

## SIMULAÇÃO DA FORÇA DE REAÇÃO DO SOLO ANTEROPOSTERIOR DA MARCHA USANDO MODELOS LINEARES E NÃO LINEARES

Gustavo Leporace\*, Luiz Alberto Batista\*\*, Leonardo Metsavaht\*\*\*, Flavio F. Nobre\*, Felipe Alvim\*, Aluizio d’Affonseca Netto\* e Jurandir Nadal\*

\*Programa de Engenharia Biomédica, COPPE/UFRJ, Rio de Janeiro, Brasil

\*\* Laboratório de Biomecânica e Comportamento Motor, UERJ, Rio de Janeiro, Brasil

\*\*\* Instituto Brasil de Tecnologias da Saúde, Rio de Janeiro, Brasil

e-mail: guleporace@yahoo.com.br; jn@peb.ufrj.br

**Resumo:** O objetivo desse estudo foi desenvolver e comparar modelos de redes neurais multicamadas (MLP) e de regressão linear múltipla (RL) para simular as curvas de forças de reação do solo anteroposteriores (FRSap) durante a marcha utilizando dados de acelerometria. Dezesete sujeitos com um acelerômetro afixado na região distal e anterior da perna direita caminharam em uma pista de marcha instrumentalizada com uma plataforma de força. Parâmetros obtidos da curva de aceleração anteroposterior foram inseridos em modelos de MLP e RL, usando como desfecho as FRSap coletadas. Utilizou-se o desvio médio absoluto para medir os erros das modelagens e a técnica de análise de componentes principais (PCA) para comparar as modelagens com o sinal coletado. Os resultados apontaram erros da simulação com a MLP em média 2,5 vezes menor do que com a RL. Após a PCA, os sinais simulados com a RL foram estatisticamente diferentes dos sinais modelados com MLP e dos sinais coletados, sendo que os dois últimos não apresentaram diferenças significativas. Em síntese, o modelo de rede neural multicamadas foi capaz de prever a relação altamente não-linear entre parâmetros obtidos da curva de aceleração anteroposterior e a FRSap. Embora os erros tenham sido menores do que 5%, alguns ajustes ainda precisam ser realizados antes da aplicação na prática clínica.

**Palavras-chave:** Redes neurais, Inteligência computacional, Modelagem, Biomecânica, Regressão linear.

**Abstract:** *The aim of this study was to develop and compare models of multi-layer perceptron (MLP) neural network and multiple linear regression (LR) to simulate the curves of anteroposterior ground reaction forces (apGRF) during gait using data obtained with an accelerometer. Seventeen subjects with an accelerometer attached to the distal and anterior shank walked on an instrumented walkway instrumented with a force platform. Parameters obtained from the anteroposterior acceleration curve were inserted into the MLP and LR models, using as an outcome the collected apGRF. The mean absolute deviation was used to measure the errors of the models and a principal component analysis (PCA) to compare the two modeling with the collected signal. The results showed errors of MLP simulation, on average, 2.5 times lower than LR*

*model. After PCA, the LR modelled signals were statistically different from the MLP modeled and collected signals and the last two were not significantly different. Thus, the multi-layer perceptron neural network could predict the non-linear relationship between shank anteroposterior acceleration parameters and apGRF. Although the error was lower than 5%, some improvements must be done prior to use in the clinical setting.*

**Keywords:** *Neural network, Computational intelligence, Modeling, Biomechanics, Linear regression.*

### Introdução

A análise biomecânica do movimento humano vem sendo utilizada para auxiliar o diagnóstico, acompanhar a evolução das doenças e dar suporte a tomadas de decisões relativas a tratamentos [1]. Apesar de sua validação científica, ainda há uma baixa aplicabilidade dos exames biomecânicos quantitativos na prática clínica de profissionais da saúde. Watts [2] atribuiu essa baixa aplicabilidade aos altos custos do exame, relacionados ao espaço físico, equipe técnica especializada e, principalmente, aos equipamentos necessários.

De uma forma geral, os principais métodos utilizados pela biomecânica para abordar as diversas formas de movimento são: cinemetria, dinamometria e eletromiografia [3]. Utilizando-se estes métodos, o movimento pode ser descrito detalhadamente nas suas características e ainda modelado matematicamente, permitindo uma maior compreensão dos mecanismos internos reguladores do movimento do corpo humano.

Grande parte dos equipamentos disponíveis para mensurar as variáveis biomecânicas possui um custo elevado, dificultando a implementação em ambientes clínicos privados. Por conseguinte, equipamentos com baixo custo têm sido desenvolvidos para suprir essa carência. Na área de cinemática, sensores inerciais têm sido utilizados para substituir os sistemas optoeletrônicos de análise de imagens [4], mostrando resultados promissores.

Visando substituir plataformas de força, Leporace et al. [5] propuseram a utilização de um acelerômetro, posicionado na região distal de tíbia, para prever as forças de reação do solo verticais, por meio de técnicas de inteligência computacional. Os autores encontraram

resultados promissores, com erros residuais menores do que 7%. No entanto, ainda não se sabe como seria o desempenho de diferentes modelos, com características lineares e não-lineares, na predição das forças de reação do solo anteroposteriores (FRSap) durante a marcha.

O objetivo desse estudo foi desenvolver e comparar modelos de redes neurais multicamadas e de regressão linear múltipla para simular as curvas de FRSap durante a marcha utilizando-se dados de acelerometria.

## Materiais e métodos

Dezessete sujeitos hígidos caminharam quatro vezes em uma pista de marcha de 8 m com um acelerômetro ( $\pm 6$  g, modelo MMA7260Q, Freescale, EUA) afixado na região distal e anterior da perna direita. Uma plataforma de força (AccuGait, AMTI, EUA) foi posicionada no centro da pista e coberta por um tecido para evitar a identificação da sua posição pelo participante. Todos assinaram um termo de consentimento livre e esclarecido, aprovado pelo Comitê de Ética em Pesquisa.

Os dados foram coletados usando um sistema BIOPAC (UIM, MP100 Systems, BIOPAC, USA) com uma taxa de amostragem de 1 kHz e filtrados por um filtro passa baixas Butterworth de 2ª ordem, aplicado na direção direta e reversa para evitar distorções de fase. A frequência de corte foi de 25 Hz para as FRSap e para os dados de aceleração. O período da fase de apoio da marcha foi determinado quando os sinais de força de reação do solo verticais permaneciam acima de 10 N. Os sinais filtrados de FRSap e aceleração anteroposterior da fase de apoio foram interpolados para 101 valores usando um algoritmo de spline cúbica.

Para prever os valores de FRSap, seis entradas foram selecionadas, baseadas em estudos anteriores [6,7]: (i) os dados de aceleração anteroposterior normalizados pelo peso corporal; (ii) a velocidade anteroposterior relativa dos sujeitos, representada pela integração simples da curva de aceleração; (iii) o deslocamento anteroposterior relativo dos sujeitos, representado pela integração dupla da curva de aceleração; (iv) a derivada do sinal de aceleração anteroposterior; (v) a duração da fase de apoio em segundos; (vi) o instante da fase de apoio, representado como um percentual (%) do tempo de apoio.

A modelagem não linear escolhida para simular as forças de reação do solo foi a rede neural multicamadas (MLP) com uma camada escondida. O número de neurônios na camada escondida foi selecionado por meio da testagem do ajuste na predição dos sinais, usando diferentes tamanhos (variando entre 5 e 12 neurônios), sempre buscando o modelo mais parcimonioso, ou seja, poucos neurônios e alto poder de generalização. Para avaliar o ajuste da rede neural utilizou-se o método de validação cruzada *leave-one-out*. A rede neural foi treinada usando sempre quatro ciclos da marcha de 16 sujeitos. O sinal de FRSap do sujeito deixado de fora do treinamento foi simulado utilizando a rede treinada com os dados dos outros 16 e utilizado para testar o ajuste da rede.

Para cada repetição, a rede foi treinada usando o algoritmo de retropropagação de Levenberg-Marquadt, baseado em 6464 vetores (16 sujeitos \* 4 ciclos da marcha \* 101 pontos percentuais) de seis entradas, como descrito acima, e 6464 valores de FRSap como saída [5-7].

Na camada escondida e na camada de saída, as funções de transferência utilizadas foram a tangente hiperbólica e linear, respectivamente. Essa topologia foi utilizada porque em estudos semelhantes essas funções de transferência produziram melhores resultados de predição em sinais biomecânicos, além de possibilitar uma comparação direta com resultados de outros estudos [6-8]. Para evitar o sobreajuste da rede, o erro de generalização obtido pelo grupo de validação durante o processo de treinamento e o gradiente mínimo foram utilizados como critérios de interrupção do treinamento. A rede com a menor mediana do desvio médio absoluto (DMA) entre todos os sujeitos foi selecionada como o melhor número de neurônios na camada escondida [6,7]. O DMA foi calculado como:

$$\text{DMA} = \frac{1}{101} \sum_{t=0}^{100} |\widehat{\text{FRSap}}(t) - \text{FRSap}(t)| \quad (1)$$

onde  $\widehat{\text{FRSap}}(t)$  corresponde à força de reação do solo anteroposterior simulada com a MLP e  $\text{FRSap}(t)$  corresponde à força de reação do solo anteroposterior coletada.

Para realizar a modelagem linear foi utilizada a técnica de regressão linear múltipla (RL):

$$\mathbf{y} = \mathbf{A}_0 + \sum_{i=1}^6 \mathbf{A}_i \mathbf{x}_i \quad (2)$$

onde  $\mathbf{y}$  é o sinal de FRSap coletado de todos os sujeitos,  $\mathbf{x}_i$  são as entradas utilizadas para a rede neural, descritas anteriormente, e  $\mathbf{A}_i$  são os coeficientes da regressão.

Para avaliar o ajuste da RL utilizou-se o método de validação cruzada *leave-one-out*. Os coeficientes do modelo foram calculados sempre com quatro ciclos da marcha de 16 sujeitos. O sinal de FRSap do sujeito deixado de fora do treinamento foi simulado com os coeficientes resultantes da RL e então utilizado para testar o ajuste do modelo, utilizando a DMA.

Para testar se havia diferenças significativas entre os sinais simulados e os sinais medidos, as 204 curvas de FRSap, 68 medidas, 68 simuladas com MLP e 68 simuladas com RL, foram inseridas em uma matriz  $\mathbf{D}$  [204 x 101], onde cada linha corresponde aos ciclos da marcha dos 17 sujeitos e cada coluna corresponde aos sinais interpolados. A Análise de Componentes Principais (PCA) foi aplicada à matriz  $\mathbf{D}$ , com os autovalores e autovetores estimados utilizando o algoritmo de decomposição de valores singulares [9].

Os CP retidos na análise foram aqueles cuja soma cumulativa contabilizava 90% da variância dos dados originais. Os escores dos CP retidos foram comparados entre os sinais simulados com MLP e RL e os coletados utilizando um teste de análise de variância one way, com pós-teste de diferença honestamente significativa de Tukey, com nível de significância de 0,05. Calculou-

se o coeficiente de correlação de Pearson entre os sinais coletados e simulados com MLP e também com RL. Para cada ciclo da marcha, as FRSap simuladas e coletadas também foram comparadas utilizando o DMA percentual, dada por:

$$\text{DMA\%} = \frac{\text{DMA}}{\text{range (FRSap}(t))} \times 100 \quad (3)$$

Todo o processamento dos sinais e as análises estatísticas foram realizados em rotinas desenvolvidas em ambiente MATLAB 7.8.0 (The Mathworks, EUA).

## Resultados

As medidas de erro e de correlação entre os sinais de FRSap coletados e simulado utilizando a MLP mostraram-se adequadas, ao contrário do sinal simulado utilizando a RL (Tabela 1, Figura 1). O número de neurônios na camada escondida da MLP que apresentou o menor DMA mediano foi 11.

Tabela 1: Desvio médio absoluto (DMA) e percentual (DMA%) e coeficiente de correlação (R) entre os sinais coletados e simulados com regressão logística (RL) e redes neurais multicamadas (MLP).

Parâmetro	RL	MLP
DMA	3,8 %PC	1,5 %PC
DMA%	10,3 %	3,8 %
R	0,84	0,98

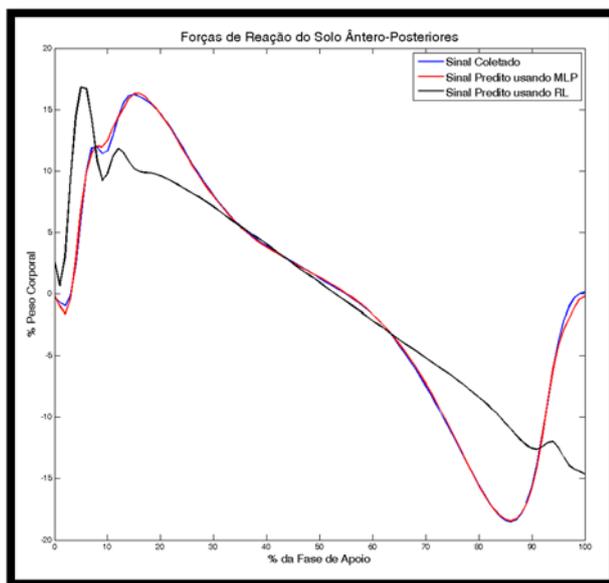


Figura 1: Média das forças de reação do solo anteroposteriores coletadas (em azul), preditas com MLP (em vermelho) e preditas com RL (em preto) durante a fase de apoio do ciclo da marcha.

Cinco CP foram retidos na PCA, representando 90,4% da variância original dos dados. Os escores do primeiro e segundo CP apresentaram diferenças

significativas no teste de Anova ( $p < 0,05$ ). Para o primeiro componente o teste de Tukey apontou diferenças entre o RL e os outros dois grupos. Para o segundo componente houve diferença somente entre o RL e os sinais coletados. Para os outros três escores não houve diferenças significativas.

## Discussão

O desenvolvimento de instrumentos de baixo custo e a simulação de dados para realização de análises biomecânicas tem sido foco de diversos estudos [5-7], uma vez que o custo das tecnologias necessárias para análise de marcha impede sua disseminação. Alguns estudos têm focado na modelagem dos momentos de força articular baseados em dados antropométricos e de força de reação do solo [6,7], cujos resultados têm sido utilizados por outros estudos biomecânicos. Todavia, esse tipo de modelagem ainda requer o emprego de sinais de uma plataforma de força. Portanto, no contexto de instrumentos de baixo custo, ainda há a necessidade de modelos que possibilitem a simulação de dados de força de reação do solo com sensores mais baratos, como acelerômetros. O presente estudo visa contribuir nesta direção.

Em estudo prévio e pioneiro, Leporace et al. [5] utilizaram sensores posicionados no mesmo local para simular os dados das forças verticais de reação do solo, encontrando erros percentuais de 6,2% e coeficiente de correlação de 0,96. Apesar do emprego de metodologia bastante similar, algumas diferenças foram realizadas nesse estudo, que contribuíram para reduzir os erros e aumentar o coeficiente de correlação.

A primeira diferença foi a interpolação da fase de apoio dos ciclos da marcha para 101 valores, assim como realizado por Favre et al. [7], ao invés de 51 valores. Com a utilização do maior número de valores, havia maior número de observações para os modelos lineares e não lineares conseguirem desenvolver seus coeficientes de maneira mais adequada. A segunda diferença foi a inclusão de uma nova variável, a derivada do sinal de acelerometria, a qual foi selecionada devido ao alto pico de impacto observado em alguns sujeitos em aproximadamente 10% da fase de apoio (Figura 1). Esse pico de impacto gera uma taxa de variação no sinal que poderia ser identificada mais adequadamente com a primeira derivada do parâmetro de entrada.

Outra diferença em relação aos estudos de simulação de sinais biomecânicos foi a inclusão de um modelo linear para verificar a real necessidade de modelos não lineares, que possuem um custo computacional maior. Os resultados do presente estudo confirmam que um modelo de rede neural multicamadas pode prever adequadamente as curvas de FRSap, baseado somente em parâmetros obtidos a partir das curvas de aceleração, diferentemente de modelos de regressão linear múltipla (Tabela 1). De forma geral, a MLP apresentou erros 2,5 vezes menores do que a RL, com coeficiente de correlação 1,2 vezes maior na MLP.

Os resultados aumentam a expectativa de prever, no futuro, os momentos de força baseados em dados de força de reação do solo obtidos de uma simulação, como no presente estudo. Além disso, o método utilizado permite que esses dados cinéticos sejam simulados durante situações mais realistas, como em corridas de rua e diferentes provas esportivas em estádios. Dessa forma, novos programas de prevenção e reabilitação esportiva poderão ser desenvolvidos para minimizar os efeitos dessas cargas mecânicas para cada tarefa motora que o sujeito for exposto, aumentando, dessa forma, a individualidade do tratamento. Ainda será possível estimar as cargas mecânicas durante técnicas terapêuticas para avaliar o real efeito de cada uma sobre os diferentes tecidos do corpo humano.

Apesar da média dos sinais coletados e simulados com a MLP ter sido muito parecida (Figura 1), alguns sujeitos não apresentam uma modelagem tão adequada (Figura 2).

Um aspecto importante é o fato de que os dados coletados de acelerometria anteroposterior são perpendiculares à tibia, enquanto que os dados de FRSap, coletados com a plataforma de força são perpendiculares ao vetor de aceleração da gravidade. O controle desse parâmetro pode auxiliar na redução do erro de predição. Uma solução seria a utilização de sensores inerciais, que possibilitam o cálculo dos ângulos de Euler, para corrigir esse *offset* entre sinais.

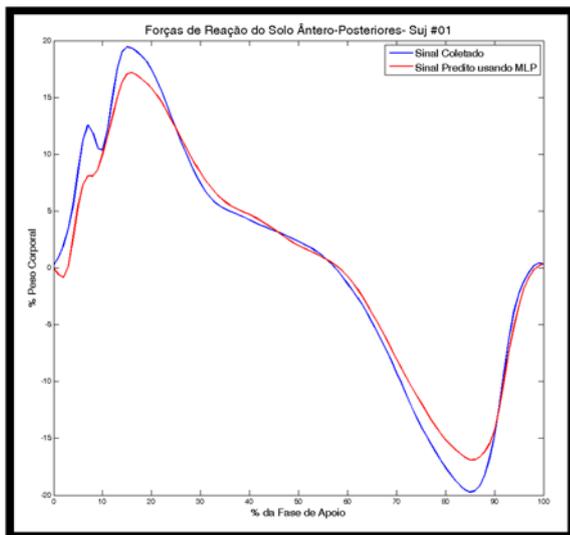


Figura 2: Média das forças de reação do solo anteroposteriores coletadas (em azul), preditas com MLP (em vermelho) do sujeito #1 durante a marcha.

Outro aspecto relevante é a ausência de uma mineração de dados inicial para selecionar as variáveis mais adequadas. A inclusão das variáveis foi realizada a partir de estudos anteriores que obtiveram resultados adequados usando parâmetros semelhantes. No entanto, não se sabe se para os modelos e os sinais utilizados no presente estudo essas variáveis são, de fato, as mais indicadas. Sugere-se para estudos futuros a identificação da relação linear e não linear entre os parâmetros de

entrada utilizando técnicas como correlação de Pearson e informação mútua visando identificar a relevância da inclusão de cada variável.

## Conclusão

Esse estudo confirmou que o modelo de rede neural multicamadas é capaz de prever a relação não-linear entre parâmetros obtidos da curva de aceleração anteroposterior e a FRSap, assim como outros estudos já o fizeram para a FRS vertical e para momentos de força. Os resultados da modelagem não linear se mostraram mais adequados do que técnicas lineares. Embora os erros tenham sido menores do que 5%, alguns ajustes ainda precisam ser realizados antes da aplicação na prática clínica.

## Agradecimentos

Os autores agradecem a FAPERJ, CNPq e CAPES pelo auxílio financeiro.

## Referências

- [1] Baker R. Gait analysis methods in rehabilitation. *Journal of Neuroengineering and Rehabilitation*. 2006;3(4):1-10.
- [2] Watts HG. Gait laboratory analysis for preoperative decision making in spastic cerebral palsy: Is it all it's cracked up to be? *Journal of Pediatric Orthopedics*. 1994;14(6):703-4.
- [3] Winter DA. *Biomechanics and Motor Control of Human Movement*, 4 ed. New Jersey: John Wiley and Sons; 2009.
- [4] See T, Raisch J, Schauer T. IMU-based joint angle measurement for gait analysis. *Sensors*. 2014; 14(4):6891-909.
- [5] Leporace G, Batista LA, Alvim F, Jesus I, Teixeira F, Netto A, Nobre FF, Nadal J, Menegaldo LL. Simulation of ground reaction forces during gait based on accelerometer data using a neural network model. In: *Proceedings of the XIV International Symposium on Computer Simulation in Biomechanics*; 2013 Aug 1-3; Natal, Brasil. 2013. p. 1-2.
- [6] Liu Y, Shih SM, Tian SL, Zhong YJ, Li L. Lower extremity joint torque predicted by using artificial neural network during vertical jump. *Journal of Biomechanics*. 2009;42(7):906-11.
- [7] Favre J, Hayoz M, Erhart-Hledik JC, Andriacchi TP. A neural network model to predict knee adduction moment during walking based on ground reaction force and anthropometric measurements. *Journal of Biomechanics*. 2012; 45(4):692-8.
- [8] Rouhani, H., Favre, J., Crevoisier, X., and Aminian, K. Ambulatory assessment of 3D ground reaction force using plantar pressure distribution. *Gait and Posture*. 2010; 32: 311-6.
- [9] Jolliffe IT. *Principal Component Analysis*. 1ª ed. New York: Springer Verlag, 2002.