

Impacto da Função de Treinamento na Precisão de Modelos Neurais de Baterias de Satélite em Simuladores Operacionais

Italo Pinto Rodrigues¹; 0000-0002-6832-8358
Bruno Lima dos Santos¹; 0009-0002-1808-2369
João Gabriel dos Santos Dias Moura Matos¹; 0009-0000-2270-6010
Gabriel Alberto Rodrigues¹; 0009-0008-6651-7156
Thalisson Wendel da Silva Nascimento¹; 0009-0007-1191-7032

1 – UniFOA, Centro Universitário de Volta Redonda, Volta Redonda, RJ.
italoprodriques@gmail.com (contato principal)

Resumo: A operação de satélites depende da disponibilidade de modelos confiáveis implementados em simuladores operacionais, capazes de reproduzir o comportamento do sistema em solo. Um desafio relevante consiste em incorporar o envelhecimento dos equipamentos nesses modelos, especialmente no caso da bateria, componente essencial para o fornecimento de energia durante eclipses. Este trabalho avalia a influência da função de treinamento na obtenção de redes neurais artificiais aplicadas à modelagem do envelhecimento da bateria do satélite CBERS-4. A arquitetura 6x9x2x1 foi mantida constante, sendo testadas três funções de treinamento: Levenberg-Marquardt, Regressão Bayesiana e Descida do Gradiente. O desempenho foi avaliado por meio do erro médio relativo quadrático (MRSE), calculado a partir de 56.081 amostras de telemetria real. Os resultados indicaram que Levenberg-Marquardt apresentou o menor erro (0,4919%), seguido pela Regressão Bayesiana (0,6058%), enquanto a Descida do Gradiente obteve desempenho inferior (1,4680%). Os achados confirmam que a escolha da função de treinamento influencia diretamente a acurácia do modelo, sendo determinante para sua aplicação em simuladores operacionais que exigem tanto fidelidade quanto execução em tempo real.

Palavras-chave: Satélites. Simuladores operacionais. Redes neurais artificiais. Envelhecimento de baterias. Funções de treinamento.

INTRODUÇÃO

Após o lançamento de um satélite, a manutenção em órbita é restrita ao envio de telecomandos, e a forma mais comum de validar tais comandos é por meio de Simuladores Operacionais de Satélites, também conhecidos como Simuladores de Treinamento, Operações e Manutenção (Hendricks; Eickhoff, 2005). Durante a fase operacional, a simulação desempenha papel central no suporte à missão, já que possibilita a reprodução em solo do comportamento do satélite com modelos de alta fidelidade, incluindo telemetria, telecomando e cargas úteis (Ambrosio *et al.*, 2006).

Um desafio crítico na concepção de simuladores reside na atualização de modelos que representem com precisão o envelhecimento dos equipamentos ao longo da vida útil do satélite. A escassez de literatura que detalhe implementações desse tipo evidencia o caráter sensível dessas informações no setor espacial (Tominaga, 2020). Ainda assim, o tema se torna cada vez mais relevante, pois missões de médio e grande porte frequentemente superam o tempo de operação inicialmente projetado, como no caso do satélite CBERS-4, que ultrapassou sua vida útil prevista de três anos e continua em operação eficiente após nove anos (Tominaga, 2020).

Nesse contexto, modelos estáticos tornam-se insuficientes, pois deixam de refletir as condições reais do satélite. Estudos prévios demonstram que a atualização dinâmica de modelos é possível, seja pela adaptação de equações matemáticas ou pelo uso de técnicas de inteligência computacional (Rodrigues *et al.*, 2021; Tipaldi *et al.*, 2020). Entretanto, a complexidade computacional dessas abordagens pode comprometer o requisito de execução em tempo real de um simulador operacional.

A bateria constitui um dos elementos mais críticos para o funcionamento contínuo do satélite, por garantir o suprimento energético em períodos de eclipse. Sua degradação impacta diretamente a confiabilidade da missão, sendo objeto de esforços de modelagem orientada a dados no âmbito do Simulador Operacional do Satélite CBERS (SimCBERS), desenvolvido no Instituto Nacional de Pesquisas Espaciais (INPE). Trabalhos anteriores mostraram que redes neurais artificiais (RNAs) otimizadas por algoritmos genéticos são capazes de representar a evolução da tensão da bateria com erro inferior a 1%, mantendo desempenho compatível com os requisitos de tempo real (Rodrigues *et al.*, 2021).

Diante disso, o presente estudo tem como objetivo demonstrar a influência da função de treinamento na obtenção de RNAs voltadas à modelagem do envelhecimento da bateria de satélite em simuladores operacionais. Para tanto, além da função de treinamento Levenberg-Marquardt, previamente empregada com sucesso, são avaliadas duas alternativas: Regressão Bayesiana e Descida do Gradiente. Os resultados obtidos permitem comparar o impacto de cada abordagem sobre o erro médio relativo quadrático (MRSE), contribuindo para a seleção de funções de treinamento mais adequadas às demandas de acurácia e tempo real em simuladores operacionais.

MÉTODOS

A pesquisa foi desenvolvida a partir de dados de telemetria real do satélite CBERS-4, utilizando o Simulador Operacional de Satélites (SimCBERS), concebido pelo Instituto Nacional de Pesquisas Espaciais (INPE). O estudo concentrou-se no subsistema de energia, em particular na bateria, componente crítico para a continuidade da missão, pois garante o fornecimento de energia durante os períodos de eclipse orbital.

A arquitetura da Rede Neural Artificial escolhida foi a 6x9x2x1, formada por quatro camadas: seis entradas, duas camadas ocultas contendo nove e dois neurônios, respectivamente, e uma saída. Essa configuração foi adotada por ter sido identificada como a de melhor desempenho em Rodrigues (2024), a partir de processo de otimização com Algoritmo Genético. A escolha dessa arquitetura assegura equilíbrio entre acurácia e complexidade computacional, condição essencial para a execução em tempo real em simuladores operacionais.

As variáveis de entrada foram definidas a partir da análise física do fenômeno de degradação da bateria e da avaliação de correlações numéricas, conforme descrito em Rodrigues (2024). Foram utilizadas seis variáveis: (i) a corrente da bateria (IBAT1), (ii) a corrente do barramento (IBUS), (iii) a corrente de entrada do regulador de descarga da bateria (IBDR1IN), (iv) a corrente de saída do regulador (IBDROUT), (v) a corrente do arranjo solar 1A (ISG1A) e (vi) a temperatura da bateria (TBAT1). A variável de saída correspondeu à tensão da bateria, parâmetro que expressa diretamente os efeitos do envelhecimento no desempenho energético do satélite.

No pré-processamento dos dados, todas as variáveis foram normalizadas para a faixa [0,1], de forma a garantir maior estabilidade durante o treinamento da rede neural. O conjunto de dados completo reuniu 4.319.678 amostras de cada variável. Desse total, foram selecionadas 56.081 amostras, divididas em três subconjuntos: o primeiro destinado ao treinamento, responsável pelo ajuste dos pesos sinápticos; o segundo utilizado na etapa de validação, empregado para monitorar a evolução do erro e evitar sobreajuste; e o terceiro reservado exclusivamente para teste, garantindo a avaliação final e imparcial do desempenho do modelo. O restante do banco de dados foi posteriormente utilizado na etapa de generalização, correspondente à validação em contexto operacional, permitindo verificar a robustez do modelo em cenários diferentes daqueles empregados no treinamento inicial.

Três funções de treinamento foram aplicadas para analisar seu impacto no desempenho da rede. A primeira foi o método Levenberg-Marquardt, usado como referência por ter apresentado o menor erro em trabalhos anteriores. A segunda foi a Regressão Bayesiana, que introduz mecanismos de regularização para reduzir sobreajuste e aumentar a capacidade de generalização do modelo. A terceira foi a Descida do Gradiente, técnica clássica e iterativa amplamente empregada em aprendizado de máquina, cuja simplicidade permite avaliar o comportamento do modelo em condições de treinamento menos sofisticadas.

O desempenho de cada rede neural foi avaliado por meio do erro médio relativo quadrático (MRSE), conforme Equação 1, métrica que quantifica os desvios entre os valores estimados pela rede e as telemetrias reais. Esse indicador foi adotado por sua adequação em estudos comparativos de modelagem de sistemas, permitindo mensurar a precisão do modelo de forma direta e objetiva. A análise comparativa do MRSE entre as funções de treinamento possibilitou avaliar não apenas a acurácia obtida em cada caso, mas também sua viabilidade para aplicações em simuladores operacionais, que exigem fidelidade dos resultados e execução em tempo real.

$$MRSE(\%) = \frac{1}{n_o} \sum_{0=1}^{n_o} \left[\sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (\hat{y}_i)^2}} \right] \quad (1)$$

RESULTADOS E DISCUSSÃO

A avaliação do desempenho das três arquiteturas de redes neurais artificiais permitiu identificar o impacto direto da topologia sobre a acurácia da modelagem do envelhecimento da bateria. Os resultados, apresentados na Tabela 1, mostram os valores da Média Relativa do Erro Quadrático (MRSE) para cada configuração. A arquitetura 6x9x2x1, apresentada na Figura 1a, previamente identificada por Rodrigues (2024) como a melhor solução por meio de algoritmo genético, apresentou MRSE de 0,4919%, confirmando seu bom equilíbrio entre acurácia e custo computacional. Já a arquitetura 6x1x1x1x1, considerada a mais simples, obteve MRSE de 0,5510%, um valor próximo ao da configuração de referência, mas com leve perda de precisão, como ilustrado na Figura 1b. Por outro lado, a arquitetura mais complexa, 6x10x10x10x1, alcançou MRSE de 0,6160%, demonstrando desempenho inferior às demais, conforme mostrado na Figura 1c.

Tabela 1 – Resumo dos resultados.

Entrada	Arquitetura		MRSE (%)
	Camadas ocultas	Saída	
6	1x1x1	Levenberg-Marquardt	0,4919
6	9x2	Regressão Bayesiana	0,6058
6	10x10x10	Descida do Gradiente	1,4680

Fonte: Elaborada pelos autores.

Os resultados mostram que a função Levenberg-Marquardt apresentou o menor erro (0,4919%), confirmando o bom desempenho já relatado em estudos anteriores. A Regressão Bayesiana alcançou resultado ligeiramente superior (0,6058%), mas ainda dentro de um intervalo aceitável para aplicações em simuladores operacionais. Já a Descida do Gradiente apresentou desempenho inferior, com erro de 1,4680%, valor que pode comprometer a fidelidade da simulação em tempo real.

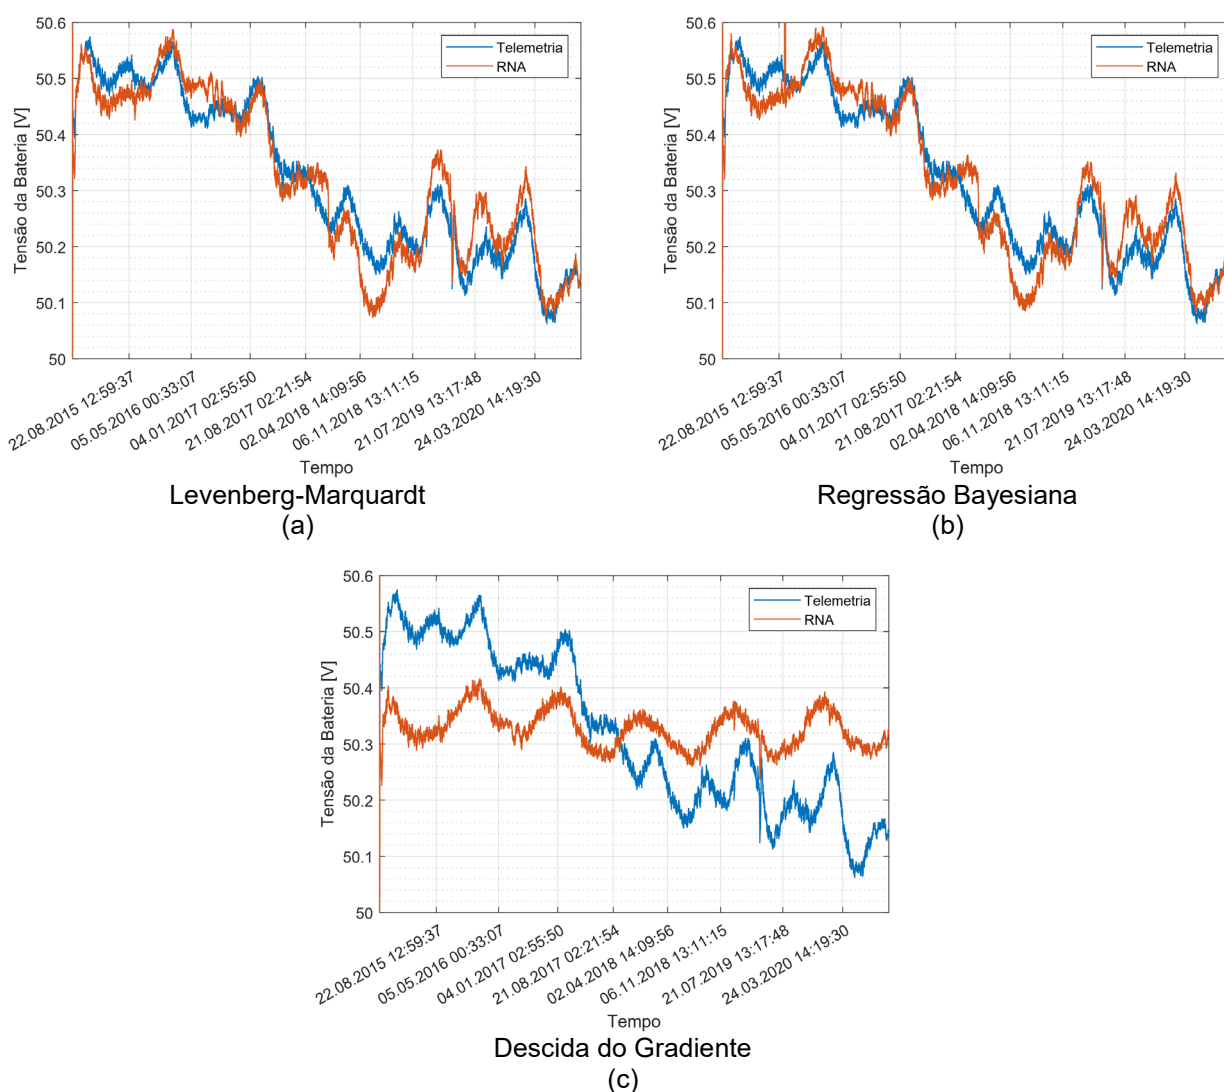
A Figura 1a ilustra a comparação direta dos erros obtidos para as três funções de treinamento, evidenciando a superioridade da função Levenberg-Marquardt em relação às demais.

Para além da comparação numérica, é relevante observar o comportamento temporal das estimativas geradas pelas redes em relação aos valores de telemetria real. A Figura 1b

apresenta a resposta obtida com a função Levenberg-Marquardt, na qual se verifica alta aderência entre os valores simulados e os observados.

A Figura 1c mostra a resposta correspondente ao treinamento com Descida do Gradiente. Nota-se maior divergência entre os valores simulados e os reais, especialmente em pontos de variação acentuada da tensão, o que justifica o valor mais elevado de MRSE.

Figura 1 – Resultado do treinamento.



Fonte: Elaborada pelos autores.

Esses resultados reforçam que a escolha da função de treinamento tem impacto direto na acurácia do modelo de envelhecimento da bateria. Enquanto Levenberg-Marquardt e Regressão Bayesiana produzem erros aceitáveis para o uso em simuladores operacionais,

a Descida do Gradiente apresenta limitações significativas. Ainda assim, o uso de diferentes funções permitiu evidenciar a robustez da arquitetura adotada, uma vez que todos os testes apresentaram erros inferiores a 2%, valor considerado adequado em aplicações de simulação de sistemas espaciais.

CONCLUSÕES

Este trabalho investigou a influência da função de treinamento na obtenção de redes neurais artificiais aplicadas à modelagem do envelhecimento da bateria do satélite CBERS-4, no contexto de simuladores operacionais de satélite. Mantida a mesma arquitetura da rede (6x9x2x1), foram avaliadas três funções de treinamento: Levenberg-Marquardt, Regressão Bayesiana e Descida do Gradiente.

Os resultados demonstraram que a função Levenberg-Marquardt apresentou o melhor desempenho, com MRSE de 0,4919%, seguida pela Regressão Bayesiana, com 0,6058%. Já a Descida do Gradiente apresentou desempenho inferior, alcançando MRSE de 1,4680%. Esses valores confirmam que a escolha da função de treinamento exerce impacto direto na acurácia do modelo, mesmo quando a arquitetura permanece inalterada.

Os achados reforçam a viabilidade do uso de redes neurais artificiais em simuladores operacionais de satélite, desde que sejam aplicadas funções de treinamento adequadas às restrições de fidelidade e tempo real. Além disso, evidenciam que técnicas de maior complexidade, como Levenberg-Marquardt e Regressão Bayesiana, oferecem maior confiabilidade para representar o envelhecimento da bateria, enquanto métodos mais simples, como a Descida do Gradiente, podem não atender aos requisitos necessários para aplicações em operação espacial.

A análise realizada contribui para o avanço da modelagem orientada a dados no contexto de simuladores operacionais, oferecendo subsídios para a seleção criteriosa de funções de treinamento em futuras implementações.

AGRADECIMENTOS

Os autores agradecem ao Centro Universitário de Volta Redonda (UniFOA) pelo apoio institucional e financeiro, por meio do Programa Institucional de Bolsas de Iniciação Científica (PIBIC) (92782/17/RPE, 92845/17/RPE, 94041/17/RPE) e Programa Institucional de Bolsas de Iniciação Científica – PIBIC/CNPq (Resolução Normativa RN-017/2006 do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq)).

REFERÊNCIAS

- AMBROSIO, Ana Maria; CARDOSO, Paulo Eduardo; ORLANDO, Valcir; NETO, José Bianchi. Brazilian Satellite Simulators: Previous Solutions Trade-off and New Perspectives for the CBERs Program. *In: 8TH CONFERENCE ON SPACE OPERATIONS, 2006. Proceedings of the 8th Conference on Space Operations [...].* Rome, Italy: AIAA, 2006. . Acesso em: 14 set. 2025.
- HASANPOUR, Seyyed Hossein; ROUHANI, Mohammad; FAYYAZ, Mohsen; SABOKROU, Mohammad. Lets keep it simple, Using simple architectures to outperform deeper and more complex architectures. [s. l.], 2016. DOI 10.48550/ARXIV.1608.06037. Disponível em: <https://arxiv.org/abs/1608.06037>. Acesso em: 14 set. 2025.
- HENDRICKS, Reinhard; EICKHOFF, Jens. The significant role of simulation in satellite development and verification. **Aerospace Science and Technology**, [s. l.], v. 9, n. 3, p. 273–283, abr. 2005. <https://doi.org/10.1016/j.ast.2004.12.006>.
- RODRIGUES, Italo Pinto. **Análise exploratória para modelagem do envelhecimento de baterias em um simulador operacional de satélites**. 2024. 152 f. Tese (Doutorado em Engenharia e Tecnologia Espaciais) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2024. Disponível em: <http://urlib.net/ibi/8JMKD3MGP3W34T/4BJDL3P?ibiurl.backgroundlanguage=pt-BR>.
- RODRIGUES, Italo Pinto; OLIVEIRA, Priscylla A.S.; AMBROSIO, Ana Maria; CHAGAS, Ronan A.J. Modeling satellite battery aging for an operational satellite simulator. **Advances in Space Research**, [s. l.], v. 67, n. 6, p. 1981–1999, mar. 2021. <https://doi.org/10.1016/j.asr.2020.12.031>.
- SHAH, Harshay; TAMULY, Kaustav; RAGHUNATHAN, Aditi; JAIN, Prateek; NETRAPALLI, Praneeth. The Pitfalls of Simplicity Bias in Neural Networks. [s. l.], 2020. DOI 10.48550/ARXIV.2006.07710. Disponível em: <https://arxiv.org/abs/2006.07710>. Acesso em: 14 set. 2025.
- TIPALDI, Massimo; FERUGLIO, Lorenzo; DENIS, Pierre; D'ANGELO, Gianni. On applying AI-driven flight data analysis for operational spacecraft model-based diagnostics. **Annual Reviews in Control**, [s. l.], v. 49, p. 197–211, 2020. <https://doi.org/10.1016/j.arcontrol.2020.04.012>.
- TOMINAGA, Jun. **Simulação de satélites com base em adaptação autônoma de modelos comportamentais**. 2020. 153 f. Tese (Doutorado em Engenharia e Tecnologia Espaciais) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2020. Disponível em: <http://urlib.net/ibi/8JMKD3MGP3W34R/42SQ8J8>.