals. Raw data from the sensorized insole and FP treadmill were filtered using a finite response filter (moving average of six periods) and normalized to the maximum value. The frequency of data processing was reduced to 100 Hz. Each step was identified using an algorithm that detected the stance and swing phases; the latter was considered when the sum of sensor signals was equal to zero. We calculated the mean and SD of ten steps extracted from the middle period of data acquisition. The mean vGRF of each measured point was used to analyze the measurement properties of the sensorized insole.

3) Statistical analysis

We performed a descriptive analysis and used the Kolmogorov-Smirnov test to verify data normality (data were normally distributed [$p > 0.05$]). Pearson's correlation coefficient [19][20] and multiple correlation coefficient [21] assessed the concurrent validity of the sensorized insole and FP treadmill by comparing 101 data points obtained from each individual. The intraclass correlation coefficient (ICC) assessed [22][23] the test-retest reliability of the sensorized insole and FP treadmill collected within a one-week interval. Measurements were considered appropriate when values > 0.7 [15] and were classified as substantial (values ≤ 0.8) or excellent (values > 0.8) [22][24].

III. RESULTS

A. First phase: development of sensorized insoles

Any pressure applied to the circuit was promptly recorded during the development of the sensorized insole and application of the conductive polymer. Despite the potential advantage of sensitivity, exacerbated recordings were problematic for movement measurement because the mechanism automatically triggered and constantly recorded the signal when the shoe was put on. To solve this problem, we inserted a non-conductive material (vinyl) that spaced the polymeric film from the copper structure and allowed contact without interference when pressed (fig.2). Consequently, the vinyl provided inertia for activating sensors, which occurred only when 2 kgf (19.61 N) were applied.

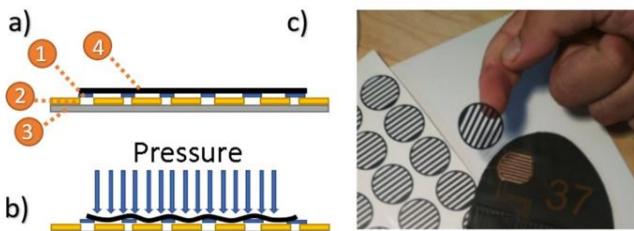


Fig.2. Vinyl Spacer. a) Cross-sectional view of the sensorized insole circuit and vinyl spacer; 1) vinyl spacer; 2) copper circuit; 3) polyamide base; 4) conductive polymer; b) Circuit under pressure; c) Fixing process with the vinyl spacer.

The initial prototypes also needed structural adjustments. The sheet with the flexible circuit was easily deformed while inserted into the shoe. As this could damage the sensorized insole and affect data acquisition, we initially wrapped the sensorized insole using Polaseal to increase rigidity. However, this reduced the durability of the insole since rigidity contributed to breaking the circuit structure after few steps. Breaks were observed in places of greater foot mobility during walking, such as the medial region near the first metatarsophalangeal joint (fig.3).

To correct this problem, we removed the lamina and fixed the sensorized insole to a 2 mm EVA sheet with shore hardness of 30 on the sole. This strategy provided an intermediate rigidity compared with previous versions and allowed an easier insertion into the shoe without breaking during movement, similar to standard shoe insoles.

Table 1 – Components and costs.

Component	Cost (US\$)*
Copper	3.75
Conductive polymer	1.76
2 mm EVA board	0.13
Non-conductive material (vinyl)	0.56
RJ45 connector and cables	0.07
TOTAL	6.27

* 1 US\$ is equivalent to R\$5.33 reais.

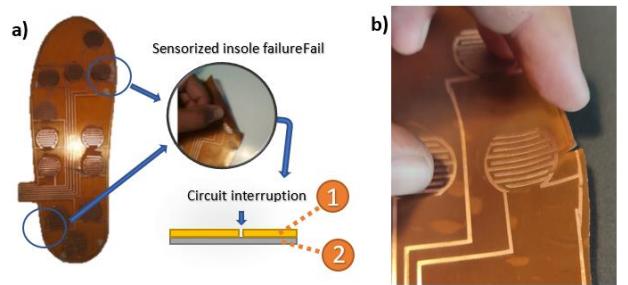


Fig.3. Circuit break. a) Schematic representation: 1) Sheet coated in copper; 2) Polyamide base of the sensorized insole. b) Rupture of the circuit near the region under the first metatarsophalangeal joint.

The initial design of the circuit was also restructured by inserting a redundancy for the circuit supply to ensure the durability of the sensorized insole (fig.4). Therefore, if the insole breaks at one point, it will still work until a second break occurs.

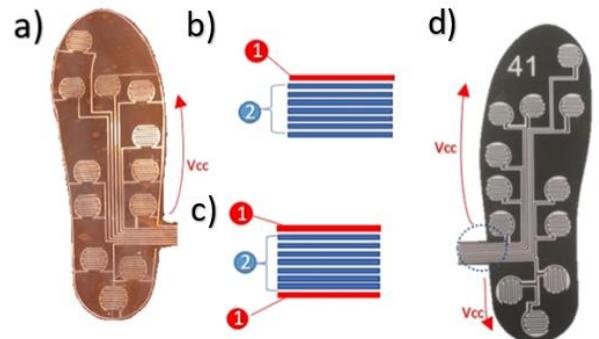


Fig.4. Redundancy for circuit power. a) First version of the sensorized insole (V1). b) Power of V1: 1) Integrated circuit power supply (Voltage at the common collector [VCC+]); 2) Sensor tracks. c) Power of the second version of the sensorized insole (V2) with a redundant circuit power supply (1,2,1). d) V2 with a redundant circuit power supply (arrows) and two channels with source, one in the upper part of the image and another in the posterior region.

Last, we observed that foot's sweat oxidized the circuit during the first pilot test and affected measurements. Thus, we added a surface layer of adhesive vinyl to ensure waterproof (fig.5). The total cost of materials summed \$6.27, as detailed in Table 1.



Fig.5. Final version of the sensorized insole. a) Final version of the sensorized insole. b) Detailed thickness with the EVA and vinyl surface layers.

B. Second phase: assessment of measurement properties

The mean Pearson's correlation coefficient between sensorized insole and FP treadmill measures indicated a strong, positive, and statistically significant association (0.83 [95%CI 0.79 to 0.87]). The mean multiple correlation coefficient was 0.88 (95%CI 0.85 to 0.90). Despite the good validity, the middle part of the curves of the sensorized insole and FP treadmill was distant and the SD of data from the sensorized insole was high at these points (fig. 6).

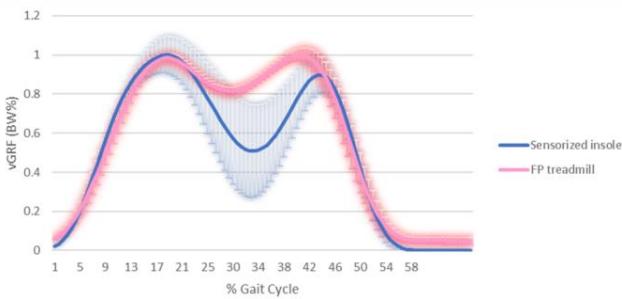


Fig.6. Vertical ground reaction force on the FP treadmill and sensorized insole. Legend: FP treadmill: split-belt instrumented treadmill with two force platforms; BW: body weight; vGRF: Vertical ground reaction force.

Regarding test-retest reliability, the mean time interval between the first and second data acquisition was 11.7 days ($SD = 4.56$). ICC values (95%CI) for vGRF of the sensorized insole and FP treadmill were 0.87 (95%CI 0.84 to 0.90) and 0.97 (95%CI 0.95 to 0.99), respectively, indicating excellent test-retest reliability.

IV. DISCUSSION

This study aimed to develop a sensorized insole and assess its concurrent validity and test-retest reliability for collecting vGRF during the stance phase of gait. The sensorized insole showed excellent concurrent validity and test-retest reliability. However, data recorded during the mid-stance phase of gait must be interpreted with caution.

The initial versions of the sensorized insole presented sensitivity, rigidity, and permeability problems, which were partially corrected during the development phase. The distinction between stance and swing phases was improved using a spacer applied to increase the threshold of signal recordings. However, this configuration may have impacted on pressure recordings during the mid-stance phase of gait, in which vGRF is generally reduced, and contributed to deviating the vGRF curve of the sensorized insole. We believe this systematic error may be mitigated in future studies using a computational optimization algorithm ([25]. Furthermore, the development phase revealed points of weakness and breakage in the circuit of the sensorized insole caused by metacarpophalangeal extension during the stance phase of gait [26][27]. The redundancy of circuits and waterproof strategies were efficient and increased the durability of the sensorized insole. Thus, these adjustments are recommended when developing new models of sensorized insoles [28].

Data on temporal series of vGRF of the sensorized insole showed an excellent concurrent validity and test-retest reliability compared with the FP treadmill, similar to previous

studies with others sensorized insoles [29][30][31]. Regarding the reliability of sensorized insoles, values were similar to or higher than observed in previous studies [2][31] but slightly lower than results of vGRF of the FP treadmill. However, considering that sensorized insoles have a lower cost and greater portability than the FP treadmill, the validity and reliability values suggested that the former may be recommended for assessing vGRF during gait in future studies and clinical settings, especially at the beginning and end of the stance phase.

The final version of the sensorized insole was built at an initial cost of \$6.27 per foot. Considering the minimum durability (4.5 hours) and time for clinical assessment (i.e., one minute for familiarization and one minute for data acquisition), at least 135 assessments could be performed with each sensorized insole at an estimated cost of \$0.09 per patient. Although several sensorized insoles are available on the market, the costs and durability may limit the dissemination of the product [6][9][10]. Therefore, after adaptations, the proposed sensorized insole presented low cost, long durability, and appropriate measures for future use.

The present study is not free of limitations. Individuals presented different foot postures but not deformities; thus, the extrapolation of results to individuals with foot deformities must be conducted with caution, and further studies are needed to verify the measurement properties of sensorized insoles in this population [3]. Although previous studies have also used sensorized insoles with the same or smaller number of sensors [6][9], the reduced number of sensors used in our study can be considered a limitation. We used few sensors to reduce costs and improve the acquisition frequency during data acquisition. Fuchs et al. (2022) found similar results by analyzing different arrangements and sensors to identify the configuration that best optimized the validity of sensorized insoles [17].

We believe the developed sensorized insole may be used in different clinical contexts. For example, it may help treatment adherence and weight-bearing training of patients during postoperative rehabilitation by providing immediate feedback to the patient and health care team [12][32]. Its portability also facilitates the evaluation, reevaluation, and follow-up through telerehabilitation. Furthermore, durable and accessible sensorized insoles may benefit researchers by favoring the acquisition of kinetic data from different patients (e.g., those who often cannot go to movement analysis laboratories) and contexts. Therefore, this would help understand the relationships between kinetic variables, health conditions, and individual characteristics of functionality [33].

V. CONCLUSION

We developed and verified the concurrent validity and test-retest reliability of a low-cost sensorized insole to assess vGRF during the stance phase of gait. The sensorized insole showed excellent concurrent validity and test-retest reliability and can be used in clinical settings and future studies. However, data provided during the mid-stance phase of gait must be interpreted with caution.

VI. REFERENCES

- [1] S. S. Zulkifli & W. P. A. Loh, "A state-of-the-art review of foot pressure", *Foot Ankle Surgery*, vol. 26, no. 1, pp. 25-32, 2020.
- [2] L. B. Oliveira et al, "Reliability of wireless insole baropodometry of normal individual's gait," *Acta Ortopédica Brasileira*, vol. 29, no. 5, pp. 238-241, 2021.
- [3] C. Giacomozi et al, "Integration of Foot Pressure and Foot Kinematics Measurements for Medical Applications. In: Müller B, et al. (eds) *Handbook of Human Motion*. Springer, Cham. 2016 https://doi.org/10.1007/978-3-319-30808-1_186-1
- [4] J. Tabori et al, "Gait Partitioning Methods: A Systematic Review". *Sensors (Basel)*, vol. 16, no. 1, pp. 66, 2016.
- [5] E. A. Fuller, "Center of pressure and its theoretical relationship to foot pathology," *Journal of the American Podiatric Medical Association*, vol. 89, no. 6, pp.: 278-291, 1999.
- [6] J. A. Ramirez-Bautista et al, "A Review in Detection and Monitoring Gait Disorders Using In-Shoe Plantar Measurement Systems," *IEEE Transactions on Biomedical Engineering*, vol. 10, pp. 299-309, 2017.
- [7] P. Bonato, "Advances in wearable technology and physical medicine and rehabilitation applications," *Journal of Neuroengineering and Rehabilitation*, vol. 2, no. 1, pp. 2, 2005.
- [8] E. Shahabpoor & A. Pavic, "Measurement of Walking Ground Reactions in Real-Life Environments: A Systematic Review' of Techniques and Technologies," *Sensors (Basel)*, vol. 17, no. 9, pp. 20852017, 2017.
- [9] Y. Tan et al, "A Soft Wearable and Fully-Textile Piezoresistive Sensor for Plantar Pressure Capturing. *Micromachines*". *Sensor (Basel)*, vol. 12, no. 2 pp. 0, 2021.
- [10] A. M. Tahir , "A Systematic Approach to the Design and Characterization of A Smart Insole for Detecting Vertical Ground Reaction Force (vGRF) in Gait Analysis". *Sensors (Basel)*, vol. 20, no. 4, pp. 957, 2020.
- [11] Y. Kuroda Y et al, "Advanced rehabilitation technology in an orthopaedics-a narrative review", *International Orthopedics*, vol. 45, no. 8, pp. 1933-1940, 2021.
- [12] A. H. Razak et al, "Foot plantar pressure measurement system: a review," *Sensors (Basel)*, vol. 12, no. 7, pp. 9884-912, 2012.
- [13] K. Ivanov K et al., "Design of a sensor insole for gait analysis, in International Conference on Intelligent Robotics and Applications," *Lecture Notes in Computer Science*, vol 11743, pp. 433–444, 2019.
- [14] A. E. Davis, "Instrument development: getting started," *Journal of Neuroscience Nursing*, vol. 28, pp. 204-207, 1996.
- [15] L. G. Portney & M. P. Watkins, *Foundations of clinical research: application to practice*. New Jersey: Prentice-Hall. 2000
- [16] A.M. Howell et al, "Kinetic Gait Analysis Using a Low-Cost Insole," *IEEE Trans Biomed Eng*, vol. 60, no. 12, pp; 3284-3290, 2013.
- [17] P. X. Fuchs et al, " Sensor number in simplified insole layouts and the validity of ground reaction forces during locomotion," *Sports Biomech*, vol. 2, pp. 1-14, 2022.
- [18] W. Lee, S. H. Hong, & H. W. Oh, "Characterization of Elastic Polymer-Based Smart Insole and a Simple Foot Plantar Pressure Visualization Method Using 16 Electrodes," *Sensors Journal*, vol. 19, no. 1, pp. 44, 2018.
- [19] S. Crea et al, "A wireless flexible sensorized insole for gait analysis". *Sensors (Basel)*, vol. 14, no. 1, pp; 1073-1093, 2014.
- [20] P.S Dyer PS, S. J. Bamberg, "Instrumented insole vs force plate: a comparison of the centre of plantar pressure". *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 6805-6809, 2011.
- [21] A. Ferrari et al, "A new formulation of the coefficient of multiple correlations to assess the similarity of waveforms measured synchronously by different motion analysis protocols," *Gait & Posture*, vol. 31, no. 4, pp. 540-542, 2010.
- [22] J. Kottner,et al., "Guidelines for Reporting Reliability and Agreement Studies (GRRAS) were proposed," *Int J Nurs Stud*, vol. 48, no. 6, pp. 661-71, 2011.
- [23] G. S. Sabino et al , "Validity and reliability of a smartphone application for knee posture quantification and the effects of external markers on the precision of this measure," *Journal of Bodywork Movement Therapies*, vol. 28, pp. 42-48, 2021.
- [24] M. M. Mukaka, "Statistics corner: A guide to appropriate use of correlation coefficient in medical research", *Malawi Med J.*, vol. 24, no. 3, pp. 69-71, 2012.
- [25] J. DeBerardinis et al., "Enhancing the Accuracy of Vertical Ground Reaction Force Measurement During Walking Using Pressure-Measuring Insoles.", *J Biomech Eng.*, vol. 143, no. 1, pp. 011010, 2021.
- [26] V. J. Hetherington et al., "Motion of the first metatarsophalangeal joint," *J Foot Surg*, vol. 28, no. 1, pp. 13-9, 1989
- [27] S. J. Otter et al, "The reliability of a smartphone goniometer application compared with a traditional goniometer for measuring first metatarsophalangeal joint dorsiflexion," *J Foot Ankle Res*, vol. 23, no. 8, pp. 30, 2015 .
- [28] D. Sahu et al, *The Internet of Things in Geriatric Healthcare. Journal of Healthcare Engineering*, pp.: 6611366, 2021.
- [29] G .T. Burns et al., "Validation of a wireless shoe insole for ground reaction force measurement," *Journal of Sports Sciences*, vol. 37, no. 10, pp. 1129-1138, 2019.
- [30] A. M. Tan et al, "Development of a smart insole for medical and sports purposes". *Procedia Engineering*, vol. 112, pp. 152-156, 2015.
- [31] L. A. Cramer et al., "Validity and Reliability of the Insole3 Instrumented Shoe Insole for Ground Reaction Force Measurement during Walking and Running," *Sensors (Basel)*, vol. 22, no. 6, pp. 2203, 2022.
- [32] K. North K et al, "An insole sensor recording weight-bearing behaviour during tibial fracture rehabilitation", *Annu Int Conf IEEE Eng Med Biol Soc.*, vol. 2010, pp. 1856-9, 2010.
- [33] J. Vergheze e al, "Abnormality of gait as a predictor of non-Alzheimer's dementia". *N Engl J Med*, vol. 347, no. 22, pp. 1761-8, 2002.

Apêndice E

Termo de Consentimento Livre e Esclarecido e Direito de Imagem

Termo de Consentimento Livre e Esclarecido

Prezado voluntário, você está sendo convidado(a) a participar, como voluntário(a), da pesquisa **VALIDADE E CONFIABILIDADE DE UM INSTRUMENTO PARA AVALIAÇÃO CLÍNICA DO MOVIMENTO HUMANO** sob a responsabilidade do Prof. Dr. Renan Alves Resende do Departamento de Fisioterapia da Universidade Federal de Minas Gerais (UFMG).

OBJETIVO

O objetivo dessa pesquisa é avaliar a qualidade de um instrumento de medida clínico para a Fisioterapia, verificando sua validade e confiabilidade.

PROCEDIMENTOS DO ESTUDO

Inicialmente serão coletados os seus dados demográficos (dados pessoais, idade, peso e altura) e você responderá a um questionário sobre seu possível histórico de lesões e/ou cirurgias nos membros inferiores. Após esta entrevista, você será submetido (a) a uma análise do seu andar e da sua corrida. Essa análise será feita utilizando marcas de isopor revestidas por fita reflexiva em pontos específicos do seu corpo (instrumento não invasivo e indolor). Para essa análise você será solicitado a andar e a correr em uma esteira ergométrica por aproximadamente 3 minutos, descansar por cinco minutos, e então andar e correr novamente por mais 3 minutos. Esse mesmo procedimento será repetido em uma nova visita, a qual deverá acontecer após aproximadamente 7 dias. Todos as coletas serão realizadas no Laboratório de Análise do Movimento da UFMG

RISCOS E DESCONFORTOS

A análise da forma como você anda e corre apresenta um risco mínimo de quedas e será feita em condições de extrema segurança e por pessoas altamente treinadas. Você poderá cansar durante a análise, o que apresentará melhora rápida ao término da coleta.

BENEFÍCIOS

Os resultados da avaliação poderão ser disponibilizados para você, o que poderá ajudá-lo na prevenção de lesões e/ou melhora do desempenho. Esperamos também que este estudo traga informações importantes sobre a avaliação biomecânica na

clínica de Fisioterapia, o que no futuro poderá ajudar diversos pacientes e profissionais.

CUSTO/REEMBOLSO

Não haverá nenhum gasto por sua participação nessa pesquisa, além dos relacionados com seu deslocamento, bem como, não haverá nenhum pagamento pela sua participação. A coleta dos dados será realizada no Laboratório de Análise do Movimento da UFMG

CONFIDENCIALIDADE DA PESQUISA

Você será identificado(a) por um número e portanto, os dados serão apenas mencionados por essa numeração. O pesquisador responsável pelo estudo garante total sigilo e privacidade dos dados confidenciais envolvidos na pesquisa.

NATUREZA VOLUNTÁRIA DO ESTUDO/LIBERDADE PARA SE RETIRAR

A sua participação não é obrigatória e você poderá desistir a qualquer momento de participar e poderá, assim, retirar seu consentimento sem qualquer repreensão ou ônus. A recusa em participar dessa pesquisa não trará nenhum prejuízo.

USO DOS RESULTADOS DA PESQUISA

Os dados obtidos no estudo serão utilizados para fins de pesquisa, podendo ser apresentados em congressos e seminários e publicados em artigos científicos, porém sua identidade será mantida em sigilo absoluto.

ARMAZENAMENTO DOS RESULTADOS

Após a finalização do estudo os dados coletados, incluindo as filmagens realizadas, e o termo de consentimento ou assentimento livre e esclarecido assinados serão armazenados na sala do pesquisador Prof. Dr. Renan Alves Resende, no Departamento de Fisioterapia da UFMG, pelo período de cinco anos, sendo o mesmo responsável por sua guarda.

DECLARAÇÃO E ASSINATURA

Eu, _____, li e entendi toda a informação repassada sobre o estudo, sendo os objetivos e procedimentos satisfatoriamente explicados. Tive tempo suficiente para considerar a informação acima e tive a oportunidade de tirar todas as minhas dúvidas. Estou assinando este termo em duas vias, voluntariamente, sendo uma a mim disponibilizada e tenho direito, de agora ou mais tarde, discutir qualquer dúvida que

eu venha a ter com relação à pesquisa com o Prof. Dr. Renan Alves, (0XX31) 3409 7412, email: renan.aresende@gmail.com ou com George Schayer Sabino no email: george@propulsao.com.

Assinando este termo de consentimento, eu estou indicando que concordo com a minha participação nesse estudo.

Voluntário

Data

Assinatura do Pesquisador Responsável

Data

TERMO DE AUTORIZAÇÃO DE USO DE IMAGEM

Eu _____ depois de conhecer e entender os objetivos, procedimentos metodológicos, riscos e benefícios da pesquisa, bem como de estar ciente da necessidade do uso de imagem, especificado no Termo de Consentimento Livre e Esclarecido (TCLE), AUTORIZO, através do presente termo, os pesquisadores Renan Alves Resende e George Schayer Sabino do projeto de pesquisa intitulado **“VALIDADE E CONFIABILIDADE DE UM INSTRUMENTO PARA AVALIAÇÃO CLÍNICA DO MOVIMENTO HUMANO”** a realizar os vídeos que se façam necessários sem quaisquer ônus financeiros a nenhuma das partes. Ao mesmo tempo, libero a utilização destes vídeos para fins científicos e de estudos (livros, artigos, slides e transparências), em favor dos pesquisadores da pesquisa, acima especificados.

Assinatura do Voluntário

Data

Assinatura do Pesquisador Responsável

Data

Em caso de dúvidas sobre o caráter ético da pesquisa, o(a) Sr.(a) poderá consultar:
COEP-UFMG - Comitê de Ética em Pesquisa da UFMG
Av. presidente Antônio Carlos, 6627. Unidade Administrativa II – 2º andar – Sala 2005. Campus Pampulha. Belo Horizonte, MG – Brasil. CEP: 31270-901.
E-mail: coep@prpq.ufmg.br. Tel: 34094592.