



RESUMO

Introdução: O modelo histerético de Bouc-Wen-Fung (BWF) pode ser utilizado em biomateriais para simular a energia dissipada em diferentes cenários. A importância disto na biomecânica é destacada em função de sua testabilidade *in silico* (gêmeo digital) antes de aplicação *in vivo*, podendo promover um aumento da eficiência no treinamento e na reabilitação. **Objetivo:** avaliar e comparar a capacidade preditiva de algoritmos da inteligência artificial (Random Forest e Gradient Boosting) em estimar a energia dissipada do modelo BWF a partir da amplitude do movimento, da viscosidade e da frequência do ciclo carga-descarga em um biomaterial. **Métodos:** foi consolidado um banco de dados (*in silico*) com mil diferentes dados para as variáveis do modelo, respeitando os limites funcionais do mesmo. Um algoritmo em Python foi utilizado para aplicar os métodos Random Forest (RF) e Gradient Boosting (GB), comparando-os para testar a confiabilidade do modelo. **Resultados:** o método RF, obteve $R^2 = 0,980$, identificando a amplitude do movimento, a viscosidade e a frequência do ciclo carga-descarga como as variáveis mais relevantes do mesmo. O Erro Médio Absoluto (MAE) foi de 0,153 e a Raiz do Erro Quadrático Médio (RMSE) 0,219, corroborando junto com a técnica GB a alta precisão preditiva do modelo em estimar a energia dissipada; o τ de Kendall foi de 0,92 evidenciando que tanto a RF quanto o GB são estratégias robustas para modelos preditivos da capacidade dissipativa em modelo Bouc-Wen-Fung. Embora os limites de equivalência neste estudo tenham sido regidos por critérios de precisão numérica *in silico*, os resultados estabelecem uma base metodológica para futuras investigações *in vivo*.

Palavras-chave: Modelo Bouc-Wen fung; dissipação energia; inteligência artificial.

ABSTRACT

Introduction: The Bouc-Wen-Fung (BWF) hysteretic model can be applied to biomaterials to simulate dissipated energy under various conditions. Its significance in biomechanics is underscored by the ability to test it *in silico* (as a digital twin) prior to *in vivo* application, which can enhance efficiency in training and rehabilitation protocols. **Objective:** To evaluate and compare the predictive performance of machine learning algorithms (Random Forest and Gradient Boosting) in estimating the dissipated energy of the BWF model based on motion amplitude, viscosity, and loading-unloading cycle frequency in biomaterials. **Methods:** An *in silico* dataset comprising 1,000 distinct data points for the model parameters was generated, adhering to their functional constraints. Random Forest (RF) and Gradient Boosting (GB) algorithms were implemented in Python and compared to assess their predictive reliability. **Results:** The RF model achieved an R^2 of 0.980, identifying motion amplitude, viscosity, and loading-unloading cycle frequency as the most significant predictors. For this method, the Mean Absolute Error (MAE) was 0.153 and the Root Mean Square Error (RMSE) was 0.219, which, alongside the performance of the GB technique, corroborates the high predictive accuracy in estimating dissipated energy. A Kendall's τ of 0.92 further demonstrated that both RF and GB are robust strategies for predictive modeling of the dissipative capacity within the BWF framework.

Keywords: Bouc-Wen Fung model; energy dissipation; artificial intelligence.

1. International Society of Human Movement Sciences - ISHMS.
2. UNIFIP-Moc / Afya.
3. Instituto Jundiaense de Ortopedia e Traumatologia.
4. Faculdade de Medicina de Jundiai.
5. Hospital São Vicente de Paulo - Jundiai.

Autor de correspondência

Guanis de Barros Vilela Junior - guanis@gmail.com

INTRODUÇÃO

Um dos grandes desafios metodológicos nas ciências da vida é compreender, em diferentes níveis topológicos, da maquinaria genética à escala macroscópica de sistemas complexos, o comportamento dos fluxos de energia entre eles. O controle desses fluxos energéticos em todas as escalas parece estar longe de resultados com evidências científicas robustas. Vários modelos *in silico* buscam simular a geração, transferência e dissipação da energia. Neste cenário, a complexidade e não linearidade dos sistemas biológicos é um desafio espetacular: afinal, os biomateriais apresentam comportamento visco-plástico-elástico alterado sistematicamente diante de estímulos endógenos e exógenos. Modelos são caricaturas da realidade que nos escapa a cada fração de segundo; um dado coletado informa do passado de uma vida que já mudou. Não obstante, modelos têm a capacidade de inferir sobre o que pode acontecer, primeiro, com o gêmeo digital que cada ser humano consolida à medida que compartilha seus hábitos e estilos de vida em um mundo superconectado; dados de atividade física, tempo de sedentarismo, qualidade nutricional, nível de estresse, qualidade das relações sociais, drogas consumidas (lícitas e ilícitas), dados genéticos e epigenéticos herdados de pais e irmãos. Com algoritmos de Inteligência Artificial (IA) e os big data de cada sujeito, as possibilidades são tanto otimistas quanto pessimistas. O caminho do

meio parece ser o mais sensato: que a IA seja usada eticamente para a melhoria da qualidade de vida de toda a humanidade, e não mais um elemento de exclusão e conflitos.

Longe de ser um formalismo árido, o modelo Bouc-Wen-Fung (BWF)^(1,2,3,4) propõe que não há deformação sem memória. Tal afirmação fica de compreensão facilitada se observarmos o relevo de qualquer lugar no planeta, sua história é contada pelas deformações que sofreram em bilhões de anos. Ao gerar dados a partir do modelo BWF e submetê-los a dois paradigmas distintos de aprendizado, o coletivo paralelo da Random Forest e o corretivo sequencial do Gradient Boosting, não buscamos apenas validar um algoritmo, mas testar se uma equação é capaz de ensinar a uma máquina o que é ter história. Com os biomateriais não é diferente, suas propriedades elásticas, plásticas e viscosas definem o que acontece com os seres vivos. O modelo BWF pode ser útil na compreensão dos processos histeréticos que atestam que a assinatura termodinâmica precisa ser adequada para a manutenção da vida.

MÉTODOS

A partir das equações que regem o modelo histerético de Bouc-Wen^(1,2,4,5) e do modelo hiperelástico de biomateriais de Fung⁽³⁾ um banco de dados foi consolidado com mil diferentes dados para as variáveis do modelo, respeitando os limites funcionais do mesmo. Um algoritmo em Python foi utilizado para aplicar os métodos Random Forest


(RF) e Gradiente Boosting (GB), comparando-os para testar a confiabilidade do modelo. A escolha desses algoritmos está fundamentada em suas arquiteturas distintas, na RF (aprendizado por conjunto) a regressão é tratada a partir da média de todas as árvores, para reduzir a variância e evitar o overfitting pela independência e variabilidade, por sua vez, no GB o foco está na redução de vieses em sucessivas iterações. Essa técnica de *stacking* é importante dado que a RF é bastante eficiente para capturar a estrutura global dos dados e lidar com ruído. Por sua vez o GB é mais eficiente na refinação local, sendo capaz de capturar interações não-lineares complexas e sutis que o RF não consegue satisfatoriamente. Foi utilizado o teste de Kendall (τ) para avaliar a concordância entre desses paradigmas. As variáveis utilizadas foram frequência (Hz), amplitude (mm), viscosidade (Pa.s), tração e compressão de Fung (Pa). Para a avaliação de equivalência estatística, os limites de equivalência (Smallest Effect Size of Interest - SESOI) foram definidos em unidades brutas como $\pm 0,05$ para as variáveis de saída do modelo. Em estudos *in silico*,

diferentemente de ensaios *in vivo*, a definição de equivalência não se baseia em relevância clínica, mas sim na tolerância numérica máxima aceitável pelo algoritmo de solução. Este limiar foi estabelecido para garantir que quaisquer diferenças observadas abaixo desta magnitude sejam atribuídas a ruído computacional, erros de arredondamento de ponto flutuante ou tolerâncias de convergência do solver (ex.: critério de Newton-Raphson), e não a divergências mecânicas reais no modelo^(12,13).

RESULTADOS

O coeficiente de determinação ($R^2=0,980$) é um indicativo que o Random Forest é capaz de explicar 98% da variância na variável dependente (energia dissipada) usando as variáveis independentes fornecidas. Isso sugere que o modelo tem um alto poder preditivo. Não obstante, no contexto de biomateriais do aparelho locomotor humano, um R^2 elevado é crucial para o design de biomateriais e simulações *in silico*. A importância das variáveis, está sintetizada na figura 1.

Figura 1 – importância das variáveis no modelo BWF usando modelo Random Forest



Na figura 1 observa-se que a Amplitude (ou deslocamento) responde por 46,9% da importância das variáveis, sendo o fator dominante na dissipação de energia. No aparelho locomotor, isso pode se referir à quantidade de movimento ou deformação que um tecido ou implante experimenta. Por exemplo, em uma articulação, uma maior amplitude de movimento pode levar a uma maior dissipação de energia pelo material cartilaginoso ou pelo líquido sinovial. Biomateriais projetados para substituir ou reparar esses tecidos precisam ser otimizados para lidar com amplitudes específicas.

A viscosidade é o segundo fator mais importante (30,1%) sendo um indicativo da resistência ao fluxo ou à deformação gradual sob tensão. Muitos tecidos biológicos (cartilagem, líquido sinovial e até mesmo o osso em escalas de tempo mais longas) são viscoelásticos, o que significa que suas propriedades mecânicas dependem da taxa de deformação. Uma maior viscosidade geralmente implica maior dissipação de energia durante a deformação cíclica (como ocorre durante a caminhada ou corrida), convertendo energia mecânica em calor. Isso é vital para a absorção de choque e proteção de estruturas adjacentes.


A frequência de aplicação da força é terceira variável mais relevante com 22%. Tecidos biológicos no aparelho locomotor são constantemente submetidos a carregamentos cíclicos em diversas frequências (por exemplo, a frequência de passos ao caminhar). A dependência

da energia dissipada em relação à frequência é uma característica chave dos materiais viscoelásticos. Materiais que dissipam energia de forma eficaz em frequências fisiológicas específicas são desejáveis para reduzir o acúmulo de estresse e fadiga nos tecidos e implantes. Os parâmetros tensores e compressores de Fung respondem com apenas 0,5% cada um, sugere que, para a energia dissipada neste conjunto de dados específico, a compressibilidade intrínseca do material (como ele se deforma volumetricamente sob pressão) tem um impacto mínimo. É provável que a deformação mais relevante para a dissipação de energia não seja a compressão pura, mas sim o cisalhamento ou outras formas de deformação elástica e viscosa.

O modelo destaca que a amplitude da deformação, a viscosidade e a frequência de carregamento são os principais responsáveis pela dissipação de energia no biomaterial estudado, enquanto os parâmetros específicos de Fung para compressibilidade e tensão/estiramento parecem ter uma influência desprezível neste modelo. Esta informação é valiosa para a otimização no desenvolvimento de biomateriais para o aparelho locomotor, focando nas propriedades que mais importam para o desempenho e a longevidade.

Os resultados do Gradient Boosting (GB) corroboraram os achados da Random Forest (RF) com importância das variáveis bastante similares às obtidas no RF, conforme ilustra a figura 2.

Figura 2 – Importância das variáveis pelo modelo Gradiente Boosting




Os resultados mostrados na figura 2, relativa ao GB, são sustentados por $R^2=0,99$; essa consistência entre os dois algoritmos aumenta a confiança sobre as variáveis mais influentes neste conjunto de dados. Considerando o contexto do R^2 em ambos os algoritmos, os valores de MAE e RMSE são bastante baixos, sugerindo que os modelos têm uma alta precisão nas suas previsões da energia dissipada. Assim, o RF apresenta elevada robustez em relação aos outliers que tendem a ficar isolados em uma árvore com pouco impacto

nos resultados gerais, complementarmente, o GB tende a ajustar os outliers a todo custo, o que pode degradar o modelo^(7,8).

Portanto, essas três principais variáveis devem ser priorizadas em pesquisas in vivo, especialmente em relação ao desenvolvimento de biomateriais que estejam associados à melhoria da saúde humana^(7,8).

A figura 3 mostra a matriz de correlação entre as três variáveis mais relevantes do modelo BWF.

Figura 3 – Matriz de correlação entres variáveis mais relevantes no modelo BWF.




As baixas correlações, positivas e negativas, atestam que amplitude, frequência e viscosidade são altamente independentes nesse modelo, ou seja, elas atuam no modelo com baixíssima redundância, atestando a eficiência topológica do mesmo.

Na figura 4 observa-se a dispersão entre amplitude (mm) e o log da energia dissipada, além da clara tendência do aumento da energia dissipada à medida que a amplitude aumenta.

É importante observar que, por exemplo, para a mesma amplitude de 1,0 mm o log da energia dissipada oscila entre $\sim 1,5\text{kPa}$ e $6,5\text{kPa}$, ou seja, a energia dissipada apresenta variabilidade de ~ 100 mil vezes, uma evidência da natureza não determinística da energia dissipada, já que ela depende de outras variáveis.


Figura 4 – Dispersão entre Amplitude e log da energia.



A figura 5 mostra os dois modelos preditivos da energia dissipada a partir do modelo *in silico* BWF, não existindo diferenças significativas entre ambos. Entretanto, destaca-se

que no GB a variável FungTração não contribui na dissipação de energia, enquanto que a variável Fung compressão tem um papel bastante reduzido quanto comparado com as outras três variáveis.

Figura 5 – Comparação entre as técnicas Random Forest e Gradient Boosting



CONSIDERAÇÕES FINAIS

A comparação entre duas técnicas preditivas (RF e GB) da energia dissipada em

sistemas histeréticos mostrou o rigor matemático do modelo BWF. Embora os limites de equivalência neste estudo tenham sido regidos por critérios de precisão numérica *in silico*, os

resultados estabelecem uma base metodológica para futuras investigações *in vivo*. Em estudos subsequentes, os limites de equivalência (SESOI) serão derivados de parâmetros constitutivos de tecidos biológicos, conforme descrito na teoria da viscoelasticidade de Fung (FUNG, 1993), permitindo traduzir a tolerância numérica do modelo em limiares de relevância biomecânica e de mecanotransdução celular.

REFERÊNCIAS

1. - Bouc R (1967) Forced vibrations of a mechanical system with hysteresis. In: Proc 4th conf on nonlinear oscillations, Prague, Czechoslovakia
- 2- Vilela Junior, G. de B., Passos, R. P., & Casagrande, R. M. (2026). Bouc-Wen-Fung Hysteretic Model for The determination of dissipated energy in biomaterials. Revista CPAQV - Centro De Pesquisas Avançadas em Qualidade De Vida , 18(3), 1.
- 3- Bouc R, Boussaa D (2002) Drifting response of hysteretic oscillators to stochastic excitation. Int J Non-linear Mech 37:1397–1406
- 4- Wen YK (1976) Method for random vibration of hysteretic systems. J Eng Mech Div 102(EM2):246–263
- 5- Erlicher, S., & Point, N. (2004). Thermodynamic admissibility of Bouc–Wen type hysteresis models. Comptes rendus mecanique, 332(1), 51-57.
- 6- Smith, P. F., Ganesh, S., & Liu, P. (2013). A comparison of random forest regression and multiple linear regression for prediction in neuroscience. Journal of neuroscience methods, 220(1), 85-91.
- 7- Win, P. P., Phyo, S. W., & Zaw, K. K. (2024, November). Comparative analysis of predicting hospitalization time for diabetes patients using gradient boosting and random forest algorithms. In 2024 5th International Conference on Advanced Information Technologies (ICAIT) (pp. 1-6). IEEE.
- 8- Zulu, G. (2026). Advancing Predictive Modeling in Behavioral Health: A Comparative Evaluation of Gradient-Boosted Bootstrap Model, Random Forest, and Logistic Regression Approaches to Treatment Completion.
- 9- Pian, T.H.H. and Sumihara, K. (1985). Rational approach for assumed stress finite elements. Int. J. Numer. Meth. Eng., 20:1685–1695.
- 10- Simon, B.R.J. et al. (1985). Poroelastic dynamic structural models of rhesus spinal motion segments. Spine, 10(6):494–507.
- 11- Basu, U. and Chopra, A.K. (2004). Perfectly matched layers for transient elastodynamics of unbounded domains. Int. J. Numer. Meth. Eng., 59:1039–1074.
- 12- Bathe, K. J. Finite Element Procedures. 2. ed. Watertown, MA: K.J. Bathe, 2014.
- 13- Zienkiewicz, O. C.; Taylor, R. L. (2005). The Finite Element Method: Its Basis and Fundamentals. 6. ed. Oxford: Butterworth-Heinemann, v. 1.

Observação:

- 1) Os/(as) autores/(as) declaram não existir conflitos de interesses de qualquer natureza.
- 2) Os autores declaram, se for o caso, estarem de acordo com as políticas de uso ético da Inteligência Artificial, reportando o mesmo nos agradecimentos ou nos métodos do artigo, em consonância com as normativas da WAME (World Association Medical Editors).



International Society of Human Movement Sciences - ISHMS

<https://www.ishms.net/>



Center of Advanced Researches in Quality of Life - CPAQV

<https://revista.cpaqv.org/index.php/CPAQV>

Nosso Instagram



<https://www.instagram.com/revistacpaqv>