

Universidade Federal do Pará
Instituto de Tecnologia
Programa de Pós Graduação em Engenharia Elétrica

**Estimativa da força de reação do solo a partir de dados de acelerômetros
com redes neurais profundas: Um estudo comparativo entre arquiteturas
Bi-LSTM, TCN e híbrida**

Sérgio de Nazaré Rodrigues Lima Júnior
DM: 24/2025

Belém-PA

2025

Universidade Federal do Pará
Instituto de Tecnologia
Programa de Pós Graduação em Engenharia Elétrica

Sérgio de Nazaré Rodrigues Lima Júnior
DM: 24/2025

Estimativa da força de reação do solo a partir de dados de acelerômetros com redes neurais profundas: Um estudo comparativo entre arquiteturas Bi-LSTM, TCN e híbrida

Dissertação submetida à banca examinadora do programa de pós-graduação em engenharia elétrica da UFPa para a obtenção do grau de mestre em engenharia elétrica na área de telecomunicações

Orientador: Prof. Dr. Antônio Pereira Junior
Coorientador: Prof. Dr. Ronaldo de Freitas Zampolo

Belém-PA

2025

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)

L732e Lima Júnior, Sérgio de Nazaré.
Estimativa da força de reação do solo a partir de dados de acelerômetros com redes neurais profundas: Um estudo comparativo entre arquiteturas Bi-LSTM, TCN e híbrida / Sérgio de Nazaré Lima Júnior. — 2019.
64 f. : il. color.

Orientador(a): Prof. Dr. Antônio Pereira Júnior
Coorientador(a): Prof. Dr. Ronaldo de Freitas Zampolo
Dissertação (Mestrado) - Universidade Federal do Pará,
Instituto de Tecnologia, Programa de Pós-Graduação em
Engenharia Elétrica, Belém, 2019.

1. Força de Reação do Solo. 2. Redes Neurais Profundas.
3. Sensores Inerciais. 4. Biomecânica da Marcha. I. Título.

CDD 621.3822



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

“ESTIMATIVA DA FORÇA DE REAÇÃO DO SOLO A PARTIR DE ACELERÔMETROS COM REDES NEURAS PROFUNDAS: UM ESTUDO COMPARATIVO ENTRE ARQUITETURAS BI-LSTM, TCN E HÍBRIDA”

AUTOR: SÉRGIO DE NAZARÉ RODRIGUES LIMA JÚNIOR

DISSERTAÇÃO DE MESTRADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA NA ÁREA DE TELECOMUNICAÇÕES.

APROVADA EM: 12/08/2025

BANCA EXAMINADORA:

Prof. Dr. Antônio Pereira Júnior
(Orientador - PPGEE/ITEC/UFPA)

Prof. Dr. Ronaldo de Freitas Zampolo
(Coorientador - FCT/UFPA)

Prof. Dr. Bruno Duarte Gomes
(Avaliador Interno - PPGEE/ITEC/UFPA)

Prof. Dr. Felipe de Oliveira Matos
(Avaliador Externo - UEM)

VISTO:

Prof. Dr. Diego Lisboa Cardoso
(Coordenador do PPGEE/ITEC/UFPA)

A todos que me ajudaram.

Agradecimentos

A Deus, pela dádiva da vida e pela graça de me permitir chegar até aqui, concluindo mais esta etapa acadêmica, que representa muito mais do que um título, mas uma vitória pessoal, familiar e espiritual.

À minha família, que é a base de tudo. À minha mãe, **Nazaré Silva**, e à minha avó, **Marciana Ribeiro**, exemplos de força, resiliência e amor incondicional, que nunca mediram esforços, de infinitas maneiras, para que eu pudesse seguir em frente e trilhar o caminho dos estudos. Ao meu irmão, **Márcio Lima**, e ao meu tio, **Edgar Tocantins**, que sempre estiveram presentes, oferecendo apoio, incentivo e suporte em todos os momentos decisivos dessa caminhada.

À minha esposa, **Iasmim Vasconcelos**, e à minha filha, **Maitê Lima**, por compreenderem com amor e paciência minhas longas jornadas de dedicação. Vocês são minha maior motivação e razão para acreditar que todo esforço vale a pena.

Aos amigos de graduação, **Carlos, Diogo, Luiz e Gabriel**, que foram fundamentais no início dessa trajetória, me incentivando, acreditando no meu potencial e me ajudando a compreender que este sonho era possível e alcançável.

Ao **Professor Dr. Antônio Pereira Júnior** e ao **Prof. Dr. Ronaldo de Freitas Zampolo**, pela excelente orientação, pela dedicação, pela partilha de conhecimento e pela condução cuidadosa e competente ao longo desta pesquisa. Suas contribuições foram fundamentais para a construção deste trabalho e para minha formação acadêmica e profissional.

À equipe do **Laboratório de Processamento de Sinais (LaPS)**, pelo acolhimento, pela troca de conhecimentos e por sempre proporcionarem um ambiente colaborativo e enriquecedor para o desenvolvimento científico.

Por fim, agradeço à **Universidade Federal do Pará (UFPA)**, pela oportunidade e por ser este espaço transformador de vidas, e à universidade pública brasileira, que, mesmo diante dos desafios, continua sendo farol de esperança, desenvolvimento e construção do conhecimento.

*“A educação é amarga em suas raízes,
mas doce em seus frutos.”*
(Aristóteles)

Resumo

A força de reação do solo (Ground Reaction Force – GRF) é uma variável biomecânica essencial para a análise da marcha humana, amplamente utilizada em contextos clínicos, esportivos e de reabilitação. Tradicionalmente, sua medição precisa depende de plataformas de força ou palmilhas instrumentadas, equipamentos de alto custo e restritos a laboratórios especializados. Este estudo propõe uma alternativa baseada na estimativa da GRF por meio de sinais de acelerômetros processados por redes neurais profundas. Foram comparadas três arquiteturas: Bi-LSTM (Bidirectional Long Short-Term Memory), TCN (Temporal Convolutional Network) e uma arquitetura Híbrida. O pré-processamento envolveu filtragem, normalização por z-score e janelamento, e o treinamento supervisionado foi realizado com validação cruzada. Os resultados demonstraram que o sensor posicionado no pé apresenta a maior similaridade com a GRF, justificando seu uso nos modelos. Entre as arquiteturas, o modelo Híbrido obteve o melhor desempenho em termos de acurácia (RMSE de 103,22 N, rRMSE de 6,90%, $R^2 = 0,87$ e correlação cruzada de 0,96), enquanto a Bi-LSTM apresentou resultados próximos, porém com maior custo de treinamento. Já a TCN, apesar de ser a mais eficiente em termos de tempo de processamento (6 minutos e 13 segundos no treinamento e 0,02 segundos por predição), apresentou desempenho inferior (RMSE de 152,05 N, rRMSE de 10,49% e $R^2 = 0,70$). Esses achados evidenciam um compromisso entre desempenho e eficiência computacional: o modelo Híbrido destacou-se como a melhor opção para estimativas precisas da GRF. Em todos os casos, os tempos de inferência foram reduzidos e compatíveis com aplicações em tempo real, confirmando a viabilidade da abordagem proposta para monitoramento da marcha fora de ambientes laboratoriais.

Palavras-chave: Força de Reação do Solo. Redes Neurais Profundas. Sensores Inerciais. Biomecânica da Marcha

Abstract

The ground reaction force (GRF) is an essential biomechanical variable for human gait analysis, widely used in clinical, sports, and rehabilitation contexts. Traditionally, its accurate measurement depends on force platforms or instrumented insoles, which are expensive devices restricted to specialized laboratories. This study proposes an alternative approach based on GRF estimation through accelerometer signals processed by deep neural networks. Three architectures were compared: Bi-LSTM (Bidirectional Long Short-Term Memory), TCN (Temporal Convolutional Network), and a Hybrid architecture. The preprocessing stage involved filtering, z-score normalization, and windowing, and supervised training was performed with cross-validation. The results showed that the sensor positioned on the foot presented the highest similarity with the GRF, justifying its use in the models. Among the architectures, the Hybrid model achieved the best performance in terms of accuracy (RMSE of 103.22 N, rRMSE of 6.90%, $R^2 = 0.87$, and cross-correlation of 0.96), while the Bi-LSTM achieved similar results but with higher training cost. On the other hand, the TCN, although the most efficient in terms of processing time (6 minutes and 13 seconds for training and 0.02 seconds per prediction), showed inferior performance (RMSE of 152.05 N, rRMSE of 10.49%, and $R^2 = 0.70$). These findings highlight a trade-off between performance and computational efficiency: the Hybrid model stood out as the best option for accurate GRF estimation. In all cases, inference times were reduced and compatible with real-time applications, confirming the feasibility of the proposed approach for gait monitoring outside laboratory environments.

Keywords: Ground Reaction Force. Deep Neural Networks. Inertial Sensors. Gait Biomechanics.

Lista de ilustrações

Figura 1	– Representação esquemática completa do ciclo completo da marcha humana.	19
Figura 2	– Comparação entre uma curva da Força de Reação do Solo normal e a curva de uma avaliação diagnóstica da marcha patológica.	20
Figura 3	– Esquema de uma plataforma de força, destacando a medição das componentes verticais e de cisalhamento.	21
Figura 4	– Montagens experimentais com plataformas de força embutidas em esteiras, escadas, rampas e pisos.	21
Figura 5	– Componentes da GRF durante um ciclo de marcha típico.	22
Figura 6	– Exemplos de configuração experimental com IMUs e marcadores: (a) colocação dos sensores; (b) posicionamento de marcadores em malhas elásticas nos membros inferiores; (c) visão lateral com marcadores e placas de referência fixados nas regiões da coxa e da perna.	23
Figura 7	– Posicionamento típico de sensores inerciais para análise da marcha.	24
Figura 8	– Estrutura básica da RNN. A esquerda é ilustrado o seu diagrama geral e a direita seu diagrama mais detalhado.	25
Figura 9	– Arquitetura de uma célula de memória LSTM.	27
Figura 10	– Arquitetura de uma rede Bi-LSTM para predição da componente vertical da GRF, delimitada pela cor azul.	28
Figura 11	– Arquitetura básica de uma rede CNN.	29
Figura 12	– Arquitetura típica de uma Rede TCN, com convoluções dilatadas e blocos residuais.	31
Figura 13	– Configuração completa dos sensores em um participante: sistema óptico com marcadores, IMUs fixados com tiras elásticas e palmilhas instrumentadas posicionadas nos calçados.	36
Figura 14	– Ilustração do efeito da filtragem em um sinal com ruído de alta frequência.	39
Figura 15	– Média da correlação cruzada entre a magnitude da aceleração dos sensores inerciais e a GRF.	45
Figura 16	– Gráfico do atraso médio dos sensores inerciais em relação à GRF.	46
Figura 17	– Boxplot dos valores de RMSE obtidos para as arquiteturas Bi-LSTM, TCN e Híbrida ao longo da validação cruzada com 5 folds.	47
Figura 18	– Comparação entre GRF real (laranja) e predita (azul) para o pé direito utilizando os três modelos.	50
Figura 19	– Comparação entre GRF real (laranja) e predita (azul) para o pé esquerdo utilizando os três modelos.	51

Lista de tabelas

Tabela 1 – Descrição das camadas da arquitetura Bi-LSTM	41
Tabela 2 – Descrição das camadas da arquitetura TCN	41
Tabela 3 – Descrição das camadas da arquitetura híbrida CNN-BiLSTM	42
Tabela 4 – Configurações de treinamento comuns às redes	43
Tabela 5 – Resultados da correlação cruzada entre aceleração e GRF.	45
Tabela 6 – Média das métricas por modelo após validação cruzada com 5 folds	46
Tabela 7 – Métricas de estimativa para o pé direito (GRF real vs. estimada)	47
Tabela 8 – Métricas de predição para o pé esquerdo (GRF real vs. estimada)	48
Tabela 9 – Tempo total de processamento de treinamento por arquitetura	48
Tabela 10 – Tempo de inferência por arquitetura	49
Tabela 11 – Quantidade de parâmetros dos modelos analisados.	49
Tabela 12 – Comparação entre os modelos. Os melhores valores em cada característica estão destacados em negrito.	55

Lista de abreviaturas e siglas

Bi-LSTM	<i>Bidirectional Long Short-Term Memory</i> – Memória de Longo e Curto Prazo Bidirecional
BPTT	<i>Backpropagation Through Time</i> – Retropropagação no Tempo
CoP	<i>Center of Pressure</i> – Centro de Pressão
CNN	<i>Convolutional Neural Network</i> – Rede Neural Convolutacional
FSR	<i>Force Sensing Resistor</i> – Sensor Resistivo de Força
GRF	<i>Ground Reaction Force</i> – Força de Reação do Solo
GRU	<i>Gated Recurrent Unit</i> – Unidade Recorrente com Portas
IMU	<i>Inertial Measurement Unit</i> – Unidade de Medição Inercial
LSTM	<i>Long Short-Term Memory</i> – Memória de Longo e Curto Prazo
MATLAB	<i>Matrix Laboratory</i> – Ambiente de Programação e Computação Numérica
RMSE	<i>Root Mean Square Error</i> – Erro Quadrático Médio
RNN	<i>Recurrent Neural Network</i> – Rede Neural Recorrente
rRMSE	<i>Relative Root Mean Square Error</i> – Erro Quadrático Médio Relativo
R^2	Coefficiente de Determinação
TCN	<i>Temporal Convolutional Network</i> – Rede Neural Convolutacional Temporal
vGRF	<i>Vertical Ground Reaction Force</i> – Componente Vertical da Força de Reação do Solo

Lista de símbolos

F_v	Componente vertical da força de reação do solo (N)
F_{ap}	Componente anteroposterior da força de reação do solo (N)
F_{ml}	Componente mediolateral da força de reação do solo (N)
a_x	Aceleração no eixo X (m/s^2)
a_y	Aceleração no eixo Y (m/s^2)
a_z	Aceleração no eixo Z (m/s^2)
a_{mag}	Magnitude da aceleração (m/s^2)
μ	Média aritmética
σ	Desvio padrão
t	Tempo (s)
τ	Defasagem temporal na função de correlação cruzada (s ou amostras)
ρ_τ	Coefficiente de correlação cruzada para defasagem τ .
y_i	Valor real da força de reação do solo na amostra i
\hat{y}_i	Valor estimado da força de reação do solo na amostra i
\bar{y}	Média dos valores reais da GRF
n	Número total de amostras
W	Matriz de pesos da rede neural
θ	Vetor de parâmetros do modelo (pesos e bias)
h_t	Estado oculto na etapa temporal t em redes recorrentes

Sumário

1	INTRODUÇÃO	15
1.1	Contextualização	15
1.2	Relevância do Estudo	16
1.3	Justificativa	16
1.4	Objetivo Geral	17
1.5	Objetivos Específicos	17
1.6	Estrutura da Dissertação	17
2	REFERENCIAL TEÓRICO	19
2.1	Biomecânica da Marcha Humana	19
2.2	Força de Reação do Solo	20
2.3	Sensores Inerciais e Acelerômetros	23
2.4	Redes Neurais Profundas para Séries Temporais	24
2.4.1	Redes Neurais Recorrentes (RNNs)	24
2.4.1.1	Redes Long Short-Term Memory (LSTM)	25
2.4.1.2	Redes Bi-LSTM	27
2.4.2	Redes neurais Convolucionais (CNNs)	28
2.4.2.1	Redes Convolucionais Temporais (TCNs)	30
2.5	Trabalhos Relacionados	32
2.5.0.1	Predição de GRF a partir de Acelerômetros com Modelos Tradicionais	32
2.5.0.2	Predição da GRF com Redes Neurais Profundas	32
2.5.0.3	Modelos Híbridos para Predição Biomecânica	33
2.5.0.4	Predição de Séries Temporais com Redes TCNs	33
2.5.0.5	Contribuição do Dataset Utilizado	33
2.6	Lacunas e Motivação do Presente Estudo	34
3	MATERIAIS E MÉTODOS	35
3.1	Desenho Geral do Estudo	35
3.2	Base de Dados Utilizada	35
3.3	Análise de Correlação Cruzada entre os Dados de Acelerômetros e GRF	37
3.4	Pré-processamento dos Dados	38
3.4.1	Filtragem	38
3.4.2	Normalização dos Dados	39
3.4.2.0.1	Normalização dos sinais de entrada.	39
3.4.2.0.2	Normalização da variável de saída.	40
3.4.3	Criação de Janelas Temporais	40

3.5	Descrição das Arquiteturas de Redes Neurais	41
3.5.1	Modelo Bi-LSTM	41
3.5.2	Modelo TCN	41
3.5.3	Modelo híbrido TCN-BiLSTM	41
3.6	Parâmetros de Treinamento dos Modelos	42
3.7	Métricas de Avaliação	43
4	RESULTADOS	45
4.1	Correlação Cruzada entre os Sensores Inerciais e os dados de GRF	45
4.2	Comparação entre os Modelos Propostos	46
4.3	Resultados Quantitativos	47
4.4	Análise do Tempo de Treinamento e Inferência	48
4.5	Análise da Complexidade dos Modelos	49
4.6	Análise Gráfica das Estimativas	49
5	DISCUSSÃO	52
	REFERÊNCIAS	58
	APÊNDICE A – CÓDIGO-FONTE E ARQUIVOS DO ESTUDO	62

1 Introdução

1.1 Contextualização

A força de reação do solo (Ground Reaction Force – GRF) é uma variável biomecânica fundamental na análise da marcha humana, muito utilizada em avaliação funcional, reabilitação e na performance motora em contextos clínicos e esportivos (WINTER, 2009; PERRY; BURNFIELD, 2010). Essa força é o resultado da interação entre o corpo humano, especificamente os pés, e o solo durante a marcha e fornece informações sobre o padrão dessa marcha.

A GRF pode ser medida por plataformas de força fixas ao solo, que captam suas componentes nos eixos vertical, anteroposterior e mediolateral com alta resolução temporal e espacial. Apesar de sua precisão, esses equipamentos possuem limitações importantes como o custo elevado, a necessidade de infraestrutura laboratorial especializada e a dependência de softwares especializados para análise dos resultados, o que interfere na representatividade natural dos dados coletados (MAEDA et al., 2018).

Em função dessas limitações, tem aumentado o interesse por soluções alternativas e de menor custo, como o uso de sensores inerciais como acelerômetros, integrados à técnicas de aprendizado de máquina para estimar a GRF de forma indireta (MAEDA et al., 2018; GUO et al., 2017). Essa mudança de técnicas tradicionais para soluções móveis é movida pelo desejo de se expandir a aplicação da análise biomecânica a contextos mais próximos da vida real, como ambientes externos, clínicas de fisioterapia e cenários esportivos.

Estudos recentes demonstram que é possível obter estimativas muito próximas da GRF real a partir de sensores inerciais usando modelos biomecânicos e redes neurais profundas. Por exemplo, Maeda et al. (2018) propuseram modelos para estimar forças e torques articulares sem o uso de plataformas de força, alcançando erros menores que 10% na predição da GRF. Esses resultados ratificam a viabilidade de realizar análises cinéticas em cenários extralaboratoriais, mais convenientes para os usuários finais, que muitas vezes são pacientes com restrição de movimentos e que encontram dificuldade para deslocamento aos locais de registro que utilizam equipamentos tradicionais.

Além disso, o avanço de bancos de dados abertos como os disponibilizados por Grouvel et al. (2023) e CAMARGO et al. (2021), oportunizam o acesso a bases sólidas para o desenvolvimento e avaliação de modelos de inteligência artificial para estimativa da GRF com informações cinemáticas, cinéticas e sinais de sensores vestíveis em diversas condições de marcha, sendo fundamental para a criação de modelos mais robustos e representativos.

Esses esforços são importantes para aplicações clínicas, como o monitoramento da marcha de idosos, avaliação da reabilitação neuromotora, desenvolvimento de próteses inteligentes e

acompanhamento de atletas em tempo real, permitindo tratamentos mais precisos e personalizados com base nesses dados biomecânicos advindos de sensores inerciais.

1.2 Relevância do Estudo

A possibilidade de estimar a GRF por meio de sensores inerciais e algoritmos de aprendizado de máquina é um avanço importante para permitir a análise do movimento humano em ambientes extra laboratoriais. Essa abordagem tem o potencial de popularizar o acesso à avaliação biomecânica, permitindo que a marcha e outros comportamentos motores de pacientes e atletas possam ser avaliados fora do contexto tradicional da clínica.

Estudos como o de Choi et al. (2024), demonstram que a predição da GRF pode ser realizada com técnicas de redes neurais a partir de dados oriundos de sensores de baixo custo, como FSRs, se aproximando da acurácia de sistemas comerciais mais sofisticados. Essa tecnologia já demonstrou melhoria de mais de 30% na acurácia preditiva em relação a abordagens convencionais.

Além disso, estudos como o de CHAABAN et al. (2021) e Havashinezhadian et al. (2023) comprovam que modelos que utilizam dados de sensores inerciais conseguem estimar com boa precisão a GRF em diferentes condições de marcha, com experimentos conduzidos tanto em ambientes laboratoriais quanto em situações mais próximas da vida real. Isso reforça o potencial de uso em contextos clínicos, domiciliares e esportivos, onde soluções portáteis e de fácil implementação são importantes.

A importância da análise dos dados de GRF pode ser comprovada, por exemplo, em populações idosas, auxiliando na identificação precoce de padrões de marcha associados com doenças neurodegenerativas (HERSSENS et al., 2022). Em contextos esportivos, ela permite o controle de carga durante treinos e competições, otimizando o desempenho e prevenindo lesões (JOHNSON et al., 2021). Na reabilitação neuromotora, esses dados podem ser utilizados para fornecer feedback a pacientes com sequelas neurológicas, auxiliando durante intervenções terapêuticas (CHEN et al., 2007).

O uso de redes neurais profundas também possibilita a modelagem não linear e dinâmica dos dados de acelerômetros, capturando padrões sutis que seriam difíceis de se obter com abordagens tradicionais (FENG; ZHANG; KHANDELWAL, 2021). Dessa forma, o presente estudo contribui tanto para o avanço do estado da arte em aprendizado profundo aplicado à biomecânica quanto para a viabilização de soluções práticas na área da engenharia biomédica.

1.3 Justificativa

A análise da GRF é fundamental para compreender a dinâmica da marcha humana e suas implicações em contextos clínicos e esportivos. Normalmente, a aquisição da GRF depende

de plataformas de força, que, apesar de precisas, apresentam limitações importantes quanto à portabilidade e custo (MAEDA et al., 2018). Estas limitações dificultam sua aplicação em ambientes extralaboratoriais e em favor de populações que se beneficiariam de avaliações mais acessíveis, como idosos e pacientes em reabilitação neuromotora.

Com o avanço das tecnologias de sensores inerciais e técnicas de aprendizado de máquina, surge a possibilidade de estimar a GRF de forma indireta, utilizando dispositivos portáteis e de menor custo. Essa abordagem permite avaliações em vários ambientes extraclínicos, promovendo um acompanhamento contínuo e personalizado da marcha. Além disso, a integração de sensores inerciais com modelos preditivos baseados em redes neurais profundas tem demonstrado resultados promissores na estimativa da GRF, com níveis de precisão adequados para aplicações clínicas e esportivas (ARSHAD et al., 2022).

O presente estudo justifica-se como uma contribuição científica para o esforço de desenvolver e validar modelos preditivos que utilizem dados de sensores inerciais para estimar a GRF, ampliando o acesso a avaliações biomecânicas e contribuindo para tratamentos mais eficazes em diferentes populações.

1.4 Objetivo Geral

Desenvolver e comparar modelos de redes neurais profundas para a predição da GRF a partir de dados de acelerômetros, visando aplicações em contextos clínicos e esportivos.

1.5 Objetivos Específicos

- Revisar a literatura sobre métodos de predição da GRF utilizando sensores inerciais e técnicas de aprendizado profundo.
- Utilizar e pré-processar dados de acelerômetros provenientes de um banco de dados de marcha humana.
- Implementar modelos de redes neurais profundas, como Bi-LSTM, TCN e uma rede híbrida, para estimar a GRF com base nos dados utilizados.
- Avaliar o desempenho dos modelos propostos utilizando métricas de erro e correlação.

1.6 Estrutura da Dissertação

Esta dissertação está organizada em cinco capítulos principais:

- **Capítulo 1 – Introdução:** apresenta a contextualização do tema, a relevância e a justificativa do estudo, os objetivos geral e específicos, e a motivação da pesquisa.

- **Capítulo 2 – Referencial Teórico:** discute os fundamentos da biomecânica da marcha humana, a GRF, os sensores inerciais e as principais arquiteturas de redes neurais profundas aplicadas à estimativa de sinais biomecânicos.
- **Capítulo 3 – Materiais e Métodos:** descreve o delineamento da pesquisa, os dados utilizados, as etapas de pré-processamento, a análise de correlação cruzada, as arquiteturas de redes neurais implementadas, as métricas de avaliação e os procedimentos de validação.
- **Capítulo 4 – Resultados:** apresenta os resultados obtidos pelos modelos propostos, com destaque para métricas quantitativas, desempenho computacional, análise gráfica e uma seção interpretativa baseada na literatura.
- **Capítulo 5 – Conclusão:** resume os principais achados da pesquisa, compara os resultados com a literatura, verifica o cumprimento dos objetivos, destaca as contribuições do estudo, discute suas limitações e propõe direções para investigações futuras.

Esta dissertação também inclui apêndice onde é disponibilizado o link do repositório de código-fonte dos modelos implementados, os parâmetros utilizados nas etapas de pré-processamento e arquivos .csv dos resultados, com o intuito de garantir reprodutibilidade e apoiar a continuidade desta linha de pesquisa.

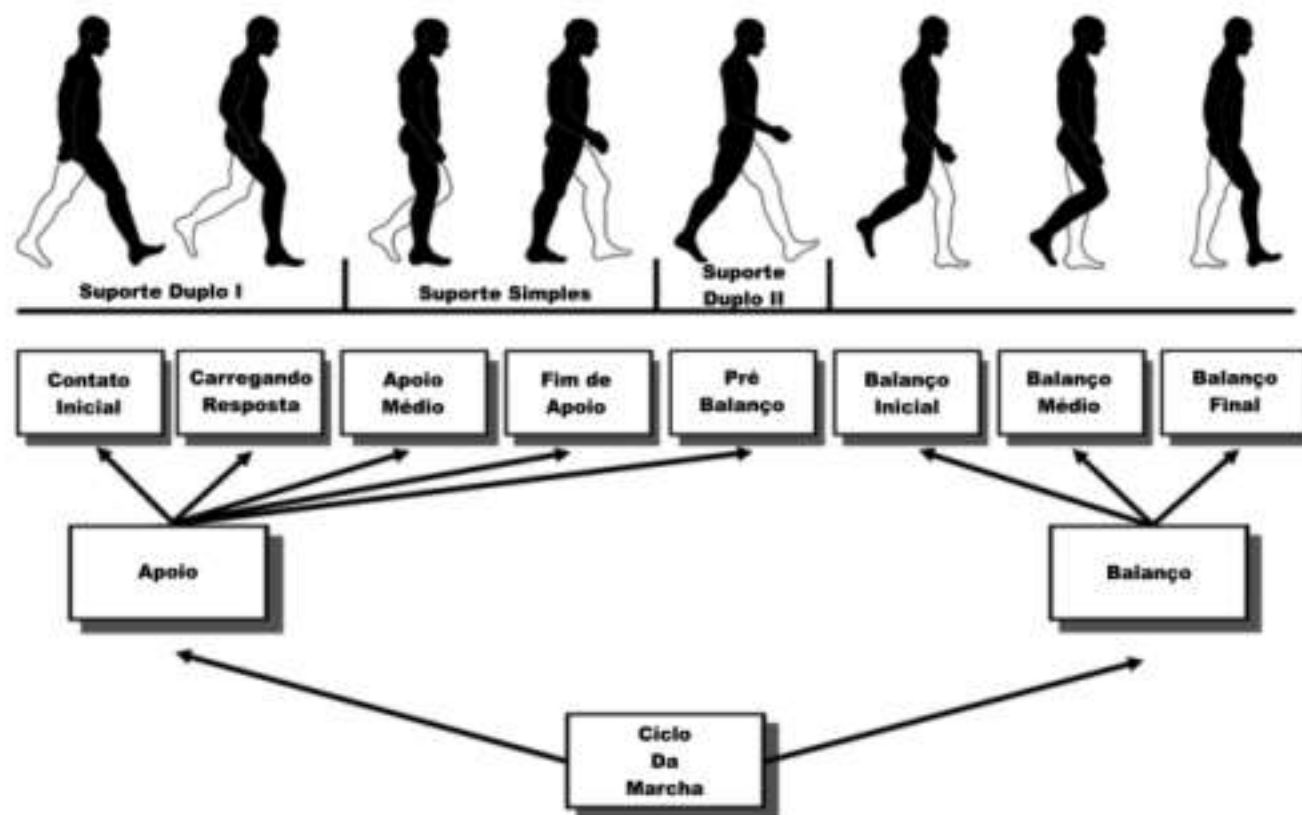
2 Referencial Teórico

2.1 Biomecânica da Marcha Humana

A marcha humana é um processo biomecânico composto por ciclos de movimentos coordenados entre múltiplos segmentos corporais e grupos musculares, cujo objetivo é promover o deslocamento eficiente do corpo no espaço (PERRY; BURNFIELD, 2010). Cada ciclo de marcha se inicia e termina com o contato inicial do mesmo pé com o solo, sendo classificado em duas fases principais: a fase de apoio, em que o pé está em contato com o solo; e a fase de balanço, quando o pé se desloca no ar em direção ao próximo passo (NOVACHECK, 1998). Essa divisão é fundamental para compreender os eventos biomecânicos associados à locomoção, incluindo a geração e a transmissão de forças pelo sistema musculoesquelético.

A marcha humana deve ser entendida como um processo no qual o controle neuromuscular atua para manter a estabilidade postural e a progressão suave do centro de massa do indivíduo. Cada segmento corporal contribui para o movimento, sendo que o padrão de movimento é resultado direto do equilíbrio entre forças externas e internas geradas pelos músculos e articulações. A análise cinética fornece informações importantes sobre a distribuição das cargas articulares, o torque gerado nos membros inferiores e o padrão de ativação muscular durante cada fase da marcha (WINTER, 2009).

Figura 1 – Representação esquemática completa do ciclo completo da marcha humana.



Fonte: Adaptado de (CICIRELLI et al., 2022)

Clinicamente, a análise da marcha é uma ferramenta fundamental para identificar

alterações, otimizar e monitorar a progressão de pacientes em tratamento fisioterapêutico. Com essa análise é possível identificar déficits de mobilidade, riscos de quedas e desequilíbrios neuromusculares (HERSSENS et al., 2022; NOVACHECK, 1998).

Portanto, compreender a biomecânica da marcha envolve a análise integrada da cinética, da cinemática e do controle motor pelo cérebro e não se limita apenas à descrição de fases e eventos temporais.


2.2 Força de Reação do Solo

A GRF pode ser definida como uma força exercida pelo solo sobre o corpo humano em resposta às forças que este exerce sobre a superfície durante o movimento. Conforme a terceira lei de Newton, para cada força exercida pelo corpo sobre o solo, há uma força de igual intensidade e direção oposta aplicada pelo solo ao corpo. A GRF é uma variável fundamental na análise cinética da marcha, sendo amplamente utilizada para avaliar padrões de locomoção, detectar assimetrias do movimento e diagnosticar disfunções neuromusculares (WINTER, 2009; PERRY; BURNFIELD, 2010).

A GRF possui três componentes ortogonais:


- Componente vertical, associada ao suporte do peso corporal;
- Componente anteroposterior, relacionada à frenagem e à propulsão;
- Componente mediolateral, relacionada ao controle do equilíbrio.

Figura 2 – Comparação entre uma curva da Força de Reação do Solo normal e a curva de uma avaliação diagnóstica da marcha patológica.



Essas forças podem ser representadas vetorialmente, combinando magnitude e direção em cada instante do ciclo da marcha, sendo que o ponto de aplicação do vetor resultante (Centro de Pressão – CoP) migra ao longo da superfície plantar durante o apoio do pé sobre a superfície de locomoção (PERRY; BURNFIELD, 2010).

Figura 3 – Esquema de uma plataforma de força, destacando a medição das componentes verticais e de cisalhamento.



Fonte: (HAVASHINEZHADIAN et al., 2023).

Na fase de apoio, várias forças atuam sobre o corpo, entre elas a GRF, considerada uma das variáveis biomecânicas mais relevantes. A GRF reflete a interação entre o corpo e a superfície de apoio, sendo crucial para a sustentação do corpo, absorção de impactos e geração de propulsão para o próximo passo (WINTER, 2009). A medição precisa da GRF é tradicionalmente realizada por meio de plataformas de força embutidas no solo, que capturam suas componentes verticais e horizontais (anteroposterior e mediolateral) (PERRY; BURNFIELD, 2010).

Figura 4 – Montagens experimentais com plataformas de força embutidas em esteiras, escadas, rampas e pisos.

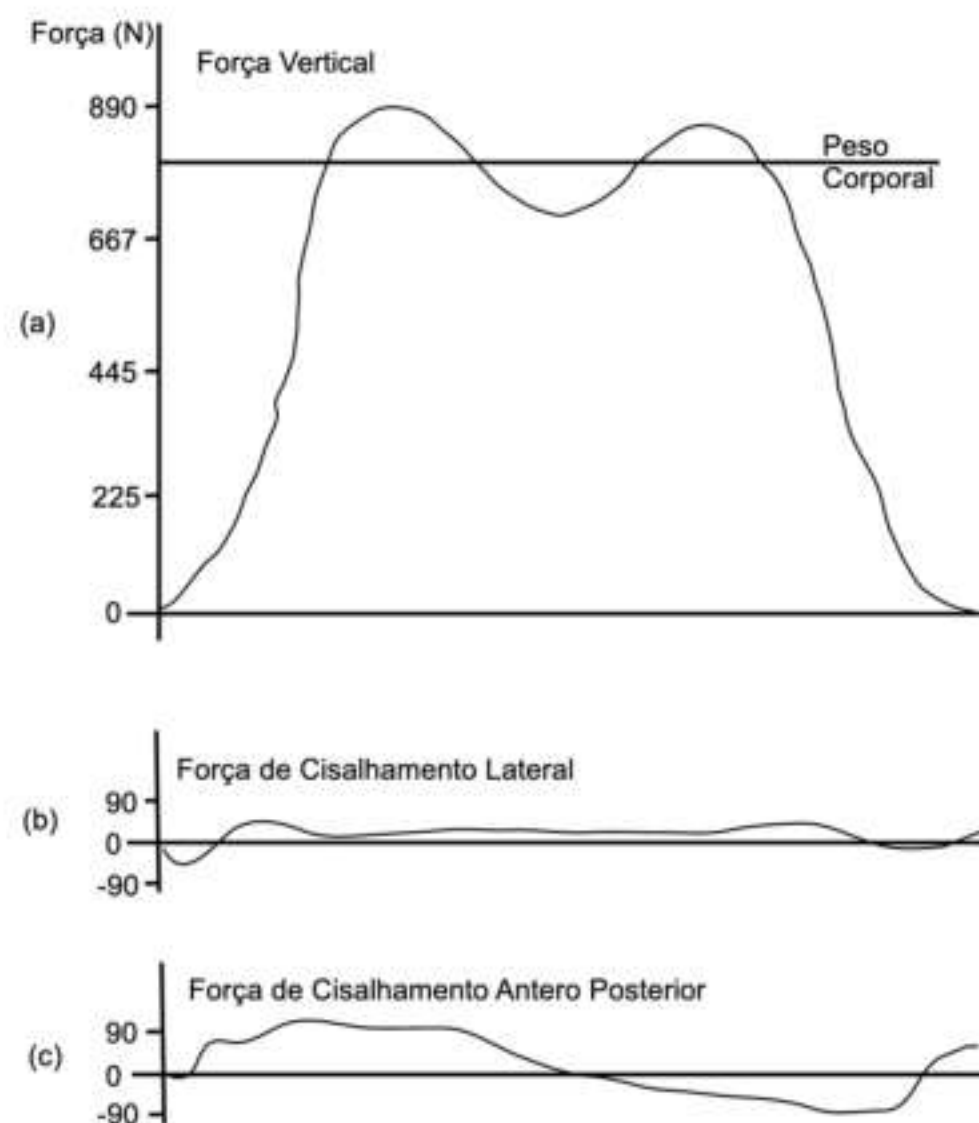


Fonte: (CAMARGO et al., 2021).

Devido à predominância da componente vertical da GRF na marcha, muitas abordagens se concentram exclusivamente nessa direção, uma vez que as componentes anteroposterior e mediolateral contribuem minimamente para a magnitude total da força durante o ciclo da marcha (MARTÍNEZ-PASCUAL et al., 2023). Isso permite que técnicas simplificadas de estimativa, baseadas em dados de acelerômetros, focalizem na força vertical, otimizando o processamento e mantendo a relevância clínica e biomecânica.

A Figura 5 ilustra a distribuição típica das forças de reação do solo durante a marcha. Observa-se que a componente vertical (a) apresenta dois picos e um vale intermediário, refletindo os momentos de aceitação de carga e impulsão do corpo, com valores que excedem o próprio peso corporal. Em contrapartida, as componentes de cisalhamento, lateral (b) e anteroposterior (c), possuem magnitudes muito menores e variação mais sutil ao longo do ciclo da marcha. Essa diferença de escala justifica por que a vGRF (vertical Ground Reaction Force) é frequentemente o foco principal em estudos de predição com sensores inerciais.

Figura 5 – Componentes da GRF durante um ciclo de marcha típico.

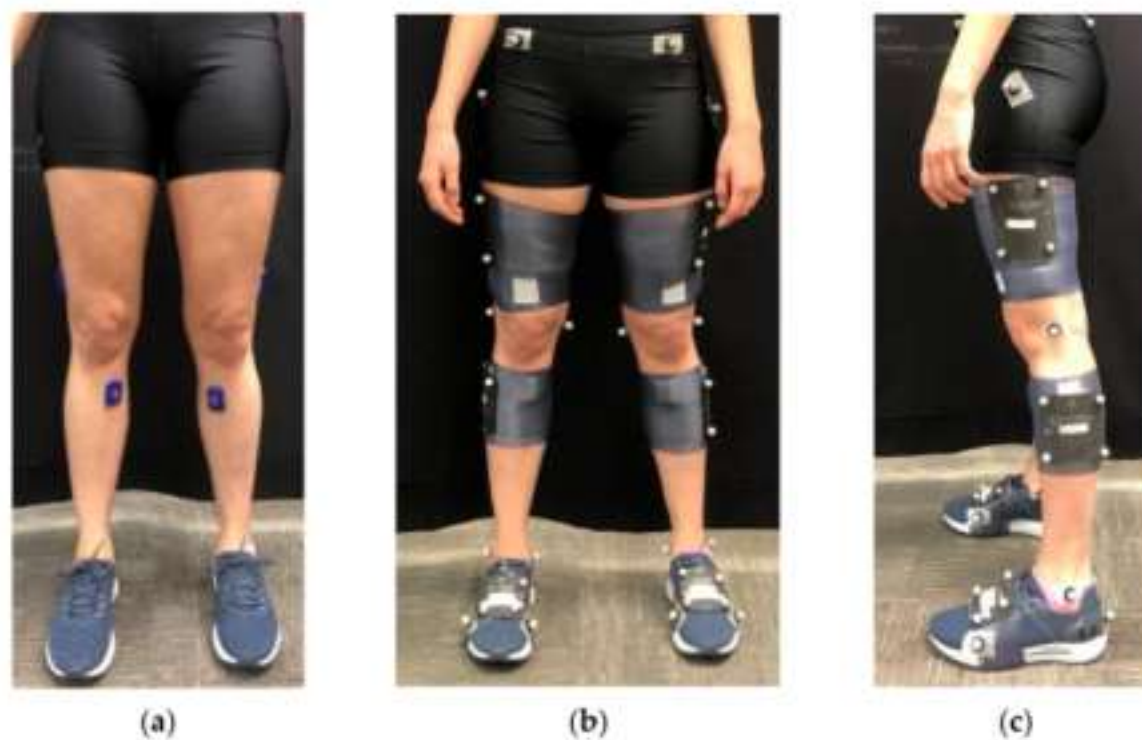


Durante a marcha, a curva da componente vertical da GRF exibe um padrão característico em forma de “M”, composto por dois picos e um vale intermediário. O primeiro pico acontece na fase de resposta à carga, indicando o impacto inicial do calcanhar no solo, enquanto o segundo pico aparece na fase de propulsão, ligado ao impulso gerado pela flexão plantar do tornozelo. Entre esses dois picos, há um vale correspondente ao apoio médio, quando o centro de massa corporal está diretamente sobre o pé de apoio (WINTER, 2009; PERRY; BURNFIELD, 2010).

2.3 Sensores Inerciais e Acelerômetros

Sensores inerciais, também conhecidos como Unidades de Medição Inercial (IMUs – Inertial Measurement Units), são dispositivos que combinam acelerômetros, giroscópios e, opcionalmente, magnetômetros. Quando posicionados em segmentos corporais, permitem estimar sua orientação em um sistema de coordenadas global, a partir da fusão dos dados dos sensores (PACHER et al., 2020).

Figura 6 – Exemplos de configuração experimental com IMUs e marcadores: (a) colocação dos sensores; (b) posicionamento de marcadores em malhas elásticas nos membros inferiores; (c) visão lateral com marcadores e placas de referência fixados nas regiões da coxa e da perna.



Fonte: (CHAABAN et al., 2021).

A Figura 6 ilustra diferentes configurações experimentais de posicionamento de IMUs e marcadores para análise da marcha. Destaca-se a fixação dos sensores sobre os principais segmentos dos membros inferiores, como a coxa, tíbia e pé, visando capturar com precisão os movimentos articulares durante a locomoção.


No contexto da análise da marcha humana, o uso de dados de acelerômetros tem sido amplamente explorado devido à sua portabilidade, baixo custo e fácil integração a dispositivos vestíveis. Esses sensores são capazes de capturar sinais relacionados à dinâmica corporal durante a locomoção, permitindo a detecção de eventos do ciclo da marcha. Além disso, acelerômetros apresentam menor sensibilidade a *drift* (desvio cumulativo de sinal) em comparação aos giroscópios, o que os torna mais adequados para aplicações de longo prazo sem necessidade de calibração frequente. Enquanto os giroscópios medem a velocidade angular e são úteis para capturar movimentos rotacionais, seu uso contínuo pode levar a erros acumulados ao integrar esses dados para obter orientação. Por isso, os acelerômetros são preferidos quando o objetivo principal é identificar padrões cíclicos e eventos temporais da marcha, com maior robustez e

menor dependência de processamento complexo (SY et al., 2021).

Todavia, o uso de acelerômetros exclusivamente impõe desafios, como a necessidade de calibração entre o sensor e o segmento corporal, a sincronização com outros dispositivos e a susceptibilidade a ruídos e artefatos de movimento. Diversas técnicas de calibração entre os sensores e os segmentos corporais tem sido propostas. No entanto não há consenso na literatura sobre o método mais adequado (PACHER et al., 2020).

Estudos recentes como o de Pimentel et al. (2024) mostram que a localização do sensor influencia diretamente a acurácia da estimativa da GRF. Posições como a região lombar (sacro) e a tíbia distal apresentam melhor correlação com os padrões da GRF durante a marcha, sendo recomendadas em protocolos de análise de marcha com sensores vestíveis. A Figura 7 ilustra o posicionamento típico das IMUs em estudos biomecânicos da marcha.

Figura 7 – Posicionamento típico de sensores inerciais para análise da marcha.



2.4 Redes Neurais Profundas para Séries Temporais

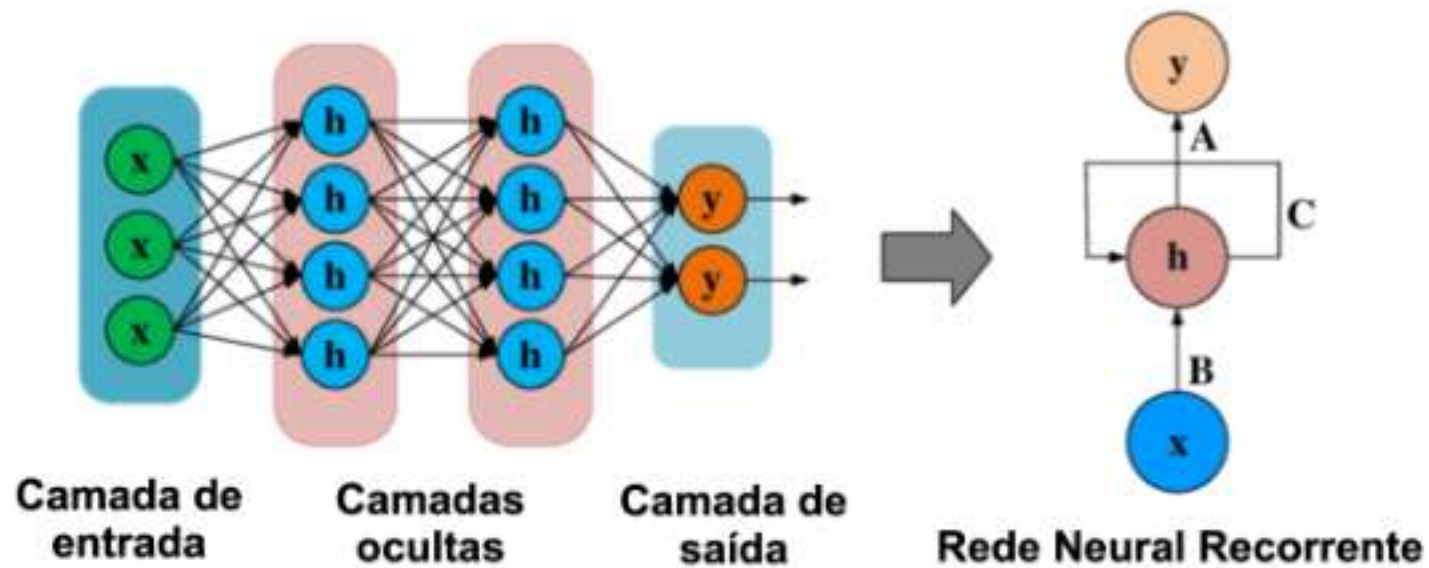
As redes neurais vêm sendo muito utilizadas para modelar dados temporais em aplicações como reconhecimento de atividade motora, previsão de movimento e estimativa de parâmetros biomecânicos que aproveitam a capacidade dos modelos de aprendizado profundo de capturar dependências temporais e características peculiares a partir de dados sequenciais, o que é crucial para interpretar com precisão as características da marcha. A junção de várias arquiteturas de redes neurais avançou significativamente, permitindo soluções cada vez mais eficientes (ARSHAD et al., 2022).

2.4.1 Redes Neurais Recorrentes (RNNs)

As RNNs são muito utilizadas para o processamento de dados sequenciais por sua capacidade de modelar dependências temporais complexas, permitindo que informações passadas

influenciem diretamente as previsões futuras, aspecto importante para a modelagem de variáveis biomecânicas que se modificam ao longo do tempo. Essa estrutura recursiva facilita a manutenção das componentes temporais da forma de onda da GRF, com previsões mais precisas em diferentes condições de marcha (ALCANTARA et al., 2022).

Figura 8 – Estrutura básica da RNN. A esquerda é ilustrado o seu diagrama geral e a direita seu diagrama mais detalhado.



Fonte: Adaptado de (SARKER et al., 2023).

A Figura 8 ilustra a estrutura básica de uma RNN. Essas redes introduzem conexões recorrentes que alimentam de volta o estado oculto de uma etapa anterior para a seguinte. Essa retroalimentação é a chave que permite à rede capturar dependências de longo prazo nas sequências temporais (SARKER et al., 2023).

As RNNs também realizam estimativas quase em tempo real de variáveis biomecânicas, o que as torna promissoras para aplicações fora do ambiente clínico/laboratorial, como o monitoramento de corridas em terrenos inclinados por meio de sensores vestíveis (ALCANTARA et al., 2022). No entanto, as RNNs apresentam algumas limitações. A principal delas está relacionada ao problema das dependências de longo prazo, pois a rede pode ter dificuldades em aprender relações entre eventos distantes na sequência temporal, devido à ocorrência de gradientes explosivos ou desvanecentes (HOCHREITER; SCHMIDHUBER, 1997). Embora modelos mais avançados, como as Long Short-Term Memory (LSTM) tenham sido desenvolvidas para diminuir esse problema, essa ainda é uma limitação das RNNs convencionais (BENGIO; SIMARD; FRASCONI, 1994).

Portanto, mesmo com as RNNs sendo altamente eficazes na modelagem de sequências temporais e apresentem potencial para previsão em tempo real de variáveis biomecânicas, suas limitações devem ser consideradas.

2.4.1.1 Redes Long Short-Term Memory (LSTM)

Como já foi mencionado, as redes LSTM superam algumas limitações das redes RNNs. A principal inovação das redes LSTM é o uso de células de memória dotadas de portas de entrada,

esquecimento e saída, que regulam o fluxo de informações ao longo do tempo, guardando estados importantes e permitindo que certas informações sejam armazenadas e acessadas mesmo após longas sequências temporais (HOCHREITER; SCHMIDHUBER, 1997). Essas portas atuam de forma seletiva, selecionando as informações que devem ser atualizadas, mantidas ou descartadas. Isso ajuda o modelo destacar apenas os estados mais relevantes da sequência temporal.

A Figura 9 detalha todos os componentes internos de uma célula de memória LSTM e o fluxo de dados entre eles. As portas multiplicativas (indicadas pelo símbolo de multiplicação \otimes) são responsáveis por controlar seletivamente quais informações serão mantidas, atualizadas ou descartadas.

A porta de esquecimento (f_t) recebe como entrada o estado oculto anterior h_{t-1} e a entrada atual x_t , passando por uma camada totalmente conectada (FC) com função de ativação sigmoide. Essa operação gera um vetor com valores entre 0 e 1, que determina quais partes do estado da célula anterior c_{t-1} devem ser mantidas ou descartadas.

A porta de entrada (i_t) é responsável por controlar a escrita de novas informações no estado da célula. Ela opera em conjunto com o vetor de atualização candidato g_t , que é obtido a partir de uma ativação tangente hiperbólica, também aplicada a uma camada totalmente conectada. A multiplicação entre i_t e g_t define o quanto das novas informações será armazenado na célula.


A porta de saída (o_t) determina qual parte da memória interna será exposta como saída h_t , também chamada de estado oculto da célula. Essa saída é obtida a partir da multiplicação entre a ativação $\tanh c_t$ e a saída da porta o_t , que também utiliza a função sigmoide.

As operações de adição (\oplus) e multiplicação elemento a elemento (\otimes) desempenham papel fundamental no mecanismo interno da célula, combinando os vetores das portas com os estados da célula em cada instante de tempo. O vetor c_t representa o estado da célula atualizado, enquanto $h_t = y_t$ corresponde ao estado oculto e saída da célula naquele instante.

A figura também evidencia que todas as portas dependem diretamente das entradas x_t e do estado oculto anterior h_{t-1} , reforçando a capacidade das LSTMs de modelar dependências temporais de longo prazo de forma eficaz.

Essa representação gráfica reflete a implementação moderna da LSTM, tal como proposta nas extensões da arquitetura original de Hochreiter e Schmidhuber (1997), e é amplamente utilizada em tarefas de modelagem sequencial, como previsão de séries temporais, reconhecimento de padrões temporais e processamento de linguagem natural (ALMANI; HAN, 2023).

Figura 9 – Arquitetura de uma célula de memória LSTM.

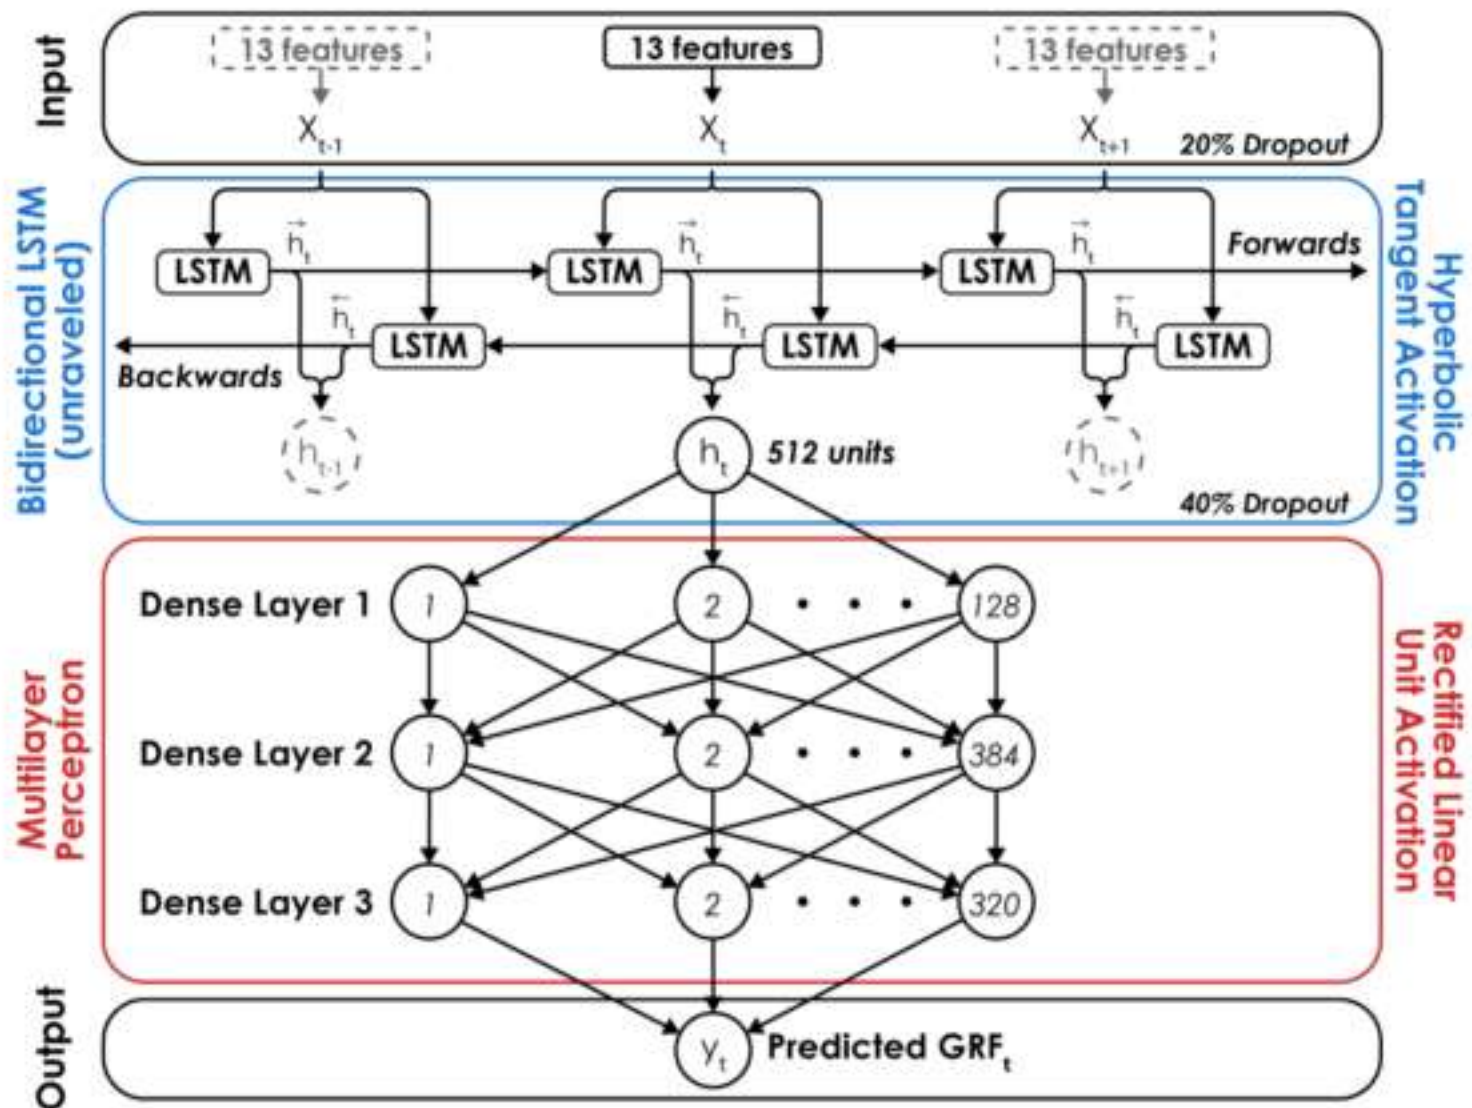


Fonte: (GÉRON, 2019).

2.4.1.2 Redes Bi-LSTM

Para que a rede neural processe sequências tanto na direção do tempo quanto na direção inversa, a variante bidirecional da LSTM foi desenvolvida. A arquitetura Bi-LSTM consiste em duas camadas LSTM paralelas: uma que processa a sequência de entrada no sentido direto (do tempo t_0 até t_n) e outra que a percorre no sentido reverso (de t_n até t_0). As saídas dessas duas redes são então combinadas para formar uma representação contextualizada bidirecional de cada instante da sequência (GRAVES; SCHMIDHUBER, 2005).

Figura 10 – Arquitetura de uma rede Bi-LSTM para predição da componente vertical da GRF, delimitada pela cor azul.



Fonte: (ALCANTARA et al., 2022).

Esse modelo é importante para tarefas onde a informação relevante não está apenas no passado, mas também no futuro próximo da sequência. A arquitetura Bi-LSTM é muito utilizada para geração de sequências complexas, como texto e traços de escrita manual (GRAVES, 2013), demonstrando sua eficiência em modelar estruturas de longo alcance em diferentes domínios sequenciais. No contexto de séries temporais biomecânicas, essa característica permite que a rede compreenda melhor mudanças entre as fases do ciclo da marcha, como o momento do contato inicial do calcanhar ou a fase de propulsão, melhorando a predição da GRF.

A variante bidirecional da rede LSTM apresenta estabilidade superior em tarefas de geração e modelagem sequencial, estando menos sujeita a problemas de instabilidade ao gerar sequências longas (GRAVES; SCHMIDHUBER, 2005). Essa característica é essencial para a predição da GRF, pois o modelo precisa manter coerência ao longo de ciclos completos da marcha, respeitando as transições entre suas fases (ALCANTARA et al., 2022).

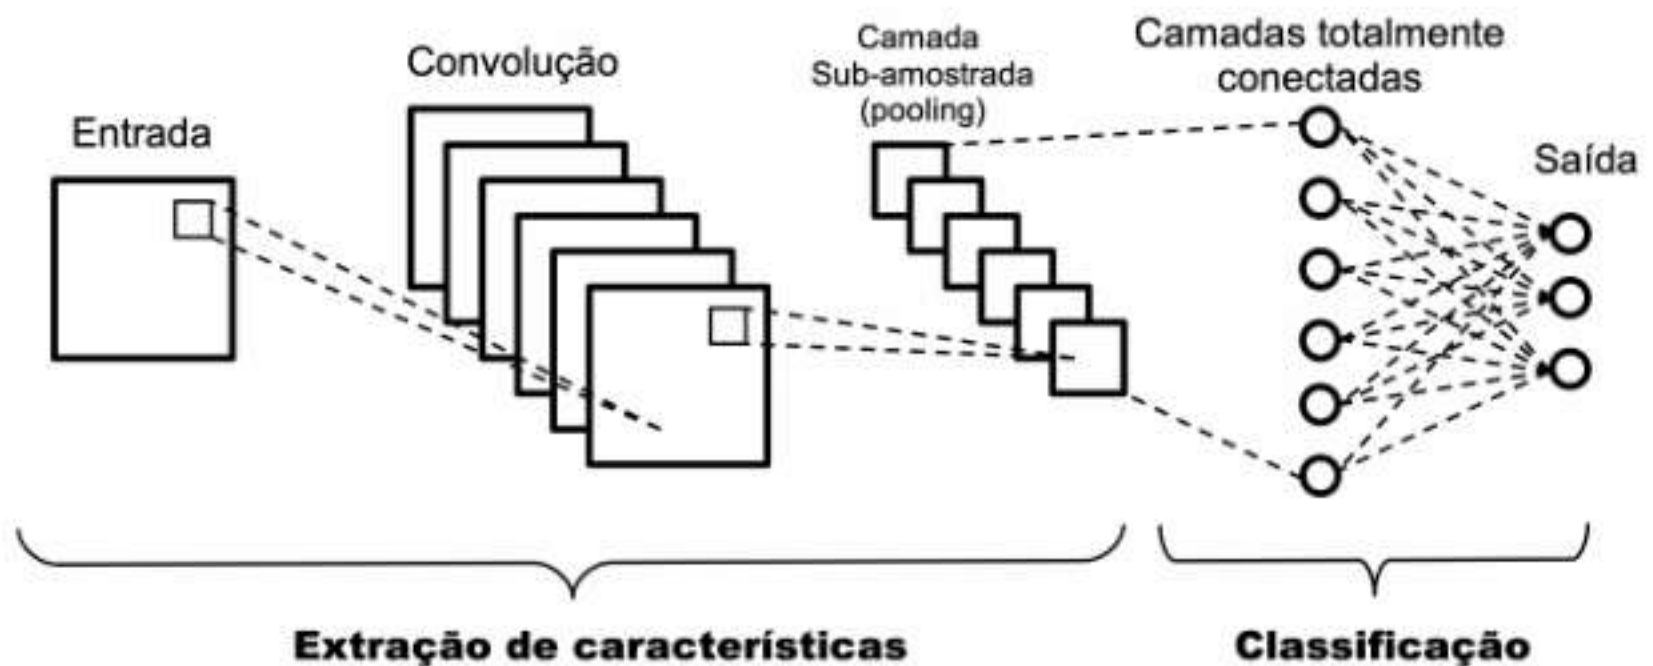
2.4.2 Redes neurais Convolucionais (CNNs)

As CNNs vêm se destacando como uma arquitetura eficiente para várias tarefas de processamento de sinais biomecânicos. Inicialmente desenvolvidas para o reconhecimento de padrões em imagens, as CNNs foram projetadas para explorar a estrutura espacial dos dados por

meio de operações de convolução local, o que as tornou extremamente eficazes em tarefas como classificação de imagens, detecção de objetos e segmentação semântica (LECUN; BENGIO; HINTON, 2015). Essa ênfase inicial em dados visuais impulsionou o desenvolvimento de mecanismos sofisticados de extração de características locais e hierárquicas, que posteriormente se mostraram vantajosos também em outros domínios de dados estruturados. Entre suas principais vantagens está exatamente essa capacidade robusta de extrair características espaciais, o que é especialmente útil em sinais biomecânicos complexos, como os captados por acelerômetros ou pelas trajetórias de marcadores durante a marcha humana. Essa característica permite que as CNNs identifiquem padrões locais relevantes, como aqueles associados a eventos de contato do pé com o solo. As redes CNNs demonstram grande potencial na extração dessas características, resultando em previsões precisas da GRF a partir de dados de captura de movimento, evidenciando sua eficácia na modelagem de padrões espaciais complexos presentes na marcha. (JOHNSON et al., 2019).

A Figura 11 ilustra de forma esquemática a arquitetura básica de uma CNN. O processo é dividido em duas etapas principais: extração de características e classificação. Na primeira, camadas convolucionais aplicam filtros aos dados de entrada para detectar padrões locais, seguidas por camadas de *pooling* que reduzem a dimensionalidade mantendo as informações mais relevantes. Na segunda etapa, os dados extraídos são processados por camadas totalmente conectadas (fully connected), que realizam a classificação desejada.

Figura 11 – Arquitetura básica de uma rede CNN.



Fonte: Adaptado de (PHUNG; RHEE, 2019)

As CNNs também oferecem uma eficiência computacional significativa, especialmente devido à possibilidade de processamento paralelo e ao compartilhamento de parâmetros, o que reduz o número de pesos e a complexidade do modelo (LECUN; BENGIO; HINTON, 2015). Essas características tornam as CNNs adequadas para aplicações em tempo real, nas quais latência e tempo de resposta reduzidos são fatores almejados. Outro ponto favorável é a robustez

apresentada por essas redes em diversas aplicações de reconhecimento de padrões, evidenciando seu potencial para tarefas mais complexas, incluindo a predição da GRF (O'SHEA; NASH, 2015).

Apesar das vantagens, as CNNs possuem limitações. Essas redes normalmente exigem grandes quantidades de dados para serem treinadas de forma eficaz. Em certas aplicações, obter tais conjuntos de dados pode ser um desafio. Outro fator importante é a necessidade de técnicas de regularização adequadas. Sem essas técnicas, as redes CNNs tendem a se sobreajustar, especialmente quando há limitação na quantidade de dados disponíveis. Isso pode gerar modelos com bom desempenho em dados de treinamento, mas ruins quando se utilizarem dados não vistos (HERNÁNDEZ-GARCÍA; KÖNIG, 2019).

Embora as redes CNNs sejam altamente eficazes na extração de padrões espaciais e ofereçam eficiência computacional para aplicações em tempo real, sua utilização para tarefas que envolvem dados sequenciais, como a predição da GRF, pode ser limitada. A integração com arquiteturas capazes de capturar dependências temporais continua sendo uma solução alternativa promissora para potencializar seu desempenho.

2.4.2.1 Redes Convolucionais Temporais (TCNs)

As TCNs representam uma evolução no campo do processamento de séries temporais, destacando-se como uma boa alternativa às RNNs, tradicionalmente utilizadas para essa finalidade. A TCN é uma adaptação da CNN ao domínio temporal, estruturada para lidar com sequências, preservando a ordem dos dados e respeitando a causalidade. As redes TCNs combinam convoluções causais, convoluções dilatadas e blocos residuais, resultando em uma arquitetura capaz de capturar dependências de longo prazo de forma eficiente, com grandes vantagens em termos de paralelização, estabilidade dos gradientes e controle do campo receptivo (LEA et al., 2017).

Ao contrário das RNNs, que propagam informações em sequência, as TCNs realizam convoluções ao longo da dimensão temporal, permitindo que todas as amostras de uma sequência sejam processadas simultaneamente (BAI; KOLTER; KOLTUN, 2018). Isso favorece uma maior eficiência computacional e viabiliza o processamento de sequências longas sem ocasionar problemas com gradientes (BAI; KOLTER; KOLTUN, 2018). Essas características são cruciais para a predição da GRF, pois permite capturar padrões biomecânicos de longo alcance presentes nos sinais de acelerômetros durante o ciclo da marcha.

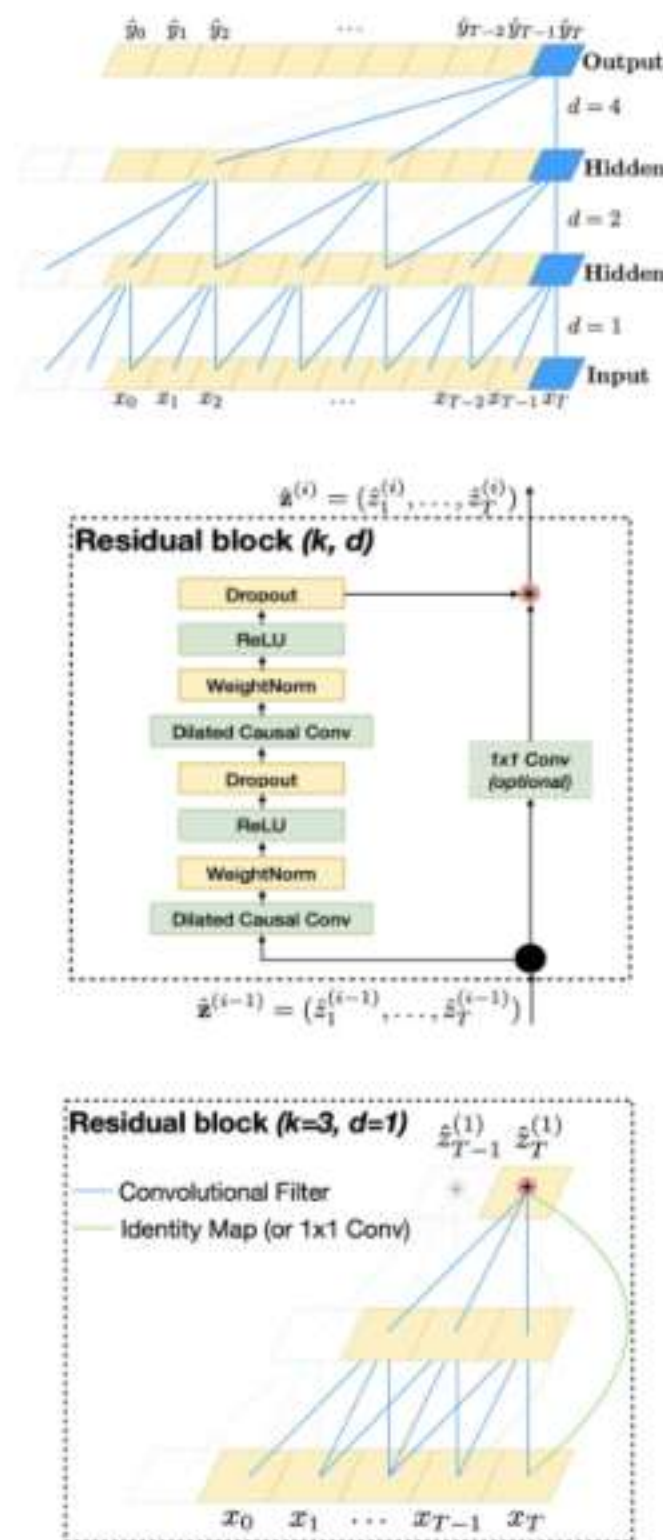
As TCNs utilizam convoluções dilatadas (*dilated convolutions*), que são uma extensão da operação de convolução tradicional, amplamente utilizadas para modelar séries temporais com dependências de longo alcance. A principal característica dessa técnica é a inserção de lacunas (ou "buracos") entre os elementos do kernel, permitindo que o filtro cubra uma região temporal maior sem aumentar o número de parâmetros do modelo (BAI; KOLTER; KOLTUN, 2018).

A utilização de convoluções dilatadas com múltiplos níveis de dilatação em blocos

residuais permite que o modelo aprenda tanto padrões locais quanto globais da série temporal. Isso é especialmente importante em tarefas onde transições suaves e eventos biomecânicos importantes podem ocorrer em janelas temporais espaçadas (PIMENTEL et al., 2024).

Além disso, por não depender de recorrência como nas RNNs, as TCNs com convoluções dilatadas permitem maior paralelismo durante o treinamento, estabilidade e capacidade de generalização em séries temporais complexas (BAI; KOLTER; KOLTUN, 2018). Os blocos residuais presentes na arquitetura suavizam o problema do desvanecimento dos gradientes, facilitando o treinamento de redes profundas.

Figura 12 – Arquitetura típica de uma Rede TCN, com convoluções dilatadas e blocos residuais.



Fonte: (BAI; KOLTER; KOLTUN, 2018).

A Figura 12 ilustra os principais elementos de uma TCN, destacando a convolução causal dilatada e os blocos residuais. No primeiro painel, observa-se como a convolução dilatada com diferentes fatores de dilatação ($d = 1, 2, 4$) permite ampliar o campo receptivo da rede sem perda

de resolução temporal, capturando informações de entradas passadas distantes na sequência. Os vetores x_t representam os dados de entrada em cada instante de tempo, enquanto os vetores z_t indicam as ativações intermediárias, que são representações da sequência aprendidas pela rede. Já os vetores y_t correspondem às saídas finais da rede. Os blocos residuais reforçam a estabilidade e eficiência da TCN, permitindo que informações originais sejam preservadas ao longo das camadas por meio de conexões diretas, mesmo em redes profundas.

2.5 Trabalhos Relacionados

A predição da GRF a partir de dados de sensores inerciais tem sido constantemente investigada na literatura, principalmente com a crescente utilização de modelos de aprendizado profundo, que possibilitam modelar relações não lineares e dependências temporais complexas. Nesta seção, são discutidos estudos relevantes que abordam diferentes arquiteturas de redes neurais, sensores utilizados, estratégias de modelagem e métricas de desempenho, destacando contribuições significativas e lacunas ainda existentes, as quais motivam este trabalho.

2.5.0.1 Predição de GRF a partir de Acelerômetros com Modelos Tradicionais

Diversos estudos adotam abordagens convencionais, como regressão linear, redes neurais artificiais simples e métodos baseados em dinâmica inversa para prever a GRF. Por exemplo, Ngoh et al. (2018) apresentaram um modelo baseado em rede neural feedforward para estimar a componente vertical da GRF (vGRF), utilizando um único acelerômetro uniaxial posicionado no calçado, sobre o terceiro metatarso, durante corrida em diferentes velocidades. O modelo obteve RMSE médio entre 0.015 e 0.017 BW e coeficiente de correlação superior a 0.99, demonstrando bom desempenho em condições controladas. No entanto, essas abordagens revelam limitações na modelagem de relações não lineares mais complexas, especialmente em padrões de marcha variados ou realizados em ambientes não tradicionais de captura de dados (extraclínicos).

2.5.0.2 Predição da GRF com Redes Neurais Profundas

Com os avanços em aprendizado profundo, outros estudos passaram a empregar arquiteturas mais sofisticadas para a predição da GRF. Por exemplo, Johnson et al. (2019) utilizaram redes convolucionais para estimar forças e momentos tridimensionais a partir de dados de marcadores retro-reflexivos, obtendo coeficientes de correlação superiores a 0.97. Mesmo sendo baseados em captura de movimento, os resultados mostram a capacidade das redes CNNs em extrair características relevantes.

ALTAI et al. (2023) compararam diferentes arquiteturas, incluindo CNNs, RNNs e Transformers, para estimar momentos articulares em diferentes condições de marcha utilizando apenas sinais de IMUs. O modelo XCM, baseado em CNNs para séries temporais multivariadas,

alcançou RMSE médio de 0.046 Nm/kg, evidenciando o potencial dessa abordagem na extração de padrões biomecânicos complexos a partir de sensores vestíveis.

ALCANTARA et al. (2022) propuseram um modelo Bi-LSTM para prever ondas contínuas da GRF durante corrida em inclinações variadas, com RMSE médio de 0.16 BW. O uso da arquitetura bidirecional permitiu capturar dependências temporais de longo alcance, preservando a estrutura dinâmica da marcha.

2.5.0.3 Modelos Híbridos para Predição Biomecânica

Modelos híbridos que combinam características de diferentes arquiteturas têm-se mostrado promissores para a predição de dados biomecânicos. ALHARTHI e OZANYAN (2019) propuseram uma arquitetura híbrida CNN-LSTM para classificar padrões de marcha em pacientes com Parkinson a partir da GRF, atingindo até 96% de precisão e superando abordagens tradicionais baseadas em extração manual de características. Essa abordagem end-to-end alia eficiência computacional e robustez preditiva, sendo aplicável em contextos clínicos e industriais.

Liu, Li e Ye (2023) demonstraram, na previsão de séries temporais financeiras, que modelos híbridos CNN-LSTM superam redes convencionais, com redução de até 35,97% no erro de predição. Mesmo não se tratando de um estudo biomecânico, os fundamentos da modelagem de sequências complexas reforçam a aplicabilidade dos modelos híbridos à predição da GRF com sensores inerciais, dada a natureza simultaneamente espacial e temporal dos sinais.

2.5.0.4 Predição de Séries Temporais com Redes TCNs

As redes TCNs são alternativas robustas para modelagem de séries temporais. BAI, KOLTER e KOLTUN (2018) demonstraram que redes TCNs superam arquiteturas recorrentes em várias tarefas, principalmente por permitirem paralelização e uso de convoluções dilatadas, que capturam dependências de longo alcance. Recentemente, Zhong (2024) aplicou TCNs à previsão de séries multivariadas, obtendo desempenho superior ao de modelos LSTM e GRU, o que reforça sua aplicabilidade em tarefas biomecânicas como a predição da GRF.

2.5.0.5 Contribuição do Dataset Utilizado

Conjuntos de dados amplos e integrados são fundamentais para o treinamento e validação de modelos robustos. Grouvel et al. (2023) e CAMARGO et al. (2021) disponibilizaram datasets que combinam informações de IMUs, plataformas de força, palmilhas instrumentadas e captura de movimento sob múltiplas condições de marcha. Esses conjuntos viabilizam a criação de modelos generalizáveis, fornecendo dados sincronizados e diversificados, indispensáveis para tarefas de predição como a GRF.

2.6 Lacunas e Motivação do Presente Estudo

Mesmo com estes avanços, algumas lacunas continuam. Muitos estudos dependem de múltiplos sensores ou de ambientes laboratoriais controlados, o que restringe a aplicabilidade em contextos reais. Além disso, a generalização dos modelos para diferentes modos de marcha é pouco abordada. Neste sentido, o presente trabalho propõe estimar a GRF a partir de acelerômetros com IMU's estrategicamente posicionados, explorando três arquiteturas, contribuindo para o desenvolvimento de sistemas portáteis, de menor custo e com potencial de aplicação em ambientes clínicos ou cotidianos.

3 Materiais e Métodos

3.1 Desenho Geral do Estudo

Este estudo propõe a estimativa da GRF com base em dados de acelerômetros, propondo diferentes arquiteturas de redes neurais. Para isso, foi adotada uma abordagem quantitativa e experimental, baseada em dados previamente coletados e disponibilizados em uma base pública (GROUVEL et al., 2023).

A metodologia compreende as seguintes etapas:

- Pré-processamento de dados de sensores inerciais (acelerômetros) e GRF, com aplicação de filtros e normalização com z-score;
- Segmentação temporal dos sinais;
- Construção e treinamento de modelos de redes neurais profundas (Bi-LSTM, TCN e rede híbrida);
- Avaliação quantitativa dos modelos com base nas métricas RMSE, rRMSE e coeficiente de determinação (R^2).

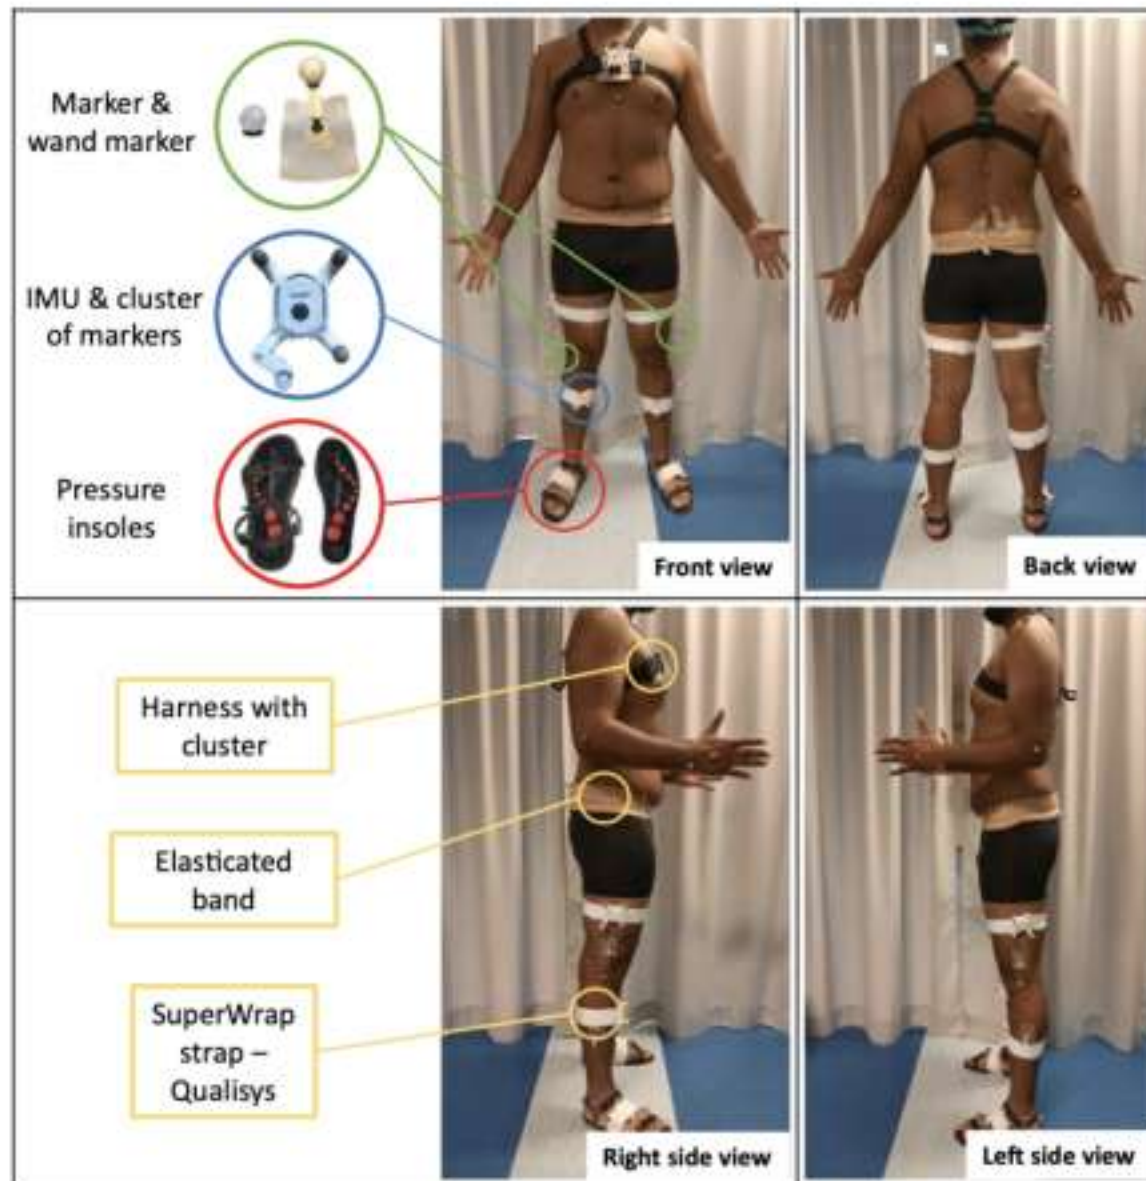
Todas as etapas foram desenvolvidas e realizadas em MATLAB, utilizando a Deep Learning Toolbox (MathWorks, 2024a), em um computador MacBook Air com processador M2, 8 GB de memória RAM e sistema operacional macOS Ventura versão 13.6.1.

3.2 Base de Dados Utilizada

Para a realização deste estudo, foi utilizada a base de dados pública criada por Grouvel et al. (2023), composta de informações biomecânicas detalhadas da marcha humana, obtidas a partir da aquisição simultânea de dados de IMUs e palmilhas instrumentadas.

O conjunto de dados foi obtido a partir de dez participantes assintomáticos, que realizaram múltiplas tarefas de locomoção em ambiente laboratorial. Os dados utilizados no presente estudo foram extraídos especificamente dos ensaios de marcha normal, marcha lenta, marcha rápida e caminhada de 2 minutos, totalizando 131 ensaios.

Figura 13 – Configuração completa dos sensores em um participante: sistema óptico com marcadores, IMUs fixados com tiras elásticas e palmilhas instrumentadas posicionadas nos calçados.



Fonte: (GROUVEL et al., 2023).

Os dados de acelerômetros foram adquiridos com sensores Physilog®6S (Gait Up, 2024) fixados em oito regiões corporais: lombar, pelve, coxas, pernas e pés. Esses sensores capturaram sinais de aceleração linear, velocidade angular e campo magnético nos três eixos com uma frequência de amostragem de 256 Hz. No presente trabalho, foram utilizados os dados tridimensionais dos acelerômetros posicionados nas coxas, pernas e pés.

O registro dos dados de GRF foi feito por palmilhas instrumentadas Insole3 (Moticon ReGo AG, 2024), capazes de registrar a força total aplicada por cada pé a uma taxa de 100 Hz. Essas palmilhas são equipadas com 16 sensores de pressão distribuídos pela superfície plantar e um sistema inercial interno, sendo utilizadas para a quantificação da carga e do centro de pressão (CoP) em estudos de marcha.

Os dados utilizados nesse estudo foram obtidos a partir dos arquivos .csv sincronizados, disponibilizados pelos autores do dataset com alinhamento temporal pré-processado a partir da detecção de eventos padronizados (picos de aceleração e saltos verticais).

3.3 Análise de Correlação Cruzada entre os Dados de Acelerômetros e GRF

Com o objetivo exclusivo de selecionar o sensor inercial mais representativo em relação à GRF, foi implementada uma análise de correlação cruzada estatística baseada na função `xcorr` do MATLAB (MathWorks, 2024c), com a sua normalização. Essa análise teve caráter preliminar e não foi utilizada diretamente no treinamento das redes, mas sim para identificar, entre os sensores, aquele cujos sinais apresentavam maior similaridade com os padrões da GRF. Dessa forma, a análise de correlação cruzada contribuiu unicamente para otimizar a escolha do sensor, priorizando aquele capaz de fornecer dados mais informativos (HAVASHINEZHADIAN et al., 2023; PIMENTEL et al., 2024).

Do dataset utilizado, foram extraídos os dados adquiridos dos sensores inerciais posicionados na coxa direita, perna direita e pé direito. A análise foi realizada apenas no lado direito, uma vez que os participantes eram assintomáticos e apresentavam padrão de marcha simétrica (WANG; ZHANG; LI, 2005). Assim, não se fazia necessário avaliar ambos os pés nessa etapa de seleção, tendo sido escolhido o pé direito como referência.

Considerando que o uso de filtros de Butterworth de 2ª a 4ª ordem, com frequência de corte entre 6 a 10 Hz, é amplamente reconhecido como apropriado para suavizar sinais de movimento humano em análises cinemáticas e dinâmicas da marcha (WINTER, 2009), os dados de acelerômetro foram filtrados com um filtro passa-baixa de 4ª ordem (Butterworth) com frequência de corte de 10 Hz. Em seguida, foi calculada a magnitude da aceleração a_{mag} , conforme a Equação 3.1:

$$a_{mag}t = \sqrt{a_x t^2 + a_y t^2 + a_z t^2} \quad (3.1)$$

onde a_x , a_y e a_z correspondem às acelerações registradas ao longo dos três eixos ortogonais.

A função de correlação cruzada normalizada foi então aplicada entre a magnitude da aceleração e a GRF para cada defasagem temporal τ , conforme a Equação 3.2:

$$\rho\tau = \frac{t a_{mag}t \cdot ft \tau}{\|a_{mag}\| \cdot \|f\|} \quad (3.2)$$

onde ft representa o sinal de GRF e $\|a_{mag}\| \cdot \|f\|$ indica a normalização da correlação. O valor máximo da função $\rho\tau$ foi registrado como o grau de correlação estatística entre os sinais.

Esse procedimento foi repetido para todos os arquivos da base de dados, sendo calculada a média e o desvio padrão da correlação para cada sensor. O sensor fixado no pé apresentou a maior correlação média com a GRF e, portanto, foi considerado o mais representativo para ser utilizado como referência de entrada nos modelos de predição propostos. Importante ressaltar que essa etapa serviu apenas para a escolha do sensor mais correlacionado. Para o treinamento

das redes neurais, diferentemente dessa análise preliminar, foram utilizados os dados de ambos os pés, visto que na análise da marcha é fundamental considerar o comportamento bilateral para uma caracterização mais completa dos ciclos locomotores. Os resultados consolidados da correlação cruzada foram apresentados em formato tabular e gráfico na Seção 4.1.

3.4 Pré-processamento dos Dados


Para garantir a consistência, qualidade e padronização dos dados para entrada nos modelos das redes neurais propostas, os dados provenientes dos sensores inerciais e das palmilhas de força foram submetidos a um conjunto de etapas de pré-processamento.

De acordo com Grouvel et al. (2023), todos os sinais já estavam previamente sincronizados e uniformemente amostrados a 100 Hz que é o denominador comum de amostragem da IMU e palmilha, não sendo necessária qualquer etapa de reamostragem. A frequência foi mantida em todas as fases do processamento, permitindo a preservação das variações temporais relevantes da marcha.

3.4.1 Filtragem

Os dados do acelerômetro foram filtrados por um filtro passa-baixa de quarta ordem do tipo Butterworth com frequência de corte de 10 Hz, conforme indicado na literatura para atenuar ruídos de alta frequência sem comprometer a dinâmica dos sinais de marcha (CRENNA; ROSSI; BERARDENGO, 2021). A filtragem foi feita utilizando a função `filtfilt`, eliminando atrasos de fase. Esse tipo de filtragem é utilizado para a aplicação do filtro digital duas vezes: primeiro no sentido direto do tempo e, em seguida, no sentido inverso. Ao aplicar o filtro nos dois sentidos, os atrasos de fase introduzidos na primeira filtragem são cancelados na segunda, gerando na saída um sinal filtrado com resposta de fase zero. Além disso, esse procedimento dobra a ordem efetiva do filtro, preservando com maior fidelidade as características de amplitude do sinal original (MathWorks, 2024b), o que é especialmente importante para a análise precisa de eventos no domínio temporal, como na detecção de fases da marcha. A Figura 14 ilustra esse efeito comparando sinais com e sem filtragem.

Figura 14 – Ilustração do efeito da filtragem em um sinal com ruído de alta frequência.



3.4.2 Normalização dos Dados

A normalização dos dados é uma etapa fundamental no pré-processamento de séries temporais multivariadas para redes neurais profundas, especialmente em contextos com variabilidade interindividual significativa, como a análise biomecânica. A técnica adotada neste estudo foi a padronização z-score, aplicada tanto aos sinais de entrada quanto aos sinais de saída.

3.4.2.0.1 Normalização dos sinais de entrada.

Para cada eixo dos sinais de acelerômetro coletados pelos sensores inerciais, foi aplicada uma normalização individual segundo a Equação 3.3:

$$x_{\text{norm}} = \frac{x - \mu}{\sigma} \quad (3.3)$$

onde x representa o vetor de amostras em um eixo específico, μ a média aritmética e σ o desvio padrão desse eixo ao longo de todo o conjunto de dados (separadamente para o pé direito e esquerdo). Esse procedimento permite que os sinais sejam centralizados em torno de zero com variância unitária, o que facilita o aprendizado das redes neurais ao eliminar escalas distintas entre variáveis (LECUN et al., 2012; IOFFE; SZEGEDY, 2015).

3.4.2.0.2 Normalização da variável de saída.

A GRF, medida pelas palmilhas instrumentadas, também foi normalizada por z-score. Os parâmetros estatísticos de normalização (μ e σ) foram calculados globalmente antes da divisão dos dados em folds de validação cruzada, sendo então aplicados de forma uniforme a todo o conjunto. Esse processo garante consistência na escala dos dados durante o treinamento e a avaliação. Na inferência, a normalização foi revertida com os mesmos parâmetros salvos previamente, permitindo que as métricas de erro fossem calculadas em Newton. A normalização dos dados de saída é recomendada para evitar que a função de perda seja dominada por variações absolutas da amplitude do sinal (SHASHUA, 2008).

3.4.3 Criação de Janelas Temporais

A janela temporal foi fixada em 30 amostras, o que corresponde a 0.3 segundos considerando a taxa de amostragem de 100 Hz. Janelas de 0.3 segundos são suficientemente curtas para capturar eventos como o contato inicial, o pico de resposta à carga e o início da propulsão, que são os momentos em que a GRF sofre variações importantes. Como o ciclo completo da marcha possui duração média entre 1 e 1.2 segundos (WINTER, 2009), essa janela representa uma parcela importante da marcha. Além disso, estudos como os de ALCANTARA et al. (2022), Johnson et al. (2019) e Hammerla, Halloran e Plötz (2016) recomendam o uso de janelas curtas em tarefas relacionadas à predição da GRF com redes neurais profundas. Nesse sentido, a escolha da janela de 30 amostras supõe-se eficiente no contexto de resolução temporal, capacidade preditiva e desempenho computacional na modelagem da GRF a partir de dados de acelerômetros.

Para aumentar a diversidade e a representatividade das amostras no conjunto de dados, foram utilizados múltiplos deslocamentos entre janelas (*step sizes*) com valores de 1, 3 e 5 amostras. Isso trouxe variações sobrepostas e não sobrepostas entre os segmentos, permitindo capturar mudanças mais finas e mais amplas do ciclo da marcha.

Cada janela foi representada como um tensor tridimensional com dimensões 3×30 (3 canais de entrada: dados dos eixos x , y , z do acelerômetro), e a saída associada foi definida como o valor da força total no instante correspondente à última amostra da janela. Essa opção está de acordo com abordagens supervisionadas baseadas em previsão pontual, como descrito em ALCANTARA et al. (2022).

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 (REISS; STRICKER, 2012; HAMMERLA; HALLORAN; PLÖTZ, 2016).

3.5 Descrição das Arquiteturas de Redes Neurais

3.5.1 Modelo Bi-LSTM

A arquitetura utilizada combina duas camadas Bi-LSTM com diferentes profundidades, sendo intercaladas com a utilização de técnicas de *dropout* para evitar sobreajuste, seguidas por camadas totalmente conectadas com função de ativação *ReLU* e uma camada de regressão. A Tabela 1 descreve seus elementos e suas respectivas funções.

Tabela 1 – Descrição das camadas da arquitetura Bi-LSTM

Elemento	Descrição da Função
<code>sequenceInputLayer(3)</code>	Camada de entrada com 3 canais (dados do acelerômetro).
<code>biLstmLayer(128, 'OutputMode', 'sequence')</code>	Primeira camada Bi-LSTM com 128 unidades, retornando toda a sequência.
<code>dropoutLayer(0.4)</code>	Regularização com 40% de dropout.
<code>biLstmLayer(64, 'OutputMode', 'last')</code>	Segunda camada Bi-LSTM com 64 unidades, retornando apenas a última saída.
<code>dropoutLayer(0.4)</code>	Segunda camada de dropout para prevenção de overfitting.
<code>fullyConnectedLayer(64)</code>	Camada totalmente conectada com 64 unidades.
<code>reluLayer</code>	Função de ativação ReLU.
<code>fullyConnectedLayer(1)</code>	Camada de saída com 1 unidade para regressão da GRF.
<code>regressionLayer</code>	Camada de perda que utiliza o erro quadrático médio (MSE).

3.5.2 Modelo TCN

A arquitetura TCN é baseada em convoluções unidimensionais causais com fatores de dilatação, o que permite que a rede aprenda dependências temporais de longo alcance com menor custo computacional em comparação com os outros modelos desse estudo.

Tabela 2 – Descrição das camadas da arquitetura TCN

Elemento	Descrição da Função
<code>sequenceInputLayer(3)</code>	Camada de entrada com 3 canais.
<code>convolution1dLayer(3, 128, 'padding', 'causal')</code>	Convolução 1D causal com 128 filtros e kernel de tamanho 3.
<code>reluLayer</code>	Ativação ReLU aplicada após a convolução.
<code>dropoutLayer(0.3)</code>	Dropout com taxa de 30% para regularização.
<code>convolution1dLayer(3, 64, 'padding', 'causal')</code>	Segunda convolução causal com 64 filtros e dilatação.
<code>reluLayer</code>	Ativação ReLU.
<code>dropoutLayer(0.3)</code>	Segunda camada de dropout com 30%.
<code>globalMaxPooling1dLayer</code>	Reduz a sequência para uma saída fixa com operação de máxima global.
<code>fullyConnectedLayer(64)</code>	Camada densa com 64 unidades.
<code>reluLayer</code>	Função de ativação ReLU.
<code>fullyConnectedLayer(1)</code>	Camada de saída com 1 unidade (predição da GRF).
<code>regressionLayer</code>	Camada de regressão com função de perda MSE.

3.5.3 Modelo híbrido TCN-BiLSTM

Com o intuito de explorar tanto padrões temporais locais quanto dependências de longo alcance nos sinais de aceleração, a arquitetura híbrida foi composta por camadas convolucionais causais dilatadas, baseadas em redes TCNs, seguidas por camadas recorrentes do tipo Bi-LSTM. Com isso, obtem-se uma captura eficiente de informações espaciais e temporais complementares, melhorando a acurácia na tarefa de regressão da GRF.

A estrutura híbrida utilizada neste modelo é composta inicialmente por dois blocos convolucionais causais com dilatações progressivas, seguidos de uma camada Bi-LSTM. Essa estratégia permite a detecção de padrões locais com janela de recepção expandida e, em seguida, a captura de dinâmicas temporais de longo prazo. As saídas da Bi-LSTM são então passadas por camadas densas para predição da GRF. A arquitetura está descrita na Tabela 3:

Tabela 3 – Descrição das camadas da arquitetura híbrida CNN-BiLSTM

Elemento	Descrição da Função
<code>sequenceInputLayer(3)</code>	Camada de entrada com 3 canais.
<code>convolution1dLayer(3, 64, 'Padding', 'causal')</code>	Primeira convolução causal com 64 filtros e kernel de tamanho 3.
<code>reluLayer</code>	Função de ativação ReLU.
<code>convolution1dLayer(3, 64, 'Padding', 'causal')</code>	Segunda camada convolucional causal com 64 filtros.
<code>reluLayer</code>	Segunda ativação ReLU.
<code>biLstmLayer(64, 'OutputMode', 'last')</code>	Camada Bi-LSTM para aprendizado de dependências temporais.
<code>dropoutLayer(0.3)</code>	Dropout de 30% aplicado para regularização.
<code>fullyConnectedLayer(64)</code>	Camada densa com 64 unidades.
<code>reluLayer</code>	Ativação ReLU.
<code>fullyConnectedLayer(1)</code>	Camada de saída com 1 unidade (valor estimado da GRF).
<code>regressionLayer</code>	Camada de regressão com perda MSE.

3.6 Parâmetros de Treinamento dos Modelos

Todos os modelos desenvolvidos neste trabalho foram treinados e avaliados sob as mesmas condições experimentais, com o intuito de garantir uma comparação adequada entre os desempenhos das diferentes arquiteturas.

Configuração do treinamento

O processo de treinamento foi realizado utilizando o otimizador *Adam*, com taxa de aprendizado inicial fixada em 5×10^{-3} e decaimento progressivo de 20% a cada 10 épocas. O número máximo de épocas foi estabelecido em 30, com *mini-batches* de 128 amostras e regularização L2 com parâmetro de penalização igual a 10^{-4} . Para prevenir oscilações acentuadas no gradiente durante a retropropagação, aplicou-se o controle de gradiente com limiar igual a 1.

As redes foram treinadas com embaralhamento dos dados a cada época (passagem completa por todo o conjunto de dados de treinamento) e validação periódica a cada 50 iterações (processamento de um mini-batch de dados pela rede), com critério de parada antecipada configurado para 10 ciclos (intervalo de verificação da métrica de validação) consecutivos sem melhora na métrica de validação.

Validação cruzada

Para gerar maior diversidade nos treinamentos devido à base de dados ser pequena, utilizou-se validação cruzada estratificada com o número de partição igual a 5 para estimar a generalização dos modelos. 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.

Tabela 4 – Configurações de treinamento comuns às redes

Parâmetro	Valor	Descrição
Otimizador	Adam	Método adaptativo de otimização dos pesos com momentum e correções de variância.
Taxa de aprendizado inicial	5×10^{-3}	Valor inicial da taxa de aprendizado usada pelo otimizador.
LearnRateDropFactor	0,8	Fator de redução da taxa de aprendizado após número definido de épocas.
LearnRateDropPeriod	10	Número de épocas após o qual a taxa de aprendizado é reduzida.
Épocas máximas	30	Limite máximo de iterações sobre todo o conjunto de treinamento.
Mini-batch	128	Número de amostras usadas em cada atualização dos pesos.
Regularização L2	10^{-4}	Penalidade para evitar overfitting, aplicada aos pesos da rede.
GradientThreshold	1	Valor máximo permitido para o gradiente durante backpropagation.
Shuffle	every-epoch	Os dados de entrada são embaralhados ao final de cada época.
ValidationFrequency	50	Frequência (em iterações) de cálculo da métrica de validação.
ValidationPatience	10	Número de ciclos sem melhora antes de interromper o treinamento.
Validação cruzada	5 folds	Estratégia K-Fold para generalização e robustez estatística.
Formato de salvamento	.mat e .csv	Pesos salvos em .mat e métricas exportadas em .csv, com nomes específicos para cada rede.
Normalização da saída	Z-score	A GRF foi padronizada por média e desvio padrão global.

A Tabela 4 apresenta as configurações de treinamento adotadas de forma padronizada para todas as arquiteturas avaliadas neste estudo, garantindo condições de igualdade entre os modelos, assegurando que eventuais diferenças de desempenho estejam associadas à estrutura das redes e não a variações nos parâmetros de treinamento.

3.7 Métricas de Avaliação

Para a análise do desempenho dos modelos propostos, foram utilizadas três métricas amplamente empregadas na literatura de estimativas biomecânicas (ALCANTARA et al., 2022): a raiz do erro quadrático médio (RMSE), a raiz do erro quadrático médio relativo (rRMSE) e o coeficiente de determinação (R^2). Essas métricas foram calculadas ao final de cada uma das 5 repetições da validação cruzada (*K-fold*) implementada nos scripts de treinamento.

Os resíduos de predição, que é a diferença entre os valores reais e os valores preditos, também foram exportados e salvos em arquivos .csv por fold, com o intuito de permitir análises qualitativas posteriores e a construção de gráficos de erro residual.

Raiz do Erro Quadrático Médio (RMSE)

O RMSE mede a magnitude média do erro entre os valores preditos e os valores reais da GRF. Essa métrica é sensível a outliers, penalizando desajustes maiores. O RMSE foi calculado segundo a Equação 3.4:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.4)$$

onde y_i representa o valor real da GRF na amostra i , \hat{y}_i o valor estimado pelo modelo, e n o número total de amostras no conjunto de teste.

Raiz do Erro Quadrático Médio Relativo (rRMSE)

O rRMSE calcula o erro relativo à amplitude dos valores reais da GRF, permitindo comparação entre modelos independentemente da escala. Ele foi calculado a partir do RMSE de cada fold, dividido pela diferença entre o valor máximo e mínimo da GRF no conjunto de teste, segundo a Equação 3.5:

$$\text{rRMSE}\% = \left[\frac{\text{RMSE}}{\text{max}_y - \text{min}_y} \right] \times 100 \quad (3.5)$$

Essa métrica foi fundamental para avaliar a precisão relativa das estimativas, considerando a variabilidade das forças geradas em diferentes sujeitos e condições.

Coefficiente de Determinação (R^2)

O coeficiente de determinação quantifica a proporção da variância da GRF que é explicada pelo modelo. Ele foi obtido segundo a Equação 3.6:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.6)$$

onde \bar{y} representa a média dos valores reais da GRF. Valores de R^2 próximos a 1 indicam maior capacidade explicativa do modelo.

4 Resultados

4.1 Correlação Cruzada entre os Sensores Inerciais e os dados de GRF


Com o objetivo de selecionar qual localização do sensor inercial apresenta maior potencial preditivo em relação à GRF e usar os dados de acelerômetros adquiridos por este sensor no treinamento das redes neurais, foi realizada uma análise de correlação cruzada entre a magnitude da aceleração de cada sensor utilizado e os dados de GRF, como foi visto na seção 3.3.

A Tabela 5 apresenta os resultados obtidos da correlação cruzada entre os sinais de aceleração resultante dos sensores localizados na coxa, perna e pé em relação à GRF, considerando tanto a correlação média quanto o atraso médio (em amostras e convertido para segundos).

Tabela 5 – 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	0,827	0,165	0,064

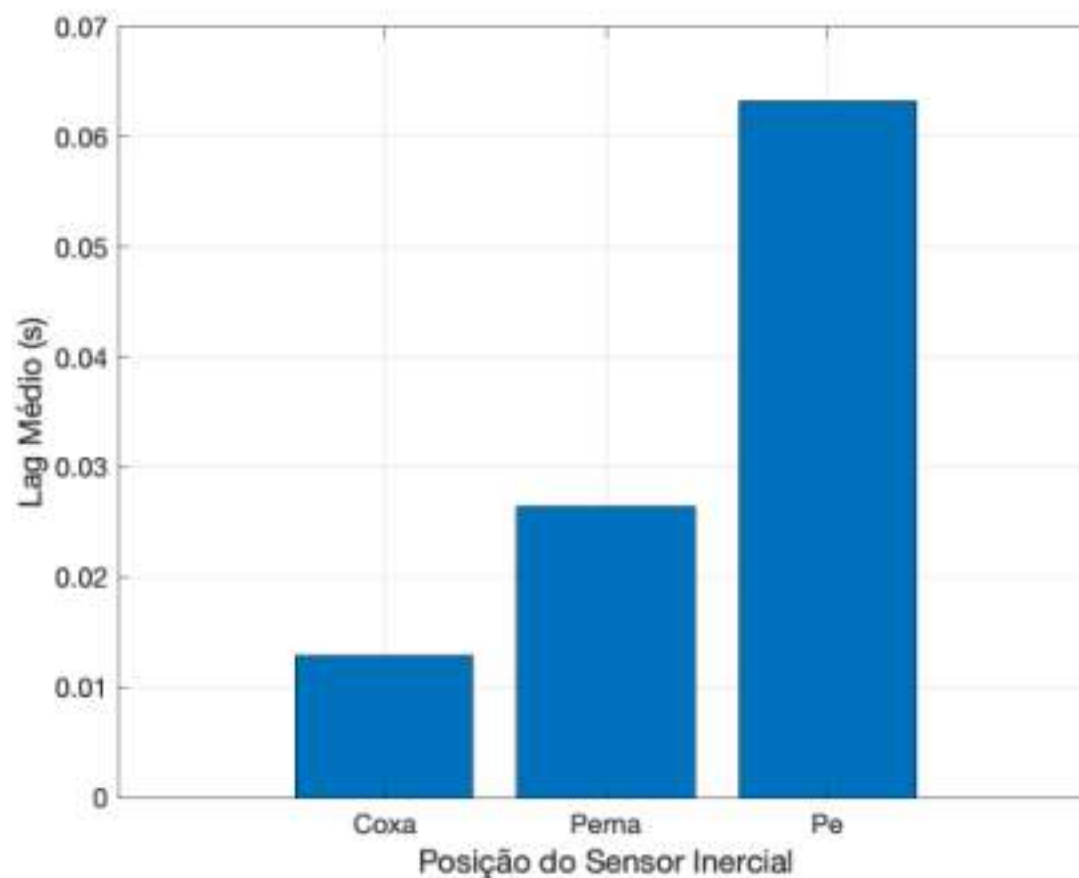
Figura 15 – Média da correlação cruzada entre a magnitude da aceleração dos sensores inerciais e a GRF.



A Figura 15 mostra a média da correlação cruzada da magnitude da aceleração de cada sensor em relação aos dados de GRF, onde as hastes representam o valor médio e os erros indicam o desvio padrão.

A Figura 16 mostra o atraso médio dos sensores inerciais em relação à GRF, onde é possível observar que o mesmo aumenta progressivamente conforme o sensor está mais distal no membro inferior, sendo o menor na coxa e o maior no pé. Este padrão reflete a dinâmica biomecânica da marcha, na qual os segmentos mais proximais estão mais sincronizados temporalmente com a GRF, enquanto os segmentos distais apresentam atraso devido às características próprias do movimento pendular dos membros inferiores (PIMENTEL et al., 2024).

Figura 16 – Gráfico do atraso médio dos sensores inerciais em relação à GRF.



4.2 Comparação entre os Modelos Propostos


Com o objetivo de avaliar comparativamente o desempenho das diferentes arquiteturas de redes neurais implementadas, a Tabela 6 apresenta a média dos valores das métricas RMSE, rRMSE e R^2 ao longo dos cinco folds para cada modelo. Esses resultados quantitativos permitem uma análise direta do desempenho de generalização das arquiteturas propostas.

Tabela 6 – Média das métricas por modelo após validação cruzada com 5 folds

Modelo	RMSE (N)	rRMSE (%)	R^2
Bi-LSTM	105,07	7,08	0,86
TCN	152,05	10,49	0,70
Híbrido	103,22	6,90	0,86

A Figura 17 apresenta um boxplot comparativo dos valores de RMSE obtidos para cada uma das três arquiteturas testadas. Cada grupo representa a distribuição dos erros ao longo dos cinco folds da validação cruzada, permitindo uma visualização clara da variação, dispersão e presença de outliers em cada modelo. Essa representação gráfica auxilia na compreensão da consistência e da estabilidade preditiva das redes avaliadas ao longo dos diferentes subconjuntos de teste.

Figura 17 – Boxplot dos valores de RMSE obtidos para as arquiteturas Bi-LSTM, TCN e Híbrida ao longo da validação cruzada com 5 folds.



4.3 Resultados Quantitativos

A Tabela 7 e 8 apresentam as métricas RMSE, rRMSE e R^2 obtidas durante a fase de inferência para os modelos aplicados aos sinais dos pés direito e esquerdo, respectivamente.

Tabela 7 – Métricas de estimativa para o pé direito (GRF real vs. estimada)

Arquitetura	RMSE (N)	rRMSE (%)	R^2	Correlação Cruzada
Bi-LSTM	120,40	17,70	0,70	0,93
TCN	160,90	23,68	0,46	0,89
Híbrido	92,42	13,60	0,82	0,96

Tabela 8 – Métricas de predição para o pé esquerdo (GRF real vs. estimada)

Arquitetura	RMSE (N)	rRMSE (%)	R^2	Correlação Cruzada
Bi-LSTM	89,60	12,45	0,85	0,97
TCN	165,00	22,90	0,50	0,91
Híbrido	82,63	11,47	0,87	0,97

Além das métricas tradicionais de regressão, as Tabelas 7 e 8 trazem o cálculo a correlação cruzada entre os sinais preditos e os valores reais da GRF para avaliar o grau de similaridade temporal entre as séries, permitindo identificar o atraso entre dois sinais e quantificar sua similaridade, independentemente de deslocamentos temporais. Assim, mesmo que uma predição esteja defasada no tempo, mas mantenha o padrão da série real, a correlação cruzada pode capturar essa correspondência estrutural.

Essa análise permite verificar não apenas a acurácia em termos absolutos, mas também a consistência temporal das predições realizadas pelos modelos.

4.4 Análise do Tempo de Treinamento e Inferência

Além da acurácia preditiva, a eficiência computacional é um fator importante na avaliação de modelos baseados em redes neurais profundas (CHEN et al., 2023). Os tempos foram calculados somando-se o tempo de treinamento de cada k-fold da validação cruzada, usando o mesmo hardware e condições de execução. Essa métrica fornece uma estimativa da viabilidade de implantação dos modelos em sistemas de monitoramento contínuo.

Tabela 9 – Tempo total de processamento de treinamento por arquitetura

Arquitetura	Tempo (min:seg)
Bi-LSTM	154:02
TCN	6:13
Híbrida	57:13

Os resultados indicam que o modelo TCN apresentou o menor tempo de treinamento, seguido pelo híbrido e, por fim, o modelo Bi-LSTM, que teve o maior tempo de processamento.

De acordo com a Tabela 10, observa-se que todos os modelos apresentaram tempos bastante reduzidos e muito próximos entre eles. O modelo TCN foi o mais eficiente, com apenas 0,02 segundos por predição em ambos os lados. O modelo híbrido apresentou desempenho intermediário, com 0,03 segundos, enquanto o Bi-LSTM, embora mais lento, manteve valores próximos de 0,06 a 0,07 segundos, ainda compatíveis com aplicações de monitoramento contínuo.

Tabela 10 – Tempo de inferência por arquitetura

Arquitetura	Lado Direito (s)	Lado Esquerdo (s)
Bi-LSTM	0,07	0,06
TCN	0,02	0,02
Híbrida	0,03	0,03

4.5 Análise da Complexidade dos Modelos

Um aspecto relevante na avaliação dos modelos desenvolvidos é a análise da quantidade de parâmetros que cada arquitetura possui. No presente estudo, a Tabela 11 apresenta a quantidade de parâmetros utilizada por cada modelo proposto. Observa-se que a rede TCN é a mais complexa em termos de parâmetros (30.145), seguida pelo modelo Híbrido (21.825) e pela Bi-LSTM (9.857).

Tabela 11 – Quantidade de parâmetros dos modelos analisados.

Arquitetura	Número de Parâmetros
Bi-LSTM	9.857
TCN	30.145
Híbrido	21.825

4.6 Análise Gráfica das Estimativas

As Figuras 18 e 19 mostram os sinais preditos por cada uma das redes comparados com a GRF real, para os pés direito e esquerdo, respectivamente. As previsões foram suavizadas com filtro passa-baixa e desnormalizadas conforme parâmetros estatísticos salvos durante o treinamento. As análises de inferência foram feitas utilizando ensaios que não fizeram parte do treinamento de nenhum dos modelos.

Figura 18 – Comparação entre GRF real (laranja) e predita (azul) para o pé direito utilizando os três modelos.





Figura 19 – Comparação entre GRF real (laranja) e predita (azul) para o pé esquerdo utilizando os três modelos.



5 Discussão

A análise dos resultados confirma que é possível estimar a GRF a partir de dados de acelerômetros, utilizando modelos baseados em redes neurais profundas. As investigações realizadas empregaram validação cruzada, análise gráfica, estatística e avaliação computacional dos modelos Bi-LSTM, TCN e Híbrido.

Análise da Correlação Cruzada Entre Dados dos Acelerômetros e GRF

A análise de correlação cruzada evidenciou que o sensor inercial localizado no pé possui a maior similaridade com a GRF, com média de correlação cruzada de 0,827 e desvio padrão de 0,165, superior àqueles observados nos sensores da perna (0,762) e da coxa (0,757). Embora o atraso temporal seja maior no sensor do pé (0,064 s), essa defasagem pode ser compensada computacionalmente, justificando sua escolha como fonte de dados para os modelos estimativos offline.

A partir de uma perspectiva biomecânica, o maior acoplamento entre os dados de acelerômetros do pé e a forma temporal da GRF decorre do fato de que, durante a fase de apoio, o pé é o único segmento em contato com o solo e concentra os dois grandes eventos que moldam o sinal característico da GRF: a aceitação de carga logo após o contato inicial e a propulsão no pré-balanço (WINTER, 2009; PERRY; BURNFIELD, 2010). Além disso, a progressão do centro de pressão do retropé para o antepé ao longo do apoio faz com que as variações de aceleração captadas no pé reflitam, com mínima filtragem articular, a dinâmica de transferência de carga e de geração de impulso que compõem a GRF (PERRY; BURNFIELD, 2010). Em contraste, dados adquiridos de segmentos mais proximais (perna e coxa) tendem a apresentar atenuação e defasagens relativas aos eventos externos por efeito combinado de rotações intersegmentares, amortecimento por tecidos moles e do comportamento pendular do membro inferior, o que reduz a similaridade morfológica com a GRF quando comparados ponto a ponto no tempo (WINTER, 2009). Sendo assim, esses fatores explicam por que o sensor no pé alcança correlações mais elevadas com a GRF neste estudo, enquanto posições proximais preservam menos fielmente a assinatura temporal dos picos de aceitação de carga e de propulsão (WINTER, 2009; PERRY; BURNFIELD, 2010).

Comparação Entre as Arquiteturas Propostas

A comparação entre as arquiteturas propostas mostrou que os modelos Bi-LSTM e Híbrido obtiveram desempenhos superiores em relação às métricas de erro e coeficiente de determinação. Na validação cruzada, o modelo Híbrido apresentou os valores menores de RMSE (103,22 N) e rRMSE (6,90%), além de um R^2 de 0,86, equivalente ao do modelo Bi-LSTM (RMSE de 105,07

N, rRMSE de 7,08%). Já modelo TCN, mesmo sendo mais eficiente computacionalmente, teve desempenho inferior, com RMSE de 152,05 N, rRMSE de 10,49% e R^2 de apenas 0,70.

O desempenho superior do modelo Híbrido está associado a uma explicabilidade temporal mais consistente com a fisiomecânica do apoio. Estruturalmente, os blocos convolucionais capturam padrões locais e transitórios do sinal (como a aceitação de carga após o contato inicial e a propulsão no pré-balanço), enquanto as camadas recorrentes integram dependências de longo alcance ao longo do ciclo, preservando a coerência temporal entre eventos sucessivos (PERRY; BURNFIELD, 2010; WINTER, 2009; HOCHREITER; SCHMIDHUBER, 1997). Em contraste, os modelos tradicionais tendem a apresentar limitações específicas: a TCN dispõe de campo receptivo controlável, porém pode distribuir relevância por janelas extensas quando a dinâmica requer cobertura temporal ampla, reduzindo a nitidez das regiões críticas (??); a Bi-LSTM modela dependências de longo alcance por meio de estados internos, mas tende a difundir a importância por muitos instantes, dificultando a localização precisa de trechos importantes para a predição (HOCHREITER; SCHMIDHUBER, 1997). Nos resultados obtidos, o modelo Híbrido apresentou relevâncias temporalmente mais concentradas e co-localizadas com os intervalos do ciclo de apoio em que há maior conteúdo mecânico (contato inicial/aceitação de carga e pré-balanço/propulsão), compatíveis com a migração do centro de pressão do retropé ao antepé e com os picos característicos da GRF (PERRY; BURNFIELD, 2010; WINTER, 2009). Esses achados estão alinhados com a literatura recente que indica vantagens de arquiteturas híbridas ou com memória explícita para tarefas de estimativa biomecânica e eventos da marcha, em comparação a arquiteturas puramente convolucionais ou recorrentes (ALTAI et al., 2023; ARSHAD et al., 2022; HOSSAIN et al., 2022).

Os erros do modelo Híbrido são compatíveis com monitoramento longitudinal extra-laboratorial, avaliação de simetria entre membros e biofeedback em tempo quase real, bem como com progressões de carga baseadas em frações do peso corporal (PERRY; BURNFIELD, 2010; WINTER, 2009; ALCANTARA et al., 2022; JOHNSON et al., 2019). A correlação elevada indica preservação da morfologia dos transientes de aceitação de carga e propulsão, e o rRMSE inferior a 10% sustenta a detecção de mudanças clinicamente relevantes (10–15%) entre avaliações seriadas (PERRY; BURNFIELD, 2010; WINTER, 2009). Em contrapartida, inferências cinéticas de alta precisão (p. ex., momentos articulares por dinâmica inversa) e discriminações diagnósticas muito sutis requerem validação adicional e/ou instrumentação de referência, (ALTAI et al., 2023). Em síntese, os resultados são clinicamente aceitáveis para monitoramento, simetria e feedback fora do laboratório, enquanto aplicações que demandam quantificação cinética fina devem ser acompanhadas de validação dirigida (ALTAI et al., 2023).

Análise da Inferência da GRF por Cada Modelo

Durante a fase de inferência, os resultados mostraram coerência: para o pé direito, o modelo Híbrido apresentou o melhor desempenho com $R^2 = 0,82$ e correlação cruzada de 0,96,

seguido pela Bi-LSTM ($R^2 = 0,70$) e pelo modelo TCN, que obteve apenas $R^2 = 0,46$. Para o pé esquerdo, o modelo Híbrido novamente obteve o melhor desempenho ($R^2 = 0,87$), superando a Bi-LSTM ($R^2 = 0,85$) e, por fim, o modelo TCN ($R^2 = 0,50$). Essas diferenças são apoiadas pelas análises gráficas apresentadas nas Figuras 18 e 19, com os modelos mais robustos conseguindo reproduzir de forma mais fiel os picos e vales característicos do ciclo da marcha.

Tempo de Treinamento e Inferência

Por fim, a análise do tempo de processamento mostrou um compromisso importante: o modelo TCN é o mais eficiente em termos de treinamento (6 minutos e 13 segundos), mas sacrifica o desempenho da estimativa. A Bi-LSTM, por outro lado, requer um tempo significativamente maior para treinar (154 minutos), enquanto o modelo Híbrido oferece um maior equilíbrio entre menor complexidade computacional e acurácia (57 minutos).

No que se refere ao tempo de inferência, todos os modelos apresentaram tempos bastante reduzidos, compatíveis com aplicações em tempo real. O TCN novamente se destacou como o mais rápido (0,02 segundos por predição em ambos os lados), seguido pelo modelo Híbrido (0,03 segundos) e pela Bi-LSTM, que mesmo sendo mais custosa no treinamento, apresentou tempos de inferência apenas ligeiramente superiores (0,06–0,07 segundos). Esses resultados evidenciam que, apesar das diferenças expressivas no treinamento, os três modelos são viáveis para uso em sistemas de monitoramento contínuo.

Complexidade dos Modelos e Número de Parâmetros

A quantidade de parâmetros reflete a complexidade de cada arquitetura e influencia diretamente o custo computacional do treinamento. A TCN apresentou o maior número de parâmetros (30.145), seguida pelo modelo Híbrido (21.825) e pela Bi-LSTM (9.857). Apesar disso, a TCN foi a mais rápida para treinar (6 minutos e 13 segundos), enquanto a Bi-LSTM, mesmo com menos parâmetros, demandou maior tempo (154 minutos) devido ao caráter sequencial de suas camadas recorrentes. O modelo Híbrido manteve um equilíbrio entre ambos, com tempo de 57 minutos. Esses resultados mostram que o número de parâmetros não explica sozinho o custo de treinamento, sendo necessário considerar também a natureza da arquitetura.

A Tabela 12 sintetiza os resultados obtidos, reunindo as principais métricas de desempenho, tempos de processamento e complexidade estrutural de cada modelo. Essa apresentação comparativa permite visualizar de forma clara os pontos fortes e limitações de cada arquitetura, destacando qual delas se sobressai em cada característica avaliada. Observa-se que o modelo Híbrido apresentou os melhores resultados em termos de acurácia preditiva (menor RMSE e rRMSE, maior R^2 e correlação cruzada), enquanto a TCN se mostrou mais eficiente em tempo de treinamento. A Bi-LSTM, por sua vez, embora apresente o menor número de parâmetros, demandou maior tempo de treinamento. Dessa forma, a tabela reforça a análise de compromisso

entre desempenho e eficiência computacional discutida nas subseções anteriores.

Tabela 12 – Comparação entre os modelos. Os melhores valores em cada característica estão destacados em negrito.

Característica	Bi-LSTM	TCN	Híbrido
RMSE (N)	105,07	152,05	103,22
rRMSE (%)	7,08	10,49	6,90
R^2	0,86	0,70	0,87
Correlação	0,93	0,89	0,96
Tempo de Treino	154 min	6 min 13 s	57 min
Tempo de Inferência	0,06–0,07 s	0,02 s	0,03 s
Parâmetros	9.857	30.145	21.825

Comparação com Trabalhos Relacionados

Os resultados obtidos neste estudo comprovam a eficácia das redes neurais profundas na estimativa da GRF a partir de sensores inerciais, como apontado por outros trabalhos disponíveis na literatura. Por exemplo, Pimentel et al. (2024) demonstraram que é possível estimar o pico da GRF com erro médio de 4,4% do peso corporal utilizando uma arquitetura MLP simples e apenas um acelerômetro na cintura. Apesar da simplicidade da abordagem, os autores observaram queda de desempenho ao incluir sensores no pé — o que contrasta com os achados do presente trabalho, em que o sensor no pé apresentou maior similaridade com a GRF (correlação média de 0,827), favorecendo sua utilização na predição offline da curva completa da força.

De forma semelhante, ALCANTARA et al. (2022) utilizaram uma RNN para prever a curva da GRF durante corrida em terrenos inclinados, alcançando RMSE médio de aproximadamente 130 N, valor superior ao obtido no presente trabalho pelo modelo Híbrido (RMSE de 103,22 N). Essa diferença pode ser atribuída à arquitetura mais sofisticada empregada no presente estudo e ao uso de sensores no segmento distal, que oferecem maior resolução dinâmica.

Em relação ao uso de arquiteturas híbridas, os resultados encontrados também se comparam aos de ARSHAD et al. (2022), que aplicaram um modelo CNN-BiGRU com mecanismo de atenção para detectar eventos da marcha (heel-strike e toe-off) com precisão superior a 99%. Apesar da diferença de foco — detecção de eventos discretos versus predição contínua da GRF — ambos os trabalhos confirmam que modelos híbridos são mais eficazes que arquiteturas puramente convolucionais ou recorrentes.

Já ALTAI et al. (2023) avaliaram diversas arquiteturas profundas, incluindo CNNs, LSTMs, TCNs e Transformers, na predição de momentos articulares e GRF. Os autores observaram que as redes recorrentes (especialmente Bi-LSTM) e modelos híbridos superaram os TCNs em termos de acurácia, corroborando os resultados obtidos no presente estudo, nos quais o modelo TCN foi o mais eficiente computacionalmente, mas apresentou desempenho inferior ($R^2 = 0,70$ e rRMSE de 10,49%).

Por fim, os resultados de Hossain et al. (2022) com o modelo DeepBBWAE-Net — uma combinação de CNN, RNN e ensemble learning — também reforçam a tendência observada: modelos híbridos são especialmente promissores para estimativas biomecânicas complexas, como a GRF, principalmente quando aplicados a sensores localizados próximos ao pé ou ao centro de massa.

Os nossos resultados, portanto, complementam estudos anteriores, demonstrando que a escolha adequada do sensor e da arquitetura da rede é determinante para alcançar um bom equilíbrio entre desempenho preditivo e eficiência computacional.

Alcance dos Objetivos Propostos

O objetivo principal deste estudo foi verificar a viabilidade de estimar a GRF a partir de dados de acelerômetros com o uso de redes neurais profundas. Os resultados comprovam que esse objetivo foi alcançado de forma satisfatória. As arquiteturas Híbrida e Bi-LSTM obtiveram métricas de erro reduzidas e altos coeficientes de determinação, ratificando sua capacidade estimativa. A escolha do sensor no pé, fundamentada pela análise de correlação cruzada, mostrou-se correta, refletindo a maior semelhança estrutural com os padrões da GRF.

Relevância do Estudo

As contribuições deste trabalho são relevantes para a área de biomecânica computacional e aprendizado profundo aplicado à saúde e esportes:

- Proposição de uma metodologia baseada em correlação cruzada para selecionar a posição mais promissora do sensor inercial para estimativa da GRF, sendo desconsiderado o atraso temporal;
- Implementação e análise comparativa de três arquiteturas profundas sob as mesmas condições experimentais, possibilitando inferências robustas;
- Apresentação de uma abordagem de estimativa prática e de baixo custo, viável para uso extra laboratoriais;
- Criação de scripts reutilizáveis para análise biomecânica com redes neurais, contribuindo para a reprodutibilidade científica;
- Inclusão da análise de correlação cruzada como métrica complementar à acurácia tradicional, enriquecendo a avaliação temporal dos modelos.

Limitações

Indicamos as seguintes limitações do Estudo:

- A base de dados utilizada inclui apenas indivíduos saudáveis em condições padronizadas de marcha, o que pode limitar a generalização dos resultados;
- Apenas um sensor foi usado por vez como entrada nos modelos, não sendo exploradas arquiteturas multissensoriais;
- As análises focaram exclusivamente no componente vertical da GRF;
- Os resultados ainda não foram validados com aquisição de dados em tempo real.

Perspectivas Futuras

A partir das conclusões obtidas, sugerem-se algumas direções:

- Explorar estratégias com um único sensor inercial, aumentando a robustez dos modelos;
- Validar os modelos em populações clínicas com alterações na marcha, como idosos, amputados ou pacientes neurológicos;
- Estender a estimativa para variáveis biomecânicas adicionais, como momentos articulares ou GRF multidimensional;
- Validar o modelo híbrido em condições típicas de atletas como corridas e saltos.
- Investigar arquiteturas computacionais emergentes, como Transformers e redes auto-supervisionadas, visando ganho de desempenho com menor custo;
- Realizar validação com coleta de dados em tempo real.

Conclusão

Conclui-se, portanto, que a utilização de redes neurais profundas para estimativa da GRF a partir de dados de acelerômetros é uma alternativa promissora, acessível e precisa, com amplo potencial de aplicação em contextos clínicos e esportivos, contribuindo para democratizar a análise biomecânica fora de ambientes especializados.

Referências

- ALCANTARA, R. S. et al. Predicting continuous ground reaction forces from accelerometers during uphill and downhill running: a recurrent neural network solution. *PeerJ*, v. 10, p. e12752, 2022. Citado 7 vezes nas páginas 25, 28, 33, 40, 43, 53 e 55.
- ALHARTHI, A. S.; OZANYAN, K. B. Deep learning for ground reaction force data analysis: Application to wide-area floor sensing. In: *Proceedings of the 28th International Symposium on Industrial Electronics (ISIE)*. [S.l.]: IEEE, 2019. p. 1401–1406. Citado na página 33.
- ALMANI, A. A.; HAN, X. Real-time pricing-enabled demand response using long short-time memory deep learning. *Energies*, MDPI, v. 16, n. 5, p. 2410, 2023. Citado na página 26.
- ALTAI, Z. et al. Performance of multiple neural networks on predicting lower limb joint moments using wearable sensors. *Scientific Reports*, v. 13, p. 12282, 2023. Citado 3 vezes nas páginas 32, 53 e 55.
- ARSHAD, M. et al. Gait events prediction using hybrid cnn-rnn-based deep learning models through a single waist-worn wearable sensor. *Sensors*, v. 22, n. 21, p. 8226, 2022. Citado 4 vezes nas páginas 17, 24, 53 e 55.
- BAI, S.; KOLTER, J. Z.; KOLTUN, V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. In: *Proceedings of the 35th International Conference on Machine Learning (ICML)*. Stockholm, Sweden: PMLR, 2018. p. 899–908. Citado 3 vezes nas páginas 30, 31 e 33.
- BENGIO, Y.; SIMARD, P.; FRASCONI, P. Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, v. 5, n. 2, p. 157–166, 1994. Citado na página 25.
- CAMARGO, J. et al. A comprehensive, open-source dataset of lower limb biomechanics in multiple conditions of stairs, ramps, and level-ground ambulation and transitions. *Journal of Biomechanics*, v. 119, p. 110320, 2021. Citado 3 vezes nas páginas 15, 21 e 33.
- CHAABAN, C. R. et al. Combining inertial sensors and machine learning to predict vgrf and knee biomechanics during a double limb jump landing task. *Sensors*, v. 22, n. 16, p. 6032, 2021. Citado 2 vezes nas páginas 16 e 23.
- CHEN, C.-Y. et al. Ground reaction force patterns in stroke patients with various degrees of motor recovery determined by plantar dynamic analysis. *Chang Gung medical journal*, v. 87, n. 4, p. 552–556, 2007. Citado na página 16.
- CHEN, F. et al. How to obtain and run light and efficient deep learning networks. *Information Fusion*, v. 93, p. 21–37, 2023. Citado na página 48.
- CHOI, H. S. et al. Calibrating low-cost smart insole sensors with recurrent neural networks for accurate prediction of center of pressure. *Sensors*, v. 24, n. 15, p. 4765, 2024. Citado na página 16.

CICIRELLI, G. et al. Human gait analysis in neurodegenerative diseases: A review. *IEEE Journal of Biomedical and Health Informatics*, v. 26, n. 1, p. 229–241, 2022. Citado na página 19.

CRENNA, F.; ROSSI, G. B.; BERARDENGO, M. Filtering biomechanical signals in movement analysis. *Sensors*, v. 21, n. 13, p. 4580, 2021. Citado na página 38.

FENG, N.; ZHANG, G.; KHANDELWAL, K. On the application of data-driven deep neural networks in linear and nonlinear structural dynamics. *CoRR*, abs/2111.02784, 2021. Citado na página 16.

Gait Up. *Physilog*[®] – Wearable gait lab for clinical and sports analysis. [S.l.], 2024. Disponível em: <<https://physilog.com>>. Acesso em: 19 de maio de 2025. Citado na página 36.

GRAVES, A. Generating sequences with recurrent neural networks. *CoRR*, abs/1308.0850, 2013. Citado na página 28.

GRAVES, A.; SCHMIDHUBER, J. Framewise phoneme classification with bidirectional lstm and other neural network architectures. *Neural Networks*, v. 18, n. 5–6, p. 602–610, 2005. Citado 2 vezes nas páginas 27 e 28.

GROUVEL, G. et al. A dataset of asymptomatic human gait and movements obtained from markers, imus, insoles and force plates. *Scientific Data*, v. 10, p. 180, 2023. Citado 5 vezes nas páginas 15, 33, 35, 36 e 38.

GUO, Y. et al. A new proxy measurement algorithm with application to the estimation of vertical ground reaction forces using wearable sensors. *Sensors*, v. 17, n. 10, p. 2181, 2017. Citado na página 15.

GÉRON, A. *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow*. 2. ed. Rio de Janeiro: Alta Books, 2019. Tradução da obra: Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow. ISBN 9788550813946. Citado na página 27.

HAMMERLA, N. Y.; HALLORAN, S.; PLÖTZ, T. Deep, convolutional, and recurrent models for human activity recognition using wearables. In: *Proceedings of the 25th International Joint Conference on Artificial Intelligence (IJCAI)*. [S.l.: s.n.], 2016. p. 1533–1540. Citado na página 40.

HAVASHINEZHADIAN, S. et al. Inertial sensor location for ground reaction force and gait event detection using reservoir computing in gait. *International Journal of Environmental Research and Public Health*, v. 20, n. 4, p. 3120, 2023. Citado 3 vezes nas páginas 16, 21 e 37.

HERNÁNDEZ-GARCÍA, A.; KÖNIG, P. Further advantages of data augmentation on convolutional neural networks. *CoRR*, abs/1906.11052, 2019. Citado na página 30.

HERSSENS, N. et al. Falls among people with bilateral vestibulopathy: A review of causes, incidence, injuries, and methods. *JAMA Otolaryngology–Head & Neck Surgery*, v. 148, n. 2, p. 187–194, 2022. Citado 2 vezes nas páginas 16 e 20.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural Computation*, v. 9, n. 8, p. 1735–1780, 1997. Citado 3 vezes nas páginas 25, 26 e 53.

- HOSSAIN, M. S. B. et al. Deepbbwae-net: A cnn-rnn based deep superlearner for estimating lower extremity sagittal plane joint kinematics using shoe-mounted imu sensors in daily living. *IEEE Journal of Biomedical and Health Informatics*, IEEE, v. 26, n. 8, p. 3906–3917, 2022. Citado 2 vezes nas páginas 53 e 56.
- IOFFE, S.; SZEGEDY, C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. In: *Proceedings of the 32nd International Conference on Machine Learning (ICML)*. [S.l.: s.n.], 2015. Citado na página 39.
- JOHNSON, W. R. et al. Predicting athlete ground reaction forces and moments from spatio-temporal driven cnn models. *IEEE Transactions on Biomedical Engineering*, v. 66, n. 3, p. 689–694, 2019. Citado 4 vezes nas páginas 29, 32, 40 e 53.
- JOHNSON, W. R. et al. Multidimensional ground reaction forces and moments from wearable sensor accelerations via deep learning. *IEEE Transactions on Biomedical Engineering*, v. 68, n. 1, p. 289–297, 2021. Citado na página 16.
- LEA, C. et al. Temporal convolutional networks for action segmentation and detection. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2017. p. 156–165. Citado na página 30.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015. Citado na página 29.
- LECUN, Y. et al. Efficient backprop. In: *Neural Networks: Tricks of the Trade*. [S.l.]: Springer, 2012. p. 9–48. Citado na página 39.
- LIU, A.; LI, J.; YE, H. A prediction model combining convolutional neural network and lstm neural network. In: *Proceedings of the 2nd International Conference on Artificial Intelligence and Autonomous Robot Systems (AIARS)*. [S.l.: s.n.], 2023. p. 318–321. Citado na página 33.
- MAEDA, T. et al. A force platform free gait analysis. *Proceedings*, v. 2, n. 6, p. 207, 2018. Citado 2 vezes nas páginas 15 e 17.
- MARTÍNEZ-PASCUAL, D. et al. Estimating vertical ground reaction forces during gait from lower limb kinematics and vertical acceleration using wearable inertial sensors. *Frontiers in Bioengineering and Biotechnology*, v. 11, p. 1199459, 2023. Citado na página 22.
- MathWorks. *Deep Learning Toolbox Documentation*. [S.l.], 2024. Disponível em: <<https://www.mathworks.com/help/deeplearning/index.html>>. Acesso em: 19 de maio de 2025. Citado na página 35.
- MathWorks. *filtfilt – Zero-phase digital filtering*. [S.l.], 2024. Disponível em: <<https://www.mathworks.com/help/signal/ref/filtfilt.html>>. Acesso em: 03 de maio de 2025. Citado na página 38.
- MathWorks. *xcorr - Cross-correlation*. [S.l.], 2024. MATLAB Documentation. Disponível em: <<https://www.mathworks.com/help/matlab/ref/xcorr.html>>. Acesso em: 21 de maio de 2025. Citado na página 37.
- Moticon ReGo AG. *Moticon – Wireless Sensor Insoles and Analytics Software*. [S.l.], 2024. Disponível em: <<https://moticon.com>>. Acesso em: 19 de maio 2025. Citado na página 36.

- NGOH, K. J. et al. Estimation of vertical ground reaction force during running using neural network model and uniaxial accelerometer. *Journal of Biomechanics*, v. 76, p. 269–273, 2018. Citado na página 32.
- NOVACHEK, T. F. The biomechanics of running. *Gait & Posture*, v. 7, n. 1, p. 77–95, 1998. Citado 2 vezes nas páginas 19 e 20.
- O'SHEA, K.; NASH, R. An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*, 2015. Citado na página 30.
- PACHER, L. et al. Comparison of lower limb calibration methods for movement analysis with inertial measurement units (imu). *Computer Methods in Biomechanics and Biomedical Engineering*, v. 23, n. S1, p. S215–S217, 2020. Citado 2 vezes nas páginas 23 e 24.
- PERRY, J.; BURNFIELD, J. M. *Gait Analysis: Normal and Pathological Function*. 2. ed. [S.l.]: SLACK Incorporated, 2010. Citado 7 vezes nas páginas 15, 19, 20, 21, 22, 52 e 53.
- PHUNG, V. H.; RHEE, E. J. A high-accuracy model average ensemble of convolutional neural networks for classification of cloud image patches on small datasets. *Applied Sciences*, v. 9, p. 4500, 2019. Citado na página 29.
- PIMENTEL, M. B. et al. Effect of sensor placement and number on the estimation of vertical ground reaction force during walking. *PLOS Digital Health*, v. 3, n. 2, p. e0000343, 2024. Citado 5 vezes nas páginas 24, 31, 37, 46 e 55.
- REISS, A.; STRICKER, D. Introducing a new benchmarked dataset for activity monitoring. In: *Proceedings of the 2012 16th International Symposium on Wearable Computers (ISWC)*. [S.l.: s.n.], 2012. p. 108–109. Citado na página 40.
- SARKER, R. et al. Integrating climate change variables in relative humidity prediction with multivariate arima and rnn models. Preprint publicado em Research Square. 2023. Citado na página 25.
- SHASHUA, A. *Introduction to Machine Learning: Class Notes 67577*. [s.n.], 2008. abs/0904.3664. Disponível em: <<http://arxiv.org/abs/0904.3664>>. Citado na página 40.
- SY, L. et al. Estimating lower limb kinematics using a reduced wearable sensor count. *IEEE Transactions on Biomedical Engineering*, v. 68, n. 4, p. 1293–1304, 2021. Citado na página 24.
- WANG, L.; ZHANG, Y.; LI, Q. Gait symmetry based on principal component analysis method. In: *Proceedings of the 27th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. Shanghai, China: IEEE, 2005. p. 5729–5732. Citado na página 37.
- WINTER, D. A. *Biomechanics and Motor Control of Human Movement*. 4. ed. [S.l.]: John Wiley & Sons, 2009. Citado 9 vezes nas páginas 15, 19, 20, 21, 22, 37, 40, 52 e 53.
- ZHONG, P. Enhanced multivariate time series regression prediction using temporal convolution networks. In: *2024 7th International Conference on Pattern Recognition and Artificial Intelligence (PRAI)*. [S.l.]: IEEE, 2024. p. 661–666. Citado na página 33.

APÊNDICE A – Código-Fonte e Arquivos do Estudo

Este apêndice disponibiliza o repositório com todo o material desenvolvido para a realização deste trabalho, incluindo:

- Scripts em *Matlab* para pré-processamento, cálculo da correlação cruzada, treinamento dos modelos e inferência da GRF;
- Arquivos `.csv` contendo os resultados das métricas de cada modelo, os coeficientes da correlação cruzada, os valores estimados da GRF e os resíduos dos modelos;
- Arquivos `.mat` contendo os parâmetros de normalização e os pesos treinados de cada arquitetura de rede neural (Bi-LSTM, TCN e Híbrida).

O material está disponível no repositório:

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

O acesso livre a este conteúdo visa garantir a reprodutibilidade dos experimentos, bem como possibilitar futuras pesquisas e aprimoramentos no desenvolvimento de modelos estimativos aplicados à biomecânica da marcha humana.