

Leandro Vinhas de Paula

**UTILIZAÇÃO DE SENSORES INERCIAIS DE BAIXO CUSTO PARA AVALIAÇÕES  
BIOMECÂNICAS, RECONHECIMENTO DE AÇÕES E MONITORAMENTO NOS  
ESPORTES COLETIVOS**

Belo Horizonte

Escola de Educação Física, Fisioterapia e Terapia Ocupacional da UFMG

2022

Leandro Vinhas de Paula

**UTILIZAÇÃO DE SENSORES INERCIAIS DE BAIXO CUSTO PARA AVALIAÇÕES BIOMECÂNICAS, RECONHECIMENTO DE AÇÕES E MONITORAMENTO NOS ESPORTES COLETIVOS**

Tese apresentada ao Programa de Pós-graduação em Ciências do Esporte, da Escola de Educação Física, Fisioterapia e Terapia Ocupacional, da Universidade Federal de Minas Gerais, como requisito à obtenção do título de Doutor em Ciências do Esporte.

Orientador: Prof. Dr. André Gustavo Pereira de Andrade.

Coorientador: Prof. Dr. Marcelo Azevedo Costa

Linha de pesquisa: Análise de métodos para o desempenho humano e esportivo.

Belo Horizonte

Escola de Educação Física, Fisioterapia e Terapia Ocupacional da UFMG

2022

P324u Paula, Leandro Vinhas de  
2022 Utilização de sensores inerciais de baixo custo para avaliações biomecânicas, reconhecimento de ações e monitoramento nos esportes coletivos. [manuscrito] / Leandro Vinhas de Paula – 2022.  
206 f.: il.

Orientador: André Gustavo Pereira Andrade  
Coorientador: Marcelo Azevedo Costa

Tese (doutorado) – Universidade Federal de Minas Gerais, Escola de Educação Física, Fisioterapia e Terapia Ocupacional.

Bibliografia: f. 129-141

1. Esportes – Teses. 2. Biomecânica – Teses. 3. Reprodutibilidade dos testes – Teses. I. Andrade, André Gustavo Pereira. II. Costa, Marcelo Azevedo. III. Universidade Federal de Minas Gerais. Escola de Educação Física, Fisioterapia e Terapia Ocupacional. IV. Título.

CDU: 796.015

Ficha catalográfica elaborada pela bibliotecária Sheila Margareth Teixeira Adão, CRB 6: nº 2106, da Biblioteca da Escola de Educação Física, Fisioterapia e Terapia Ocupacional da UFMG.



UNIVERSIDADE FEDERAL DE MINAS GERAIS  
ESCOLA DE EDUCAÇÃO FÍSICA, FISIOTERAPIA E TERAPIA OCUPACIONAL  
PROGRAMA DE PÓS GRADUAÇÃO EM CIÊNCIAS DO ESPORTE

#### ATA DA TESE DE DOUTORADO

LEANDRO VINHAS DE PAULA

Às **14:00 horas** do dia **23 de novembro de 2022**, reuniu-se no Mini-auditório - EEFFTO - UFMG a Comissão Examinadora da Tese, indicada pelo Colegiado do Programa para julgar, em exame final, o trabalho intitulado **“UTILIZAÇÃO DE SENSORES INERCIAIS DE BAIXO CUSTO PARA AVALIAÇÕES BIOMECÂNICAS, RECONHECIMENTO DE AÇÕES E MONITORAMENTO NOS ESPORTES COLETIVOS”**. Abrindo a sessão, o Presidente da Comissão, Prof. Dr. André Gustavo Pereira de Andrade (UFMG), orientador, após dar a conhecer aos presentes o teor das Normas Regulamentares do Trabalho Final, passou a palavra para o candidato, para apresentação de seu trabalho. Seguiu-se a arguição pelos examinadores, com a respectiva defesa do candidato. Logo após, a Comissão se reuniu, sem a presença do candidato e do público, para julgamento e expedição do resultado.

#### MEMBROS DA BANCA EXAMINADORA:

PROF. DR. Andre Gustavo Pereira de Andrade (ORIENTADOR) - EEFFTO/UFMG

PROF. DR. Marcelo Azevedo Costa (MEMBRO TITULAR) – EEFFTO/UFMG

PROF. DR. Felipe Pivetta Carpes (MEMBRO TITULAR) – UNIPAMPA

PROF. DR. Felipe Arruda Moura (MEMBRO TITULAR) – UEL

PROF. DR. Renato Melo Ferreira (MEMBRO TITULAR) – UFOP

PROF. DR. Eduardo Mendonça Pimenta (MEMBRO TITULAR) – EEFFTO/UFMG

Após as indicações o candidato foi considerado: **APROVADO**

O resultado foi comunicado publicamente para o candidato pelo Presidente da Comissão. Nada mais havendo a tratar o Presidente encerrou a reunião e lavrou a presente ATA, que será assinada por todos os membros participantes da Comissão Examinadora.

Belo Horizonte, 23 de Novembro de 2022.



Documento assinado eletronicamente por **Felipe Pivetta Carpes, Usuário Externo**, em 26/11/2022, às 11:15, 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 **Andre Gustavo Pereira de Andrade, Coordenador(a) de curso de pós-graduação**, em 26/11/2022, às 11:24, 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 **Eduardo Mendonca Pimenta, Pró-reitor(a) adjunto(a)**, em 26/11/2022, às 11:42, 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 **Felipe Arruda Moura, Usuário Externo**, em 28/11/2022, às 11:02, 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 **Gustavo Pereira Cortes, Diretor(a) de unidade**, em 28/11/2022, às 11:02, 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 **Renato Melo Ferreira, Usuário Externo**, em 28/11/2022, às 14:57, 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](https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **1922181** e o código CRC **F3DB8034**.

Dedico este esforço a todos que arduamente trabalham e produzem para sustentar, não somente o ensino superior público, mas o Brasil, e que, por vezes, não veem retorno ou não se sentem respeitados. Pois, parafraseando o economista Thomas Sowell, “[...] *Um dos tristes sinais de nossa época, é que demonizamos aqueles que produzem, subsidiamos os que se recusam a produzir e canonizamos os que reclamam*”.

## AGRADECIMENTOS

Á Deus por me conceder a graça de concluir essa etapa de minha formação, com saúde e discernimento durante este período.

Agradeço a minha esposa Bruna por todo o apoio, carinho, risadas, compreensão e amor devotado durante todo este período. Agradeço ao meu filho João Vicente, nosso presente de Deus, a alegria de nossa casa, a motivação para melhorarmos e trabalharmos para que você possa um dia sentir orgulho de seus pais. Agradeço ao meu pai Antônio, minha mãe Lêda e meu irmão Alexandre: vocês me ensinaram e ensinam que para quem tem consciência do seu valor, nada resiste a obstinação silenciosa no cumprimento da jornada. Agradeço ainda ao meu amado sobrinho Antônio Augusto e minha cunhada Érica.

Agradeço a minha guerreira avó materna Maria Benvinda Soares Vinhas (*in memoriam*) devota de nossa senhora Aparecida, que infelizmente não tive a oportunidade de conhecê-la e ao meu amado avô materno Juscelino Alves Vinhas (*in memoriam*). Agradeço a minha sábia e forte avó paterna Aurora Maria Ribeiro de Paula Pereira (*in memoriam*) a qual não tive a oportunidade de me despedir e ao meu inteligente e firme avô paterno, João Batista Pereira III (*in memoriam*), prontamente respondeu a convocação para a Escola de Sargentos das Armas e 11° Batalhão de Infantaria de Montanha “Regimento Tiradentes” durante a segunda guerra mundial, deu sua contribuição, quando convidado a permanecer, declinou, voltou e trabalhou de sol a sol. Não obstante, agradeço a Dona Ana (*in memoriam*) e o Senhor Sebastião (*in memoriam*), pessoas que me viram nascer, crescer, muitas vezes cuidaram de mim e de meu irmão, participes de nossa educação em diversos momentos. “Avós” que sempre nos incentivavam a estudar e sempre fazer o melhor possível, citando os exemplos de superação de seu filho Nildo Alves Batista, médico e professor universitário.

Aos amigos do Colégio Tiradentes de Passos - MG. Aos amigos Eduardo, Pedro, Jaciele, Clodoaldo, Rafael, Leandro, Simone, Gustavo, Warley e Renato meus sinceros agradecimentos pelo apoio. Aos treinadores Benedito Cesar Ribeiro (Prefeitura Municipal de Passos - MG) e Leandro Rezende (SESI – Uberlândia – MG) que tive a oportunidade de ter no handebol, modalidade que ajudou a formar meu caráter: muito obrigado.

Agradeço a todos os professores que tive ao longo do percurso educacional. Em especial agradeço aos exemplares professores Nilson Penha Silva (Bioquímica, INGEB - UFU), Silvio Soares dos Santos (professor que aceitou ser meu orientador para uma bolsa de iniciação científica – FAEFI – UFU) e Cleudmar Amaral de Araújo (professor que abriu as portas do Laboratório de Projetos Mecânicos – FEMEC – UFU, orientando a execução do trabalho de iniciação).

Agradeço ao Prof. André pela oportunidade, apoio e orientação: quando o conheci, disse que queria ajudar os alunos, deixar algo para o laboratório e fazer um trabalho decente. Acredito que durante esse período, humildemente, perante todas as adversidades, sem as condições adequadas e com recursos próprios, cumpri minha palavra e com a missão que me comprometi, penso que não fiz um bom ou um ótimo trabalho, busquei fazer o melhor possível. Agradeço ao Prof. Marcelo Azevedo Costa, co - orientador sempre disposto a colaborar, um exemplo de profissional.

Agradeço imensamente a todos treinadores e atletas de atletismo do Centro de Treinamento Esportivo da UFMG, direção da Federação Mineira de Handebol, membros da equipe adulta masculina de handebol da Prefeitura Municipal de Poços de Caldas - MG, aos professores Luiz Maculan, Felipe Figueira e Fúlvio Ventura. Agradeço a todos que se comprometeram e participaram em alguma etapa deste estudo: sem vocês este trabalho não seria possível, muito obrigado!

Agradeço à Universidade Federal de Ouro Preto por me conceder este valoroso período de afastamento para qualificação, lugar onde obtenho meu sustento, espero agora com a mesma mentalidade de “devedor”, contribuir ainda mais para com a instituição. Agradeço aos colegas de trabalho da Escola de Educação Física da Universidade Federal de Ouro Preto, bem como os alunos dos projetos de extensão. E por fim, agradeço a todos familiares, a todos os meus tios, em especial a Lourdes e José Marinho. Agradeço aos colegas da 59ª turma da Faculdade de Educação Física e Fisioterapia, da Universidade Federal de Uberlândia. Agradeço aos funcionários da Escola de Educação Física, Fisioterapia e Terapia Ocupacional – UFMG. Agradeço aqueles que de alguma maneira contribuíram para a realização deste trabalho.

Meus sinceros agradecimentos.

*“Pedro, se o Brasil se separar, antes seja por ti, que me hás de respeitar do que para algum desses aventureiros.” [Dom João VI, 24 de abril de 1821].*

*“[...] Fique, é o que todos pedem ao Magnânimo Príncipe, que é Vossa Alteza, para orgulho e felicidade do Brasil. E, se não ficar, correrão rios de sangue, nesta grande e nobre terra, tão querida do seu Real Pai, que já não governa em Portugal, pela opressão das Cortes; nesta terra que tanto estima Vossa Alteza e a quem tanto Vossa Alteza estima.” [José Bonifácio de Andrada e Silva, 1 de setembro de 1822]*

*“[...] Pedro, o momento é o mais importante de vossa vida. Já dissestes aqui o que ireis fazer em São Paulo. Fazei, pois. Tereis o apoio do Brasil inteiro e, contra a vontade do povo brasileiro, os soldados portugueses que aqui estão nada podem fazer.” [D. Leopoldina, 29 de agosto de 1822]*

*“[...] Dom Pedro caminhou alguns passos, silenciosamente, acompanhado por mim, Cordeiro, Bregaro, Carlota e outros, em direção aos animais que se achavam à beira do caminho. De repente, estacou já no meio da estrada, dizendo-me: - “Padre Belchior, eles o querem, eles terão a sua conta. As Cortes me perseguem, chamam-me com desprezo de “Rapazinho” e de “Brasileiro”. Pois verão agora quanto vale o “Rapazinho”. De hoje em diante estão quebradas as nossas relações; nada mais quero com o governo português e proclamo o Brasil, para sempre, separado de Portugal.” (SOUZA, 2015, p.397).*

*Bicentenário de Independência do Brasil [1822 – 2022]*

## RESUMO

Nos últimos anos, novas tecnologias tais como unidades de medida inercial (UMI) têm sido introduzidas em pesquisas aplicadas nas ciências do esporte, bem como treinos e competições. A utilização de UMI tem se apresentado como uma área promissora nas ciências do esporte para: (1) análises biomecânicas; (2) classificação de ações e predição de variáveis por métodos de aprendizado de máquina; e (3) quantificação da demanda física de treinos e competições, logo, três experimentos foram conduzidos abordando tais finalidades. **Experimento I** – Analisou-se a validade (concordância entre métodos de medição) e confiabilidade teste – reteste (consistência de medida entre dias) de utilização de UMI quando comparada a dispositivos de referência, para duas tarefas distintas: (A) Saltos verticais padronizados – UMI contra uma plataforma de força e um *encoder* linear para estimação do tempo de voo, altura de salto e impulso; e (B) *Sprints* de 30 metros – UMI contra um *encoder* rotatório (*Race Encoder* - RE) para estimação da velocidade média e máxima de corrida. Ao todo 20 indivíduos foram recrutados para realizar as tarefas de saltos padronizados (saltos agachados – SA e saltos com contramovimento – SCM:  $17,35 \pm 2,28$  anos;  $60,99 \pm 8,87$  kg;  $169,30 \pm 9,30$  cm) e 19 indivíduos para os *sprints* ( $17,42 \pm 2,32$  anos;  $61,45 \pm 8,86$  kg;  $169,74 \pm 9,35$  cm), em duas sessões separadas. As UMI de baixo custo testadas apresentaram estimativas válidas para o tempo de voo, altura de salto e impulso quando comparadas à plataforma de força e *encoder* linear, com elevada confiabilidade teste – reteste entre dias para o SA e SCM. Adicionalmente, apesar de uma significativa subestimação da velocidade média de *sprints*, a velocidade máxima estimada por UMI mostrou concordância quando comparada com o *encoder* rotatório (*Race Encoder*®). Logo, estimativas válidas e com aceitável repetibilidade foram proporcionadas pela UMI para a velocidade média e máxima de *sprints*. **Experimento II** – O desempenho de classificação de ações locomotoras comuns aos esportes coletivos (circuito simulado com a utilização de UMI) foi avaliado através de métodos de aprendizado de máquina. Para o emprego de características obtidas de acelerômetros isoladamente, os classificadores treinados e testados (*Decision Trees*, *k* - *Nearest Neighbors*, *Support Vector Machines*, *Ensemble*, *Neural Networks*) evidenciaram menor sensibilidade de detecção para as ações de corrida de intensidade moderada e MMD. Entretanto, a combinação de sensores (acelerômetros e giroscópios) e agregação de diferentes tipos de características extraídas (estatísticas descritivas, customizadas e medidas de análise de séries temporais) apresentou melhor acurácia geral, sensibilidade, especificidade e precisão de classificação para o algoritmo *k*-*NN* “fine” (>90%), comparado ao emprego isolado de acelerômetros, nas ações de permanecer estático, marcha, corrida de intensidade leve, corrida de intensidade moderada, *sprints* com desaceleração, SCM e movimentos de mudança de direção (MMD). **Experimento III** – Identificar como as variáveis obtidas por UMI durante jogos no handebol agrupam – se em fatores e podem ser sumarizadas para avaliar a magnitude das demandas físicas a partir das novas variáveis construídas. Ao todo 14 atletas amadores foram monitorados com o uso de UMI em três jogos consecutivos no handebol. O emprego de procedimentos de redução da dimensionalidade a partir das variáveis originais quantificadas com o uso de UMI, evidenciou de 2 a 3 componentes e fatores retidos, com variância explicada maior que 85%. As componentes e fatores de maior variância explicada (> 65%) representam em geral indicadores úteis para monitorar e entender a magnitude da demanda física no handebol. Em síntese, a utilização de unidades de medida

inercial de baixo custo para análises de saltos verticais padronizados (tempo de vôo, altura de salto e impulso) e *sprints* (velocidade máxima e média) mostrou validade e repetibilidade quando comparada às medidas de referência adotadas. Os algoritmos de classificação treinados e testados mostraram menor sensibilidade de identificação de eventos para a corrida moderada e MMD (acelerômetro isolado). No entanto, a combinação de sensores e agregação de características extraídas mostrou melhor acurácia de classificação para o algoritmo k-NN (>90%) para todas as ações estudadas em ambas as etapas de treinamento e teste. Por fim, a utilização de UMI associada a métodos de redução da dimensionalidade mostrou que as componentes e fatores de maior variância explicada permitem a avaliação da magnitude das demandas físicas no handebol. As componentes e fatores de menor variância explicada orientam para um indicador para potencial ocorrência lesões. Em complemento, um conjunto de 2 a 3 combinações lineares e fatores foram retidas. Adicionalmente, a ponderação dos autovalores das combinações e fatores retidos para fornecer uma perspectiva geral da demanda física no handebol.

**Palavras-chave:** Unidades de Medida Inercial. Validação de critério. Aprendizado de máquina. Classificação de movimentos. Monitoramento esportivo. Esportes coletivos.

## ABSTRACT

In recent years, new technologies such as inertial measurement units (IMU) have been introduced in applied research in sport sciences, as well as training and competition. The use of IMU has been presented as a promising area in the sport sciences for: (1) biomechanical analyses; (2) classification of actions and prediction of variables by machine learning methods; and (3) quantification of training and competition physical demand, therefore, three experiments were conducted addressing these purposes. **Experiment I** – We analyzed the validity (agreement between measurement methods) and test-retest reliability (consistency of measurement between days) of the use of IMU when compared to reference devices, for two different tasks: (A) Standardized vertical jumps – IMU against a force platform and a linear encoder to estimate flight time, jump height and impulse; and (B) 30-meter sprints – IMU against a rotary encoder (Race Encoder - RE) to estimate mean and maximum running velocity. A total of 20 individuals were recruited to perform standardized jumping tasks (squat jumps – SJ and countermovement jumps – CMJ:  $17.35 \pm 2.28$  years;  $60.99 \pm 8.87$  kg;  $169.30 \pm 9.30$  cm) and 19 individuals for sprints ( $17.42 \pm 2.32$  years;  $61.45 \pm 8.86$  kg;  $169.74 \pm 9.35$  cm), in two separate sessions. The tested low-cost IMU presented valid estimates for flight time, jump height and impulse when compared to the force platform and linear encoder, with high test-retest reliability between days for the SJ and CMJ. Additionally, despite a significant underestimation the mean velocity of sprints, the maximum speed estimated by UMI showed agreement when compared with the rotary encoder (Race Encoder®). Therefore, valid estimates with acceptable repeatability were provided by the UMI for the mean and maximum velocity of sprints. **Experiment II** – The classification performance of locomotor actions common to the team sports (simulated circuit using UMI) was evaluated using machine learning methods. For the use of characteristics obtained from accelerometers (alone), the trained and tested classifiers (Decision Trees, k - Nearest Neighbors, Support Vector Machines, Ensemble, Neural Networks) showed lower detection sensitivity for moderate intensity running actions and change of direction (COD). However, the combination of sensors (accelerometers and gyroscopes) and aggregation of different types of extracted features (descriptive statistics, custom statistics, and time series analysis measures) showed better overall accuracy, sensitivity, specificity, and classification accuracy for the k-NN algorithm “fine” (>90%), compared to the isolated use of accelerometers, in the actions of remaining static, walking, light intensity running, moderate intensity running, sprints with deceleration, CMJ and COD. **Experiment III** – To identify how the variables obtained by UMI during handball games are grouped into factors and can be summarized to assess the magnitude of the physical demands from the new constructed variables. A total of 14 amateur athletes were monitored using UMI in three consecutive handball games. The use of dimensionality reduction procedures from the original variables quantified using UMI, showed 2 to 3 components and retained factors, with explained variance greater than 85%. The components and factors with the highest explained variance (> 65%) generally represent useful indicators for monitoring and understanding the magnitude of the physical demand in handball. In summary, the use of low-cost IMU for the analysis of standardized vertical jumps (flight time, jump height and impulse) and sprints (maximum and mean velocity) showed validity and repeatability when compared to the adopted reference measurements. The trained and tested classification algorithms showed lower event identification sensitivity for moderate running and MMD (accelerometer only). However, the combination of

sensors and aggregation of extracted features showed better classification accuracy for the k-NN algorithm (>90%) for all studied actions in both training and testing stages. Finally, the use of UMI associated with dimensionality reduction methods showed that the components and factors of greater explained variance allow the assessment of the magnitude of physical demands in handball. The components and factors with the lowest explained variance lead to an indicator for the potential occurrence of microlesions. In addition, a set of 2 to 3 linear combinations and factors were retained. Additionally, the weighting of the eigenvalues of the combinations retained to provide an overview of the physical demand in handball.

**Keywords:** Inertial Measurement Units. Criterion Validation. Machine Learning. Motion Classification. Sports Monitoring. Team sports.

## LISTAS DE FIGURAS

|                                                                                                                                                                                                                                                                                                                                                                                     |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1.1 – Unidades de Medida Inercial: diferentes fabricantes e aplicações. ....                                                                                                                                                                                                                                                                                                 | 27 |
| Figura 1.2 – Utilização de sensores inerciais nas ciências do esporte. ....                                                                                                                                                                                                                                                                                                         | 28 |
| Figura 2.1 – (A) Unidade de medida inercial AHRS (Attitude Heading Reference System) WT901SDCL; (B) Acionamento do sensor por meio da inserção do microcartão de memória para coletas; (C) Plataforma de força triaxial AMTI, OR5-6 (Watertown, Massachusetts, EUA); (D) Dispositivo do tipo encoder linear para medição das variáveis cinemáticas e cinéticas. ....                | 45 |
| Figura 2.2 – Dispositivo para medição de variáveis biomecânicas de sprints Race encoder®. ....                                                                                                                                                                                                                                                                                      | 46 |
| Figura 2.3 – Experimentos de saltos padronizados: (A) Vestimenta customizada; (B1-B2) Posicionamento do sensor inercial na bermuda sobre a região lombar; (C) Cinto de tração; (D) Posicionamento do Encoder Linear. ....                                                                                                                                                           | 48 |
| Figura 2.4 – (A1) Posicionamento do bloco de partida PBS-01 POLANIK®; (A2) Ajuste do apoio do bloco – perna de impulso; (A3) Ajuste do apoio do bloco – perna de apoio; (B) Posição preparatória para entrada no bloco partida com a linha do dispositivo Race encoder® tensionada; (C) Posição de saída baixa no bloco e local de fixação do sensor inercial (região lombar). .... | 49 |
| Figura 2.5 – Aceleração linear filtrada obtida dos sensores inerciais nos eixos “x”, “y” e “z” durante a realização do salto com contramovimento (SCM). ....                                                                                                                                                                                                                        | 52 |
| Figura 2.6 – Figura 2.6 – Curvas de velocidade, aceleração linear e ângulo de Euler – “roll” (sensor posicionado próximo da região lombar) obtidas dos sensores inerciais no eixo vertical “y” durante a realização de sprints de 30m (saída baixa) obtidas de UMI. ....                                                                                                            | 56 |
| FIGURA 3.1 – Circuito simulado de ações gerais - esportes coletivos. ....                                                                                                                                                                                                                                                                                                           | 76 |
| FIGURA 3.2 – Configuração do posicionamento do sensor inercial. ....                                                                                                                                                                                                                                                                                                                | 77 |
| FIGURA 3.3 – Aceleração linear no eixo vertical (“x”) durante a realização do circuito simulado de ações. ....                                                                                                                                                                                                                                                                      | 78 |
| Figura 3.4 – Paradigma de aprendizado supervisionado. ....                                                                                                                                                                                                                                                                                                                          | 82 |
| Figura 3.5 – Matriz de confusão absoluta para o conjunto de dados de treinamento (ACC3+GIR1, m = 219) utilizando o algoritmo <i>k</i> -NN “fine” e <i>k-fold cross-validation</i> . ....                                                                                                                                                                                            | 85 |

|                                                                                                                                                                                                                                                                                                           |     |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Figura 3.6 – Matriz de confusão relativa (B) para o conjunto de dados de treinamento (ACC3+GIR1, m = 219) utilizando o algoritmo $k$ -NN “fine” e $k$ -fold cross-validation. ....                                                                                                                        | 87  |
| Figura 3.7 – Matriz de confusão relativa (C) para o conjunto de dados de treinamento (ACC3 + GIR1, m = 219) utilizando o algoritmo $k$ -NN “fine” e $k$ -fold cross-validation. ....                                                                                                                      | 88  |
| Figura 3.8 – Matriz de confusão absoluta (A) para o conjunto de dados de teste (ACC3+GIR1, m = 219) utilizando o algoritmo $k$ -NN “fine”. ....                                                                                                                                                           | 90  |
| Figura 3.9 – Matriz de confusão relativa (B) para o conjunto de dados de teste (ACC3+GIR1, m = 219) utilizando o algoritmo $k$ -NN “fine”. ....                                                                                                                                                           | 91  |
| Figura 3.10 – Matriz de confusão relativa (C) para o conjunto de dados de teste (ACC3+GIR1, m = 219) utilizando o algoritmo $k$ -NN “fine”. ....                                                                                                                                                          | 92  |
| Figura 4.1 – Delineamento experimental do estudo. ....                                                                                                                                                                                                                                                    | 105 |
| Figura 4.2 – Utilização da UMI: colete de poliamida para acomodação do sensor (WT901SDCL, Wit - Motion, Shenzhen, China). ....                                                                                                                                                                            | 106 |
| Figura 4.3 – Exemplos de sinal bruto, filtrado e reamostrado para aceleração ( $m.s^{-2}$ ) no tempo (s) (“x”, “y”, “z”, aceleração resultante vertical e horizontal). ....                                                                                                                               | 108 |
| Figura 4.4 – Análise espectral do sinal bruto e filtrado (“x”, “y”, “z”) para os dados de aceleração ( $m.s^{-2}$ ) no tempo (s). ....                                                                                                                                                                    | 109 |
| Figura 4.5 – Gráficos de linhas e de dispersão – Jogos Inteiros: [A] Autoavalores vs. CP ( <i>screeplot</i> ); [B] CP1 vs. CP2; [C] EG vs. CP1; [D] F1 vs. F2; [E] EG vs. F1; [F] EG vs. F2 (†Componentes retidas [ $CP_k$ ]; --- Critério para determinar as $CP_k$ , $\lambda_{CP_i} \geq 0.70$ ). .... | 114 |
| Figura 4.6 – Gráficos de linhas e de dispersão – Primeiro Tempo: [A] Autoavalores vs. CP ( <i>screeplot</i> ); [B] CP1 vs. CP2; [C] EG vs. CP1; [D] F1 vs. F2; [E] EG vs. F1; [F] EG vs. F2 (†Componentes retidas [ $CP_k$ ]; --- Critério para determinar as $CP_k$ , $\lambda_{CP_i} \geq 0.70$ ). .... | 115 |
| Figura 4.7 – Gráficos de linhas e de dispersão – Segundo Tempo: [A] Autoavalores vs. CP ( <i>screeplot</i> ); [B] CP1 vs. CP2; [C] EG vs. CP1; [D] F1 vs. F2; [E] EG vs. F1; [F] EG vs. F2 (†Componentes retidas [ $CP_k$ ]; --- Critério para determinar as $CP_k$ , $\lambda_{CP_i} \geq 0.70$ ). ....  | 116 |
| Figura 4.8 – Escores Globais e escores dos fatores (F1 e F2) para cada jogo e respectivo agrupamento. ....                                                                                                                                                                                                | 122 |

## TABELAS

|                                                                                                                                                                                                                                                                               |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Tabela 1.1 – Descrição da amostra. ....                                                                                                                                                                                                                                       | 44 |
| Tabela 1.2 – Instruções, desvios das técnicas e protocolos de avaliação de saltos verticais. ....                                                                                                                                                                             | 47 |
| Tabela 1.3 – Análise descritiva para as variáveis obtidas dos sensores inerciais nos experimentos de saltos padronizados. ....                                                                                                                                                | 58 |
| Tabela 1.4 – Concordância entre os instrumentos de medição (PF vs. EL; PF vs. UMI; EL vs. UMI) para as variáveis obtidas nos saltos verticais padronizados (Sessão 1). ....                                                                                                   | 59 |
| Tabela 1.5 – Concordância entre os instrumentos de medição (PF vs. EL; PF vs. UMI; EL vs. UMI) para as variáveis obtidas nos saltos verticais padronizados (Sessão 2). ....                                                                                                   | 60 |
| Tabela 1.6 – Correlação ( $r$ ) [intervalo de confiança – 95%] entre instrumentos de medição (PF vs. EL; PF vs. UMI; EL vs. UMI) para as respectivas variáveis estudadas. ....                                                                                                | 61 |
| Tabela 1.7 – Confiabilidade teste - reteste para UMI, PF e EL no salto agachado e salto com contramovimento. ....                                                                                                                                                             | 62 |
| Tabela 1.8 – Concordância e associação entre instrumentos de medição ( <i>Race Encoder</i> – RE vs. Unidades de medida inercial – UMI) nas sessões 1 e 2 (A); Confiabilidade teste - reteste de UMI e RE para as variáveis $V_{max}$ e $V_{med}$ nos <i>sprints</i> (B). .... | 64 |
| Tabela 2.1 – Características extraídas ( $m$ ), ações classificadas e algoritmos de treinados e avaliados. ....                                                                                                                                                               | 80 |
| Tabela 2.2 – Conceito e cálculos de avaliação dos modelos de classificação obtidos. ....                                                                                                                                                                                      | 82 |
| Tabela 2.3 – Acurácia geral dos algoritmos de classificação (%) após o treinamento utilizando a validação cruzada ( <i>k – fold cross – validation</i> ) – dados de treinamento. ....                                                                                         | 86 |
| Tabela 2.4 – Acurácia geral dos algoritmos de classificação treinados (%) utilizando o conjunto de dados de teste. ....                                                                                                                                                       | 89 |
| Tabela 2.5 – Valores concordância para acurácia geral e relação entre sensibilidade e especificidade (AUC) de classificação entre as etapas de treinamento e avaliação. ....                                                                                                  | 93 |

|                                                                                                                                                                     |     |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Tabela 3.1 – ACP e AFE para partidas completas no handebol. ....                                                                                                    | 113 |
| Tabela 3.2 – ACP e AFE via rotação <i>varimax</i> por tempos de jogo no handebol. ....                                                                              | 117 |
| Tabela 3.3 – Exemplo de aplicação das combinações lineares (CP), escore global (EG) e fatores a partir dos dados originais de dois atletas (A1 e A2) por jogo. .... | 118 |
| Tabela 3.4 – Valores médios, intervalos de agrupamento e coeficientes de partição ( $R^2$ ) para as análises de agrupamento pelo método $k$ – médias. ....          | 120 |

## LISTA DE SIGLAS E ABREVIATURAS

ARESHmax – valor máximo do vetor de aceleração resultante horizontal.

ARESVmax – valor máximo do vetor de aceleração resultante vertical.

ARESHmedia – valor médio do vetor de aceleração resultante horizontal.

ARESVmedia – valor médio do vetor de aceleração resultante vertical.

$a_{\text{sensor}}$  – aceleração linear (sistema de referência de sensor).

$a_{\text{global}}$  – aceleração linear (sistema de referência de global).

Acel<sub>RMS</sub> – root mean square da aceleração linear por eixo.

acel<sub>res</sub> – aceleração resultante tridimensional.

acel<sub>hor</sub> – aceleração resultante horizontal.

Acel<sub>vert</sub> – aceleração resultante vertical.

ACP – análise de componentes principais.

AFE – Análise Fatorial Exploratória.

AHRS – Attitude Heading Reference Systems.

AUC – Area Under Curve.

CCC – Coeficiente de concordância de Linn.

CCI – Coeficiente de correlação intraclasse.

CP – Componente principal.

CTE – Centro de Treinamento Esportivo.

CV% – Coeficiente de variação.

dp – desvio – padrão.

dp<sub>diff</sub> – desvio – padrão das diferenças.

DIF<sub>Média</sub> – diferença média entre instrumentos.

DT - Decision Trees.

EL – Encoder Linear.

EG – Escore Global.

EPM – Erro padrão de medida.

ER% - Erro relativo entre instrumentos.

FP – Falso Positivo.

FN – Falso Negativo.

F<sub>RS</sub> – Forças de reação do solo.

GNSS – Global Navigation Satellite System.

GPS – Global Positioning Systems.

$H_{SA/SCM}$  – Altura de salto vertical para os saltos agachados e com contramovimento.

HIE – High – Intensity Events.

$IMP_{SA/SCM}$  – impulso, integral da curva força – tempo.

IMU – Inertial Measurement Units.

JG – Jogo.

KHz – Kilohertz.

KMO – Kayser-Meyer-Olkin.

k-NN – k – Nearest Neighbors.

LC – Limite de concordância.

LPS – Local Positioning Systems.

MLA – Machine Learning Algorithms.

MMD – Movimentos de mudança de direção.

NN – Neural Networks.

PL – Player load.

PF – Plataforma de força.

UMI – Unidade de Medida Inercial.

RF – Random Forest.

RMS – Root Mean Square.

RMSE – Root Mean Square Error.

ROC – Receiver operating characteristics curves.

SA – Salto agachado.

SCM – Salto com contramovimento.

SVM – Support Vector Machines.

TALE – Termo de assentimento livre esclarecido.

TCLE – Termo de consentimento livre e esclarecido.

$TV_{SA/SCM}$  – Tempo de vôo nos saltos agachados e com contramovimento.

UFMG – Universidade Federal de Minas Gerais.

$VS_{to}$  – Velocidade de saída do solo para os saltos agachados e com contramovimento.

VP – Verdadeiro Positivo.

VN – Verdadeiro Negativo.

$t_{VertA_{BAIXO}}$  – tempo na zona de aceleração vertical para cima de intensidade baixa.

$t_{VertA_{MODERADO}}$  – tempo na zona de aceleração vertical para cima de intensidade moderada.

$t_{VertA_{ALTO}}$  – tempo na zona de aceleração vertical para cima de intensidade alta.

$t_{DirBAIXO}$  – tempo na zona de aceleração a direita de intensidade baixa.

$t_{DirMODERADO}$  – tempo na zona de aceleração a direita de intensidade moderada.

$t_{DirALTO}$  – tempo na zona de aceleração a direita de intensidade alta.

$t_{ACBAIXO}$  – tempo na zona de aceleração para frente de intensidade baixa.

$t_{ACMODERADO}$  – tempo na zona de aceleração para frente de intensidade moderada.

$t_{ACALTO}$  – tempo na zona de aceleração para frente de intensidade alta.

$t_{VertDBAIXO}$  – tempo na zona de desaceleração vertical para baixo de intensidade baixa.

$t_{VertDMODERADO}$  – tempo na zona de desaceleração vertical para baixo de intensidade moderada.

$t_{VertDALTO}$  – tempo nas zonas de desaceleração vertical para baixo de intensidade alta.

$t_{EsqBAIXO}$  – tempo na zona de desaceleração a esquerda de intensidade baixa.

$t_{EsqMODERADO}$  – tempo na zona de desaceleração a esquerda de intensidade moderada.

$t_{EsqALTO}$  – tempo na zona de desaceleração a esquerda de intensidade alta.

$t_{DesBAIXO}$  – tempo na zona de desaceleração para trás de intensidade baixa.

$t_{DesMODERADO}$  – tempo na zona de desaceleração para trás de intensidade moderada.

$t_{DesALTO}$  – tempo na zona de desaceleração para trás de intensidade alta.

$W_{maximo}$  – valor basal máximo de forças de reação do solo.

$W_{medio}$  – valor basal médio de forças de reação do solo.

ZUPT – Zero – velocity updates.

## SUMÁRIO

|                                                                                                                                     |    |
|-------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>CAPÍTULO 1 – INTRODUÇÃO</b> .....                                                                                                | 25 |
| <b>1.1. Validade &amp; Confiabilidade de Sensores Inerciais</b> .....                                                               | 29 |
| <b>1.2. Utilização de Sensores Inerciais &amp; Métodos de Aprendizado de Máquina</b> .....                                          | 30 |
| <b>1.3. Utilização de Sensores Inerciais para Monitoramento das Demandas Físicas nos Esportes Coletivos</b> .....                   | 33 |
| <b>CAPÍTULO 2 – UTILIZAÇÃO DE SENSORES INERCIAIS PARA ANÁLISE DO DESEMPENHO DE SALTOS VERTICAIS E SPRINTS (EXPERIMENTO I)</b> ..... | 38 |
| <b>2.1. Introdução</b> .....                                                                                                        | 38 |
| 2.1.1. <i>Saltos Verticais Padronizados</i> .....                                                                                   | 38 |
| 2.1.2. <i>Sprints</i> .....                                                                                                         | 40 |
| <b>2.2. Objetivos</b> .....                                                                                                         | 42 |
| <b>2.3. Hipoteses</b> .....                                                                                                         | 42 |
| <b>2.4. Materiais &amp; Métodos</b> .....                                                                                           | 43 |
| 2.4.1. <i>Delineamento do estudo</i> .....                                                                                          | 43 |
| 2.4.2. <i>Cuidados éticos</i> .....                                                                                                 | 43 |
| 2.4.3. <i>Amostra</i> .....                                                                                                         | 43 |
| 2.4.4. <i>Instrumentos</i> .....                                                                                                    | 44 |
| 2.4.4.1. <i>Unidades de Medida Inercial</i> .....                                                                                   | 44 |
| 2.4.4.2. <i>Plataforma de Força</i> .....                                                                                           | 45 |
| 2.4.4.3. <i>Encoder Linear</i> .....                                                                                                | 46 |
| 2.4.4.4. <i>Race Encoder®</i> .....                                                                                                 | 46 |
| 2.4.5. <i>Procedimentos</i> .....                                                                                                   | 47 |
| 2.4.5.1. <i>Saltos Verticais</i> .....                                                                                              | 47 |
| 2.4.5.2. <i>Sprints</i> .....                                                                                                       | 50 |
| 2.4.5. <i>Processamento e Análise numérica</i> .....                                                                                | 51 |
| 2.4.5.1. <i>Saltos Verticais</i> .....                                                                                              | 51 |
| 2.4.5.2. <i>Sprints</i> .....                                                                                                       | 55 |
| 2.4.6. <i>Análise estatística</i> .....                                                                                             | 56 |
| <b>2.5. Resultados</b> .....                                                                                                        | 58 |
| 2.5.5. <i>Saltos Verticais</i> .....                                                                                                | 58 |
| 2.5.6. <i>Sprints</i> .....                                                                                                         | 63 |
| <b>2.6. Discussão</b> .....                                                                                                         | 64 |
| 2.6.5. <i>Saltos Verticais</i> .....                                                                                                | 64 |

|                                                                                                                                                                           |            |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|
| 2.6.6. Sprints .....                                                                                                                                                      | 67         |
| <b>2.7. Conclusões .....</b>                                                                                                                                              | <b>69</b>  |
| 2.7.5. Saltos Verticais .....                                                                                                                                             | 69         |
| 2.7.6. Sprints .....                                                                                                                                                      | 70         |
| <b>CAPÍTULO 3 – UTILIZAÇÃO DE SENSORES INERCIAIS E MÉTODOS DE APRENDIZADO DE MÁQUINA PARA RECONHECIMENTO DE AÇÕES COMUNS AOS ESPORTES COLETIVOS (EXPERIMENTO II).....</b> | <b>71</b>  |
| <b>3.1. Introdução .....</b>                                                                                                                                              | <b>71</b>  |
| <b>3.2. Objetivo .....</b>                                                                                                                                                | <b>74</b>  |
| <b>3.3. Hipóteses.....</b>                                                                                                                                                | <b>75</b>  |
| <b>3.4. Materiais &amp; Métodos.....</b>                                                                                                                                  | <b>75</b>  |
| 3.4.1. Delineamento do estudo.....                                                                                                                                        | 75         |
| 3.4.2. Cuidados éticos .....                                                                                                                                              | 75         |
| 3.4.3. Amostra.....                                                                                                                                                       | 76         |
| 3.4.4. Procedimentos e Instrumentos.....                                                                                                                                  | 76         |
| 3.4.5. Processamento e Análise Estatística .....                                                                                                                          | 79         |
| <b>3.5. Resultados .....</b>                                                                                                                                              | <b>85</b>  |
| <b>3.6. Discussão.....</b>                                                                                                                                                | <b>94</b>  |
| <b>3.7. Conclusões .....</b>                                                                                                                                              | <b>99</b>  |
| <b>CAPÍTULO 4 – UTILIZAÇÃO DE SENSORES INERCIAIS PARA MONITORAMENTO DAS DEMANDAS FÍSICAS NO HANDEBOL (EXPERIMENTO III).....</b>                                           | <b>100</b> |
| <b>4.1. Introdução .....</b>                                                                                                                                              | <b>100</b> |
| <b>4.2. Objetivo.....</b>                                                                                                                                                 | <b>104</b> |
| <b>4.3. Hipóteses.....</b>                                                                                                                                                | <b>104</b> |
| <b>4.4. Materiais &amp; Métodos.....</b>                                                                                                                                  | <b>104</b> |
| 4.4.1. Delineamento do estudo.....                                                                                                                                        | 104        |
| 4.4.2. Cuidados éticos .....                                                                                                                                              | 104        |
| 4.4.3. Amostra.....                                                                                                                                                       | 105        |
| 4.4.4. Procedimentos e Instrumentos.....                                                                                                                                  | 105        |
| 4.4.5. Processamento dos dados.....                                                                                                                                       | 107        |
| 4.4.6. Análise estatística.....                                                                                                                                           | 111        |
| <b>4.5. Resultados .....</b>                                                                                                                                              | <b>112</b> |
| <b>4.6. Discussão.....</b>                                                                                                                                                | <b>118</b> |
| <b>4.7. Conclusões .....</b>                                                                                                                                              | <b>124</b> |
| <b>CAPÍTULO 5 – CONSIDERAÇÕES FINAIS .....</b>                                                                                                                            | <b>126</b> |
| <b>REFERÊNCIAS .....</b>                                                                                                                                                  | <b>129</b> |
| <b>APÊNDICE A – TERMO DE CONSENTIMENTO LIVRE ESCLARECIDO (TCLE) .....</b>                                                                                                 | <b>142</b> |
| <b>APÊNDICE B – TERMO DE ASSENTIMENTO LIVRE E ESCLARECIDO (TALE) .....</b>                                                                                                | <b>145</b> |

|                                                                                                                                                                                                                 |            |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|
| <b>APÊNDICE C – GRÁFICOS DE DISPERSÃO DE “BLAND ALTMAN” DE CONCORDÂNCIA ENTRE INSTRUMENTOS DE MEDIÇÃO E ENTRE SESSÕES (CAPÍTULO 2).....</b>                                                                     | <b>149</b> |
| <b>APÊNDICE D – ANÁLISE DE REGRESSÃO LINEAR ENTRE INSTRUMENTOS DE MEDIÇÃO (CAPÍTULO 2). .....</b>                                                                                                               | <b>166</b> |
| <b>APÊNDICE E – MATRIZ DE CONFUSÃO ABSOLUTA E RELATIVA DE DESEMPENHO DE CLASSIFICAÇÃO DAS AÇÕES PARA OS ALGORITMOS DE MELHOR DESEMPENHO PARA OS CONJUNTOS DE DADOS DE TREINAMENTO E TESTE (CAPÍTULO 3).....</b> | <b>168</b> |
| <b>APÊNDICE F – ESTATÍSTICAS DESCRITIVAS (CAPÍTULO 4).....</b>                                                                                                                                                  | <b>205</b> |



## CAPÍTULO 1 – INTRODUÇÃO

Nos últimos anos, alterações substanciais têm sido experimentadas no esporte devido ao desenvolvimento de novas tecnologias para utilização em experimentos na área de ciências do esporte e ferramenta de monitoramento e controle das demandas físicas impostas em sessões de treinos e competições (CARDINALE; VARLEY, 2017; CUST *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019). O monitoramento e controle destas demandas é parte essencial do processo de treinamento, tendo como finalidade de assegurar a efetividade que as sessões de treino se aproximem ou correspondam à planificação desenhada por treinadores, proporcionar uma informação sobre o efeito de treinamento, avaliar o desempenho e determinar as características de adaptação do atleta, e, portanto, permitir o ajuste do planejamento a ser adotado se necessário, para administração das demandas físicas de treinamento em sessões posteriores (HALSON, 2014; SANDS *et al.*, 2017; HADER *et al.*, 2019). Adicionalmente, o monitoramento e controle das tarefas envolvem a utilização de instrumentos, testes e tarefas para entender o desempenho competitivo atual (SANDS *et al.*, 2017). Logo, estes devem melhorar a efetividade do treinamento, evidenciar especificidade, proporcionar informações confiáveis, registrar possíveis alterações individuais como resultado de influências de treinamento, sendo compreensíveis a treinadores e atletas, de modo a possibilitar uma relação direta entre a informação comunicada e a tomada de decisão no processo de treinamento (HALSON, 2014; BUCHHEIT; SIMPSON, 2017; SANDS *et al.*, 2017; HADER *et al.*, 2019; TORRES – RONDA *et al.*, 2022).

Dentre os instrumentos disponíveis, a observação direta e registro manual consiste em uma das formas de quantificar os componentes de prescrição e monitoramento das atividades durante as sessões de treinamento (tipo de exercício ou movimento, volume, duração, intensidade absoluta e/ou relativa etc.). Entretanto, este procedimento baseia-se no julgamento de um observador, portanto está sujeito a riscos inerentes à subjetividade, e, conseqüentemente, quase sempre evidencia a divergências perceptivas entre treinadores e atletas sobre uma mesma sessão de treino. Além disso, o registro manual é por vezes dispendioso, laborioso e pode levar inequivocamente a erros. Logo, a utilização de métodos objetivos de natureza quantitativa para monitoramento e controle das demandas físicas de treinamento que ofereçam maior confiabilidade, sem o viés inerente ao componente subjetivo

(HALSON, 2014; BUCHHEIT; SIMPSON, 2017), apresentam-se como uma possibilidade.

Dentre os métodos objetivos para monitoramento da demanda física externa, particularmente entre os métodos de medição em biomecânica, a análise cinemática para rastreamento de movimentos caracteriza-se pela aquisição de imagens por sistemas de múltiplas câmeras de alta frequência ( $\geq 120\text{Hz}$ ). Apesar da ampla utilização como ferramenta de pesquisa laboratorial e monitoramento nos esportes coletivos, estes sistemas apresentam custos elevados para aquisição, operação e restrição em geral a ambientes laboratoriais, sendo que aspectos como oclusão, alteração da posição das câmeras e condições ambientais podem afetar os resultados obtidos (CARDINALE; VARLEY, 2017; CUST *et al.*, 2018; CAMOMILLA *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019).


A despeito dos sistemas de análise cinemática tridimensional serem reconhecidas amplamente como método padrão-ouro (CUST *et al.*, 2018; CAMOMILLA *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019), tais limitações apresentadas têm direcionado para estudo e possível emprego de instrumentos que superem estas limitações para a finalidade de monitoramento e controle das demandas físicas de treinamento. Logo, em consonância a estas questões de ordem prática, a utilização de sistemas de posicionamento local (*Local Positioning Systems - LPS*) ou global (*Global Positioning Systems - GPS*) remetendo ao perfil de ações de locomoção dos atletas, tem permitido o monitoramento de treinos e competições nos esportes coletivos (MALONE *et al.*, 2017; SERPIELLO *et al.*, 2018; MANCHADO *et al.*, 2020).

Nesse sentido, os LPS ou GPS têm sido questionados quanto a validade e confiabilidade de registro de ações de alta intensidade, custos, portabilidade ou utilização restrita a ambientes abertos no caso dos GPS (VARLEY; FAIRWEATHER; AUGHEY, 2011; JOHNSTON *et al.*, 2014; MALONE *et al.*, 2017; MALONE *et al.*, 2020). Com o intuito de mitigar em parte os problemas manifestados acima por estes sistemas, unidades de medida inercial – UMI (*“Inertial Measurement Units”* – IMU) têm sido incorporadas aos dispositivos por seus respectivos fabricantes ou administradas isoladamente (MALONE *et al.*, 2017; CARDINALE; VARLEY, 2017; CUST *et al.*, 2018; CAMOMILLA *et al.*, 2018; LU *et al.*, 2019; ADESIDA; PAPI; MCGREGOR, 2019).

As UMI (Figura 1.1) tem sido utilizadas para aquisição de variáveis cinemáticas, sendo compostas por acelerômetros para medição da aceleração linear ( $\text{m}\cdot\text{s}^{-2}$ ), giroscópios para medição da velocidade angular ( $^{\circ}/\text{s}$ ) e magnetômetros triaxiais que mensuram o

campo magnético ( $\mu\text{T}$ ), integrados por algoritmos de fusão de sensores para determinação da orientação de movimento (ângulos de Euler – *pitch*, *roll*, *yaw*; quatérnions) (CHAMBERS *et al.*, 2015; CUST *et al.*, 2018; CAMOMILLA *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019). De forma simplificada, a fusão de sensores remete ao processo de combinação de dados de múltiplos sensores (ex.: acelerômetro, giroscópio, magnetômetro, barômetro etc.) com o objetivo de fornecer uma estimativa de orientação das UMI, denominados como “*Attitude Heading Reference Systems – AHRS*” (CAMOMILLA *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019).

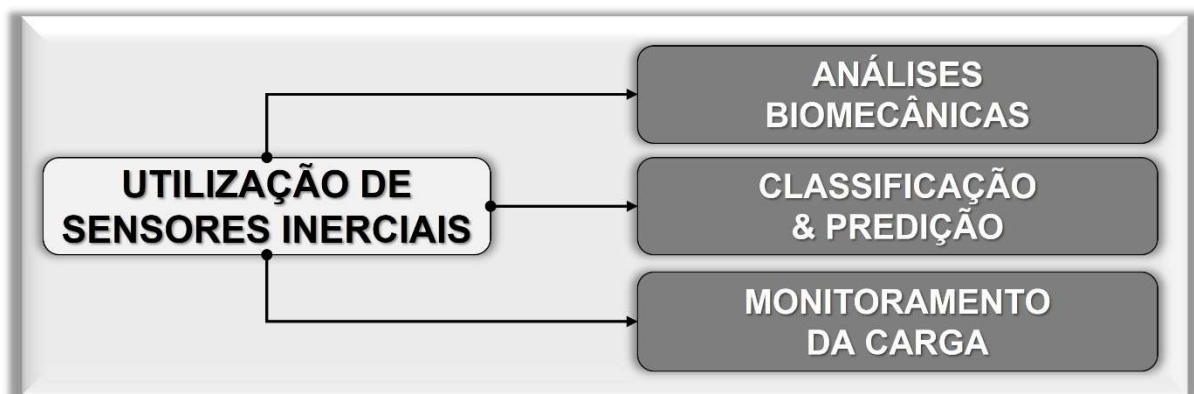
Figura 1.1 – Unidades de Medida Inercial: diferentes fabricantes e aplicações.



Fonte: Haladjian *et al.* (2020); <https://www.xsens.com/>; <https://sabellabs.com/>; <https://mbientlab.com/>; <https://motusglobal.com/>; <https://www.vicon.com/>.

A utilização de UMI tem se apresentado como uma área promissora, com possibilidades diversas nas ciências do esporte em diferentes ambientes de prática para: (1) análises biomecânicas com a finalidade de avaliação da técnica, condição física ou prevenção de lesões; (2) classificação ou reconhecimento de ações e predição de variáveis de desempenho por métodos de aprendizado de máquina; e (3) quantificação das demandas físicas de treinos e competições (CUST *et al.*, 2018; HALILAJ *et al.*, 2018; CAMOMILLA *et al.*, 2018; TWOMEY *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019). A figura 1.2 sintetiza a utilização de sensores inerciais nas ciências do esporte.

Figura 1.2 – Utilização de sensores inerciais nas ciências do esporte.



Fonte: Dados da Pesquisa.

Apesar de diversos estudos utilizarem os sensores inerciais vestíveis como ferramenta no monitoramento, há considerável controvérsia na literatura quanto a validade e confiabilidade de variáveis biomecânicas obtidas por meio de UMI no contexto da prática esportiva (CUST *et al.*, 2018; CAMOMILLA *et al.*, 2018; TWOMEY *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019). Logo, se os sensores inerciais se mostrarem válidos e confiáveis em diferentes contextos (ex.: saltos verticais, sprints e diversas ações comuns de locomoção realizadas em um circuito), um desafio que se coloca é a automatização do processo de reconhecimento de ações nos esportes coletivos por meio da UMI combinado a técnicas de aprendizagem estatística, que possui grande potencial para melhorar o monitoramento e controle das tarefas de treinamento prescritas, a partir de variáveis mecânicas.

### 1.1. Validade & Confiabilidade de Sensores Inerciais

Os sensores inerciais são caracterizados pela não dependência de satélites ou ambientes abertos para sua utilização, normalmente com representação tridimensional dos movimentos e amostragem oscilando entre 50Hz e 1KHz. Entretanto, tendo em vista a elevada proliferação de sensores vestíveis de baixo custo comercialmente disponíveis, a ampla utilização destes dispositivos sem o prévio estudo da validade e confiabilidade, pode levar a enganos e interpretações equivocadas em atividades com a finalidade de prevenção de lesões e melhora do desempenho esportivo (CARDINALE; VARLEY, 2017; CUST *et al.*, 2018; MALONE *et al.*, 2017; CAMOMILLA *et al.*, 2018; TWOMEY *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019). Logo, há a necessidade de escrutínio público por meio da análise da validade e confiabilidade da capacidade de estimação de variáveis biomecânicas por parte destes dispositivos, uma vez que os fabricantes em sua maioria não expõem essas características, em vista ao crescente número de estudos com sensores inerciais para quantificar ações nos esportes coletivos (WUNDERSITZ *et al.*, 2015b; MACDONALD *et al.*, 2017; CUST *et al.*, 2018; TWOMEY *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019).

Apesar dos sensores inerciais serem amplamente estudados em ambiente laboratorial, de forma geral, há escassez ou não há consenso por vários fatores entre estudos de verificação da validade e confiabilidade na estimação ou predição de variáveis cinemáticas e cinéticas, conforme verificado na análise de saltos verticais (PICERNO; CAMOMILLA; CAPRANICA, 2011; JAITNER *et al.*, 2016; SETUAIN *et al.*, 2016; SPANGLER *et al.*, 2018; RANTALAINEN *et al.*, 2018; RANTALAINEN; FINNI; WALKER, 2019), movimentos de mudanças de direção (TWOMEY *et al.*, 2019), sprints (SETUAIN *et al.*, 2018; GURCHIEK *et al.*, 2019), exercícios de musculação (BALSALOBRE *et al.*, 2015; SATO *et al.*, 2015; BROWN; BICHLER; ALT, 2015; ORANGE *et al.*, 2016; LAKE *et al.*, 2019), esportes individuais (FULTON; PYNE; BURKETT, 2009; DADASHI *et al.*, 2012; STAMM; JAMES; THIEL, 2013; SCHMIDT *et al.*, 2016), coletivos (AKINS *et al.*, 2015; WUNDERSITZ *et al.*, 2015b; GAGELER; WEARING; JAMES, 2015; MACDONALD *et al.*, 2017; BLAIR *et al.*, 2018; SKEJØ *et al.*, 2020) e esportes paralímpicos (MASON *et al.*, 2014; LEWIS *et al.*, 2019).

As divergências nos estudos de validação possivelmente podem ser atribuídas às (1) características dos sensores, tais como a faixa nominal de aceleração ( $g$ ), giroscópio

(°/s) perante a ação realizada (ações de maior intensidade podem solicitar faixa nominal maior), bem como a integração de um magnetômetro ao dispositivo para a conversão do sistema de referência do sensor para um sistema de referência global; (2) desenho experimental adotado, pois muitos protocolos não reportam ou não viabilizam a determinação da confiabilidade teste – reteste ou repetibilidade de protocolos de análises biomecânicas; (3) a medida de referência adotada no desenho experimental para estudo da validade do sensor (tapete de contato, plataforma de força, sistemas de análise 3D e *encoder linear*); (4) frequência de amostragem selecionada  $\leq 100\text{Hz}$ , frente a ações rápidas de curta duração; (5) condução ou não da conversão do sistema de referência do sensor para um sistema de referência global; (6) presença ou não de um filtro de Kalman para alisamento dos dados; (7) procedimentos adotados que podem levar a um viés de estimação de variáveis de desempenho (ex.: tempo de vôo vs. velocidade de saída do solo); o (8) local e orientação de posicionamento das UMI que pode levar a uma subestimação das forças de reação do solo no tempo (SETUAIN *et al.*, 2016; CAMOMILLA *et al.*, 2018; CUST *et al.*, 2018; PEAKE *et al.*, 2018; ROELL *et al.*, 2018; TWOMEY *et al.*, 2018; BLAIR *et al.*, 2018; ROELL *et al.*, 2019; RANTALAINEN; FINNI; WALKER, 2019; ADESIDA; PAPI; MCGREGOR, 2019; TAN *et al.*, 2019; SESHADRI *et al.*, 2019). Logo, há a necessidade de checagem e/ou determinação prévia da validade e confiabilidade das variáveis biomecânicas obtidas dos sensores disponíveis para análise biomecânicas, para assegurar a capacidade de compreensão de pesquisas e do processo de treinamento em diferentes situações de prática (TWOMEY *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019; CUST *et al.*, 2018; CAMOMILLA *et al.*, 2018).

## **1.2. Utilização de Sensores Inerciais & Métodos de Aprendizado de Máquina**

No contexto atual, a utilização de sensores inerciais tem sido associada ao emprego de algoritmos de aprendizado de máquina (*Machine Learning Algorithms* - MLA), devido ao grande volume de dados de aceleração linear, velocidade angular, campo magnético e ângulo de euler obtidos, colocando-se como um desafio às ciências do esporte (CARDINALE; VARLEY, 2017; CUST *et al.*, 2018; SIDEY-GIBBONS; SIDEY-GIBBONS, 2019). Dessa maneira, os MLA têm sido utilizados com a finalidade de automatização de tarefas sem que sejam programadas explicitamente (SIDEY-

GIBBONS; SIDEY-GIBBONS, 2019). Os MLA aprendem a partir de vetores de características de entrada para construção e validação de um modelo automatizado, e, posteriormente, execução de tarefas de classificação, para predição de classes de movimentos, ou regressão, para predição de valores discretos e contínuos (HASTIE; TIBISHIRANI; FRIEDMAN, 2017).

A construção de um modelo tem por objetivo encontrar um conjunto ótimo de parâmetros para descrição de uma função, e por fim, realizar predições a partir de novos dados de entrada. Os algoritmos de treinamento em aprendizagem estatística podem ser denominados como: aprendizado supervisionado (I), onde o vetor de variáveis de entrada e os rótulos da respectiva saída são conhecidos; aprendizado não – supervisionado (II), em que as saídas do conjunto de variáveis de entrada são desconhecidas; aprendizado semi – supervisionado (III), decorrente da combinação dos dois paradigmas anteriores para formação do banco de dados; e aprendizagem por reforço (IV) consistindo no treinamento de MLA para tomar uma sequência de decisões em ambientes complexos (JAMES *et al.*, 2013; HASTIE; TIBISHIRANI; FRIEDMAN, 2017; CUST *et al.*, 2018; SIDEY-GIBBONS; SIDEY-GIBBONS, 2019).

Neste contexto, o termo detecção refere-se a localização automática de uma tarefa – alvo (ex.: chutes no futebol, golpes no tênis de mesa, etc.) e a classificação consiste no reconhecimento de diferentes tarefas automaticamente (ex.: diferenciação entre passes e chutes no futebol; movimentos de *forehand*, *backhand* no tênis, etc.), envolvendo interpretações adicionais para determinação de categorias específicas dos movimentos identificados (CUST *et al.*, 2018; HALILAJ *et al.*, 2018; TWOMEY *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019). Logo, UMI associados a algoritmos computacionais tem sido utilizadas para detecção e classificação de atividades diárias (BROOKE *et al.*, 2016), exercícios de musculação (O'REILLY *et al.*, 2017; LAKE *et al.*, 2019), esportes individuais (BLANK *et al.*, 2015; SCHULDHAUS *et al.*, 2015; WHITESIDE *et al.*, 2017), coletivos (WUNDERSITZ *et al.*, 2015b; KAUTZ *et al.*, 2017; MACDONALD *et al.*, 2017), bem como ferramentas de avaliação de saltos (PICERNO; CAMOMILLA; CAPRANICA, 2011; SETUAIN *et al.*, 2016), sprints (SETUAIN *et al.*, 2018; GURCHIEK *et al.*, 2019), configurando – se como uma nova área de investigação na biomecânica do esporte (ADESIDA; PAPI; MCGREGOR, 2019). Para avaliar o desempenho de detecção e classificação dos algoritmos empregados nestes estudos, as métricas utilizadas remetem à taxa de classificações corretas obtidas pelo algoritmo classificador (acurácia), a proporção de resultados positivos que são de fato

positivos (precisão), proporção de resultados positivos verdadeiros corretamente identificados (sensibilidade) e a proporção de resultados negativos corretamente identificados (especificidade) (HALILAJ *et al.*, 2018; SIDEY-GIBBONS; SIDEY-GIBBONS, 2019).

Nos últimos anos, alguns experimentos conduzidos nos esportes coletivos têm alcançado êxito em classificar corretamente atividades envolvendo caminhada, *jogging*, corrida, saltos, *sprints* diferentes tipos de dribles e arremessos no basquetebol (NGUYEN *et al.*, 2015; HOLZEMANN; LAERHOVEN, 2018; EGGERT, MUNDT, MARKERT, 2020), passes, chutes e ações de defesa de goleiros no futebol (SCHULDHAUS *et al.*, 2015; HALADJIAN *et al.*, 2020), ações de saque, diferentes tipos de toque, ataque e bloqueio no voleibol (KAUTZ *et al.*, 2017; WANG *et al.*, 2017), diferentes tipos de lançamento no handebol (TILAAAR; BHANDURGE; STEWART, 2020) e contatos no rugby (KELLY *et al.*, 2012).

Entretanto, os experimentos citados anteriormente apresentaram limitações quanto a especificidade e características das tarefas, sendo realizadas predominantemente de forma descontextualizada à prática dos esportes coletivos, o que em hipótese, pode comprometer o processo de classificação de ações de forma acurada na prática. Adicionalmente, as variáveis de entrada extraídas nestes estudos para treinamento e validação dos algoritmos de classificação são estritamente de ordem estatística (ex.: média, desvio padrão, mínimo, máximo, curtose, etc). Entretanto, as melhores práticas para construção de modelos de MLA direcionam para combinação de características extraídas a partir dos dados (variáveis estatísticas) com aquelas que apresentem significado e potencial de discriminação para os movimentos estudados, sendo, portanto, fundamental a etapa de pré-processamento dos dados (HALILAJ *et al.*, 2018; CAMOMILLA *et al.*, 2018).

Nesse sentido, há a necessidade de mais estudos nos esportes coletivos que, além de verificar a validade e confiabilidade destes dispositivos, avaliem a utilização de UMI para classificação de ações nos esportes coletivos por métodos de aprendizado de máquina no processo de treinamento. Apesar de ser uma tarefa desafiadora devido a elevada variabilidade nas ações realizadas nos esportes coletivos durante treinos e jogos, a detecção e classificação de movimentos pode fornecer um registro sobre de ações realizadas com o decorrer dos dias, semanas e meses, que pode ser empregado para planejamento de sessões de treinamento posteriores (HOLZEMANN; LAERHOVEN, 2018; GILES; KOVALCHIK; REID, 2019; HALADJIAN *et al.*, 2020).

Além disso, a utilização de UMI isoladamente representa uma alternativa possível e de baixo custo para classificação de movimentos por MLA comparado aos dispositivos GPS/LPS instrumentados com sensores inerciais, ou ainda a sistemas de análise cinemática tridimensional (CUST *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019).

### 1.3. Utilização de Sensores Inerciais para Monitoramento das Demandas Físicas nos Esportes Coletivos

Os sensores inerciais têm sido empregados como instrumento de monitoramento para capturar o perfil de atividades de locomoção de atletas nos esportes coletivos (marcha, corrida em intensidade leve, moderada, mudanças de direção, saltos e *sprints*). O registro da intensidade das acelerações remete ao custo metabólico das ações realizadas, por outro lado, a intensidade das desacelerações representa a demanda física imposta, no qual, magnitude elevadas de impacto podem levar a um maior dano nas estruturas teciduais da unidade músculo–tendínea, caso estas forças não possam ser atenuadas de forma adequada. Um incremento nas variáveis que remetem a acelerações e desacelerações em alta intensidade está associada à diminuição da capacidade de desempenho neuromuscular e indicadores de dano muscular após a execução da tarefa, logo, diferentes métricas têm sido propostas e quantificadas para tal finalidade (HARPER; CARLING; KIELY, 2019; HADER *et al.*, 2019; TORRES-HONDA *et al.*, 2022).

A acelerometria é um método recente utilizado para quantificar das demandas físicas. Dentre estas propostas, os respectivos fabricantes de dispositivos GPS com UMI associadas propuseram métodos para mensurar a demanda física de treino desenvolvida por atletas por meio da quantificação da soma dos vetores de aceleração, denominadas como “*player load*” (PL), “*body load*” ou “*accumulation load*”. A variável “*player load*” com algumas variações, é definida como a taxa instantânea de alteração da aceleração linear (Equação 1), expressa em unidades arbitrárias.

$$PL(t) = \frac{\sqrt{(ac_{y(t)} - ac_{y(t-1)})^2 + (ac_{x(t)} - ac_{x(t-1)})^2 + (ac_{z(t)} - ac_{z(t-1)})^2}}{100} \quad \text{Equação 1}$$

A variável “*player load*” e suas derivações têm sido amplamente empregadas para entender demandas físicas em modalidades esportivas em ambientes fechados, como

no handebol (LUTEBERGET; SPENCER, 2017; LUTEBERGET; TROLLERUD; SPENCER, 2017; WIK; LUTEBERGET; SPENCER, 2017), basquetebol (FOX *et al.*, 2017), voleibol (VLANTES; READDY, 2017), dentre outras. Entretanto, conceitos difusos, métodos divergentes e instrumentos de empresas diversas, dificultam o estabelecimento de comparações entre achados obtidos em pesquisas e na prática, direcionando para a necessidade de unificação conceitual (GÓMEZ-CARMONA *et al.*, 2020).

Adicionalmente, por definição, a variável “*player load*” (PL) não está diretamente relacionada com a magnitude da aceleração, fato que limita o potencial de monitoramento das demandas físicas, uma vez que, atletas com acelerações diferentes, mas com alterações similares da mesma, apresentam escores similares para a variável “*player load*”. Logo, variáveis que manifestam a magnitude ou intensidade das acelerações, tempo nas zonas de acelerações, desacelerações, impactos, frequência de ações específicas, podem possuir melhor potencial para descrever as demandas físicas impostas em treinos e competições (GÓMEZ-CARMONA *et al.*, 2020; BREDT *et al.*, 2020; BURLAND *et al.*, 2020). Em detrimento, métodos bem estabelecidos para análise da intensidade do sinal como a raiz quadrada da média dos quadrados ( $Acel_{RMS}$ , “*root mean square*” – RMS por eixo, equação 2) (FIGLIOLA; BEASLEY, 2007) e o cômputo da norma da aceleração medida (aceleração resultante tridimensional,  $acel_{res}$ , aceleração resultante horizontal,  $acel_{hor}$ ; e aceleração resultante vertical  $acel_{vert}$ , Equações de 3 a 5) têm sido preteridos em relação a métricas como a PL em grande parte dos estudos. A variável  $ac_x$  representa o eixo vertical,  $ac_y$  o eixo látero – lateral e  $ac_z$  ântero – posterior.

$$Acel_{RMSx} = \sqrt{\frac{\sum_{i=1}^n ac_{x(i)}^2}{N}} \quad \text{Equação 2}$$

$$acel_{res} = \sqrt{ac_{x(i)}^2 + ac_{y(i)}^2 + ac_{z(i)}^2} \quad \text{Equação 3}$$

$$acel_{hor} = \sqrt{ac_{y(i)}^2 + ac_{z(i)}^2} \quad \text{Equação 4}$$

$$accel_{vert} = \sqrt{ac_{x(i)}^2} \quad \text{Equação 5}$$

Wundersitz *et al.* (2015a) estudaram a validade de um acelerômetro para medição de impactos (picos de aceleração) nos esportes coletivos comparado a um sistema de análise cinemática tridimensional, por meio de um circuito simulado de atividades envolvendo saltos verticais, mudanças de direção, colisões, marcha, corrida leve e *sprints*, realizado com indivíduos saudáveis. O acelerômetro subestimou a aceleração de pico durante colisões e saltos (erro sistemático médio de -0,06g a -0,18g;  $d = -0,06$  a -0,2), superestimou para as ações de marcha, corrida leve, mudanças de direção e *sprints* (erro sistemático médio de 0,03g a 0,14g;  $d = 0,05$  a 0,24), com precisão (CV%) oscilando de 3,7% a 6,9%, quando comparado à medida de referência. Logo, os achados indicaram que o acelerômetro quando filtrado (filtro *butterworth*, passa – baixa, frequência de 12Hz), mostrou nível aceitável de concordância, contudo dependente do tipo de ação executada.

Por outro lado, Roell *et al.* (2018) avaliaram a validade de UMI para medir a magnitude da aceleração de pico e média em ambiente fechado em movimentos específicos nos esportes coletivos, comparado a um sistema de análise cinemática tridimensional. Nesse sentido, o filtro passa – baixa para correção da gravidade sobre os dados de aceleração e dois algoritmos de fusão de sensores (filtro de Kalman e complementar) para estimação da orientação foram comparados com a análise cinemática 3D, evidenciando diferenças significativas entre os dados filtrados e a referência ( $p < 0,05$ ), mas não entre os algoritmos estudados. Adicionalmente, uma maior precisão e baixo erro relativo foram encontrados para os algoritmos de fusão de sensores (Filtro complementar, RMSE = 0,05; CV% = 2,6%; Filtro de Kalman, RMSE = 0,15; CV% = 3,8%) em relação aos dados filtrados (Filtro passa – baixa, RMSE = 1,14; CV% = 47,6%) considerando a magnitude do vetor resultante, direcionando fortemente a implementação da estimação da orientação para descrição acurada da aceleração. Além disso, os achados mostraram que as UMI posicionadas entre as escápulas podem adequadamente ser aplicadas para monitoramento em esportes coletivos em ambiente fechado, com potencial para acuradamente quantificar acelerações e desacelerações com validade aceitável, nos eixos “x”, “y” e “z”.

Em estudo complementar, Roell *et al.* (2019) buscaram determinar se técnicas de processamento de dados e demandas esportivas específicas podem influenciar a

validade da aceleração medida por UMI, comparada a um sistema de análise cinemática tridimensional. A magnitude da aceleração de pico e média foram obtidos a partir de dois algoritmos de fusão de sensores (filtro de Kalman e Complementar) em diferentes amostragens de 5Hz, 10Hz e 100Hz. O algoritmo de fusão de sensores a partir do filtro de Kalman superestimou os valores de aceleração resultante para a aceleração média ( $0,42 \pm 0,31 \text{ m.s}^{-2}$ ) e de pico ( $4,18 \pm 0,31 \text{ m.s}^{-2}$ ), enquanto para o filtro complementar de  $0,57 \pm 0,41 \text{ m.s}^{-2}$  e  $-2,31 \pm 2,25 \text{ m.s}^{-2}$ , respectivamente. Por outro lado, a adoção do procedimento de reamostragem (*downsample*) de 100Hz para 5Hz evidenciou uma diminuição do erro absoluto de 14% para aceleração média e 56% para aceleração de pico. Em suma, os resultados obtidos direcionam que as UMI podem ser utilizadas para medição das acelerações em esportes coletivos com níveis aceitáveis. Logo, Roell *et al.* (2018) e Roell *et al.* (2019) indicam a necessidade de utilização de algoritmos de fusão de sensores e procedimentos de reamostragem (*downsample*) para diminuição dos erros absolutos.

De forma alternativa, Waldron *et al.* (2021) analisaram a validade e confiabilidade um modelo comercial de sensor inercial aderido aos pés para com três modelos de GPS para medição de variáveis de deslocamento, velocidade, aceleração e a contagem de acelerações e desacelerações, durante a execução de um circuito simulado de atividades no futebol. As variáveis cinemáticas foram obtidas por meio da detecção da fase de marcha ou corrida por métodos de aprendizado de máquina, pela dupla integração da aceleração, utilizando o filtro de Kalman para alisamento dos dados através do qual o algoritmo de atualização “zero – velocity updates” (ZUPT) utilizado para calibrar o sensor (COYTE *et al.*, 2013; MA *et al.*, 2018a; LU *et al.*, 2019; YU *et al.*, 2019). O sensor superestimou significativamente em relação aos dispositivos GPS para as variáveis de distância total, distâncias percorridas nas zonas de velocidade (< 1,5 m/s; 1,5 a 3,5 m/s; 3,51 a 5,5 m/s), velocidade média, picos de aceleração e desaceleração, bem como um maior número de mudanças de velocidade de alta intensidade, entretanto, os sensores são confiáveis e não há diferenças significativas entre UMI. Uma vez que são evidenciadas diferenças entre UMI e dispositivos GPS, há a necessidade de estudo da validade dos sensores perante medidas–critério (análise cinemática tridimensional). A utilização desta metodologia de correção do *drift* de integração numérica pode apresentar-se como uma alternativa viável, especialmente para monitoramento e prescrição em ambientes fechados, quando fundamentadas em estudos de validação de critério.

Outro aspecto a ser considerado reside na necessidade de consideração das redundâncias entre as variáveis. Frequentemente, treinadores e comissões técnicas se veem desafiadas pela imensa quantidade de variáveis e dados obtidos e acumulados por meio de sensores vestíveis, carecendo de um rápido processamento, interpretação sobre a demanda física desenvolvida por atletas em treinos e competições. Logo, neste cenário, a capacidade de síntese sobre os dados obtidos é de vital importância na gestão de equipes e comunicação eficaz entre membros da comissão técnica, sendo agravado pelos sistemas de competições adotados, seja pela redução de custos ou maximização de receitas. Logo, fica evidente a necessidade de remoção da característica de multicolinearidade presente entre as variáveis quantificadas por meio de técnicas estatísticas multivariadas, onde novas variáveis não correlacionadas são construídas a partir das variáveis originais (WEAVING *et al.*, 2017a; TORRES-HONDA *et al.*, 2022).

Por outro lado, apesar de Owen *et al.* (2017) também identificarem a problemática de aquisição de muitas variáveis e sua respectiva compreensão de forma isolada, com a pretensão de fornecer escores de intensidade e volume em partidas de futebol por meio da combinação de variáveis obtidas das sessões de treino (distância total, corrida em alta velocidade, distâncias percorridas em *sprints*, acelerações, desacelerações). Entretanto, estes autores desconsideraram o problema de colinearidade entre as variáveis, potencialmente presentes nestes escores de volume e intensidade (WEAVING; READ, 2022).

Logo, acerca dos apontamentos, reflexões e estudos levantados, o presente estudo buscou avançar sobre a literatura existente por meio da análise da validade e confiabilidade do uso de sensores inerciais de baixo custo para avaliação do desempenho de saltos verticais e *sprints* (Experimento I – Capítulo 2), investigar suas características de acurácia, precisão, sensibilidade e especificidade para classificação de ações comuns aos esportes coletivos (Experimento II – Capítulo 3) e evidenciar a abordagem de monitoramento de competições por UMI, baseando-se no emprego da estratégia de redução da dimensionalidade e utilização dos escores produzidos para avaliação do desempenho (Experimento III – Capítulo 4).

## CAPÍTULO 2 – UTILIZAÇÃO DE SENSORES INERCIAIS PARA ANÁLISE DO DESEMPENHO DE SALTOS VERTICAIS E SPRINTS (EXPERIMENTO I)

### 2.1. Introdução

A análise do desempenho físico - esportivo constitui-se como parte essencial do processo de treinamento. Nesse sentido, a análise da capacidade de produção de força e potência de membros inferiores tem sido associada diretamente ao desempenho de saltos verticais e *sprints* (MORIN; SAMOZINO, 2016; MORIN; SAMOZINO, 2018; SAMOZINO *et al.*, 2021). O desempenho das tarefas de saltos verticais e *sprints* é comumente avaliado por instrumentos tipicamente laboratoriais, medidas – critério, tais como plataformas de força (PF) e sistemas de análise cinemática tridimensional, produzindo medidas válidas e confiáveis para variáveis cinemáticas e cinéticas. Todavia, frequentemente há a necessidade de avaliação do desempenho de saltos e *sprints* durante a rotina de treinos e competições de vários indivíduos, requerendo a implementação de instrumentos de baixo custo e portáteis, tais como sensores inerciais vestíveis (SETUAIN *et al.*, 2016; RANTALAINEN *et al.*, 2018; RANTALAINEN *et al.*, 2019). Logo, há a necessidade prévia de avaliação da validade e confiabilidade destes instrumentos dada sua proliferação, principalmente por parte dos fabricantes que devem levar ao conhecimento da comunidade científica os resultados obtidos para análise, uma vez que tem sido identificado que apenas 5% dos sensores vestíveis disponíveis comercialmente têm sido formalmente validados (CAMOMILLA *et al.*, 2018; PEAKE; KERR; SULLIVAN, 2018; ADESIDA; PAPI; MCGREGOR, 2019).

#### 2.1.1. Saltos Verticais Padronizados

A análise da validade de critério e confiabilidade do desempenho de saltos verticais por sensores inerciais tem sido analisada por diferentes estudos, porém sem consenso para as variáveis biomecânicas mensuradas (PICERNO; CAMOMILLA; CAPRANICA, 2011; SETUAIN *et al.*, 2016; STAUNTON *et al.*, 2018; SPANGLER *et al.*, 2018; RANTALAINEN *et al.*, 2018). Em parte, além das características de amostragem e componentes dos sensores, as divergências decorrem da adoção ou não do procedimento de correção do sistema de referência do sensor para global dos

dados de aceleração para os sensores posicionados no quadril ou tronco, o método de estimação da altura de salto baseado no tempo de voo ou velocidade de saída do solo, bem como o local e orientação do posicionamento de UMI, que podem resultar na subestimação das forças de reação do solo no tempo. Surpreendentemente, estes experimentos não necessariamente reportam a confiabilidade teste – reteste (repetibilidade), tanto para as medidas referência (ex.: plataforma de força, *encoder* linear, sistemas de análise cinemática tridimensional), como para os sensores inerciais testados, característica fundamental a ser evidenciada para adoção destes últimos à rotina diária de treinamento (PICERNO; CAMOMILLA; CAPRANICA, 2011; SETUAIN *et al.*, 2016; STAUNTON *et al.*, 2018; SPANGLER *et al.*, 2018; RANTALAINEN *et al.*, 2018; TAN *et al.*, 2019; ADESIDA; PAPI; MCGREGOR, 2019). Adicionalmente, Rantalainen *et al.* (2018) avaliaram a validade concorrente de UMI para com um tapete de contato, na determinação da altura de salto vertical por meio tempo de voo e da velocidade de saída do solo. Os autores verificaram que o sensor superestimou significativamente o registro da altura de salto vertical em ambos os métodos de estimação. Em adição, uma concordância razoável entre métodos de medição foi observada para altura de salto determinada a partir da velocidade de saída do solo, e, quando computada pelo tempo de voo, evidenciou um nível excelente de concordância entre instrumentos, acompanhada por uma boa congruência entre os métodos de estimação da altura de salto. Logo, concluiu-se que as estimativas obtidas destes instrumentos diferem entre si e não podem ser utilizados intercambiavelmente. Porém, o sensor testado exibiu excelente concordância com o tapete de contato (medida concorrente) quando a altura é estimada pelo método do tempo de voo. Nesse sentido, concluiu-se que o método tempo de voo é preferível para o uso de UMI na estimação da altura de saltos padronizados.

No entanto, em relação ao estudo anterior, Rantalainen; Finni; Walker (2019) exploraram se um novo método baseado na aceleração global para refinamento da estimativa do tempo de voo e respectiva determinação da altura de saltos verticais, para minimizar o erro sistemático entre um modelo de sensor inercial (NGIMU, x-io, Bristol, Reino Unido) e um tapete de contato, com a finalidade de proporcionar um tutorial a pesquisadores. O refinamento do método para estimar a altura de salto pelo tempo de voo a partir da aceleração global mostrou excelente concordância e confiabilidade intra – sessão para com o tapete de contato. Entretanto, fornecer um tutorial para uso de UMI para esta finalidade pressupõe a avaliação da validade do

algoritmo contra diferentes medidas critério, além da determinação da confiabilidade teste – reteste (repetibilidade), haja vista a necessidade de emprego com elevada frequência, utilizando modelos de sensores de baixo custo (< 100 dólares) diferentes dos empregados no estudo de Rantalainen; Finni; Walker (2019), ou seja, a reprodutibilidade da ferramenta disponibilizada.

### 2.1.2. Sprints

Haja vista que o desempenho de saltos verticais padronizados está relacionado frequentemente ao desempenho de *sprints* (MORIN; SAMOZINO, 2016; PALLIS; MCNITT-GRAY; HUNG, 2019; SAMOZINO *et al.*, 2021), uma questão que se coloca é se o monitoramento e controle das demandas físicas impostas em treinamentos pode ser conduzido por meio de UMI. Tradicionalmente, a avaliação de *sprints* requer considerável investimento de recursos financeiros para aquisição de instrumentos laboratoriais, exigindo recursos humanos treinados (ex.: sistemas de análise cinemática 3D, múltiplas plataformas de força alinhadas, radares, esteiras instrumentadas com plataformas de força geralmente restritos), ou ainda em campo por meio de GPS, fotocélulas e *encoders* rotatórios. Nesse contexto, a validade e confiabilidade de uso dos sensores inerciais tem sido analisada como uma alternativa para análise do desempenho de *sprints*, considerando as vantagens de portabilidade, baixo custo e versatilidade de uso dos sensores inerciais (BERGAMINI *et al.*, 2013; SCHIMIDT *et al.*, 2016; SETUAIN *et al.*, 2017; GURCHIEK *et al.*, 2018; APTE *et al.*, 2020).

Para a saída baixa de *sprints*, Bergamini *et al.* (2013) avaliaram a validade de utilização de UMI para as variáveis de inclinação do tronco e velocidade angular no plano sagital comparado com um sistema de análise cinemática. A UMI posicionada na região lombar indicou elevada concordância ( $r > 0,99$ ; RMSE < 7 graus) para as variáveis de deslocamento e velocidade angular, suportando a possibilidade de utilização por técnicos diretamente em campo para análise da técnica de saída baixa em provas de velocidade no atletismo.

Por outro lado, Setuain *et al.* (2017) avaliaram se UMI posicionadas na região lombar reportam variáveis cinéticas de forma válida e confiável comparada a uma plataforma de força, durante *sprints* de 20 metros. Apesar de níveis significativos dos coeficientes de correlação ( $r=0,88$ ), concordância (CCC = 0,87 a 0,88) e de regressão ( $b = 0,94$  a 1,01,  $p<0,05$ ) para os valores médios de forças de reação do solo (componentes

horizontal e vertical), ligeiras tendências de discrepância entre os métodos de medição foram evidenciadas (Componente Horizontal,  $b = 0,14$ ,  $p < 0,001$ ; Componente vertical,  $b = 0,08$ ,  $p = 0,002$ ) conforme os gráficos de dispersão de “Bland – Altman”, em que valores maiores evidenciaram divergências crescentes. No entanto, não foram evidenciadas discrepâncias para as variáveis de potência máxima, força máxima, velocidade máxima e perda de aplicação de força horizontal ( $b = 0,17$  a  $-0,23$ ,  $p > 0,05$ ), apresentando alta concordância ( $ccc = 0,76$  a  $0,97$ ), associação ( $r = 0,81$  a  $0,97$ ) e com coeficiente de regressão elevados e significativos entre métodos de medição ( $b = 0,65$  a  $0,93$ ,  $p < 0,05$ ). Adicionalmente, um grau elevado a muito elevado do CCI foi verificado para as variáveis de desempenho de *sprints* (CCI =  $0,88$  a  $0,95$ ) para as UMI. Por fim, os sensores testados mostraram validade e confiabilidade adequadas para estimação de variáveis cinemáticas e cinéticas em *sprints* de 20 metros.

Adicionalmente, Gurchiek *et al.* (2018) avançaram sobre a implementação de um algoritmo adaptativo de filtragem para estimar a velocidade de *sprints* de 40 metros, empregando um sensor inercial alocado na porção lombar, baseado no uso do filtro de Kalman, correção da orientação e da velocidade estimada (máxima e média). Os autores avaliaram reportaram a validade concorrente de estimação da velocidade média e de pico por UMI, onde para o pico de velocidade e velocidade média (intervalo de 10 metros) foram verificadas alterações sistemáticas significativas pelos sensores, quando comparado a fotocélulas. Logo, o método proposto para correção do *drift* de integração, proveniente de uma patente (PERKINS; MCGINNIS, 2015), sugere a possibilidade de utilização de UMI para determinar a velocidade em tarefas de *sprints*. A partir de dados preliminares, Parrington *et al.* (2016) analisaram a validade de UMI contra um radar laser de velocidade (medida critério) durante a realização de *sprints* de 100 metros. Os resultados obtidos mostraram elevada correlação entre instrumentos para o pico de velocidade e valores de velocidades parciais registrados a cada 10 metros e baixo erro padrão de estimação. Adicionalmente, Apte *et al.* (2020) propuseram um método flexível baseado na fusão de dispositivos (*Global Navigation Satellite System* – GNSS e UMI) para estimar a velocidade instantânea durante *sprints*, posicionado entre as escápulas. Para validação do método para determinação da velocidade e duração de *sprints*, os sensores foram comparados a um radar (velocidade) e fotocélulas (duração) como referência. Os resultados mostraram que a mediana da raiz quadrada da média dos quadrados dos erros para a estimação velocidade que oscilou de 6,14% a 8,11% e a duração de *sprints* de 0,1 a -6,0%.

Nesse sentido, uma concordância entre os valores estimados e de referência da velocidade máxima foi verificada, logo, os autores concluíram que o algoritmo proposto foi válido para descrever a velocidade e duração para testes de *sprints*.

Para além da necessidade de estudo da validade dos sensores inerciais disponíveis, apesar da indicação de utilização prática na perspectiva de análise da condição física em tarefas de *sprints* pelos estudos reportados, como já destacado, dada sua importância para o monitoramento e controle da demanda imposta em treinamento, a confiabilidade entre dias (repetibilidade) não tem sido quantificada para as variáveis cinemáticas e cinéticas estimadas para os respectivos sensores. Adicionalmente, variáveis biomecânicas tais como a magnitude de impactos (pico de aceleração linear vertical), fundamental na perspectiva da biomecânica preventiva, ou ainda o pico de velocidade, para análise da condição física, não tem recebido a atenção devida nos estudos de validação de UMI para a tarefa de *sprints*.

Logo, a partir dos argumentos, reflexões e críticas apresentadas, neste experimento inicial, a validade e confiabilidade do uso de sensores inerciais vestíveis de baixo custo foi testada para avaliação de saltos verticais e *sprints*.

## 2.2. Objetivos

Analisar a validade (concordância entre métodos de medição) e confiabilidade teste – reteste (consistência de medida entre dias) de uso de UMI, comparado a dispositivos de referência para: (A) Saltos verticais padronizados – UMI contra uma plataforma de força e um *encoder* linear para estimação do tempo de voo, altura de salto e impulso; e (B) *Sprints* de 30 metros – UMI contra um *encoder* rotatório (*Race Encoder* - RE) para estimação da velocidade média e máxima de corrida.

## 2.3. Hipoteses

H1 – Os sensores inerciais apresentarão concordância e de boa a excelente repetibilidade teste–reteste na determinação de variáveis biomecânicas (tempo de voo, altura de salto e impulso) nos saltos padronizados comparado à plataforma de força e *encoder linear*.

H2 – Os sensores inerciais e o dispositivo *Race Encoder*® mostrarão concordância e boa repetibilidade teste–reteste para determinação da velocidade máxima e média nos *sprints* de 30 metros.

## **2.4. Materiais & Métodos**

### *2.4.1. Delineamento do estudo*

Este estudo realizado foi do tipo experimental e de validação de critério e concorrente (HOPKINS, 2000; CURREL; JEUKENDRUPP, 2008; FRENCH; RONDA, 2021), de um modelo de sensor inercial de baixo custo comparado a medidas – critério e concorrente (plataforma de força e encoder linear – saltos verticais; *race encoder* – *sprints*). Os participantes recrutados foram submetidos aleatoriamente à realização de testes de saltos padronizados (SA, SCM) e *sprints*, separadamente. As atividades foram realizadas com a finalidade de obtenção das variáveis cinemáticas e cinéticas a partir dos sensores inerciais vestíveis simultaneamente ao registro referente à plataforma de força e encoder linear (saltos padronizados) e ao uso do *race encoder* (*sprints*).

### *2.4.2. Cuidados éticos*

Este estudo foi submetido e aprovado junto ao comitê de ética em pesquisa local (CAAE 38365620.3.0000.5149) e foi realizado em conformidade com as normas estabelecidas pelas resoluções 466/2012 e 510/16 do Conselho Nacional em Saúde. Os voluntários foram informados quanto aos objetivos, métodos, possíveis riscos e benefícios oriundos da participação no estudo. Em seguida, o consentimento foi recolhido por escrito por intermédio de um Termo de Consentimento Livre e Esclarecido (TCLE, Apêndice A) e/ou Termo de Assentimento Livre e Esclarecido (TALE, Apêndice B), sendo facultado aos voluntários o direito de deixar de participar do estudo a qualquer momento, sem qualquer prejuízo.

### *2.4.3. Amostra*

Para realização do estudo, foram recrutados atletas de ambos os sexos engajados em regime de treinamento regular em provas de saltos e velocidade, na modalidade de atletismo, durante o calendário competitivo. Os indivíduos selecionados não possuíam diagnóstico prévio e não se encontravam em situação de tratamento agudo

ou crônico de lesões músculo-tendíneas. Os atletas amadores foram selecionados e recrutados conforme a conveniência do pesquisador, sendo oriundos do projeto de desenvolvimento de atleta de base do Centro de Treinamento Esportivo da Universidade Federal de Minas Gerais (CTE-UFMG), por intermédio da obtenção de autorização prévia para realização das atividades experimentais junto à direção e treinadores. A tabela 1.1 descreve os indivíduos recrutados respectivamente às tarefas realizadas.

Tabela 1.1 – Descrição da amostra.

| Tarefa         | Tamanho | Idade [anos] | Massa [kg] | Estatura [cm] | Especialidade                                                                                               |
|----------------|---------|--------------|------------|---------------|-------------------------------------------------------------------------------------------------------------|
| SA e SCM       | N=20    | 17,35±2,28   | 60,99±8,87 | 169,30±9,30   | Atletismo (8 saltadores e 12 velocistas – Saltos verticais; 8 saltadores e 11 velocistas - <i>Sprints</i> ) |
| <i>Sprints</i> | N=19    | 17,42±2,32   | 61,45±8,66 | 169,74±9,35   |                                                                                                             |

#### 2.4.4. Instrumentos


##### 2.4.4.1. Unidades de Medida Inercial

No presente estudo foi empregado um modelo de sensor inercial de baixo custo (WT901SDCL, Wit - Motion, Shenzhen, China), selecionado considerando as necessidades de aplicação, coleta, armazenamento e transferência de dados (JAMES; PETRONE, 2016). O sensor permite o uso em ambiente laboratorial e contextual a prática (*offline*), sem a necessidade de conexão com *internet* ou custeio para descarregamento de dados. O equipamento é composto por um acelerômetro (x, y, z; ±16 g), giroscópio (x, y, z; ±2000°/s) e magnetômetro (x, y, z; ±4900µT) triaxiais (MPU-9250, TDK Invensense, San Jose, California, EUA). O registro *wireless* é realizado a uma taxa de amostragem de 200Hz e o armazenamento de dados é efetuado em micro-cartão de memória (SDHC I, classe 10, A1, 80mb/s de velocidade e 16gb de capacidade). Adicionalmente, o sensor possui a função “*timestamp*” para registro de data e hora de realização de coletas de dados.

O sensor inercial WT901SDCL (Figura 2.1.) é integrado a microprocessadores de desempenho elevado e associado ao uso de um filtro dinâmico de Kalman, que reduz a magnitude do ruído melhorando a acurácia de medida. O consumo corrente é menor que 40mA/h sendo alimentado por uma bateria de lítio recarregável de 260mA/h e tensão operacional de 3,7V. A calibração, carregamento e configuração dos

parâmetros do sensor WT901SDCL foi efetuado por meio de um cabo USB conexo a um computador, por meio do software MIMU® (Wit - Motion, Shenzhen, China). O acelerômetro foi calibrado de forma estática com 1g ( $g=9,81 \text{ m.s}^{-2}$ ) e o magnetômetro pelo método elipsóide através da movimentação contínua do sensor em torno dos eixos “x”, “y” e “z”. O giroscópio é calibrado automaticamente com a calibração através do software MIMU®. Os dados brutos para aceleração linear ( $g$ ), velocidade angular ( $^{\circ}/s$ ), campo magnético ( $\mu T$ ), ângulo de euller (eixos “x”, *pitch*; “y”, *roll*; “z”, *yaw*), quatérnions ( $q_0$ ,  $q_1$ ,  $q_2$  e  $q_3$ ) e o registro de data e hora das coletas (função “*time-stamp*”) foram armazenados em microcartão de memória, sendo descarregados por meio do software disponibilizado pelo fabricante

Figura 2.1 - (A) Unidade de medida inercial AHRS (*Attitude Heading Reference System*) WT901SDCL; (B) Acionamento do sensor por meio da inserção do microcartão de memória para coletas; (C) Plataforma de força triaxial AMTI, OR5-6 (Watertown, Massachusetts, EUA); (D) Dispositivo do tipo encoder linear para medição das variáveis cinemáticas e cinéticas.



Fonte: [www.amti.biz](http://www.amti.biz); <https://chronojump.org/>.

#### 2.4.4.2. Plataforma de Força

Na análise das tarefas de saltos verticais propostas foi empregado uma plataforma de força (PF) triaxial AMTI - OR5/6® a uma taxa de amostragem de 1KHz (eixo “X” – látero – lateral; eixo “Y” – ântero – posterior; “Z” – superior - inferior; Advanced Mechanical Technology Inc, Watertown, Massachusetts, EUA), como medida padrão – ouro para medição das forças de reação do solo no tempo (Figura 2.1). A PF é conexo a um conversor analógico-digital e este é ligado a uma placa de aquisição de

dados multifuncional (*Data Translation* DT9826 series, 16 canais, Measurement Computing Corporation, Norton, Massachussets, EUA), em interface com um computador por intermédio de um cabo USB. Os dados foram adquiridos por intermédio do software *DASYLab* 11.0 (*DASYLab* - Data Acquisition System Laboratory, Measurement Computing Corporation, Norton, Massachussets, EUA) e exportados em extensão “.asc”, para posterior processamento dos dados.

#### 2.4.4.3. Encoder Linear

Figura 2.2 – Dispositivo para medição de variáveis biomecânicas de sprints *Race encoder*®.



Fonte: Dados da pesquisa.

Adicionalmente, para os saltos padronizados foi empregado um dispositivo do tipo encoder linear a uma taxa de amostragem de 1KHz (Linear Encoder, Chronojump Bosco System®, Barcelona, Espanha), conectado a um conversor analógico-digital, por sua vez em interface com um *notebook*, através de um cabo USB. Este dispositivo também foi empregado como medida concorrente para quantificação das variáveis cinemáticas e cinéticas no tempo durante os saltos verticais (Figura 2.1). Os dados foram adquiridos, analisados e exportados por meio do software *Chronojump* 2.2.1 (Chronojump Bosco System®, Barcelona, Espanha).

#### 2.4.4.4. Race Encoder®

Para análise das tarefas de sprints foi utilizado um dispositivo baseado em um *encoder* rotatório (Race encoder®, Chronojump Bosco System, Barcelona, Espanha), para distância máxima de 120m, resolução de  $3 \cdot 10^{-2}$  m e acurácia temporal de  $4 \cdot 10^{-6}$  s,

como medida concorrente para determinação das variáveis cinemáticas e cinéticas (Figura 2.2) em interface com uma placa de aquisição de dados e respectivamente a um *notebook* por meio de um cabo USB. Os dados foram adquiridos e exportados através do software *Chronojump* 2.2.1 (Chronojump Bosco System®, Barcelona, Espanha).

#### 2.4.5. Procedimentos

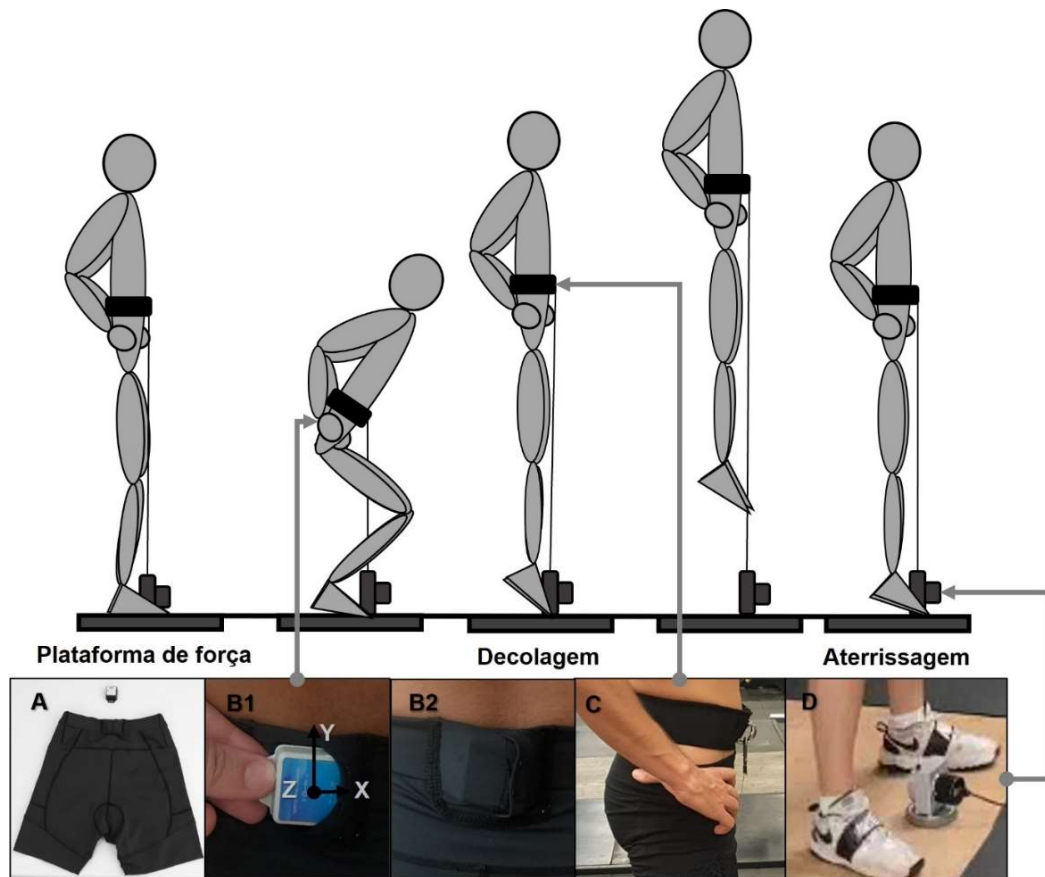
##### 2.4.5.1. Saltos Verticais

Tabela 1.2 – Instruções, desvios das técnicas e protocolos de avaliação de saltos verticais (Byrne *et al.*, 2020).

| TÉCNICAS                        | INSTRUÇÕES                                                                                                                                                                                                                                                                                                                                                                                                                                                                 | DESVIOS                                                                                                                                                                                                                                                                                       |
|---------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Salto Agachado (SA)             | I.) Posicionar-se sobre a plataforma de força e aguardar as instruções do pesquisador para realizar o teste.<br>II.) Saltar o mais alto possível partindo da posição agachada com as mãos posicionadas sobre a cintura e joelhos flexionados com angulação auto – selecionada (próximo a 90 graus).<br>III.) Sair e retornar ao solo a partir da ponta dos pés.<br>IV.) A visão deve estar orientada a um ponto fixo no horizonte durante o SA.                            | I.) Executar um contramovimento no início da execução do salto.<br>II.) Saltar sem posicionar os braços sobre a cintura.<br>III.) Abordar o solo simultaneamente com toda superfície plantar.<br>IV.) Executar movimentos demasiados de hiperextensão de tronco e cabeça.                     |
| Salto com contramovimento (SCM) | I.) Posicionar-se sobre a plataforma de força e aguardar as instruções do pesquisador para realizar o teste.<br>II.) Executar um rápido contramovimento preparatório até alcançar uma angulação auto – selecionada (próximo a 90 graus) e imediatamente saltar o mais alto possível com as mãos posicionadas sobre a cintura.<br>III.) Sair e retornar ao solo a partir da ponta dos pés.<br>IV.) A visão deve estar orientada a um ponto fixo no horizonte durante o SCM. | I.) Executar um contramovimento lento e/ou com ângulo de flexão do joelho restrita.<br>II.) Saltar sem posicionar os braços sobre a cintura.<br>III.) Abordar o solo simultaneamente com toda superfície plantar.<br>IV.) Executar movimentos demasiados de hiperextensão de tronco e cabeça. |

Inicialmente, os voluntários recrutados para participação no estudo receberam as informações sobre o estudo e declararam seu consentimento por escrito (TCLE), em seguida foram caracterizados com relação a sua massa corporal (Kg), estatura (m) e idade (anos). A massa corporal e a estatura foram obtidas por meio de uma balança digital com um estadiômetro acoplado (SECA®, Hamburgo, Alemanha), com resolução de medida de 0,1 Kg e 0,1 cm, respectivamente.

Figura 2.3 – Experimentos de saltos padronizados: (A) Vestimenta customizada; (B1-B2) Posicionamento do sensor inercial na bermuda sobre a região lombar; (C) Cinto de tração; (D) Posicionamento do Encoder Linear.




Fonte: Dados da pesquisa.

Após a obtenção do consentimento à participação do estudo, os voluntários selecionaram o tamanho de bermudas em poliamida previamente customizados para utilização e acomodação dos sensores inerciais durante os testes (Figura 04). Em seguida foram instruídos e familiarizados com as técnicas de execução de saltos agachados (SA) e saltos com contramovimento (SCM), sendo orientados sobre seus respectivos desvios, conforme sintetizado na tabela 1.2 (página anterior). Os voluntários recrutados foram orientados a não realizar qualquer tipo de esforço 48 horas antes do início dos experimentos.

Inicialmente, os indivíduos realizaram um aquecimento padrão composto por 10 minutos de corrida leve com velocidade auto-selecionada em esteira e 5 saltos submáximos repetidos. Após o aquecimento, os indivíduos vestiram a bermuda customizada e posicionaram-se sobre a plataforma de força triaxial. Na sequência, ao nível da cintura foi ajustado um cinto de tração com argolas na porção anterior, onde o gancho (tipo mosquetão) do *encoder* linear foi conectado. Para a realização dos

testes, o encoder linear foi posicionado ligeiramente a frente e entre as pernas dos voluntários (Figura 04).

Figura 2.4 – (A1) Posicionamento do bloco de partida PBS-01 POLANIK®; (A2) Ajuste do apoio do bloco – perna de impulso; (A3) Ajuste do apoio do bloco – perna de apoio; (B) Posição preparatória para entrada no bloco partida com a linha do dispositivo *Race encoder*® tensionada; (C) Posição de saída baixa no bloco e local de fixação do sensor inercial (região lombar).



Fonte: Dados da pesquisa.

Previamente ao início dos testes, os valores basais de força foram ajustados a zero, descontando o peso corporal e do encoder linear situados sobre a plataforma de força,

orientando os indivíduos a permanecerem estáticos previamente à realização do protocolo. Logo, o sensor inercial foi acionado e acomodado internamente a um compartimento customizado sob medida na bermuda com a finalidade de evitar quaisquer deslocamentos indesejados que possam afetar as medidas obtidas (TAN *et al.*, 2019; SESHADRI *et al.*, 2019). O sensor foi posicionado na região lombar (vértebras L4 e L5), próximo ao centro de gravidade corporal (Figura 2.3). Os sensores empregados foram previamente calibrados e ajustados a uma amostragem de 200Hz para realização das coletas.

Em seguida, os indivíduos executaram cinco saltos máximos para cada uma das técnicas selecionadas, com intervalo de 30 segundos entre tentativas em conformidade com as instruções fornecidas na tabela 1.2. Duas sessões separadas minimamente por 48 horas foram executadas antes das sessões de treinamento dos atletas, sendo repetidas na semana subsequente para determinação da confiabilidade. Para minimizar o efeito de ordem, as respectivas técnicas de saltos correspondentes a cada sessão foram aleatorizadas. No total, nesta etapa de avaliação da validade e confiabilidade discreta dos sensores inerciais para saltos verticais foram coletados 400 saltos (200 SCM e 200 SA).

#### 2.4.5.2. Sprints

Após serem informados a respeito do estudo, os voluntários declararão seu consentimento e caracterizados quanto a massa, estatura e idade por meio de uma balança digital com um estadiômetro acoplado (SECA®, Hamburgo, Alemanha). Os voluntários selecionaram as bermudas customizada em poliamida previamente para acomodação dos sensores durante o protocolo de *sprints* (Figura 2.4). Em seguida foram instruídos e familiarizados sobre a realização da tarefa de *sprints* no estudo. Os voluntários foram orientados a não realizar qualquer tipo de esforço 48 horas antes do início dos experimentos.

Os indivíduos vestiram a bermuda e realizaram um aquecimento composto por exercícios de alongamento, 10 minutos de corrida leve (velocidade auto-selecionada) e exercícios coordenativos específicos para tarefas de velocidade. Logo, os indivíduos fixaram o bloco de partida (PBS01, Polanik, Varsóvia, Polônia) a um pé de distância da linha de partida, ajustaram a inclinação dos apoios dos pés e posicionaram os mesmos a dois pés (perna dominante) e um pé (perna de apoio) de distância da extremidade do bloco de partida. Em seguida os voluntários testaram a posição de

saída a partir do bloco por pelo menos três tentativas, com a finalidade de verificar a necessidade de ajustes. A figura 2.4 ilustra o ajuste do bloco de partida realizado pelos voluntários.

Em seguida, o sensor inercial foi acionado e fixado na região lombar (vértebras L4 e L5), próximo ao centro de gravidade corporal internamente ao compartimento da bermuda (TAN *et al.*, 2019; SESHADRI *et al.*, 2019). Como medida concorrente, um analisador do desempenho de sprints baseado em dispositivo do tipo encoder rotatório (Race Encoder® - RE, Chronojump. Barcelona, Espanha) foi empregado simultaneamente ao uso dos sensores inerciais, sendo aderido ao cinto de tração da bermuda imediatamente acima do compartimento de acomodação do sensor próximo à região lombar através de um mosquetão com trava (Figura 2.4).

Logo após, os voluntários foram orientados a se posicionar no bloco de partida, concomitantemente ao ajuste da linha aderida ao cinto de tração, sendo mantida pré-tensionada para a realização dos testes (Figura 2.4). Em seguida, os indivíduos executaram um protocolo de sprints, composto por 3 sprints de 30 metros, com intervalos de 5 minutos entre repetições. Ao todo 2 sessões separadas por 72 horas foram executadas, sendo repetidas na mesma semana para determinação da confiabilidade, sempre antes do início das sessões de treinamento. No total, nesta etapa de avaliação da validade e confiabilidade discreta dos sensores inerciais foram coletados ao todo 114 sprints. Os sensores empregados foram calibrados e ajustados previamente a uma amostragem de 200Hz para realização das coletas

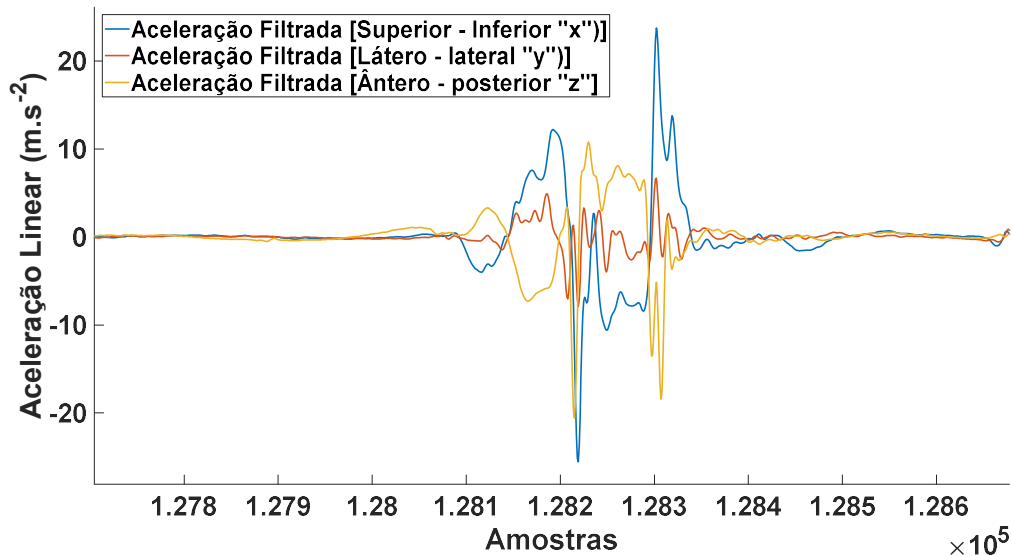
#### 2.4.5. *Processamento e Análise numérica*

##### 2.4.5.1. Saltos Verticais

Para a quantificação das variáveis a partir do sensor inercial, a aceleração linear ( $\bar{a}_{sensor}$ ) foi rotacionada do sistema de coordenadas dos sensores inerciais (x, y, z) para um sistema global de coordenadas ( $\bar{a}_{global}$ ), previamente. A alteração do sistema de coordenadas é realizada por meio da aplicação do algoritmo de estimativa de orientação de Madgwick (WADA *et al.*, 2018; PALLIS; MCNITT-GRAY; HUNG, 2019; RANTALAINEN; FINNI; WALKER, 2019). Na produção da estimativa de orientação nos saltos verticais foram utilizados os sinais brutos obtidos do acelerômetro e giroscópio. O algoritmo retorna o quaternion conjugado do quaternion de orientação necessário para rotacionar a aceleração linear do sensor inercial. O algoritmo para

estimativa da orientação de código aberto encontra-se disponível em ambiente matlab (<https://cmj.sport.jyu.fi/>), sendo considerado para as análises somente a aceleração vertical global ( $a_{y[global]}$ ) (RANTALAINEN; FINNI; WALKER, 2019).

Figura 2.5 – Aceleração linear filtrada obtida dos sensores inerciais nos eixos “x”, “y” e “z” durante a realização do salto com contramovimento (SCM).



Fonte: Dados da pesquisa.

Subsequentemente, ainda para as UMI, para a detecção dos saltos verticais, a  $a_{y[global]}$  foi filtrada com um filtro *butterworth* passa – baixa (frequência de 2 Hz, zero-lag, 4ª ordem) e períodos da série temporal abaixo de 0,5g ( $4,905 \text{ m.s}^{-2}$ ) com duração  $\geq 0,100\text{s}$  foram identificados a partir do sinal filtrado. Para quantificar o tempo de vôo, o momento da decolagem (“*takeoff*” -  $to_{a_{y[gl]}}$ ) ou saída do solo foi determinado como a primeira amostra “*i*” com valor de  $a_{y[global]}$  menor que 0,5g e o momento de aterrissagem ou abordagem do solo (“*landing*” -  $land_{a_{y[global]}}$ ) como a última amostra “*i*” com valor de aceleração menor que 0,5g, conforme destacado por Rantalainen; Finni; Walker (2019).

A partir da posição das amostras referentes aos momentos de decolagem e abordagem do solo, o tempo de vôo para os saltos agachados e com contramovimento ( $TV_{SA}$  e  $TV_{SCM}$ ) foi determinado com base na equação 1, onde “*n*” corresponde a amostragem (Hz) de coleta do sensor inercial:

$$TV_{SA/SCM} = \frac{(land_{a_y[global]} - to_{a_y[global]})}{n} \quad \text{Equação 1}$$

Após determinar o tempo de voo, foram computadas a altura de salto vertical ( $H_{SA}$  e  $H_{SCM}$ ) e a velocidade de saída do solo ( $VS_{SA}$  e  $VS_{SCM}$ ) baseado no método do tempo de voo (LINTHORNE, 2001; CORMIE; MCBRIDE; MCAULLEY, 2009), respectivamente destacado nas equações 2 e 3 ( $g = -9,81 \text{ m.s}^{-2}$ ):

$$H_{SA/SCM} = -\frac{1}{8} * g * TV_{SA/SCM}^2 \quad \text{Equação 2}$$

$$VS_{SA/SCM} = \frac{g * TV_{SA/SCM}}{2} \quad \text{Equação 3}$$

Na sequência, o impulso foi quantificado ( $IMP_{SA}$ ,  $IMP_{SCM}$ ), aplicando o teorema impulso ( $J$ ) – momento ( $\rho$ ) (Equação 4), respectivamente, a partir dos valores de massa e velocidade de saída do solo ( $VS_{to}$ ) conhecidos (LINTHORNE, 2001). Para o encoder linear, as variáveis foram de tempo de voo, altura de salto vertical e velocidade de saída do solo foram quantificadas a partir do software proprietário Chronojump 2.2.1 (Chronojump Bosco System®, Barcelona, Espanha). A variável de impulso foi quantificada a partir da velocidade de saída do solo, em conformidade com a equação 4.

$$J = \Delta\rho = \int_{t_i}^{t_{to}} (F_{RS} - mg)dt = mVS_{to} = J_{FRS} - J_{PESO} = mVS_{to} \quad \text{Equação 4}$$

Por fim, no caso dos registros obtidos da plataforma de força triaxial, as variáveis de interesse foram determinadas utilizando apenas o registro das forças de reação do solo ( $F_{RS}$ ) no eixo vertical “z”, sendo previamente filtrado com um filtro *butterworth* passa – baixa (frequência de 10 Hz, zero-lag, 4ª ordem). Para detectar o início (“onset”) da execução dos saltos padronizados, o método do limiar foi empregado (EAGLES *et al.*, 2015; MCMAHON *et al.*, 2018), sendo estabelecido inicialmente para esta finalidade o valor médio basal de força (peso médio -  $W_{médico}$ ), o valor máximo basal de força (peso máximo -  $W_{máximo}$ ) e o respectivo o desvio – padrão referentes às primeiras 50 amostras da série temporal ( $dp$ ).

Para definir o momento de início dos saltos verticais pelo método do limiar, duas condições possíveis foram respeitadas, conforme destacado a seguir: (1) Se o  $W_{\text{máximo}}$  fosse maior ou igual ao somatório do  $W_{\text{médio}}$  com o valor de  $5 dp$  ( $W_{\text{máximo}} \geq W_{\text{médio}} + 5*dp$ ), as respectivas posições das amostras “ $i$ ” com valor maior que a soma do  $W_{\text{máximo}}$  e  $5 dp$  e “ $j$ ” menor que a diferença entre o valor do  $W_{\text{máximo}}$  e  $5 dp$  ( $W_{\text{máximo}} \pm 5*dp$ ), foram armazenadas respectivamente; (2) Caso o  $W_{\text{máximo}}$  mostre valor menor que a soma do  $W_{\text{médio}}$  e  $5 dp$  ( $W_{\text{máximo}} < W_{\text{médio}} + 5*dp$ ), as posições referentes as amostras “ $m$ ” e “ $n$ ” de valor maior que a soma do  $W_{\text{médio}}$  com  $5 dp$  e menor que a diferença entre o valor do  $W_{\text{médio}}$  e  $5 dp$  ( $W_{\text{médio}} \pm 5*dp$ ), foram respectivamente identificadas. Nas duas condições acima, o “*onset*” foi definido como a amostra identificada primeiro.

A partir da identificação do “*onset*”, as curvas de forças de reação do solo no tempo foram segmentadas e calculada a curva de aceleração no tempo por meio da divisão da curva de força pela massa corporal. A curvas de velocidade no tempo foram obtidas por meio da integração trapezoidal ponto – a – ponto, a partir da curva de aceleração no tempo. Adicionalmente, as curvas de deslocamento no tempo foram quantificadas através da integração trapezoidal no tempo ponto – a – ponto da curva de velocidade no tempo (LINTHORNE, 2001; CORMIE; MCBRIDE; MCAULLEY, 2009; CHAPRA, 2012).

Na sequência, previamente à quantificação das variáveis, o momento de decolagem foi identificado como a posição da amostra “ $i$ ” com valor menor ou igual a 20N. Por outro lado, o momento de aterrissagem foi determinado como a posição da amostra “ $i$ ” com valor maior que 20N (EAGLES *et al.*, 2015; MCMAHON *et al.*, 2018). Logo, o tempo de vôo e a altura de salto foram determinados conforme destacado nas equações 1 e 2. Entretanto, a velocidade de saída do solo foi determinada a partir da curva de velocidade no tempo, através da posição da amostra referente ao momento de decolagem ou *takeoff*. Adicionalmente, o impulso foi calculado por meio do procedimento de integração trapezoidal da curva força - tempo do *onset* ao *takeoff* (Equação 5). As análises foram processadas no software Matlab R2021b (MathWorks®, Natick, EUA).

$$J_{F_{RS}-W_{Médio}} = \int_{t_{onset}}^{t_{takeoff}} (F_{RS} - mg) dt \quad \text{Equação 5}$$

#### 2.4.5.2. Sprints

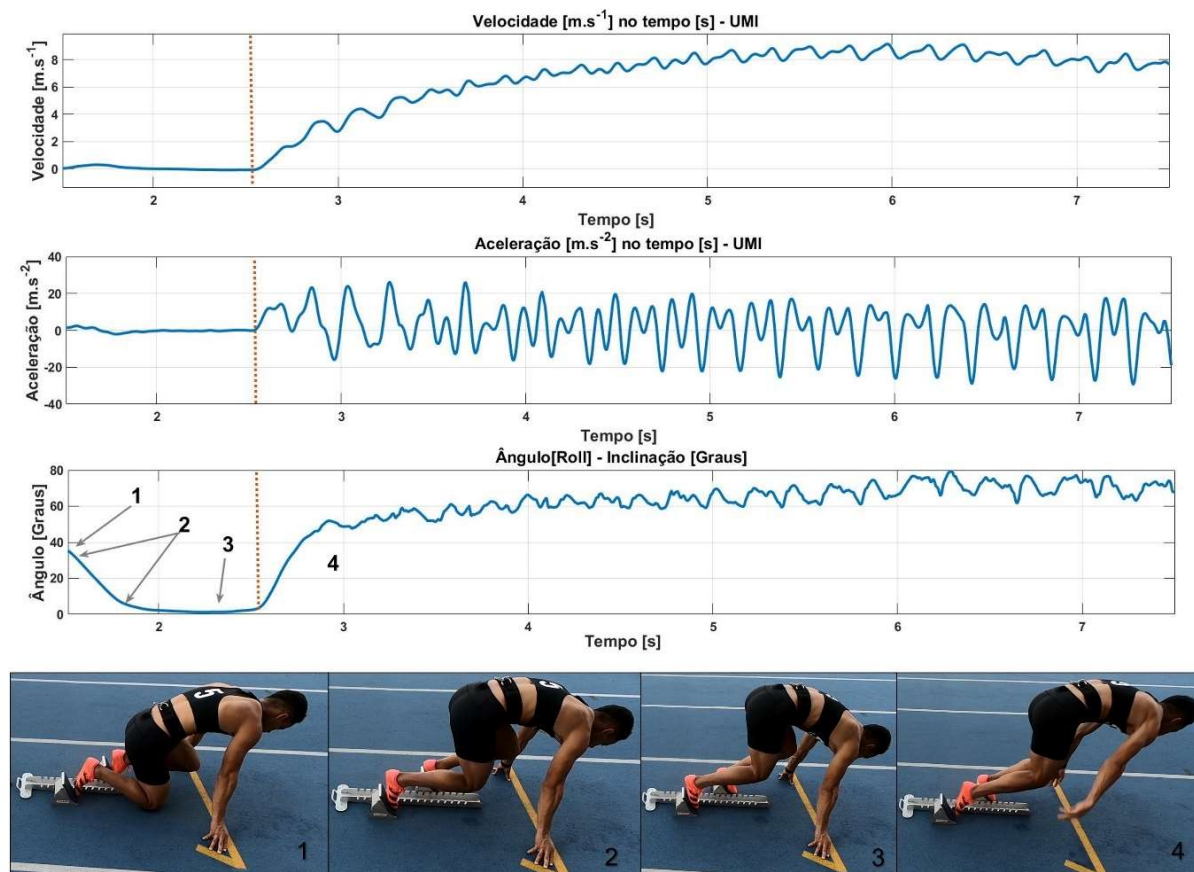
Inicialmente, as séries temporais de aceleração e velocidade angular oriundas da UMI foram importadas e filtradas com um filtro *butterworth* passa – baixa (6 Hz, *zero-lag*, 4ª ordem; 40 Hz, *zero-lag*, 4ª ordem, respectivamente) para rejeição do ruído (ROELL *et al.*, 2019). Em seguida, a aceleração linear ( $\bar{a}_{sensor}$ ) foi rotacionada do sistema de coordenadas dos sensores inerciais (x, y, z) para um sistema global de coordenadas ( $\bar{a}_{global}$ ). A alteração do sistema de coordenadas é realizada por meio da aplicação do algoritmo de estimativa de orientação de Madgwick (PALLIS; MCNITT-GRAY; HUNG, 2019; RANTALAINEN; FINNI; WALKER, 2019). Na produção da estimativa de orientação nos *sprints* foram utilizados os sinais filtrados obtidos do acelerômetro e giroscópio. O algoritmo retorna o quatérnion conjugado do quatérnion de orientação necessário para rotacionar a aceleração linear do sensor inercial (<https://x-io.co.uk/open-source-imu-and-ahrs-algorithms/>) (RANTALAINEN; FINNI; WALKER, 2019). A partir da aceleração vertical global ( $a_{y[global]}$ ), um procedimento de integração trapezoidal ponto a ponto foi conduzido (Equação 6), onde  $v(t_k)$  representa a velocidade instantânea para cada posição “k”,  $a_{y[Global]}(t)$  o vetor de aceleração instantânea no tempo e  $dt$  o intervalo de tempo amostral.

$$v(t_{k+1}) = \int_{t_k}^{t_{k+1}} a_{y[Global]}(t)dt + v(t_k) \quad k = 1, 2, \dots \quad \text{Equação 6}$$

As séries temporais de dados de deslocamento obtidas do *Race Encoder*® (medida concorrente) foram filtradas com um filtro *butterworth* passa – baixa (15 Hz, *zero-lag*, 4ª ordem), precedidas por uma interpolação linear para uma amostragem de 200Hz (CHAPRA, 2012). A partir dos dados interpolados e filtrados, um procedimento de derivação numérica foi conduzido para obtenção da curva de velocidade no tempo nos *sprints*. Na sequência, as séries temporais de velocidade de ambos os dispositivos foram sincronizadas pelo método do limiar (conforme descrito previamente na subseção 2.4.5.1) por meio da amostra “j” (“onset”) do ângulo de Euler obtida da UMI (*pitch*, eixo “x”) referente a transição entre as etapas 3 (Posição estática) e 4 (Início dos *sprints*), que remete à inclinação do tronco da saída baixa, indicada pela curva de angulação no tempo (BERGAMINI *et al.*, 2013), representada na figura 2.6 (linha tracejada em vermelho). Após o procedimento de sincronização, a primeira amostra “j” referente a 30 metros de deslocamento registrada pelo RE foi

identificada como o momento final (“end”) dos *sprints* para ambos os instrumentos. Subsequentemente, um ajuste polinomial (3ª ordem, selecionada a partir de testes - piloto) foi aplicada para as séries temporais de velocidade, sendo extraídas as variáveis de velocidade média ( $V_{med}$ ) e de pico ( $V_{max}$ ). A  $V_{max}$  e  $V_{med}$  foram calculadas para ambos os dispositivos como o valor máximo e o valor médio observado entre as amostras “i” (onset) e “j” (end) da curva de velocidade instantânea, respectivamente. As análises foram conduzidas no software Matlab R2021b (MathWorks®, Natick, EUA).

Figura 2.6 – Curvas de velocidade, aceleração linear e ângulo de Euler – “roll” (sensor posicionado próximo da região lombar) obtidas dos sensores inerciais no eixo vertical “y” durante a realização de sprints de 30m (saída baixa) obtidas de UMI.



Fonte: Dados da pesquisa.

Etapas – Saída baixa: (1) “Em posição”; (2) Transição; (3) Posição estática; (4) Início do *sprint*.

#### 2.4.6. Análise estatística

Previamente, os dados obtidos foram descritos em termos de média, desvio – padrão e coeficiente de variação (%) para as variáveis estudadas (Baixa instabilidade relativa  $\leq 15\%$ ; moderada instabilidade de  $>15\%$  e  $<30\%$ ;  $>30\%$ ). Para avaliar a validade entre

as medidas de referência e as UMI testados o limite de concordância com um intervalo de confiança de 95% (Método de Bland-Altman;  $\bar{x}_{dif} \pm 1.96 * dp_{dif}$ ) e sua respectiva representação gráfica da diferença entre os escores contra a média das observações dos dois métodos (Gráfico de dispersão de “Bland – Altman”) foram computados entre a medida concorrente e o sensor, para cada a variável (Saltos verticais -  $TV_{SCM}$ ,  $TV_{SA}$ ;  $H_{SCM}$ ,  $H_{SA}$ ;  $IMP_{SCM}$ ,  $IMP_{SA}$ ; *Sprints* –  $V_{max}$ ;  $V_{med}$ ). Nos gráficos de dispersão, um modelo de regressão foi ajustado para verificação do erro sistemático absoluto, com a checagem prévia dos pressupostos de normalidade e homoscedasticidade dos dados. Adicionalmente, o erro sistemático relativo (%) foi determinado por meio do cômputo da diferença percentual em módulo entre os instrumentos de medição ( $ER[\%] = \left| \frac{UMI-MC}{MC} \right| * 100$ ), para cada variável (BLAND; ALTMAN, 1999).

Adicionalmente, os pressupostos de normalidade e homocedasticidade (testes de Shapiro-Wilk e Bartlett, respectivamente) foram testados para as variáveis estudadas, e caso algum destes seja violado, uma transformação logarítmica foi aplicada. A partir dos dados transformados, os pressupostos foram novamente testados para utilização da análise de variância (saltos e *sprints*), com a finalidade de testar a hipótese de diferenças entre métodos de medição e entre sessões. Para os saltos verticais padronizados, caso o valor da estatística “F” fosse significativo na comparação entre os métodos de medição, um teste *post hoc* de *tukey* para comparações múltiplas foi conduzido.

Para avaliar a confiabilidade, o erro padrão de medida ( $EPM = \frac{dp_{dif}}{\sqrt{2}}$ ) foi computado para cada variável, proporcionando uma medição da quantidade de variação aleatória absoluta entre os métodos de medição e entre sessões, respectivamente. Para analisar a relação entre métodos de medição e sessões, o coeficiente de correlação de pearson ( $r$ ) (trivial,  $\leq 0,25$ ; fraco;  $0,26 - 0,50$ ; moderado,  $0,51 - 0,75$ ; e forte,  $0,76 - 1,00$ ), modelos de regressão linear e seu respectivo coeficiente de determinação ( $R^2$ ) foram determinados. Concomitantemente, sucedeu-se a verificação da significância estatística dos modelos (intercepto [“a”] e coeficiente de regressão [“b”]). Por fim, a confiabilidade entre dias (relativa) foi determinada pelo coeficiente de correlação intraclassa ( $CCI_{3,1}$  – análise de variância para dois fatores, modelo de efeito fixo), classificado conforme Weir (2005). Os valores foram classificados como fracos ( $CCI < 0,40$ ), aceitáveis ( $0,40 \leq CCI < 0,59$ ), bons ( $0,59 < CCI < 0,75$ ) ou excelentes ( $CCI > 0,75$ ) (WEIR, 2005). As análises dos dados foram realizadas utilizando os

softwares “R”, versão 4.1.2 (<https://cran.r-project.org/>, R Core Team, 2021, Vienna, Áustria), para uma significância estatística ( $\alpha$ ) menor que 0,05.

## 2.5. Resultados

### 2.5.5. Saltos Verticais

A tabela 1.3 apresenta os resultados descritivos obtidos em termos de média, desvio padrão e coeficiente de variação para os experimentos de saltos verticais. As tabelas 1.4 (Sessão 1) e 1.5 (Sessão 2) mostram os dados relativos à concordância (erro sistemático absoluto e relativo) e precisão (erro aleatório - EPM) entre os instrumentos nos experimentos de saltos verticais. Os gráficos de dispersão “Bland – Altman” para todas as variáveis, entre cada método de medição, técnicas de salto para ambas as sessões são destacados no apêndice C.

Tabela 1.3 – Análise descritiva para as variáveis obtidas dos sensores inerciais nos experimentos de saltos padronizados.

| SALTO COM CONTRA-MOVIMENTO [SCM] |                                 |                                 |                                 |                                 |                                 |                                 |
|----------------------------------|---------------------------------|---------------------------------|---------------------------------|---------------------------------|---------------------------------|---------------------------------|
| Variável                         | PF [ $\bar{x} \pm s$ (CV%)]     |                                 | EL [ $\bar{x} \pm s$ (CV%)]     |                                 | UMI [ $\bar{x} \pm s$ (CV%)]    |                                 |
|                                  | S1                              | S2                              | S1                              | S2                              | S1                              | S2                              |
| TV <sub>SCM</sub><br>[s]         | 0,533±0,047<br>(8,818%)         | 0,526±0,047<br>(8,935%)         | 0,552±0,048<br>(8,695%)         | 0,545±0,046<br>(8,440%)         | 0,539±0,059<br>(10,946%)        | 0,539±0,047<br>(8,719%)         |
| H <sub>SCM</sub><br>[m]          | 0,352±0,062<br>(17,613%)        | 0,342±0,061<br>(17,836%)        | 0,376±0,063<br>(16,75%)         | 0,367±0,061<br>(16,621%)        | 0,362±0,085<br>(23,480%)        | 0,360±0,064<br>(17,777%)        |
| IMP <sub>SCM</sub><br>[N.s]      | 159,878±<br>40,571<br>(25,376%) | 157,217±<br>35,987<br>(22,890%) | 165,921±<br>35,401<br>(21,336%) | 163,692±<br>34,534<br>(21,096%) | 162,442±<br>38,052<br>(23,424%) | 162,140±<br>35,622<br>(21,969%) |
| SALTO AGACHADO [SA]              |                                 |                                 |                                 |                                 |                                 |                                 |
| Variável                         | PF [ $\bar{x} \pm s$ (CV%)]     |                                 | EL [ $\bar{x} \pm s$ (CV%)]     |                                 | UMI [ $\bar{x} \pm s$ (CV%)]    |                                 |
|                                  | S1                              | S2                              | S1                              | S2                              | S1                              | S2                              |
| TV <sub>SA</sub><br>[s]          | 0,505±0,042<br>(8,316%)         | 0,501±0,038<br>(7,584%)         | 0,503±0,035<br>(6,958%)         | 0,499±0,037<br>(7,414%)         | 0,530±0,046<br>(8,679%)         | 0,511±0,046<br>(9,001%)         |
| H <sub>SA</sub><br>[m]           | 0,315±0,053<br>(16,825%)        | 0,310±0,048<br>(15,483%)        | 0,314±0,044<br>(14,012%)        | 0,308±0,046<br>(14,935%)        | 0,348±0,062<br>(17,816%)        | 0,324±0,059<br>(18,209%)        |
| IMP <sub>SA</sub><br>[N.s]       | 146,952±<br>26,707<br>(18,173%) | 147,013±<br>27,941<br>(19,005%) | 150,552±<br>26,704<br>(17,737%) | 149,216±<br>26,731<br>(17,914%) | 159,211±<br>33,604<br>(21,106%) | 153,821±<br>35,475<br>(23,062%) |

TV<sub>SCM/SA</sub> – tempo de voo nos saltos verticais padronizados; H<sub>SCM/SA</sub> – Altura de salto nos saltos verticais padronizados; IMP<sub>SCM/SA</sub> – Impulso nos saltos verticais padronizados.

Na sessão 1, a análise do SA não evidenciou diferenças entre métodos de medição para as variáveis estudadas (TV<sub>SA</sub>, F=2,55, p=0,087; H<sub>SA</sub>, F=2,658, p=0,078; IMP<sub>SA</sub>, F=0,932, p=0,400). Adicionalmente, não foram identificadas diferenças entre métodos de medição na análise do SCM (sessão 1) para todas as variáveis (SCM - TV<sub>SCM</sub>, F=0,642, p=0,530; H<sub>SCM</sub>, F=0,628, p=0,537; IMP<sub>SCM</sub>, F=0,127, p=0,881). Na sessão 2,

para ambos os saltos padronizados não foram verificadas diferenças significativas entre métodos de medição para todas as variáveis ( $SA - TV_{SA}$ ,  $F=0,438$ ,  $p=0,647$ ;  $H_{SA}$ ,  $F=0,484$ ,  $p=0,619$ ;  $IMP_{SA}$ ,  $F=0,263$ ,  $p=0,770$ ;  $SCM - TV_{SCM}$ ,  $F=0,813$ ,  $p=0,449$ ;  $H_{SCM}$ ,  $F=0,820$ ,  $p=0,446$ ;  $IMP_{SCM}$ ,  $F=0,183$ ,  $p=0,834$ ). Nesse sentido, as UMI testadas e PF concordaram entre si em ambas as sessões experimentais.

Em complemento, os modelos de regressão ajustados nos gráficos de “Bland – Altman” (Apêndice C) mostraram a ausência de relacionamento e associação das diferenças observadas entre a PF e UMI e seus respectivos valores médios para ambas as técnicas de saltos verticais e sessões (Sessão 1 – SCM – [a] e [b],  $p>0,05$ ;  $r = -0,333$  a  $0,405$ ,  $p>0,05$ ;  $R^2 = 0,01$  a  $0,06$ ; SA – [a] e [b],  $p>0,05$ ;  $r = -0,113$  a  $-0,360$ ,  $p>0,05$ ;  $R^2 = 0,01$  a  $0,08$ ; Sessão 2 – SCM – [a] e [b],  $p>0,05$ ;  $r = -0,055$  a  $0,220$ ,  $p>0,05$ ;  $R^2 = -0,052$  a  $-0,004$ ; SA – [a] e [b],  $p>0,05$ ;  $r = 0,004$  a  $0,336$ ,  $p>0,05$ ;  $R^2 = 0,004$  a  $0,064$ ) para todas as variáveis estudadas.

Tabela 1.4 – Concordância entre os instrumentos de medição (PF vs. EL; PF vs. UMI; EL vs. UMI) para as variáveis obtidas nos saltos verticais padronizados (Sessão 1).

| PF vs. EL [SCM]   |                      |                   |        |               |
|-------------------|----------------------|-------------------|--------|---------------|
| VARIÁVEIS         | DIF <sub>Média</sub> | LC [95%]          | EPM    | ER [%]        |
| $TV_{SCM}$ [s]    | -0,018               | [-0,060; 0,023]   | 0,030  | 4,316±3,190   |
| $H_{SCM}$ [m]     | -0,024               | [-0,080; 0,031]   | 0,040  | 8,910±6,702   |
| $IMP_{SCM}$ [N.s] | -6,043               | [-41,373; 29,287] | 25,492 | 7,845±6,182   |
| PF vs. UMI [SCM]  |                      |                   |        |               |
| VARIÁVEIS         | DIF <sub>Média</sub> | LC [95%]          | EPM    | ER [%]        |
| $TV_{SCM}$ [s]    | -0,006               | [-0,088; 0,077]   | 0,059  | 6,333±4,179   |
| $H_{SCM}$ [m]     | -0,010               | [-0,125; 0,105]   | 0,083  | 12,937±8,668  |
| $IMP_{SCM}$ [N.s] | -2,564               | [-35,394; 30,265] | 23,688 | 7,296±5,677   |
| EL vs. UMI [SCM]  |                      |                   |        |               |
| VARIÁVEIS         | DIF <sub>Média</sub> | LC [95%]          | EPM    | ER [%]        |
| $TV_{SCM}$ [s]    | 0,012                | [-0,078; 0,103]   | 0,065  | 6,916±4,463   |
| $H_{SCM}$ [m]     | 0,014                | [-0,112; 0,141]   | 0,091  | 13,597±8,683  |
| $IMP_{SCM}$ [N.s] | 3,478                | [-24,884; 31,842] | 20,465 | 6,918±4,463   |
| PF vs. EL [SA]    |                      |                   |        |               |
| VARIÁVEIS         | DIF <sub>Média</sub> | LC [95%]          | EPM    | ER [%]        |
| $TV_{SA}$ [s]     | 0,002                | [-0,046; 0,050]   | 0,034  | 3,718±2,944   |
| $H_{SA}$ [m]      | 0,001                | [-0,056; 0,060]   | 0,042  | 7,115±5,614   |
| $IMP_{SA}$ [N.s]  | -3,600               | [-30,690; 23,490] | 19,546 | 5,625±7,556   |
| PF vs. UMI [SA]   |                      |                   |        |               |
| VARIÁVEIS         | DIF <sub>Média</sub> | LC [95%]          | EPM    | ER [%]        |
| $TV_{SA}$ [s]     | -0,024               | [-0,104; 0,054]   | 0,057  | 8,165±4,684   |
| $H_{SA}$ [m]      | -0,033               | [-0,136; 0,070]   | 0,074  | 17,076±10,257 |
| $IMP_{SA}$ [N.s]  | -12,258              | [-55,648; 31,130] | 31,307 | 10,542±13,793 |
| EL vs. UMI [SA]   |                      |                   |        |               |
| VARIÁVEIS         | DIF <sub>Média</sub> | LC [95%]          | EPM    | ER [%]        |
| $TV_{SA}$ [s]     | -0,026               | [-0,111; 0,057]   | 0,061  | 8,472±5,389   |
| $H_{SA}$ [m]      | -0,034               | [-0,145; 0,075]   | 0,079  | 17,462±11,508 |
| $IMP_{SA}$ [N.s]  | -8,658               | [-37,077; 19,759] | 20,504 | 8,471±5,389   |

Tabela 1.5 – Concordância entre os instrumentos de medição (PF vs. EL; PF vs. UOMI; EL vs. UMI) para as variáveis obtidas nos saltos verticais padronizados (Sessão 2).

| PF vs. EL [SCM]          |                      |                   |        |               |
|--------------------------|----------------------|-------------------|--------|---------------|
| VARIÁVEIS                | DIF <sub>Média</sub> | LC [95%]          | EPM    | ER [%]        |
| TV <sub>SCM</sub> [s]    | -0,018               | [-0,057; 0,020]   | 0,027  | 4,353±2,777   |
| H <sub>SCM</sub> [m]     | -0,024               | [-0,076; 0,027]   | 0,037  | 8,902±5,801   |
| IMP <sub>SCM</sub> [N.s] | -6,474               | [-21,073; 8,124]  | 10,533 | 5,481±3,542   |
| PF vs. UMI [SCM]         |                      |                   |        |               |
| VARIÁVEIS                | DIF <sub>Média</sub> | LC [95%]          | EPM    | ER [%]        |
| TV <sub>SCM</sub> [s]    | -0,012               | [-0,104; 0,078]   | 0,065  | 7,306±5,461   |
| H <sub>SCM</sub> [m]     | -0,017               | [-0,140; 0,104]   | 0,088  | 15,228±11,698 |
| IMP <sub>SCM</sub> [N.s] | -4,923               | [-34,837; 24,990] | 21,584 | 7,687±6,638   |
| EL vs. UMI [SCM]         |                      |                   |        |               |
| VARIÁVEIS                | DIF <sub>Média</sub> | LC [95%]          | EPM    | ER [%]        |
| TV <sub>SCM</sub> [s]    | 0,005                | [-0,084; 0,096]   | 0,065  | 7,522±3,568   |
| H <sub>SCM</sub> [m]     | 0,006                | [-0,115; 0,128]   | 0,087  | 14,982±7,310  |
| IMP <sub>SCM</sub> [N.s] | 1,551                | [-26,414; 29,516] | 20,178 | 7,520±3,567   |
| PF vs. EL [SA]           |                      |                   |        |               |
| VARIÁVEIS                | DIF <sub>Média</sub> | LC [95%]          | EPM    | ER [%]        |
| TV <sub>SA</sub> [s]     | 0,002                | [-0,044; 0,049]   | 0,033  | 3,683±2,856   |
| H <sub>SA</sub> [m]      | 0,002                | [-0,055; 0,060]   | 0,041  | 7,254±5,689   |
| IMP <sub>SA</sub> [N.s]  | -2,202               | [-34,366; 29,960] | 23,207 | 6,916±8,808   |
| PF vs. UMI [SA]          |                      |                   |        |               |
| VARIÁVEIS                | DIF <sub>Média</sub> | LC [95%]          | EPM    | ER [%]        |
| TV <sub>SA</sub> [s]     | -0,009               | [-0,088; 0,070]   | 0,057  | 6,342±4,915   |
| H <sub>SA</sub> [m]      | -0,013               | [-0,116; 0,089]   | 0,074  | 13,215±10,298 |
| IMP <sub>SA</sub> [N.s]  | -6,807               | [-54,374; 40,759] | 34,321 | 10,738±13,916 |
| EL vs. UMI [SA]          |                      |                   |        |               |
| VARIÁVEIS                | DIF <sub>Média</sub> | LC [95%]          | EPM    | ER [%]        |
| TV <sub>SA</sub> [s]     | -0,011               | [-0,098; 0,075]   | 0,062  | 7,032±5,977   |
| H <sub>SA</sub> [m]      | -0,016               | [-0,127; 0,094]   | 0,080  | 14,664±13,140 |
| IMP <sub>SA</sub> [N.s]  | -4,604               | [-33,592; 24,382] | 20,915 | 7,029±5,979   |

Esta ausência de relacionamento significativo é também verificada majoritariamente entre as medidas – critério (Sessão 1 - PF e EL - [a] e [b],  $p > 0,05$ ;  $r = -0,031$  a  $0,339$ ,  $p < 0,05$ ;  $R^2 = 0,01$  a  $0,06$ ; Sessão 2 - PF e EL - [a] e [b],  $p > 0,05$ ;  $r = -0,025$  a  $0,264$ ,  $p < 0,05$ ;  $R^2 = -0,005$  a  $0,018$ ) e entre o EL e a UMI ([a] e [b],  $p > 0,05$ ;  $r = -0,087$  a  $0,028$ ,  $p > 0,05$ ;  $R^2 = -0,054$  a  $-0,047$ ). Adicionalmente, o IMP<sub>SA</sub> (Sessão 1 – EL e UMI – SA - [a] e [b],  $p < 0,05$ ;  $r = -0,486$ ,  $p = 0,029$ ;  $R^2 = 0,194$ ; Sessão 2 – EL e UMI – SA - [a] e [b],  $p < 0,05$ ;  $r = -0,602$ ,  $p = 0,004$ ;  $R^2 = 0,327$ ), mostraram um viés entre os métodos de medição, com tendência decrescente à medida que há ocorrência de aumento dos valores médios, ao observar a reta ajustada.

Adicionalmente, o ER (%) em média mostrou diferenças entre a PF e EL de 3,718% a 8,483% (Sessão 1), 3,683% a 9,784% (Sessão 2); entre a PF e a UMI de 8,165% a 17,662% (Sessão 1), 6,342% a 17,636% (Sessão 2); e entre o EL e a UMI de 8,471%

a 17,462% (Sessão 1), 7,029% a 14,664% (Sessão 2) para o SA. Para o SCM, as diferenças percentuais em média oscilaram de 4,316% a 16,136% (Sessão 1) e 4,353% a 11,372% (Sessão 2) entre a PF e EL; de 6,333% a 15,188% (Sessão 1) e 7,306% a 16,177% (Sessão 2) entre a PF e a UMI; e de 6,916% a 13,597% (Sessão 1) e de 7,520% a 14,982% entre o EL e a UMI para as variáveis estudadas. Na perspectiva de associação entre métodos de medição, um grau de associação positiva de moderada a forte entre os métodos de medição foi verificado, exceto para as variáveis  $TV_{SCM}$  e  $H_{SCM}$  entre o EL e UMI, onde foi verificado um nível fraco de associação positiva. Para a análise de regressão linear entre os métodos de medição, em todos os modelos ajustados o coeficiente de regressão estimado foi significativo ( $p < 0,05$ ; Apêndice D - Tabela 1).

Tabela 1.6 – Correlação ( $r$ ) [intervalo de confiança – 95%] entre instrumentos de medição (PF vs. EL; PF vs. UMI; EL vs. UMI) para as respectivas variáveis estudadas.

| SESSÃO 1          |                        |                       |                       |
|-------------------|------------------------|-----------------------|-----------------------|
| VARIÁVEIS         | PF vs. EL [SCM]        | PF vs.UMI [SCM]       | EL vs. UMI [SCM]      |
|                   | $r$ [95%]              | $r$ [95%]             | $r$ [95%]             |
| $TV_{SCM}$ [s]    | 0,899 [0,758;0,959] *  | 0,705 [0,382;0,874] * | 0,643 [0,281;0,845] * |
| $H_{SCM}$ [m]     | 0,896 [0,753;0,958] *  | 0,687 [0,352;0,866] * | 0,617 [0,241;0,832] * |
| $IMP_{SCM}$ [N.s] | 0,896 [0,751;0,958] *  | 0,911 [0,785;0,964] * | 0,924 [0,816;0,970] * |
| VARIÁVEIS         | PF vs. EL [SA]         | PF vs.UMI [SA]        | EL vs. UMI [SA]       |
|                   | $r$ [95%]              | $r$ [95%]             | $r$ [95%]             |
| $TV_{SA}$ [s]     | 0,815 [0,583;0,924] *  | 0,589 [0,199;0,818] * | 0,476 [0,043;0,759] * |
| $H_{SA}$ [m]      | 0,828 [0,609;0,930] *  | 0,590 [0,199;0,819] * | 0,481 [0,050;0,761] * |
| $IMP_{SA}$ [N.s]  | 0,866 [0,686;0,946] *  | 0,753 [0,466;0,896] * | 0,909 [0,781;0,963] * |
| SESSÃO 2          |                        |                       |                       |
| VARIÁVEIS         | PF vs. EL [SCM]        | PF vs.UMI [SCM]       | EL vs. UMI [SCM]      |
|                   | $r$ [95%]              | $r$ [95%]             | $r$ [95%]             |
| $TV_{SCM}$ [s]    | 0,911 [0,785; 0,964] * | 0,517 [0,097;0,781] * | 0,521 [0,103;0,783] * |
| $H_{SCM}$ [m]     | 0,907 [0,777;0,963] *  | 0,501 [0,075;0,772] * | 0,511 [0,089;0,778] * |
| $IMP_{SCM}$ [N.s] | 0,978 [0,945;0,991] *  | 0,909 [0,780;0,963] * | 0,917 [0,800;0,967] * |
| VARIÁVEIS         | PF vs. EL [SA]         | PF vs.UMI [SA]        | EL vs. UMI [SA]       |
|                   | $r$ [95%]              | $r$ [95%]             | $r$ [95%]             |
| $TV_{SA}$ [s]     | 0,805 [0,563;0,919] *  | 0,560 [0,155;0,803] * | 0,456 [0,017;0,748] * |
| $H_{SA}$ [m]      | 0,807 [0,567;0,920] *  | 0,540 [0,128;0,793] * | 0,450 [0,010;0,744] * |
| $IMP_{SA}$ [N.s]  | 0,821 [0,593;0,926] *  | 0,731 [0,427;0,886] * | 0,924 [0,816;0,970] * |

\*Indica que o coeficiente de correlação é significativo ( $p < 0,05$ ).

Para ambos os saltos verticais padronizados, um grau excelente de confiabilidade teste – reteste (repetibilidade) para as UMI (SA -  $CCI_{3,1} = 0,758 - 0,961$ ; SCM -  $CCI_{3,1} = 0,909 - 0,984$ ), seguido por uma forte associação positiva teste – reteste (SA –  $r = 0,757 - 0,962$ ; SCM –  $r = 0,929 - 0,986$ ) e sem alterações significativas ( $p > 0,05$ ) foram evidenciadas entre dias (sessões) para todas as variáveis estudadas. A tabela 1.6

reporta as medidas de correlação entre instrumentos para ambos as técnicas de saltos padronizados. Os gráficos de dispersão “Bland – Altman” são reportados no apêndice C.

Tabela 1.7 – Confiabilidade teste-reteste para UMI, PF e EL no SA e SCM.

| UMI [SCM]                   |                      |                      |                    |                          |        |                          |
|-----------------------------|----------------------|----------------------|--------------------|--------------------------|--------|--------------------------|
| VARIÁVEIS                   | DIF <sub>Média</sub> | LC [95%]             | F [p-valor]        | r [95%]                  | EPM    | CCI <sub>3,1</sub> [95%] |
| TV <sub>SCM</sub><br>[s]    | 0,003                | [-0,044;<br>0,045]   | 0,002<br>[p=0,967] | 0,929<br>[0,827;0,972] * | 0,032  | 0,909<br>[0,784;0,963]   |
| H <sub>SCM</sub><br>[m]     | 0,001                | [-0,058;<br>0,061]   | 0,004<br>[p=0,951] | 0,934<br>[0,840;0,974] * | 0,043  | 0,911<br>[0,789;0,964]   |
| IMP <sub>SCM</sub><br>[N.s] | 0,302                | [-12,493;<br>13,098] | 0,001<br>[p=0,985] | 0,986<br>[0,965;0,994] * | 9,232  | 0,984<br>[0,961;0,994]   |
| UMI [SA]                    |                      |                      |                    |                          |        |                          |
| VARIÁVEIS                   | DIF <sub>Média</sub> | LC [95%]             | F [p-valor]        | r [95%]                  | EPM    | CCI <sub>3,1</sub> [95%] |
| TV <sub>SA</sub><br>[s]     | 0,019                | [-0,044;<br>0,083]   | 1,763<br>[p=0,192] | 0,757<br>[0,474;0,898] * | 0,045  | 0,758<br>[0,484;0,897]   |
| H <sub>SA</sub><br>[m]      | 0,024                | [-0,056;<br>0,105]   | 1,771<br>[p=0,191] | 0,771<br>[0,498;0,904] * | 0,058  | 0,770<br>[0,506;0,902]   |
| IMP <sub>SA</sub><br>[N.s]  | 5,390                | [-13,588;<br>24,369] | 0,243<br>[p=0,625] | 0,962<br>[0,904;0,985] * | 13,694 | 0,961<br>[0,949;0,992]   |
| PF [SCM]                    |                      |                      |                    |                          |        |                          |
| VARIÁVEIS                   | DIF <sub>Média</sub> | LC [95%]             | F [p-valor]        | r [95%]                  | EPM    | CCI <sub>3,1</sub> [95%] |
| TV <sub>SCM</sub><br>[s]    | 0,007                | [-0,032;<br>0,046]   | 0,240<br>[p=0,627] | 0,908<br>[0,780;0,963] * | 0,028  | 0,909<br>[0,785;0,963]   |
| H <sub>SCM</sub><br>[m]     | 0,028                | [-0,041;<br>0,060]   | 0,234<br>[p=0,632] | 0,910<br>[0,783;0,964] * | 0,037  | 0,910<br>[0,787;0,963]   |
| IMP <sub>SCM</sub><br>[N.s] | 2,660                | [-25,538;<br>30,860] | 0,025<br>[p=0,875] | 0,936<br>[0,843;0,974] * | 20,346 | 0,930<br>[0,831;0,972]   |
| PF [SA]                     |                      |                      |                    |                          |        |                          |
| VARIÁVEIS                   | DIF <sub>Média</sub> | LC [95%]             | F [p-valor]        | r [95%]                  | EPM    | CCI <sub>3,1</sub> [95%] |
| TV <sub>SA</sub><br>[s]     | 0,003                | [-0,028;<br>0,036]   | 0,083<br>[p=0,775] | 0,921<br>[0,809;0,969] * | 0,023  | 0,918<br>[0,805;0,967]   |
| H <sub>SA</sub><br>[m]      | 0,005                | [-0,034;<br>0,045]   | 0,098<br>[p=0,756] | 0,923<br>[0,813;0,969] * | 0,028  | 0,920<br>[0,809;0,967]   |
| IMP <sub>SA</sub><br>[N.s]  | -0,060               | [-15,892;<br>15,770] | 0,001<br>[p=0,987] | 0,957<br>[0,893;0,983] * | 11,422 | 0,956<br>[0,893;0,982]   |
| EL [SCM]                    |                      |                      |                    |                          |        |                          |
| VARIÁVEIS                   | DIF <sub>Média</sub> | LC [95%]             | F [p-valor]        | r [95%]                  | EPM    | CCI <sub>3,1</sub> [95%] |
| TV <sub>SCM</sub><br>[s]    | 0,006                | [-0,034;<br>0,048]   | 0,217<br>[p=0,644] | 0,901<br>[0,764;0,960] * | 0,029  | 0,948<br>[0,869;0,979]   |
| H <sub>SCM</sub><br>[m]     | 0,009                | [-0,046;<br>0,065]   | 0,232<br>[p=0,633] | 0,895<br>[0,749;0,958] * | 0,040  | 0,895<br>[-0,046;0,065]  |
| IMP <sub>SCM</sub><br>[N.s] | 2,229                | [-10,447;<br>14,905] | 0,035<br>[p=0,852] | 0,983<br>[0,957;0,993] * | 9,146  | 0,983<br>[0,957;0,993]   |
| EL [SA]                     |                      |                      |                    |                          |        |                          |
| VARIÁVEIS                   | DIF <sub>Média</sub> | LC [95%]             | F [p-valor]        | r [95%]                  | EPM    | CCI <sub>3,1</sub> [95%] |
| TV <sub>SA</sub><br>[s]     | 0,004                | [-0,045;<br>0,053]   | 0,134<br>[p=0,717] | 0,765<br>[0,488;0,902] * | 0,035  | 0,867<br>[0,663;0,947]   |
| H <sub>SA</sub><br>[m]      | 0,006                | [-0,057;<br>0,069]   | 0,183<br>[p=0,671] | 0,751<br>[0,445;0,891] * | 0,046  | 0,751<br>[0,454;0,889]   |
| IMP <sub>SA</sub><br>[N.s]  | 1,336                | [-14,091;<br>16,765] | 0,025<br>[p=0,876] | 0,956<br>[0,891;0,983] * | 11,132 | 0,957<br>[0,894;0,983]   |

\*Indica que o coeficiente de correlação é significativo (p<0,05).

Em adição, as medidas – critério adotadas na experimentação mostraram também um grau excelente de confiabilidade (PF - SA -  $CCI_{3,1} = 0,752 - 0,956$ ; SCM -  $CCI_{3,1} = 0,767 - 0,930$ ; EL - SA -  $CCI_{3,1} = 0,751 - 0,957$ ; SCM -  $CCI_{3,1} = 0,895 - 0,983$ ), com uma associação forte e positiva teste – reteste (PF – SA –  $r = 0,756 - 0,957$ ; SCM –  $r = 0,807 - 0,936$ ; EL – SA –  $r = 0,751 - 0,956$ ; SCM –  $r = 0,895 - 0,983$ ) e sem alterações significativas ( $p > 0,05$ ) foram identificadas entre sessões para as variáveis de tempo de voo, altura de salto, impulso e trabalho realizado. A tabela 1.7 descreve as medidas de confiabilidade entre dias e os gráficos de dispersão “Bland – Altman” são mostrados no apêndice C.

#### 2.5.6. Sprints

A tabela 1.8 mostra os dados referentes à concordância (erro sistemático absoluto e relativo), precisão (erro aleatório - EPM) e associação entre instrumentos nos testes de *sprints*. Os gráficos de “Bland – Altman” para as variáveis  $V_{max}$  e  $V_{med}$  entre instrumentos e sessões para os testes de *sprints* de 30 metros (Apêndice C). As análises de *sprints* evidenciaram diferenças sistemáticas significativas entre UMI e RE para  $V_{med}$  (S1: UMI –  $5,60 \pm 0,66$  m/s, CV = 11,83%; RE –  $7,02 \pm 0,50$  m/s, CV = 7,13%; ER% = 21,55%; F = 84,76;  $p < 0,001$ ; S2: UMI –  $6,94 \pm 0,59$  m/s, CV = 8,52%; RE –  $5,65 \pm 0,67$  m/s, CV = 11,98%; ER% = 18,53%;  $V_{med}$  – F = 31,74;  $p < 0,001$ ), porém, sem alterações para a  $V_{max}$  (Sessão 1: RE –  $8,18 \pm 0,66$  m/s, CV = 8,16%; UMI -  $7,85 \pm 1,06$  m/s, CV = 13,61%;  $V_{max}$  – ER% = 10,25%; F=6,517;  $p = 0,015$ ; Sessão 2: RE –  $8,11 \pm 0,71$  m/s, CV = 8,83%; UMI –  $8,03 \pm 1,08$  m/s, CV = 13,56%; ER% = 11,72%; F = 0,71;  $p = 0,141$ ), ou entre sessões para cada instrumento de medição (UMI:  $V_{med}$  – F = 0,05,  $p = 0,81$ ;  $V_{max}$  – F=0,26,  $p = 0,61$ ; RE:  $V_{med}$  – F=1,07,  $p = 0,31$ ;  $V_{max}$  – F=0,65,  $p = 0,42$ ).

Os modelos de regressão ajustados nos gráficos de “Bland – Altman” (Apêndice C) mostraram a ausência de relacionamento e associação para as diferenças observadas entre RE e UMI (Sessão 1 – [a] e [b],  $p > 0,05$ ;  $r = 0,02$  a  $0,10$ ,  $p > 0,05$ ;  $R^2 = 0,001$  a  $0,1$ ; Sessão 2 – [a] e [b],  $p > 0,05$ ;  $r = 0,03$  a  $0,35$ ,  $p > 0,05$ ;  $R^2 = 0,01$  a  $0,12$ ) e sessões para as variáveis estudadas (RE - [a] e [b],  $p > 0,05$ ;  $r = -0,142$  a  $-0,301$ ,  $p > 0,05$ ; UMI - [a] e [b],  $p > 0,05$ ;  $r = -0,142$  a  $-0,301$ ,  $p > 0,05$ ). Entre os métodos de medição, em detrimento aos coeficientes de regressão e correlação, os interceptos estimados foram significativos ([a]  $p < 0,05$  e [b],  $p > 0,05$ ;  $R^2 = 0,03$  a  $0,06$  - Tabela D2). Por outro lado, os valores de CCI indicam um grau aceitável para UMI, com boa a elevada

consistência de medida entre dias para RE para os instrumentos de medição estudados (Tabela 1.8).

Tabela 1.8 – Concordância e associação entre instrumentos de medição (*Race Encoder* – RE vs. Unidades de medida inercial – UMI) nas sessões 1 e 2 (A); Confiabilidade teste - reteste de UMI e RE (B) para a  $V_{max}$  e  $V_{med}$  nos *sprints*.

| Concordância entre Instrumentos |                      |                |      |                      |                         |
|---------------------------------|----------------------|----------------|------|----------------------|-------------------------|
| UMI vs. RE (Sessão 1)           |                      |                |      |                      |                         |
| Variáveis                       | DIF <sub>Média</sub> | LC [95%]       | EPM  | ER [%]               | r [95%]                 |
| $V_{med}$                       | -1,61                | [-2,87; -0,34] | 0,88 | 21,55±8,13           | 0,25 [-0,26; 0,65]      |
| $V_{max}$                       | -0,62                | [-2,38; 1,14]  | 1,21 | 10,25±7,11           | 0,26 [-0,25; 0,66]      |
| UMI vs. RE (Sessão 2)           |                      |                |      |                      |                         |
| Variáveis                       | DIF <sub>Média</sub> | LC [95%]       | EPM  | ER [%]               | r [95%]                 |
| $V_{med}$                       | -1,27                | [-2,94; 0,40]  | 1,20 | 18,53±9,68           | 0,21 [-0,30; 0,62]      |
| $V_{max}$                       | -0,12                | [-2,49; 2,26]  | 1,63 | 11,72±9,03           | 0,27 [-0,33; 0,60]      |
| Confiabilidade teste – reteste  |                      |                |      |                      |                         |
| UMI                             |                      |                |      |                      |                         |
| Variáveis                       | DIF <sub>Média</sub> | LC [95%]       | EPM  | r [95%]              | CC <sub>1,1</sub> [95%] |
| $V_{med}$                       | -0,12                | [-1,46; 1,22]  | 1,02 | 0,41 [-0,05; 0,72] † | 0,58 [-0,08; 0,83]      |
| $V_{max}$                       | -0,3                 | [-2,64; 2,04]  | 1,79 | 0,31 [-0,17; 0,66]   | 0,50 [0,61; 0,94]       |
| RE                              |                      |                |      |                      |                         |
| Variáveis                       | DIF <sub>Média</sub> | LC [95%]       | EPM  | r [95%]              | CC <sub>1,1</sub> [95%] |
| $V_{med}$                       | 0,21                 | [-0,89; 1,32]  | 0,78 | 0,56 [0,14; 0,81] *  | 0,71 [0,23; 0,88]       |
| $V_{max}$                       | 0,2                  | [-0,81; 1,21]  | 0,71 | 0,75 [0,44; 0,89] *  | 0,85 [0,61; 0,89]       |

\*Indica coeficiente de correlação é significativo ( $p < 0,05$ ); †Indica coeficiente de correlação as margens da significância ( $0,05 < p < 0,10$ ).

## 2.6. Discussão

### 2.6.5. Saltos Verticais

O presente estudo analisou a validade e confiabilidade de um modelo de sensores inerciais de baixo custo comparado às medidas–critério, sendo hipotetizado que os sensores inerciais de baixo custo testados devem apresentar concordância entre instrumentos e de boa a excelente consistência de medidas entre sessões para as variáveis estudadas. Além da confirmação da hipótese traçada inicialmente, de nosso conhecimento, ressalta-se que além de validar o tutorial proposto comparado a medidas padrão-ouro, este é primeiro estudo a evidenciar a ausência de diferenças ou viés significativo de UMI para com as medidas - critério (PF e EL), acompanhado por uma elevada repetibilidade em ambas as sessões de testagem (S1 e S2) para as variáveis de tempo de voo, altura de salto vertical e impulso em ambas as técnicas de SA e SCM.

As variáveis de tempo de voo e altura de salto para as técnicas de SA e SCM mostraram concordância e moderada associação entre UMI e PF. Em adição, a UMI

para com o EL mostrou de fraca a boa associação, sem diferenças, elevada concordância e confiabilidade teste – reteste para o tempo de voo e altura de saltos para ambos as técnicas. Os achados são consistentes com os estudos de Picerno; Camomilla; Capranica (2011), Staunton *et al.* (2018) e Rantalainen *et al.* (2018) que avaliaram a validade de um sensor inercial vestível para estimar a altura de SCM contra uma medida – critério (PF ou Sistema de análise cinemática 3D). Após a correção do sistema de referência, nestas pesquisas o desempenho do SCM para as variáveis de tempo de voo e altura de salto apresentou elevada concordância e associação entre os instrumentos de medição, sem alterações entre os métodos de medição. A altura de SCM baseada no tempo de voo exibiu melhor concordância e repetibilidade do que a altura de salto calculada a partir da velocidade de saída do solo.

Logo, não somente para o SCM como também para o SA, os resultados do presente estudo mostram que a avaliação do tempo de voo e altura de salto vertical pode ser realizada de forma acurada e com repetibilidade (confiabilidade teste–reteste) para o sensor testado, também para o SA. Na prática, isto sinaliza a possibilidade de quantificação da diferença de desempenho entre os SCM e SA por um sensor portátil e de baixo custo, um parâmetro que remete à capacidade de utilização do ciclo de alongamento–encurtamento, expressa pela razão ou percentual do desempenho observado entre ambas as técnicas de salto padronizado, em que quanto maior a diferença, maior sua utilização e desejável em diversas modalidades esportivas (HOOREN; ZOLOTARJOVA, 2017; STAUNTON *et al.*, 2018; RANTALAINEN *et al.*, 2019).

Para além do registro de saltos verticais padronizados, Spangler *et al.* (2018) analisaram a validade de sensores inerciais para detecção e quantificação a altura de saltos verticais durante a execução de circuito de atividades nos esportes coletivos. As atividades do circuito envolveram marcha, mudanças de direção, sprints, saltos verticais e horizontais. Entretanto, em contraste com os resultados obtidos no corrente estudo, a altura de salto vertical mensurada pelo sensor foi significativamente diferente da medida critério (análise cinemática 3D), subestimando a altura de salto, apesar da excelente associação entre os métodos de medição para ambos os tipos de saltos. O sensor e o algoritmo desenvolvido foram capazes de detectar saltos automaticamente e, apesar da excelente confiabilidade teste – reteste para ambos os instrumentos, contudo os autores aconselham cautela a respeito da quantificação da

altura de saltos. Possivelmente, o posicionamento dos sensores entre as escápulas em detrimento à colocação do sensor na região lombar, podem justificar as diferenças de subestimação da altura de salto encontradas (SPANGLER *et al.*, 2018; RANTALAINEN *et al.*, 2018).

Entre as medidas – critério (PF e EL), as variáveis de altura de SA e SCM mostraram elevada associação entre os métodos, confiabilidade teste – reteste e elevada concordância entre instrumentos. De forma divergente, apesar dos estudos de O'donnell *et al.* (2017), Wadih *et al.* (2018) e Hojka *et al.* (2022) apresentarem uma elevada confiabilidade teste – reteste e excelente associação entre instrumentos, o encoder linear evidenciou uma elevada superestimação (erro sistemático) em relação a plataforma de força para a altura de SA e SCM. Nesse sentido, a diferença entre os resultados obtidos pode ser atribuída aos dispositivos empregados e o método de medição da altura de salto.

O modelo de sensor testado apresentou de boa a excelente associação entre métodos de medição (PF vs. EL, PF vs. UMI e EL vs. UMI), excelente correlação entre sessões para cada instrumento (PF, EL e UMI), com excelente confiabilidade teste – reteste para a variável impulso no SA e SCM. Adicionalmente, elevada concordância entre foi verificada entre as medidas–critério adotadas e entre a PF para com o sensor testado, sem viés significativo entre os instrumentos para ambos os saltos. Entretanto, apesar da excelente confiabilidade entre sessões, excelente associação do EL e UMI (SCM e SA), com adequada concordância para  $IMP_{SCM}$ , um pequeno viés decrescente e significativo foi verificado para o  $IMP_{SA}$ . Nesse sentido, entre a PF e UMI, os resultados corroboram com os achados obtidos por Staunton *et al.* (2018), entretanto, os autores não reportaram a confiabilidade teste – reteste, devido ao desenho experimental adotado. Conceitualmente, o impulso é definido como a integral da curva de força no tempo, logo, uma variável determinante de grande importância para avaliar adequadamente a capacidade de força, sensível monitoramento do desempenho neuromuscular (AAGAARD *et al.*, 2002; RICE *et al.*, 2016). Além disso, dada a repetibilidade reportada pelo instrumento, a obtenção de dados de múltiplos indivíduos na rotina diária de treinos e competições torna-se viável e rápida.

Setuain *et al.* (2016) examinaram a confiabilidade dos dados obtidos de UMI e validade contra uma PF para avaliação biomecânica de SCM unilateral, saltos em profundidade uni e bilaterais. Os autores verificaram um nível robusto de associação entre os dados brutos da curva força - tempo entre UMI e PF. Contudo, uma tendência

crescente do erro sistemático de medida foi evidenciada, ou seja, quanto maior a força, maior a discordância entre os dispositivos de medição. No entanto, neste estudo foram utilizadas técnicas de saltos verticais e variáveis de diferentes das quantificadas no presente trabalho, dificultando o estabelecimento adequado de comparações entre os sensores utilizados e resultados obtidos.

Uma das limitações do estudo residiu na ausência de um sistema de análise cinemática para condução do estudo de validação, além da necessidade de exploração de um maior número de variáveis relacionadas ao desempenho de saltos verticais. Além disso, em virtude de o sensor testado possuir características de armazenamento de dados *offline*, na prática, o monitoramento do desempenho de saltos verticais pode ser viabilizado apenas após as sessões de treino. Logo, para a obtenção dos resultados, há a necessidade de dispêndio de tempo considerável entre sessões para processamento de dados de muitos indivíduos, constituindo-se em uma das limitações para o uso do sensor validado.

#### 2.6.6. *Sprints*

A análise da validade e confiabilidade de UMI comparada ao dispositivo *Race Encoder*® destacou uma significativa subestimação da  $V_{med}$ , em contraste com a concordância entre dispositivos observada para a  $V_{max}$  registrada em *sprints* de 30m. Além disso, uma aceitável repetibilidade entre – dias das UMI foi evidenciada para ambas as variáveis na determinação das variáveis de  $V_{max}$  e  $V_{med}$  foram evidenciadas, em linha com a hipótese delineada previamente.

Apesar da ausência de associação e diferenças sistemáticas entre UMI e a medida concorrente para a velocidade máxima de *sprints*, os achados obtidos parecem alinhar-se com os resultados observados na literatura (PARRINGTON *et al.*, 2016; SETUAIN *et al.*, 2017; GURCHIEK *et al.*, 2018; APTE *et al.*, 2020). Setuain *et al.* (2018), ao analisar a validade e confiabilidade de UMI durante *sprints* de 20 metros, não evidenciaram alterações médias e baixo erro sistemático ente métodos de medição para a velocidade máxima ( $ER\% = 3,35 \pm 4,07\%$ ) contra a PF (medida-critério), com elevado grau de confiabilidade intra-sessão para as UMI (CCI = 0,88). Logo, em consonância com o presente estudo, as UMI testadas mostraram validade e confiabilidade satisfatórias para determinação da  $V_{max}$  em *sprints*. Por outro lado, Gurchiek *et al.* (2018) evidenciaram uma pequena superestimação do pico de velocidade (0,20m/s), comparado a fotocélulas ( $ER\% = 7,84\%$ ) em *sprints* de 40

metros. Em linha, ao estabelecer uma comparação entre uma medida-critério (radar laser) e UMI durante *sprints* de 100 metros, Parrington *et al.* (2016) mostraram elevada associação e baixo erro padrão de estimação (EPE) entre sensores inerciais e um radar laser para a determinação da  $V_{max}$  ( $r = 0,89$ ; EPE = 0,23;  $4,2 \pm 2,5\%$ ). Adicionalmente, Apte *et al.* (2020), a partir do método proposto de fusão de dispositivos GNSS e UMI, reportaram uma íntima concordância entre a velocidade máxima estimada pelo sensor e os valores da medida-critério (Diferença média = -0,16; LC = -1,20; 0,89).

Apesar da subestimação significativa destacada no presente estudo para determinação da  $V_{med}$ , os resultados observados parecem corroborar em parte com a tendência de alteração sistemática observada em estudos prévios. Gurchiek *et al.* (2018) ao avaliar a validade concorrente de UMI para registro da velocidade média a cada 10 metros, verificou uma significativa subestimação de -0,05 m/s a -0,25 m/s nos trechos de 0 a 10m, 10m a 20m e 20m a 30m, superestimando o último trecho por 0,13m/s (30m a 40m), com o erro absoluto oscilando de 0,20m/s a 0,63 m/s e o erro relativo da ordem de 3,95% a 7,84%. No entanto, para a confiabilidade de medida intra-sessão, com o aumento dos intervalos de distâncias percorridas, o limite de concordância cresceu progressivamente (0 a 10m: -0,59 m/s, 0,34 m/s; 10 a 20m: -1,18 m/s, 0,68 m/s; 20 a 30m: -1,30 m/s, 1,20 m/s; 30 a 40m: -1,32m/s, 1,59 m/s). Por outro, para *sprints* de 100m, Parrington *et al.* (2016) mostraram elevada associação entre UMI e valores de referência obtidos de um radar laser para valores de velocidades média registrados a cada 10 metros, com baixo erro padrão de estimação (0,17m/s a 0,44 m/s).

No entanto, para ambas as variáveis estudadas, em virtude do emprego de diferentes sensores inerciais (sensores de diferentes fabricantes compostos por acelerômetros e giroscópios com ou sem magnetômetros), variados dispositivos de referência na literatura (plataforma de força, radar laser, fotocélulas, dispositivos GNSS, etc), distâncias adotadas para tarefa de *sprint* (20m, 30m, 40m, 60m e 100m), bem como os procedimentos de processamento adotados (fusão de sensores, integração numérica, interpolação ou ajuste adotado) a comparação para com os resultados obtidos deve ser observada com cautela, uma vez que, somente no presente estudo um *encoder* rotatório foi empregado como medida de referência. Além disso, os estudos citados não reportam a confiabilidade teste-reteste, fundamental ao entendimento do comportamento do sensor para emprego diário por possíveis

usuários. Para além dos resultados observados para as UMI, este é o primeiro estudo a reportar a repetibilidade de medida para dispositivos baseados em *encoders* rotatórios na tarefa de sprints, evidenciando de boa ( $V_{max}$ ) a excelente ( $V_{med}$ ) consistência de medida para a tarefa de sprints. Logo, o dispositivo *Race Encoder*® mostrou-se também como uma alternativa viável para medição da velocidade instantânea em avaliações de rotina do desempenho de *sprints*.

Por outro lado, apesar do erro oriundo da integração numérica sobre séries temporais curtas (<6s) ser considerado como desprezível, é importante ressaltar que a melhoria da acurácia de estimação da velocidade instantânea está relacionada com a adoção de métodos de correção do *drift* de integração, não realizada neste estudo. Logo, a estimação da função no tempo que se aproxima do *drift* deve ser executada empregando o algoritmo de atualização ZUPT, para calibração do sensor e correção da velocidade instantânea (COYTE *et al.*, 2013; MA *et al.*, 2018a; LU *et al.*, 2019; YU *et al.*, 2019). Além disso, o presente estudo falhou em não introduzir um procedimento objetivo de sincronização entre instrumentos (*Race Encoder* vs. UMI), considerando a óbvia limitação de conexão sem fio dos sensores de baixo custo utilizados, bem como pela ausência de um sistema de análise cinemática tridimensional para condução do estudo de validação, assim como há a necessidade de exploração de outras variáveis.

## 2.7. Conclusões

### 2.7.5. Saltos Verticais

Em conclusão, o modelo de UMI de baixo custo testado proporcionou medições válidas para a determinação do tempo de vôo, altura de salto e impulso quando comparadas à plataforma de força e encoder linear (medidas - critério), com elevada confiabilidade teste – reteste (repetibilidade) quando os saltos padronizados (SA e SCM) são executadas em sessões (dias) diferentes, confirmando a hipótese previamente estabelecida. Logo, os sensores testados são viáveis, por serem leves, portáteis, de baixo custo e permitindo a avaliação rápida de muitos indivíduos para monitoramento do desempenho (entre sessões).

### 2.7.6. *Sprints*

Em suma, apesar da concordância reportada entre dispositivos de medição para a determinação da velocidade máxima, o modelo de UMI subestimou significativamente a quantificação da velocidade média em relação ao dispositivo *Race Encoder*, possibilitando medições válidas com aceitável repetibilidade. Nesse sentido, além da portabilidade, as UMI possuem viabilidade para avaliação relativamente rápida do desempenho de *sprints* de grupos de indivíduos para monitoramento e controle das demandas físicas. Entretanto, para medições mais acuradas, novos estudos adotando a correção do *drift* de integração devem ser conduzidos por meio da utilização do método “zero – velocity updates” (ZUPT).

## **CAPÍTULO 3 – UTILIZAÇÃO DE SENSORES INERCIAIS E MÉTODOS DE APRENDIZADO DE MÁQUINA PARA RECONHECIMENTO DE AÇÕES COMUNS AOS ESPORTES COLETIVOS (EXPERIMENTO II)**

### **3.1. Introdução**

A classificação de atividades físico – esportivas é parte essencial na análise de treinos e competições para entendimento das demandas, otimização do desempenho e prevenção de lesões. O procedimento de classificação das atividades ou ações – alvo perpassa frequentemente pelo registro de vídeo, requerendo considerável dispêndio de recursos humanos, financeiros e tempo disponível para execução da tarefa (CARDINALE; VARLEY, 2017; JOWITT *et al.*, 2020; MCGRATH *et al.*, 2020). Entretanto, uma abordagem alternativa tem sido proposta para superar estas limitações, baseando-se na adoção de unidades de medida inercial (UMI) de baixo custo e utilização das características de sinal dos sensores para automatização do reconhecimento de atividades por meio de métodos de aprendizado de máquina (SWEETING *et al.*, 2017; CAMOMILLA *et al.*, 2018; HALILAJ *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019; MCGRATH *et al.*, 2020). Logo, por definição esta abordagem é dependente de características de entrada com potencial discriminativo, utilizadas para treinamento e validação de tais algoritmos de classificação (CAMOMILLA *et al.*, 2018; HALILAJ *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019).

Na prática do treinamento e maioria dos estudos conduzidos, os sensores vestíveis de rastreamento empregados integram dispositivos GPS e sensores inerciais (acelerômetros, giroscópios e magnetômetros) com a finalidade de quantificação de variáveis mecânicas, sendo posicionados predominantemente no tronco entre as escápulas (MALONE *et al.*, 2017; CAMOMILLA *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019). Entretanto, considerando os custos elevados de aquisição, somado aos problemas identificados a respeito da validade de variáveis cinemáticas em ações de alta intensidade, estes dispositivos têm sido empregados de forma restrita a uma parcela de equipes profissionais (JOHNSTON *et al.*, 2014; MALONE *et al.*, 2017; MALONE *et al.*, 2020). Nesse contexto, diversos experimentos têm destacado a possibilidade de melhor exploração de UMI de baixo custo em treinos e

competições, aprimorando procedimentos de análise do desempenho nos esportes coletivos (KELLY *et al.*, 2012; TROST *et al.*, 2014; WUNDERSITZ *et al.*, 2015b; SCHULDHAUS *et al.*, 2015; NGUYEN *et al.*, 2015; KAUTZ *et al.*, 2017; HOLZEMANN; LAERHOVEN, 2018; PENG *et al.*, 2018; HALADJIAN *et al.*, 2020 JOWITT *et al.*, 2020). Nesse sentido, Trost; Zheng; Wong (2014) compararam a capacidade de reconhecimento de classificadores treinados a partir do sinal de acelerômetros posicionado no punho e no quadril. A acurácia média de classificação para o sensor posicionado no quadril foi de 91,0% e 88,4% para o dispositivo fixado punho nas atividades de permanecer deitado, sentado, parado, durante a marcha, corrida e prática do basquetebol. Logo, os algoritmos treinados para ambas as posições de fixação dos sensores alcançaram níveis aceitáveis de acurácia para o reconhecimento das atividades citadas.

Em circuito simulado, Wundersitz *et al.* (2015b) avaliaram se os dados obtidos a partir de um único sensor inercial podem ser utilizados para classificar atividades relacionadas com os esportes coletivos. Os autores encontraram que o algoritmo *Logistic Model Tree* apresentou melhor desempenho para acurácia de classificação (79% a 92%), utilizando características extraídas no domínio do tempo e da frequência do acelerômetro e giroscópio. Logo, a utilização de características oriundas do giroscópio melhorou substancialmente o desempenho médio de classificação (92%), envolvendo atividades de parada, marcha, corrida, mudanças de direção, saltos e colisões. Deve ser mencionado que, por importância prática, permanece em aberto se a posição acomodação dos sensores afeta o desempenho dos algoritmos de classificação é afetado (Ex.: sensor no tronco vs. sensor próximo ao centro de gravidade).

Adicionalmente, Kautz; Groh; Eskofier (2015) treinaram algoritmos de reconhecimento (*Random Forest, Naive Bayes, Multilayer perceptron, Bayes Network*) para quantificar colisões e *scrums* no rugby utilizando UMI associado com sistema de posicionamento local. Os autores encontraram uma acurácia maior que 97%, sensibilidade e especificidade de detecção superior a 95% dos movimentos, evidenciando que os sensores podem efetivamente reconhecer estas atividades em múltiplos indivíduos. Em outra perspectiva, Jowitt *et al.* (2020) adotaram a abordagem baseada em aprendizado de máquina para classificar automaticamente movimentos de lançamento no cricket obtidos em treinos e competições utilizando dados provenientes de dispositivos GPS e sensores inerciais (sensor posicionado nas costas). O algoritmo

treinado mostrou elevada sensibilidade e especificidade (> 95%) de classificação dos lançamentos para treinos e partidas, proporcionando uma ferramenta útil de monitoramento para treinadores.

No futebol, Haladjian *et al.* (2020) desenvolveram um algoritmo para classificar exercícios de treinamento para goleiros empregando um sensor inercial customizado nas luvas dos voluntários. Após o emprego de técnicas de pré-processamento, os pesquisadores extraíram características de ordem estatística e heurística para descrever e treinar os classificadores (*Nayve Bayes, Decision Tree, Random Forest, Support Vector Machines, k – Nearest Neighbors e Neural Networks*), obtendo em média 90,6% de precisão (proporção de eventos corretamente identificados em relação ao número total de eventos detectados) e 96,5% de acurácia (taxa de classificações corretas obtidas pelo algoritmo classificador – eventos e não - eventos). Adicionalmente, Schuldhaus *et al.* (2015) desenvolveram um sensor inercial de baixo custo customizado nas chuteiras e caneleiras dos voluntários para classificar passes e chutes também no futebol. Logo, as características foram extraídas e os classificadores treinados (*Support Vector Machines, Naive Bayes, Classification and Regression Trees*). Os resultados mostraram que o sistema composto pelo sensor e algoritmo de reconhecimento foi capaz de diferenciar corretamente passes de chutes em 84,2% das ações.

Para o basquetebol, diferentes estudos têm sido conduzidos com a tentativa de classificar diferentes tipos de atividades de jogo por meio de UMI customizadas e acomodadas no punho (NGUYEN *et al.*, 2015; HOLZEMANN; LAERHOVEN, 2018; MA *et al.*, 2018b; KUHLMAN; MIN, 2021). Ma *et al.* (2018b) encontraram uma acurácia média de classificação muito elevada (98,9%) para ações de permanecer parado, marcha, correr, saltos, executar dribles, arremessos e arremessos com saltos. Na mesma linha, Holzemann; Laerhoven (2018) verificaram uma boa acurácia geral de 83,6% a 87,5% para ações de drible, arremessos ou passes, e em estudo preliminar, Kuhlman; Min (2021) evidenciaram um acurácia de 85% para classificação de arremessos com boa e má execução de 2 e 3 pontos. Tais resultados podem ser explicados em parte pela utilização de dados de apenas de poucos indivíduos (n = 1 a 3) no treinamento dos classificadores. No entanto, Nguyen *et al.* (2015) falharam em identificar com elevada acurácia atividades de deslocamento (marcha - 80,98%; corrida leve - 51,98%; corrida moderada - 44,63%; sprints – 59,29%; saltos – 66,60%) e de arremessos (arremesso com salto – 78,65%; bandeja – 65,39%; arremesso de

pivô – 90,22%), sugerindo a necessidade de adição de novas características dos sensores e mais participantes. Logo, uma vez que não há consenso sobre a capacidade das UMI de baixo custo para classificar acuradamente ações de locomoção nos esportes coletivos, há a necessidade de melhor exploração das possibilidades do tema, por exemplo, ampliando o tamanho da amostra e o número de informações a serem utilizadas pelo algoritmo de aprendizagem (CAMOMILLA *et al.*, 2018; HALILAJ *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019).

Além disso, apesar do relativo sucesso observado no treinamento e validação dos algoritmos de aprendizado de máquina, evidenciado pela acurácia, sensibilidade, especificidade e precisão de classificação, tais experimentos amplamente não têm reportado essas mesmas características de desempenho para um conjunto independente de dados de teste, bem como a verificação da concordância entre eventos corretamente identificados no treinamento e a avaliação (testagem) do desempenho dos modelos. Outra limitação dos estudos reportados, é que o treinamento e validação dos algoritmos de classificação foram conduzidos a partir de características de entrada com natureza estatística de ordem descritiva nos domínios do tempo e frequência das ações (CAMOMILLA *et al.*, 2018; HALILAJ *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019). Partindo do pressuposto que o processo de classificação é realizado por meio do registro de séries temporais de dados dos sensores, parece razoável que a combinação da extração de características de ordem estatística, baseadas na aceleração resultante (customizadas) e medidas de análise de séries temporais para o treinamento dos algoritmos de classificação, em hipótese, evidencie um melhor desempenho de acurácia, precisão, sensibilidade e especificidade, dado o acréscimo de informação na caracterização dos diferentes padrões de movimento. Logo, no presente capítulo, será explorada a utilização dos sensores inerciais para reconhecimento de ações comuns presentes nos esportes coletivos empregando métodos de aprendizado de máquina.

### **3.2. Objetivo**

Analisar o desempenho de classificação das ações comuns aos esportes coletivos (permanecer estático, situações de marcha, corrida de intensidade leve, corrida de intensidade moderada, *sprints* com desaceleração, saltos padronizados e mudanças de direção) por métodos de aprendizagem estatística, a partir de características

extraídas da literatura (estatísticas descritivas), customizadas (aceleração resultante vertical e horizontal) e medidas de análise de séries temporais.

### **3.3. Hipóteses**

H1 – Os sensores inerciais testados terão desempenho de classificação e concordância entre as etapas de treinamento e testagem satisfatória para as ações do circuito simulado proposto.

H2 – A combinação de acelerômetros e giroscópios evidenciará melhor desempenho para classificação de ações comparado a utilização isolada do acelerômetro.

H3 – O desempenho de classificação com a combinação de sensores e características estatísticas, customizadas e medidas de análise de séries temporais apresentarão melhor acurácia, precisão, sensibilidade e especificidade.

### **3.4. Materiais & Métodos**

#### *3.4.1. Delineamento do estudo*

Este estudo é caracterizado também como do tipo experimental e transversal, para reconhecimento de ações através do uso de sensores inerciais. Os participantes foram submetidos à realização de um circuito de atividades composto por ações comuns aos jogos esportivos coletivos (parada, marcha, corrida de intensidade leve, moderada, *sprints* com desacelerações, mudanças de direção, saltos com contramovimento).


#### *3.4.2. Cuidados éticos*

Este estudo foi submetido e aprovado junto ao comitê de ética em pesquisa local (CAAE 38365620.3.0000.5149). Os voluntários foram informados quanto aos objetivos, métodos, possíveis riscos e benefícios oriundos da participação no estudo. Em seguida, o consentimento foi recolhido por escrito por intermédio de um TCLE (Apêndice A), sendo facultado aos voluntários o direito de deixar de participar do estudo a qualquer momento, sem prejuízos.



Neste segundo experimento, os participantes foram submetidos inicialmente à familiarização com um circuito de ações comuns aos esportes coletivos. O circuito de ações compreenderá um salto com contramovimento, caminhada, corridas de intensidade leve (*jogging*), corrida de intensidade moderada (*moderate intensity running*), corrida de intensidade máxima (*sprint*) seguida por uma desaceleração e movimento de mudança de direção (MMD). Os indivíduos foram instruídos a executar ações de SCM, *sprint* e MMD sempre com a maior intensidade possível, enquanto para as ações de caminhada (sem a retirada ambos os tornozelos do solo), corridas de intensidade leve e moderada deverão ser executadas em velocidade auto – selecionada. Após o procedimento de familiarização, os voluntários realizaram um aquecimento padrão composto por 10 minutos de corrida leve com velocidade auto - selecionada e 5 saltos com contramovimento submáximos. A figura 3.1 mostra o circuito simulado de ações comuns aos esportes coletivos.

FIGURA 3.2 – Configuração do posicionamento do sensor inercial.

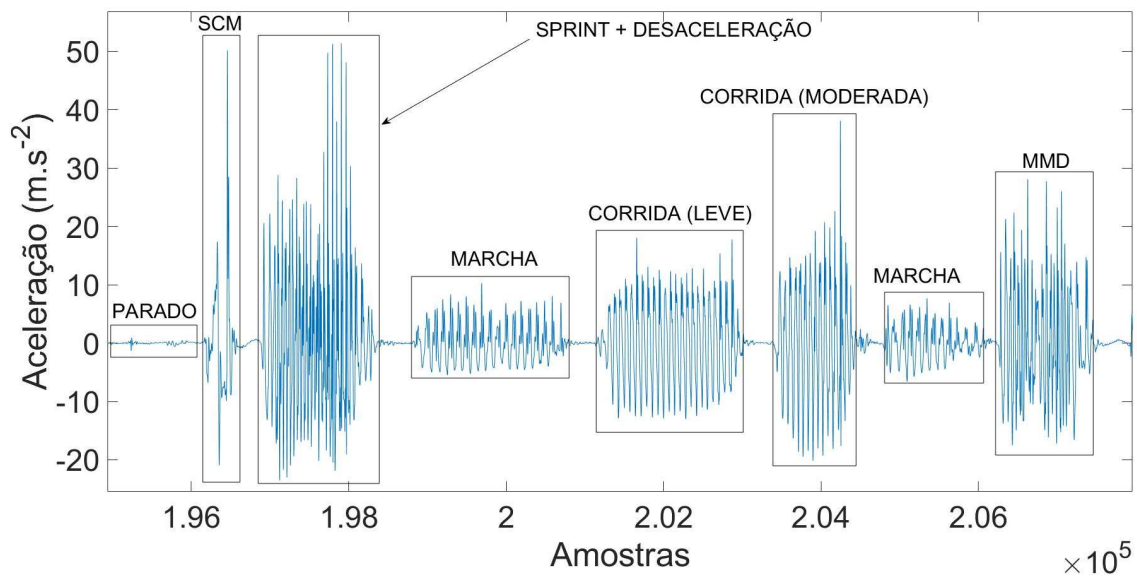


Fonte: Dados da pesquisa.

Na sequência, sensores inerciais (WT901SDCL, Wit - Motion, Shenzhen, China) foi acionado e posicionado na região lombar (L4-L5) aderido ao cinto de tração nos indivíduos (Figura 3.2). O sensor é composto por um acelerômetro (x, y, z;  $\pm 16$  g), giroscópio (x, y, z;  $\pm 2000^\circ/\text{s}$ ) e magnetômetro (x, y, z;  $\pm 4900\mu\text{T}$ ) triaxiais (MPU-9250, TDK InvenSense, San Jose, California, EUA). O registro foi realizado a uma taxa de amostragem de 100Hz e o armazenamento em micro – cartão de memória. O sensor possui a função de registro de data e hora, utilizados para identificação do momento de realização de coletas de dados nos experimentos (consumo  $< 40\text{mA/h}$ , bateria de lítio de  $260\text{mA/h}$  e tensão de 3,7V). Os sensores foram previamente calibrados em

conformidade com o procedimento executado no experimento anterior. As séries temporais de aceleração linear ( $g$ ), velocidade angular ( $^{\circ}/s$ ), campo magnético ( $\mu T$ ), ângulo de Euler (eixos “x”, *pitch*; “y”, *roll*; “z”, *yaw*), quatérnions ( $q_0$ ,  $q_1$ ,  $q_2$  e  $q_3$ ) e o registro de data e hora das coletas (função “*time-stamp*”) foram armazenados em microcartão de memória, sendo descarregados por meio do software MIMU® (Wit - Motion, Shenzhen, China).

FIGURA 3.3 – Aceleração linear no eixo vertical (“x”) durante a realização do circuito simulado de ações.



Fonte: Dados da pesquisa.

O SCM foi sucedido em sequência por um *sprint* de 20 metros, uma desaceleração de 10 metros seguida por uma recuperação incompleta e estática de 10 segundos. Após breve recuperação, os participantes executaram um trecho de marcha por 10m, sucedida por um período estático de 10 segundos. Imediatamente após, os participantes realizaram uma corrida de intensidade leve por 15 metros e uma corrida de intensidade moderada intercaladas por uma pausa de 10 segundos. Na sequência, os indivíduos percorreram um trecho de marcha de 5 metros e uma pausa de 10 segundos antes executar o MMD. Para o MMD, os participantes correram em linha reta por 5 m e realizaram uma mudança de  $180^{\circ}$ , retornando à posição inicial pelo mesmo trajeto iniciado, respeitando as marcações estabelecidas no solo (STEVENS *et al.*, 2014; JOHNSTON *et al.*, 2014; WUNDERSITZ *et al.*, 2015b; FESSI *et al.*, 2018;

FALCH; RAEDERGARD; TILAAAR, 2019; BALLOCH *et al.*, 2019; GILES; KOVALCHIK; REID, 2020).

Cada indivíduo por repetição realizou 1 SCM, 15 metros de caminhada, 10 metros de desacelerações, 15 metros de corrida em intensidade leve, 15 metros de corrida em intensidade moderada, 20 metros de *sprints* e 1 MMD (10 metros) por circuito simulado. Ao todo cada indivíduo percorreu 20 vezes o circuito, sendo distribuídas em 2 séries de 6 repetições, repetidas após 48 horas. Entre séries foram respeitados de 2 a 3 minutos de descanso entre repetições (WUNDERSITZ *et al.*, 2015b; GILES; KOVALCHIK; REID, 2020).

Para registro das coletas, visualização e inspeção das ações realizadas durante a realização dos circuitos simulados, uma câmera *GoPro Hero 6 Black*® fixada em um tripé próximo à linha de fundo da quadra foi empregada (GoPro, San Mateo, EUA, bateria de 5200mA/h, tensão operacional de 3,7V – 5V, taxa de amostragem de 120Hz, full HD, 12 megapixels, 1080x240 de resolução). A câmera foi acionada remotamente e armazenadas em um microcartão de memória (SDXC e 256gb). A partir destes registros, as ações foram inspecionadas para identificar possíveis problemas de execução dos circuitos e posterior exclusão do conjunto amostral, caso necessário.

#### 3.4.5. *Processamento e Análise Estatística*

Nesta subseção, o pré-processamento, processo de extração de características, treinamento, validação cruzada e avaliação do desempenho dos algoritmos de classificação de ações são detalhadas. Inicialmente, as séries temporais de aceleração linear ( $g$ ) e velocidade angular ( $^{\circ}/s$ ) nos eixos “x”, “y” e “z” foram descarregadas através do software MIMU® (Wit - Motion, Shenzhen, China). Na sequência, as séries temporais de aceleração e velocidade angular foram filtradas com um filtro *butterworth* passa – baixa (8 Hz, *zero-lag*, 4ª ordem; 40 Hz, *zero-lag*, 4ª ordem, respectivamente) para rejeição do ruído e um filtro *butterworth* passa – alta (0,3 Hz, *zero-lag*, 4ª ordem) para correção da gravidade (ROELL *et al.*, 2019). Em seguida, as ações dos circuitos foram segmentadas e rotuladas manualmente para extração das características, por meio da visualização séries temporais e identificação dos períodos de “silêncio” (ou ruído basal) entre as ações no sinal através do software Matlab R2021b (MathWorks®, Natick, EUA). As ações executadas no circuito simulado, bem como os períodos de “silêncio” são ilustrados na figura 3.3.

No próximo passo, uma rotina foi construída para extração de características de natureza estatística descritiva, características customizadas a partir da aceleração resultante e por procedimentos de análises de séries temporais provenientes do acelerômetro (eixos “x”, “y”, “z”,  $a_{hor}$  e  $a_{vert}$ ) e giroscópio (eixos “x”, “y” e “z”), empregando o pacote “*tsfeatures*” (HYNDMAN *et al.*, 2020), do software “R”, versão 4.1.2 (<https://cran.r-project.org/>). A partir dos dados filtrados, as series temporais aceleração resultante na direção horizontal ( $a_{hor}$ , eixos “y” e “z”) e vertical ( $a_{vert}$ , eixo “x”) foram calculadas conforme as equações de 1 a 2:

$$a_{hor} = \sqrt{y^2 + z^2} \quad \text{Equação 1}$$

$$a_{vert} = \sqrt{x^2} \quad \text{Equação 2}$$

Após a extração das características e rotulação das amostras (Tabela 2.1), os dados obtidos foram particionados em bancos de dados independentes para treinamento e validação do modelo (70% dos dados) e avaliação do desempenho dos algoritmos treinados (30% dos dados). A composição buscou manter a independência entre os bancos de dados, onde as repetições de um indivíduo “*i*” uma vez alocadas para treinamento e validação dos algoritmos, não fizeram parte do banco de dados de teste do desempenho dos modelos, para minimizar o viés de seleção. Inicialmente, sete indivíduos foram alocados para o treinamento e validação dos algoritmos de classificação e três para o banco de dados de teste. Uma vez que 11 indivíduos foram recrutados e coletados, as repetições de um indivíduo foram divididas proporcionalmente entre ambos os bancos de dados.

Tabela 2.1 – Características extraídas (*m*), ações classificadas e algoritmos de treinados e avaliados.

|                                        | Características (Variáveis de entrada)                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                        | Algoritmos de classificação                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                 | Ações (variáveis de saída)                                                                                                                                                                                                                                                         |
|----------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Estadística descritiva                 | <p><b>Domínio do tempo:</b> média, mediana, variância, amplitude, máximo, mínimo, assimetria, curtose, quartis, amplitude interquartis, correlação entre eixos;</p> <p><b>Domínio da frequência:</b> mediana espectral, centroide espectral, quartis (25% e 75%) e amplitude interquartis espectrais.</p>                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                     | <p><b>1) Decision trees (DT Fine)</b> – árvores de decisão consistem em conjunto de “nós” internos organizadas como um modelo hierárquico do tipo “se – então”;</p> <p><b>2) Support Vector Machines (SVM linear, quadratic e cubic)</b> – conjunto de métodos de aprendizado supervisionado para análise do conjunto de dados de entrada com o objetivo de encontrar um hiperplano de separação entre classes e predição destas classes;</p> <p><b>3) k – Nearest Neighbors (k-NN “fine”, “medium”, “cosine”, “cubic”, “weighted”)</b> – algoritmo de aprendizado baseado em instâncias por meio de métricas de similaridade ou dissimilaridade entre amostras;</p> <p><b>4) Ensemble classifiers (Boosted Trees, Bagged Trees)</b> – modelo preditivo de aprendizagem estatística, composto por uma combinação ponderada de vários algoritmos de classificação, em geral, a combinação de vários algoritmos de classificação aumenta o desempenho preditivo</p> <p><b>5) Neural Networks (Narrow, Medium, Wide, Bilayered, Trilayered)</b> – algoritmo baseado em um conjunto de neurônios artificiais e função de ativação específica, distribuídos ou não em camadas a partir de conjunto de entrada e saídas conhecidas, em que os pesos das arestas são ajustados para classificação a partir de uma taxa de aprendizagem conhecida por meio do algoritmo <i>backpropagation</i>.</p> | <p>1) Parada;</p> <p>2) Salto com contramovimento (SCM);</p> <p>3) Caminhada;</p> <p>4) Corrida em intensidade leve;</p> <p>5) Corrida em intensidade moderada;</p> <p>6) Sprints com desacelerações;</p> <p>7) Movimento de mudanças de direção (MMD) de 180 graus.</p> <p>..</p> |
| Medidas de Análise de Séries Temporais | <p><b>Crossing Points</b> - número de vezes que os valores “<i>i</i>” da série temporal cruza/supera o valor da mediana;</p> <p><b>Entropia espectral da série temporal</b> - Medida de dispersão dos dados de séries temporais estimado usando um modelo autoregressivo, dados com uma distribuição de probabilidade ampla e achatada apresentam um elevado de entropia; dados com uma distribuição estreita e em picos possuirão um baixo valor de entropia da série temporal, um descritor estatístico de variabilidade do sinal respectivo para cada ação estudada;</p> <p><b>Flat spots</b> - número de <i>flat spots</i> ou pontos/regiões de baixa magnitude de aceleração na série temporal;</p> <p><b>Moda da série temporal</b> - moda do vetor de dados;</p> <p><b>Coefficiente de Hurst</b> - parâmetro de quantificação da tendência e intensidade de uma série temporal, oscilando de 0 a 1: (a) <math>0 &lt; Hurst &lt; 0,5</math> - representa uma série anti – persistente em que um aumento sinalizará um decrescimento, ou vice-versa; (b) <math>0,5 &lt; Hurst &lt; 1,0</math> – descreve um comportamento de persistência, onde um decrescimento tenderá a seguir de um decrescimento; (c) <math>Hurst = 0,5</math> – descreve um comportamento aleatório da série temporal;</p> <p><b>Medida de granulidade</b> - variância das variâncias da série da série temporal;</p> <p><b>Estabilidade</b> - variância da média da série temporal;</p> <p><b>Coefficiente de não – linearidade da série temporal</b> (cômputo de uma estatística de não – linearidade da série temporal - <math>10X^2/T</math>, onde <math>X^2</math> representa a estatística de qui – quadrado de “Testasvirta” e “T”, o comprimento da série temporal);</p> <p><b>Tendência e sazonalidade da série temporal</b> – (a) Tendência corresponde ao aumento ou diminuição gradual de observações ao longo do tempo, assumindo diferentes comportamentos (linear, exponencial, estocástica etc.); (b) Sazonalidade remonta a um fenômeno ou comportamento é repetido em um período semelhante.</p> |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                             |                                                                                                                                                                                                                                                                                    |

As “*features*” ou características (*m*) foram organizadas em bancos de dados da seguinte forma: (1) Estatísticas descritivas obtidas do acelerômetro triaxial (ACC1); (2) Estatísticas descritivas e customizadas (aceleração resultante horizontal e vertical) obtidas do acelerômetro triaxial (ACC2); (3) Estatísticas descritivas, customizadas e medidas de análise de séries temporais obtidos do acelerômetro triaxial (ACC3); (4) Estatísticas descritivas obtidas do acelerômetro e giroscópio triaxial (ACC1+GIR1); (5) Estatísticas descritivas obtidos do acelerômetro triaxial e giroscópio triaxial, além das customizadas (ACC2+GIR1); e (6) Estatísticas descritivas obtidos do acelerômetro triaxial e giroscópio triaxial, customizadas e medidas de análise de séries temporais obtidos do acelerômetro triaxial (ACC3+GIR1), totalizando 6 bancos de treinamento e 6 de avaliação do desempenho dos modelos.

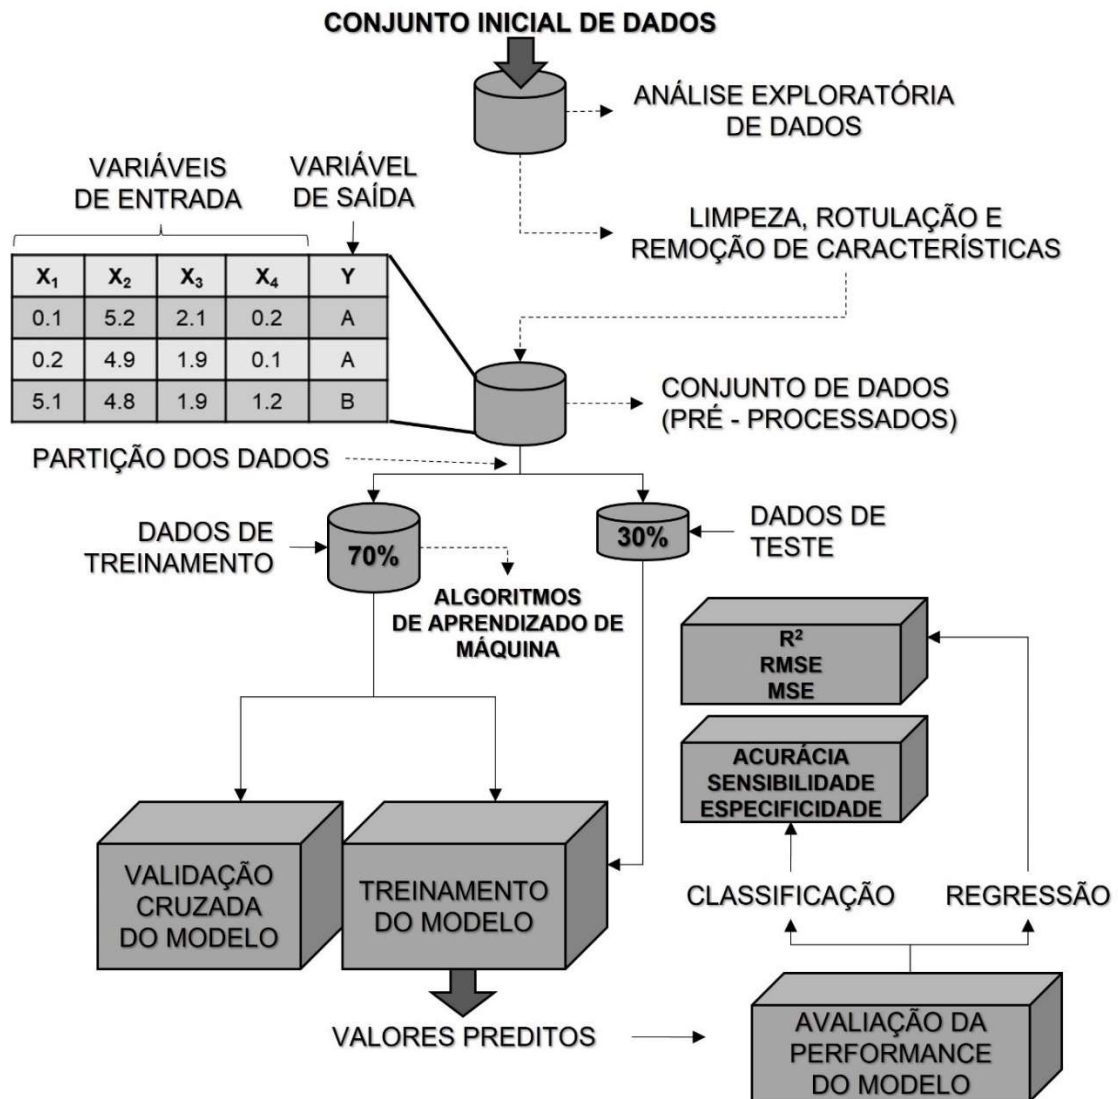
Tabela 2.2 – Conceito e cálculos de avaliação dos modelos de classificação obtidos. (HALILAJ *et al.*, 2018).

| Conceito                                                                                                                                    | Cálculo                                                       |
|---------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------|
| <b>Acurácia</b> - taxa de classificações corretas obtidas pelo algoritmo classificador (eventos e não - eventos).                           | $\text{Acurácia} = \frac{VP + VN}{\text{Total de predições}}$ |
| <b>Sensibilidade</b> - proporção de eventos corretamente identificados (resultados positivos), sem considerar os não – eventos.             | $\text{Sensibilidade} = \frac{VP}{VP + FN}$                   |
| <b>Especificidade</b> - proporção de não – eventos corretamente identificados (resultados negativos), sem considerar os eventos detectados. | $\text{Especificidade} = \frac{VN}{VN + FP}$                  |
| <b>Precisão</b> - proporção de eventos corretamente identificados em relação ao número total de eventos detectados.                         | $\text{Precisão} = \frac{VP}{VP + FP}$                        |

Em seguida, os dados foram importados para o software Matlab R2021b (MathWorks®, Natick, EUA), sendo processados no aplicativo “*Classification Learners*” (MathWorks®, Natick, EUA), que permite exportar o algoritmo treinado para o espaço de trabalho ou aplicações externas para classificação de novos dados de entrada extraídos das séries temporais. Em virtude do grande número de características que potencialmente apresentam um problema multicolinearidade ( $m = 54$  a  $219$ ), uma análise de componentes principais (ACP) foi conduzida para normalização dos dados, redução da dimensionalidade e construção de novas variáveis (*feature engineering*). O número de combinações lineares ou componentes retidas observou o critério de representatividade da variância explicada em relação à variância total (>95%) (MINGOTTI, 2017), para os bancos de dados formados. Logo, os conjuntos de dados de treinamento e teste foram formados a partir dos escores

obtidos das componentes retidas e sua respectiva classe ou *label* (HASTIE; TIBISHIRANI; FRIEDMAN, 2017; HALILAJ *et al.*, 2018; SOEKARJO *et al.*, 2019).

Figura 3.4 – Paradigma de aprendizado supervisionado.



Fonte: Rebala (2019).

Para proteger do sobreajuste (“*overfitting*”), o conjunto de dados foi particionado e a acurácia foi estimada utilizando a técnica de validação cruzada (*k – fold cross – validation*,  $k=10$ ) (HALILAJ *et al.*, 2018). Em seguida, o ajuste ao conjunto de dados (treinamento) foi iniciado utilizando diferentes algoritmos listados na tabela 2.1 (HASTIE; TIBISHIRANI; FRIEDMAN, 2017). Os algoritmos treinados foram testados a partir do banco de dados de teste (independente) para avaliação da acurácia de

classificação (HALILAJ *et al.*, 2018; TWOMEY *et al.*, 2018; SIDEY-GIBBONS; SIDEY-GIBBONS, 2019). Adicionalmente, para cada uma das combinações de características de entrada, a sensibilidade, especificidade e precisão de classificação foram determinadas para os algoritmos que apresentaram melhor acurácia nas etapas de treinamento e avaliação (Tabela 2.2).

Os resultados referentes a estes parâmetros são representados como uma matriz de confusão, especificando os resultados verdadeiros positivos (VP), negativos (VN), falsos positivos (FP) e falsos negativos (FN) encontrados para cada um dos movimentos estudados e partes do estudo. Para construir a matriz de confusão, a frequência absoluta dos resultados preditos pelos algoritmos de classificação é apresentada contra os resultados verdadeiros (rótulos) para as respectivas amostras testadas, especificando os resultados absolutos e relativos para cada categoria de movimento (HALILAJ *et al.*, 2018; SIDEY-GIBBONS; SIDEY-GIBBONS, 2019). Adicionalmente, para avaliar a relação entre sensibilidade e especificidade dos algoritmos treinados foram plotadas curvas de características de operação do receptor (*Receiver operating characteristics curves - ROC curves*), facilitada por meio do cálculo da área do sobre a curva ROC (*Area Under Curve - AUC*), denominada AUC (HALILAJ *et al.*, 2018; TWOMEY *et al.*, 2018; SIDEY-GIBBONS; SIDEY-GIBBONS, 2019). A figura 3.4 sintetiza as etapas de classificação das ações nas diferentes etapas do estudo.

Para avaliar a concordância para a acurácia (eventos e não – eventos identificados corretamente) e AUC (relação entre sensibilidade e especificidade) dos classificadores entre as etapas de treinamento e avaliação, o coeficiente de concordância de Kendall ( $\tau$ ) (trivial,  $\leq 0,25$ ; fraco,  $0,26 - 0,50$ ; moderado,  $0,51 - 0,75$ ; e forte,  $0,76 - 1,00$ ) e o coeficiente de correlação intraclasse ( $CCI_{2,1}$  – análise de variância para dois fatores) foram quantificados. Os valores foram classificados como fracos ( $CCI < 0,40$ ), aceitáveis ( $0,40 \leq CCI < 0,59$ ), bons ( $0,59 < CCI < 0,75$ ) ou excelentes ( $CCI > 0,75$ ) (WEIR, 2005). Adicionalmente, uma comparação da acurácia e AUC para os diferentes conjuntos de características de entrada estudadas foi conduzida por meio do teste não – paramétrico de Friedman (conjunto de dados de treinamento e de teste), seguido por um teste de comparações múltiplas de Nemenyi, caso necessário. As análises dos dados foram realizadas utilizando os softwares “R”, versão 4.1.2 (<https://cran.r-project.org/>, R Core Team, 2021, Vienna, Áustria), para uma

significância estatística ( $\alpha$ ) de  $p < .05$ . As características extraídas, ações e algoritmos de classificação em cada parte do estudo são sumarizados na tabela 2.1.

### 3.5. Resultados

Figura 3.5 – Matriz de confusão absoluta para o conjunto de dados de treinamento (ACC3+GIR1,  $m = 219$ ) utilizando o algoritmo  $k$ -NN “fine” e  $k$ -fold cross-validation.

**[A] k - NN (Fine) [Valores absolutos] - TREINAMENTO**

|                   |                 |                |                 |     |        |        |     |         |
|-------------------|-----------------|----------------|-----------------|-----|--------|--------|-----|---------|
| Classe Verdadeira | CorridaLeve     | 157            |                 |     |        | 1      | 2   |         |
|                   | CorridaModerada | 1              | 151             | 1   | 2      | 1      |     | 5       |
|                   | MMD             |                | 3               | 168 |        |        |     | 1       |
|                   | Marcha          |                | 1               |     | 177    | 1      |     |         |
|                   | Parada          | 2              |                 |     | 3      | 166    |     | 4       |
|                   | SCM             |                |                 |     |        | 1      | 178 |         |
|                   | Sprints         | 1              | 5               | 2   |        | 3      | 1   | 165     |
|                   |                 | CorridaLeve    | CorridaModerada | MMD | Marcha | Parada | SCM | Sprints |
|                   |                 | Classe Predita |                 |     |        |        |     |         |

Fonte: Dados da pesquisa.

O tempo para treinamento dos algoritmos de melhor acurácia geral de classificação oscilou de 4,928 (ACC3+GIR1) a 7,890 segundos (ACC1) para  $k$ -NN “fine” e de 10,436 a 17,904 segundos para *Ensemble “Bagged Trees”* (ACC2, ACC3, ACC1+GIR1, ACC2+GIR1), destacando que o algoritmo de menor tempo de processamento apresentou melhor acurácia geral de classificação (96,5%), perante um maior número de características ( $m=219$ ) e uso da ACP (Desktop-750PPIE, Processador Intel Core i5-7200U CPU 2.50GHz a 2.71 GHz, RAM 8GB, Sistema operacional de 64 bits). A acurácia geral de classificação de cada algoritmo analisada em seis combinações

diferentes de sensores e características de entrada, conforme apresentado nas tabelas 2.3 e 2.4, variou para os conjuntos de dados de treinamento e teste de 83,9% a 91,9% e 80,3% a 89,2% (ACC1), 79,3% a 87,8% e 75,7% a 85,1% (ACC2), 78,5% a 89,8% e 77,4% a 88,0% (ACC3), 77,0% a 89,1% e 75,1% a 86,6% (ACC1+GIR1), 77,9% a 88,9% e 71,0% a 85,9% (ACC2+GIR1) e 90,4% a 96,2% e 88,0% a 96,5% (ACC3+GIR1), respectivamente para as diferentes ações locomotoras estudadas.

Tabela 2.3 – Acurácia geral dos algoritmos de classificação (%) após o treinamento utilizando a validação cruzada (*k – fold cross – validation*) – dados de treinamento.

| Classificador                  | Acurácia (%)      |                  |                  |                     |                      |                      |
|--------------------------------|-------------------|------------------|------------------|---------------------|----------------------|----------------------|
|                                | ACC1<br>(m=54)    | ACC2<br>(m=83)   | ACC3<br>(m=138)  | ACC1+GIR1<br>(m=99) | ACC2+GIR1<br>(m=131) | ACC3+GIR1<br>(m=219) |
| DT (Fine)                      | 83,9%             | 79,7%            | 83,8%            | 82,7%               | 81,5%                | 90,4%                |
| SVM (Linear)                   | 85,4%             | 79,3%            | 78,5%            | 84,5%               | 84,7%                | 92,3%                |
| SVM<br>(Quadratic)             | 89,5%             | 82,0%            | 85,5%            | 85,1%               | 85,5%                | 95,8%                |
| SVM (Cubic)                    | 86,0%             | 79,3%            | 85,3%            | 77,0%               | 77,9%                | 95,4%                |
| KNN (Fine)                     | <b>91,9%</b>      | 83,3%            | 80,0%            | 84,8%               | 86,0%                | <b>96,2%</b>         |
| KNN<br>(Medium)                | 87,9%             | 80,5%            | 80,2%            | 79,1%               | 83,3%                | 94,1%                |
| KNN (Cosine)                   | 87,4%             | 79,1%            | 79,3%            | 79,3%               | 83,3%                | 94,0%                |
| KNN (Cubic)                    | 87,4%             | 80,0%            | 79,5%            | 77,1%               | 82,0%                | 93,5%                |
| KNN<br>(Weighted)              | 91,1%             | 83,0%            | 81,5%            | 83,0%               | 87,0%                | 95,5%                |
| Ensemble<br>(Boosted<br>Trees) | 83,3%             | 79,6%            | 82,4%            | 83,7%               | 81,5%                | 91,2%                |
| Ensemble<br>(Bagged<br>Trees)  | 91,1%             | <b>87,8%</b>     | <b>89,8%</b>     | <b>89,1%</b>        | <b>88,9%</b>         | 95,2%                |
| Narrow NN                      | 88,4%             | 86,9%            | 89,4%            | 85,9%               | 87,9%                | 93,4%                |
| Medium NN                      | 88,4%             | 85,4%            | 86,6%            | 85,2%               | 86,0%                | 95,2%                |
| Wide NN                        | 89,2%             | 86,5%            | 87,4%            | 84,0%               | 86,5%                | 95,4%                |
| Bilayered NN                   | 86,3%             | 85,7%            | 89,4%            | 84,3%               | 85,6%                | 95,0%                |
| Trilayered NN                  | 87,7%             | 83,8%            | 86,5%            | 85,5%               | 84,9%                | 93,8%                |
| <b>Média (%)</b>               | <b>87,8±2,4%†</b> | <b>82,6±3,1%</b> | <b>84,0±3,9%</b> | <b>83,1±3,3%</b>    | <b>84,5±2,8%</b>     | <b>94,1±1,7%*</b>    |

Conjuntos de variáveis explicativas – ACC1 – Acelerômetro (Estatísticas descritivas); ACC2 – Acelerômetro (Estatísticas descritivas + aceleração resultante); ACC3 – Acelerômetro (Estatísticas descritivas + aceleração resultante + medidas de não – linearidade de séries temporais); GIR1 – Giroscópio (Estatísticas descritivas). \*Indica diferenças significativas de ACC3+GIR1 para com a ACC2, ACC3, ACC1+GIR1 e ACC2+GIR1 ( $p < 0,001$ ). † Indica diferenças significativas de ACC1 para com ACC2 ( $p < 0,001$ ).

Adicionalmente, durante a etapa de treinamento e validação cruzada, assim como na etapa de avaliação do desempenho, os algoritmos de classificação *k – Nearest Neighbors “Fine”* (Acurácia para treinamento & validação 91,9% e teste 89,2% - ACC1 – Estatísticas descritivas obtidas do acelerômetro triaxial; e acurácia para treinamento & validação 96,2% e teste 96,5% - ACC3 + GIR1 – Estatísticas descritivas obtidos do acelerômetro triaxial e giroscópio triaxial, customizadas e medidas de não - linearidade

na análise de séries temporais obtidos do acelerômetro triaxial) e *Ensemble “Bagged Trees”* (ACC2 - Acurácia para treinamento & validação 87,8% e teste 85,1% - Estatísticas descritivas e customizadas de aceleração resultante horizontal e vertical obtidas do acelerômetro triaxial; ACC3 – Acurácia para treinamento & validação 89,8% e teste 88,0% - Estatísticas descritivas, customizadas e de não - linearidade na análise de séries temporais obtidos do acelerômetro triaxial; ACC1 + GIR1 – Acurácia para treinamento & validação 89,1% e teste 86,6% - Estatísticas descritivas obtidas do acelerômetro e giroscópio triaxial; ACC2 + GIR1 – Acurácia para treinamento & validação 88,9% e teste 85,9% - Estatísticas descritivas obtidos do acelerômetro triaxial e giroscópio triaxial, além das customizadas) apresentaram melhores valores absolutos e relativos para predição correta das ações estudadas.

Figura 3.6 – Matriz de confusão relativa (B) para o conjunto de dados de treinamento (ACC3+GIR1, m=219) utilizando o algoritmo *k*-NN “fine” e *k*-fold cross-validation.

**[B] k - NN (Fine) [%] - TREINAMENTO**

| Classe Verdadeira | Classe Predita |                 |       |        |        |       |         | TPR   | FNR  |
|-------------------|----------------|-----------------|-------|--------|--------|-------|---------|-------|------|
|                   | CorridaLeve    | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints |       |      |
| CorridaLeve       | 98.1%          |                 |       |        | 0.6%   | 1.2%  |         | 98.1% | 1.9% |
| CorridaModerada   | 0.6%           | 93.8%           | 0.6%  | 1.2%   | 0.6%   |       | 3.1%    | 93.8% | 6.2% |
| MMD               |                | 1.7%            | 97.7% |        |        |       | 0.6%    | 97.7% | 2.3% |
| Marcha            |                | 0.6%            |       | 98.9%  | 0.6%   |       |         | 98.9% | 1.1% |
| Parada            | 1.1%           |                 |       | 1.7%   | 94.9%  |       | 2.3%    | 94.9% | 5.1% |
| SCM               |                |                 |       |        | 0.6%   | 99.4% |         | 99.4% | 0.6% |
| Sprints           | 0.6%           | 2.8%            | 1.1%  |        | 1.7%   | 0.6%  | 93.2%   | 93.2% | 6.8% |

Fonte: Dados da pesquisa.

TPR - “*True Positive Rates*” – Verdadeiros Positivos (%) ou sensibilidade; FNR - “*False Negative Rates*” – Falsos Negativos (%).

Figura 3.7 – Matriz de confusão relativa (C) para o conjunto de dados de treinamento (ACC3 + GIR1, m = 219) utilizando o algoritmo *k*-NN “fine” e *k*-fold cross-validation.

|                   |                 |                |                 |       |        |        |       |         |
|-------------------|-----------------|----------------|-----------------|-------|--------|--------|-------|---------|
| Classe Verdadeira | CorridaLeve     | 97.5%          |                 |       |        | 0.6%   | 1.1%  |         |
|                   | CorridaModerada | 0.6%           | 94.4%           | 0.6%  | 1.1%   | 0.6%   |       | 2.9%    |
|                   | MMD             |                | 1.9%            | 98.2% |        |        |       | 0.6%    |
|                   | Marcha          |                | 0.6%            |       | 97.3%  | 0.6%   |       |         |
|                   | Parada          | 1.2%           |                 |       | 1.6%   | 96.0%  |       | 2.3%    |
|                   | SCM             |                |                 |       |        | 0.6%   | 98.3% |         |
|                   | Sprints         | 0.6%           | 3.1%            | 1.2%  |        | 1.7%   | 0.6%  | 94.3%   |
| PPV               | 97.5%           | 94.4%          | 98.2%           | 97.3% | 96.0%  | 98.3%  | 94.3% |         |
| FDR               | 2.5%            | 5.6%           | 1.8%            | 2.7%  | 4.0%   | 1.7%   | 5.7%  |         |
|                   |                 | CorridaLeve    | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints |
|                   |                 | Classe Predita |                 |       |        |        |       |         |

Fonte: Dados da pesquisa.

PPV - “Positive Predictive Values” – Valores Preditivos Positivos (%) ou precisão; FDR - “False Discovery Rates” – Falsas Descobertas (%) ou Falsos Positivos.

Para a utilização isolada do acelerômetro, considerando os algoritmos que apresentaram melhor acurácia de treinamento e teste, as ações de corrida em intensidade moderada e MMD apresentaram menor sensibilidade e precisão para detecção das ações pelos algoritmos *k*-NN “fine” e *Ensemble “Bagged Trees”* (Treinamento – ACC1, ACC2 e ACC3 – Sensibilidade – corrida moderada - 65,8% a 75,8%, MMD – 75,2% a 83,1%; Precisão - corrida Moderada - 69,5% a 77,2%, MMD – 76,0% a 86,7%; Teste – ACC1, ACC2 e ACC3 – Sensibilidade – corrida moderada – 62,9% a 84,3%, MMD – 62,7% a 71,0%; Precisão – corrida Moderada – 62,5% a 76,6%, MMD - 71,0% a 81,0%), no entanto, as ações de marcha, permanecer parado e SCM mostraram elevada sensibilidade de identificar corretamente os eventos e precisão, ou seja, a proporção de resultados positivos que são de fato positivos

(Treinamento – ACC1, ACC2, ACC3 – sensibilidade – marcha 98,3% a 99,4%; parada – 95,4% a 99,4%; SCM 93,9% a 98,3%; precisão – parada 95,1% a 97,2%; marcha – 98,9% a 99,4%; SCM – 92,3% a 99,4%; Teste – ACC1, ACC2, ACC3 – Teste – ACC1, ACC2, ACC3 – sensibilidade – marcha – 97,4% a 100%; parada – 96,0% a 97,3%; SCM – 93,5%, a 100%; precisão – parada – 96,1% a 98,6%; marcha – 96,2% a 98,7%; SCM – 91,1% a 96,2%). As matrizes de confusão referentes a estas combinações são reportadas nas figuras de E1 a E9 e E16 a E24 (Apêndice E).

Tabela 2.4 – Acurácia geral dos algoritmos de classificação treinados (%) utilizando o conjunto de dados de teste.

| Classificador                  | Acurácia (%)          |                  |                  |                         |                          |                          |
|--------------------------------|-----------------------|------------------|------------------|-------------------------|--------------------------|--------------------------|
|                                | ACC1<br>(m=54)        | ACC2<br>(m=83)   | ACC3<br>(m=138)  | ACC1+GIR<br>1<br>(m=99) | ACC2+GIR<br>1<br>(m=131) | ACC3+GIR<br>1<br>(m=219) |
| DT (Fine)                      | 80,3%                 | 75,7%            | 83,0%            | 78,4%                   | 77,6%                    | 90,0%                    |
| SVM (Linear)                   | 85,1%                 | 76,6%            | 77,4%            | 85,3%                   | 85,5%                    | 90,2%                    |
| SVM(Quadratic)                 | 84,7%                 | 80,5%            | 83,0%            | 85,3%                   | 84,9%                    | 94,2%                    |
| SVM (Cubic)                    | 85,7%                 | 75,5%            | 84,0%            | 75,1%                   | 71,0%                    | 94,4%                    |
| KNN (Fine)                     | <b>89,2%</b>          | 78,4%            | 78,4%            | 80,1%                   | 81,7%                    | <b>96,5%</b>             |
| KNN (Medium)                   | 84,7%                 | 77,6%            | 79,7%            | 78,6%                   | 80,5%                    | 93,4%                    |
| KNN (Cosine)                   | 83,2%                 | 78,6%            | 79,9%            | 78,0%                   | 79,7%                    | 92,3%                    |
| KNN (Cubic)                    | 84,0%                 | 78,0%            | 79,0%            | 79,0%                   | 79,7%                    | 92,5%                    |
| KNN<br>(Weighted)              | 88,8%                 | 80,7%            | 81,9%            | 82,6%                   | 83,4%                    | 94,8%                    |
| Ensemble<br>(Boosted<br>Trees) | 81,7%                 | 76,1%            | 79,9%            | 81,7%                   | 80,9%                    | 88,0%                    |
| Ensemble<br>(Bagged Trees)     | 88,4%                 | <b>85,1%</b>     | <b>88,0%</b>     | <b>86,6%</b>            | <b>85,9%</b>             | 93,4%                    |
| Narrow NN                      | 85,9%                 | 83,2%            | 86,5%            | 84,7%                   | 81,9%                    | 92,5%                    |
| Medium NN                      | 87,3%                 | 81,1%            | 86,1%            | 84,2%                   | 84,2%                    | 92,7%                    |
| Wide NN                        | 86,7%                 | 80,3%            | 86,5%            | 82,8%                   | 81,9%                    | 93,2%                    |
| Bilayered NN                   | 87,1%                 | 81,9%            | 85,9%            | 83,6%                   | 80,7%                    | 90,0%                    |
| Trilayered NN                  | 85,1%                 | 81,7%            | 89,2%            | 81,9%                   | 84,2%                    | 93,1%                    |
| <b>Média (%)</b>               | <b>85,5±2,4%</b><br>† | <b>79,4±2,8%</b> | <b>83,0±3,7%</b> | <b>81,7±3,2%</b>        | <b>81,5±3,6%</b>         | <b>92,6±2,1%*</b>        |

ACC1 – Acelerômetro (Estatísticas descritivas); ACC2 – Acelerômetro (Estatística descritiva + aceleração resultante); ACC3 – Acelerômetro (Estatística descritiva + aceleração resultante + medidas de não – linearidade de séries temporais); GIR1 – Giroscópio (Estatística descritiva). \*Indica diferenças significativas de ACC3+GIR1 para com a ACC2, ACC3, ACC1+GIR1 e ACC2+GIR1 ( $p < 0,001$ ). † Indica diferenças significativas de ACC1 para com ACC2 e ACC1+GIR1 ( $p < 0,001$ ).

Fonte: Dados da pesquisa.

Por outro lado, a proporção de não–eventos corretamente identificados (especificidade) dos classificadores de melhor acurácia geral, sem considerar os eventos ou ações detectados corretamente, permaneceu muito elevada independente do incremento das diferentes características extraídas (Treinamento & Validação – ACC1 – Especificidade – 0,97 a 0,99; ACC2 – 0,96 a 0,99; ACC3 – 0,95 a 0,99; Teste

– Especificidade – ACC1 – 0,96 a 1,00; ACC2 – 0,94 a 1,00; ACC3 – 0,94 a 0,99), oscilando de 0,95 a 1,00 e 0,94 a 1,00, nas etapas de treinamento e teste, respectivamente.

Figura 3.8 – Matriz de confusão absoluta (A) para o conjunto de dados de teste (ACC3+GIR1, m = 219) utilizando o algoritmo *k*-NN “fine”.

**[A] k - NN (Fine) [Valores absolutos] - TESTE**

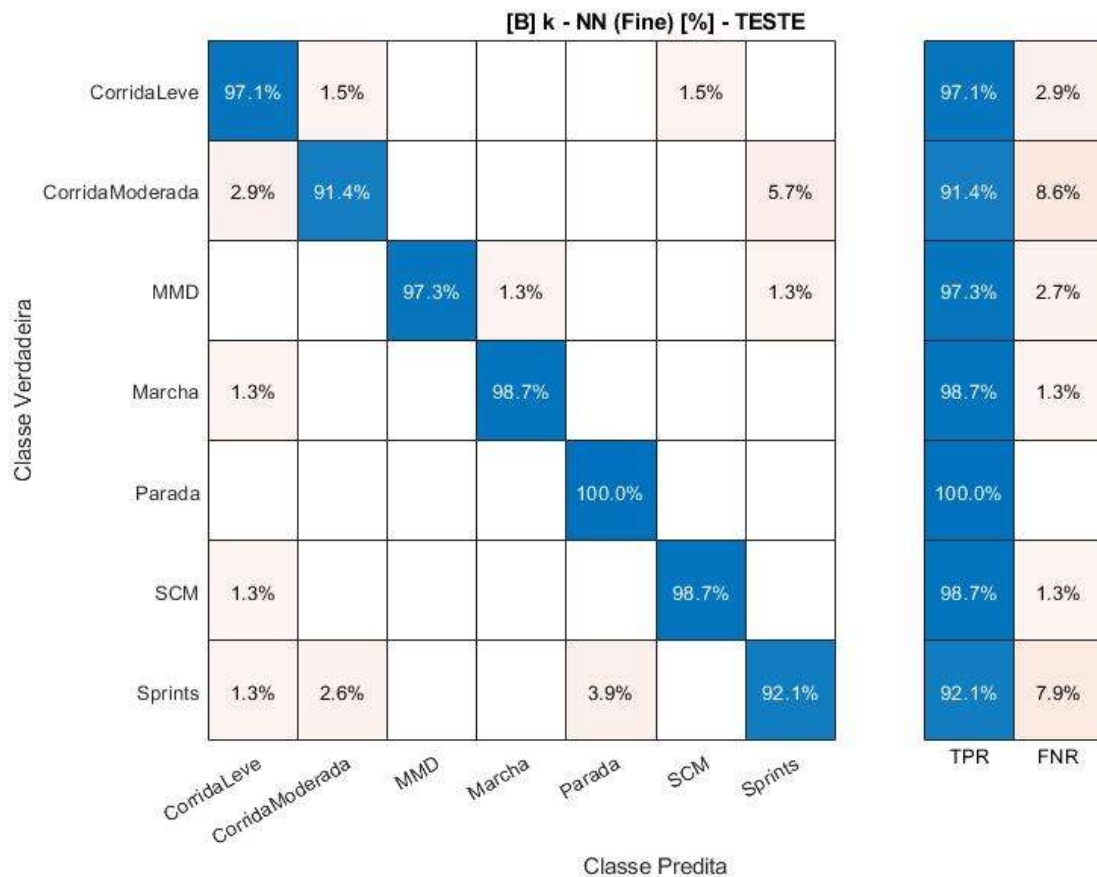
|                   |                 |                |                 |     |        |        |     |         |
|-------------------|-----------------|----------------|-----------------|-----|--------|--------|-----|---------|
| Classe Verdadeira | CorridaLeve     | 66             | 1               |     |        |        | 1   |         |
|                   | CorridaModerada | 2              | 64              |     |        |        |     | 4       |
|                   | MMD             |                |                 | 73  | 1      |        |     | 1       |
|                   | Marcha          | 1              |                 |     | 76     |        |     |         |
|                   | Parada          |                |                 |     |        | 75     |     |         |
|                   | SCM             | 1              |                 |     |        |        | 76  |         |
|                   | Sprints         | 1              | 2               |     |        | 3      |     | 70      |
|                   |                 | CorridaLeve    | CorridaModerada | MMD | Marcha | Parada | SCM | Sprints |
|                   |                 | Classe Predita |                 |     |        |        |     |         |

Fonte: Dados da pesquisa.

A combinação de características estatísticas de natureza descritiva das séries temporais de acelerômetros e giroscópios triaxiais, o algoritmo *Ensemble “Bagged Trees”* mostrou acurácia maior em ambas etapas de treinamento e avaliação, em que as ações de corrida em intensidade moderada, MMD e *sprints* evidenciaram menor sensibilidade para correta identificação de eventos pelo modelo obtido (Treinamento – ACC1 + GIR1 – sensibilidade – MMD – 69,8%, corrida moderada – 77,0%, sprints – 83,6%; Teste – ACC1 + GIR1 – sensibilidade – MMD – 57,3%, corrida moderada – 78,6%, sprints – 86,8%), além de uma menor precisão foi identificada para as ações de corrida em intensidade leve, corrida de intensidade moderada, MMD e *sprints* (Treinamento – ACC1 + GIR1 – precisão – MMD – 85,7%, corrida leve – 91,2%, corrida

moderada – 74,3%, sprints – 78,7%; Teste – precisão – MMD – 86,0%, corrida leve – 78,2%; corrida moderada – 73,3%, sprints – 73,3%).

Figura 3.9 – Matriz de confusão relativa (B) para o conjunto de dados de teste (ACC3+GIR1, m = 219) utilizando o algoritmo *k*-NN “fine”.



Fonte: Dados da pesquisa.

TPR - “True Positive Rates” – Verdadeiros Positivos (%) ou sensibilidade; FNR - “False Negative Rates” – Falsos Negativos (%).

A adição de características customizadas (aceleração resultante vertical e horizontal) juntamente a características de ordem estatística descritiva evidenciou menor sensibilidade para mesmo algoritmo (Treinamento – ACC2 + GIR1 – sensibilidade – MMD – 71,5%, corrida leve – 91,9%; corrida moderada – 76,4%; sprints – 83,6%; precisão – MMD – 84,8%, corrida leve – 78,0%; corrida moderada – 75,5%; sprints – 78,7%; Teste – ACC2 + GIR1 – sensibilidade – MMD – 57,3%, corrida leve – 94,1%; corrida moderada – 67,1%, sprints – 89,5%; precisão – MMD – 79,6%, corrida leve – 78,0%; corrida moderada – 73,4%, sprints – 73,9%). As matrizes de confusão referentes a estas combinações são reportadas nas figuras de E10 a E15 e E25 a E30 (Apêndice E).

A combinação de características obtidas dos acelerômetros (estatísticas descritivas, customizadas e medidas de não - linearidade) e giroscópios triaxiais (estatísticas descritivas) mostrou melhor acurácia no treinamento (96,2%) do algoritmo *k-NN "fine"*, com elevada sensibilidade oscilando de 93,2% para os *sprints* a 99,4% nos SCM, bem como alta precisão variando de 94,3% para os *sprints* a 98,3% nos SCM (Treinamento – ACC3 + GIR1, Figuras 3.5 e 3.7). Adicionalmente, a avaliação do desempenho (Teste – ACC3 + GIR1, Figuras 3.8 e 3.10) do modelo obtido revelou acurácia de 96,5%, com sensibilidade superior a 91,4% (corrida moderada) e com precisão superior a 93,0% (corrida leve).

Figura 3.10 – Matriz de confusão relativa (C) para o conjunto de dados de teste (ACC3+GIR1, m = 219) utilizando o algoritmo *k-NN "fine"*.

| Classe Verdadeira | CorridaLeve      | CorridaModerada | MMD    | Marcha | Parada | SCM   | Sprints |
|-------------------|------------------|-----------------|--------|--------|--------|-------|---------|
| CorridaLeve       | 93.0%            | 1.5%            |        |        |        | 1.3%  |         |
| CorridaModerada   | 2.8%             | 95.5%           |        |        |        |       | 5.3%    |
| MMD               |                  |                 | 100.0% | 1.3%   |        |       | 1.3%    |
| Marcha            | 1.4%             |                 |        | 98.7%  |        |       |         |
| Parada            |                  |                 |        |        | 96.2%  |       |         |
| SCM               | 1.4%             |                 |        |        |        | 98.7% |         |
| Sprints           | 1.4%             | 3.0%            |        |        | 3.8%   |       | 93.3%   |
| PPV               | 93.0%            | 95.5%           | 100.0% | 98.7%  | 96.2%  | 98.7% | 93.3%   |
| FDR               | 7.0%             | 4.5%            |        | 1.3%   | 3.8%   | 1.3%  | 6.7%    |
|                   | CorridaLeve      | CorridaModerada | MMD    | Marcha | Parada | SCM   | Sprints |
|                   | Classe Preditada |                 |        |        |        |       |         |

Fonte: Dados da pesquisa.

PPV - "Positive Predictive Values" – Valores Preditivos Positivos (%) ou precisão; FDR - "False Discovery Rates" – Falsas Descobertas (%) ou Falsos Positivos.

As diferentes combinações de sensores e características de entrada mostraram alterações significativas para acurácia geral observada no treinamento e testagem dos classificadores (Treinamento & Validação –  $X^2 = 58,453$ ,  $p < 0,001$ ; Teste -  $X^2 = 58,759$ ,

$p < 0,001$ ). Logo, um incremento significativo sobre a taxa de predições corretas obtidas pelos classificadores treinados e testados com a combinação de sensores (acelerômetro e giroscópio) e características (estatísticas descritivas, customizadas e medidas de análise de séries temporais) em relação a ACC2, ACC3, ACC1+GIR1 e ACC2+GIR1 ( $p < 0,001$ ), exceto para ACC1 (Treinamento & Validação –  $p = 0,468$ ; Teste –  $p = 0,228$ ), por sua vez, com acurácia geral significativamente superior a ACC2 (Treinamento & Validação –  $p < 0,05$ ; Teste –  $p < 0,05$ ) e ACC1+GIR1 (Treinamento & Validação –  $p < 0,001$ ).

A especificidade dos classificadores de melhor acurácia geral permaneceu muito elevada quando os acelerômetros e giroscópios triaxiais são combinados, indiferentemente do tipo de características incorporadas, oscilando de 0,95 a 1,00 e 0,94 a 1,00, nas etapas de treinamento e testagem, respectivamente (Treinamento & Validação – Especificidade – ACC1+GIR1 – 0,96 a 0,99; ACC2+GIR1 – 0,96 a 0,99; ACC3+GIR1 – 0,99 a 1,00; Teste – Especificidade – ACC1+GIR1 – 0,95 a 0,99; ACC2+GIR1 – 0,95 a 0,99; ACC3+GIR1 – 0,98 a 1,00).

Tabela 2.5 – Valores concordância para acurácia e relação entre sensibilidade e especificidade (AUC) de classificação entre as etapas de treinamento e avaliação.

| Características         | Acurácia           |                            | AUC                |                           |
|-------------------------|--------------------|----------------------------|--------------------|---------------------------|
|                         | Kendall ( $\tau$ ) | CCI (2,1)                  | Kendall ( $\tau$ ) | CCI (2,1)                 |
| ACC1<br>(k-NN)          | 0,587*             | 0,571<br>[-0,1; 0,867] *   | 0,761*             | 0,795<br>[0,715; 0,854] * |
| ACC2<br>(Ensemble)      | 0,677*             | 0,566<br>[-0,1; 0,877] *   | 0,772*             | 0,912<br>[0,832; 0,949] * |
| ACC3<br>(Ensemble)      | 0,762*             | 0,893<br>[0,622; 0,965] *  | 0,780*             | 0,924<br>[0,889; 0,948] * |
| ACC1+GIR1<br>(Ensemble) | 0,644*             | 0,793<br>[0,326; 0,932] *  | 0,777*             | 0,871<br>[0,818; 0,910] * |
| ACC2+GIR1<br>(Ensemble) | 0,512*             | 0,554<br>[-0,1; 0,856] *   | 0,743*             | 0,856<br>[0,797; 0,899] * |
| ACC3+GIR1<br>(k-NN)     | 0,706*             | 0,590<br>[-0,075; 0,866] * | 0,586*             | 0,710<br>[0,578; 0,802] * |

\*Indica concordância estatística significativa para os coeficientes de Kendall e CCI ( $p < 0,001$ )

Fonte: Dados da pesquisa.

A relação entre sensibilidade e especificidade (AUC) para classificação de ações mostrou diferenças médias significativas para características obtidas pela combinação de sensores e os diferentes tipos de características extraídas (Treinamento & Validação – ACC3+GIR1 –  $0,99 \pm 0,02$  –  $X^2 = 165,35$ ,  $p < 0,001$ ; Teste – ACC3+GIR1 –  $0,98 \pm 0,02$  –  $X^2 = 165,36$ ,  $p < 0,001$ ) para com os demais agrupamentos de características em ambas as etapas de treinamento e avaliação (Treinamento – ACC1 –  $0,95 \pm 0,05$ ; ACC2 –  $0,95 \pm 0,05$ ; ACC3 –  $0,95 \pm 0,05$ ; ACC1+GIR1 –  $0,95 \pm 0,05$ ;

ACC2+GIR1 –  $0,95\pm 0,05$ ;  $p < 0,001$ , Teste – ACC1 –  $0,95\pm 0,06$ ; ACC2 –  $0,94\pm 0,05$ ; ACC3 –  $0,95\pm 0,05$ ; ACC1+GIR1 –  $0,94\pm 0,05$ ; ACC2+GIR1 –  $0,98\pm 0,02$ ;  $p < 0,001$ , respectivamente), bem como para uso isolado do acelerômetro (Treinamento – ACC1 vs. ACC2,  $p = 0,010$ ; Teste – ACC1 vs. ACC2,  $p = 0,004$ ; ACC2 vs. ACC3,  $p < 0,001$ ). As curvas ROC nas etapas de treinamento e teste referente ao algoritmo de melhor acurácia geral de classificação (ACC3+GIR1 – k-NN “*fine*”) em uma das ações executadas no circuito simulado é apresentada no apêndice E, oscilando de 0,95 (Corrida Moderada e *Sprints*) a 1,00 (Parada) no treinamento e validação e de 0,96 (Corrida Moderada, *Sprints*) a 1,00 (SCM).

Adicionalmente, a concordância para a acurácia e AUC obtidas dos classificadores treinados e as respectivas avaliações de desempenho, revelou concordância de moderada a forte para ambas as variáveis (Acurácia -  $\tau = 0,512$  a  $0,762$ ,  $p < 0,001$ ; AUC -  $\tau = 0,586$  a  $0,780$ ,  $p < 0,001$ ) por meio do coeficiente de concordância de Kendall, bem como de aceitável a excelente para a acurácia e de boa a excelente para AUC pelo CCI (Acurácia – CCI =  $0,554$  a  $0,893$ ; AUC – CCI =  $0,710$  a  $0,924$ ). A tabela 2.5 reporta os valores de concordância entre as etapas de treinamento e avaliação para a acurácia geral e AUC dos classificadores. As curvas ROC referentes às ações de permanecer parado, marcha, corrida de intensidade leve, corrida de intensidade moderada, sprints com desaceleração e movimentos de mudança de direção são reportadas nas figuras de 31 a 37 (Apêndice E).

### 3.6. Discussão

O presente estudo teve como objetivo analisar o desempenho de classificação de ações comuns aos esportes coletivos de sensores inerciais utilizando métodos de aprendizado de máquina. De forma geral, os algoritmos treinados e testados mostraram um desempenho satisfatório de acurácia geral de classificação para as ações estudadas, com concordância de moderada a forte entre as etapas de treinamento e teste com conjuntos de dados independentes, com menor sensibilidade de detecção para as ações de corrida moderada e MMD. Os algoritmos *Ensemble “Bagged Trees”* e k-NN “*fine*” mostraram melhor acurácia geral de classificação de ações. Entretanto, a combinação de sensores (acelerômetros e giroscópios) e agregação de diferentes tipos de características (estatísticas descritivas, customizadas e medidas de análise de séries temporais) apresentou melhor

desempenho de classificação de ações corretamente (>90%) em relação ao emprego isolado de acelerômetros, com boa concordância entre as etapas de treinamento e teste do algoritmo k-NN (acurácia geral e AUC).

A agregação de características estatísticas descritivas (séries temporais do acelerômetro, giroscópio, aceleração resultante horizontal e vertical) e medidas de análise de séries temporais (acelerômetro e aceleração resultante) no treinamento e teste dos classificadores mostrou maior acurácia geral (k-NN “*fine*”, Treinamento - 96,2%; Teste – 96,5%) dentre os algoritmos utilizados no estudo. Logo, a adoção de medidas de análise de séries temporais incrementou significativamente de 9,6% a 11,1% para a acurácia geral média dos classificadores (treinamento & teste). A melhora do desempenho de classificação pode ser atribuída à captação de determinadas características do sinal não obtidas por meio de estatísticas descritivas tradicionais empregadas na literatura (CAMOMILLA *et al.*, 2018; HALILAJ *et al.*, 2018; ADESIDA; PAPI; MCGREGOR, 2019). Como exemplo, a utilização de características a partir do coeficiente de “Hurst”, um importante método derivado da teoria do caos para quantificar os processos de memória de longo prazo de uma série temporal e, conseqüentemente, utilização para treinamento de algoritmos de classificação (MOSQUEDA-HERRERA *et al.*, 2020; FU *et al.*, 2021). Mesmo medidas clássicas de análises de séries temporais, como tendência e sazonalidade podem auxiliar na classificação de ações como, por exemplo, eventos de marcha e corrida, por serem atividades motoras de natureza cíclica.

Além disso, a combinação de acelerômetro e giroscópio em relação ao emprego isolado de acelerômetros aumentou significativamente a capacidade de predição correta de eventos de 9,6% a 13,2%. Em uma perspectiva biomecânica, a adição de características extraídas do giroscópio possui especial importância, considerando a característica do sensor em detectar movimentos de rotação, tais como MMD e de corrida, complementando o registro da aceleração linear ofertado. Na mesma linha, os demais algoritmos classificadores *decision trees*, *support vector machines* e *neural networks* apresentaram elevada acurácia geral de classificação nas etapas de treinamento e teste (>0,90). Logo, a combinação de sensores (acelerômetro e giroscópio) com a adição de métodos de extração de características de séries temporais representou um aumento do potencial de classificação das ações (tabela 2.3 e tabela 2.4), auxiliando positivamente no processo de descrição das séries temporais de dados, por meio do pacote “*tsfeatures*” (HYNDMAN *et al.*, 2020).

Wundersitz *et al.* (2015b) verificaram que a combinação de dados de entrada obtidos a partir de acelerômetros, giroscópios e a aceleração resultante (tridimensional), a associação de características oriundas do acelerômetro e vetor de aceleração resultante, bem como a utilização isolada de acelerômetros mostrou elevada acurácia geral em consonância com os resultados do presente estudo para classificar as ações de parada estacionária, marcha, corrida de intensidade leve, MMD, *sprints* e salto com contramovimento (*Logistic Model Trees* – 92,0% vs. *Ensemble “Bagged Trees”* – 88,9%, acurácia média dos classificadores –  $84,5 \pm 2,8\%$ ; *Logistic Model Trees* – 89,0% a 90,0% vs. *Ensemble “Bagged Trees”* – 87,8%; acurácia média dos classificadores -  $82,6 \pm 3,1\%$ ; *Logistic Model Trees* – 89,0% a 90,0% vs. *Ensemble “Bagged Trees”* – 87,8%; acurácia média dos classificadores -  $82,6 \pm 3,1\%$ , respectivamente).

Mitchell; Monaghan; O’Connor (2013) reportaram uma acurácia geral de 75% para identificação das ações de permanecer parado, marcha, corrida de intensidade leve e *sprints* utilizando um acelerômetro, e, portanto, de 7,6% a 12,8% menor que a acurácia geral descrita registrada (82,6% a 87,8%, tabela 2.6). No entanto, Trost; Zheng; Wong (2014) evidenciaram taxas de predições corretas semelhantes para acelerômetros posicionados no punho ( $91,0 \pm 3,1\%$ ) e quadril ( $88,4 \pm 3,0\%$ ) no monitoramento de atividades de crianças, extraíndo características estatísticas das séries temporais para classificar as ações de permanecer parado (Quadril - 95,8%; Punho - 91,7%), marcha (quadril e punho - 95,8%), corrida de intensidade leve (quadril - 95,8%; Punho - 78,8%) por regressão logística.

Nesse sentido, provavelmente as diferenças verificadas nos estudos de Mitchell; Monaghan; O’Connor (2013), Trost; Zheng; Wong (2014) e Wundersitz *et al.* (2015b) podem ser atribuídas ao local de posicionamento do sensor e ausência do giroscópio para extração de características e treinamento dos classificadores, bem como o emprego de técnicas de redução da dimensionalidade no presente experimento (HALILAJ *et al.*, 2018; TWOMEY *et al.*, 2018; MCGRATH *et al.*, 2020). Além disso, ambos os estudos citados não descrevem a acurácia geral dos classificadores treinados a partir dos dados de teste, para atestar a concordância dos classificadores treinados perante um conjunto amostral independente.

Adicionalmente, a respeito do acréscimo do número de sensores, utilizando um conjunto de cinco sensores inerciais (acelerômetro e giroscópio) nos membros inferiores posicionados na região lombar, coxas e pernas, Ahmadi *et al.* (2013) classificaram com elevada sensibilidade e precisão as ações de marcha (sensibilidade

– 98,8% e precisão – 100,0%), corrida de intensidade leve (sensibilidade – 97,6% e precisão – 100,0%), sprints (sensibilidade – 96,6% e precisão – 100,0%), saltos (sensibilidade – 93,1% e precisão – 93,1%), com acurácia geral de 98,3% utilizando a técnica “*discrete wavelet transform*” para extração de características em conjunto com o classificador “*random forest*”. Contudo, apesar de Nguyen et al. (2015) utilizarem cinco sensores com a mesma configuração mostraram sensibilidade de 80,98% para atividades de marcha, 51,98% para corrida de intensidade leve, 44,63% para corrida de intensidade moderada, 59,29% para os *sprints* e 66,6% para os saltos verticais em basquetebolistas.

Logo, a acurácia geral registrada por Ahmadi et al. (2013) foi superior à verificada no presente estudo, a partir da extração de características estatísticas e combinação de sensores (*Ensemble “Bagged Trees”* - ACC1+GIR1 – 89,1%; ACC2+GIR1 – 88,9%), entretanto, quando comparadas com a acurácia geral observada pela adoção de características estatísticas e medidas de análise de séries temporais, resultados semelhantes entre estudos foram encontrados entre estudos a partir de uma única UMI (k-NN “*fine*” – ACC3+GIR1 – 96,2%). Por outro lado, a capacidade de identificação das atividades de marcha, corrida de intensidade leve, corrida de intensidade moderada, *sprints* e saltos verticais para Nguyen et al. (2015) foram substancialmente menores que a verificada no presente estudo (tabelas 2.3 e 2.4).

Em uma perspectiva prática, os resultados promissores verificados no reconhecimento de ações por algoritmos de aprendizado de máquina por meio de UMI de baixo custo podem no processo de monitoramento de treinos e competições nos esportes coletivos, uma vez que a validade e confiabilidade do registro de atividades de alta intensidade como mudanças de direção e *sprints* por dispositivos GPS tem sido frequentemente questionados (VARLEY; FAIRWEATHER; AUGHEY, 2011; JOHNSTON et al., 2014; MALONE et al., 2017; SWEETING et al., 2017; MALONE et al., 2020). Entretanto, os resultados observados devem ser considerados com cautela, há a necessidade de definição do comprimento ou tamanho da janela de extração de características das séries temporais para automatização do reconhecimento de ações, constituindo-se em uma limitação do estudo, fortemente dependente do tipo de ação alvo (WUNDERSITZ et al., 2015b).

Não obstante, apesar de destacar a avaliação do desempenho dos classificadores como parte dos paradigmas de aprendizado supervisionado, os estudos identificados a respeito do reconhecimento de atividades não têm avaliado a concordância entre os

eventos identificados corretamente (acurácia) e relação entre sensibilidade e especificidade dos classificadores nas etapas de treinamento e testagem, para atestar a validade da capacidade de preditiva e extrapolação dos algoritmos treinados por meio de dados independentes (KELLY *et al.*, 2012; MITCHELL; MONAGHAN; O'CONNOR, 2013; AHMADI *et al.*, 2013; TROST; ZHENG; WONG, 2014; WUNDERSITZ *et al.*, 2015b; SCHULDHAUS *et al.*, 2015; NGUYEN *et al.*, 2015; KAUTZ *et al.*, 2017; HOLZEMANN; LAERHOVEN, 2018; PENG *et al.*, 2018; HALADJIAN *et al.*, 2020; JOWITT *et al.*, 2020). Logo, no presente estudo, os algoritmos utilizados mostraram concordância de moderada a forte (coeficiente concordância de Kendall) e aceitável a forte (CCI) para a acurácia e de aceitável a excelente (coeficiente concordância de Kendall) e boa a excelente (CCI) para relação entre sensibilidade e especificidade entre as etapas de treinamento e avaliação da performance dos classificadores (tabela 2.5).

No entanto, apesar do excelente desempenho de acurácia, precisão, sensibilidade e especificidade dos classificadores treinados e testados com a combinação de sensores e agregação de diferentes tipos de características de entrada (ACC3+GIR1) evidenciado no estudo, há a necessidade de condução de mais estudos com protocolos que envolvam transições para reconhecimento de ações aproximando-se da realidade, uma possível limitação para a extrapolação dos classificadores obtidos para a prática. Nesse sentido, a adoção de protocolos de atividades de treinamento e competições (circuitos de atividades específicas do esporte, jogos reduzidos, jogos etc.) para incremento progressivo de validade ecológica de algoritmos de aprendizado de máquina a partir de dados obtidos de UMI para reconhecimento válido e confiável de atividades físico – esportivas, bem como a diversificação, atualização ou ainda individualização do conjunto amostral para treinamento e testagem do(s) classificador(es). Logo, estudos futuros devem avaliar que características possuem maior peso na classificação dos diversos movimentos, utilizando técnicas de seleção de variáveis, como por exemplo, o algoritmo *Least Absolute Shrinkage and Selection Operator* (LASSO) (HASTIE; TIBISHIRANI; FRIEDMAN, 2017).

A partir da premissa de análise da técnica de movimento por meio da descrição do comportamento do centro de gravidade corporal, consolidada na biomecânica, em hipótese, o desempenho para reconhecimento de ações poderia ser maximizado com o posicionamento de UMI na região lombar, ou seja, próximo à posição do centro de gravidade. Entretanto, em uma perspectiva prática, o posicionamento de sensores

vestíveis em treinos e competições é comumente realizado no tronco, entre as escápulas, especialmente nos esportes coletivos. Logo, permanece em aberto e adicionada às limitações já apresentadas, se há ou não divergência sobre o desempenho dos classificadores quanto ao posicionamento dos sensores inerciais, remontando uma outra possível limitação do estudo, no sentido de extrapolação dos algoritmos treinados diretamente a prática.

### **3.7. Conclusões**

A combinação das informações do acelerômetro, giroscópio e das diferentes características de entrada (estatísticas descritivas, customizadas e medidas de análise de séries temporais) mostrou melhor acurácia, sensibilidade, especificidade e precisão de classificação de ações de permanecer parada, em marcha, corrida leve, corrida moderada, MMD, SCM e *sprints* (>90%) em relação ao emprego isolado de acelerômetros. Além disso, uma concordância de boa/moderada para acurácia geral e relação entre sensibilidade e especificidade para o desempenho observado no treinamento e teste do algoritmo k-NN “fine” foi identificada, confirmando as hipóteses pré-estabelecidas. Os resultados obtidos por UMI de baixo custo são promissores, porém, novos estudos com desenho experimental de maior validade ecológica são necessários para adoção algoritmos treinados e avaliados a partir das séries temporais de dados obtidas de UMI no processo de monitoramento de treinos e competições.

## CAPÍTULO 4 – UTILIZAÇÃO DE SENSORES INERCIAIS PARA MONITORAMENTO DAS DEMANDAS FÍSICAS NO HANDEBOL (EXPERIMENTO III)

### 4.1. Introdução

Atualmente, diversos dispositivos vestíveis, tais como sensores inerciais, compostos por acelerômetros, giroscópios e magnetômetros, têm sido incorporados aos esportes coletivos, fornecendo um amplo conjunto de variáveis para dar suporte ao processo decisório de comissões técnicas (CARDINALE; VARLEY, 2017; CUST *et al.*, 2018). As UMI têm sido utilizados como recurso de monitoramento do perfil de atletas por meio da determinação intensidade do sinal de aceleração (RMS, resultante vetorial e “*player load*” - PL), impactos, frequência e tempo gasto por zonas para acelerações e desacelerações. Adicionalmente, por meio de técnicas não – lineares de aprendizado de máquina, o desempenho ou atividades locomotoras (ex.: marcha, corrida, mudanças de direção, sprints etc) podem ser classificadas por UMI, ou ainda, por meio da correção do *drift* de integração, para determinação do perfil de deslocamento e velocidade nos esportes coletivos (WUNDERSITZ *et al.*, 2015a; SWEETING *et al.*, 2017; ROELL *et al.*, 2019; BURLAND *et al.*, 2020; WALDRON *et al.*, 2022). Nesse sentido, apesar do entendimento da complexidade das demandas físicas e fisiológicas e seus efeitos, a abordagem convencional de interpretação isolada de tais variáveis torna-se paradoxal. Logo, o monitoramento baseado na abordagem de combinação de variáveis por dispositivos vestíveis, por vezes colineares, a adoção de métodos para redução da dimensionalidade por meio da construção de combinações lineares, permite sumarizar e visualizar a complexidade da demanda imposta, facilitando a comunicação e a incorporação de dados na tomada de decisões. Por consequência, viabiliza a seleção de variáveis mais importantes e a avaliação de diferenças intra e interindividuais por meio dos escores das variáveis construídas, de suma importância aos esportes coletivos (WEAVING *et al.*, 2014; WEAVING *et al.*, 2017b; WEAVING *et al.*, 2018; WEAVING *et al.*, 2019; WEAVING *et al.*, 2020; RYAN *et al.*, 2020; WEAVING; READ, 2022).

Dentre os diversos esportes coletivos de invasão, o handebol é caracterizado por ações intermitentes de alta intensidade, envolvendo corridas, *sprints*, mudanças de

direção, acelerações, desacelerações, lançamentos, saltos e colisões, intercalados por atividades de baixa intensidade como corrida leve e marcha (GOROSTIAGA *et al.*, 1999; CORVINO *et al.*, 2016; CORVINO *et al.*, 2016). Sendo assim, o entendimento das demandas físicas impostas no handebol, é essencial para a planificação e individualização do processo de treinamento. A partir da compreensão dos desafios para determinação das demandas em ambiente fechados, captura de ações de alta intensidade, custos e restrições técnicas impostas por GPS, LPS e de análise cinemática tridimensional a adoção de UMI tem possibilitado o monitoramento de situações de treinos e jogos no handebol (WIK; LUTEBERGET; SPENCER, 2017; LUTEBERGET; SPENCER, 2017; LUTEBERGET; TROLLERUD; SPENCER, 2017; LUTEBERGET *et al.*, 2018; GÓMEZ-CARMONA *et al.*, 2020).

Wik; Luteberget; Spencer (2017) analisaram os perfis de atividade de atletas de handebol feminino de alto nível em partidas oficiais (n=9) por meio quantificação da variável PL (Equação 1) em períodos de 5 e 10 minutos utilizando UMI (100 Hz). Os autores verificaram uma elevada intensidade inicial para a equipe e jogadoras com mais de períodos consecutivos de jogo, com substancial declínio para a variável “*player load*” observado ao longo das partidas para a equipe como um todo e para as atletas com vários tempos de jogo consecutivos em quadra (> 60% do tempo em quadra). Estas tendências foram encontradas para todas as posições de jogo e a intensidade da equipe aumentou substancialmente nos cinco minutos finais do primeiro tempo de jogo. Tais achados podem ser atribuídos à fadiga e fatores situacionais de jogo.

Na mesma linha, Luteberget; Spencer (2017) descreveram o perfil de atividades de alta intensidade em partidas internacionais por posição de jogo, por meio das variáveis PL, contagem de acelerações, desacelerações e mudanças de direção e “*high – intensity events*” ou eventos de alta intensidade (HIE, definido como à soma de acelerações, desacelerações e mudanças de direção) por UMI (acelerômetro, giroscópio e magnetômetro; 100Hz). Os pesquisadores verificaram diferenças substanciais entre posições de jogo, onde armadores evidenciaram maior frequência de HIE/minuto ( $5,0 \pm 1,1$ ) que todas as outras posições de jogo, também mostrado para a variável PL/minuto. Os autores concluíram que os HIE no handebol feminino internacional são específicos por posição e a intensidade geral depende do papel posicional ocupado na equipe. Adicionalmente, Luteberget; Trollerud; Spencer (2017) comparam a intensidade de jogos reduzidos (3 vs. 3; 6 vs. 6) com a de partidas oficiais

por posição de jogo em jogadoras semi - profissionais, utilizando UMI (acelerômetro, giroscópio e magnetômetro; 100Hz), para as variáveis PL/minuto e HIE/minuto. Os resultados indicaram uma maior intensidade para PL/minuto e HIE/minuto ( $p < 0,05$ ) nos jogos reduzidos onde um menor número de jogadores (3 vs. 3). Adicionalmente, os autores verificaram que a intensidade dos jogos reduzidos com duração de 5 minutos mostrou valores significativamente maiores que a intensidade média de partidas oficiais para armadores, pontas e pivôs para a variável PL/minuto ( $p < 0,05$ ). No entanto, o mesmo padrão para a variável HIE/minuto não ocorreu para armadores e pivôs, somente para pontas ( $p < 0,05$ ).

Entretanto, deve ser mencionado que as variáveis adquiridas nos estudos supracitados notadamente são caracterizadas pelo fenômeno de multicolinearidade, ou seja, estas métricas para monitoramento de treinos e jogos notadamente apresentam algum grau de associação (ex.: HIE vs. mudanças de direção; acelerações vs. PL etc.) significativa entre si (WEAVING *et al.*, 2014; WEAVING *et al.*, 2018; WEAVING *et al.*, 2019; RYAN *et al.*, 2020, PINO-ORTEGA *et al.*, 2021). Este fenômeno é amplamente observado entre variáveis de ordem biomecânica ou entre variáveis fisiológicas e biomecânicas, como numa relação dose - resposta, sendo dependentes do contexto em que as medidas são realizadas (SANDS *et al.*, 2017; WEAVING *et al.*, 2017). Em uma perspectiva mais ampla, o vasto conjunto de variáveis obtidas ao longo de treinos e jogos a partir de sensores vestíveis é frequentemente pouco explorado adequadamente por comissões técnicas, dada a pressão por resultados, calendários competitivos exigentes, ou ainda o desconhecimento de procedimentos estatísticos adequados para sintetizar as informações coletadas (SANDS *et al.*, 2017; WEAVING *et al.*, 2017; OWEN, 2022; WEAVING; READ, 2022).

Nesse sentido, a simplificação da complexidade do monitoramento esportivo por estratégias multivariadas tem sido utilizada essencialmente através da análise fatorial exploratória (AFE) pelo método das componentes principais, acompanhado pela rotação ortogonal apropriada dos fatores (WEAVING *et al.*, 2017; WEAVING *et al.*, 2019; PINO-ORTEGA *et al.*, 2021; TORRES-HONDA *et al.*, 2022), que deve ser diferenciada da análise de componentes principais (ACP). Logo, a redução da dimensionalidade tem sido empregada para identificação das métricas mais relevantes e suas inter-relações em treinos e competições de forma geral (WEAVING *et al.*, 2018; RYAN *et al.*, 2020; SHEHAN *et al.*, 2020; WEAVING *et al.*, 2020), entre

posições (SVILLAR *et al.*, 2018; MORENCOS *et al.*, 2021; STONE *et al.*, 2022), meio de treinamento (WEAVING *et al.*, 2014; CASAMICHANA *et al.*, 2019), tempos de jogo (RICO – GONZÁLEZ *et al.*, 2020) e conforme o contexto de jogo dentro e fora de casa (OLIVA – LOZANO *et al.*, 2021), exclusivamente nos esportes coletivos de invasão, por variáveis predominantemente mecânicas (distâncias percorridas por zonas de velocidade, tempo gasto em cada intensidade, acelerações, desacelerações, mudanças de direções, impactos, saltos, etc.).

Entretanto, apesar dos escores obtidos por meio das componentes ou fatores construídos apresentarem uma valorosa utilidade prática para avaliação das diferenças intra – atleta e entre atletas e jogos (WEAVING *et al.*, 2017; WEAVING *et al.*, 2018; RYAN *et al.*, 2020; WEAVING; READ, 2022), os estudos que tem explorado o potencial contido nas novas variáveis construídas a partir das variáveis originais são escassos, para além do interesse sobre a seleção e identificação das inter-relações entre as métricas para monitoramento.

Conforme mencionado, a imensa quantidade de dados obtidos no processo de treinamento tem-se colocado como um desafio rotineiro às ciências do esporte e à prática de treinadores e comissão técnica (CARDINALE; VARLEY, 2017; CUST *et al.*, 2018). Nesse sentido, a aplicação de técnicas multivariadas para sumarizar a grande quantidade de variáveis quantificadas em treinos e jogos enquanto conserva a estrutura de variabilidade dos dados, não tem recebido a devida atenção como ferramenta de monitoramento na busca de equilibrar a necessidade de comunicação dos dados entre os membros da comissão técnica (WEAVING *et al.*, 2017; WEAVING *et al.*, 2019; RYAN *et al.*, 2020; TORRES – HONDA *et al.*, 2022; WEAVING; READ, 2022), especialmente em modalidades como o handebol que ascenderam tardiamente à utilização de tecnologias e sistemas de rastreamento para monitoramento das demandas físicas impostas.

Nesse sentido, entendendo a possível presença do fenômeno de multicolinearidade entre as variáveis mecânicas quantificadas a partir de sensores inerciais, há a necessidade de síntese das informações coletadas para entendimento do desempenho esportivo. Logo, em detrimento a uma análise isolada, uma abordagem de combinação de variáveis foi empregada para sumarizar e identificar como as variáveis originais agrupam – se em fatores, e, a partir dos escores das variáveis construídas nas análises, classificar o desempenho individual observado em jogos consecutivos no handebol, ou seja, em condições reais de prática.

## 4.2. Objetivo

Os objetivos deste capítulo são: (i) sumarizar as informações contidas nas variáveis originais e identificar como estas agrupam-se para interpretação das demandas físicas observada nas partidas e por tempo de jogo no handebol por meio da utilização de sensores inerciais vestíveis; bem como (ii) a partir das novas variáveis construídas, avaliar a magnitude das demandas físicas impostas em jogos e tempos de jogo no handebol.

## 4.3. Hipóteses

H1 – Uma maior contribuição do tempo nas zonas de aceleração e desaceleração com maior intensidade no cômputo dos escores das componentes e fatores de maior variância explicada será evidenciada nas análises multivariadas;

H2 – Uma redução dos escores obtidos nas análises ocorrerá ao longo das partidas consecutivas realizadas;

H3 – Os escores obtidos nas análises apresentarão alterações entre tempos de jogo, evidenciando uma queda de desempenho.

## 4.4. Materiais & Métodos

### 4.4.1. *Delineamento do estudo*

Este estudo foi caracterizado como do tipo experimental transversal, delineado inteiramente ao acaso para analisar a abordagem de monitoramento a partir de variáveis quantificadas a partir dos sensores inerciais, durante jogos consecutivos (JG) no handebol em um campeonato estadual de formato eliminatório (Figura 4.1).

### 4.4.2. *Cuidados éticos*


Este estudo foi aprovado junto ao comitê de ética em pesquisa local (CAAE 38365620.3.0000.5149) e sua condução respeitou a declaração de Helsinki. Antes da realização da competição, os atletas foram contactados e informados quanto aos objetivos, métodos, possíveis riscos e benefícios oriundos da participação no estudo.

O consentimento foi recolhido por meio de um TCLE (Apêndice A), sendo reservado aos voluntários o direito, por quaisquer motivos, de deixar de participar do estudo a qualquer momento, sem qualquer prejuízo.

#### 4.4.3. Amostra

Para este estudo, 16 jogadores adultos de handebol do sexo masculino foram recrutados ( $29,62 \pm 3,66$  anos,  $85,62 \pm 15,22$  kg,  $179,36 \pm 6,60$  cm). Porém, os goleiros foram excluídos do estudo para a execução do desenho experimental ( $n=14$  indivíduos). No início das competições, os jogadores não reportaram lesões de ordem músculo – esquelética e todos possuíam pelo menos cinco anos de experiência em competições estaduais e/ou nacionais de handebol. Entretanto, dois indivíduos foram excluídos da amostra por lesão (primeiro e terceiro jogo) e um por problema no acionamento do sensor (primeiro jogo). O indivíduo lesionado no primeiro jogo foi substituído por outro atleta para os jogos seguintes. O atleta excluído das análises no primeiro jogo por problemas de acionamento no sensor foi reincorporado à amostra nos jogos seguintes. Os indivíduos incluídos no estudo eram integrantes de uma equipe de handebol amador, participante da fase final do campeonato mineiro adulto de handebol (2 vitórias, 1 derrota, classificado como 3° lugar geral). Logo, a execução do desenho experimental compreendeu o número de 39 repetições obtidas (JG1,  $n=12$ ; JG2,  $n=14$ ; JG3,  $n=13$ ).

Figura 4.1 – Delineamento experimental do estudo.



Fonte: Dados da pesquisa.

#### 4.4.4. Procedimentos e Instrumentos

Inicialmente, os voluntários recrutados receberam as informações sobre o estudo e na sequência foi recolhido o consentimento por escrito via TCLE. Na sequência, os indivíduos foram caracterizados com relação a sua massa corporal (Kg) e estatura

(m), no local da competição. A massa corporal e a estatura foram obtidas por meio de uma balança digital com um estadiômetro acoplado (SECA®, Hamburgo, Alemanha). Logo após, os voluntários foram orientados a selecionar coletes em poliamida conforme o tamanho, para acomodação dos sensores inerciais durante os jogos (Figura 4.2).

Para monitoramento dos jogos, os jogadores vestiram os respectivos coletes em poliamida enumerados com o mesmo número de uniformes, utilizando um sensor inercial WT901SDCL® revestido por uma peça em EVA sua estabilização (Figura 02), sendo acionados e acomodados entre as escápulas aproximadamente 30 minutos antes do início das partidas, sendo recolhidos e desligados imediatamente ao final de cada jogo. Ao todo foram monitorados três jogos realizados em dias consecutivos (sexta a domingo), respeitando um sistema de disputa de caráter eliminatório, composto por 8 equipes (JG1, 20h15min - 21h35min; JG2 – 19h30min a 20h50min; JG3 – 11h a 12h20min; Intervalo entre JG1 e JG2 – aproximadamente 21h55min; Intervalo entre JG2 e JG3 – aproximadamente 14h10min).

Figura 4.2 – Utilização da UMI: colete de poliamida para acomodação do sensor (WT901SDCL, Wit - Motion, Shenzhen, China).



Fonte: Dados da pesquisa.

O sensor utilizado permite o uso contextual a prática (*offline*), sendo composto por um acelerômetro (x, y, z;  $\pm 16$  g), giroscópio (x, y, z;  $\pm 2000^\circ/\text{s}$ ) e magnetômetro (x, y, z;  $\pm 4900\mu\text{T}$ ) triaxiais (MPU-9250, TDK Invensense, San Jose, California, EUA), possuindo um filtro dinâmico de Kalman para alisamento dos dados. O registro *wireless* foi realizado a uma taxa de amostragem de 100Hz e o armazenamento de

dados é efetuado em micro-cartão de memória (consumo corrente < 40mA/h, bateria LiPO 260mA/h, tensão operacional de 3,7V). O sensor possui a função de registro de data e hora (função “*time-stamp*”), utilizada para identificação do momento inicial e final de cada tempo nas coletas de dados, perfazendo os pedidos de tempo realizados e intervalos de jogo.

A calibração, carregamento e configuração do equipamento foi efetuado previamente por meio do software MIMU® proprietário (Wit - Motion, Shenzhen, China). O acelerômetro foi calibrado estaticamente ( $1g$ ,  $g=9,81 \text{ m.s}^{-2}$ ) e o magnetômetro pelo método elipsóide através da movimentação em torno dos eixos superior-inferior, látero-lateral e ântero-posterior do sensor. O giroscópio é calibrado automaticamente com a calibração através do software MIMU®.

Para registro das coletas, uma câmera *GoPro Hero 6 Black*® (GoPro, San Mateo, EUA) acoplada a uma bateria externas recarregável de 5200mA/h para extensão da autonomia de utilização (tensão operacional de 3,7V – 5V), a uma taxa de amostragem de 240Hz (full HD, 12 megapixels, 1080x240 de resolução) foi utilizada. A câmera foi fixada sobre um tripé em posição diagonal à quadra próximo à linha de fundo, sempre em perspectiva de topo. A câmera foi acionada por um controle remoto *wifi* recarregável. As imagens foram armazenadas em um microcartão de memória SDXC com capacidade de 256gb (formato HEVC).

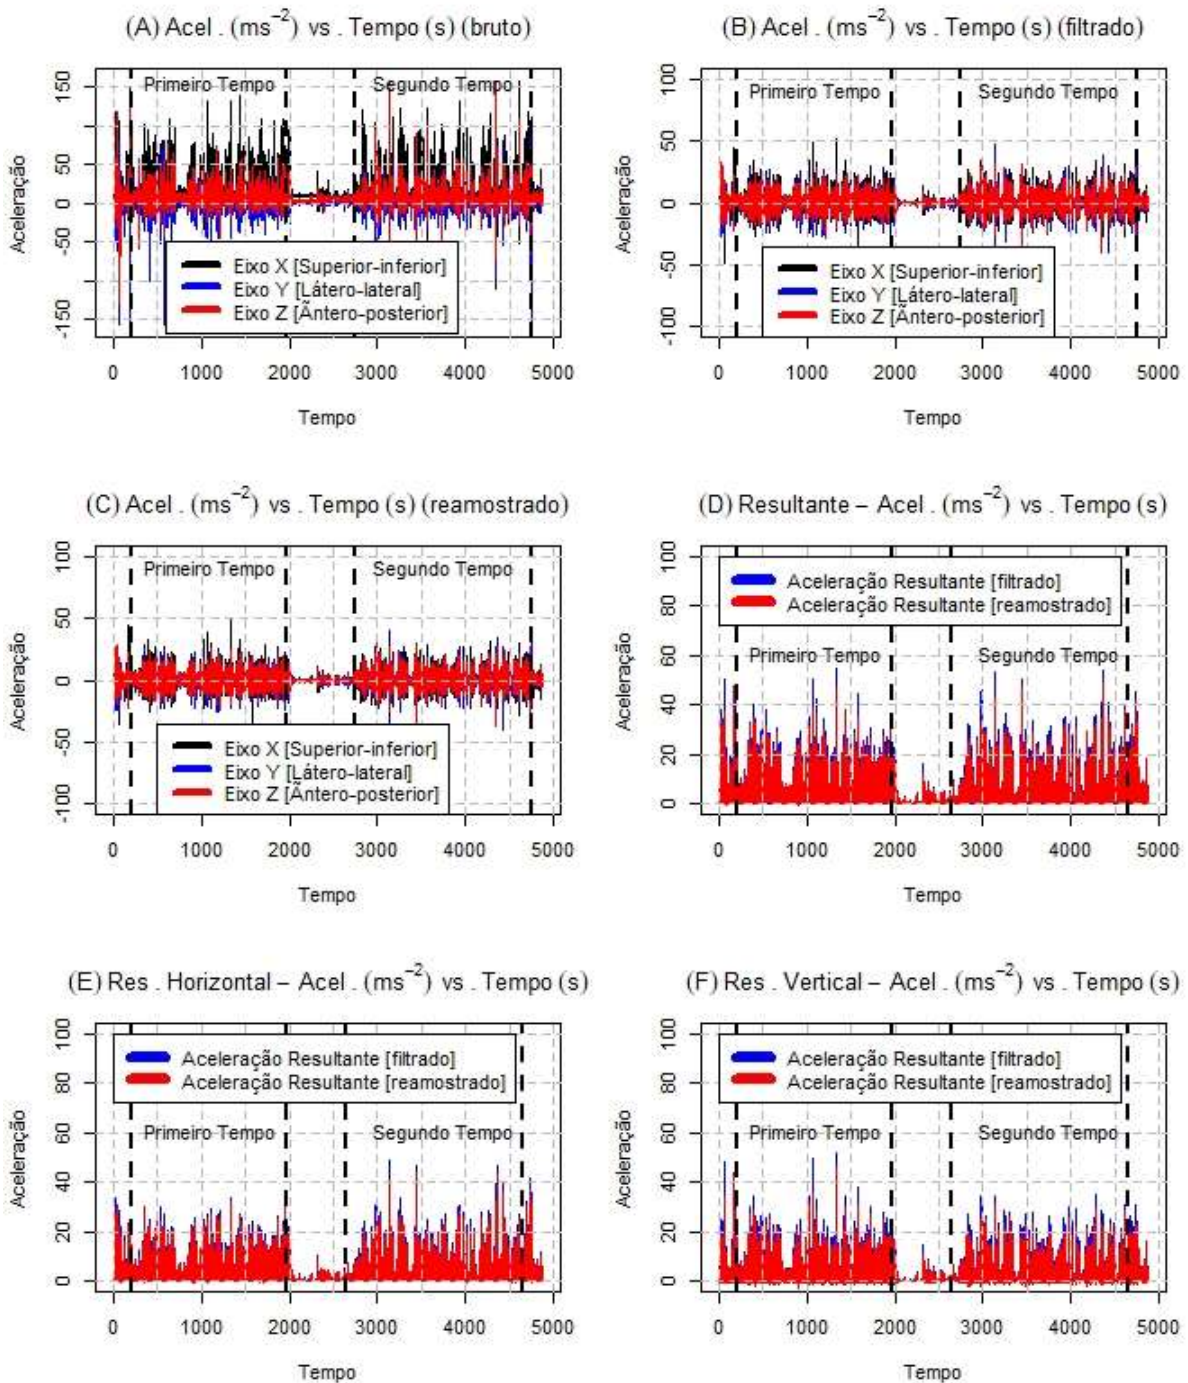
#### 4.4.5. *Processamento dos dados*

Os dados brutos dos sensores inerciais referentes à aceleração linear ( $g$ ), velocidade angular ( $^{\circ}/s$ ), campo magnético ( $\mu T$ ), ângulo de euller (eixos “x”, *pitch*; “y”, *roll*; “z”, *yaw*), quatérnions ( $q_0$ ,  $q_1$ ,  $q_2$  e  $q_3$ ) e o registro de data e hora das coletas armazenados em microcartão de memória, foram descarregados por meio do software MIMU® e exportados manualmente para planilhas em Microsoft Excel (Microsoft Excel 2021, versão 365, Redmond, Washington, EUA). As planilhas foram importadas e as análises realizadas usando rotinas customizadas no software “R”, versão 4.1.2 (R Core Team, 2021, Vienna, Áustria [<https://cran.r-project.org/>]).

Inicialmente, um filtro *butterworth* passa – baixa (8 Hz, *zero-lag*, 4ª ordem), seguido por um filtro *butterworth* passa – alta (0,3 Hz, *zero-lag*, 4ª ordem) foram aplicados sobre os dados brutos de aceleração referentes aos eixos “x”, “y”, “z”, para remoção do ruído e correção da gravidade, respectivamente (ROELL *et al.*, 2018; ROELL *et al.*, 2019). As figuras 4.3 e 4.4 exemplifica a magnitude do sinal bruto e o impacto da

filtragem no domínio do tempo e da frequência nos eixos superior – inferior (“x”), látero – lateral (“y”) e ântero – posterior (“z”).

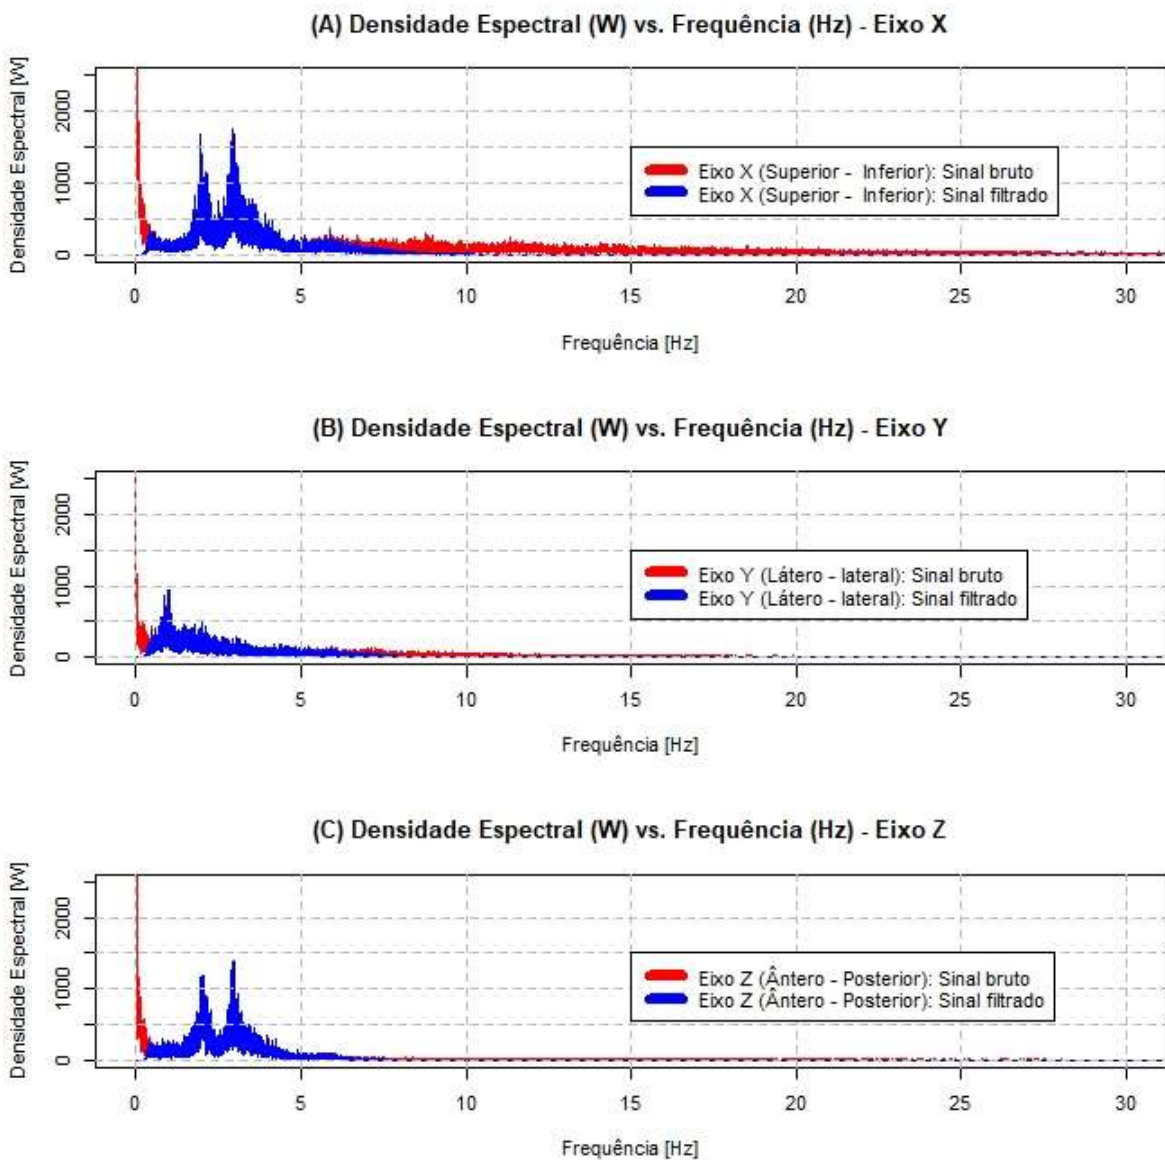
Figura 4.3 – Exemplos de sinal bruto, filtrado e reamostrado para aceleração ( $\text{m.s}^{-2}$ ) no tempo (s) (“x”, “y”, “z”, aceleração resultante vertical e horizontal).



Fonte: Dados da pesquisa.

Após o procedimento de filtragem, os dados de aceleração foram reamostrados (*downsample*) de 100Hz para 20Hz. A frequência foi selecionada em conformidade com os resultados obtidos após a aplicação da transformada rápida de Fourier, como pode ser visualizado na figura 4.4.

Figura 4.4 – Análise espectral do sinal bruto e filtrado para os dados de aceleração no tempo.



Fonte: Dados da pesquisa.

Os resultados evidenciaram maior densidade espectral de potência em componentes de frequência menores que 5 Hz. Logo, a escolha foi realizada respeitando o teorema

de amostragem de Shannon – Nyquist, que define que a frequência de amostragem mínima deve ser o dobro do componente de frequência de maior densidade espectral de potência (FIGLIOLA; BEASLEY, 2007). Subsequentemente, a partir dos dados reamostrados foram computadas as resultantes horizontal ( $acel_{horizontal}$ , eixos “y” e “z”) e vertical ( $acel_{vertical}$ , eixo “x”) para determinar os respectivos valores médios e de pico referentes a cada uma das curvas (Horizontal - ARESHmedia, ARESHmax; Vertical - ARESVmedia, ARESVmax), conforme as equações de 1 a 2 abaixo:

$$acel_{horizontal} = \sqrt{y^2 + z^2} \quad \text{Equação 1}$$

$$acel_{vertical} = \sqrt{x^2} \quad \text{Equação 2}$$

Na sequência, os dados reamostrados foram utilizados para determinar o tempo gasto por faixas de acelerações para os eixos “x” (vertical para cima), “y” (direita) e “z” (anterior) (tVertA<sub>BAIXO</sub>; tDir<sub>BAIXO</sub>; tAC<sub>BAIXO</sub>: 1,0 a 2,5 m/s<sup>-2</sup> - baixa; tVertA<sub>MODERADO</sub>; tDir<sub>MODERADO</sub>; tAC<sub>MODERADO</sub>: 2,6 a 4,0 m/s<sup>-2</sup> - moderada; tVertA<sub>ALTO</sub>; tDir<sub>ALTO</sub>; tAC<sub>ALTO</sub>: >4,0 m/s<sup>-2</sup> – alta), faixas de desaceleração somente nos eixos “x” (vertical para baixo), “y” (esquerda) e “z” (posterior) (tVertD<sub>BAIXO</sub>; tEsq<sub>BAIXO</sub>; tDes<sub>BAIXO</sub>: -1,0 a -2,5 m/s<sup>-2</sup> - baixa; tVertD<sub>MODERADO</sub>; tEsq<sub>MODERADO</sub>; tDes<sub>MODERADO</sub>: -2,6 a -4,0 m/s<sup>-2</sup> - moderada; tVertD<sub>ALTO</sub>; tEsq<sub>ALTO</sub>; tDes<sub>ALTO</sub>: < -4,0 m/s<sup>-2</sup> – alta). Adicionalmente, especificamente para o eixo vertical (“x”), o número de impactos foi calculado como o número de acelerações registradas entre 2g e 6g (CASAMICHANA *et al.*, 2019; MORENCOS *et al.*, 2021). O número de saltos foi quantificado como o número de eventos identificados no eixo “x” vertical, onde o valor da amostra “i” foi menor que 2g. O valor de corte foi arbitrariamente selecionado com base em testes piloto (detecção ≥ 90%) tendo em vista as oscilações que ocorrem no acelerômetro no ato da decolagem e aterrissagem (figura 2.5) ao solo nos saltos verticais (RANTALAINEN; FINNI; WALKER, 2019). Em caso afirmativo de identificação da condição estabelecida, a busca sobre as amostras subsequentes prosseguiu após 2,5 segundos (*i+50* amostras). A determinação do número de impactos e de saltos verticais foi executada a partir do sinal filtrado e reamostrado (*downsample*).

#### 4.4.6. Análise estatística

As variáveis quantificadas (ARESHmax, ARESVmax, ARESHmedia, ARESVmedia, tVertA<sub>BAIXO</sub>, tVertA<sub>MODERADO</sub>, tVertA<sub>ALTO</sub>, tDir<sub>BAIXO</sub>, tDir<sub>MODERADO</sub>, tDir<sub>ALTO</sub>, tAC<sub>BAIXO</sub>, tAC<sub>MODERADO</sub>, tAC<sub>ALTO</sub>, tVertD<sub>BAIXO</sub>, tVertD<sub>MODERADO</sub>, tVertD<sub>ALTO</sub>, tEsq<sub>BAIXO</sub>, tEsq<sub>MODERADO</sub>, tEsq<sub>ALTO</sub>, tDes<sub>BAIXO</sub>, tDes<sub>MODERADO</sub>, tDes<sub>ALTO</sub>, número de saltos e impactos) foram descritas em termos de média e desvio – padrão (Anexo E). Previamente à realização da ACP e AFE para avaliar a adequação dos dados foi empregado a medida de adequação amostral de Kayser-Meyer-Olkin ( $KMO \geq 0.5$ , adequados para ACP e AFE - Primeiro Tempo -  $KMO = 0,76$ ; Segundo Tempo -  $KMO = 0,88$ ; Jogos Inteiros -  $KMO = 0,88$ ) e o teste de esfericidade de Bartlett, sendo considerados adequados para a condução das análises (Primeiro Tempo -  $\chi^2 = 2262,325$ ;  $p < 0,001$ ; Segundo Tempo -  $\chi^2 = 2157,90$ ;  $p < 0,001$ ; Jogos Inteiros -  $\chi^2 = 2256,412$ ;  $p < 0,001$ ) (TABACHNICK; FIDELL, 2013). Para classificar o desempenho individual nos jogos, ACP foram conduzidas para obter combinações lineares ( $CP_i$ ) e os valores gerais, denominados escores globais ( $EG$ ) neste estudo. Em seguida, uma padronização ( $Z_i$ ) das variáveis originais ( $p$ ) foi efetuada, equivalente ao cômputo da matriz de correlação para reduzir o efeito da variância sobre o cálculo dos autovetores ( $e_i$ ), onde a  $i$ -ésima componente principal ( $CP_i$ ) é definida abaixo (equação 3):

$$CP_i = e_{i1}Z_{i1} + e_{i2}Z_{i2} + \dots + e_{ip}Z_{ip} \quad i = 1,2,3, \dots \quad \text{Equação 3}$$

A seleção do número ( $k$ ) de PC a serem retidas respeitou o critério de análise da representatividade dos autovalores ( $\lambda_{CP_i}$ ) observado em cada componente ( $\lambda_{CP_i} \geq 0,70$ ), para reduzir o número de variáveis a combinações lineares ( $k < p$ ) e explicar adequadamente a variabilidade do vetor aleatório composto pelas variáveis originais (EVERITT, 2011). Em seguida, os escores das combinações retidas foram ponderados por sua respectiva variância explicada e somados para calcular os EG, onde  $\lambda_{CP_k}$  corresponde ao autovalor de cada componente “ $k$ ” retida,  $\lambda_k$  o somatório dos autovalores das componentes retidas e  $CP_k$  os respectivos escores das componentes, conforme a equação 4 abaixo:

$$EG = \sum \left( \frac{\lambda_{CP_k}}{\lambda_k} \right) * CP_k \quad k = 1,2,3, \dots \quad \text{Equação 4}$$

Adicionalmente, uma AFE via matriz de correlação foi conduzido para verificar como as variáveis originais ( $p$ ) agrupam-se em fatores ( $m$ ), onde as cargas fatoriais ( $\hat{l}_j$ ), variâncias específicas ( $\widehat{\psi}_j$ ) e comunalidades ( $\widehat{h}_j^2$ ) foram estimadas pelo método das componentes, observando o critério de kayser para determinação do número de fatores ( $\lambda_{F_j} \geq 1; m < p$ ), sendo submetidos a uma rotação varimax para maximização das cargas fatoriais. Neste experimento, somente variáveis com carga fatorial ( $\hat{l}_j > 0,50$ ) foram considerados para interpretação dos resultados dos  $m$  fatores. Cada  $j$ -ésimo fator ( $F_j$ ) é definido conforme a equação 5 a seguir:

$$F_j = l_{j1}Z_1 + l_{j2}Z_2 + \dots + l_{jp}Z_p \quad j = 1,2,3, \dots \quad \text{Equação 5}$$

Para classificar o desempenho dos indivíduos no campeonato perante a equipe, uma análise de agrupamento pelo método  $k$  – médias foi conduzida a partir dos escores das variáveis construídas nas análises, utilizando o coeficiente de partição ( $R^2$ ) para verificar a qualidade dos agrupamentos obtidos (JAMES *et al.*, 2013; MINGOTTI, 2017; TABACHNIK *et al.*, 2013). As análises foram conduzidas no software “R”, versão 3.6.1 (R Core Team, 2019, Vienna, Áustria, <https://cran.r-project.org/>).

#### 4.5. Resultados

No anexo E, as variáveis quantificadas em termos de média e desvio padrão por tempo de jogo. Após a condução das diferentes ACP, as combinações lineares CP1 apresentaram variância explicada superior a 80% (81,44% - 81,71%). As figuras de 4.5 a 4.7 reportam os gráficos *screeplot* dos autovalores para cada combinação linear, indicando as “ $k$ ” componentes retidas. Adicionalmente, os gráficos de dispersão entre componentes, fatores e escores globais contra componentes e fatores de maior variância explicada são reportados nas figuras de 4.5 a 4.7. A partir do critério estabelecido, os autovalores e percentual da variância explicada dos componentes retidos totalizaram de 87,18% a 88,24% ( $\lambda = 21,17$  a  $21,74$ ) nas ACP realizadas. As tabelas 3.1 e 3.2 reportam as cargas fatoriais, autovalores, comunalidades, variâncias específicas e percentuais de variância explicada correspondentes à cada fator e no total para cada AFE executada nos respectivos tempos de jogo e jogos completos. A

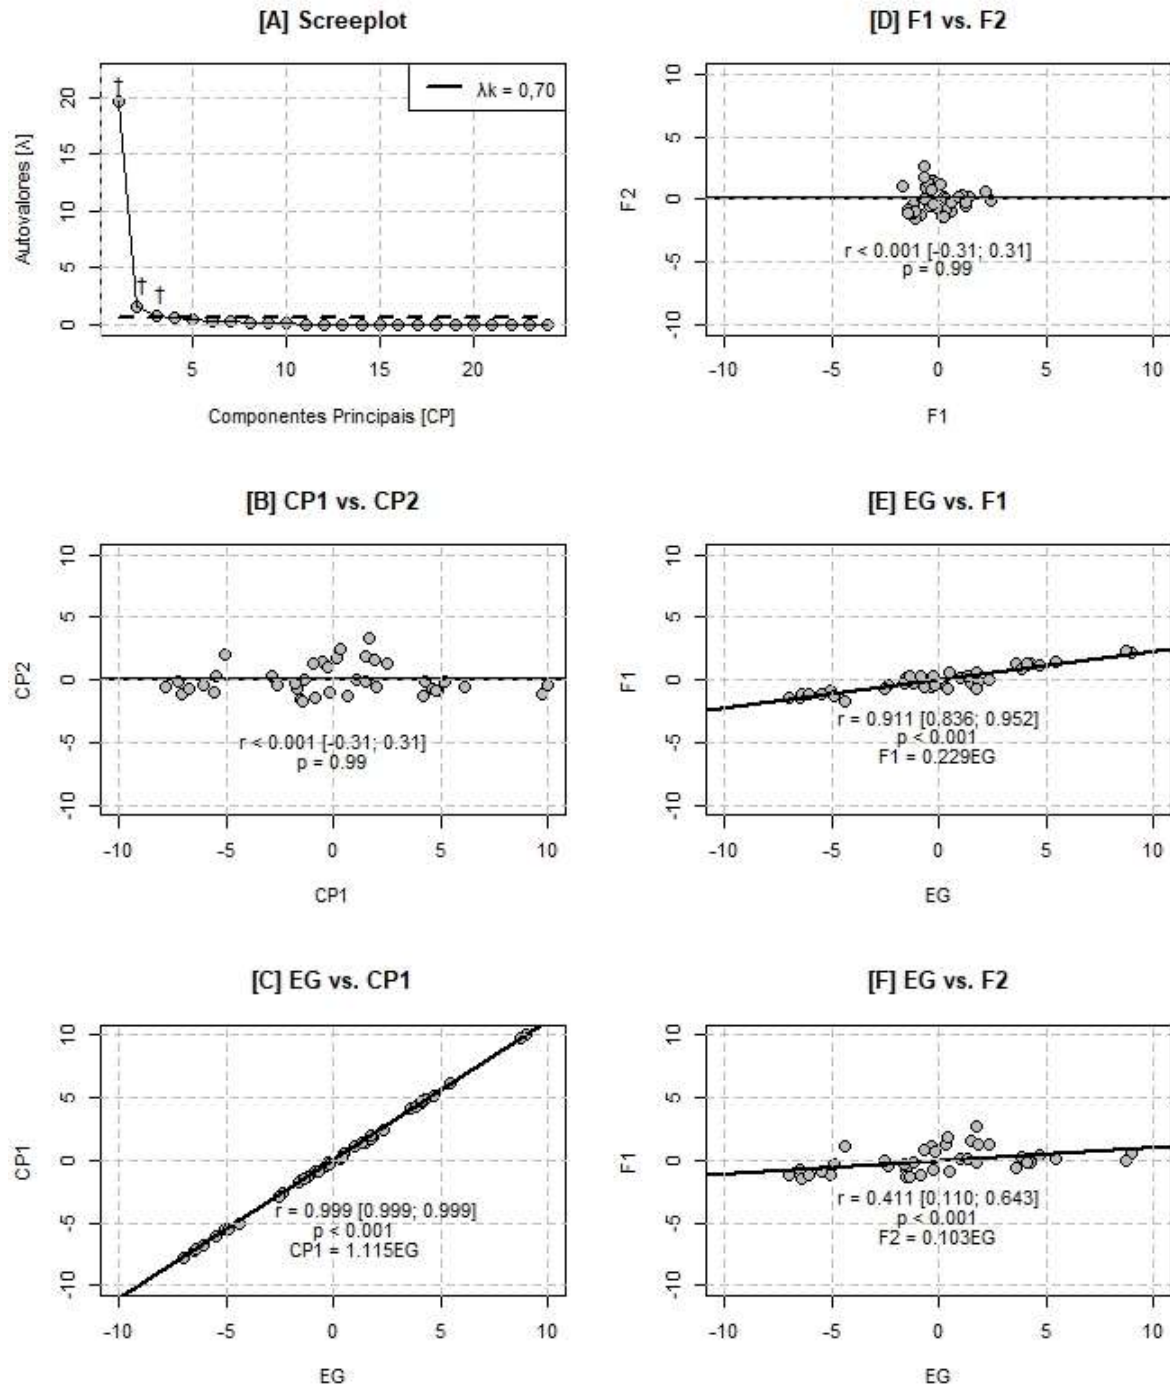
tabela 3.3 exemplifica com os valores individuais das variáveis originais a aplicação do EG, escores das componentes e fatores obtidos nas análises.

Para as análises de agrupamentos pelo método  $k$  – médias, o número de quatro agrupamentos (AG1 – demanda baixa; AG2 – demanda moderada; AG3 – demanda alta; AG4 – demanda muita alta) foi arbitrariamente definido com a finalidade de minimizar a soma dos quadrados residuais e consequentemente aumentar os valores percentuais obtidos de  $R^2$ . Para as análises de agrupamento por tempos de jogo, os valores de  $R^2$  obtidos foram superiores a 89%, indicando uma elevada heterogeneidade entre grupos, resultando em uma elevada soma dos quadrados entre grupos e a uma grande homogeneidade dos escores alocados em cada grupo.

Tabela 3.1 – ACP e AFE para partidas completas no handebol.


| Variáveis                                      | Autovetores ( $e_i$ ) |               |             | Cargas fatoriais ( $l_j$ ) |                      |                       |                |
|------------------------------------------------|-----------------------|---------------|-------------|----------------------------|----------------------|-----------------------|----------------|
|                                                | CP1                   | CP2           | CP3         | F1( $\hat{l}_{j1}$ )       | F2( $\hat{l}_{j2}$ ) | $\hat{h}_j^2$         | $\hat{\psi}_j$ |
| ARESHmax                                       | 0,166                 | 0,274         | -0,106      | <b>0,55</b>                | <b>0,60</b>          | 0,66                  | 0,35           |
| ARESVmax                                       | 0,134                 | 0,425         | -0,476      | 0,34                       | <b>0,71</b>          | 0,62                  | 0,38           |
| ARESHmedia                                     | 0,205                 | 0,014         | -0,109      | <b>0,83</b>                | 0,37                 | 0,83                  | 0,17           |
| ARESVmedia                                     | 0,196                 | 0,190         | 0,013       | <b>0,71</b>                | <b>0,56</b>          | 0,81                  | 0,19           |
| tVertA <sub>BAIXO</sub>                        | 0,212                 | -0,138        | -0,244      | <b>0,93</b>                | 0,21                 | 0,91                  | 0,09           |
| tVertA <sub>MODERADO</sub>                     | 0,220                 | -0,048        | 0,090       | <b>0,92</b>                | 0,33                 | 0,96                  | 0,04           |
| tVertA <sub>ALTO</sub>                         | 0,218                 | 0,091         | 0,204       | <b>0,85</b>                | 0,48                 | 0,95                  | 0,05           |
| tDir <sub>BAIXO</sub>                          | 0,211                 | -0,134        | -0,259      | <b>0,93</b>                | 0,22                 | 0,90                  | 0,10           |
| tDir <sub>MODERADO</sub>                       | 0,206                 | -0,183        | -0,001      | <b>0,93</b>                | 0,15                 | 0,89                  | 0,11           |
| tDir <sub>ALTO</sub>                           | 0,217                 | -0,023        | 0,197       | <b>0,90</b>                | 0,35                 | 0,93                  | 0,07           |
| tAC <sub>BAIXO</sub>                           | 0,217                 | -0,064        | -0,228      | <b>0,92</b>                | 0,30                 | 0,93                  | 0,07           |
| tAC <sub>MODERADO</sub>                        | 0,218                 | -0,108        | -0,004      | <b>0,94</b>                | 0,26                 | 0,95                  | 0,05           |
| tAC <sub>ALTO</sub>                            | 0,219                 | -0,010        | 0,142       | <b>0,90</b>                | 0,37                 | 0,95                  | 0,05           |
| tVertD <sub>BAIXO</sub>                        | 0,219                 | -0,082        | -0,121      | <b>0,93</b>                | 0,29                 | 0,96                  | 0,04           |
| tVertD <sub>MODERADO</sub>                     | 0,216                 | -0,041        | 0,153       | <b>0,90</b>                | 0,33                 | 0,92                  | 0,08           |
| tVertD <sub>ALTO</sub>                         | 0,215                 | 0,156         | 0,192       | <b>0,80</b>                | <b>0,55</b>          | 0,94                  | 0,06           |
| tEsq <sub>BAIXO</sub>                          | 0,207                 | -0,134        | -0,308      | <b>0,91</b>                | 0,21                 | 0,87                  | 0,13           |
| tEsq <sub>MODERADO</sub>                       | 0,210                 | -0,163        | -0,011      | <b>0,94</b>                | 0,18                 | 0,91                  | 0,09           |
| tEsq <sub>ALTO</sub>                           | 0,215                 | -0,029        | 0,237       | <b>0,89</b>                | 0,34                 | 0,91                  | 0,09           |
| tDes <sub>BAIXO</sub>                          | 0,217                 | -0,090        | -0,142      | <b>0,93</b>                | 0,28                 | 0,94                  | 0,06           |
| tDes <sub>MODERADO</sub>                       | 0,217                 | -0,090        | 0,083       | <b>0,93</b>                | 0,28                 | 0,94                  | 0,06           |
| tDes <sub>SALTO</sub>                          | 0,217                 | 0,035         | 0,118       | <b>0,87</b>                | 0,42                 | 0,93                  | 0,07           |
| Saltos                                         | 0,180                 | 0,228         | 0,434       | <b>0,63</b>                | <b>0,57</b>          | 0,72                  | 0,28           |
| Impactos                                       | 0,061                 | <b>-0,678</b> | -0,059      | -0,08                      | <b>0,87</b>          | 0,77                  | 0,24           |
| <b>Autovalor (<math>\lambda_{CP_k}</math>)</b> | <b>19,61</b>          | <b>1,50</b>   | <b>0,75</b> | <b>16,83</b>               | <b>4,28</b>          | $\Sigma\lambda_{F_j}$ | <b>21,11</b>   |
| <b>Variância (%)</b>                           | <b>81,71</b>          | <b>6,25</b>   | <b>3,14</b> | <b>70,0%</b>               | <b>18,0%</b>         | $\Sigma Var$          | <b>88,0%</b>   |

Figura 4.5 – Gráficos de linhas e de dispersão – Jogos Inteiros: [A] Autovalores vs. CP (*screepplot*); [B] CP1 vs. CP2; [C] EG vs. CP1; [D] F1 vs. F2; [E] EG vs. F1; [F] EG vs. F2 ( $\dagger$  Componentes retidas [ $CP_k$ ]; --- Critério para determinar as  $CP_k$ ,  $\lambda_{CP_i} \geq 0.70$ ).



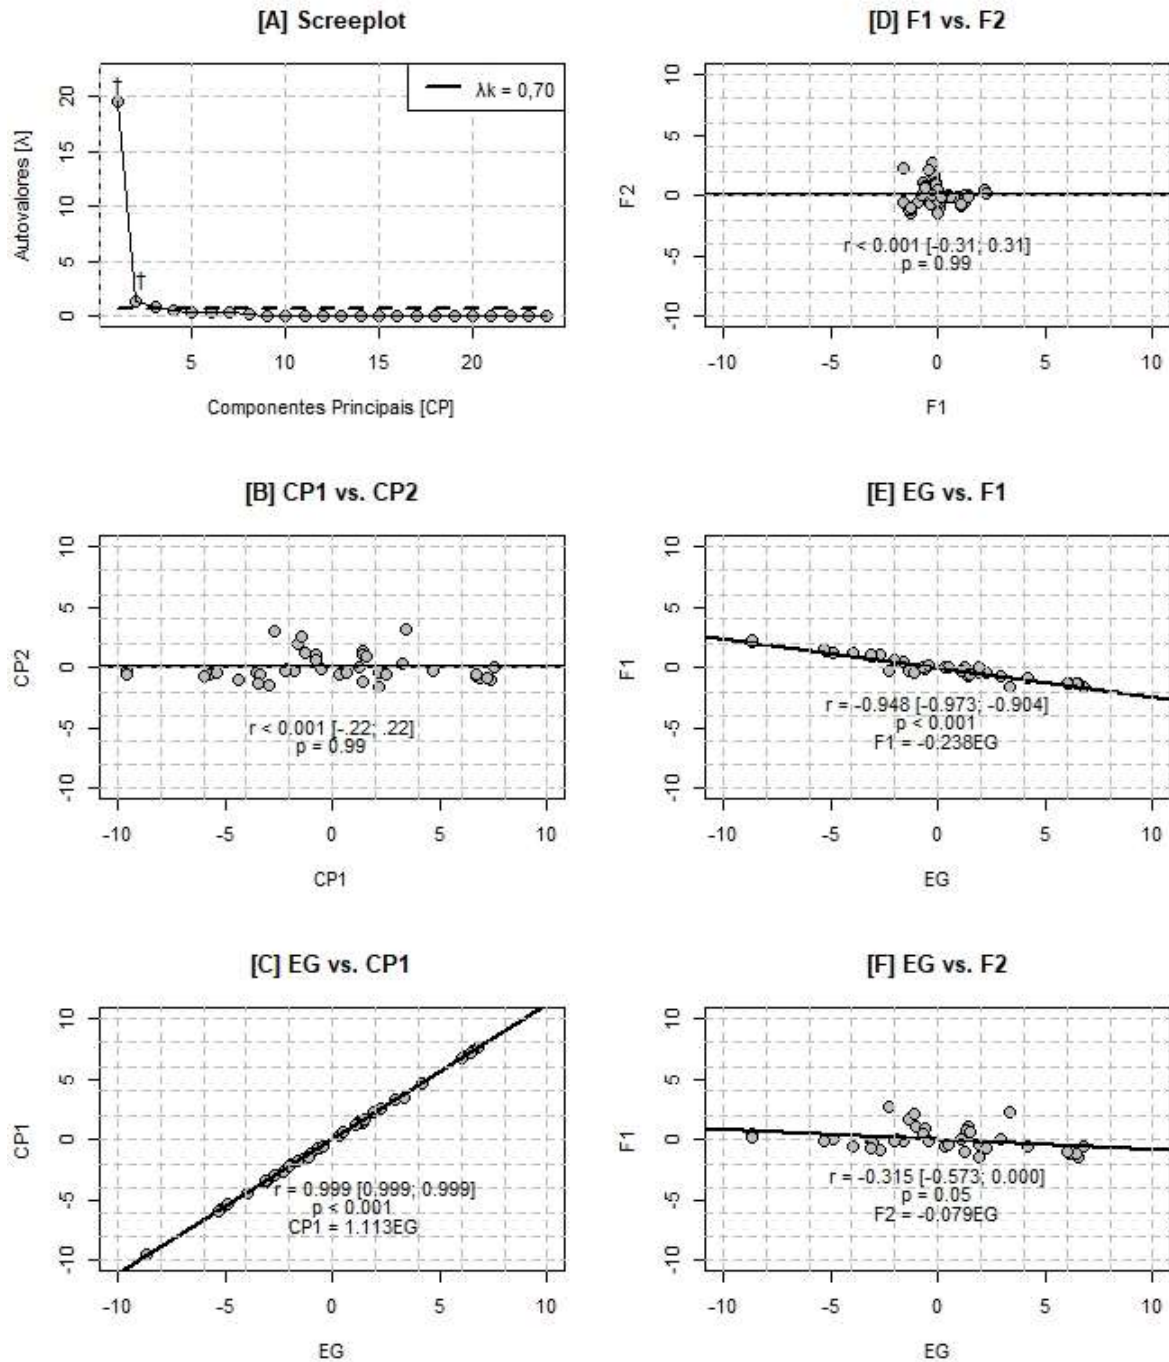
Fonte: Dados da pesquisa.

Figura 4.6 – Gráficos de linhas e de dispersão – Primeiro Tempo: [A] Autovalores vs. CP (*screeplot*); [B] CP1 vs. CP2; [C] EG vs. CP1; [D] F1 vs. F2; [E] EG vs. F1; [F] EG vs. F2 ( $\dagger$  Componentes retidas [ $CP_k$ ]; --- Critério para determinar as  $CP_k$ ,  $\lambda_{CP_i} \geq 0.70$ ).



Fonte: Dados da pesquisa.

Figura 4.7 – Gráficos de linhas e de dispersão – Segundo Tempo: [A] Autovalores vs. CP (*screeplot*); [B] CP1 vs. CP2; [C] EG vs. CP1; [D] F1 vs. F2; [E] EG vs. F1; [F] EG vs. F2 ( $\dagger$  Componentes retidas [ $CP_k$ ]; --- Critério para determinar as  $CP_k$ ,  $\lambda_{CP_i} \geq 0.70$ ).



Fonte: Dados da pesquisa.

Tabela 3.2 – ACP e AFE via rotação *varimax* por tempos de jogo no handebol.

| Variáveis                                      | T1                    |              |                            |                      |                      |                       |                | T2                    |              |             |                            |                      |                       |                |
|------------------------------------------------|-----------------------|--------------|----------------------------|----------------------|----------------------|-----------------------|----------------|-----------------------|--------------|-------------|----------------------------|----------------------|-----------------------|----------------|
|                                                | ACP [p=24; k=2]       |              | AFE [p=24; m=3]            |                      |                      |                       |                | ACP [p=24; k=3]       |              |             | AFE [p=24; m=2]            |                      |                       |                |
|                                                | Autovetores ( $e_i$ ) |              | Cargas fatoriais ( $l_j$ ) |                      |                      |                       |                | Autovetores ( $e_i$ ) |              |             | Cargas fatoriais ( $l_j$ ) |                      |                       |                |
|                                                | CP1                   | CP2          | F1( $\hat{l}_{j1}$ )       | F2( $\hat{l}_{j2}$ ) | F3( $\hat{l}_{j3}$ ) | $\hat{h}_j^2$         | $\hat{\Psi}_j$ | CP1                   | CP2          | CP3         | F1( $\hat{l}_{j1}$ )       | F2( $\hat{l}_{j2}$ ) | $\hat{h}_j^2$         | $\hat{\Psi}_j$ |
| ARESHmax                                       | -0,117                | 0,404        | 0,22                       | 0,3                  | <b>0,89</b>          | 0,92                  | 0,076          | -0,170                | 0,158        | 0,122       | <b>0,65</b>                | 0,43                 | 0,6                   | 0,4            |
| ARESVmax                                       | -0,130                | 0,420        | 0,27                       | <b>0,58</b>          | 0,47                 | 0,63                  | 0,368          | -0,136                | 0,437        | 0,419       | 0,4                        | <b>0,68</b>          | 0,63                  | 0,374          |
| ARESHmedia                                     | -0,217                | 0,008        | <b>0,85</b>                | 0,36                 | 0,27                 | 0,93                  | 0,075          | -0,205                | -0,028       | 0,014       | <b>0,87</b>                | 0,27                 | 0,83                  | 0,174          |
| ARESVmedia                                     | -0,209                | 0,164        | <b>0,73</b>                | <b>0,54</b>          | 0,28                 | 0,91                  | 0,095          | -0,195                | 0,144        | -0,110      | <b>0,76</b>                | 0,45                 | 0,78                  | 0,221          |
| tVertA <sub>BAIXO</sub>                        | -0,209                | -0,209       | <b>0,95</b>                | 0,12                 | 0,16                 | 0,94                  | 0,063          | -0,213                | -0,099       | 0,270       | <b>0,93</b>                | 0,2                  | 0,9                   | 0,097          |
| tVertA <sub>MODERADO</sub>                     | -0,220                | -0,061       | <b>0,91</b>                | 0,34                 | 0,15                 | 0,96                  | 0,042          | -0,221                | -0,032       | -0,033      | <b>0,94</b>                | 0,29                 | 0,96                  | 0,035          |
| tVertA <sub>ALTO</sub>                         | -0,219                | 0,114        | <b>0,8</b>                 | <b>0,54</b>          | 0,2                  | 0,97                  | 0,029          | -0,218                | 0,076        | -0,223      | <b>0,88</b>                | 0,41                 | 0,94                  | 0,06           |
| tDir <sub>BAIXO</sub>                          | -0,209                | -0,160       | <b>0,92</b>                | 0,15                 | 0,22                 | 0,91                  | 0,089          | -0,214                | -0,108       | 0,254       | <b>0,93</b>                | 0,2                  | 0,91                  | 0,088          |
| tDir <sub>MODERADO</sub>                       | -0,210                | -0,135       | <b>0,91</b>                | 0,16                 | 0,26                 | 0,91                  | 0,085          | -0,208                | -0,179       | 0,002       | <b>0,94</b>                | 0,11                 | 0,89                  | 0,106          |
| tDir <sub>ALTO</sub>                           | -0,218                | -0,013       | <b>0,87</b>                | 0,39                 | 0,17                 | 0,94                  | 0,062          | -0,216                | -0,026       | -0,228      | <b>0,91</b>                | 0,29                 | 0,92                  | 0,083          |
| tAC <sub>BAIXO</sub>                           | -0,216                | -0,147       | <b>0,94</b>                | 0,22                 | 0,14                 | 0,95                  | 0,047          | -0,216                | -0,029       | 0,252       | <b>0,91</b>                | 0,29                 | 0,92                  | 0,082          |
| tAC <sub>MODERADO</sub>                        | -0,217                | -0,089       | <b>0,91</b>                | 0,31                 | 0,12                 | 0,94                  | 0,055          | -0,219                | -0,094       | 0,049       | <b>0,95</b>                | 0,22                 | 0,96                  | 0,044          |
| tAC <sub>ALTO</sub>                            | -0,219                | 0,043        | <b>0,84</b>                | 0,46                 | 0,17                 | 0,95                  | 0,048          | -0,218                | -0,030       | -0,162      | <b>0,92</b>                | 0,29                 | 0,94                  | 0,062          |
| tVertD <sub>BAIXO</sub>                        | -0,219                | -0,125       | <b>0,94</b>                | 0,25                 | 0,15                 | 0,97                  | 0,034          | -0,219                | -0,065       | 0,163       | <b>0,94</b>                | 0,25                 | 0,95                  | 0,054          |
| tVertD <sub>MODERADO</sub>                     | -0,216                | -0,036       | <b>0,87</b>                | 0,37                 | 0,15                 | 0,92                  | 0,081          | -0,218                | -0,022       | -0,090      | <b>0,92</b>                | 0,3                  | 0,93                  | 0,067          |
| tVertD <sub>ALTO</sub>                         | -0,216                | 0,170        | <b>0,76</b>                | 0,6                  | 0,22                 | 0,97                  | 0,026          | -0,214                | 0,139        | -0,222      | <b>0,84</b>                | 0,47                 | 0,93                  | 0,073          |
| tEsq <sub>BAIXO</sub>                          | -0,206                | -0,170       | <b>0,91</b>                | 0,14                 | 0,19                 | 0,89                  | 0,112          | -0,210                | -0,110       | 0,295       | <b>0,92</b>                | 0,19                 | 0,88                  | 0,117          |
| tEsq <sub>MODERADO</sub>                       | -0,210                | -0,149       | <b>0,91</b>                | 0,15                 | 0,25                 | 0,92                  | 0,077          | -0,213                | -0,149       | -0,025      | <b>0,95</b>                | 0,15                 | 0,92                  | 0,08           |
| tEsq <sub>ALTO</sub>                           | -0,217                | -0,010       | <b>0,87</b>                | 0,38                 | 0,18                 | 0,93                  | 0,07           | -0,214                | -0,034       | -0,256      | <b>0,91</b>                | 0,28                 | 0,9                   | 0,098          |
| tDes <sub>BAIXO</sub>                          | -0,216                | -0,150       | <b>0,94</b>                | 0,23                 | 0,12                 | 0,95                  | 0,046          | -0,217                | -0,054       | 0,191       | <b>0,93</b>                | 0,26                 | 0,93                  | 0,071          |
| tDes <sub>MODERADO</sub>                       | -0,215                | -0,066       | <b>0,89</b>                | 0,33                 | 0,14                 | 0,92                  | 0,085          | -0,220                | -0,070       | -0,048      | <b>0,95</b>                | 0,25                 | 0,95                  | 0,046          |
| tDes <sub>ALTO</sub>                           | -0,216                | 0,099        | <b>0,8</b>                 | <b>0,52</b>          | 0,19                 | 0,95                  | 0,054          | -0,214                | -0,005       | -0,170      | <b>0,9</b>                 | 0,31                 | 0,9                   | 0,101          |
| Saltos                                         | -0,184                | 0,225        | <b>0,6</b>                 | <b>0,57</b>          | 0,26                 | 0,75                  | 0,247          | -0,165                | 0,245        | -0,391      | <b>0,59</b>                | <b>0,51</b>          | 0,62                  | 0,384          |
| Impactos                                       | -0,093                | <b>0,557</b> | 0,05                       | <b>0,87</b>          | 0,13                 | 0,77                  | 0,228          | -0,057                | <b>0,748</b> | 0,062       | -0,05                      | <b>0,91</b>          | 0,84                  | 0,163          |
| <b>Autovalor (<math>\lambda_{CP_k}</math>)</b> | <b>19,56</b>          | <b>1,61</b>  | <b>15,90</b>               | <b>4,08</b>          | <b>1,83</b>          | $\Sigma\lambda_{F_j}$ | <b>21,81</b>   | <b>19,54</b>          | <b>1,37</b>  | <b>0,83</b> | <b>17,53</b>               | <b>3,39</b>          | $\Sigma\lambda_{F_j}$ | <b>20,92</b>   |
| <b>Variância (%)</b>                           | <b>81,50</b>          | <b>6,74</b>  | <b>66,0%</b>               | <b>17,0%</b>         | <b>8,0%</b>          | $\Sigma$ Variance     | <b>91,0%</b>   | <b>81,44</b>          | <b>5,74</b>  | <b>3,49</b> | <b>73,0%</b>               | <b>14,0%</b>         | $\Sigma$ Variance     | <b>87,0%</b>   |

Tabela 3.3 – Exemplo de aplicação das combinações lineares (CP), escore global (EG) e fatores a partir dos dados originais de dois atletas (A1 e A2) por jogo.

| Variáveis Originais        | Atleta 1 [A1] |        |        | Atleta 2 [A2] |        |        |
|----------------------------|---------------|--------|--------|---------------|--------|--------|
|                            | [JG1]         | [JG2]  | [JG3]  | [JG1]         | [JG2]  | [JG3]  |
| ARESHmax                   | 39,48         | 52,55  | 46,73  | 46,10         | 49,94  | 45,05  |
| ARESVmax                   | 38,61         | 34,11  | 39,23  | 32,07         | 30,62  | 37,74  |
| ARESHmedia                 | 2,39          | 1,79   | 1,744  | 1,05          | 1,60   | 1,35   |
| ARESVmedia                 | 3,13          | 2,38   | 2,31   | 1,54          | 2,45   | 2,13   |
| tVertA <sub>BAIXO</sub>    | 527,65        | 425,18 | 433,46 | 558,41        | 514,12 | 495,7  |
| tVertA <sub>MODERADO</sub> | 267,62        | 197,23 | 204,99 | 280,47        | 176,86 | 155,13 |
| tVertA <sub>ALTO</sub>     | 436,41        | 315,96 | 323,07 | 442,18        | 242,55 | 238,42 |
| tDir <sub>BAIXO</sub>      | 818,41        | 680,14 | 718,18 | 879,88        | 832,97 | 780,7  |
| tDir <sub>MODERADO</sub>   | 325,08        | 226,15 | 236,26 | 336,38        | 186,44 | 196    |
| tDir <sub>ALTO</sub>       | 248,55        | 155,16 | 169,93 | 250,52        | 132,4  | 141,54 |
| tAC <sub>BAIXO</sub>       | 497,36        | 379,76 | 421,37 | 526,39        | 465,54 | 452,49 |
| tAC <sub>MODERADO</sub>    | 247,74        | 176,2  | 191,67 | 257,12        | 180,89 | 174,02 |
| tAC <sub>ALTO</sub>        | 397,04        | 306,51 | 282,89 | 400,33        | 253,47 | 251,71 |
| tVertD <sub>BAIXO</sub>    | 651,07        | 482,38 | 548,91 | 689,23        | 572,48 | 522,79 |
| tVertD <sub>MODERADO</sub> | 252           | 185,61 | 181,66 | 260,8         | 140,92 | 129,09 |
| tVertD <sub>ALTO</sub>     | 436,67        | 320,99 | 319,59 | 440,07        | 241,45 | 242,22 |
| tEsq <sub>BAIXO</sub>      | 825,75        | 661,63 | 672,06 | 882,12        | 906,1  | 885,31 |
| tEsq <sub>MODERADO</sub>   | 361,65        | 249,8  | 256,84 | 375,49        | 201,72 | 234,38 |
| tEsq <sub>ALTO</sub>       | 239,98        | 155,52 | 172,81 | 242,41        | 120,93 | 112,72 |
| tDes <sub>BAIXO</sub>      | 647,5         | 495,89 | 553,3  | 690,96        | 581,54 | 536,04 |
| tDes <sub>MODERADO</sub>   | 300,53        | 214,86 | 207,62 | 307,23        | 191,26 | 167,37 |
| tDes <sub>ALTO</sub>       | 366,29        | 284,97 | 259,35 | 365,93        | 252,24 | 266,69 |
| Impactos                   | 136           | 94     | 82     | 131           | 35     | 34     |
| Saltos                     | 26            | 16     | 19     | 25            | 11     | 8      |
| Variáveis Construídas      | Atleta 1 [A1] |        |        | Atleta 2 [A2] |        |        |
|                            | [JG1]         | [JG2]  | [JG3]  | [JG1]         | [JG2]  | [JG3]  |
| EG                         | 8,688         | -0,720 | 0,314  | 4,302         | -7,001 | -0,173 |
| F1                         | 2,395         | -0,603 | -0,513 | 1,254         | -1,424 | -0,385 |
| F2                         | -0,016        | 0,881  | 1,312  | -0,148        | -1,140 | 0,743  |

Na tabela 3.4, os valores médios, intervalos de agrupamento e coeficientes de partição ( $R^2$ ) obtidos nas análises de agrupamento por tempos de jogo são reportados. Na análise por jogos inteiros, o coeficiente de partição foi de 91,5% para os valores dos EG (AG1: -5,716 [-7,00; -4,41]; AG2: -1,221 [-2,54; -0,17]; AG3: 1,266 [0,31; 2,31]; AG4: 5,302 [3,59; 8,99]), 91,5% para o escores F1 (AG1: -1,308 [-1,72; -1,08]; AG2: -0,531 [-0,85; -0,27]; AG3: 0,228 [-0,11; 0,58]; AG4: 1,446 [0,94; 2,40]) e 89,5% para F2 (AG1: -1,266 [-1,51; -1,14]; AG2: -0,638 [-0,90; -0,29]; AG3: 0,111 [-0,20; 0,74]; AG4: 1,405 [0,88; 2,65]), remetendo a uma maior heterogeneidade entre grupos e homogeneidade dentro dos grupos.

#### 4.6. Discussão

Este estudo teve como objetivo sumarizar as informações observadas nas variáveis originais e entender como agrupam-se em fatores para interpretação da demanda física imposta em jogos consecutivos no handebol por meio de sensores inerciais vestíveis, além de avaliar sua magnitude entre jogos e tempos de jogo, a partir das novas variáveis construídas. Os resultados obtidos análises evidenciaram que as componentes e fatores de maior variância explicada (CP1 > 81,44% e F1 > 66,00%) representam indicadores úteis para entender a magnitude das demandas físicas no handebol, reduzindo dimensionalidade enquanto conserva a estrutura de variabilidade do banco de dados. Um conjunto de 2 a 3 combinações lineares e fatores foram necessários para explicar a maior parte da estrutura de variabilidade do banco de dados (> 85% da variância explicada), e, por consequência, a demanda externa imposta nos jogos, a partir de 24 variáveis originais, evidenciando o problema de multicolinearidade. Adicionalmente, este estudo apresenta uma nova abordagem para quantificação das demandas físicas (escores globais) baseada nas componentes retidas por meio de sensores inerciais vestíveis, fundamentada na ponderação dos autovalores das combinações lineares para fornecer um indicador da demanda em treinos e competições. Neste sentido, o presente estudo é o primeiro a lidar com o problema de multicolinearidade no monitoramento no handebol, a partir do uso de sensores inerciais e métodos de redução da dimensionalidade.

No presente estudo, nas combinações lineares de maior variância explicada (CP1) (sem rotação), nenhuma das variáveis originais mostrou valor dos autovetores em módulo superior a 0,5. Logo, valores mais negativos dos escores podem indicar uma maior demanda imposta em cada tempo. As CP2 seguem a mesma tendência anterior, onde escores mais negativos podem remeter à presença de um maior número de impactos (variável de maior peso na CP2), logo esta componente constitui-se em um indicador importante de estresse mecânico, relacionado às ações no handebol que envolvem de saltos verticais nas abordagens por tempo de jogo e jogos completos. Weaving *et al.* (2014) encontraram apenas uma componente a partir de cinco variáveis originais (impulso de treinamento, percepção subjetiva de esforço, distância percorrida em alta velocidade, impactos e a métrica *body load* para intensidade de relativa de exercício) com 68,44% da variância explicada, semelhante aos resultados obtidos nas análises neste capítulo, parte delas obtidas por meio de sensores inerciais, porém todos os autovetores obtidos foram superiores a 0,5. Entretanto, entre os estudos relacionados com a redução da dimensionalidade,

apenas um estudo explorou o uso da ACP (sem rotação ortogonal), que deve ser diferenciada da AFE (com rotação ortogonal), mais empregada nos estudos encontrados (WEAVING *et al.*, 2014; SVILAR *et al.*, 2018; WEAVING *et al.*, 2018; CASAMICHANA *et al.*, 2019; RYAN; KEMPTON; COUTTS, 2020; SHEEHAN *et al.*, 2020; STONE *et al.*, 2022).

Após a realização das AFE por tempos de jogo e jogos inteiros, a maximização das cargas fatoriais mostrou que a maioria das variáveis está fortemente associada com o F1 ( $\hat{l}_{j1} > 0,5$ ; T1 – ARESHmedia, ARESVmedia, saltos, tempo nas zonas de aceleração e desaceleração nos eixos x, y e z; T2 e Jogos Inteiros – ARESHmedia, ARESHmax, ARESVmedia, saltos, tempo nas zonas de aceleração e desaceleração nos eixos x, y e z), atribuído como um indicador geral de intensidade das demandas físicas no handebol. Entretanto, a variável ARESHmax está alocada e associada ao F1 nas análises do segundo tempo e por jogos inteiros, que remete a colisões durante acelerações, desacelerações, mudanças de direção e sprints, diferindo do primeiro tempo de jogo (associada ao fator 3, de menor variância explicada).

Tabela 3.4 – Valores médios, intervalos de agrupamento e coeficientes de partição ( $R^2$ ) para as análises de agrupamento pelo método  $k$  – médias.

| Agrupamentos [AG]  |     |                         |  |                    |     |                         |  |
|--------------------|-----|-------------------------|--|--------------------|-----|-------------------------|--|
| Variáveis          |     | T1 (Média [Intervalo])  |  | Variáveis          |     | T2 (Média [Intervalo])  |  |
| EG<br>$R^2=92,6\%$ | AG1 | 5,314 [4,163; 7,336]    |  | EG<br>$R^2=92,5\%$ | AG1 | 6,000 [4,165; 6,765]    |  |
|                    | AG2 | 0,753 [-1,083; 2,910]   |  |                    | AG2 | 1,648 [0,310; 3,383]    |  |
|                    | AG3 | -3,107 [-4,398; -2,190] |  |                    | AG3 | -1,941 [-3,967; -0,615] |  |
|                    | AG4 | -6,385 [-7,211; -5,782] |  |                    | AG4 | -6,533 [-8,658; -4,854] |  |
| F1<br>$R^2=89,4\%$ | AG1 | -1,017 [-1,667; -0,476] |  | F1<br>$R^2=91,9\%$ | AG1 | -1,012 [-1,804; -0,623] |  |
|                    | AG2 | 0,219 [-0,353; 0,659]   |  |                    | AG2 | -0,137 [-0,310; 0,140]  |  |
|                    | AG3 | 1,250 [1,014; 1,440]    |  |                    | AG3 | 0,826 [0,418; 1,418]    |  |
|                    | AG4 | 1,687 [1,512; 1,961]    |  |                    | AG4 | 2,400 [2,303; 2,497]    |  |
| F2<br>$R^2=90,2\%$ | AG1 | -1,125 [-1,318; -0,926] |  | F2<br>$R^2=89,6\%$ | AG1 | -0,866 [-1,914; -0,536] |  |
|                    | AG2 | -0,531 [-0,808; -0,277] |  |                    | AG2 | 0,149 [-0,333; 0,517]   |  |
|                    | AG3 | 0,408 [-0,036; 0,905]   |  |                    | AG3 | 1,123 [-0,933; 1,574]   |  |
|                    | AG4 | 1,631 [1,264; 2,983]    |  |                    | AG4 | 2,465 [2,094; 2,837]    |  |
| F3<br>$R^2=90,0\%$ | AG1 | -1,206 [-1,804; -0,758] |  |                    |     |                         |  |
|                    | AG2 | -0,215 [-0,648; 0,060]  |  |                    |     |                         |  |
|                    | AG3 | 0,375 [0,117; 0,967]    |  |                    |     |                         |  |
|                    | AG4 | 1,785 [1,249; 2,637]    |  |                    |     |                         |  |

Todavia, os demais fatores com menor variância estão associados a variáveis que aludem a atividades de jogo realizadas com saltos (lançamentos, passes, ações de bloqueios), desacelerações e colisões durante situações ofensivas ou defensivas em geral, (F2: T1 - ARESVmax, ARESVmedia, tVertAALTO, tDesALTO, saltos, impactos; F3: T1 – ARESHmax; F2: T2 – ARESVmax, Impactos e saltos; Jogos Inteiros:

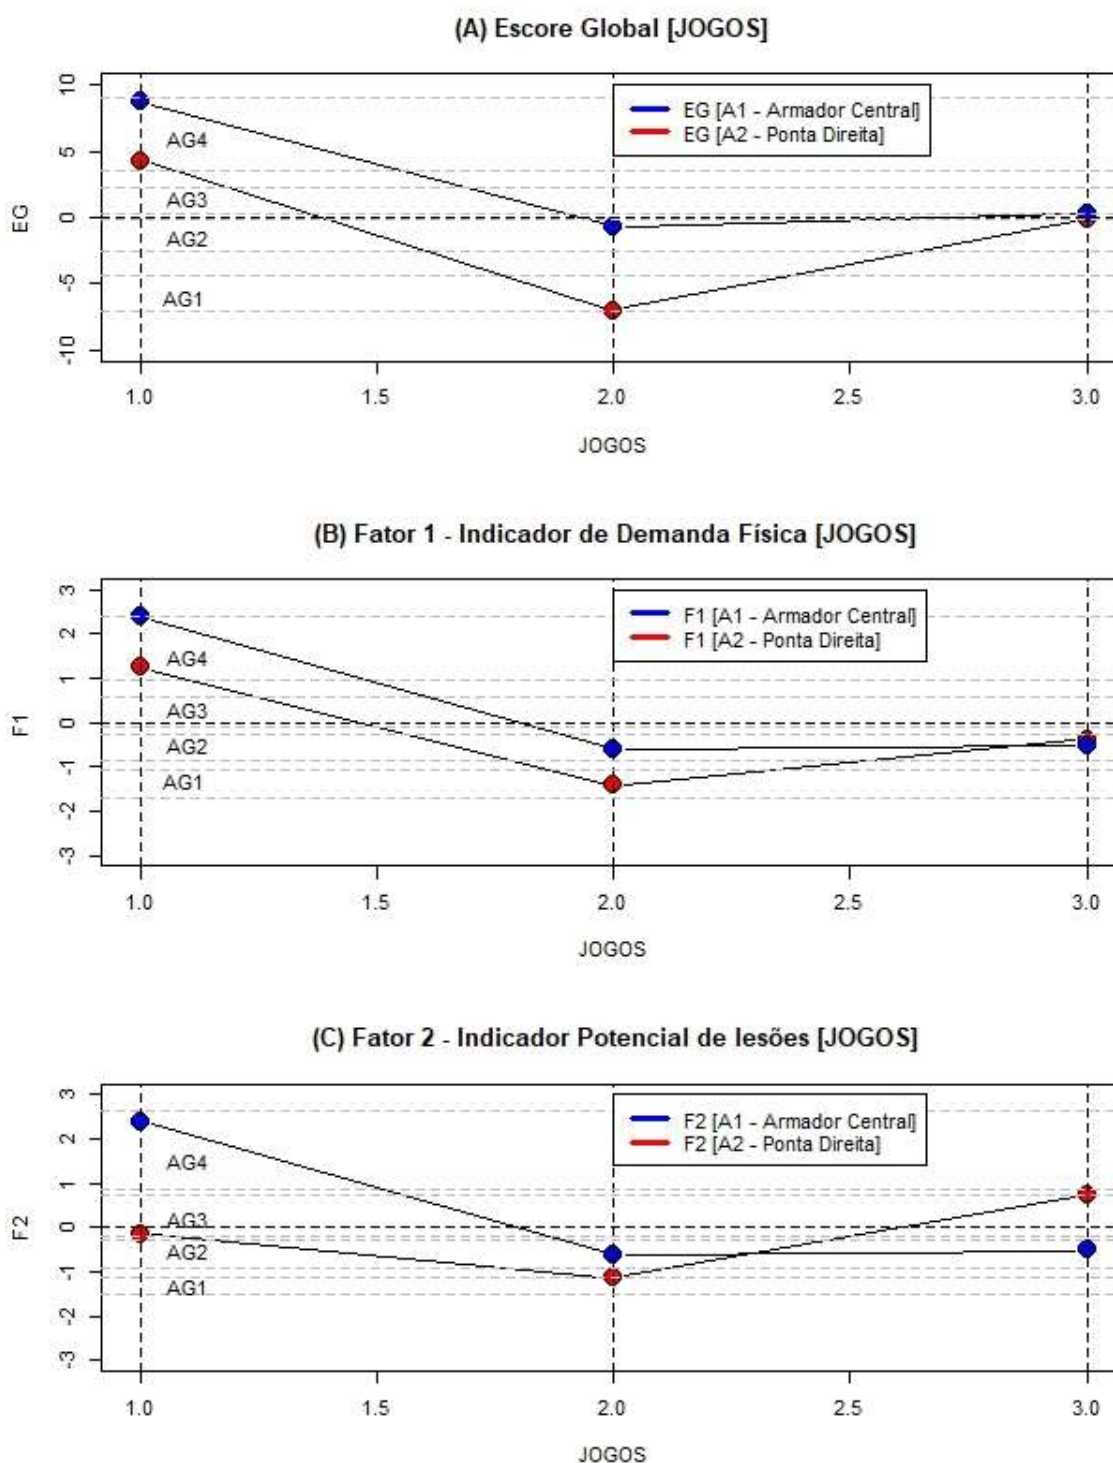
ARESHmax, ARESVmedia, ARESVmax, tVertA<sub>ALTO</sub>, saltos, impactos). De forma simplificada, as desacelerações podem ser conceituadas como a capacidade do atleta em reduzir a velocidade, capacidade fundamental para mudanças de direção, e, considerando que os atletas são submetidos a uma quantidade substancial e repetida de cargas excêntricas que podem levar ao dano muscular (SWEETING *et al.*, 2017). Logo, o fator retido foi denominado, arbitrariamente, como um indicador potencial de lesões musculares.

Wik; Luteberget; Spencer (2017); Luteberget; Spencer (2017) e Luteberget; Trollerud; Spencer (2017), conforme destacado, quantificaram as variáveis PL/minuto, HIE/minuto, acelerações, desacelerações e mudanças de direção, em detrimento das variáveis determinadas no presente estudo. Porém, não obstante o problema de multicolinearidade entre as variáveis, conforme já evidenciado anteriormente, a variável PL apresenta problemas conceituais e metodológicos para avaliação intra interindividual da magnitude das demandas físicas (BREDT *et al.*, 2020; GOMEZ-CARMONA *et al.*, 2020).

Logo, a utilização da variável PL para classificação do desempenho individual em partidas por meio da análise de agrupamento *k*-médias, para diferentes critérios de posição de jogo, período de jogo e tempo jogado (YOUNG *et al.*, 2016; REINA *et al.*, 2020), apresenta dificuldades para interpretação dos resultados. Não obstante, pelos mesmos motivos, os estudos de Weaving *et al.* (2017), Weaving *et al.* (2018), Weaving *et al.* (2019) e Weaving *et al.* (2020) que conduziram procedimentos de redução da dimensionalidade incorporando a variável PL, devem ser interpretados com a mesma cautela a respeito das demandas físicas relacionadas a treinos e jogos.

Por outro lado, em uma perspectiva prática para os escores da ACP e AFE, as variáveis originais podem ser multiplicadas pelas ponderações obtidas nas novas variáveis construídas ( $CP_k$  e  $F_m$ ) e somadas para produzir escores úteis a prática. A vantagem dessa abordagem reside em proporcionar uma única medida arbitrária que representa o constructo de monitoramento, considerando a contribuição das variáveis incluídas nas análises (WEAVING *et al.*, 2017; RYAN; KEMPTON; COUTTS, 2020). Os valores individuais obtidos podem ser utilizados com a finalidade de avaliação intra e interindividual da demanda física de atletas e de jogos (RYAN; KEMPTON; COUTTS, 2020; WEAVING; READ, 2022).

Figura 4.8 – Escores Globais e escores dos fatores (F1 e F2) para cada jogo e respectivo agrupamento.



Fonte: Dados da pesquisa.

Agrupamentos: AG1 – demanda baixa; AG2 – demanda moderada; AG3 – demanda alta; AG4 – demanda muita alta (limites com linhas tracejadas e destacadas em cinza).

Com a mesma finalidade, os EG foram calculados por um procedimento semelhante, por meio da soma dos escores das novas variáveis ponderadas pela relação entre a

variância explicada de cada componente (sem rotação das combinações lineares) e o somatório das  $CP_k$ , para obter um indicador único de demanda física. Logo, conforme mostrado nas figuras 4.5 a 4.7, uma forte associação positiva do EG foi verificada para com a CP1 e negativa para com F1, compartilhando covariância entre si. Em adição, as componentes (CP1 vs. CP2) e fatores (F1 vs. F2) de maior variância explicada mostraram não estão correlacionadas, em conformidade com a literatura existente (WEAVING *et al.*, 2014; SVILLAR *et al.*, 2018; WEAVING *et al.*, 2019; STONE *et al.*, 2022). Em síntese, estes resultados descrevem que ambas as novas variáveis podem ser utilizadas para compreender as demandas da competição, porém o EG leva em consideração as demais componentes retidas e uma maior variabilidade dos dados. Para exemplificar a aplicação dos escores por meio da classificação do desempenho pelo método  $k$ -médias para avaliação intra e interindividual (tabela 3.4), a tabela 3.3 reporta os resultados individuais, conforme os jogos para as variáveis originais e construídas para os atletas A1 (armador central – tempo em quadra: JG1 – Tempo 1 – 1369s, Tempo 2 – 1565s, Total – 2934s; JG2 – Tempo 1 – 1150s, Tempo 2 – 1486s, Total – 2636s; JG3 – Tempo 1 – 1662s, Tempo 2 – 829s, Total – 2491s) e A2 (ponta direita – tempo em quadra: JG1 – Tempo 1 – 681s, Tempo 2 – 1173s, Total – 1854s; JG2 – Tempo 1 – 1684s, Tempo 2 – 1800s, Total – 3484s; JG3 – Tempo 1 – 1318s, Tempo 2 – 1610s, Total – 2928s).

Em ambos os escores EG e F1, as demandas físicas foram numericamente maiores no JG1 em relação ao JG2 para ambos os atletas (redução da muita alta – AG4; para de moderada – AG3 a baixa – AG1), porém, entre o segundo e o terceiro jogo, uma elevação foi verificada para A1 e A2 (demanda moderada – AG3 a alta – AG3), conforme evidenciado na tabela 3.3 e a figura 4.8. Por outro lado, para F2 verifica-se um aumento dos escores após o primeiro jogo para A1 (aumento da demanda de alta – AG3, para muita alta – AG4) e uma redução para A2 (redução da demanda de alta – AG3, para baixa – AG1), sinalizando uma queda do estresse mecânico nas atividades que envolvem saltos, desacelerações e colisões no JG2. Porém, houve um aumento dos escores para A1 e A2 no JG3, destacando uma demanda muito alta (A1) a alta (A2), no último certame. A figura 4.8 ilustra a evolução dos escores globais e dos fatores (F1 e F2) ao longo dos jogos obtidos pelos atletas, bem como os limites dos respectivos agrupamentos (linha tracejadas em cinza).

Entretanto, além dos escores obtidos de forma combinada serem menos interpretáveis, esta abordagem para o monitoramento de treinos e competições possui

a limitação de diluir a variância para cada componente (RYAN; KEMPTON; COUTTS, 2020). Além disso, para utilização da abordagem estatística de redução da dimensionalidade, a partir dos escores das componentes, fatores ou escores globais, há a necessidade de realização de estudos de validação da metodologia em experimentos práticos na condução de treinos e competições, evidenciando ou não sua efetividade.

Por outro lado, por dificuldades de ordem instrumental devido a impossibilidade de utilização de sensores por conexão *wifi* no local de coletas ou de sincronização entre câmeras e os dispositivos, a determinação do início e o final exato dos tempos de jogo foram prejudicadas. Além disso, deve ser destacado que não foi possível adicionar uma tarefa específica de movimento (ex.: salto vertical) durante a rotina da competição para sincronização, logo o procedimento de realização das coletas durante o torneio foi restrito à colocação dos sensores durante o decurso da preparação de jogo da equipe. Independentemente desses problemas, há a necessidade de uma melhor exploração dos dados, no sentido de quantificar outras variáveis representativas do desempenho por meio da integração de sensores (acelerômetro, giroscópio e magnetômetro) e de emprego de técnicas de aprendizado de máquina para classificação automática de ações nos esportes coletivos.

#### **4.7. Conclusões**

A utilização das técnicas de ACP e AFE para sumarização das informações contidas nas variáveis originais com o uso de sensores inerciais vestíveis, evidenciou de 2 a 3 componentes e fatores retidos, com variância explicada acumulada maior que 85%. Logo, a variável ARESHmax alocou-se no fator de maior variância explicada no segundo tempo, variável que diferencia os tempos de jogo. As componentes ou fatores de maior variância explicada representam em geral indicadores úteis para monitorar e entender a magnitude das demandas físicas no handebol (ARESHmedia, ARESVmedia, número de saltos, tempo nas zonas de aceleração e desaceleração nos eixos x, y e z; CP1 e F1 > 65% da variância explicada), enquanto conserva a maior parte da estrutura de variabilidade do banco de dados. As componentes e fatores de menor variância explicada representam indicadores relacionados ao potencial de lesões, com maior peso para a variável de número de impactos. Adicionalmente, para além da avaliação intra e interindividual dos escores das componentes e fatores retidos, uma nova abordagem de quantificação das demandas

impostas baseada nos escores das componentes retidas, fundamentada na ponderação dos autovalores das combinações lineares, para fornecer um indicador da demanda física, mostrado e exemplificado através dos escores globais.

## CAPÍTULO 5 – CONSIDERAÇÕES FINAIS

A utilização de unidades de medida inercial de baixo custo para análises biomecânicas evidenciou validade (concordância entre instrumentos) e confiabilidade teste - reteste quando comparadas às medidas de referência adotadas para estimativa do tempo de voo, altura de salto e impulso nas análises de saltos verticais padronizados, bem como para a estimativa da velocidade máxima e média de *sprints*, em acordo com as hipóteses estabelecidas. Logo, os sensores testados apresentam-se como ferramentas viáveis economicamente, portáteis, permitindo uma rápida avaliação de muitos indivíduos para monitoramento do desempenho (entre sessões) de saltos verticais e *sprints*. Em face aos resultados encontrados, é imperativa a necessidade de aprimoramento da avaliação da validade de estimativas de variáveis discretas e funcionais para diferentes UMI disponíveis tendo como foco primário a comparação (quando possível) a sistemas de análise cinemática tridimensional para utilização em tarefas de saltos verticais padronizados (salto agachado, salto com contramovimento, salto em profundidade, saltos horizontais) e *sprints* na determinação de parâmetros cinemáticos (velocidade e deslocamento) e cinéticos (potência e forças de reação do solo), especialmente por partes dos fabricantes, com adoção do algoritmo “zero velocity updates” (ZUPT).

O uso do algoritmo ZUPT tem como finalidade de correção do erro acumulado durante a realização do procedimento integração numérica ponto – a – ponto. Nessa mesma linha, dispositivos inovadores desenvolvidos a partir de UMI, conforme evidenciado por Waldron *et al.* (2021), necessitam de novos estudos de validação que podem se traduzir em ferramentas viáveis e portáteis para os esportes coletivos, em contraponto à sistema de câmeras, GPS e LPS. Logo, para além disso, treinadores na modalidade de atletismo de provas específicas como salto em distância, salto triplo e provas de velocidade (100m e 200m rasos, 400m rasos) podem se beneficiar de um diagnóstico do desempenho durante a realização de competições, bem como o estudo da assimetria do desempenho das tarefas executadas em competições.

A respeito do reconhecimento de ações no contexto dos esportes coletivos por UMI, os classificadores treinados e testados evidenciaram desempenho satisfatório de acurácia geral de classificação de ações, com menor sensibilidade de identificação de eventos para a corrida moderada e MMD (acelerômetros isolados). No entanto, a combinação de sensores (acelerômetros e giroscópios) e agregação de

características extraídas (estatísticas descritivas, aceleração resultante e medidas de análise de séries temporais) apresentou melhor acurácia de classificação para o algoritmo k-NN (>90%) comparado ao emprego isolado de acelerômetros para todas as ações de permanecer estático, situações de marcha, corrida em intensidade leve, corrida em intensidade moderada, *sprints* com desaceleração, saltos padronizados e mudanças de direção (treinamento & teste).

Adicionalmente, a linha de investigação referente ao reconhecimento de atividades humanas (*Human Activity Recognition*), dentro do contexto das ciências do esporte, há muito que ser desenvolvido e aprimorado. Um desafio latente no processo de classificação de ações remete a inclusão de transições no protocolo estudado, sem a realização de pausas estacionárias. Em hipótese, essa modificação no protocolo poderia impactar negativamente sobre a acurácia, sensibilidade e especificidade de classificação para as ações ou categorias alvo. Estudos futuros devem abordar esse problema para analisar o processo de classificação em circuitos simulados de ações, bem como situações que se aproximem do ambiente real de treinos e competições, tal como a adoção de circuitos de tarefas analíticas e jogos reduzidos, como um *continuum* de incremento de validade ecológica para o reconhecimento de ações nos esportes coletivos por métodos de aprendizado máquina.

No contexto do monitoramento de jogos e treinamentos nos esportes coletivos de invasão, em especial no handebol, a utilização de UMI associada a métodos de redução da dimensionalidade para sumarização das variáveis originais e subsequente interpretação das demandas físicas por meio escores das componentes e fatores de maior variância explicada, pode ser aprimorada pelo emprego de técnicas de análise de agrupamento. Nessa perspectiva, enquanto conserva-se a estrutura de variabilidade dos dados, o desempenho individual pode ser classificado por meio de indicadores adimensionais para monitoramento das atividades prescritas (CP1 e F1 > 65% da variância explicada), permitindo a avaliação intra e interindividual da magnitude das demandas impostas no handebol. O emprego de ACP e AFE revelou um conjunto de 2 a 3 combinações lineares e fatores foram retidos para explicar a magnitude da demanda observada (variância explicada acumulada > 85%), a partir de 24 variáveis originais quantificadas. Em complemento, a ARESHmax (valor máximo do vetor de aceleração resultante horizontal) constitui-se na variável diferenciação entre tempos de jogo. Na mesma direção, para fornecer um indicador uma perspectiva geral da demanda física em treinos e competições no handebol, uma nova abordagem

de quantificação baseada na ponderação dos autovalores das combinações lineares retidas foi apresentada e exemplificada através dos escores globais.

Nesse sentido, novos experimentos longitudinais são necessários para atestar a capacidade das métricas utilizadas para melhorar o desempenho físico – esportivo e prevenção de lesões com o uso de UMI, bem como a melhora da comunicação entre os membros da comissão técnica. Por outro lado, as novas variáveis de menor variância explicada (componentes e fatores) sinalizam para indicadores relacionados ao potencial para ocorrência lesões, com maior peso para a variável de número de impactos.

## REFERÊNCIAS

- AAGAARD, P.; SIMONSEN, E.B.; ANDERSEN, J.L.; MAGNUSEN, P.; DYHRE-POULSEN, P. Increased rate of force development and neural drive of human skeletal muscle following resistance training. **Journal of Applied Physiology**, v.93, n.4, p.1318-1326, 2002.
- ADESIDA, Y.; PAPI, E.; MCGREGOR, A.H. Exploring the role of wearable technology in sport kinematics and kinetics: a systematic review. **Sensors**, v.19, n.7, p.1-27, 2019.
- AHMADI, A.; MITCHELL, E.; RICHTER, C.; DESTELLE, F.; GOWING, M.; O'CONNOR, N.E.; MORAN, K. Towards automatic activity classification and movement assessment during a sports training session. **IEEE Internet of Things Journal**, v.2, n.1, p. 23 – 32, 2015.
- AKINS, J.S.; HEEBNER, N.R.; LOVALEKAR, M.; SELL, T.C. Reliability, and validity of instrumented soccer equipment. **Journal of Applied Biomechanics**, v.31, n.3, p.195-201, 2015.
- APTE, S.; MEYER, F.; GREMEAUX, V.; DADASHI, F.; AMINIAN, K. A sensor fusion approach to the estimation of instantaneous velocity using single wearable sensor during sprint. **Frontiers in Bioengineering and Biotechnology**, v.8, p.1-11, 2020.
- BALLOCH, A.S.; MEGHJI, M.; NEWTON, R.U.; HART, N.H.; WEBER, J.A.; AHMAD, I.; HABIBI, D. Assessment of a novel algorithm to determine change-of-direction angles while running using inertial sensors. **Journal of Strength and Conditioning Research**, v.34, n.1, p.134-144, 2019.
- BALSALOBRE, F.C.; KUZDUB, M.; POVEDA-ORTIZ, P.; CAMPO – VECINO, J.D. Validity and Reliability of the PUSH Wearable Device to Measure Movement Velocity During the Back-Squat Exercise. **Journal of Strength and Conditioning Research**, v.30, n.7, p.1968-1974, 2016
- BERGAMINI, E.; GUILLON, P.; CAMOMILLA, V.; PILLET, H.; SKALLI, W.; CAPPOZZO, A. Trunk inclination estimate during the sprint start using an inertial measurement unit: a validation study. **Journal of Applied Biomechanics**, v.29, n.5, p.622-627, 2013.
- BLAIR, S.; DUTHIE, G.; ROBERTSON, S.; HOPKINS, W.; BALL, K. Concurrent validation of an inertial measurement system to quantify kicking biomechanics in four football codes. **Journal of Biomechanics**, v.73, p.24-32, 2018.
- BLAND, J.M.; ALTMAN, D.G. Measuring agreement in method comparison studies. **Statistical Methods in Medical Research**, v.8, n.2, p.135-160, 1999.
- BLANK, P.; HOßBACH, J.; SCHULDHAUS, D.; ESKOFIER, B. Sensor-based Stroke Detection and Stroke Type Classification in Table Tennis. In: ISWC '15: ACM International Symposium on Wearable Computers, 2015, Osaka, Japão. **Anais...** Osaka: ACM, 2015. p.93-100.

BRETT, S.G.T.; CHAGAS, M.H.; PEIXOTO, G.H.; MENZEL, H.J.K.; ANDRADE, A.G.P. Understanding player load: meanings and limitations. **Journal of Human Kinetics**, v.71, p.5-9, 2020.

BROWN, N.; BICHLER, S.; ALT, W. Detecting repetitions and time features in resistance training using triaxial accelerometry. **Sports Technology**, v.8, n.1, 2015.

BROOKE, S.M.; AN, H.S.; KANG, S.K.; NOBLE, J.M.; BERG, K.E.; LEE, J.M. Concurrent validity of wearable activity trackers under free-living conditions. **Journal of Strength and Conditioning Research**, v.31, n.4, p.1097-1106, 2016.

BUCHHEIT, M.; SIMPSON, B.M. Player-tracking technology: half-full or half-empty glass. **International Journal of Sports Physiology and Performance**, v.12, s.2, p.35-41, 2017.

BURLAND, J.P.; OUTERLEYS, J.B.; LATTERMANN, C.; DAVIS, I.S. Reliability of wearable sensors to assess impact metrics during sport – specific tasks. **Journal of Sports Sciences**, v.39, n.4, p. 406-411, 2020.

BYRNE, P.J.; MOODY, J.A.; COOPER, S.M.; CALLANAN, D.; KINSELLA, S. Potentiating response to drop jump protocols on sprint acceleration: drop jump volume and intra-repetition recovery duration. **Journal of Strength and Conditioning Research**, v.34, n.3, p.717-727, 2020.

CARDINALE, M.; VARLEY, M.C. Wearable training-monitoring technology: applications, challenges, and opportunities. **International Journal of Sports Physiology and Performance**, v.12, s.2, p.55-62, 2017.

CAMOMILLA, V.; BERGAMINI, E.; FANTOZZI, S.; VANOZZI, G. Trends supporting the in-field use of wearable inertial sensors for sports performance evaluation: a systematic review. **Sensors**, v.18, n.3, p.1-50, 2018.

CASAMICHANA, D.; CASTELLANO, J.; DIAZ, A.G.; MARTIN-GARCIA, A. Looking for complementary intensity variables in different training games in football. **Journal of Strength and Conditioning Research**, p.1-8, 2019.

CHAMBERS, R.; GABETT, T.J.; COLE, M.H.; BEARD, A. The use of wearable microsensors to quantify sport-specific movements. **Sports Medicine**, v.45, n.7, p.1065-1081, 2015.

CHAPRA, S.C. Métodos numéricos aplicados com Matlab® para engenheiros e cientistas. Mcgraw-Hill: New York. 655p.

CORMIE, P.; MCBRIDE, J.M.; MCCAULLEY, G.O. Power – time, force – time, and velocity – time curve analysis of the countermovement jump: impact of training. **Journal of Strength and Conditioning Research**, v.23, n.1, p.177-186, 2009.

COYTE, J.L.; SULRING, D.; ROS, M.; DU, H.; GRAY, A. Displacement profile estimation using low-cost inertial motion sensors with applications in sporting and rehabilitation exercises. In: IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM), 2013, Wollongong, Australia. **Anais...** Wollongong: IEEE/ASME, 2013. p.1290-1295.

CORVINO, M.; TESSITORE, A.; MINGANTI, C.; ŠIBILA, M. Effect of court dimensions on players' external and internal load during small-sided handball games. **Journal of Sports Science and Medicine**, v.13, n.2, p.297–303, 2014.

CORVINO, M.; VULETA, D.; ŠIBILA, M. Analysis of load and players' effort in 4vs4 small-sided handball games in relation to court dimensions. **Kinesiology**, v.48, n.2, p.213–222, 2016.

CURREL, K.; JEUKENDRUPP, A.E. Validity, reliability and sensitivity of measures of sporting performance. **Sports Medicine**, v.38, n.4, p.297-316, 2008.

CUST, E.C.; SWEETING, A.J.; BALL, K.; ROBERTSON, S. Machine and deep learning for sport-specific movement recognition: a systematic review of model development and performance. **Journal of Sports Sciences**, v.37, n.5, p.568-600, 2019.

DADASHI, F.; CRETENAND, F.; MILLET, G.P.; AMINIAN K. Front-crawl instantaneous velocity estimation using a wearable inertial measurement unit. **Sensors**, v.12, n.10, p.12927-12939, 2012.

EAGLES, A. N.; SAYERS, M. G. L.; BOUSSON, M.; LOVELL, D. I. Correction to: Current Methodologies and Implications of Phase Identification of the Vertical Jump: A Systematic Review and Meta-analysis. **Sports Medicine**, v.48, n.2, p.497–497, 2015.

EGGERT, B.; MUNDT, M.; MARKERT, B. Imu-based activity recognition of the basketball jump shot. In: 38<sup>th</sup> International Society of Biomechanics in Sport Conference, 2020, Liverpool, Reino Unido. **Anais...** Liverpool: ISBS, 2020. p.952-955.

EVERITT, B.; HOTHORN, T. **An Introduction to Applied Multivariate Analysis with R**. Springer: New York. 289p. 2011.

FALCH, H.N.; RAEDERGARD, H.G.; TILAAAR, R.V.D. Effect of diferente physical training forms on change of direction ability: a systematic review and meta-analysis. **Sports Medicine**, v.5, n.53, 2019.

FESSI, M.S.; FARHAT, F.; DELLAL, A.; MALONE, J.J.; MOALLA, W. Straight-line and change of direction intermitente running in professional soccer players. **International Journal of Sports Physiology and Performance**, v.13, n.5, p.562-567, 2018.

FIGLIOLA, R.S.; BEASLEY, D.E. **Teoria e projeto para medições mecânicas**. São Paulo: LTC. 492p. 2007.

FOX, J.L.; SCANLAN, A.T.; STANTON, R. A review of player monitoring approaches in basketball: current trends and future directions. **Journal of Strength and Conditioning Research**, v.31, n.7, p. 2021–2029, 2017.

FULTON, S.K.; PYNE, D.B.; BURKETT, B. Validity and reliability of kick count and rate in freestyle using inertial sensor technology. **Journal of Sports Sciences**, v.37, n.10, p.1051-1058, 2009.

FU, F.; XIANG, W.; AN, Y.; & LIU, B.; CHEN, X.; ZHU, S. *et al.* Comparison of Machine Learning Algorithms for the Quality Assessment of Wearable ECG Signals Via Lenovo H3 Devices. *Journal of Medical and Biological Engineering*, v.41, p.231–240, 2021.

GAGELER, W.H.; WEARING, S.; JAMES, D.A. Automatic jump detection method for athlete monitoring and performance in volleyball. **International Journal of Performance Analysis in Sport**, v.15, n.1, p.284-296, 2015

GILES, B.; KOVALCHIK, S.; REID, M. A. A machine learning approach for automatic detection and classification of changes of direction from player tracking data in professional tennis. **Journal of Sports Sciences**, v.37, n.25, p.1-8, 2019.

GOROSTIAGA, E.M.; IZQUIERDO, M.; ITURRALDE, P.; RUESTA, M.; IBÁÑEZ, J. Effects of heavy resistance training on maximal and explosive force production, endurance and serum hormones in adolescent handball players. **European Journal of Applied Physiology and Occupational Physiology**, v.80, n.5, p.485-493, 1999.

GÓMEZ-CARMONA, C.D.; BASTIDA-CASTILLO, A.; IBÁÑEZ, S.J.; PINO-ORTEGA, J. Accelerometry as a method for external workload monitoring in invasion team sports: a systematic review. **PLOS ONE**, v.15, n.8, p.1-25, 2020.

GURCHIEK, R.D.; DON, R.H.S.A.; WATAGODA, L.C.R.P.; MCGINNIS, R.S.; WERKHOVEN, H.V.; NEEDLE, A.R.; MCBRIDE, J.M.; ARNHOLDT, A.T. Sprint assessment using machine learning and a wearable accelerometer. **Journal of Applied Biomechanics**, v.35, n.2, p.164-169, 2019.

GURCHIEK, R.D.; MCGINNIS, R.S.; NEEDLE, A.R.; MCBRIDE, J.M.; WERKHOVEN, H.V. An adaptive filtering algorithm to estimate sprint velocity using a single inertial sensor. **Sports Engineering**, v.21, n.2, p.389-399, 2018.

HADER, K.; RUMPF, M.C.; HERTZOG, M.; KILDUFF, L.P.; GIRARD, O.; SILVA, J.R. Monitoring the athlete match response: can external load variables predict post – match acute and residual fatigue in soccer? A systematic review with meta-analysis. **Sports Medicine**, v.5, n.1, 2019.

HALADJIAN, J.; SCHLABBERS, D.; TAHERI, S.; THARR, M.; BRUEGGE, B. Sensor-based detection and classification of soccer goalkeeper training exercises. **ACM Transactions on Internet of Things**, v.1, n.2, p.1-20, 2020.

HALILAJ, E.; RAJAGOPAL, A.; FITERAU, M.; HICKS, J.L.; HASTIE, T.; DELP, S.L. Machine learning in human movement biomechanics: best practices, common pitfalls, and new opportunities. **Journal of Biomechanics**, v.16, n. 81, p.1-11, 2018.

HALSON, S.L. Monitoring training load to understand fatigue in athletes. **Sports Medicine**, v.44, s.2, p.1-11, 2014.

HARPER, D.J.; CARLING, C.; KIELY, J. High-intensity acceleration and deceleration demands in elite team sports competitive match play: a systematic review and meta-analysis of observational studies. **Sports Medicine**, v.49, n.12, p.1923-1947, 2019.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The elements of statistical learning: data mining, inference, and prediction**. New York: Springer, 2017. 745p.

HYNDMAN, R.; KANG, Y.; MANSO, P.M.; TALAGALA, T.; WANG, E.; YANG, Y.; WILD, M.O. tsfeatures: Time Series Feature Extraction. R package version 1.0.2. <https://CRAN.R-project.org/package=tsfeatures>. 2020.

HOJKA, V.; ŠŤASTNÝ, P.; TUFANO, J.J.; OMCIRK, D.; JANIKOV, M.T.; KOMARC, M.; JEBAVÝ, R. Does a linear position transducer placed on a stick and belt provide sufficient validity and reliability of countermovement jump performance outcomes? **Biology of Sport**, v.39, n.2, p.341-348.

HOPKINS, W.G. Measures of reliability in sports medicine and science. **Sports Medicine**, v.30, n.1, p.1-15, 2000.

HOLZEMANN, A.; LAERHOVEN, K.V. Using wrist-worn activity recognition for basketball game analysis. In: 5<sup>th</sup> International Workshop on Sensor-Based Activity Recognition and Interaction, 2018, Berlin, Germany. **Anais...** Berlin: ACM, 2018. p.1-6.

HOOREN, B.V.; ZOLOTARJOVA, J. The Difference Between Countermovement and Squat Jump Performances: A Review of Underlying Mechanisms With Practical Applications **Journal of Strength and Conditioning Research**, v.31, n.7, p. 2011–202, 2017.

JAITNER, T.; SCHMIDT, M.; NOLTE, K.; RHEINLANDER, C.; WILLE, S.; WEHN, N. Vertical jump diagnosis for multiple athletes using a wearable inertial sensor unit. **Sports Technology**, v.8, n.1, p.51-57, 2016.

JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An introduction to statistical learning with applications in R**. New York: Springer, 2013. 426p.

JOHNSTON, R.J.; WATSFORD, M.L.; KELLY, S.J.; PINE, M.J.; SPURRS, R.W. Validity and interunit reliability of 10 Hz and 15 Hz GPS units for assessing athlete movement demands. **Journal of Strength and Conditioning Research**, v.28, n.6, p.1649-1655, 2014.

JOWITT HK, DURUSSEL J, BRANDON R, KING M. Auto detecting deliveries in elite cricket fast bowlers using microsensors and machine learning. **Journal of Sports Sciences**, v,38, n.7, p.767-772. 2020

KAUTZ, T.; GROH, B.H.; HANNINK, J.; JENSEN, U.; STRUBBERG, H.; ESKOFIER, B.M. Activity recognition in beach volleyball using a Deep Convolutional Neural Network: leveraging the potential of deep learning in sports. **Data Mining and Knowledge Discovery**, v.31, n.6, p.1678–1705, 2017.

KELLY, D.; COUGHLAN, G.F.; GREEN, B.S.; CAULFIELD, B. Automatic detection of collisions in elite level rugby union using a wearable sensing device. **Sports Engineering**, v.15, n.1, p.81-92, 2012.

KUHLMAN, N.; MIN, C.H. Analysis and Classification of Basketball Shooting Form Using Wearable Sensor Systems. In: IEEE 11th Annual Computing and Communication Workshop and Conference (CCWC), 2021, NV, EUA. **Anais... IEEE**, 2021, p.1478-1482.

LAKE, J.; AUGUSTUS, S.; AUSTIN, K.; COMFORT, P.; MCMAHON, MUNDY, J.P.; HAFF, G.G. The reliability and validity of the bar-mounted PUSH Band TM 2.0 during bench press with moderate and heavy loads. **Journal of Sports Sciences**, v.37, n.23, p.2685-2690, 2019.

LEWIS, A.R.; PHILIPS, E.J.; ROBERTSON, W.S.P; GRIMSHAW, P.N.; PORTUS, M.; WINTER, J. A practical assessment of wheelchair Racing performance kinetics using accelerometers. **Sports Biomechanics**, v.29, n.1, p.1-14, 2019.

LINTHORNE, N. Analysis of standing vertical jumps using a force platform. **American Journal of Physics**, v.69, n.11, p.1198-1204, 2001.

LU, C.; UCHIYAMA, H.; THOMAS, D.; SHIMADA, A. Indoor positioning system based on chest - mounted IMU. **Sensors**, v.19, n.2, p.1-20, 2019.

LUTEBERGET, L.S.; SPENCER, M. High – intensity events in international women’s team handball matches. **International Journal of Sports Physiology and Performance**, v.12, n.1, p.56-61, 2017.

LUTEBERGET, L.S.; TROLLERUD, H.P.; SPENCER, M. Physical demands of game – based training drills in women’s team handball. **Journal of Sports Sciences**, v.36, n.5, p.592-598, 2017.

MA, M.; SONG, Q.; GU, Y.; LI, Y.; ZHOU, Z. An adaptive zero velocity detection algorithm based on multi-sensor fusion for a pedestrian navigation system. **Sensors**, v.18, n.10, p.1-16, 2018.

MA, R.; PENG, H.; YANG, T.; SHA, X.; ZHAO, Y.; LIU, L. Basketball movements recognition using a wrist wearable inertial measurement unit. In: IEEE International Conference on micro/nano sensors for AI, healthcare and robotics, 2018, Shenzhen, China. **Anais ...Shenzen: IEEE**, 2018. p.73-76.

MACDONALD, K.; BAHR, R.; BALTICH, J.; WHITTAKER, J.L. Validation of an inertial measurement unit for the measurement of jump count and height. **Physical Therapy in Sport**, v.25, n.1, p.15-19, 2017.

MALONE, J.J.; LOVELL, R.; VARLEY, M.C.; COUTTS, A.J. Unpacking the black box: applications and considerations for using GPS devices in sport. **International Journal of Sports Physiology and Performance**, v.12, n.2, p.18-26, 2017.

MALONE, J.J.; BARRETT, S.; BARNES, C.; TWIST, C.; DUST, B. To infinity and beyond: the use of GPS devices within the football codes. **Science and Medicine in Football**, v.4, n.1, p.82-84, 2020.

MANCHADO, C.; MARTINEZ, J.T.; PUEO, B.; TORMO, J.M.C.; VILA, H.; FERRAGUT, C.; et al. High-performance handball player's time motion analysis by playing positions. **International Journal of Environmental Research and Public Health**, v.17, n.18, p.1-15, 2020

MASON, B.S.; RHODES, J.M.; GOOSEY-TOLFREY; V.L. Validity and Reliability of an Inertial Sensor for Wheelchair Court Sports Performance. **Journal of Applied Biomechanics**, v.30, n.2, p.326-331, 2014.

MCGRATH, J.; NEVILLE, J.; STEWART, T.; CRONIN, J. Upper body activity classification using an inertial measurement unit in court and field-based sports: systematic. **Journal of Sports Engineering and Technology**, v.235, n.2, p.1-13, 2020.

MCMAHON, J.J.; SUCHOMEL, T.J.; LAKE, J. P.; COMFORT, P. Understanding the Key Phases of the Countermovement Jump Force-Time Curve. **Strength and Conditioning Journal**, v.40, n.4, p 96-106, 2018.

MINGOTTI, S.A. **Análise de dados através de métodos de estatística multivariada. uma abordagem aplicada.** Editora UFMG: Belo Horizonte, 2017, 295p.

MITCHELL E, MONAGHAN D, O'CONNOR NE. Classification of sporting activities using smartphone accelerometers. **Sensors**, v.13, n.4, p.5317-5337, 2013.

MORIN, J.B.; SAMOZINO, P. **Biomechanics of training and testing.** Springer: New York, 2018, 313p.

MORIN, J.B.; SAMOZINO, P. Interpreting power – force – velocity profiles for individualized and specific training. **International Journal of Sports Physiology and Performance**, 2016, v.11, n.2, p.267-272.

MORENCOS, E.; ROMERO-MORALEDA, B.; MARKEL RICO-GONZÁLEZ, M.; ROJAS-VALVERDE, D.; PINO-ORTEGA, J. Principal component analysis identifies different representative match load profiles in international women's field hockey based on playing positions. **Revista Internacional de Ciencias del Deporte**, v.64, n.17, p.112-123, 2021.

MOSQUEDA-HERRERA, A.; MARTINEZ-PEON, D.; GOMEZ-SANCHEZ, L.; RAMIREZ-SOSA, M.I.; DELFIN-PRIETO, S.; BENAVIDES-BRAVO, F.G. Characterization of Kinesthetic Motor Imagery paradigm for wrist and forearm using an algorithm based on the Hurst Exponent and Variogram. In: IEEE International Conference on Systems, Man, and Cybernetics (SMC), 2020, Toronto, Canada. **Anais**...Toronto: IEEE, 2020. p. 3683-3688.

NGUYEN, L.N.N.; MARTIN, D.R.; CATALÀ, A.; LÓPEZ, C.P.; SAMÀ A.; CAVALLARO, A. Basketball activity recognition using wearable inertial measurement units. In: XVI International Conference on Human Computer Interaction, 2015, Vilanova, Spain. **Anais...** Vilanova: ACM, 2015. p.1-6.

ORANGE, S.T.; METCALFE, J.W.; LIEFEITH, A.; MARSHALL, P.; MADDEN, L.A.; FEWSTER, C.R.; VINCE, R.V. Validity and reliability of a wearable inertial sensor to measure velocity and power in the back squat and bench press. **Journal of Strength and Conditioning Research**, v.33, n.9, p.2398-2408, 2019.

O'REILLY, M.A.; WHELAN, D.; WARD, T.; DELAHUNT, E.; CAUFIELD, B. Technology in strength and conditioning: tracking lower limb exercises with wearable sensors. **Journal of Strength and Conditioning Research**, v.31, n.6, p.1726-1736, 2017.

O'DONNELL, S.; FRANCISCO TAVARES, F.; MCMASTER, D.; CHAMBERS, S.; DRILLER, M. The validity and reliability of the GymAware linear position transducer for measuring countermovement jump performance in female athletes. **Measurement in Physical Education and Exercise Science**, v.22, n.1, p.101-107, 2018.

OLIVA-LOZANO. J.M.; ROJAS-VALVERDE, D.; GÓMEZ-CARMONA, C.D.; FORTES. V.; PINO-ORTEGA. J. Impact of contextual variables on the representative external load profile of Spanish professional soccer match-play: A full season study. **European Journal of Sport Science**, v.21, n.4, p.497-506, 2020.

OWEN, A.L.; DJAOUI, L.; NEWTON, M.; MALONE, S.; MENDES, B. A contemporary multi – modal mechanical approach to training monitoring in professional soccer. **Science and Medicine in Football**, v.1, n.3, p.216-221, 2017.

PARRINGTON, L.; PHILIPS, E.; WONG, A.; FINCH, M.; WAIN, E.; MACMAHON, C. Validation of inertial measurement units for tracking 100m sprint data. In: 34th International Conference on Biomechanics in Sports, 2016, Tsukuba, Japão. **Anais...** Tsukuba: ISBS, 2016, p.18-22.

PALLIS, J.M.; MCNITT-GRAY, J.L.; HUNG, G.K. **Biomechanical principles and applications in sports**. New York: Springer, 2019. 321p.

PEAKE, J.H.; KERR, G.; SULLIVAN, J.P. A critical review of consumer wearables, mobile applications, and equipment for providing biofeedback, monitoring stress, and sleep in physically active populations. **Frontiers in Physiology**, 2018, v.9, p.1-19.

PENG, K.; ZHAO, Y.; SHA, X.; MA, W.; WANG, Y.; LI, W.J. Accurate recognition of volleyball motion based on fusion of MEMS inertial measurement unit and video analytic. In: IEEE International Conference on CYBER technology in automation, control, and intelligent systems, 2018, Tianjin, China. **Anais...** Shenzhen: IEEE, 2018. p.440-444.

PERKINS, Noel; MCGINNIS, Ryan. **Athlete speed prediction method using data from attached inertial measurement unit**. Titular: University of Michigan. US n.9213889B2. Depósito: 25 mar. 2014. Concessão: 15 dez. 2015.

PINO-ORTEGA, J.; ROJAS-VALVERDE, D.; GÓMEZ-CARMONA, C.D.; RICO-GONZÁLEZ, M. Training Design, Performance Analysis, and Talent Identification-A Systematic Review about the Most Relevant Variables through the Principal Component Analysis in Soccer, Basketball, and Rugby. **International Journal of Environmental Research and Public Health**, v.18, n.5, p.1-19, 2021.

PICERNO, P.; CAMOMILLA, V.; CAPRANICA, L. Countermovement jump performance assessment using a wearable 3D inertial measurement unit. **Journal of Sports Sciences**, v.29, n.2, p.139-146, 2011.

RANTALAINEN, T.; FINNI, T.; WALKER, S. Jump height from inertial recordings: a tutorial for a sports scientist. **Scandinavian Journal of Medicine and Science in Sports**, v.30, n.1, p.38-45, 2019.

RANTALAINEN, T.; HESKETH, K.D.; RODDA, C.; DUCKHAM, R.L. Validity of hip-worn inertial measurement unit compared to jump mat for jump height measurement in adolescents. **Scandinavian Journal of Medicine and Science in Sports**, v.28, n.10, p.2183-2188, 2018.

REBALA, G.; RAVI, A.; CHURIWALA, S. **An introduction to machine learning**. Springer: New York, 263p.

REINA, M.; RUBIO, J.G.; ESTEVES, P.T.; IBÁÑEZ, S.J. How external load of youth basketball players varies according to playing position, game period and playing time. **International Journal of Performance Analysis in Sport**, v.20, n.6, p.917-930, 2020.

RICE, P.E.; GOODMAN, C.L.; CAPPS, C.R.; TRIPLETT, N.T.; ERICKSON, T.M.; MCBRIDE, J.M. Force – and power – time curve comparison during jumping between strength – matched male and female basketball players. **European Journal of Sports Sciences**, v.17, n.3, p.286-293, 2016.

ROELL, M.; ROECKER, K; GEHRING, D.; MAHLER, H.; GOLLHOFER, A. Player monitoring in indoor team sports: concurrent validity of inertial measurement units to quantify average and peak acceleration values. **Frontiers in Physiology**, v.19, n.1, p.1-13, 2018.

ROELL, M.; MAHLER, H.; LIENHARD, J.; GEHRING, D.; GOLLHOFER, A.; ROECKER, K. Validation of wearable sensors during team sport-specific movements in indoor environments. **Sensors**, v.19, n.16, p.1-13, 2019.

RICO-GONZÁLEZ, M.; ARCOS, A.L.; ROJAS-VALVERDE, D.; PINO-ORTEGA, J. A Principal Component Analysis in futsal according to game halves: A case study of an amateur futsal cup final. **Revista Internacional de Ciencias del Deporte**, v.17, n.63, p.88-101, 2021.

RYAN, S.; KEMPTON, T.; COUTTS, A.J. Data reduction approaches to athlete monitoring in professional Australian football. **International Journal of Sports Physiology and Performance**, v.16, n.1, p.59-65, 2021.

SATO, K.; BECKHAM, G.K.; CARROLL, K.; BAZYLER, C.; SHA, Z.; HAFF, G.G. Validity of Wireless Device Measuring Velocity of Resistance Exercises. **Journal of Trainology**, v.4, n.1, p.15-18, 2015.

SAMOZINO, P.; PEYROT, N.; EDOUARD, P.; NAGAHARA, R.; JIMENEZ-REYES, P.; VANWANSEELE, B.; MORIN, J.B. Optimal mechanical force-velocity profile for sprint acceleration performance. **Scandinavian Journal of Medicine and Science in Sports**, v.32, n.3, p.559-575, 2021.

SANDS, W.A.; KAVANAUGH, A.A.; MURRAY, S.R.; MCNEAL, J.R.; JEMNI, M. Modern Techniques and Technologies Applied to Training and Performance Monitoring. **International Journal of Sports Physiology and Performance**, v.12, s.2, p.63-72, 2017.

SCHMIDT, M.; RHEINLÄNDER, C.; NOLTE, K.F.; WILLE, S.; WHEN, N.; JAITNER, T. IMU-based determination of stance duration during sprinting. **Procedia Engineering**, v. 147, p.747 – 752, 2016.

SCHULDHAUS, D.; ZWICK, C.; KOERGER, H.; DORSCHKY, E.; KIRK, R.; ESKOFIER, B. Inertial sensor-based approach for shot/pass classification during a soccer match. In: 21<sup>st</sup> ACM SIGKDD Conference on Knowledge Discovery and Data Mining, 2015, Sydney, Australia. **Anais...** Sydney: ACM, 2015. p.1-4.

SHEEHAN, W.B.; TRIBOLET, R.; SPURRS, R.; FRANSEN, J.; NOVAK, A.R.; WATSFORD, M.L. Simplifying the complexity of assessing physical performance in professional Australian football. **Science and Medicine in Football**, v.4, n.4, p.285-292.

SETUAIN, I.; LECUMBERRI, P.; AHTIAINEN, J.P.; MERO, A.A.; HAKKINEN, K.; IZQUIERDO, M. Sprint mechanics evaluation using inertial sensor-based technology: a laboratory validation study. **Scandinavian Journal of Medicine and Science in Sports**, v.28, n.2, p.463-472, 2018.

SETUAIN, I.; MARTINIKORENA, J.; GONZALEZ-IZAL, M.; MARTINEZ-RAMIREZ, A.; GÓMEZ, M.; ALFARO-ADRIÁN, J.; IZQUIERDO, M. Vertical jumping biomechanical evaluation through the use of an inertial sensor-based technology. **Journal of Sports Sciences**, v.34, n.9, p.843-851, 2016.

SIDEY-GIBBONS, J.A.M.; SIDEY-GIBBONS, C.J. Machine learning in medicine: a practical introduction. **BMC Medical Research Methodology**, v.19, n.1, p.1-18, 2019.

SKEJØ, S.D.; BENCKE, J.; MØLLER, M.; SØRENSEN, H. Estimating throwing speed in handball using a wearable device. **Sensors**, v.20, n.17, p.1-27, 2020.

SPANGLER, R.; RANTALAINEN, T.; WUNDERSITZ, D. Inertial sensors are a valid tool to detect and consistently quantify jumping. **International Journal of Sports Medicine**, v.39, n.10, p.802-808, 2018.

SERPIELLO, F.R.; HOPKINS, W.G.; BARNESA, S.; TAVROU, J.; DUTHIE, G.M.; AUGHEY, R.J.; BALL, K. Validity of an ultra-wideband local positioning system to

measure locomotion in indoor sports. **Journal of Sports Sciences**, v.36, n.15, p.1727-1733, 2018.

SESHADRI, D.R.; LI, R.T.; VOOS, J.E.; ROWBOTTOM, J.R.; ALFES, C.M.; ZORMAN, C.A.; DRUMMOND, C.K. Wearable sensors for monitoring the internal and external workload of the athlete. **Nature**, v.71, n.2, p.1-8, 2019.

SOEKARJO, K.M.W.; ORTH, D.; WARMERDAM, E.; KAMP, J.V.D. Automatic Classification of Strike Techniques Using Limb Trajectory Data. **Machine Learning and Data Mining for Sports Analytics**, p.131-141, 2019.

SOUZA, O.T. **História dos fundadores do império do Brasil: a vida de Pedro I. Senado Federal: Brasília. 368p. 2015.**

STAMM, A.; JAMES, D.A.; THIEL, D.V. Velocity profiling using inertial sensors for freestyle swimming. **Sports Engineering**, v.16, n.1, p.1-11, 2013.

STANTON, C.A.; STANGER, J.J.; WUNDERSITZ, D.W.T.; GORDON, B.A.; CUSTOVIC, E.; KINGSLEY, M.L.C. Criterion validity of a MARG sensor to assess countermovement jump performance in elite basketballers. **Journal of Strength and Conditioning Research**, v.35, n.3, p.797-803, 2018.

STEVENS, T.G.A.; DE RUITER, C.J.; NIEL, C.V.; DE RHEE, R.V.; BEEK, P.J.; SAVELSBERGH, G.J.P. Measuring acceleration and deceleration in soccer-specific movements using a local positioning measurement (LPM) system. **International Journal of Sports Physiology and Performance**, v.9, n.3, p.446-456, 2014.

STONE, J.D.; MERRIGAN, J.J. RAMADAN, J.; BROWN, R.S.; CHENG, G.T.; HORNSBY, W.G.; SMITH, H.; GAISTER, S.M.; HAGEN, J.A. Simplifying external load in NCAA division – I men's basketball competitions: a principal component analysis. **Frontiers in Sports and Active Living**, v.16, n.4, p.1-10, 2022.

SVILAR, L.; CASTELLANO, J.; JUKIC, I.; CASAMICHANA, D. Positional differences in elite basketball: selecting appropriate training load measures. **International Journal of Sports Physiology and Performance**, v.13, n.7, p.947-952, 2018.

SWEETING, A.J.; CORMACK, S.J.; MORGAN, S.; AUGHEY, R.J. When Is a Sprint a Sprint? A Review of the Analysis of Team-Sport Athlete Activity Profile. **Frontiers in Physiology**, v.8, p.1-12, 2017.

TAN, T.; CHIASSON, D.P.; HU, H.; SHULL, P.B. Influence of IMU position and orientation placement errors on ground reaction force estimation. **Journal of Biomechanics**, v.97, n.3, p.24-32, 2018.

TABACHNICK, B.G.; FIDELL, L.S. **Using Multivariate Statistics**. Pearson: New York. 983p. 2013.

TILAAR, R.V.D.; BHANDURGE, S.; STEWART, T. Detection of different throw types and ball velocity with IMUs and machine learning in team handball. 38<sup>th</sup> International

Society of Biomechanics in Sport Conference, 2020, Liverpool, Reino Unido, **Anais...** Liverpool: ISBS, 2020. p.952-955.

TORRES – HONDA, L.; BEANLAND, E.; WHITEHEAD, S.; SWEETING, A.; CLUBB, J. Tracking systems in team sports: a narrative review of applications of the data and sport specific analysis. **Sports Medicine**, v.8, n.1, p.1-22, 2022.

TROST, S.G.; ZHENG, Y.; WONG, W.K. Machine learning for activity recognition: hip versus wrist data. **Physiological Measurement**, v.35, n.1, p.2183-22, 2189.

TWOMEY, N.; DIETHE, T.; FAFOUTIS, X.; ELSTS, A.; MCCONVILLE, R.; FLACH, P.; CRADOCK, I. A comprehensive study of activity recognition using accelerometers. **Informatics**, v.5, n.2, p.1-37, 2016.

VARLEY, M.C.; FAIRWEATHER, I.H.; AUGHEY, R.J. Validity and reliability of GPS for measuring instantaneous velocity during acceleration, deceleration, and constant motion. **Journal of Sports Sciences**, v.30, n.2, p.1-7, 2011.

VLANTES, T.G.; READDY, T. Using microsensor technology to quantify match demands in collegiate women's volleyball. **Journal of Strength and Conditioning Research**, v.31, n.12, p.3266-3278, 2017.

WADA, T.; MIZUTANI, M.; LEE, J.; ROWLANDS, D.; JAMES, D. 3D Visualization of wearable inertial/magnetic sensors. In: The 12th Conference of the International Sports Engineering Association (Proceedings), 2018, Brisbane: Australia. **Anais...** Brisbane: ISEA, 2018. p.1 – 6.

WADHI, T.; RAUCH, J.T.; TAMULEVICIUS, N.; ANDERSEN, J.C.; DE SOUZA, E.O. Validity and Reliability of the GymAware Linear Position Transducer for Squat Jump and Counter-Movement Jump Height. **Sports**, v.6, n.4, p.177, 2018.

WALDRON, M.; HARDING, J.; BARRETT, S.; GRAY, A. A new foot-mounted inertial measurement system in soccer: reliability and comparison to global positioning systems for velocity measurements during team sport actions. **Journal of Human Kinetics**, v.77, p.37-50, 2021.

WANG, Y.; ZHAO, Y.; CHAN, R.H.M.; LI, W.J. Volleyball skill assessment using a single wearable micro inertial measurement unit at wrist. **IEEE access**, v.6, n.1, p. 13758 - 13765, 2018.

WEIR, J.P. Quantifying test-retest reliability using the intraclass correlation coefficient. **Journal of Strength and Conditioning Research**, v.19, n.1, p.231-240, 2005.

WEAVING, D.; BEGGS, C.; DALTON-BARRON, N.; JONES, B.; ABT, G. Visualizing the complexity of the athlete – monitoring cycle through principle – component analysis. **International Journal of Sports Physiology and Performance**, v.14, n.9, p.1304-1310, 2019.

WEAVING, D.; DALTON, N.E.; BLACK, C.; JONES, J.D.; PHIBBS, P.J.; GRAY, M.; JONES, B.; ROE, G.A.B. The Same Story or a Unique Novel? Within-Participant

Principal-Component Analysis of Measures of Training Load in Professional Rugby Union Skills Training. **International Journal of Sports Physiology and Performance**, v.13, n.9, p.1175-1181, 2018.

WEAVING, D.; DALTON, N.E.; MCLAREN, S.; SCANTLEBURY, S.; CUMMINS, C.; ROE, G.; JONES, B.; BEGGS, C.; ABT, G. The relative contribution of training intensity and duration to daily measures of training load in professional rugby league and union. **Journal of Sports Sciences**, v.38, n.14, p.1674-1681, 2020

WEAVING, D.; JONES, B.; TILL, K.; ABT, G.; BEGGS, C. The case for adopting a multivariate approach to optimize training load quantification in team sports. **Frontiers in Physiology**, v.8, n.1024, p.1-3, 2017a.

WEAVING, D.; JONES, B.; MARSHALL, P.; TILL, K.; ABT, G. Multiple Measures are Needed to Quantify Training Loads in Professional Rugby League. **International Journal of Sports Medicine**, v.38, n.10, p. 735-740, 2017b.

WEAVING, D.; MARSHALL, P.; EARLE, K.; NEVILL, A.; ABT, G. Combining internal and external-training load measures in professional rugby league. **International Journal of Sports Physiology and Performance**, v.9, n.6, p.905-912, 2014.

WEAVING, D.; READ, D.B. Re: A contemporary multi-modal mechanical approach to training monitoring in elite professional soccer: a statistical problem. **Science and Medicine in Football**, v.6, n.2, p.268-269, 2022.

WIK, E.H.; LUTEBERGET, L.S.; SPENCER, M. Activity profiles in international women's team handball using playerload. **International Journal of Sports Physiology and Performance**, v.12, n.7, p.934-942, 2017.

WHITESIDE, D.; CANT, O.; CONNOLLY, M.; REID, M. Monitoring hitting load in tennis using inertial sensors and Machine Learning. **International Journal of Sports Physiology and Performance**, v.12, n.2, p.1212-1217, 2017

WUNDERSITZ, D.W.T.; JOSMAN, C.; GUPTA, R.; NETTO, K.J.; GASTIN, P.B.; ROBERTSON, S. Classification of team sport activities using a single wearable tracking device. **Journal of Biomechanics**, v.48, n.15, p.3975-3981, 2015.

WUNDERSITZ, D.; GASTIN, P.; ROBERTSON, S., DAVEY, P., AND NETTO, K. Validation of a trunk-mounted accelerometer to measure peak impacts during team sport movements. **International Journal of Sports Medicine**. v.36, n.9, 742-746. 2015.

YOUNG, C.M.; GASTIN, P.B.; SANDERS, N.; MACKEY, L.; DWYER, D.B. Player Load in Elite Netball: Match, Training, and Positional Comparisons. **International Journal of Sports Physiology and Performance**, v.11, n.8, p.1074 -1079. 2016.

YU, X.; LIU, B.; LAN, X.; XIAO, Z.; LIN S.; YAN, B.; ZHOU, L. AZUPT: adaptive zero velocity update based on neural networks for pedestrian tracking. In: IEEE Global Communications Conference (GLOBECOM), 2019, Waikoloa, USA. **Anais...** Waikoloa: IEEE, 2019. p.1-6.

## APÊNDICE A – TERMO DE CONSENTIMENTO LIVRE ESCLARECIDO (TCLE)

Você está sendo convidado(a) como voluntário(a) a participar da pesquisa “**APLICAÇÃO DE SENSORES INERCIAIS E MÉTODOS DE APRENDIZADO DE MÁQUINA PARA CLASSIFICAÇÃO DE AÇÕES NOS ESPORTES COLETIVOS**” desenvolvida pelo discente de doutorado Leandro Vinhas de Paula (matrícula n.º 2018713374) e orientada pelo docente André Gustavo Pereira Andrade, sendo responsáveis pelo estudo. Após os devidos esclarecimentos sobre a pesquisa, caso você aceite participar da mesma, assine o documento, que estará apresentado em duas vias, sendo uma sua. Todos os participantes da pesquisa serão voluntários e fica garantido o anonimato e o absoluto sigilo de todas as informações pessoais fornecidas por você. Caso aceite a participar desta pesquisa, esta não proporcionará nenhum tipo de gasto por parte do voluntário. Além disso, os pesquisadores são responsáveis por eventual necessidade de indenização.

O estudo tem como objetivo avaliar a acurácia, sensibilidade, especificidade e precisão de aplicação de sensores inerciais para detecção e classificação de ações nos esportes coletivos. A importância e justificativa do estudo reside na viabilização prática de instrumentos de medição baixo custo, com a finalidade de redução de lesões e melhora do desempenho nos esportes coletivos. Os resultados que se desejam alcançar são os seguintes: verificação da validade e confiabilidade de medição em ambiente laboratorial e análise da aplicação de sensores inerciais para classificação de ações nas modalidades esportivas coletivas de futsal, basquetebol, voleibol e handebol. O presente estudo será realizado em três partes: (1) Parte 1 – Experimentos de análise de saltos verticais, sprints e circuito simulado de ações; (2) Parte 2 – Circuito de ações específicas nas modalidades esportivas coletivas de futsal, basquetebol, voleibol e handebol; e (3) Parte 3 – Atividades de pequenos jogos nas modalidades esportivas coletivas de futsal, basquetebol, voleibol e handebol. Você participará somente de uma das partes do estudo.

Caso você tenha sido convidado a participar da **primeira parte do estudo**, será coletada sua massa, estatura e será familiarizado com os **exercícios de saltos agachados** (SA, partindo da posição agachada, com as mãos posicionadas na cintura, saltar o mais alto possível), **saltos com contramovimento** (SCM, com as mãos na cintura, partindo da posição ortostática, realizar um contramovimento para baixo e saltar o mais alto possível), **saltos em profundidade** (SP, posicionado sobre um caixote de madeira, realizar uma queda e imediatamente saltar o mais possível) e determinada a altura ótima de queda para realização dos SP. Nas visitas subsequentes, após escolher e vestir um short e um colete em poliamida, você realizará um aquecimento (corrida leve e saltos submáximos) e se posicionará sobre uma plataforma de força triaxial empregada simultaneamente ao uso dos sensores inerciais para análise do desempenho de saltos. Nestas sessões, você irá executar 5 séries de 10 saltos (3 minutos de pausa entre séries, 30 segundos entre repetições) referentes a cada um dos exercícios de saltos supracitados. As sessões serão realizadas conforme sua disponibilidade com um intervalo mínimo de 48 horas, duração máxima estimada de 1 hora e 10 minutos, sendo repetidas na semana subsequente para determinação da consistência das medições (300 saltos no total). Após a realização dos saltos, você vestirá novamente o colete e a bermuda, realizará um aquecimento padrão composto por exercícios de alongamento para membros inferiores e 10 minutos de corrida leve com velocidade auto-selecionada para execução de **sprints**, com a utilização dos respectivos sensores simultaneamente ao emprego de um equipamento do tipo *encoder* (*Race Analyzer*) para mensuração do desempenho. Em seguida, você realizará um protocolo de sprints, onde serão realizadas 3 séries de 5 sprints de 30 metros, com intervalos de 3 minutos entre repetições e 5 minutos entre séries. Ao todo 2 sessões separadas por 72 horas serão executadas, sendo repetidas na semana subsequente para determinação da confiabilidade, totalizando 60 sprints por indivíduo.

Na sequência, você será familiarizado com um **circuito de ações** que compreenderá saltos com contramovimento, caminhada, trechos de corridas em intensidade leve, elevada, sprints, desacelerações e movimentos de mudanças de direção. Nas visitas seguintes, após escolher e vestir um short e um colete em poliamida, você realizará um aquecimento (corrida leve) e

se posicionará no ponto de início para realização do circuito de ações. No total, você irá percorrer 20 vezes o circuito de ações composto por 4 séries de 5 repetições, com 5 minutos de pausa entre séries e 2 minutos de descanso entre repetições. Em cada repetição você realizará 6 saltos com contramovimento, 25 metros de caminhada, 20 metros de desacelerações, 20 metros de corrida em intensidade leve, 30 metros de corrida em intensidade elevada, 30 metros de sprints e 4 movimentos de mudança de direção. Uma câmera filmadora será empregada simultaneamente ao uso dos sensores inerciais para registro das ações realizadas no circuito de ações. As sessões serão realizadas conforme sua disponibilidade com duração máxima estimada de 1 hora e 30 minutos. O circuito de ações será repetido na semana subsequente para verificação da consistência de medida (40 séries no total).

Caso você tenha sido convidado a participar da **segunda parte do estudo**, após o aquecimento você realizará 40 séries de um **circuito de ações específicas** à modalidade esportiva coletiva ao qual possua experiência prévia (voleibol - toques por cima, por baixo e ataque; basquetebol - passes, dribles, arremessos e mudanças de direção com e sem bola; futsal - passes, conduções, chutes e deslocamento com e sem bola; ou handebol - passes, lançamentos, deslocamentos com e sem bola). Você irá escolher e utilizar uma bermuda em poliamida com um sensor inercial durante a realização dos circuitos, simultaneamente ao registro por duas câmeras filmadoras. Nas modalidades de predominância de membros superiores (handebol, voleibol e basquetebol) um sensor inercial adicional será acomodado em manguito de tecido vestido no antebraço. Caso sua experiência seja com a modalidade de futsal, você irá vestir uma faixa em neoprene na perna com um sensor inercial adicional.

Por fim, caso você tenha sido convidado a participar da **terceira parte do estudo**, após o aquecimento você irá participar de uma intervenção estruturada de **atividades de pequenos jogos** (atividade coletiva de 3 contra 3 indivíduos, 4 séries de 5 minutos, com 3 minutos de pausa entre séries) específicos à modalidade esportiva coletiva ao qual você tenha experiência prévia (voleibol, basquetebol, futsal ou handebol), com duração aproximada de 1 hora. No início e ao final dos pequenos jogos, você irá realizar três saltos agachados, três saltos com contramovimento e três sprints máximos de 30 metros, com 30 segundos de recuperação para os saltos e 60 segundos para os sprints entre repetições. Você vestirá um colete utilizando um sensor inercial concomitantemente ao registro por duas câmeras filmadoras para registro das ações. O protocolo será replicado após três dias para verificação da consistência das ações registradas.

Adicionalmente, em conformidade com as resoluções 466/12 e 510/16, os aspectos éticos da pesquisa com seres humanos, implicam em: respeito ao participante da pesquisa em sua dignidade e autonomia, reconhecendo sua vulnerabilidade, assegurando sua vontade de contribuir e permanecer, ou não, na pesquisa, por intermédio de manifestação expressa, livre e esclarecida; ponderação entre riscos e benefícios; a garantia de que danos previsíveis serão evitados. **Em qualquer momento da pesquisa existe a possibilidade de revogação do seu consentimento sem qualquer tipo de penalização e sem prejuízo por parte do voluntário. As informações obtidas por meio da sua participação não permitirão a identificação de sua pessoa, sendo garantido o sigilo e anonimato, exceto aos responsáveis pelo estudo. Além disso, ao final da pesquisa, os dados serão publicados por meio de uma tese de doutoramento e artigos em revistas científicas especializadas.**

Os outros meios conhecidos para se obter os mesmos resultados são as seguintes: realizar o estudo com animais, o que não significa que seriam obtidos resultados semelhantes em humanos, dada natureza exclusivamente humana da atividade esportiva. Os incômodos que poderá sentir com a participação são os seguintes: alguma dor muscular tardia devido à atividade física (dor ou desconforto muscular após a sessão de treinamento), sendo este efeito comum ao exercício e esporte e não será necessário o uso de medicamentos. Para minimização destes possíveis efeitos as sessões de treinamento serão realizadas com intervalo mínimo de 48 - 72 horas. Esta pesquisa foi planejada de forma que você possua o menor desconforto físico possível. Entretanto, apesar de todos cuidados tomados, os possíveis riscos à sua saúde física e mental são: microlesões músculo-esqueléticas e lesões ósteo – mio – articulares, que ocorrem com baixa frequência nas atividades a serem aplicadas.

Caso você julgue-se incapaz de realizar as tarefas de exercício ou se a dor permanecer por um período superior a 72 horas, você será encaminhado à avaliação médica e sua participação será suspensa.

Os benefícios que você deverá esperar com a sua participação, mesmo que não diretamente são: contribuir para o estudo da atividade física e do esporte, ajudando a viabilizar novas metodologias de medição de baixo custo que ajudem, inclusive, na redução de lesões no esporte e otimização do desempenho de atletas nos esportes coletivos. Sempre que desejar serão fornecidos esclarecimentos sobre cada uma das etapas do estudo. Cabe destacar que todos os dados serão armazenados no disco rígido do computador pessoal, com cópia no disco rígido externo de propriedade do pesquisador responsável Leandro Vinhas de Paula (Discente de Doutorado), localizado em sua respectiva residência (Rua Gonçalves Veloso, 210, Apartamento 202, Coração de Jesus, Belo Horizonte, MG, Brasil – CEP - 30380-620). O disco rígido externo com a cópia dos dados será mantido em um armário com chave no mesmo endereço. Os dados serão mantidos durante o período de 10 anos e após este período serão inutilizados.

Qualquer dúvida em relação ao caráter ético deve ser esclarecida junto ao Comitê de Ética e Pesquisa da Universidade Federal de Minas Gerais, e as condizentes à pesquisa devem ser esclarecidas com o pesquisador. Finalmente, tendo eu compreendido perfeitamente tudo o que me foi informado sobre a minha participação no mencionado estudo e consciente dos meus direitos, das minhas responsabilidades, dos riscos e dos benefícios que a minha participação implica, concordo em dele participar e, para isso, eu DOU O MEU CONSENTIMENTO SEM QUE PARA ISSO EU TENHA SIDO FORÇADO OU OBRIGADO. O presente termo de consentimento é feito de livre e espontânea vontade, sendo assinado nesta data, em duas vias (sendo uma via minha e outra dos pesquisadores) para que produza seus efeitos éticos, jurídicos e legais.

Belo Horizonte, \_\_\_\_\_ / \_\_\_\_\_ / 2021

\_\_\_\_\_  
Assinatura do voluntário

\_\_\_\_\_  
Assinatura do pesquisador

**Pesquisadores responsáveis:**

**Prof. Dr. André Gustavo Pereira Anadrade (Orientador)**

**Av. Pres. Antônio Carlos, 6627 Campus - Pampulha - Belo Horizonte - MG - CEP 31270-901, EEFFTO - Escola de Educação Física, Fisioterapia e Terapia Ocupacional (EEFFTO), Universidade Federal de Minas Gerais (UFMG)**

**Telefone para contato: 31-994516185 - e-mail: [andreguto@yahoo.com.br](mailto:andreguto@yahoo.com.br)**

**Leandro Vinhas de Paula (Discente de Doutorado)**

**Rua Gonçalves Veloso, 210, Apartamento 202, Coração de Jesus, Belo Horizonte, MG – CEP - 30380-620.**

**Telefone para contato: 31-993747564 - e-mail: [leandro.paula@ufop.edu.br](mailto:leandro.paula@ufop.edu.br)**

**Comitê de Ética em Pesquisa - UFMG.**

**Av. Presidente Antonio Carlos, 6627, Pampulha - Belo Horizonte - MG - CEP 31270-901; Universidade Federal de Minas Gerais, Unidade Administrativa II - 2º Andar - Sala: 2005**

**Telefone: (031) 3409-4592 - e-mail: [coep@prpq.ufmg.br](mailto:coep@prpq.ufmg.br)**

## APÊNDICE B – TERMO DE ASSENTIMENTO LIVRE E ESCLARECIDO (TALE)

Você está sendo convidado(a) para participar por vontade própria, de um estudo chamado: **“APLICAÇÃO DE SENSORES INERCIAIS E MÉTODOS DE APRENDIZADO DE MÁQUINA PARA CLASSIFICAÇÃO DE AÇÕES NOS ESPORTES COLETIVOS”**. Após tirar todas as suas dúvidas sobre a pesquisa, caso você aceite participar com o estudo, assine este documento que está em duas folhas. Fica garantido o segredo de todas as informações dadas por você. Não tem problema algum, se você não quiser participar.

### INFORMAÇÕES SOBRE A PESQUISA:

Título do projeto: **“APLICAÇÃO DE SENSORES INERCIAIS E MÉTODOS DE APRENDIZADO DE MÁQUINA PARA CLASSIFICAÇÃO DE AÇÕES NOS ESPORTES COLETIVOS.”**

**Pesquisadores responsáveis:** Leandro Vinhas de Paula (aluno de doutorado, matrícula n.º 2018713374) e orientada por André Gustavo Pereira Andrade (professor da Escola de Educação Física, Fisioterapia e Terapia Ocupacional – EEFFTO - UFMG).

**Telefone para contato:** (31) 99374-7564

O estudo tem como objetivo avaliar a acurácia, sensibilidade, especificidade e precisão de aplicação de sensores inerciais para detecção e classificação de ações nos esportes coletivos. A importância e justificativa do estudo reside na viabilização prática de instrumentos de medição baixo custo, com a finalidade de redução de lesões e melhora do desempenho nos esportes coletivos. Participarão do estudo adolescentes com idade a partir dos 15 anos. A coleta de dados ocorrerá no local onde ocorrem os treinos, em data e horário previamente marcados. As coletas ocorrerão fora do horário das aulas dos atletas e do trabalho dos treinadores. O presente estudo será realizado em três partes: (1) Parte 1 – Experimentos de análise de saltos verticais, sprints e circuito simulado de ações; (2) Parte 2 – Circuito de ações específicas nas modalidades esportivas coletivas de futsal, basquetebol, voleibol e handebol; e (3) Parte 3 – Atividades de pequenos jogos nas modalidades esportivas coletivas de futsal, basquetebol, voleibol e handebol. Você participará somente de uma das partes do estudo.

Caso você tenha sido convidado a participar da **primeira parte do estudo**, será coletada sua massa, estatura e será familiarizado com os **exercícios de saltos agachados** (SA, partindo da posição agachada, com as mãos posicionadas na cintura, saltar o mais alto possível), **saltos com contramovimento** (SCM, com as mãos na cintura, partindo da posição ortostática, realizar um contramovimento para baixo e saltar o mais alto possível), **saltos em profundidade** (SP, posicionado sobre um caixote de madeira, realizar uma queda e imediatamente saltar o mais possível) e determinada a altura ótima de queda para realização dos SP. Nas visitas subsequentes, após escolher e vestir um short e um colete em poliamida, você realizará um aquecimento (corrida leve e saltos submáximos) e se posicionará sobre uma plataforma de força triaxial empregada simultaneamente ao uso dos sensores inerciais para análise do desempenho de saltos. Nestas sessões, você irá executar 5 séries de 10 saltos (3 minutos de pausa entre séries, 30 segundos entre repetições) referentes a cada um dos exercícios de saltos supracitados. As sessões serão realizadas conforme sua disponibilidade com um intervalo mínimo de 48 horas, duração máxima estimada de 1 hora e 10 minutos, sendo repetidas na semana subsequente para determinação da consistência das medições (300 saltos no total). Após a realização dos saltos, você vestirá novamente o colete e a bermuda, realizará um aquecimento padrão composto por exercícios de alongamento para membros inferiores e 10 minutos de corrida leve com velocidade auto-selecionada para execução de **sprints**, com a utilização dos respectivos sensores simultaneamente ao emprego de um equipamento do tipo encoder (*Race Analyzer* – Analisador de corridas) para mensuração do desempenho. Em seguida, você realizará um protocolo de sprints, onde serão realizadas 3 séries de 5 sprints de 30 metros, com intervalos de 3 minutos entre repetições e 5 minutos entre séries. Ao todo 2 sessões separadas por 72 horas serão executadas, sendo

repetidas na semana subsequente para determinação da confiabilidade, totalizando 60 sprints por indivíduo.

Na sequência, você será familiarizado com um **circuito de ações** que compreenderá saltos com contramovimento, caminhada, trechos de corridas em intensidade leve, elevada, sprints, desacelerações e movimentos de mudanças de direção. Nas visitas seguintes, após escolher e vestir um short e um colete em poliamida, você realizará um aquecimento (corrida leve) e se posicionará no ponto de início para realização do circuito de ações. No total, você irá percorrer 20 vezes o circuito de ações composto por 4 séries de 5 repetições, com 5 minutos de pausa entre séries e 2 minutos de descanso entre repetições. Em cada repetição você realizará 6 saltos com contramovimento, 25 metros de caminhada, 20 metros de desacelerações, 20 metros de corrida em intensidade leve, 30 metros de corrida em intensidade elevada, 30 metros de sprints e 4 movimentos de mudança de direção. Uma câmera filmadora será empregada simultaneamente ao uso dos sensores inerciais para registro das ações realizadas no circuito de ações. As sessões serão realizadas conforme sua disponibilidade com duração máxima estimada de 1 hora e 30 minutos. O circuito de ações será repetido na semana subsequente para verificação da consistência de medida (40 séries no total).

Caso você tenha sido convidado a participar da **segunda parte do estudo**, após o aquecimento você realizará 40 séries de um **circuito de ações específicas** à modalidade esportiva coletiva ao qual possua experiência prévia (voleibol - toques por cima, por baixo e ataque; basquetebol - passes, dribles, arremessos e mudanças de direção com e sem bola; futsal - passes, conduções, chutes e deslocamento com e sem bola; ou handebol - passes, lançamentos, deslocamentos com e sem bola). Você irá escolher e utilizar uma bermuda em poliamida com um sensor inercial durante a realização dos circuitos, simultaneamente ao registro por duas câmeras filmadoras. Nas modalidades de predominância de membros superiores (handebol, voleibol e basquetebol) um sensor inercial adicional será acomodado em manguito de tecido vestido no antebraço. Caso sua experiência seja com a modalidade de futsal, você irá vestir uma faixa em neoprene na perna com um sensor inercial adicional.

Por fim, caso você tenha sido convidado a participar da **terceira parte do estudo**, após o aquecimento você irá participar de uma intervenção estruturada de **atividades de pequenos jogos** (atividade coletiva de 3 contra 3 indivíduos, 4 séries de 5 minutos, com 3 minutos de pausa entre séries) específicos à modalidade esportiva coletiva ao qual você tenha experiência prévia (voleibol, basquetebol, futsal ou handebol), com duração aproximada de 1 hora. No início e ao final dos pequenos jogos, você irá realizar três saltos agachados, três saltos com contramovimento e três sprints máximos de 30 metros, com 30 segundos de recuperação para os saltos e 60 segundos para os sprints entre repetições. Você vestirá um colete utilizando um sensor inercial concomitantemente ao registro por duas câmeras filmadoras para registro das ações. O protocolo será replicado após três dias para verificação da consistência das ações registradas.

Ao final do projeto, os resultados da pesquisa serão publicados em artigo científico em uma revista da área, sendo assegurado o anonimato. Cabe destacar que todos os dados serão armazenados no disco rígido do computador pessoal, com cópia no disco rígido externo de propriedade do pesquisador responsável Leandro Vinhas de Paula (Discente de Doutorado), localizado em sua respectiva residência (Rua Gonçalves Veloso, 210, Apartamento 202, Coração de Jesus, Belo Horizonte, MG, Brasil – CEP - 30380-620). O disco rígido externo com a cópia dos dados será mantido em um armário com chave no mesmo endereço. Os dados serão mantidos durante o período de 10 anos e após este período serão inutilizados.

**Riscos:** Os incômodos que poderá sentir com a participação são os seguintes: alguma dor muscular tardia devido à atividade física (dor ou desconforto muscular após a sessão de treinamento), sendo este efeito comum ao exercício e esporte e não será necessário o uso de

medicamentos. Para minimização destes possíveis efeitos as sessões de treinamento serão realizadas com intervalo mínimo de 48 - 72 horas. Esta pesquisa foi planejada de forma que você possua o menor desconforto físico possível. Entretanto, apesar de todos cuidados tomados, os possíveis riscos à sua saúde física e mental são: microlesões músculo-esqueléticas e lesões ósteo – mio – articulares, que ocorrem com baixa frequência nas atividades a serem aplicadas. Caso julgue-se incapaz de realizar as tarefas de exercício ou se a dor permanecer por um período superior a 72 horas, você será encaminhado à avaliação médica e sua participação será suspensa.

**Benefícios:** Os benefícios que você deverá esperar com a sua participação, mesmo que não diretamente são: contribuir para o estudo da atividade física e do esporte, ajudando a viabilizar novas metodologias de medição de baixo custo que ajudem, inclusive, na redução de lesões no esporte e otimização do desempenho de atletas nos esportes coletivos.

Esta pesquisa atende todas as especificações da Resolução 466/12 e 510/16, que aprova as diretrizes e normas regulamentadoras de pesquisas envolvendo seres humanos. O sujeito da pesquisa é o (a) participante pesquisado (a), individual ou coletivamente, de caráter voluntário, vedada qualquer forma de remuneração. Estamos à disposição para maiores esclarecimentos antes e durante o curso da pesquisa.

**Pesquisadores responsáveis:**

**Prof. Dr. André Gustavo Pereira Andrade (Orientador)**

**Av. Pres. Antônio Carlos, 6627 Campus - Pampulha - Belo Horizonte - MG - CEP 31270-901, EEFFTO - Escola de Educação Física, Fisioterapia e Terapia Ocupacional (EEFFTO), Universidade Federal de Minas Gerais (UFMG)**

**Telefone para contato: 31-994516185 - e-mail: andreguto@yahoo.com.br**

**Leandro Vinhas de Paula (Discente de Doutorado)**

**Rua Gonçalves Veloso, 210, Apartamento 202, Coração de Jesus, Belo Horizonte, MG – CEP - 30380-620.**

**Telefone para contato: 31-993747564 - e-mail: leandro.paula@ufop.edu.br**

**Comitê de Ética em Pesquisa - UFMG.**

**Av. Presidente Antonio Carlos, 6627, Pampulha - Belo Horizonte - MG - CEP 31270-901; Universidade Federal de Minas Gerais, Unidade Administrativa II - 2º Andar - Sala: 2005**

**Telefone: (031) 3409-4592 - e-mail: coep@prpq.ufmg.br**

**Assinatura do participante**

---

**Assinatura do responsável pela pesquisa**

---

**CONSENTIMENTO DA PARTICIPAÇÃO DA PESSOA COMO SUJEITO**

Eu, \_\_\_\_\_, portador (a) do documento de identidade de nº: \_\_\_\_\_, aceito participar da pesquisa "**APLICAÇÃO DE SENSORES INERCIAIS E MÉTODOS DE APRENDIZADO DE MÁQUINA PARA CLASSIFICAÇÃO DE AÇÕES NOS ESPORTES COLETIVOS**", conforme devidamente informado pelo pesquisador. Foi-me apresentado todas as informações referentes à pesquisa, como ela acontecerá e aos possíveis riscos e benefícios decorrentes da minha participação. Além disso, foi-me também garantido o segredo das informações pessoais que possam assegurar a minha identificação bem como possíveis informações que possam vir comprometer-la. Diante disto, estou de acordo que li e entendi todas as informações aqui presentes e as dúvidas que eu tinha me foram esclarecidas, sendo assim, aceito plenamente contribuir com o estudo através da utilização de todos os dados que possam servir para os fins da pesquisa científica da qual contribuirei.

Local e data: \_\_\_\_\_, \_\_\_\_/\_\_\_\_/20\_\_\_\_.

Nome do responsável: \_\_\_\_\_.

Nome do adolescente: \_\_\_\_\_.

Telefone para contato: \_\_\_\_\_.

**Assinatura do participante**

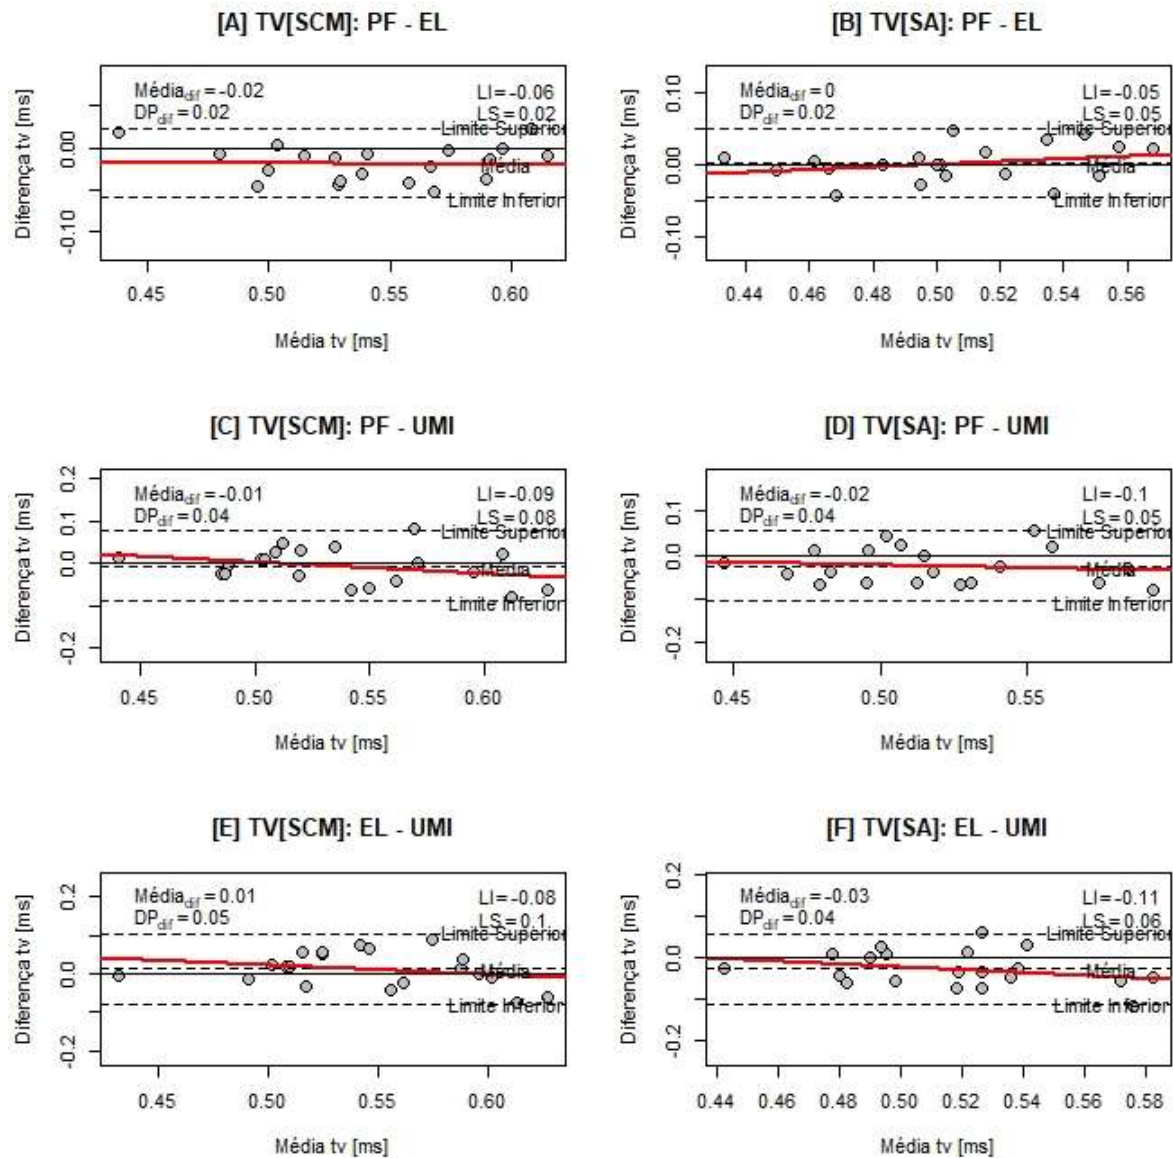
\_\_\_\_\_

**Assinatura do responsável pela pesquisa**

\_\_\_\_\_

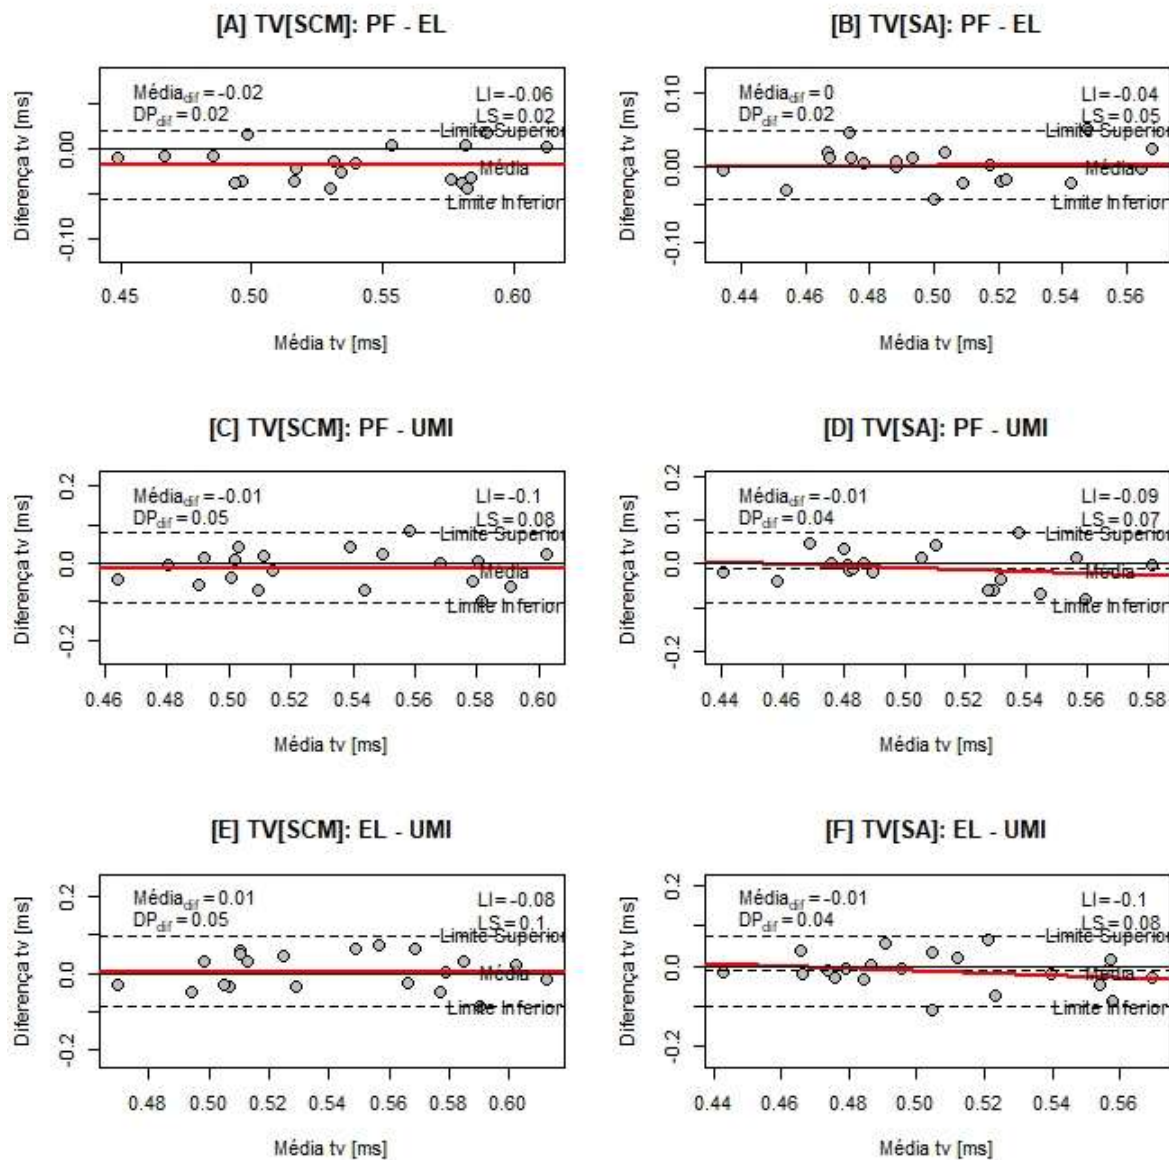
## APÊNDICE C – GRÁFICOS DE DISPERSÃO DE “BLAND ALTMAN” DE CONCORDÂNCIA ENTRE INSTRUMENTOS DE MEDIÇÃO E ENTRE SESSÕES (CAPÍTULO 2).

Figura C1 – Gráfico de Dispersão “Bland-Altman” de concordância entre instrumentos de medição para a variável tempo de vôo ( $tv_{SCM}$  e  $tv_{SA}$ ): PF e EL ([A] SCM, [B] SA), PF e UMI ([C] SCM, [D] SA) e EL e UMI ([E] SCM, [F] SA) – Sessão 1.



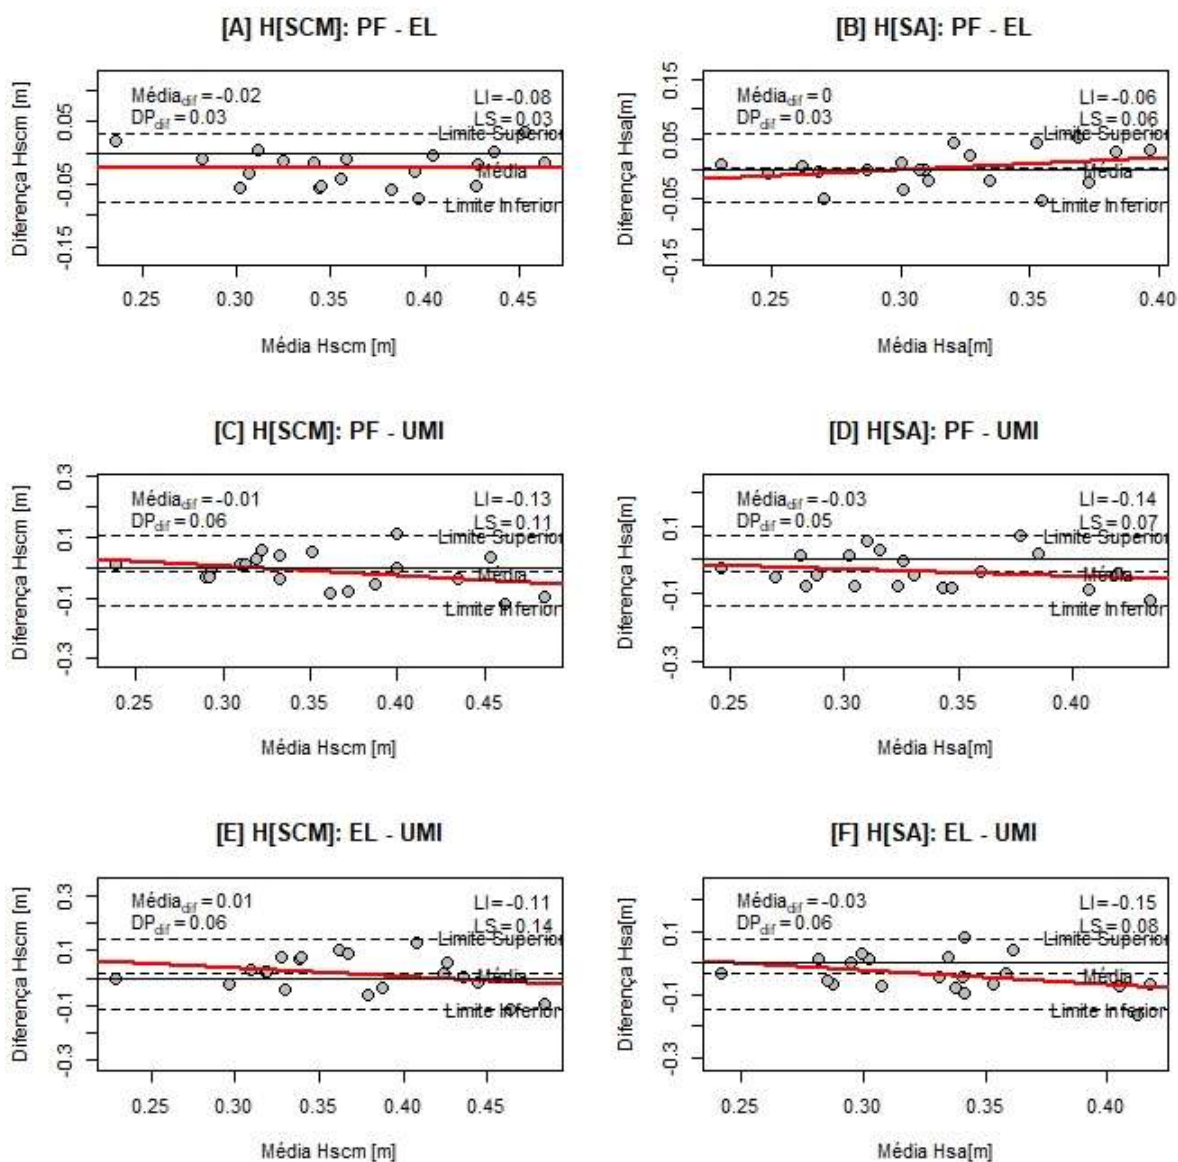
Fonte: Dados da pesquisa.

Figura C2 – Gráfico de Dispersão “Bland-Altman” de concordância entre instrumentos de medição para a variável tempo de vôo ( $tv_{SCM}$  e  $tv_{SA}$ ): PF e EL ([A] SCM, [B] SA), PF e UMI ([C] SCM, [D] SA) e EL e UMI ([E] SCM, [F] SA) – Sessão 2.



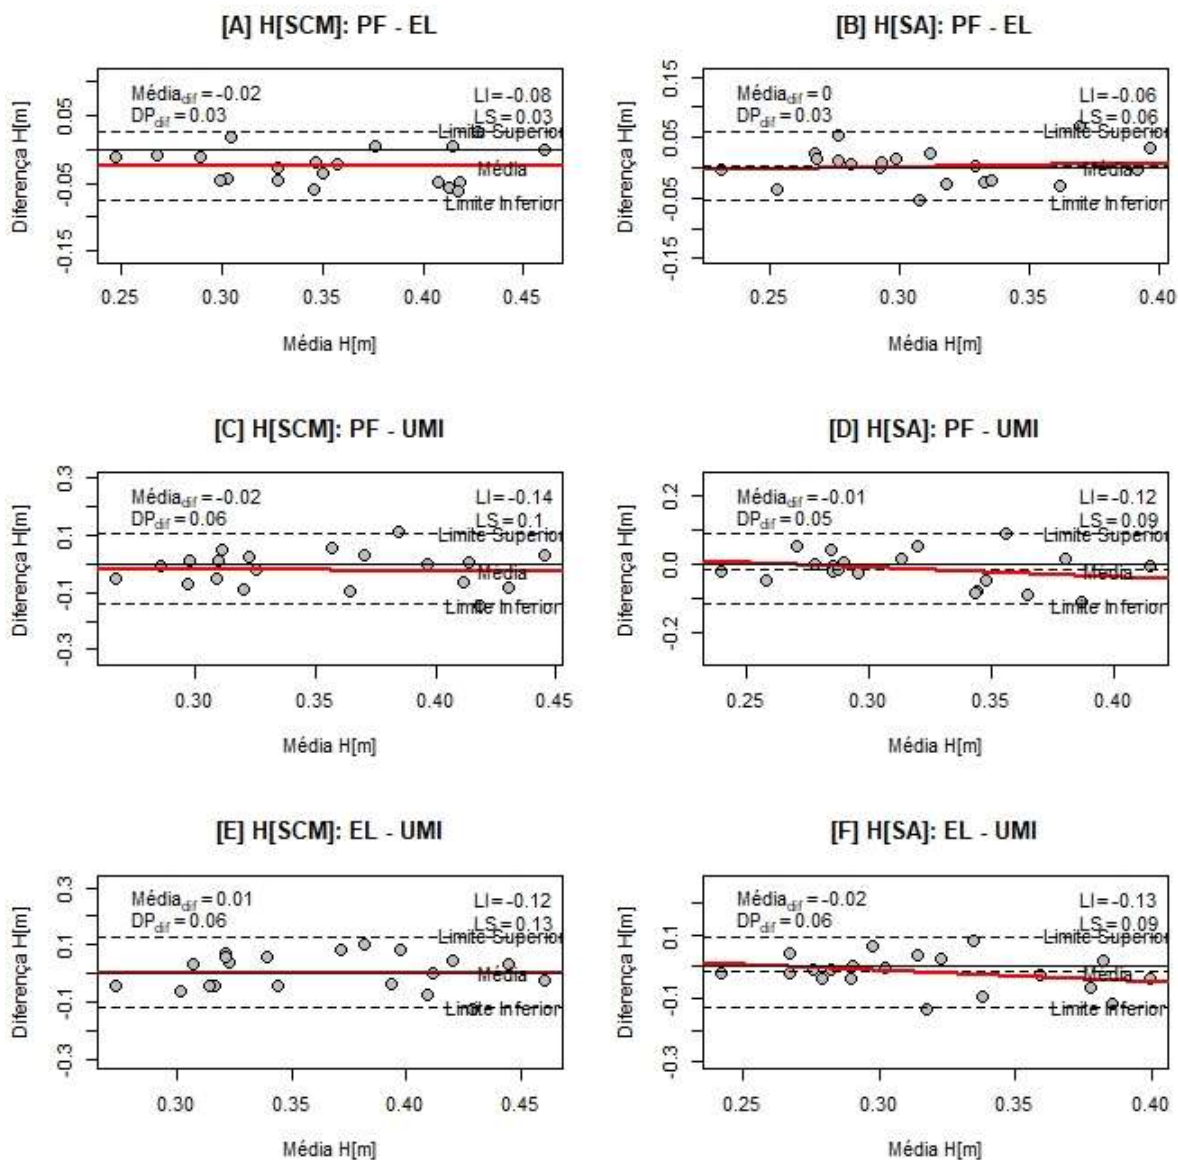
Fonte: Dados da pesquisa.

Figura C3 – Gráfico de Dispersão “Bland-Altman” de concordância entre instrumentos de medição para a variável altura de salto vertical (Hscm e Hsa): PF e EL ([A] SCM, [B] SA), PF e UMI ([C] SCM, [D] SA) e EL e UMI ([E] SCM, [F] SA) – Sessão 1.



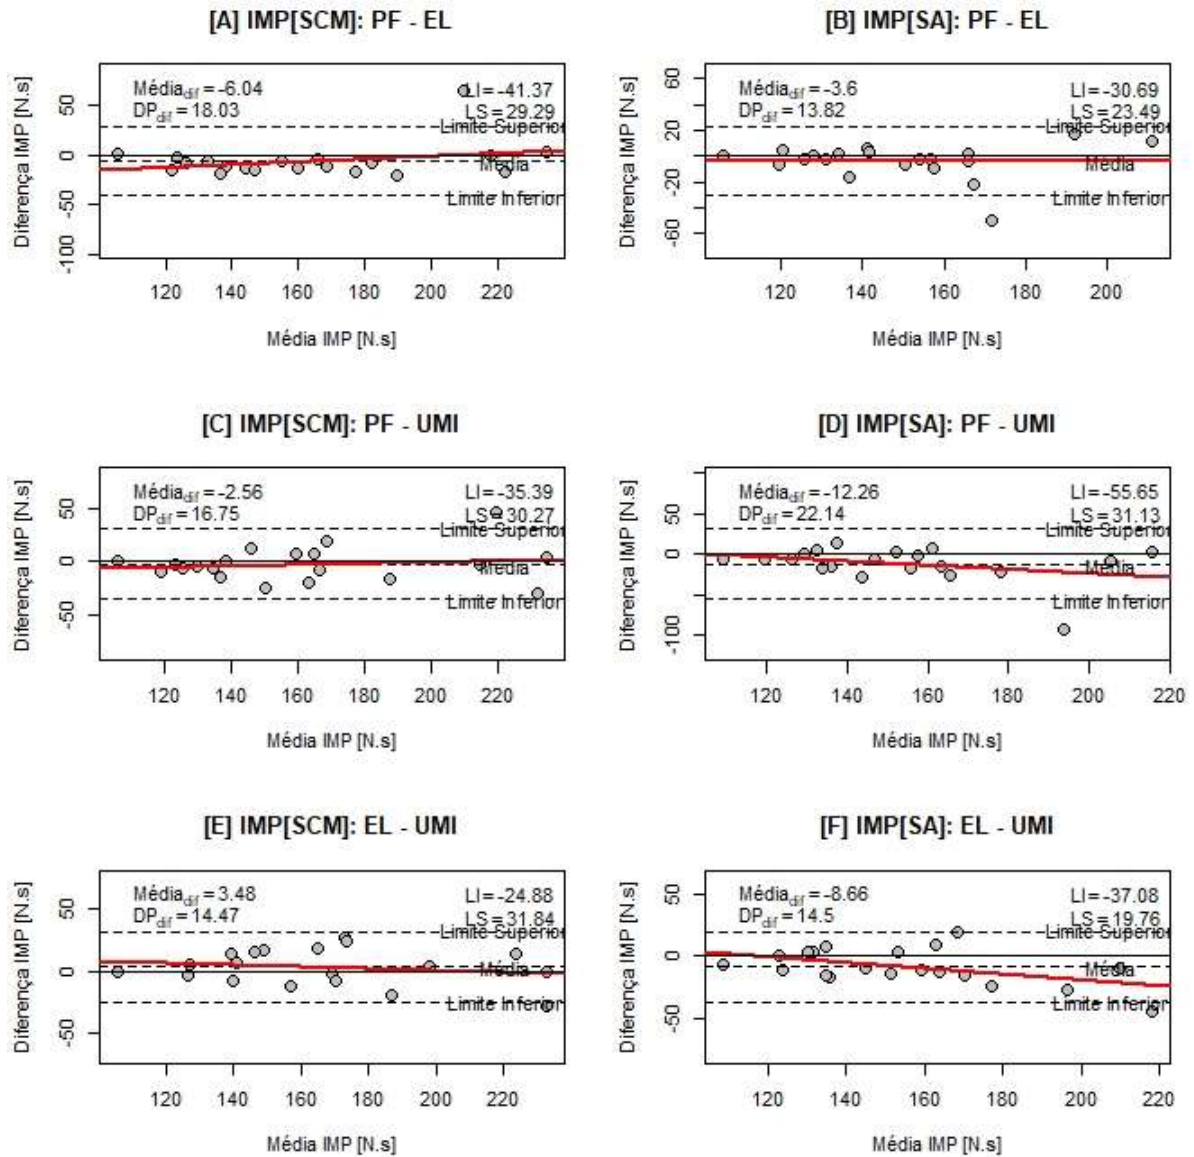
Fonte: Dados da pesquisa.

Figura C4 – Gráfico de Dispersão “Bland-Altman” de concordância entre instrumentos de medição para a variável altura de salto vertical (Hscm e Hsa): PF e EL ([A] SCM, [B] SA), PF e UMI ([C] SCM, [D] SA) e EL e UMI ([E] SCM, [F] SA) – Sessão 2.



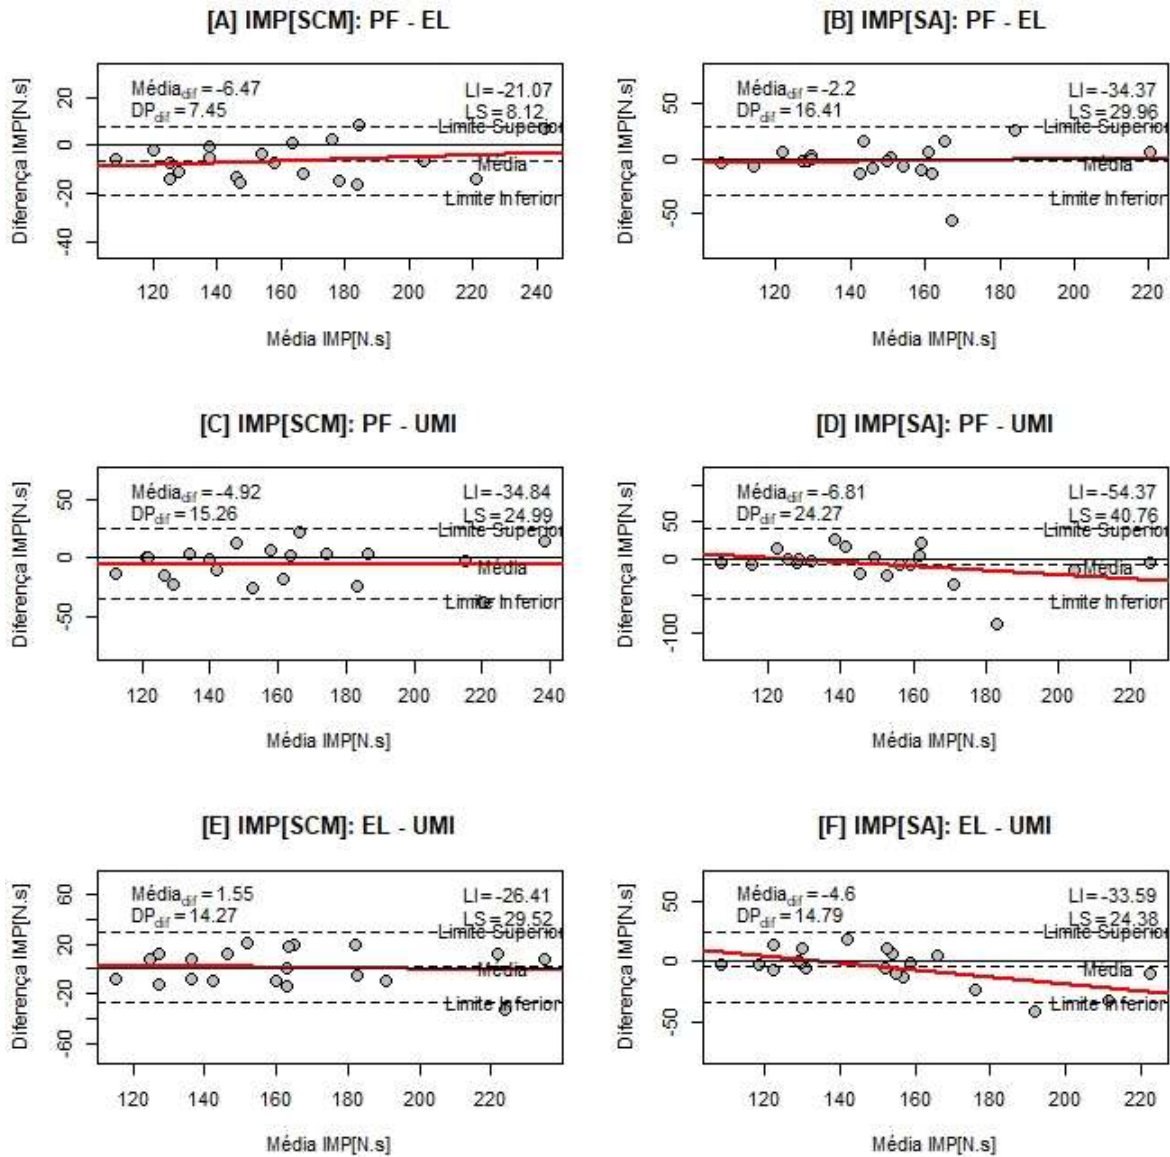
Fonte: Dados da pesquisa.

Figura C5 – Gráfico de Dispersão “Bland-Altman” de concordância entre instrumentos de medição para a variável de velocidade de saída do solo (IMP<sub>SCM</sub> e IMP<sub>SA</sub>): PF e EL ([A] SCM, [B] SA), PF e UMI ([C] SCM, [D] SA) e EL e UMI ([E] SCM, [F] SA) – Sessão 1.




Fonte: Dados da pesquisa.

Figura C6 – Gráfico de Dispersão “Bland-Altman” de concordância entre instrumentos de medição para a variável de velocidade de saída do solo (IMP<sub>SCM</sub> e IMP<sub>SA</sub>): PF e EL ([A] SCM, [B] SA), PF e UMI ([C] SCM, [D] SA) e EL e UMI ([E] SCM, [F] SA) – Sessão 2.



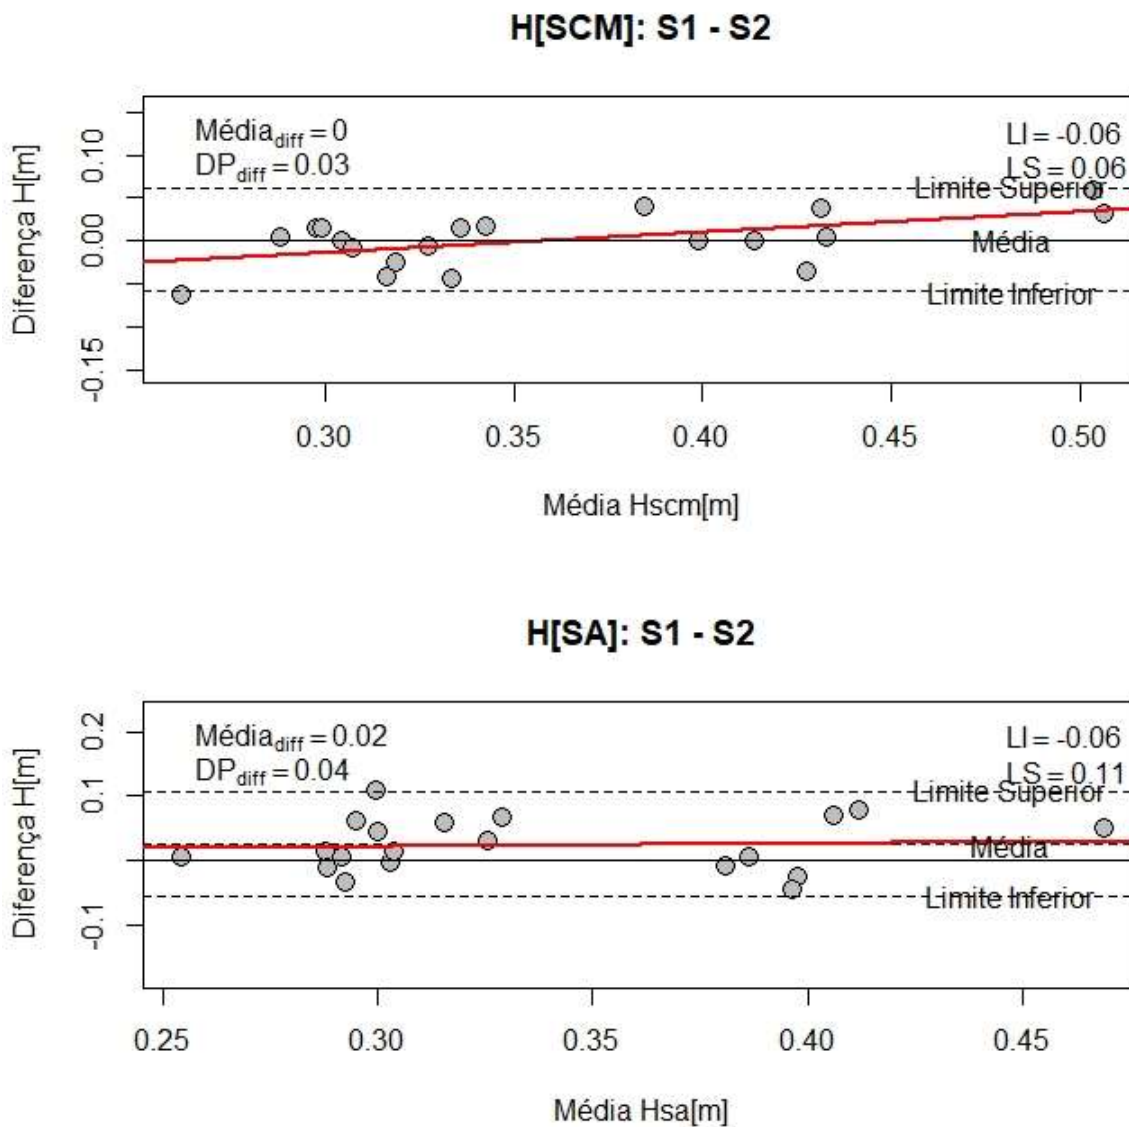
Fonte: Dados da pesquisa.

Figura C7 – Gráfico de Dispersão “Bland-Altman” de concordância entre medições (UMI) obtidas em sessões diferentes para o tempo de voo ( $TV_{SCM}$  e  $TV_{SA}$ ) nos saltos verticais.



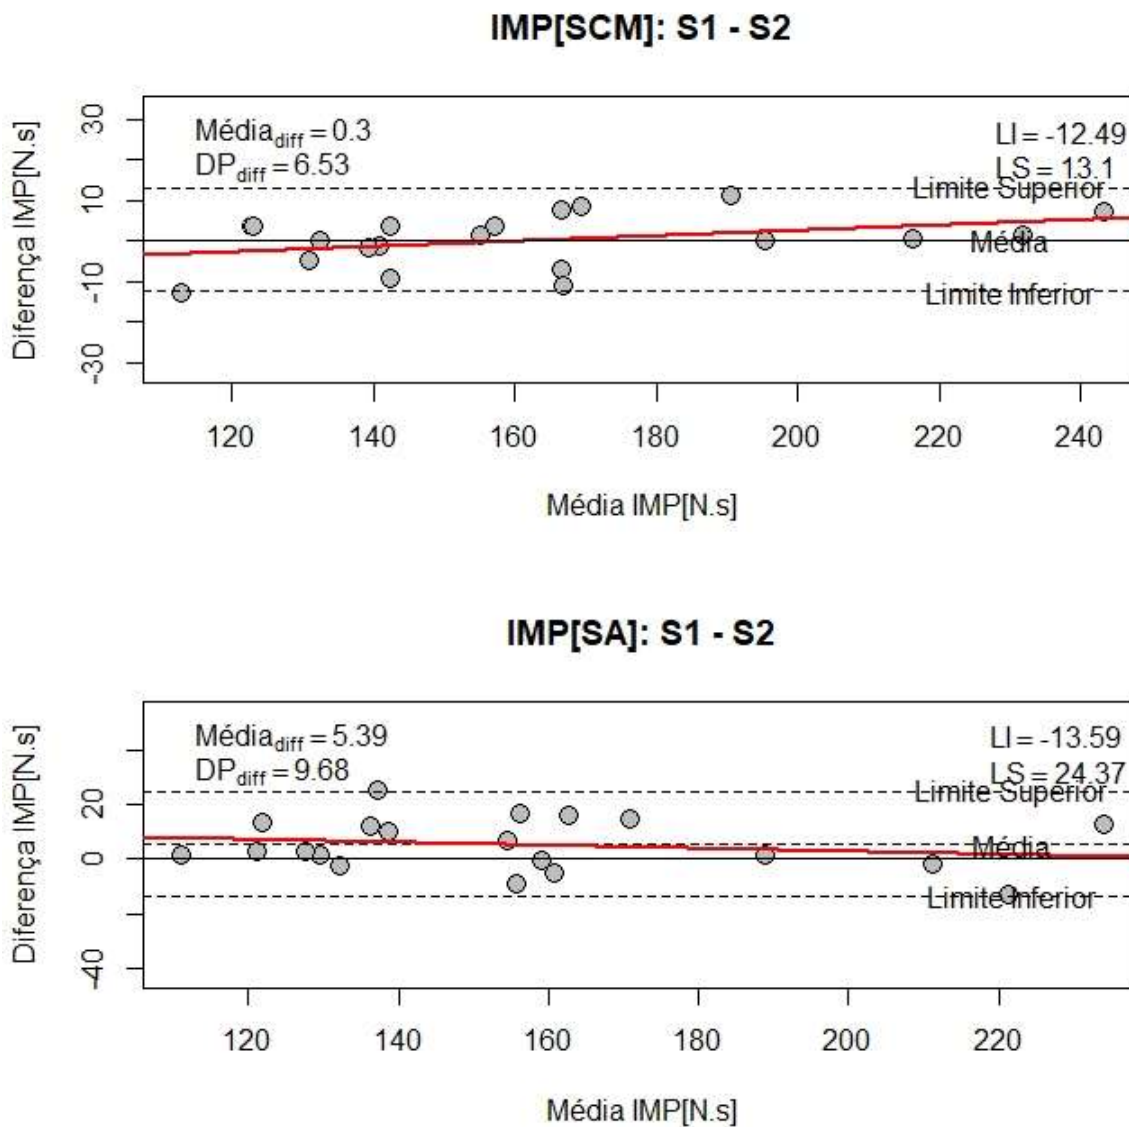
Fonte: Dados da pesquisa.

Figura C8 – Gráfico de Dispersão “Bland-Altman” de concordância entre medições (UMI) obtidas em sessões diferentes para a altura de salto vertical ( $H_{SCM}$  e  $H_{SA}$ ) nos saltos verticais.




Fonte: Dados da pesquisa.

Figura C9 – Gráfico de Dispersão “Bland-Altman” de concordância entre medições (UMI) obtidas em sessões diferentes para o impulso ( $IMP_{SCM}$  e  $IMP_{SA}$ ) nos saltos verticais.



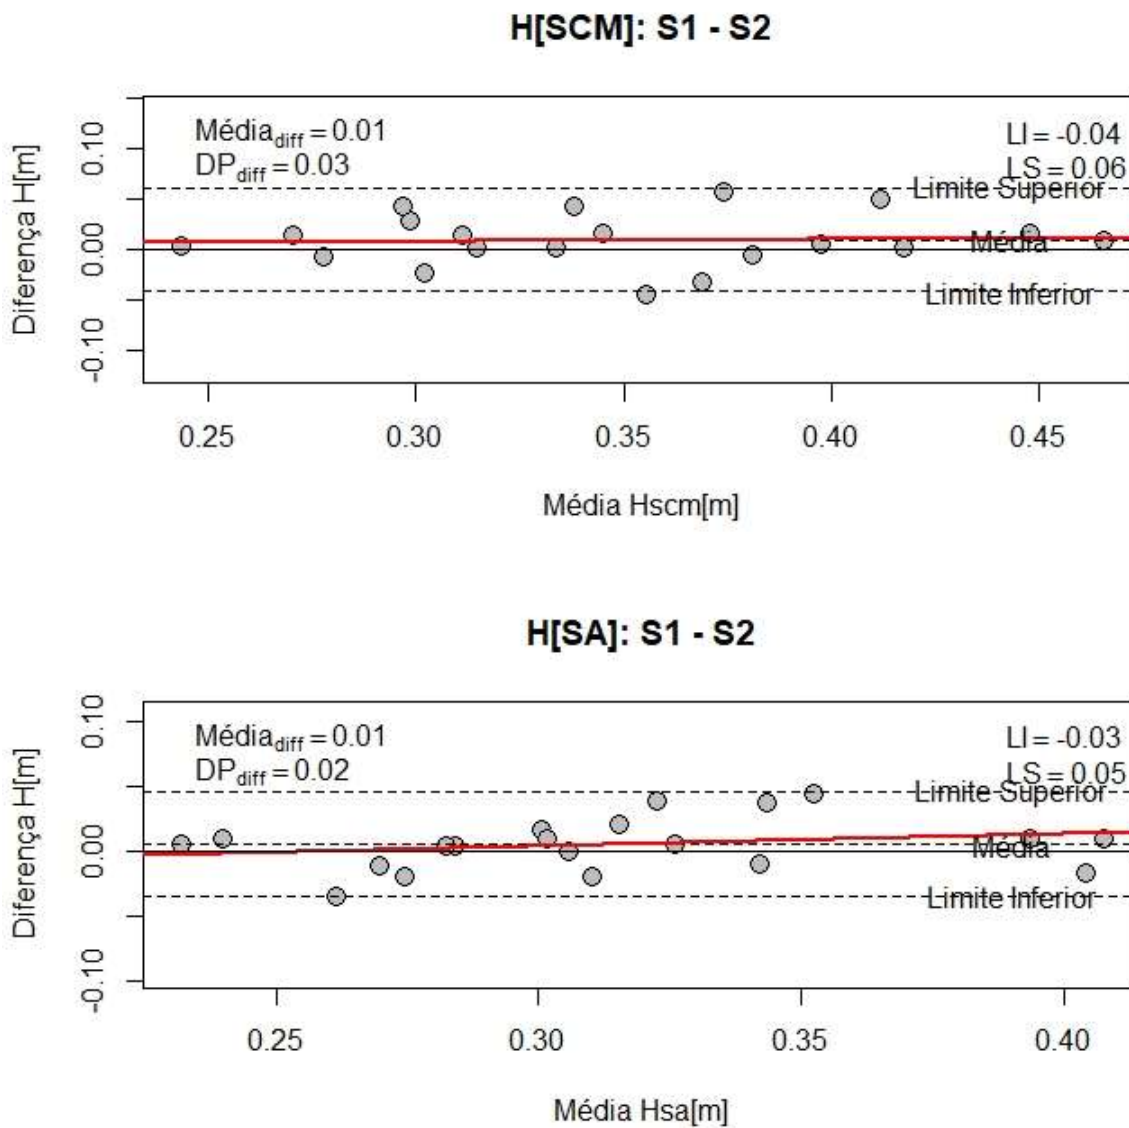
Fonte: Dados da pesquisa.

Figura C10 – Gráfico de Dispersão “Bland-Altman” de concordância entre medições (PF) obtidas em sessões diferentes para o tempo de vôo ( $TV_{SCM}$  e  $TV_{SA}$ ) nos saltos verticais.



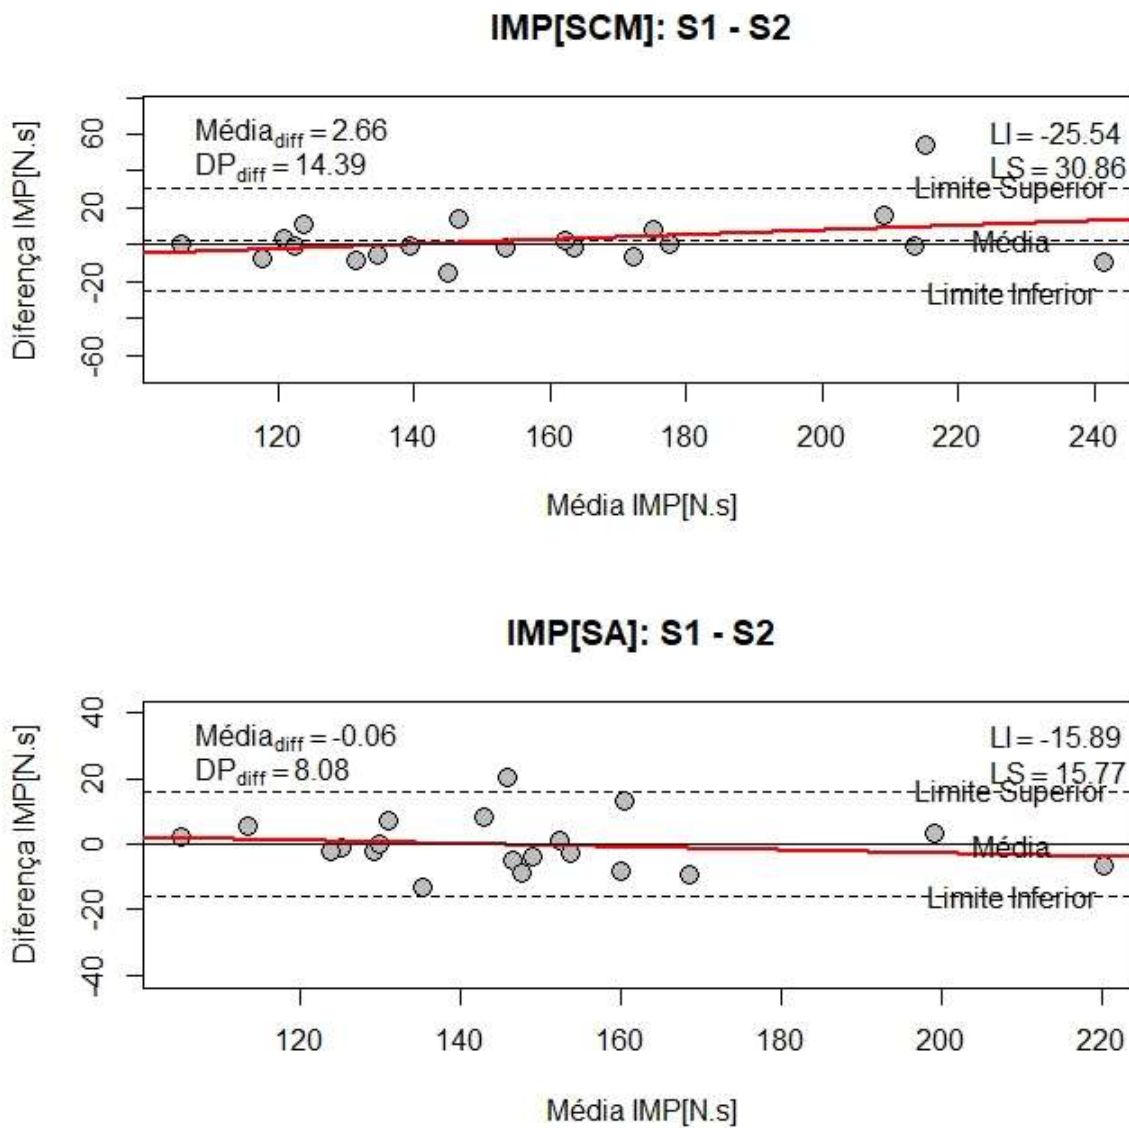
Fonte: Dados da pesquisa.

Figura C11 – Gráfico de Dispersão “Bland-Altman” de concordância entre medições (PF) obtidas em sessões diferentes para o tempo de vôo ( $H_{SCM}$  e  $H_{SA}$ ) nos saltos verticais.



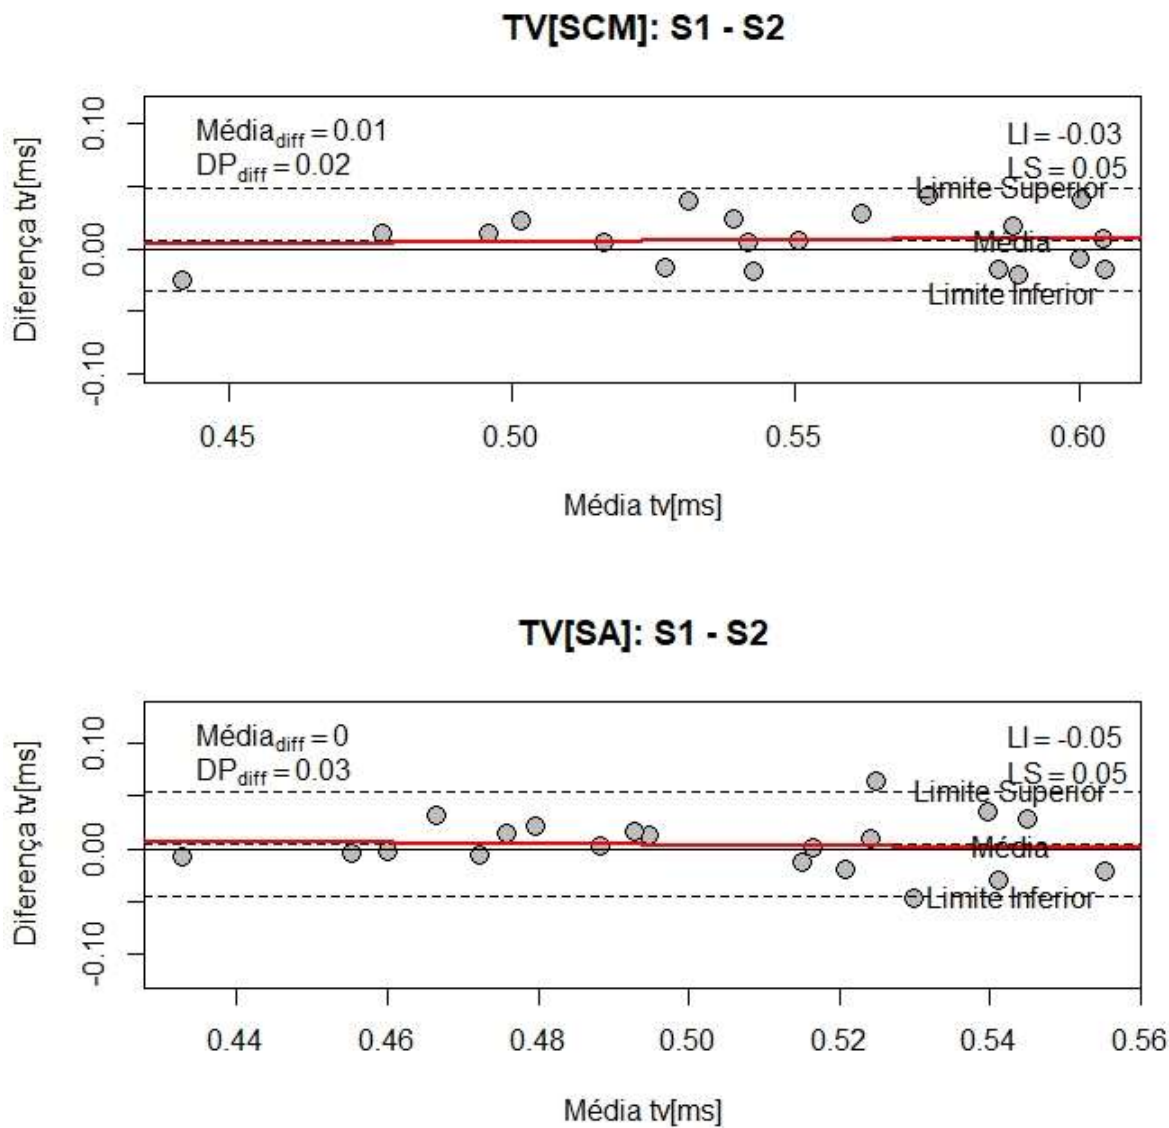
Fonte: Dados da pesquisa.

Figura C12 – Gráfico de Dispersão “Bland-Altman” de concordância entre medições (PF) obtidas em sessões diferentes para o tempo de voo (IMP<sub>SCM</sub> e IMP<sub>SA</sub>) nos saltos verticais.



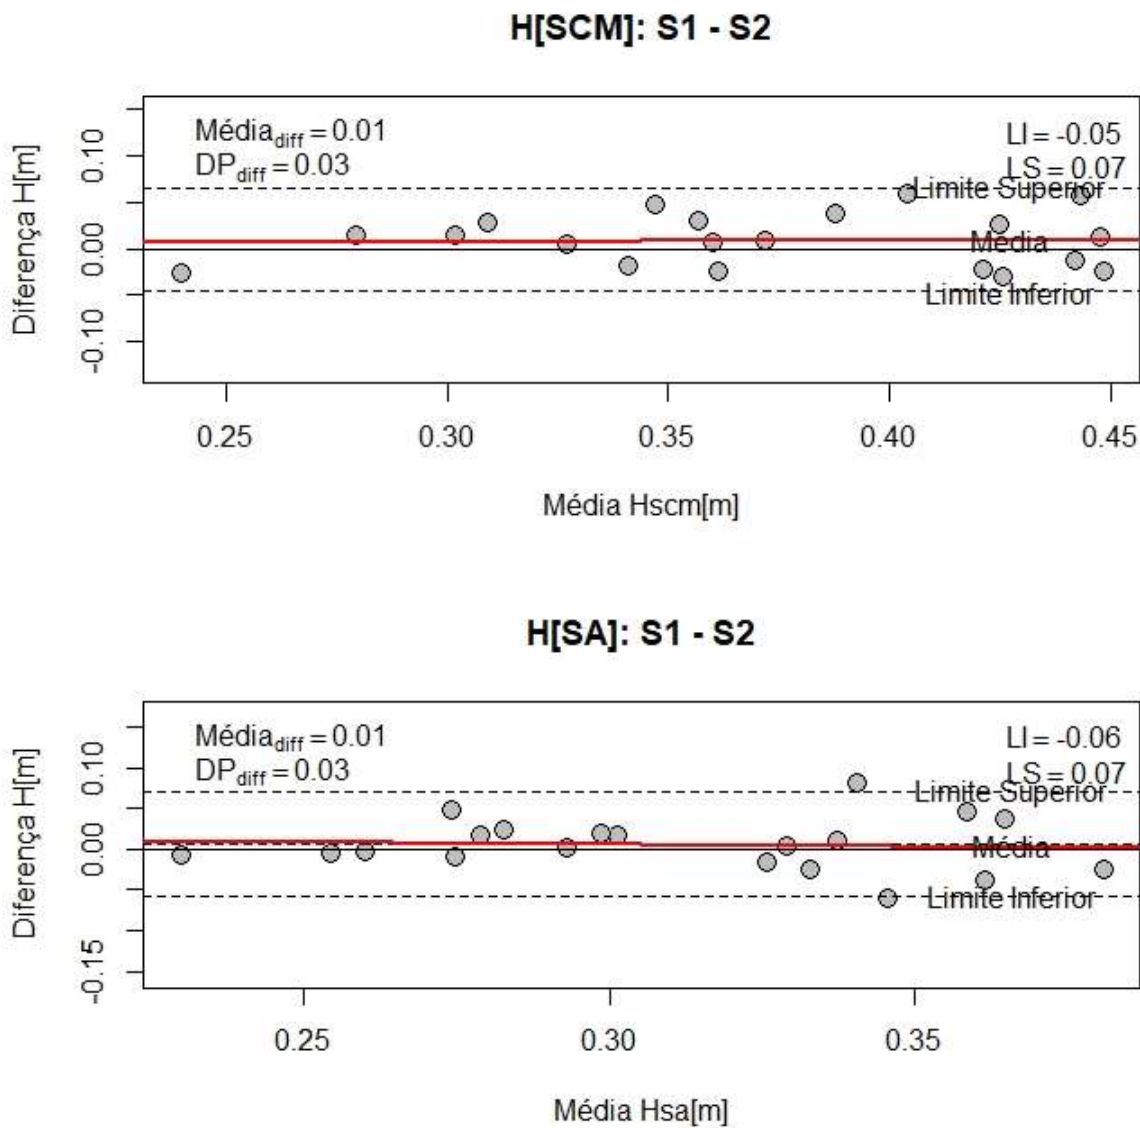
Fonte: Dados da pesquisa.

Figura C13 – Gráfico de Dispersão “Bland-Altman” de concordância entre medições (EL) obtidas em sessões diferentes para o tempo de voo (TV<sub>SCM</sub> e TV<sub>SA</sub>) nos saltos verticais.



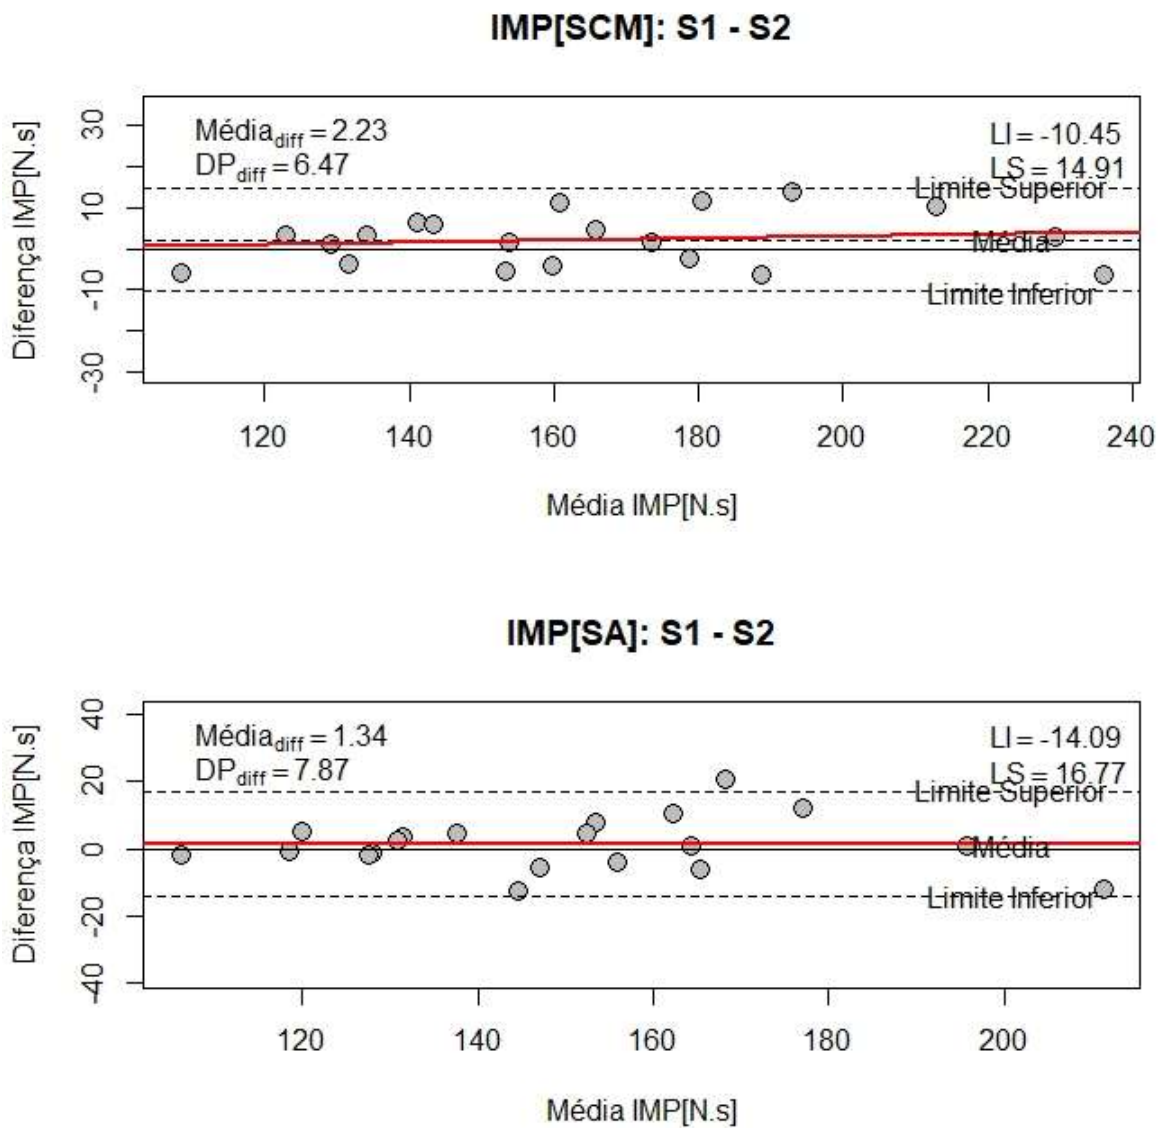
Fonte: Dados da pesquisa.

Figura C14 – Gráfico de Dispersão “Bland-Altman” de concordância entre medições (EL) obtidas em sessões diferentes para o tempo de vôo ( $H_{SCM}$  e  $H_{SA}$ ) nos saltos verticais.



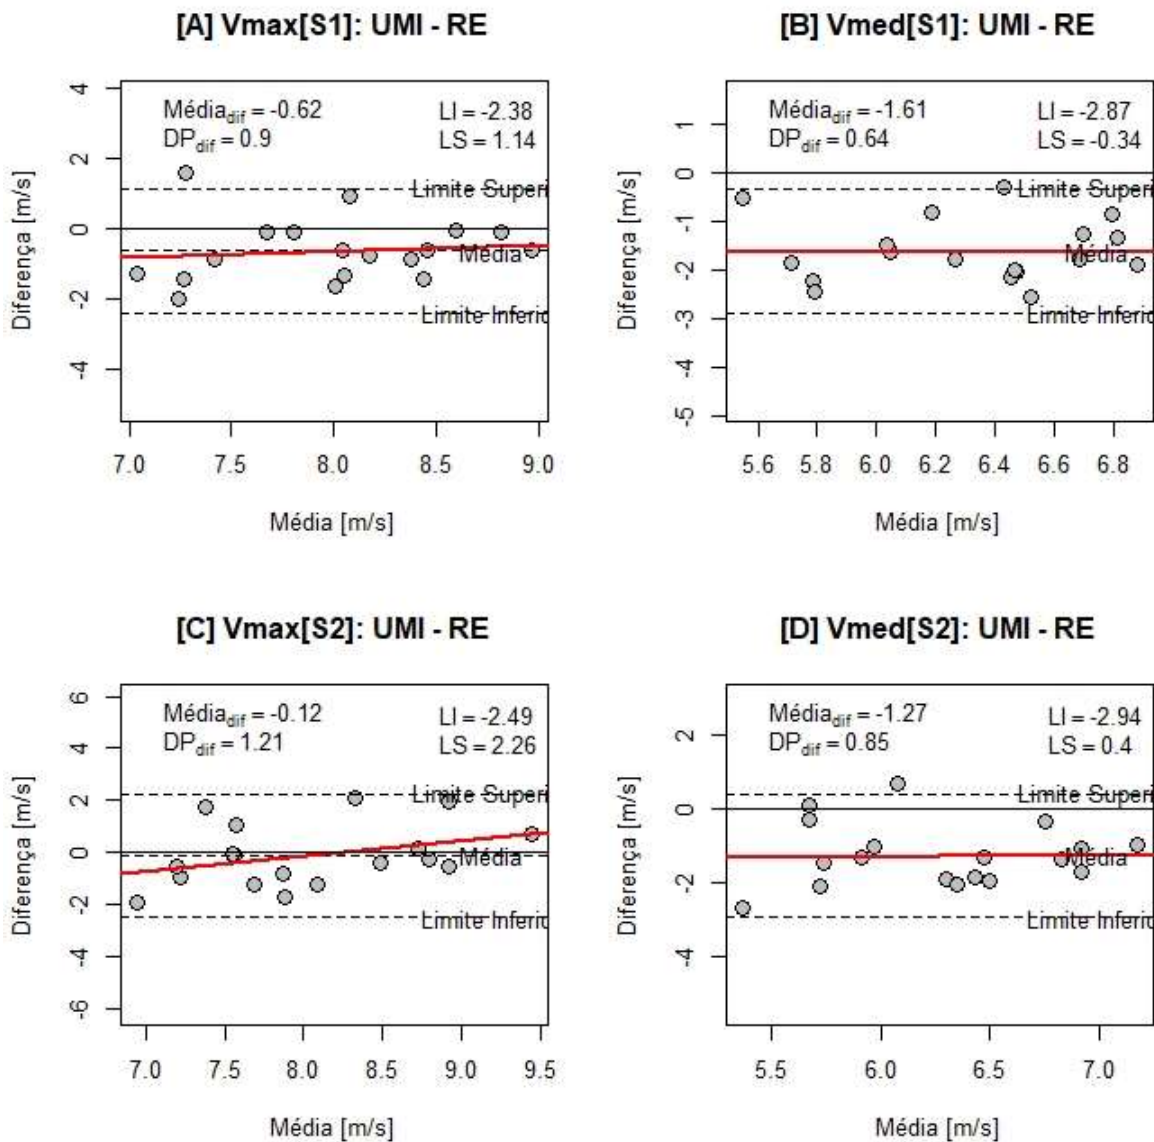
Fonte: Dados da pesquisa.

Figura C15 – Gráfico de Dispersão “Bland-Altman” de concordância entre medições (EL) obtidas em sessões diferentes para o tempo de vôo (IMP<sub>SCM</sub> e IMP<sub>SA</sub>) nos saltos verticais.



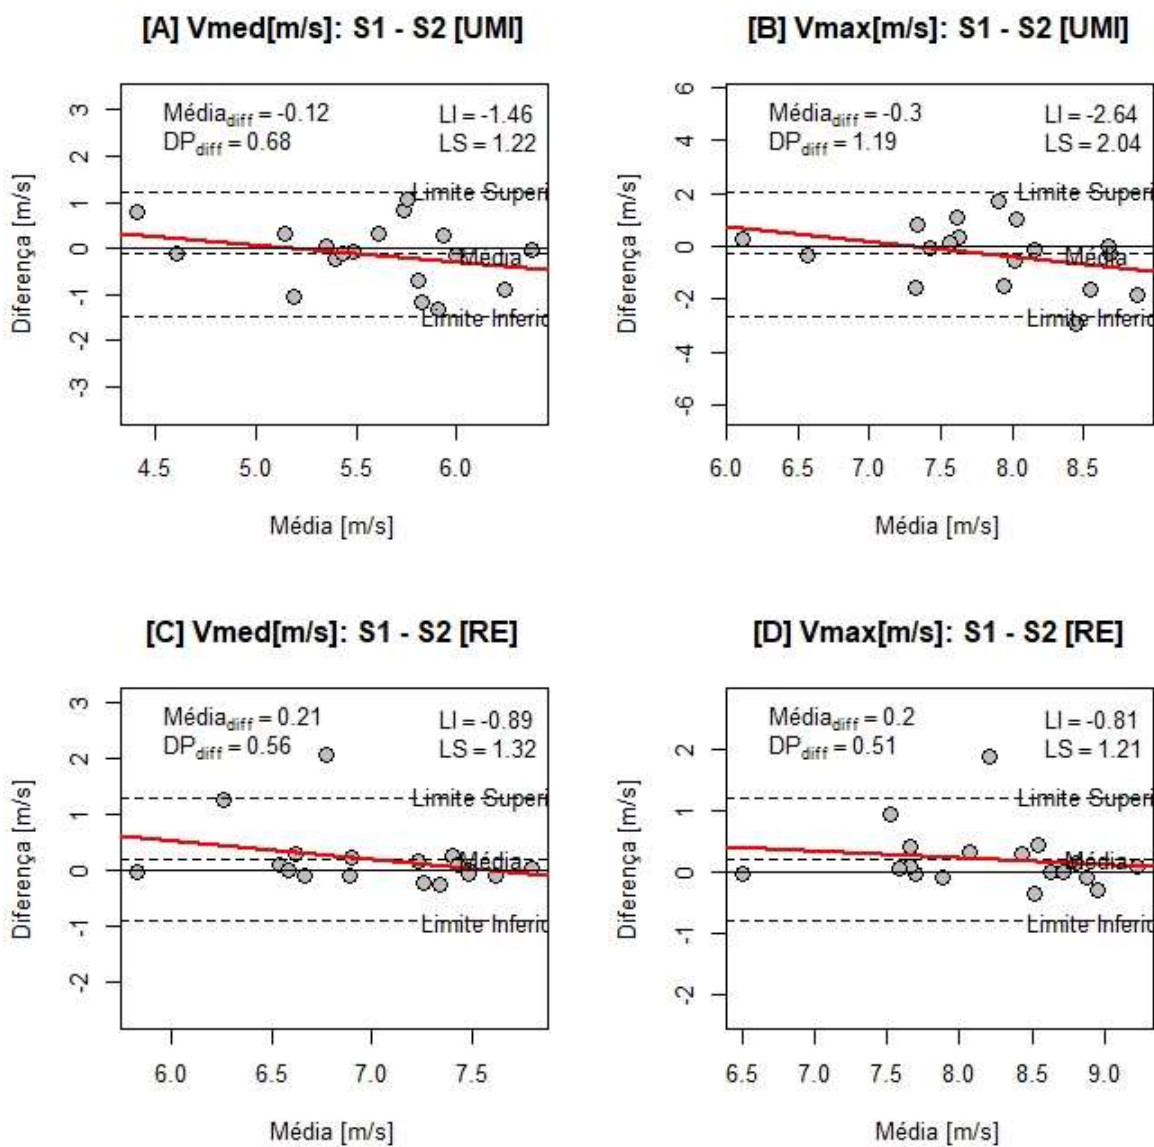
Fonte: Dados da pesquisa.

Figura C16 – Gráficos de Dispersão “Bland-Altman” de concordância entre instrumentos de medição (UMI vs. *Race Encoder* - RE) para as variáveis de  $V_{max}$  e  $V_{med}$  nos *sprints* de 30m (Sessão 1 – S1, Sessão 2 – S2).



Fonte: Dados da pesquisa.

Figura C17 – Gráfico de Dispersão “Bland-Altman” de concordância entre sessões para as variáveis de  $V_{max}$  e  $V_{med}$  nos *sprints* de 30m para UMI e RE.



Fonte: Dados da pesquisa.

## APÊNDICE D – ANÁLISE DE REGRESSÃO LINEAR ENTRE INSTRUMENTOS DE MEDIÇÃO (CAPÍTULO 2).

Tabela D1 – Análise de regressão linear entre instrumentos de medição (PF vs. EL; PF vs. UMI; EL vs. UMI) para as variáveis estudadas.

| SESSÃO 1  |                       |                |         |                      |                |         |
|-----------|-----------------------|----------------|---------|----------------------|----------------|---------|
| VARIÁVEIS | PF vs. EL [SCM]       |                |         | PF vs. EL [SA]       |                |         |
|           | $[y=a\pm bx]$         | R <sup>2</sup> | Resíduo | $[y=a\pm bx]$        | R <sup>2</sup> | Resíduo |
| TV [s]    | EL=0,911PF+0,065**    | 0,798          | 0,021   | EL=0,685PF+0,157**   | 0,646          | 0,021   |
| H [m]     | EL=0,905PF+5,761**    | 0,804          | 0,028   | EL=0,689PF+0,096**   | 0,686          | 0,025   |
| IMP [N.s] | EL=0,781PF+ 40,897**  | 0,803          | 16,14   | EL=0,866PF+23,293**  | 0,750          | 13,72   |
| VARIÁVEIS | PF vs.UMI [SCM]       |                |         | PF vs.UMI [SA]       |                |         |
|           | $[y=a\pm bx]$         | R <sup>2</sup> | Resíduo | $[y=a\pm bx]$        | R <sup>2</sup> | Resíduo |
| TV [s]    | UMI=0,881PF+0,069**   | 0,469          | 0,043   | UMI=0,646PF+0,203**  | 0,348          | 0,038   |
| H [m]     | UMI=0,887PF+4,977**   | 0,473          | 0,060   | UMI=0,690PF+ 0,130** | 0,347          | 0,051   |
| IMP [N.s] | UMI=0,854PF+ 25,808** | 0,830          | 16,11   | UMI=0,948PF+19,889** | 0,567          | 22,70   |
| VARIÁVEIS | EL vs. UMI [SCM]      |                |         | EL vs. UMI [SA]      |                |         |
|           | $[y=a\pm bx]$         | R <sup>2</sup> | Resíduo | $[y=a\pm bx]$        | R <sup>2</sup> | Resíduo |
| TV [s]    | UMI=0,881EL+0,069**   | 0,414          | 0,046   | UMI=0,621EL+0,217**  | 0,348          | 0,042   |
| H [m]     | UMI=0,887EL+0,049**   | 0,381          | 0,065   | UMI=0,677EL+ 0,136** | 0,231          | 0,056   |
| IMP [N.s] | UMI= 0,994EL-2,504**  | 0,855          | 14,87   | UMI=1,144EL-13,075** | 0,827          | 14,36   |
| SESSÃO 2  |                       |                |         |                      |                |         |
| VARIÁVEIS | PF vs. EL [SCM]       |                |         | PF vs. EL [SA]       |                |         |
|           | $[y=a\pm bx]$         | R <sup>2</sup> | Resíduo | $[y=a\pm bx]$        | R <sup>2</sup> | Resíduo |
| TV [s]    | PF=0,918EL+0,026**    | 0,821          | 0,019   | PF=0,832EL+0,086**   | 0,628          | 0,023   |
| H [m]     | PF=0,898EL+0,013**    | 0,814          | 0,026   | PF=0,847EL+0,049**   | 0,632          | 0,029   |
| IMP [N.s] | PF=1,019EL-9,698**    | 0,955          | 7,621   | PF=0,857EL+19,009**  | 0,655          | 16,400  |
| VARIÁVEIS | PF vs.UMI [SCM]       |                |         | PF vs.UMI [SA]       |                |         |
|           | $[y=a\pm bx]$         | R <sup>2</sup> | Resíduo | $[y=a\pm bx]$        | R <sup>2</sup> | Resíduo |
| TV [s]    | PF=0,509UMI+0,251**   | 0,227          | 0,041   | PF=0,466UMI+0,263**  | 0,274          | 0,033   |
| H [m]     | PF=0,477UMI+0,170**   | 0,209          | 0,054   | PF=0,440UMI+0,168**  | 0,252          | 0,041   |
| IMP [N.s] | PF=0,918UMI+8,290 **  | 0,817          | 15,390  | PF=0,576UMI+58,386** | 0,509          | 19,570  |
| VARIÁVEIS | EL vs. UMI [SCM]      |                |         | EL vs. UMI [SA]      |                |         |
|           | $[y=a\pm bx]$         | R <sup>2</sup> | Resíduo | $[y=a\pm bx]$        | R <sup>2</sup> | Resíduo |
| TV [s]    | EL=0,509UMI+0,270**   | 0,231          | 0,040   | EL=0,368UMI+0,311**  | 0,164          | 0,034   |
| H [m]     | EL=0,492UMI+0,189**   | 0,220          | 0,054   | EL=0,349UMI+0,194**  | 0,158          | 0,042   |
| IMP [N.s] | EL=0,889UMI+19,435**  | 0,833          | 14,090  | EL=0,697UMI+42,002** | 0,847          | 10,440  |

\*\*Indica que o coeficiente de regressão do modelo ajustado é significativo (p<0,05).

Tabela D2 – Análise de regressão linear entre instrumentos de medição (UMI vs. *Race Encoder*® - RE) para as variáveis estudadas.

| VARIÁVEIS | UMI vs. RE [SESSÃO 1]  |                |         | UMI vs. RE [SESSÃO 2]  |                |         |
|-----------|------------------------|----------------|---------|------------------------|----------------|---------|
|           | Modelo [ $y=a\pm bx$ ] | R <sup>2</sup> | Resíduo | Modelo [ $y=a\pm bx$ ] | R <sup>2</sup> | Resíduo |
| $V_{max}$ | UMI=0,267RE+5,457      | 0,058          | 0,764   | UMI=0,257RE+5,889      | 0,032          | 1,107   |
| $V_{med}$ | UMI=0,249RE+3,731      | 0,059          | 0,530   | UMI=0,216RE+4,137      | 0,044          | 0,692   |

**APÊNDICE E – MATRIZ DE CONFUSÃO ABSOLUTA E RELATIVA DE DESEMPENHO DE CLASSIFICAÇÃO DAS AÇÕES PARA OS ALGORITMOS DE MELHOR DESEMPENHO PARA OS CONJUNTOS DE DADOS DE TREINAMENTO E TESTE (CAPÍTULO 3).**


Figura E1 – Matriz de confusão absoluta (A) para o conjunto de dados de treinamento (ACC1 – m=54) utilizando o algoritmo *k*-NN “fine” e *k*-fold cross-validation.

**[A] k - NN (Fine) [Valores absolutos] - TREINAMENTO**

|                   |                 |                  |                 |     |        |        |     |         |
|-------------------|-----------------|------------------|-----------------|-----|--------|--------|-----|---------|
| Classe Verdadeira | CorridaLeve     | 151              | 9               |     |        |        |     |         |
|                   | CorridaModerada | 15               | 122             | 15  |        |        | 9   |         |
|                   | MMD             |                  | 20              | 143 |        |        | 9   |         |
|                   | Marcha          |                  |                 |     | 178    |        | 1   |         |
|                   | Parada          |                  |                 |     |        | 171    | 1   | 3       |
|                   | SCM             | 1                |                 |     |        | 2      | 176 |         |
|                   | Sprints         |                  | 7               | 7   | 2      | 3      |     | 158     |
|                   |                 | CorridaLeve      | CorridaModerada | MMD | Marcha | Parada | SCM | Sprints |
|                   |                 | Classe Preditada |                 |     |        |        |     |         |

Fonte: Dados da pesquisa.

Figura E2 – Matriz de confusão relativa (B) para o conjunto de dados de treinamento (ACC1 – m=54) utilizando o algoritmo *k*-NN “fine” e *k*-fold cross-validation.



Fonte: Dados da pesquisa.

TPR - “True Positive Rates” – Verdadeiros Positivos (%) ou sensibilidade; FNR - “False Negative Rates” – Falsos Negativos (%).

Figura E3 – Matriz de confusão relativa (C) para o conjunto de dados de treinamento (ACC1 – m=54) utilizando o algoritmo k-NN “fine” e *k-fold cross-validation*.

**[C] k - NN (Fine) [%] - TREINAMENTO**

|                   |                 |                |                 |       |        |        |       |         |
|-------------------|-----------------|----------------|-----------------|-------|--------|--------|-------|---------|
| Classe Verdadeira | CorridaLeve     | 90.4%          | 5.7%            |       |        |        |       |         |
|                   | CorridaModerada | 9.0%           | 77.2%           | 9.1%  |        |        | 5.0%  |         |
|                   | MMD             |                | 12.7%           | 86.7% |        |        | 5.0%  |         |
|                   | Marcha          |                |                 |       | 98.9%  |        | 0.6%  |         |
|                   | Parada          |                |                 |       |        | 97.2%  | 0.6%  |         |
|                   | SCM             | 0.6%           |                 |       |        | 1.1%   | 99.4% |         |
|                   | Sprints         |                | 4.4%            | 4.2%  | 1.1%   | 1.7%   | 87.8% |         |
|                   |                 |                |                 |       |        |        |       |         |
|                   | PPV             | 90.4%          | 77.2%           | 86.7% | 98.9%  | 97.2%  | 99.4% |         |
|                   | FDR             | 9.6%           | 22.8%           | 13.3% | 1.1%   | 2.8%   | 0.6%  |         |
|                   |                 | CorridaLeve    | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints |
|                   |                 | Classe Predita |                 |       |        |        |       |         |

Fonte: Dados da pesquisa.

PPV - “Positive Predictive Values” – Valores Preditivos Positivos (%) ou precisão; FDR - “False Discovery Rates” – Falsas Descobertas (%) ou Falsos Positivos.

Figura E4 – Matriz de confusão absoluta (A) para o conjunto de dados de treinamento (ACC2 – m=83) utilizando o algoritmo Ensemble (*Bagged Trees*) e *k-fold cross-validation*.

**[A] Ensemble (Bagged Trees) [valores absolutos] - TREINAMENTO**

|                   |                 |             |                 |     |        |        |     |         |
|-------------------|-----------------|-------------|-----------------|-----|--------|--------|-----|---------|
| Classe Verdadeira | CorridaLeve     | 137         | 14              | 5   |        |        | 4   |         |
|                   | CorridaModerada | 19          | 106             | 26  |        |        | 1   | 9       |
|                   | MMD             | 8           | 20              | 130 |        |        | 3   | 11      |
|                   | Marcha          |             | 1               | 1   | 176    |        |     | 1       |
|                   | Parada          |             |                 | 1   |        | 167    | 5   | 2       |
|                   | SCM             | 1           | 3               | 3   | 1      | 3      | 168 |         |
|                   | Sprints         | 2           | 7               | 5   | 1      | 4      | 1   | 157     |
|                   |                 | CorridaLeve | CorridaModerada | MMD | Marcha | Parada | SCM | Sprints |
|                   | Classe Predita  |             |                 |     |        |        |     |         |

Fonte: Dados da pesquisa.

Figura E5 – Matriz de confusão relativa (B) para o conjunto de dados de treinamento (ACC2 – m=83) utilizando o algoritmo Ensemble (*Bagged Trees*) e *k-fold cross-validation*.

**[B] Ensemble (Bagged Trees) [%] - TREINAMENTO**

|                   |                 |                |                 |       |        |        |       |         |       |       |
|-------------------|-----------------|----------------|-----------------|-------|--------|--------|-------|---------|-------|-------|
| Classe Verdadeira | CorridaLeve     | 85.6%          | 8.8%            | 3.1%  |        |        | 2.5%  |         | 85.6% | 14.4% |
|                   | CorridaModerada | 11.8%          | 65.8%           | 16.1% |        |        | 0.6%  | 5.6%    | 65.8% | 34.2% |
|                   | MMD             | 4.7%           | 11.6%           | 75.6% |        |        | 1.7%  | 6.4%    | 75.6% | 24.4% |
|                   | Marcha          |                | 0.6%            | 0.6%  | 98.3%  |        |       | 0.6%    | 98.3% | 1.7%  |
|                   | Parada          |                |                 | 0.6%  |        | 95.4%  | 2.9%  | 1.1%    | 95.4% | 4.6%  |
|                   | SCM             | 0.6%           | 1.7%            | 1.7%  | 0.6%   | 1.7%   | 93.9% |         | 93.9% | 6.1%  |
|                   | Sprints         | 1.1%           | 4.0%            | 2.8%  | 0.6%   | 2.3%   | 0.6%  | 88.7%   | 88.7% | 11.3% |
|                   |                 |                |                 |       |        |        |       |         | TPR   | FNR   |
|                   |                 | CorridaLeve    | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints |       |       |
|                   |                 | Classe Predita |                 |       |        |        |       |         |       |       |

Fonte: Dados da pesquisa.

TPR - “True Positive Rates” – Verdadeiros Positivos (%) ou sensibilidade; FNR - “False Negative Rates” – Falsos Negativos (%).

Figura E6 – Matriz de confusão relativa (C) para o conjunto de dados de treinamento (ACC2 – m=83) utilizando o algoritmo Ensemble (*Bagged Trees*) e *k-fold cross-validation*.

**[C] Ensemble (Bagged Trees) [%] - TREINAMENTO**

|                   |                 |                |                 |       |        |        |       |         |
|-------------------|-----------------|----------------|-----------------|-------|--------|--------|-------|---------|
| Classe Verdadeira | CorridaLeve     | 82.0%          | 9.3%            | 2.9%  |        |        | 2.2%  |         |
|                   | CorridaModerada | 11.4%          | 70.2%           | 15.2% |        |        | 0.5%  | 5.0%    |
|                   | MMD             | 4.8%           | 13.2%           | 76.0% |        |        | 1.6%  | 6.1%    |
|                   | Marcha          |                | 0.7%            | 0.6%  | 98.9%  |        |       | 0.6%    |
|                   | Parada          |                |                 | 0.6%  |        | 96.0%  | 2.7%  | 1.1%    |
|                   | SCM             | 0.6%           | 2.0%            | 1.8%  | 0.6%   | 1.7%   | 92.3% |         |
|                   | Sprints         | 1.2%           | 4.6%            | 2.9%  | 0.6%   | 2.3%   | 0.5%  | 87.2%   |
|                   | PPV             | 82.0%          | 70.2%           | 76.0% | 98.9%  | 96.0%  | 92.3% | 87.2%   |
|                   | FDR             | 18.0%          | 29.8%           | 24.0% | 1.1%   | 4.0%   | 7.7%  | 12.8%   |
|                   |                 | CorridaLeve    | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints |
|                   |                 | Classe Predita |                 |       |        |        |       |         |

Fonte: Dados da pesquisa.

PPV - “Positive Predictive Values” – Valores Preditivos Positivos (%) ou precisão; FDR - “False Discovery Rates” – Falsas Descobertas (%).


Figura E7 – Matriz de confusão absoluta (A) para o conjunto de dados de treinamento (ACC3, m=138) utilizando o algoritmo Ensemble (*Bagged Trees*) e *k-fold cross-validation*.

**[A] Ensemble (Bagged Trees) [valores absolutos] - TREINAMENTO**

|                   |                 |                |                 |     |        |        |     |         |
|-------------------|-----------------|----------------|-----------------|-----|--------|--------|-----|---------|
| Classe Verdadeira | CorridaLeve     | 143            | 10              | 6   |        |        |     | 1       |
|                   | CorridaModerada | 12             | 121             | 26  |        | 1      | 1   |         |
|                   | MMD             | 4              | 41              | 122 |        |        | 1   | 4       |
|                   | Marcha          |                |                 |     | 177    | 1      |     | 1       |
|                   | Parada          |                |                 |     |        | 174    |     | 1       |
|                   | SCM             | 1              | 1               |     | 1      |        | 176 |         |
|                   | Sprints         | 1              | 1               | 2   |        | 7      |     | 166     |
|                   |                 | CorridaLeve    | CorridaModerada | MMD | Marcha | Parada | SCM | Sprints |
|                   |                 | Classe Predita |                 |     |        |        |     |         |

Fonte: Dados da pesquisa.

Figura E8 – Matriz de confusão relativa (B) para o conjunto de dados de treinamento (ACC3, m=138) utilizando o algoritmo Ensemble (*Bagged Trees*) e *k-fold cross-validation*.



Fonte: Dados da pesquisa.

TPR - “True Positive Rates” – Verdadeiros Positivos (%) ou sensibilidade; FNR - “False Negative Rates” – Falsos Negativos (%).

Figura E9 – Matriz de confusão relativa (C) para o conjunto de dados de treinamento (ACC3, m=138) utilizando o algoritmo Ensemble (*Bagged Trees*) e *k-fold cross-validation*.

**[C] Ensemble (Bagged Trees) [%] - TREINAMENTO**

|                   |                 |                |                 |       |        |        |       |         |
|-------------------|-----------------|----------------|-----------------|-------|--------|--------|-------|---------|
| Classe Verdadeira | CorridaLeve     | 88.8%          | 5.7%            | 3.8%  |        |        |       | 0.6%    |
|                   | CorridaModerada | 7.5%           | 69.5%           | 16.7% |        | 0.5%   | 0.6%  |         |
|                   | MMD             | 2.5%           | 23.6%           | 78.2% |        |        | 0.6%  | 2.3%    |
|                   | Marcha          |                |                 |       | 99.4%  | 0.5%   |       | 0.6%    |
|                   | Parada          |                |                 |       |        | 95.1%  |       | 0.6%    |
|                   | SCM             | 0.6%           | 0.6%            |       | 0.6%   |        | 98.9% |         |
|                   | Sprints         | 0.6%           | 0.6%            | 1.3%  |        | 3.8%   |       | 96.0%   |
|                   | PPV             | 88.8%          | 69.5%           | 78.2% | 99.4%  | 95.1%  | 98.9% | 96.0%   |
|                   | FDR             | 11.2%          | 30.5%           | 21.8% | 0.6%   | 4.9%   | 1.1%  | 4.0%    |
|                   |                 | CorridaLeve    | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints |
|                   |                 | Classe Predita |                 |       |        |        |       |         |

Fonte: Dados da pesquisa.

PPV - “*Positive Predictive Values*” – Valores Preditivos Positivos (%) ou precisão; FDR - “*False Discovery Rates*” – Falsas Descobertas (%).


Figura E10 – Matriz de confusão absoluta (A) para o conjunto de dados de treinamento (ACC1+GIR1, m=99) utilizando o algoritmo Ensemble (*Bagged Trees*) e *k-fold cross-validation*.

**[A] Ensemble (Bagged Trees) [valores absolutos] - TREINAMENTO**

|                   |                 |                |                 |     |        |        |     |         |
|-------------------|-----------------|----------------|-----------------|-----|--------|--------|-----|---------|
| Classe Verdadeira | CorridaLeve     | 146            | 12              |     | 2      |        |     |         |
|                   | CorridaModerada | 17             | 124             | 9   |        |        |     | 11      |
|                   | MMD             | 2              | 20              | 120 |        |        | 2   | 28      |
|                   | Marcha          | 1              |                 |     | 178    |        |     |         |
|                   | Parada          |                |                 |     | 1      | 173    |     | 1       |
|                   | SCM             | 2              |                 |     |        | 1      | 176 |         |
|                   | Sprints         | 1              | 11              | 11  | 1      | 5      |     | 148     |
|                   |                 | CorridaLeve    | CorridaModerada | MMD | Marcha | Parada | SCM | Sprints |
|                   |                 | Classe Predita |                 |     |        |        |     |         |

Fonte: Dados da pesquisa.

Figura E11 – Matriz de confusão relativa (B) para o conjunto de dados de treinamento (ACC1+GIR1, m=99) utilizando o algoritmo Ensemble (*Bagged Trees*) e *k-fold cross-validation*.



Fonte: Dados da pesquisa.

TPR - “True Positive Rates” – Verdadeiros Positivos (%) ou sensibilidade; FNR - “False Negative Rates” – Falsos Negativos (%).

Figura E12 – Matriz de confusão relativa (C) para o conjunto de dados de treinamento (ACC1+GIR1, m=99) utilizando o algoritmo Ensemble (*Bagged Trees*) e *k-fold cross-validation*.

**[C] Ensemble (Bagged Trees) [%] - TREINAMENTO**

|                   |                 |                |                 |       |        |        |       |         |
|-------------------|-----------------|----------------|-----------------|-------|--------|--------|-------|---------|
| Classe Verdadeira | CorridaLeve     | 86.4%          | 7.2%            |       | 1.1%   |        |       |         |
|                   | CorridaModerada | 10.1%          | 74.3%           | 6.4%  |        |        |       | 5.9%    |
|                   | MMD             | 1.2%           | 12.0%           | 85.7% |        |        | 1.1%  | 14.9%   |
|                   | Marcha          | 0.6%           |                 |       | 97.8%  |        |       |         |
|                   | Parada          |                |                 |       | 0.5%   | 96.6%  |       | 0.5%    |
|                   | SCM             | 1.2%           |                 |       |        | 0.6%   | 98.9% |         |
|                   | Sprints         | 0.6%           | 6.6%            | 7.9%  | 0.5%   | 2.8%   |       | 78.7%   |
|                   | PPV             | 86.4%          | 74.3%           | 85.7% | 97.8%  | 96.6%  | 98.9% | 78.7%   |
|                   | FDR             | 13.6%          | 25.7%           | 14.3% | 2.2%   | 3.4%   | 1.1%  | 21.3%   |
|                   |                 | CorridaLeve    | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints |
|                   |                 | Classe Predita |                 |       |        |        |       |         |

Fonte: Dados da pesquisa.

PPV - “Positive Predictive Values” – Valores Preditivos Positivos (%) ou precisão; FDR - “False Discovery Rates” – Falsas Descobertas (%) ou Falsos Positivos.


Figura E13 – Matriz de confusão absoluta (A) para o conjunto de dados de treinamento (ACC2+GIR1, m=131) utilizando o algoritmo Ensemble (*Bagged Trees*) e *k-fold cross-validation*.

**[A] Ensemble (Bagged Trees) [valores absolutos] - TREINAMENTO**

|                   |                 |                |                 |     |        |        |     |         |
|-------------------|-----------------|----------------|-----------------|-----|--------|--------|-----|---------|
| Classe Verdadeira | CorridaLeve     | 147            | 11              |     | 2      |        |     |         |
|                   | CorridaModerada | 17             | 123             | 10  |        |        |     | 11      |
|                   | MMD             | 2              | 21              | 123 |        |        |     | 26      |
|                   | Marcha          | 1              |                 |     | 177    |        |     | 1       |
|                   | Parada          |                |                 |     | 1      | 172    |     | 2       |
|                   | SCM             | 4              |                 |     |        | 1      | 174 |         |
|                   | Sprints         | 2              | 8               | 12  | 1      | 5      | 1   | 148     |
|                   |                 | CorridaLeve    | CorridaModerada | MMD | Marcha | Parada | SCM | Sprints |
|                   |                 | Classe Predita |                 |     |        |        |     |         |

Fonte: Dados da pesquisa.

Figura E14 – Matriz de confusão relativa (B) para o conjunto de dados de treinamento (ACC2+GIR1, m=131) utilizando o algoritmo Ensemble (*Bagged Trees*) e *k-fold cross-validation*.



Fonte: Dados da pesquisa.

TPR - “*True Positive Rates*” – Verdadeiros Positivos (%) ou sensibilidade; FNR - “*False Negative Rates*” – Falsos Negativos (%).

Figura E15 – Matriz de confusão relativa (C) para o conjunto de dados de treinamento (ACC2+GIR1, m=131) utilizando o algoritmo Ensemble (*Bagged Trees*) e *k-fold cross-validation*.

**[C] Ensemble (Bagged Trees) [%] - TREINAMENTO**

|                   |                 |                |                 |       |        |        |       |         |
|-------------------|-----------------|----------------|-----------------|-------|--------|--------|-------|---------|
| Classe Verdadeira | CorridaLeve     | 85.0%          | 6.7%            |       | 1.1%   |        |       |         |
|                   | CorridaModerada | 9.8%           | 75.5%           | 6.9%  |        |        |       | 5.9%    |
|                   | MMD             | 1.2%           | 12.9%           | 84.8% |        |        |       | 13.8%   |
|                   | Marcha          | 0.6%           |                 |       | 97.8%  |        |       | 0.5%    |
|                   | Parada          |                |                 |       | 0.6%   | 96.6%  |       | 1.1%    |
|                   | SCM             | 2.3%           |                 |       |        | 0.6%   | 99.4% |         |
|                   | Sprints         | 1.2%           | 4.9%            | 8.3%  | 0.6%   | 2.8%   | 0.6%  | 78.7%   |
|                   | PPV             | 85.0%          | 75.5%           | 84.8% | 97.8%  | 96.6%  | 99.4% | 78.7%   |
|                   | FDR             | 15.0%          | 24.5%           | 15.2% | 2.2%   | 3.4%   | 0.6%  | 21.3%   |
|                   |                 | CorridaLeve    | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints |
|                   |                 | Classe Predita |                 |       |        |        |       |         |

Fonte: Dados da pesquisa.

PPV - “*Positive Predictive Values*” – Valores Preditivos Positivos (%) ou precisão; FDR - “*False Discovery Rates*” – Falsas Descobertas (%) ou Falsos Positivos.

Figura E16 – Matriz de confusão absoluta (A) para o conjunto de dados de teste (ACC1, m = 54) utilizando o algoritmo k-NN “fine”.

**[A] k - NN (Fine) [Valores absolutos] - TESTE**

|                   |                 |                |                 |     |        |        |     |         |
|-------------------|-----------------|----------------|-----------------|-----|--------|--------|-----|---------|
| Classe Verdadeira | CorridaLeve     | 62             | 3               | 1   |        |        | 2   |         |
|                   | CorridaModerada | 1              | 59              | 8   |        |        |     | 2       |
|                   | MMD             | 2              | 8               | 47  | 1      |        | 1   | 16      |
|                   | Marcha          |                |                 |     | 77     |        |     |         |
|                   | Parada          |                | 1               | 1   |        | 72     |     | 1       |
|                   | SCM             |                | 3               |     |        |        | 74  |         |
|                   | Sprints         |                | 3               | 1   |        | 1      |     | 71      |
|                   |                 | CorridaLeve    | CorridaModerada | MMD | Marcha | Parada | SCM | Sprints |
|                   |                 | Classe Predita |                 |     |        |        |     |         |

Fonte: Dados da pesquisa.

Figura E17 – Matriz de confusão relativa (B) para o conjunto de dados de teste (ACC1, m = 54) utilizando o algoritmo k-NN “fine”.

**[B] k - NN (Fine) [%] - TESTE**

|                   |                 |                |                 |       |        |        |       |         |        |       |
|-------------------|-----------------|----------------|-----------------|-------|--------|--------|-------|---------|--------|-------|
| Classe Verdadeira | CorridaLeve     | 91.2%          | 4.4%            | 1.5%  |        |        | 2.9%  |         | 91.2%  | 8.8%  |
|                   | CorridaModerada | 1.4%           | 84.3%           | 11.4% |        |        |       |         | 84.3%  | 15.7% |
|                   | MMD             | 2.7%           | 10.7%           | 62.7% | 1.3%   |        | 1.3%  | 21.3%   | 62.7%  | 37.3% |
|                   | Marcha          |                |                 |       | 100.0% |        |       |         | 100.0% |       |
|                   | Parada          |                | 1.3%            | 1.3%  |        | 96.0%  |       | 1.3%    | 96.0%  | 4.0%  |
|                   | SCM             |                | 3.9%            |       |        |        | 96.1% |         | 96.1%  | 3.9%  |
|                   | Sprints         |                | 3.9%            | 1.3%  |        | 1.3%   |       | 93.4%   | 93.4%  | 6.6%  |
|                   |                 |                |                 |       |        |        |       | TPR     | FNR    |       |
|                   |                 | CorridaLeve    | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints |        |       |
|                   |                 | Classe Predita |                 |       |        |        |       |         |        |       |

Fonte: Dados da pesquisa.

TPR - “True Positive Rates” – Verdadeiros Positivos (%) ou sensibilidade; FNR - “False Negative Rates” – Falsos Negativos (%).

Figura E18 – Matriz de confusão relativa (C) para o conjunto de dados de teste (ACC1, m = 54) utilizando o algoritmo k-NN “fine”.

**[C] k - NN (Fine) [%] - TESTE**

|                   |                 |                |                 |       |        |        |       |         |
|-------------------|-----------------|----------------|-----------------|-------|--------|--------|-------|---------|
| Classe Verdadeira | CorridaLeve     | 95.4%          | 3.9%            | 1.7%  |        |        | 2.6%  |         |
|                   | CorridaModerada | 1.5%           | 76.6%           | 13.8% |        |        |       | 2.2%    |
|                   | MMD             | 3.1%           | 10.4%           | 81.0% | 1.3%   |        | 1.3%  | 17.8%   |
|                   | Marcha          |                |                 |       | 98.7%  |        |       |         |
|                   | Parada          |                | 1.3%            | 1.7%  |        | 98.6%  |       | 1.1%    |
|                   | SCM             |                | 3.9%            |       |        |        | 96.1% |         |
|                   | Sprints         |                | 3.9%            | 1.7%  |        | 1.4%   |       | 78.9%   |
|                   | PPV             | 95.4%          | 76.6%           | 81.0% | 98.7%  | 98.6%  | 96.1% | 78.9%   |
|                   | FDR             | 4.6%           | 23.4%           | 19.0% | 1.3%   | 1.4%   | 3.9%  | 21.1%   |
|                   |                 | CorridaLeve    | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints |
|                   |                 | Classe Predita |                 |       |        |        |       |         |

Fonte: Dados da pesquisa.

PPV - “Positive Predictive Values” – Valores Preditivos Positivos (%) ou precisão; FDR - “False Discovery Rates” – Falsas Descobertas (%) ou Falsos Positivos.

Figura E19 – Matriz de confusão absoluta (A) para o conjunto de dados de teste (ACC2 – m=83) utilizando o algoritmo Ensemble (*Bagged Trees*).

**[A] Ensemble (Bagged Trees) [valores absolutos] - TESTE**

|                   |                 |                |                 |     |        |        |     |         |
|-------------------|-----------------|----------------|-----------------|-----|--------|--------|-----|---------|
| Classe Verdadeira | CorridaLeve     | 56             | 7               | 3   |        |        | 2   |         |
|                   | CorridaModerada | 7              | 44              | 14  |        |        | 2   | 3       |
|                   | MMD             | 2              | 15              | 49  | 1      |        | 1   | 7       |
|                   | Marcha          |                |                 |     | 77     |        |     |         |
|                   | Parada          |                |                 |     | 1      | 73     |     | 1       |
|                   | SCM             | 1              | 1               | 2   |        | 1      | 72  |         |
|                   | Sprints         |                | 1               | 1   |        | 2      | 2   | 70      |
|                   |                 | CorridaLeve    | CorridaModerada | MMD | Marcha | Parada | SCM | Sprints |
|                   |                 | Classe Predita |                 |     |        |        |     |         |

Fonte: Dados da pesquisa.

Figura E20 – Matriz de confusão relativa (B) para o conjunto de dados de teste (ACC2 – m=83) utilizando o algoritmo Ensemble (*Bagged Trees*).

**[B] Ensemble (Bagged Trees) [%] - TESTE**

|                   |                 |             |                 |       |        |        |       |         |        |       |
|-------------------|-----------------|-------------|-----------------|-------|--------|--------|-------|---------|--------|-------|
| Classe Verdadeira | CorridaLeve     | 82.4%       | 10.3%           | 4.4%  |        |        | 2.9%  |         | 82.4%  | 17.6% |
|                   | CorridaModerada | 10.0%       | 62.9%           | 20.0% |        |        | 2.9%  | 4.3%    | 62.9%  | 37.1% |
|                   | MMD             | 2.7%        | 20.0%           | 65.3% | 1.3%   |        | 1.3%  | 9.3%    | 65.3%  | 34.7% |
|                   | Marcha          |             |                 |       | 100.0% |        |       |         | 100.0% |       |
|                   | Parada          |             |                 |       | 1.3%   | 97.3%  |       | 1.3%    | 97.3%  | 2.7%  |
|                   | SCM             | 1.3%        | 1.3%            | 2.6%  |        | 1.3%   | 93.5% |         | 93.5%  | 6.5%  |
|                   | Sprints         |             | 1.3%            | 1.3%  |        | 2.6%   | 2.6%  | 92.1%   | 92.1%  | 7.9%  |
|                   |                 | CorridaLeve | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints | TPR    | FNR   |
| Classe Predita    |                 |             |                 |       |        |        |       |         |        |       |

Fonte: Dados da pesquisa.

TPR - “*True Positive Rates*” – Verdadeiros Positivos (%) ou sensibilidade; FNR - “*False Negative Rates*” – Falsos Negativos (%).

Figura E21 – Matriz de confusão relativa (C) para o conjunto de dados de teste (ACC2 – m=83) utilizando o algoritmo Ensemble (*Bagged Trees*).

**[C] Ensemble (Bagged Trees) [%] - TESTE**

|                   |                 |                |                 |       |        |        |       |         |
|-------------------|-----------------|----------------|-----------------|-------|--------|--------|-------|---------|
| Classe Verdadeira | CorridaLeve     | 84.8%          | 10.3%           | 4.3%  |        |        | 2.5%  |         |
|                   | CorridaModerada | 10.6%          | 64.7%           | 20.3% |        |        | 2.5%  | 3.7%    |
|                   | MMD             | 3.0%           | 22.1%           | 71.0% | 1.3%   |        | 1.3%  | 8.6%    |
|                   | Marcha          |                |                 |       | 97.5%  |        |       |         |
|                   | Parada          |                |                 |       | 1.3%   | 96.1%  |       | 1.2%    |
|                   | SCM             | 1.5%           | 1.5%            | 2.9%  |        | 1.3%   | 91.1% |         |
|                   | Sprints         |                | 1.5%            | 1.4%  |        | 2.6%   | 2.5%  | 86.4%   |
|                   | PPV             | 84.8%          | 64.7%           | 71.0% | 97.5%  | 96.1%  | 91.1% | 86.4%   |
|                   | FDR             | 15.2%          | 35.3%           | 29.0% | 2.5%   | 3.9%   | 8.9%  | 13.6%   |
|                   |                 | CorridaLeve    | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints |
|                   |                 | Classe Predita |                 |       |        |        |       |         |

Fonte: Dados da pesquisa.

PPV - “Positive Predictive Values” – Valores Preditivos Positivos (%) ou precisão; FDR - “False Discovery Rates” – Falsas Descobertas (%) ou Falsos Positivos.

Figura E22 – Matriz de confusão absoluta (A) para o conjunto de dados de teste (ACC3, m=138) utilizando o algoritmo Ensemble (*Bagged Trees*).

**[A] Ensemble (Bagged Trees) [valores absolutos] - TESTE**

|                   |                 |                |                 |     |        |        |     |         |
|-------------------|-----------------|----------------|-----------------|-----|--------|--------|-----|---------|
| Classe Verdadeira | CorridaLeve     | 53             | 11              | 4   |        |        |     |         |
|                   | CorridaModerada | 6              | 50              | 13  |        |        | 1   |         |
|                   | MMD             | 2              | 19              | 53  | 1      |        |     |         |
|                   | Marcha          |                |                 |     | 75     |        |     | 2       |
|                   | Parada          |                |                 |     | 1      | 73     | 1   |         |
|                   | SCM             |                |                 |     |        |        | 77  |         |
|                   | Sprints         |                |                 | 1   | 1      | 2      | 1   | 71      |
|                   |                 | CorridaLeve    | CorridaModerada | MMD | Marcha | Parada | SCM | Sprints |
|                   |                 | Classe Predita |                 |     |        |        |     |         |

Fonte: Dados da pesquisa.

Figura E23 – Matriz de confusão relativa (B) para o conjunto de dados de teste (ACC3, m=138) utilizando o algoritmo Ensemble (*Bagged Trees*).

**[B] Ensemble (Bagged Trees) [%] - TESTE**

|                   |                 |             |                 |       |        |        |        |         |        |       |
|-------------------|-----------------|-------------|-----------------|-------|--------|--------|--------|---------|--------|-------|
| Classe Verdadeira | CorridaLeve     | 77.9%       | 16.2%           | 5.9%  |        |        |        |         | 77.9%  | 22.1% |
|                   | CorridaModerada | 8.6%        | 71.4%           | 18.6% |        |        | 1.4%   |         | 71.4%  | 28.6% |
|                   | MMD             | 2.7%        | 25.3%           | 70.7% | 1.3%   |        |        |         | 70.7%  | 29.3% |
|                   | Marcha          |             |                 |       | 97.4%  |        |        |         | 97.4%  | 2.6%  |
|                   | Parada          |             |                 |       | 1.3%   | 97.3%  | 1.3%   |         | 97.3%  | 2.7%  |
|                   | SCM             |             |                 |       |        |        | 100.0% |         | 100.0% |       |
|                   | Sprints         |             |                 | 1.3%  | 1.3%   | 2.6%   | 1.3%   | 93.4%   | 93.4%  | 6.6%  |
|                   |                 | CorridaLeve | CorridaModerada | MMD   | Marcha | Parada | SCM    | Sprints | TPR    | FNR   |
| Classe Preditada  |                 |             |                 |       |        |        |        |         |        |       |

Fonte: Dados da pesquisa.

TPR - "True Positive Rates" – Verdadeiros Positivos (%) ou sensibilidade; FNR - "False Negative Rates" – Falsos Negativos (%).

Figura E24 – Matriz de confusão relativa (C) para o conjunto de dados de teste (ACC3, m=138) utilizando o algoritmo Ensemble (*Bagged Trees*).

**[C] Ensemble (Bagged Trees) [valores absolutos] - TESTE**

|                   |                 |                |                 |       |        |        |       |         |
|-------------------|-----------------|----------------|-----------------|-------|--------|--------|-------|---------|
| Classe Verdadeira | CorridaLeve     | 86.9%          | 13.8%           | 5.6%  |        |        |       |         |
|                   | CorridaModerada | 9.8%           | 62.5%           | 18.3% |        |        | 1.2%  |         |
|                   | MMD             | 3.3%           | 23.8%           | 74.6% | 1.3%   |        |       |         |
|                   | Marcha          |                |                 |       | 96.2%  |        |       | 2.7%    |
|                   | Parada          |                |                 |       | 1.3%   | 97.3%  | 1.2%  |         |
|                   | SCM             |                |                 |       |        |        | 96.2% |         |
|                   | Sprints         |                |                 | 1.4%  | 1.3%   | 2.7%   | 1.2%  | 97.3%   |
|                   | PPV             | 86.9%          | 62.5%           | 74.6% | 96.2%  | 97.3%  | 96.2% | 97.3%   |
|                   | FDR             | 13.1%          | 37.5%           | 25.4% | 3.8%   | 2.7%   | 3.7%  | 2.7%    |
|                   |                 | CorridaLeve    | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints |
|                   |                 | Classe Predita |                 |       |        |        |       |         |

Fonte: Dados da pesquisa.

PPV - “Positive Predictive Values” – Valores Preditivos Positivos (%) ou precisão; FDR - “False Discovery Rates” – Falsas Descobertas (%) ou Falsos Positivos.


Figura E25 – Matriz de confusão absoluta (A) para o conjunto de dados de teste (ACC1+GIR1, m=99) utilizando o algoritmo Ensemble (*Bagged Trees*).

**[A] Ensemble (Bagged Trees) [valores absolutos] - TESTE**

|                   |                 |                |                 |     |        |        |     |         |
|-------------------|-----------------|----------------|-----------------|-----|--------|--------|-----|---------|
| Classe Verdadeira | CorridaLeve     | 61             | 7               |     |        |        |     |         |
|                   | CorridaModerada | 7              | 55              | 4   |        |        |     | 4       |
|                   | MMD             |                | 10              | 43  | 1      |        | 1   | 20      |
|                   | Marcha          | 6              |                 |     | 71     |        |     |         |
|                   | Parada          | 1              |                 |     | 2      | 72     |     |         |
|                   | SCM             | 1              |                 |     |        |        | 76  |         |
|                   | Sprints         | 2              | 3               | 3   |        | 2      |     | 66      |
|                   |                 | CorridaLeve    | CorridaModerada | MMD | Marcha | Parada | SCM | Sprints |
|                   |                 | Classe Predita |                 |     |        |        |     |         |

Fonte: Dados da pesquisa.

Figura E26 – Matriz de confusão relativa (B) para o conjunto de dados de teste (ACC1+GIR1, m=99) utilizando o algoritmo Ensemble (*Bagged Trees*).



Fonte: Dados da pesquisa.

TPR - "True Positive Rates" – Verdadeiros Positivos (%) ou sensibilidade; FNR - "False Negative Rates" – Falsos Negativos (%).

Figura E27 – Matriz de confusão relativa (C) para o conjunto de dados de teste (ACC1+GIR1, m=99) utilizando o algoritmo Ensemble (*Bagged Trees*).

**[C] Ensemble (Bagged Trees) [%] - TESTE**

|                   |                 |                |                 |       |        |        |       |         |
|-------------------|-----------------|----------------|-----------------|-------|--------|--------|-------|---------|
| Classe Verdadeira | CorridaLeve     | 78.2%          | 9.3%            |       |        |        |       |         |
|                   | CorridaModerada | 9.0%           | 73.3%           | 8.0%  |        |        |       | 4.4%    |
|                   | MMD             |                | 13.3%           | 86.0% | 1.4%   |        | 1.3%  | 22.2%   |
|                   | Marcha          | 7.7%           |                 |       | 95.9%  |        |       |         |
|                   | Parada          | 1.3%           |                 |       | 2.7%   | 97.3%  |       |         |
|                   | SCM             | 1.3%           |                 |       |        |        | 98.7% |         |
|                   | Sprints         | 2.6%           | 4.0%            | 6.0%  |        | 2.7%   |       | 73.3%   |
|                   | PPV             | 78.2%          | 73.3%           | 86.0% | 95.9%  | 97.3%  | 98.7% | 73.3%   |
|                   | FDR             | 21.8%          | 26.7%           | 14.0% | 4.1%   | 2.7%   | 1.3%  | 26.7%   |
|                   |                 | CorridaLeve    | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints |
|                   |                 | Classe Predita |                 |       |        |        |       |         |

Fonte: Dados da pesquisa.

PPV - “Positive Predictive Values” – Valores Preditivos Positivos (%) ou precisão; FDR - “False Discovery Rates” – Falsas Descobertas (%) ou Falsos Positivos.


Figura E28 – Matriz de confusão absoluta (A) para o conjunto de dados de teste (ACC2+GIR1, m=131) utilizando o algoritmo Ensemble (*Bagged Trees*).

**[A] Ensemble (Bagged Trees) [valores absolutos] - TESTE**

|                   |                 |                |                 |     |        |        |     |         |
|-------------------|-----------------|----------------|-----------------|-----|--------|--------|-----|---------|
| Classe Verdadeira | CorridaLeve     | 64             | 4               |     |        |        |     |         |
|                   | CorridaModerada | 8              | 47              | 9   |        |        | 6   |         |
|                   | MMD             | 1              | 11              | 43  | 1      |        | 1   | 18      |
|                   | Marcha          | 5              |                 |     | 72     |        |     |         |
|                   | Parada          | 1              |                 |     | 2      | 72     |     |         |
|                   | SCM             | 1              |                 |     |        |        | 76  |         |
|                   | Sprints         | 2              | 2               | 2   |        | 2      |     | 68      |
|                   |                 | CorridaLeve    | CorridaModerada | MMD | Marcha | Parada | SCM | Sprints |
|                   |                 | Classe Predita |                 |     |        |        |     |         |

Fonte: Dados da pesquisa.

Figura E29 – Matriz de confusão relativa (B) para o conjunto de dados de teste (ACC2+GIR1, m=131) utilizando o algoritmo Ensemble (*Bagged Trees*).



Fonte: Dados da pesquisa.

TPR - "True Positive Rates" – Verdadeiros Positivos (%) ou sensibilidade; FNR - "False Negative Rates" – Falsos Negativos (%).

Figura E30 – Matriz de confusão relativa (C) para o conjunto de dados de teste (ACC2+GIR1, m=131) utilizando o algoritmo Ensemble (*Bagged Trees*).


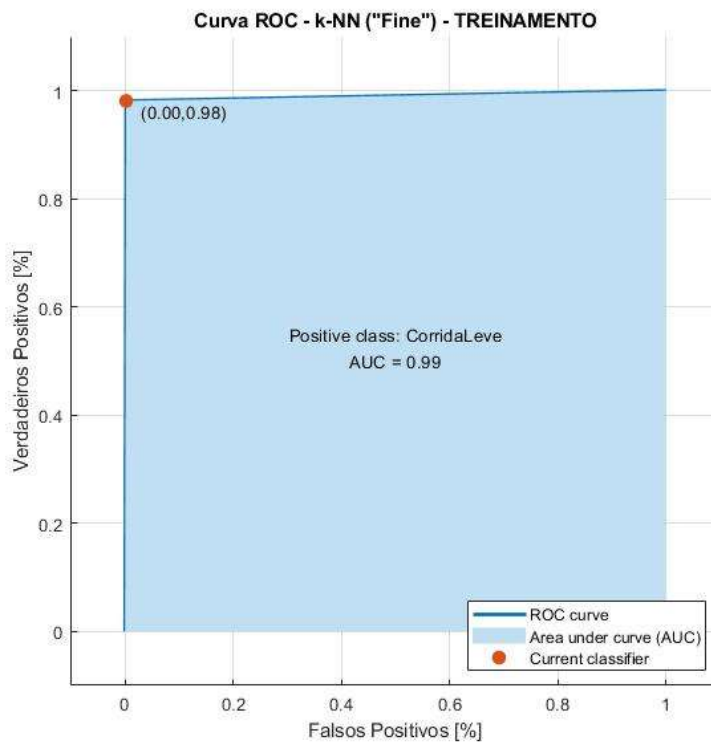
**[C] Ensemble (Bagged Trees) [%] - TESTE**

|                   |                 |                |                 |       |        |        |       |         |
|-------------------|-----------------|----------------|-----------------|-------|--------|--------|-------|---------|
| Classe Verdadeira | CorridaLeve     | 78.0%          | 6.2%            |       |        |        |       |         |
|                   | CorridaModerada | 9.8%           | 73.4%           | 16.7% |        |        |       | 6.5%    |
|                   | MMD             | 1.2%           | 17.2%           | 79.6% | 1.3%   |        | 1.3%  | 19.6%   |
|                   | Marcha          | 6.1%           |                 |       | 96.0%  |        |       |         |
|                   | Parada          | 1.2%           |                 |       | 2.7%   | 97.3%  |       |         |
|                   | SCM             | 1.2%           |                 |       |        |        | 98.7% |         |
|                   | Sprints         | 2.4%           | 3.1%            | 3.7%  |        | 2.7%   |       | 73.9%   |
|                   |                 |                |                 |       |        |        |       |         |
|                   | PPV             | 78.0%          | 73.4%           | 79.6% | 96.0%  | 97.3%  | 98.7% | 73.9%   |
|                   | FDR             | 22.0%          | 26.6%           | 20.4% | 4.0%   | 2.7%   | 1.3%  | 26.1%   |
|                   |                 | CorridaLeve    | CorridaModerada | MMD   | Marcha | Parada | SCM   | Sprints |
|                   |                 | Classe Predita |                 |       |        |        |       |         |

Fonte: Dados da pesquisa.

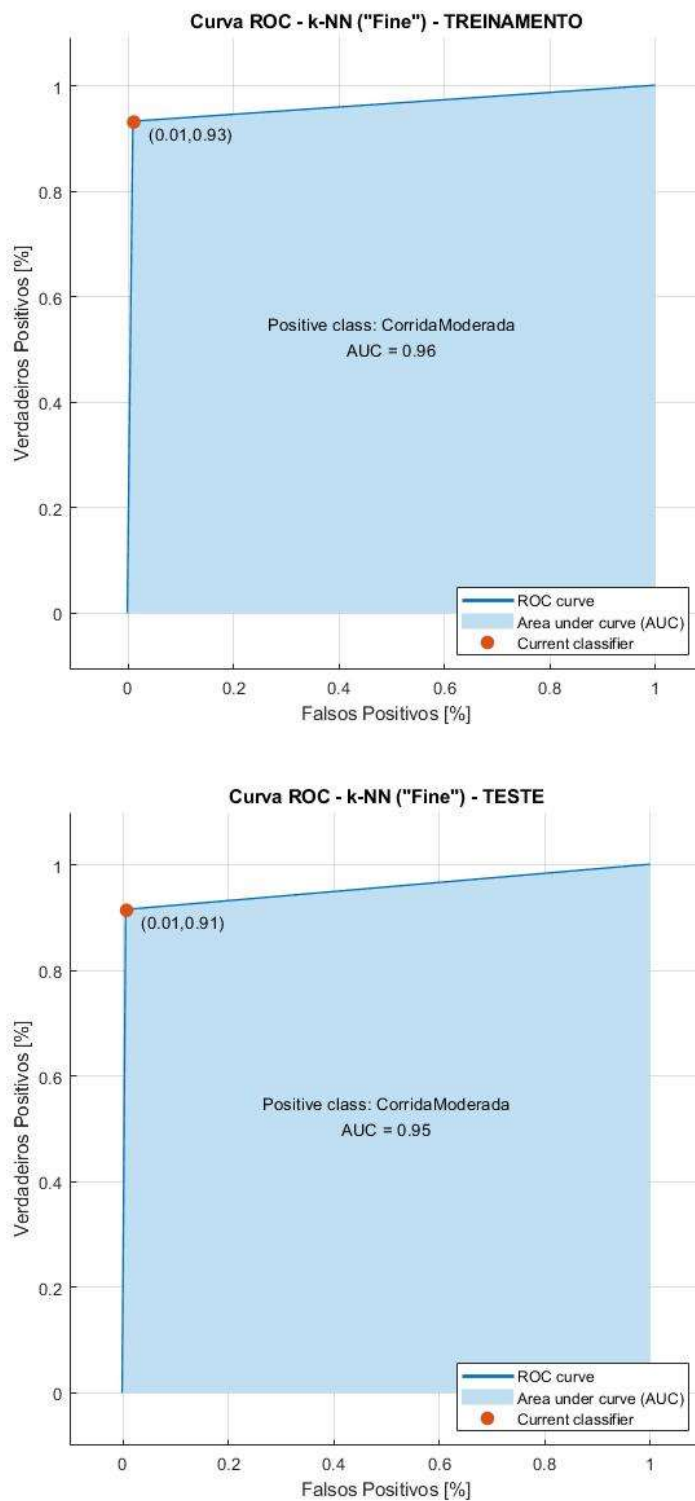
PPV - “Positive Predictive Values” – Valores Preditivos Positivos (%) ou precisão; FDR - “False Discovery Rates” – Falsas Descobertas (%) ou Falsos Positivos.

Figura E31 – Curva ROC (*Receiver operating characteristics curves*) e área do sobre a curva ROC (*Area Under Curve - AUC*) – Relação entre sensibilidade e especificidade dos algoritmos treinados e testados – Corrida Leve.





Fonte: Dados da pesquisa.

Figura E32 – Curva ROC (*Receiver operating characteristics curves*) e área do sobre a curva ROC (*Area Under Curve - AUC*) – Relação entre sensibilidade e especificidade dos algoritmos treinados e testados – Corrida Moderada.



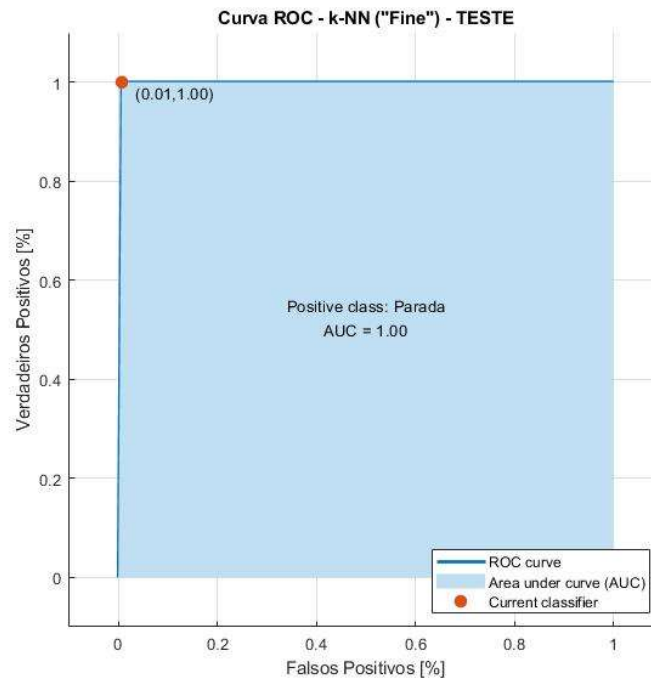

Fonte: Dados da pesquisa.

Figura E33 – Curva ROC (*Receiver operating characteristics curves*) e área do sobre a curva ROC (*Area Under Curve - AUC*) – Relação entre sensibilidade e especificidade dos algoritmos treinados e testados – Marcha.



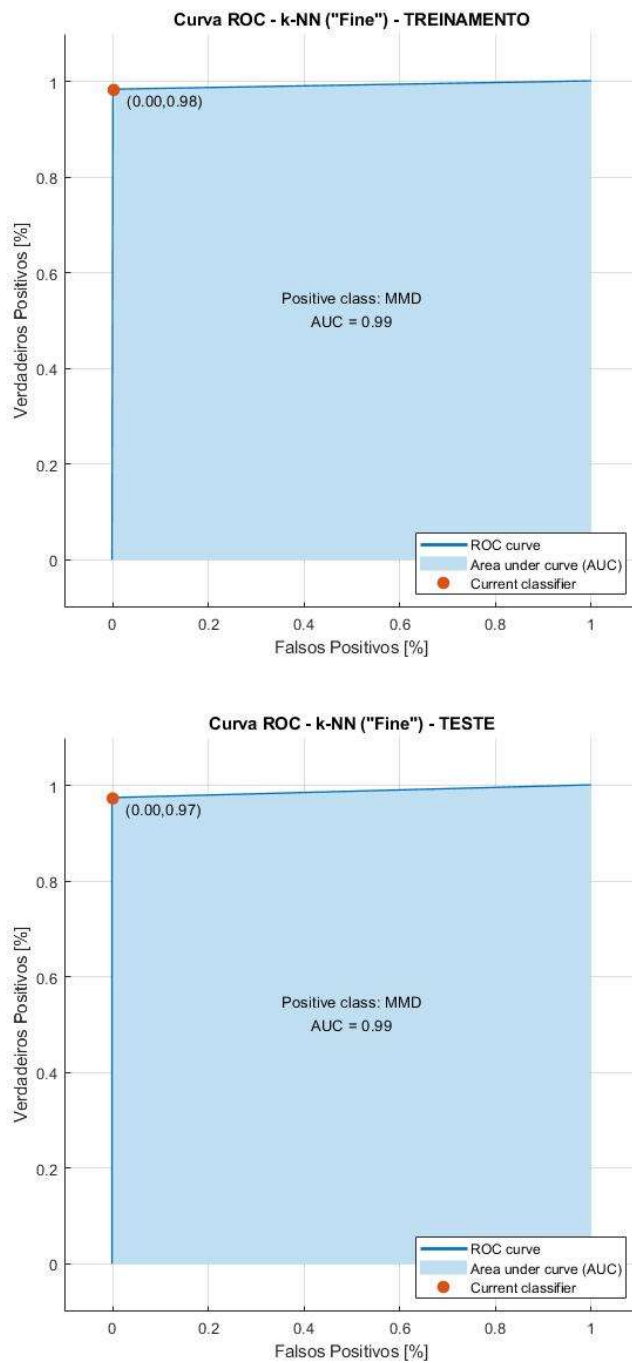
Fonte: Dados da pesquisa.

Figura E34 – Curva ROC (*Receiver operating characteristics curves*) e área do sobre a curva ROC (*Area Under Curve - AUC*) – Relação entre sensibilidade e especificidade dos algoritmos treinados e testados – Parada.





Fonte: Dados da pesquisa.

Figura E35 – Curva ROC (*Receiver operating characteristics curves*) e área do sobre a curva ROC (*Area Under Curve - AUC*) – Relação entre sensibilidade e especificidade dos algoritmos treinados e testados – MMD.





Fonte: Dados da pesquisa.

Figura E36 – Curva ROC (Receiver operating characteristics curves) e área do sobre a curva ROC (Area Under Curve - AUC) – Relação entre sensibilidade e especificidade dos algoritmos treinados e testados – SCM.



Fonte: Dados da pesquisa.

Figura E37 – Curva ROC (Receiver operating characteristics curves) e área do sobre a curva ROC (Area Under Curve - AUC) – Relação entre sensibilidade e especificidade dos algoritmos treinados e testados – *Sprints*.



Fonte: Dados da pesquisa.

## APÊNDICE F – ESTATÍSTICAS DESCRITIVAS (CAPÍTULO 4).

Tabela F1 – Estatísticas descritivas das variáveis quantificadas no estudo ( $\bar{x} \pm s$ ) por tempo de jogo em cada jogo.

| Variáveis                  | Jogo 1        |               |               | Jogo 2        |               |               | Jogo 3        |              |               |
|----------------------------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|--------------|---------------|
|                            | T1            | T2            | Completo      | T1            | T2            | Completo      | T1            | T2           | Completo      |
| ARESHmedia                 | 1,73±0,8      | 1,6±0,86      | 1,51±0,86     | 1,52±0,69     | 1,41±0,79     | 1,48±0,7      | 1,7±0,76      | 1,44±0,37    | 1,49±0,38     |
| ARESHmax                   | 33,06±8,86    | 36,15±14,63   | 33,31±13,1    | 37,96±14,02   | 36,69±18,14   | 38,44±14,13   | 40,44±14,61   | 42,27±10,55  | 40,58±11,58   |
| ARESVmedia                 | 1,33±0,64     | 1,26±0,71     | 1,18±0,71     | 1,19±0,52     | 1,1±0,62      | 1,15±0,54     | 1,36±0,62     | 1,11±0,26    | 1,17±0,25     |
| ARESVmax                   | 31,67±9,06    | 27,56±8,81    | 26,75±8,75    | 28,1±8,92     | 29,2±11,68    | 30,3±7,63     | 33,98±7,54    | 33,62±8,3    | 32,56±8,27    |
| tVertA <sub>BAIXO</sub>    | 199,7±55,45   | 174,97±77,26  | 510,16±209,49 | 166,24±56,9   | 139,52±68,48  | 454,96±174,38 | 173,18±58,13  | 168,88±46,31 | 518,54±113,73 |
| tVertA <sub>MODERADO</sub> | 81,07±35,38   | 72,4±45,01    | 206,21±127,01 | 60,94±28,0    | 51,67±33,37   | 168,95±85,28  | 69,23±30,07   | 63,93±14,89  | 202,77±41,74  |
| tVertA <sub>ALTO</sub>     | 115,74±70,08  | 114,25±76,73  | 318,97±232,28 | 93,65±52,86   | 76,92±58,59   | 256,31±153,04 | 111,68±61,29  | 95,26±29,91  | 306,86±83,77  |
| tDir <sub>BAIXO</sub>      | 304,53±113,05 | 271,44±131,15 | 781,36±384,23 | 243,04±115,18 | 214,02±125,8  | 691,35±329,54 | 263,11±110,73 | 262,41±76,53 | 800,24±194,53 |
| tDir <sub>MODERADO</sub>   | 101,03±53,59  | 95,35±63,68   | 266,24±180,37 | 71,77±44,0    | 58,94±41,8    | 203,71±112,14 | 84,013±44,22  | 75,8±19,93   | 234,7±66,28   |
| tDir <sub>ALTO</sub>       | 59,71±38,83   | 59,78±44,37   | 166,57±130,44 | 45,53±27,97   | 37,26±30,04   | 126,86±79,1   | 56,26±31,7    | 50,52±17,92  | 157,03±52,55  |
| tAC <sub>BAIXO</sub>       | 182,71±54,83  | 159,76±77,63  | 464,26±209,81 | 144,74±52,13  | 127,73±64,93  | 407,58±165,64 | 158,79±57,96  | 155,84±44,44 | 479,95±106,45 |
| tAC <sub>MODERADO</sub>    | 68,31±34,98   | 61,21±42,22   | 174,03±120,97 | 51,53±24,31   | 44,71±32,56   | 144,6±81,65   | 61,7±30,73    | 52,19±19,11  | 171,77±52,69  |
| tAC <sub>ALTO</sub>        | 98,48±63,41   | 94,82±67,51   | 268,04±204,63 | 80,13±49,4    | 66,28±53,38   | 221,17±140,21 | 91,57±55,43   | 76,38±74,22  | 246,73±88,68  |
| tVertD <sub>BAIXO</sub>    | 232,44±73,14  | 202,62±99,92  | 590,14±279,28 | 184,57±67,34  | 156,19±84,19  | 508,52±211,41 | 196,76±75,82  | 185,24±51,26 | 577,79±129,32 |
| tVertD <sub>MODERADO</sub> | 69,09±36,0    | 62,86±41,37   | 178,88±120,16 | 53,05±22,1    | 45,5±28,6     | 147,69±70,22  | 59,59±28,38   | 51,91±14,14  | 168,21±40,94  |
| tVertD <sub>ALTO</sub>     | 120,43±70,03  | 119,45±78,45  | 332,48±237,15 | 99,35±56,58   | 80,92±61,01   | 269,87±161,42 | 117,8±64,18   | 101,43±32,82 | 326,18±85,97  |
| tEsq <sub>BAIXO</sub>      | 307,45±112,11 | 275,49±131,39 | 788,07±383,5  | 241,4±115,34  | 211,08±125,51 | 683,29±331,45 | 265,09±109,72 | 267,12±92,63 | 814,27±226,24 |
| tEsq <sub>MODERADO</sub>   | 105,61±55,93  | 100,38±67,68  | 282,23±194,93 | 77,16±48,91   | 62,22±46,16   | 215,39±125,42 | 85,87±43,97   | 80,69±25,87  | 246,11±76,12  |
| tEsq <sub>ALTO</sub>       | 58,06±38,28   | 57,6±43,2     | 161,02±126,41 | 27,29±44,64   | 37,13±30,23   | 125,58±78,48  | 33,16±48,32   | 47,63±14,88  | 150,4±50,14   |
| tDes <sub>BAIXO</sub>      | 233,85±76,11  | 202,72±106,66 | 585,79±285,62 | 179,31±64,84  | 156,51±85,92  | 501,17±215,51 | 199,92±78,67  | 191,59±53,45 | 599,57±138,01 |
| tDes <sub>MODERADO</sub>   | 73,11±43,7    | 69,84±51,7    | 194,24±149,5  | 54,71±29,79   | 49,25±37,81   | 157,24±95,32  | 66,46±34,91   | 55,23±20,11  | 182,79±54,9   |
| tDes <sub>ALTO</sub>       | 93,39±62,24   | 89,37±63,38   | 255,78±195,38 | 79,33±51,65   | 63,96±52,44   | 216,39±140,28 | 88,49±56,36   | 73,38±35,96  | 235,06±98,41  |
| Saltos                     | 6,17±4,78     | 5,42±4,7      | 15,58±14,56   | 5,29±4,27     | 4,29±4,05     | 14,71±9,67    | 6,38±5,32     | 5,31±3,5     | 16,92±10,63   |
| Impactos                   | 47,75±39,93   | 51,5±45,02    | 141,08±135,15 | 35,07±43,53   | 42,64±53,48   | 121,57±135,66 | 44,08±45,4    | 36,46±40,56  | 121,85±110,22 |

