

# Estimativa da Força de Reação do Solo com Acelerômetros Vestíveis e Deep Learning: Análise Comparativa entre Arquiteturas Temporais

Sérgio de Nazaré Rodrigues Lima Jr  
*Instituto de Tecnologia*  
*Universidade Federal do Pará*  
Belém, Brasil  
serginholimaaudio@gmail.com

Ronaldo de Freitas Zampolo  
*Instituto de Tecnologia*  
*Universidade Federal do Pará*  
Belém, Brasil  
zampolo@ufpa.br

Antônio Pereira Jr  
*Instituto de Tecnologia*  
*Universidade Federal do Pará*  
Belém, Brasil  
apereira@ufpa.br

**Abstract**—Este trabalho propõe e avalia modelos baseados em redes neurais profundas para a predição da força de reação do solo (GRF) a partir de sinais de acelerômetros provenientes de sensores inerciais vestíveis. Foram desenvolvidas e comparadas três arquiteturas: Bi-LSTM, TCN e uma arquitetura híbrida TCN-BiLSTM. A metodologia incluiu análise de correlação cruzada para seleção do sensor mais relevante, pré-processamento dos sinais, segmentação temporal e treinamento dos modelos. Os resultados demonstraram que as arquiteturas Bi-LSTM e Híbrida apresentaram os melhores desempenhos, alcançando elevados coeficientes de determinação ( $R^2$ ) e baixos erros (RMSE e rRMSE), enquanto o modelo TCN apresentou menor tempo de treinamento, porém com desempenho preditivo inferior. Este estudo evidencia a viabilidade de utilizar sensores inerciais de baixo custo para estimar a GRF fora do ambiente laboratorial, contribuindo para aplicações em reabilitação, monitoramento esportivo e saúde digital.

**Index Terms**—Ground Reaction Force (GRF), Sensores Inerciais, Bi-LSTM, TCN, Aprendizado Profundo.

## I. INTRODUÇÃO

A força de reação do solo (Ground Reaction Force – GRF) é um dos dados biomecânicos mais relevantes na análise da marcha humana, muito utilizada na avaliação funcional, na reabilitação e no monitoramento da performance motora em contextos clínicos e esportivos [1], [2]. A GRF traz informações sobre a interação entre o corpo humano e o solo durante a marcha, sendo medida por plataformas de força. Mesmo com sua alta precisão, esses dispositivos possuem custo elevado, demandam infraestrutura laboratorial especializada e limitam as análises a ambientes laboratoriais [3].

O uso de sensores inerciais vestíveis (IMUs) possibilita prever a GRF de forma indireta e em ambientes extralaboratoriais, possibilitando análises em contextos do cotidiano de pacientes e atletas. Recentemente, a combinação de dados de acelerômetros e algoritmos de aprendizado de máquina se tornaram eficazes na predição de variáveis biomecânicas. Diversos estudos indicam que redes neurais profundas podem prever a GRF com erros inferiores a 10%, aproximando-se da acurácia dos equipamentos tradicionais [3], [4].

A estimativa da GRF a partir de sensores inerciais tem impacto direto em aplicações clínicas, esportivas e em tecnolo-

gias assistivas. Em populações idosas, essa predição auxilia na detecção precoce de padrões de marcha associados ao risco de quedas [5]. No esporte, permite o monitoramento de cargas externas e a prevenção de lesões [6]. Na reabilitação, pode fornecer feedback em tempo real para intervenções terapêuticas [7].

Os Modelos baseados em Redes Neurais Recorrentes (RNNs), Long Short-Term Memory (LSTM), redes convolucionais (CNNs) e arquiteturas temporais como Temporal Convolutional Networks (TCNs) trazem resultados promissores na modelagem de séries temporais biomecânicas [8], [9]. No entanto, limitações relacionadas à robustez dos modelos fora do ambiente laboratorial e à escolha do posicionamento ótimo dos sensores ainda persistem [10], [11].

Neste sentido, este trabalho propõe o desenvolvimento e a comparação de três arquiteturas de redes neurais profundas – Bi-LSTM, TCN e uma arquitetura híbrida TCN-BiLSTM – para a predição da GRF a partir de dados de acelerômetros. As arquiteturas são avaliadas quanto à acurácia, robustez temporal e desempenho computacional, visando aplicações portáteis e de baixo custo em contextos clínicos, esportivos e de reabilitação.

## II. METODOLOGIA

A metodologia foi estruturada nas seguintes etapas principais:

- Pré-processamento dos sinais de acelerômetros e GRF, incluindo filtragem e normalização;
- Análise de correlação cruzada para selecionar o sensor com maior relação com a GRF;
- Segmentação dos sinais por janelas deslizantes;
- Construção, treinamento e avaliação de modelos baseados em Bi-LSTM, TCN e uma arquitetura híbrida TCN-BiLSTM;
- Análise de desempenho preditivo e computacional dos modelos.

Todas as etapas foram desenvolvidas e realizadas em MATLAB, utilizando a Deep Learning Toolbox, com o desenvolvimento de um pipeline modular e automatizado,

abrangendo desde a leitura e filtragem dos dados até o treinamento, validação cruzada e avaliação de desempenho dos modelos. O uso do MATLAB garantiu controle detalhado dos experimentos, facilidade na manipulação de sinais biomecânicos e integração com rotinas específicas de visualização e segmentação.

#### A. Base de Dados

Os dados foram obtidos do dataset aberto publicado por Grouvel et al. [12], que inclui sinais de IMUs, palmilhas instrumentadas e plataformas de força. Foram utilizados os dados de 10 participantes assintomáticos, nas tarefas de marcha normal, lenta, rápida e caminhada de 2 minutos.

O setup experimental é ilustrado na Figura 1, onde são apresentados os sensores IMU (Physilog®6S) [13] posicionados na lombar, pelve, coxas, pernas e pés, além das palmilhas instrumentadas Insole3 [14].




Fig. 1. Configuração completa dos sensores em um participante. Fonte: [12].

#### B. Análise de Correlação Cruzada

Com o objetivo da utilização dos dados de apenas um sensor inercial, foi implementada uma análise de correlação cruzada estatística baseada na função `xcorr` do MATLAB [15], com a sua normalização, na intenção de identificar o sensor inercial cujo dados de acelerômetros estão mais correlacionados à GRF. A análise da correlação cruzada contribui de forma significativa na seleção de sensores inerciais para prever a GRF, identificando os dados do sensor mais relevante que se correlacionam com os padrões de GRF. Essa abordagem otimiza a seleção de sensores concentrando-se naquele que fornece os dados mais informativos, aumentando assim a precisão e a eficiência da previsão dos modelos [10], [11]. Do dataset utilizado, foram utilizados os dados adquiridos dos sensores inerciais posicionados na coxa direita, perna direita e

pé direito. A análise foi unilateral por se tratar de participantes assintomáticos com padrão de marcha simétrica [16].

Os resultados indicaram que o sensor localizado no pé apresentou a maior correlação com a GRF, sendo escolhido como entrada dos modelos.

#### C. Pré-processamento dos Dados

Os dados dos acelerômetros foram filtrados por um filtro passa-baixa Butterworth de 4ª ordem, com frequência de corte de 10 Hz e normalizados por z-score, individualmente para os eixos dos acelerômetros e para a GRF.

#### D. Segmentação dos Dados

Os sinais foram divididos em janelas deslizantes de 30 amostras (0,3 s), com deslocamentos de 1, 3 e 5 amostras. Esse tipo de segmentação curta e com múltiplos deslocamentos é muito utilizada em tarefas de aprendizado de máquina com sinais fisiológicos, biomecânicos e séries temporais em geral, já que aumenta a densidade de exemplos disponíveis sem necessidade de coleta adicional [17], [18]. A Tabela I ilustra o processo de segmentação.

TABLE I  
EXEMPLO DE SEGMENTAÇÃO COM JANELAS DESLIZANTES

| Subamostra | Entrada (3 pontos) | Saída (próximo ponto) |
|------------|--------------------|-----------------------|
| 1          | $(x_1, x_2, x_3)$  | $x_4$                 |
| 2          | $(x_2, x_3, x_4)$  | $x_5$                 |
| 3          | $(x_3, x_4, x_5)$  | $x_6$                 |
| $\vdots$   | $\vdots$           | $\vdots$              |

Para gerar maior diversidade nos treinamentos devido a base de dados ser pequena, foi empregada validação cruzada com  $K = 5$  folds para estimar a generalização dos modelos. Em cada repetição, o conjunto de dados foi dividido em cinco partições iguais, utilizando quatro para treinamento e uma para teste. Ao final de cada fold, o desempenho foi registrado com base em métricas quantitativas.

#### E. Arquiteturas de Redes Neurais

Foram desenvolvidos scripts baseados em três arquiteturas: Bi-LSTM, TCN e uma arquitetura híbrida TCN-BiLSTM. As tabelas II, III e IV apresentam os detalhes dos componentes de cada modelo como as funções de ativação, técnicas de regularização, operações de redução e função de perda.

TABLE II  
ARQUITETURA BI-LSTM

| Componente                         | Descrição                       |
|------------------------------------|---------------------------------|
| <code>sequenceInputLayer(3)</code> | Entrada (3 canais)              |
| <code>biLstmLayer(128)</code>      | Bi-LSTM (Output: sequência)     |
| <code>dropout(0.4)</code>          | Dropout 40%                     |
| <code>biLstmLayer(64)</code>       | Bi-LSTM (Output: último estado) |
| <code>dropout(0.4)</code>          | Dropout 40%                     |
| <code>fullyConnected(64)</code>    | Densa + ReLU                    |
| <code>fullyConnected(1)</code>     | Saída (GRF)                     |
| <code>regressionLayer</code>       | Regressão                       |

TABLE III  
ARQUITETURA TCN

| Componente             | Descrição                     |
|------------------------|-------------------------------|
| sequenceInputLayer(3)  | Entrada (3 canais)            |
| conv1d(3, 128, causal) | Convolução causal 128 filtros |
| ReLU                   | Ativação                      |
| dropout(0.3)           | Dropout 30%                   |
| conv1d(3, 64, causal)  | Convolução causal 64 filtros  |
| ReLU                   | Ativação                      |
| dropout(0.3)           | Dropout 30%                   |
| globalMaxPooling       | Redução da sequência          |
| fullyConnected(64)     | Densa + ReLU                  |
| fullyConnected(1)      | Saída (GRF)                   |
| regressionLayer        | Regressão                     |

TABLE IV  
ARQUITETURA HÍBRIDA TCN-BiLSTM

| Componente            | Descrição                     |
|-----------------------|-------------------------------|
| sequenceInputLayer(3) | Entrada (3 canais)            |
| conv1d(3, 64, causal) | Convolução causal 64 filtros  |
| ReLU                  | Ativação                      |
| conv1d(3, 64, causal) | Segunda convolução 64 filtros |
| ReLU                  | Ativação                      |
| biLstmLayer(64)       | Bi-LSTM (última saída)        |
| dropout(0.3)          | Dropout 30%                   |
| fullyConnected(64)    | Densa + ReLU                  |
| fullyConnected(1)     | Saída (GRF)                   |
| regressionLayer       | Regressão                     |

#### F. Configuração de Treinamento

Os modelos foram treinados utilizando:

- Otimizador Adam com taxa inicial de  $5 \times 10^{-3}$ ;
- 30 épocas, mini-batch de 128;
- Regularização L2 de  $10^{-4}$  e gradiente limitado a 1;
- Validação cruzada com 5 folds.

É importante ressaltar que as configurações dos hiperparâmetros e a definição das arquiteturas de rede neural utilizadas neste estudo, foram inicialmente estruturadas com o auxílio de inteligência artificial generativa, especificamente por meio da plataforma ChatGPT (OpenAI). Essa ferramenta foi utilizada como suporte na formulação das arquiteturas, seleção de parâmetros e definição das estratégias de treinamento. Após essa etapa, os ajustes finos foram realizados de forma empírica, por meio de testes sucessivos, observação dos comportamentos dos modelos e análise dos desempenhos nas fases de treinamento e validação cruzada. Essa combinação entre ferramentas de IA generativa com ajustes baseados na expertise do pesquisador, proporcionou maior eficiência na definição dos modelos e contribuiu para a obtenção dos resultados apresentados [19], [20].

#### G. Métricas de Avaliação

A avaliação do desempenho dos modelos foi realizada utilizando três métricas principais: o erro quadrático médio (RMSE), o erro quadrático médio relativo (rRMSE) e o coeficiente de determinação ( $R^2$ ). Adicionalmente, foi calculada a correlação cruzada entre os sinais preditos e a GRF real, a fim de avaliar a similaridade temporal entre as séries, e os resíduos de predição foram exportados para análises complementares,

incluindo a correlação cruzada dos sinais preditos em relação à GRF real.

### III. RESULTADOS

#### A. Análise de Correlação Cruzada

A Tabela V apresenta os valores médios de correlação, desvio padrão e atraso médio (lag) para cada sensor.

TABLE V  
RESULTADOS DA CORRELAÇÃO CRUZADA ENTRE ACELERAÇÃO E GRF

| Sensor | Correlação Média | Desvio Padrão | Atraso Médio (s) |
|--------|------------------|---------------|------------------|
| Coxa   | 0.757            | 0.150         | 0.013            |
| Perna  | 0.762            | 0.150         | 0.027            |
| Pé     | <b>0.827</b>     | <b>0.165</b>  | <b>0.064</b>     |

A Figura 2 mostra o comparativo da média das correlações cruzadas, destacando que o sensor no pé apresenta a maior correlação com a GRF.




Fig. 2. Média da correlação cruzada entre a magnitude da aceleração dos sensores inerciais e a GRF. As barras representam o valor médio e os erros indicam o desvio padrão.

A Figura 3 exibe o atraso médio (lag) dos sensores, indicando que sensores mais distais possuem maior atraso relativo à GRF.

#### B. Desempenho dos Modelos Propostos

A Tabela VI apresenta a média das métricas RMSE, rRMSE e  $R^2$  para cada arquitetura (Bi-LSTM, TCN e Híbrido) após validação cruzada com 5 folds.

TABLE VI  
MÉTRICAS MÉDIAS DOS MODELOS APÓS VALIDAÇÃO CRUZADA

| Modelo  | RMSE          | rRMSE (%)   | $R^2$       |
|---------|---------------|-------------|-------------|
| Bi-LSTM | 105.07        | 7.08        | 0.86        |
| TCN     | 152.05        | 10.49       | 0.70        |
| Híbrido | <b>103.22</b> | <b>6.90</b> | <b>0.86</b> |

A Figura 4 mostra um boxplot dos RMSE dos três modelos, evidenciando a menor dispersão dos erros na arquitetura híbrida e Bi-LSTM.




Fig. 3. Gráfico do atraso médio dos sensores inerciais em relação à GRF.




Fig. 4. Boxplot dos valores de RMSE obtidos para as arquiteturas Bi-LSTM, TCN e Híbrida.

### C. Resultados Quantitativos por Pé

As Tabelas VII e VIII detalham as métricas de RMSE, rRMSE,  $R^2$  e correlação cruzada para os sinais dos pés direito e esquerdo.

TABLE VII  
MÉTRICAS PARA O PÉ DIREITO (GRF REAL VS. ESTIMADA)

| Modelo  | RMSE (N) | rRMSE (%) | $R^2$ | Correlação |
|---------|----------|-----------|-------|------------|
| Bi-LSTM | 113.83   | 16.90     | 0.76  | 0.96       |
| TCN     | 207.23   | 30.75     | 0.23  | 0.88       |
| Híbrido | 147.53   | 21.90     | 0.61  | 0.96       |

### D. Desempenho Computacional

A Tabela IX apresenta os tempos totais de treinamento dos modelos. O TCN teve desempenho computacional significativamente superior em tempo, embora com menor acurácia.

TABLE VIII  
MÉTRICAS PARA O PÉ ESQUERDO (GRF REAL VS. ESTIMADA)

| Modelo  | RMSE (N) | rRMSE (%) | $R^2$ | Correlação |
|---------|----------|-----------|-------|------------|
| Bi-LSTM | 98.60    | 14.40     | 0.81  | 0.97       |
| TCN     | 206.26   | 31.56     | 0.11  | 0.89       |
| Híbrido | 153.50   | 22.40     | 0.55  | 0.96       |

TABLE IX  
TEMPO DE TREINAMENTO POR ARQUITETURA

| Modelo  | Tempo (min:seg) |
|---------|-----------------|
| Bi-LSTM | 154:02          |
| TCN     | 6:13            |
| Híbrido | 57:13           |

### E. Análise Gráfica das Predições

As Figuras 5 e 6 apresentam a comparação gráfica entre os sinais preditos e os sinais reais da GRF, para os pés direito e esquerdo, respectivamente. Os gráficos mostram que as arquiteturas Bi-LSTM e Híbrida acompanham de forma mais precisa os picos e vales característicos da curva da GRF.




Fig. 5. Comparação entre GRF real e predita para o pé direito utilizando os três modelos.

### F. Discussão dos Resultados

A análise dos resultados demonstra que as arquiteturas Bi-LSTM e Híbrida apresentaram os melhores desempenhos em termos de RMSE, rRMSE e  $R^2$ , com destaque para a arquitetura Híbrida, que conciliou boa acurácia com tempo de processamento mais eficiente que a Bi-LSTM.

O modelo TCN, embora apresente baixo tempo de treinamento, apresentou desempenho inferior na tarefa de predição da GRF, sobretudo refletido nos baixos valores de  $R^2$ .

A análise gráfica reforça essas conclusões, uma vez que as predições dos modelos mais robustos estão mais alinhadas




Fig. 6. Comparação entre GRF real e predita para o pé esquerdo utilizando os três modelos.

com os padrões temporais da GRF real, enquanto o modelo TCN apresentou maiores discrepâncias.

Por fim, a análise da correlação cruzada dos sensores confirmou que o sensor localizado no pé é o mais adequado para servir como entrada dos modelos, pela sua maior similaridade com os padrões da GRF, apesar do maior atraso temporal relativo, o qual pode ser compensado computacionalmente.

#### IV. CONCLUSÃO

Este trabalho teve como objetivo principal avaliar a viabilidade da predição da GRF a partir de dados de acelerômetros obtidos de sensores inerciais vestíveis, propondo a utilização de redes neurais profundas.

Os modelos Bi-LSTM e Híbrido demonstraram alta capacidade preditiva, com valores de erro (RMSE e rRMSE) relativamente baixos e coeficientes de determinação ( $R^2$ ) elevados, conforme evidenciado na Tabela VI. Esses resultados reforçam a robustez das arquiteturas aplicadas, especialmente da arquitetura Híbrida, que apresentou o melhor equilíbrio entre acurácia e desempenho computacional.

A análise de correlação cruzada confirmou que o sensor localizado no pé apresenta a maior similaridade com os sinais de GRF (Tabela V), justificando sua escolha como entrada nos modelos preditivos. Apesar do maior atraso temporal (Figura 3), esse fator pode ser compensado computacionalmente no pipeline de predição.

##### A. Contribuições

As principais contribuições deste estudo incluem:

- Proposta de uma metodologia eficiente para seleção do melhor sensor inercial, baseada na análise de correlação cruzada;

- Desenvolvimento, implementação e comparação de três arquiteturas de redes neurais profundas (Bi-LSTM, TCN e Híbrida) aplicadas à predição da GRF;
- Demonstração da viabilidade de utilizar sensores inerciais portáteis para estimar a GRF em ambientes não controlados, o que amplia o acesso a análises biomecânicas fora de ambientes laboratoriais;
- Disponibilização de um pipeline completo de scripts em MATLAB, com código aberto, permitindo replicação, extensão e aplicação em outros contextos de análise de marcha.

##### B. Limitações

Entre as limitações deste trabalho, destacam-se:

- O uso de uma base de dados limitada, composta apenas por sujeitos assintomáticos e tarefas específicas de marcha, o que pode restringir a generalização dos modelos para populações clínicas ou outros tipos de locomoção;
- A modelagem foi realizada utilizando os dados de um único sensor inercial por vez, não explorando abordagens multissensoriais que poderiam aumentar a acurácia;
- A análise concentrou-se exclusivamente na componente vertical da GRF, não incluindo momentos articulares ou forças nos eixos anteroposterior e mediolateral;
- As inferências foram realizadas offline, sem testes em tempo real ou em sistemas embarcados.

##### C. Perspectivas Futuras

Para futuros desenvolvimentos, este trabalho aponta as seguintes direções:

- Expansão dos modelos para sistemas multissensoriais, utilizando dados simultâneos de sensores em diferentes segmentos corporais;
- Aplicação dos modelos em populações clínicas (ex.: pacientes com distúrbios de marcha, idosos) e em ambientes mais desafiadores (escadas, rampas, terrenos irregulares);
- Exploração de arquiteturas mais avançadas, como Transformers e modelos auto-supervisionados, que têm se mostrado promissores na modelagem de séries temporais complexas;
- Implementação dos modelos em dispositivos embarcados para análise em tempo real, viabilizando sua aplicação em clínicas, academias ou na prática esportiva;
- Ampliação da modelagem para outras variáveis biomecânicas, como forças horizontais e momentos articulares, promovendo uma análise biomecânica mais abrangente.

Os resultados deste estudo reforçam o potencial das redes neurais profundas aplicadas à biomecânica, especialmente quando combinadas com sensores inerciais portáteis, possibilitando avanços significativos na análise da marcha em ambientes clínicos, esportivos e cotidianos.

#### REFERENCES

- [1] Winter, D. A. *Biomechanics and Motor Control of Human Movement*. 4th ed., John Wiley & Sons, 2009.

- [2] Perry, J., & Burnfield, J. M. *Gait Analysis: Normal and Pathological Function*. 2nd ed., SLACK Incorporated, 2010.
- [3] Maeda, T., Ishizuka, T., Yamaji, S., & Ohgi, Y. (2018). A Force Platform Free Gait Analysis. *Proceedings*, 2(6), 207.
- [4] Chaaban, C. R., Berry, N. T., Armitano-Lago, C., Kiefer, A. W., Mazzoleni, M. J., & Padua, D. A. (2021). Combining Inertial Sensors and Machine Learning to Predict vGRF and Knee Biomechanics during a Double Limb Jump Landing Task. *Sensors*, 21(13), 4383.
- [5] Herssens, N., How, D., van de Berg, R., & McCrum, C. (2022). Falls Among People With Bilateral Vestibulopathy: A Review of Causes, Incidence, Injuries, and Methods. *JAMA Otolaryngology–Head & Neck Surgery*, 148(2), 187–194.
- [6] Johnson, W. R., Mian, A., Robinson, M. A., Verheul, J., Lloyd, D. G., & Alderson, J. A. (2021). Multidimensional Ground Reaction Forces and Moments From Wearable Sensor Accelerations via Deep Learning. *IEEE Transactions on Biomedical Engineering*, 68(1), 289–297.
- [7] Chen, C.-Y., Chen, C.-L., Chen, H.-C., Wu, K.-P., Hsieh, W.-L., & Hsu, H.-C. (2007). Ground reaction force patterns in stroke patients with various degrees of motor recovery determined by plantar dynamic analysis. *Archives of Physical Medicine and Rehabilitation*, 88(12), 1536–1540.
- [8] Arshad, M. Z., Jamsrandorj, A., Kim, J., & Mun, K.-R. (2022). Gait events prediction using hybrid CNN-RNN-based deep learning models through a single waist-worn wearable sensor. *Sensors*, 22(21), 8226.
- [9] Bai, S., Kolter, J. Z., & Koltun, V. (2018). An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *arXiv preprint arXiv:1803.01271*.
- [10] Pimentel, M. B., Koerich, G., Mota, J. M., & Ferreira, J. P. (2024). Effect of sensor placement and number on the estimation of vertical ground reaction force during walking. *PLOS Digital Health*, 3(2), e0000343.
- [11] S. Havashinezhadian, L. Chiasson-Poirier, J. Sylvestre, and K. Turcot, “Inertial sensor location for ground reaction force and gait event detection using reservoir computing in gait,” *International Journal of Environmental Research and Public Health*, vol. 20, no. 4, p. 3120, 2023.
- [12] Grouvel, G., Carcreff, L., Moissenet, F., & Armand, S. (2023). A dataset of asymptomatic human gait and movements obtained from markers, IMUs, insoles and force plates. *Scientific Data*, 10, 180.
- [13] Gait Up. *Physilog® – Wearable gait lab for clinical and sports analysis*. Disponível em: <https://physilog.com>. Acesso em: 19 maio 2025.
- [14] Moticon ReGo AG. *Moticon – Wireless Sensor Insoles and Analytics Software*. Disponível em: <https://moticon.com>. Acesso em: 19 maio 2025.
- [15] MathWorks. *xcorr - Correlação Cruzada*. Documentação do MATLAB. Disponível em: <https://www.mathworks.com/help/matlab/ref/xcorr.html>. Acesso em: 21 maio 2025.
- [16] Wang, Z., Wang, J., Zhang, J., & Ma, Y. (2014). Gait symmetry based on principal component analysis method. *Journal of Healthcare Engineering*, 5(1), 59–74. doi:10.1260/2040-2295.5.1.59.
- [17] Reiss, A., & Stricker, D. (2012). Introducing a New Benchmarked Dataset for Activity Monitoring. In *Proceedings of the 2012 16th International Symposium on Wearable Computers (ISWC)* (pp. 108–109). IEEE.
- [18] Hammerla, N. Y., Halloran, S., & Plötz, T. (2016). Deep, convolutional, and recurrent models for human activity recognition using wearables. In *Proceedings of the 25th International Joint Conference on Artificial Intelligence (IJCAI)*, 1533–1540.
- [19] Zoph, B., & Le, Q. V. (2017). Neural Architecture Search with Reinforcement Learning. *arXiv preprint*, arXiv:1611.01578.
- [20] Rahman, M. M., Rahman, S. U., Nguyen, A., & Song, J. (2025). LEMONADE: A Large Language Model-Augmented Neural Architecture Design Framework. *Scientific Reports*, 15, 97378.

Link de acesso:

<https://github.com/Sergio-Jr86/Disserta-o-Sergio-Lima.git>

## APPENDIX

Repósitório contendo:

- Os scripts em Matlab dos modelos propostos, cálculo da correlação cruzada e inferência da GRF;
- Arquivos .csv dos resultados das métricas de cada modelo, correlação cruzada e inferência e resíduos;
- Arquivos .mat dos parâmetros de normalização e treinamento de cada modelo.