

## **Avaliação de Funções Objetivo na Busca por Arquiteturas Eficientes de Redes Neurais para Simuladores Operacionais de Satélite**

Italo Pinto Rodrigues<sup>1</sup>; 0000-0002-6832-8358  
João Gabriel dos Santos Dias Moura Matos<sup>1</sup>; 0009-0000-2270-6010  
Gabriel Alberto Rodrigues<sup>1</sup>; 0009-0008-6651-7156  
Thalisson Wendel da Silva Nascimento<sup>1</sup>; 0009-0007-1191-7032  
Bruno Lima dos Santos<sup>1</sup>; 0009-0002-1808-2369  
Rafael Sergio Gonçalves<sup>1</sup>; 0009-0009-4477-1361

1 – UniFOA, Centro Universitário de Volta Redonda, Volta Redonda, RJ.  
[italoprodrigues@gmail.com](mailto:italoprodrigues@gmail.com) (contato principal)

**Resumo:** A operação de satélites depende fortemente de simuladores operacionais para validar telecomandos e reproduzir em solo o comportamento do veículo espacial. Um desafio central consiste em garantir que tais simuladores reflitam com fidelidade o envelhecimento dos equipamentos, assegurando a confiabilidade durante toda a missão. Este trabalho investigou a influência da função objetivo na definição de arquiteturas de redes neurais artificiais aplicadas ao SimCBERS, simulador do satélite CBERS-4. Foram avaliadas duas formulações: as Equações 1 e 2, baseadas no erro de treinamento e de generalização, e a Equação 3, que substitui o segundo termo pelo RMSE. Os resultados mostraram que a primeira conduziu à arquitetura 6x9x2x1 com erro de generalização ( $E_{RMSE}$ ) de 0,4867%, enquanto a segunda selecionou a arquitetura 6x6x4x1, com  $E_{RMSE}$  de 0,5005%. Apesar da diferença marginal nos erros, observou-se que a função objetivo influencia a complexidade da arquitetura final. A segunda abordagem favoreceu redes mais compactas, alinhadas às restrições de execução em tempo real. Esses achados corroboram evidências da literatura sobre o potencial de arquiteturas simples, ao mesmo tempo em que destacam a necessidade de cautela diante do viés de simplicidade que pode comprometer a robustez. Conclui-se que a formulação da função objetivo exerce papel decisivo no equilíbrio entre acurácia e custo computacional, contribuindo para o desenvolvimento de modelos adaptativos aplicáveis à fase operacional de satélites.

**Palavras-chave:** Redes neurais artificiais. Algoritmos genéticos. Simuladores operacionais de satélites. Função objetivo. Modelagem orientada a dados.

## INTRODUÇÃO

A operação de satélites após o lançamento impõe restrições severas de manutenção, uma vez que ajustes físicos são inviáveis. Nessas condições, a validação de telecomandos depende, em grande medida, do uso de simuladores operacionais, ferramentas que permitem reproduzir o comportamento do veículo em solo e antecipar os efeitos de comandos enviados ao voo (Hendricks; Eickhoff, 2005). Por essa razão, esses sistemas se tornaram indispensáveis ao suporte de missões espaciais, sobretudo em fases críticas ou prolongadas de operação (Ambrosio *et al.*, 2006).

Apesar de sua relevância, ainda é limitado o acesso a descrições técnicas sobre o desenvolvimento e a adaptação de simuladores, principalmente devido ao caráter estratégico dessas informações (Tominaga, 2020). Um desafio recorrente decorre da necessidade de alinhar os modelos matemáticos implementados às mudanças reais que os equipamentos sofrem ao longo do tempo, já que o envelhecimento natural dos componentes pode gerar divergências entre telemetrias observadas e valores simulados. A falta de mecanismos de adaptação automática compromete, assim, a fidedignidade da simulação e, por consequência, a segurança da operação (Tominaga, 2020).

Nos últimos anos, diferentes abordagens de modelagem orientada a dados foram exploradas para reduzir tais discrepâncias. Técnicas de identificação clássica (Goodwin; Payne, 1977) e redes neurais artificiais (Rodrigues *et al.*, 2021) têm sido aplicadas em cenários diversos da engenharia de satélites, com resultados que reforçam o potencial de métodos baseados em inteligência computacional. Pesquisas recentes ampliam essa tendência ao empregar algoritmos de otimização e heurísticas capazes de atualizar automaticamente equações ou parâmetros de modelos em tempo real (Rodrigues *et al.*, 2021; Tipaldi *et al.*, 2020).

O SimCBERS, simulador operacional do satélite CBERS-4, constitui um caso representativo, em que a modelagem da bateria apresenta elevada complexidade e relevância para a missão (Magalhaes; Pinheiro, 2017). Trabalhos aplicando redes neurais nesse contexto mostraram bons níveis de precisão (Rodrigues *et al.*, 2021; Song *et al.*, 2018), mas ainda persistem limitações relacionadas ao custo computacional, especialmente em aplicações que exigem execução em tempo real.

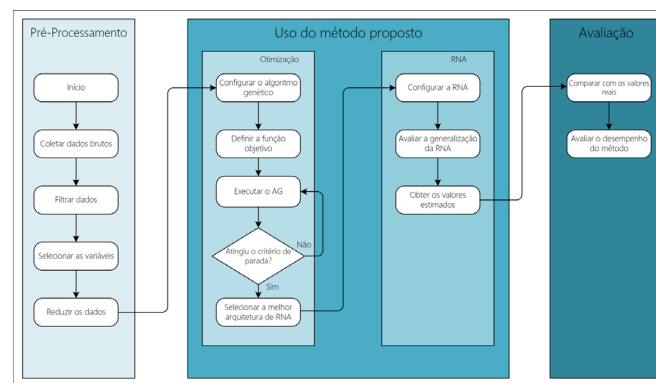
Neste estudo, investiga-se o impacto da função objetivo no processo de otimização de redes neurais artificiais voltadas à simulação do envelhecimento da bateria de satélite. A

comparação entre métricas de erro distintas — MSE e RMSE — busca evidenciar como essa escolha influencia a definição de topologias mais compactas, capazes de manter baixo erro relativo sem comprometer a execução em simuladores operacionais. O trabalho, portanto, propõe-se a contribuir para a evolução de modelos adaptativos, voltados à confiabilidade da simulação durante toda a vida útil da missão espacial.

## MÉTODOS

A metodologia adotada neste trabalho foi estruturada em três etapas principais: pré-processamento dos dados, otimização de topologias de redes neurais artificiais (RNAs) por meio de algoritmo genético (AG) e avaliação das redes obtidas, conforme Figura 1.

Figura 1 – Metodologia utilizada para obtenção das topologias.



Fonte: Elaborada pelos autores.

Na etapa de pré-processamento, os dados de telemetria foram coletados, filtrados para remoção de inconsistências e reduzidos a partir da seleção de variáveis relevantes ao problema. Todas as variáveis foram normalizadas para a faixa  $[0, 1]$ , de modo a garantir maior estabilidade durante o treinamento. O conjunto de dados completo foi composto por 4.319.678 amostras por variável. Deste total, 56.081 amostras foram separadas em três subconjuntos: treinamento, utilizado para o ajuste dos pesos sinápticos; validação, destinado ao monitoramento do erro e à prevenção de sobreajuste; e teste, reservado para a aferição final do desempenho. As amostras remanescentes foram utilizadas posteriormente na etapa de generalização, também denominada validação em contexto operacional.



A busca pela melhor topologia de RNA foi realizada com o auxílio de um AG configurado com operadores de seleção, cruzamento e mutação, executado até o atendimento de um critério de parada estabelecido pelo número máximo de gerações ou pela estagnação do valor da função objetivo. Duas formulações distintas foram utilizadas para a função objetivo. A primeira, expressa nas Equações 1 e 2, combina os erros de treinamento e de generalização.

$$f_1 = \text{penalidade} \left( \frac{\rho_1 * E_{\text{treinamento}} + \rho_2 * E_{\text{generalizacao}}}{\rho_1 + \rho_2} \right) \quad (1)$$

$$E_{\text{treinamento,generalizacao}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (2)$$

Em uma segunda abordagem, buscou-se aprimorar o balanceamento entre simplicidade e precisão substituindo o erro de generalização pelo RMSE, resultando na Equação 3.

$$f_2 = \text{penalidade} \left( \frac{\rho_1 * E_{\text{treinamento}} + \rho_2 * E_{\text{RMSE}}}{\rho_1 + \rho_2} \right) \quad (3)$$

Onde,  $\rho_1$  e  $\rho_2$  ( $\rho_1, \rho_2 > 0$ ;  $\rho_1, \rho_2 \in \Re$ ) são parâmetros utilizados para ponderar a importância dos erros,  $E_{\text{treinamento}}$  representa o erro de treinamento e  $E_{\text{generalizacao}}$  o erro de generalização. Em que:

$$E_{\text{RMSE}} = \frac{1}{n_o} \sum_{o=1}^{n_o} \left[ \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (\hat{y}_i)^2}} \right] \quad (4)$$

Onde  $y_i$  representa a saída medida (telemetria de VBAT1);  $\hat{y}_i$  a saída simulada;  $n_o$  o número total de saídas, e  $N$  a quantidade de dados (amostras) utilizada para medir o desempenho do modelo.

Para evitar que topologias excessivamente complexas fossem favorecidas, a função objetivo incorporou um fator de penalidade definido por:

$$\text{penalidade} = (e^{5*10^{-8}*nw^2}) + (5 * 10^{-5} * \text{epocas} + 1) \quad (5)$$

Em que  $nw$  representa o número de pesos sinápticos da RNA e  $\text{epocas}$  o número de ciclos de treinamento. O termo exponencial impõe crescimento acelerado da penalidade com o aumento da complexidade da topologia, enquanto o termo linear adiciona custo proporcional

ao esforço computacional do treinamento. Assim, a penalidade atuou como regulador, equilibrando desempenho e viabilidade em tempo real.

As topologias selecionadas pelo AG foram configuradas e treinadas com o subconjunto de 56.081 amostras, sendo então avaliadas quanto ao erro de teste. Posteriormente, foram utilizadas as 4.263.597 amostras restantes para verificar a capacidade de generalização. É importante ressaltar que, nessa etapa, o erro foi sempre medido pelo  $E_{RMSE}$ , independentemente da função objetivo usada na otimização, assegurando comparabilidade entre os diferentes experimentos.

## RESULTADOS E DISCUSSÃO

A aplicação do algoritmo genético permitiu identificar topologias de redes neurais artificiais otimizadas segundo diferentes formulações da função objetivo. Utilizando as Equações 1 e 2, que combinam os erros de treinamento e generalização, a melhor configuração obtida foi a rede com topologia 6x9x2x1, Figura 2a, resultando em um erro de generalização medido por  $E_{RMSE}$  de 0,4867%. Quando a busca foi conduzida com as Equações 1 e 3, na qual o erro de generalização foi substituído pelo RMSE, a topologia selecionada foi 6x6x4x1, alcançando  $E_{RMSE}$  de 0,5005%, conforme Figura 2b.

A diferença observada entre as duas formulações é pequena, mas revela um aspecto relevante: a escolha da função objetivo influencia não apenas o valor final do erro, mas também a complexidade estrutural da rede selecionada. Enquanto a primeira abordagem privilegiou uma topologia com maior profundidade em relação ao número de camadas intermediárias, a segunda conduziu a uma solução mais compacta. Esse resultado é coerente com evidências da literatura que indicam que topologias simples podem atingir desempenho equivalente — ou mesmo superior — a modelos mais complexos, desde que sejam projetadas de forma criteriosa (Hasanpour *et al.*, 2016).

No entanto, a adoção de topologias mais simples precisa ser analisada com cautela. Estudos recentes apontam que redes neurais apresentam viés de simplicidade, ou seja, tendem a explorar padrões mais fáceis de serem aprendidos, o que pode comprometer a robustez do modelo em cenários com variações de distribuição ou degradação mais acentuada dos dados (Shah *et al.*, 2020). Nesse sentido, embora a topologia 6x6x4x1 apresente erro

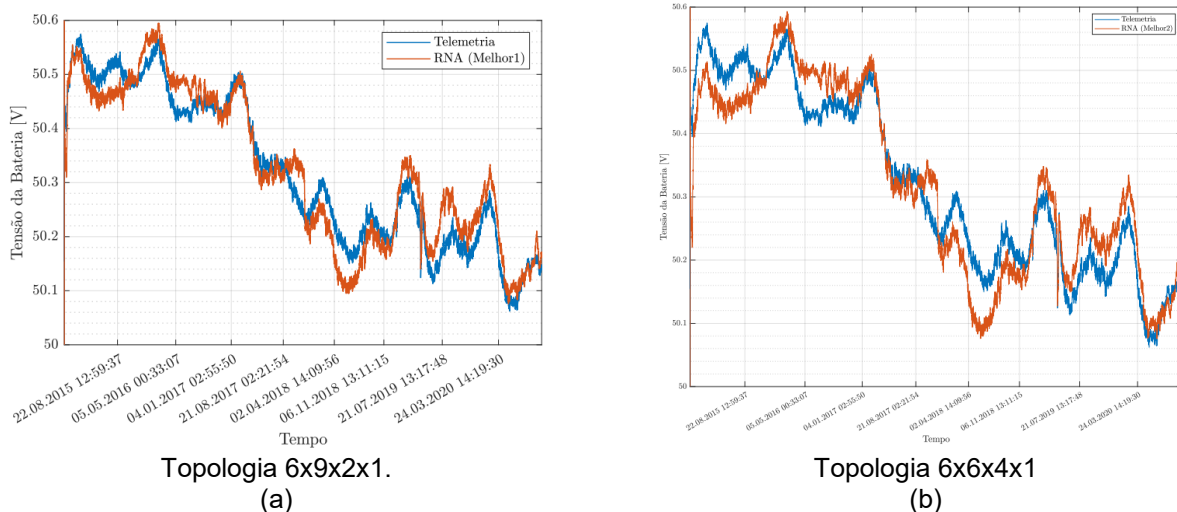
levemente superior à  $6 \times 9 \times 2 \times 1$ , seu menor número de parâmetros favorece a execução em tempo real no simulador operacional, o que representa vantagem prática no contexto de sistemas embarcados.

Tabela 1 – Resumo dos resultados.

Topologia			MRSE (%)
Entrada	Camadas ocultas	Saída	
6	9x2	1	0,4867
6	6x4	1	0,5005

Fonte: Elaborada pelos autores.

Figura 2 – Comparação entre as topologias.



Fonte: Adaptada de Rodrigues (2024).

A comparação entre os dois critérios de otimização mostra, portanto, uma tensão inerente ao problema: de um lado, a busca por menor erro absoluto; de outro, a necessidade de reduzir a complexidade para viabilizar o uso no SimCBERS. O equilíbrio entre essas dimensões é central para o desenvolvimento de modelos capazes de acompanhar o envelhecimento do satélite sem comprometer o desempenho computacional. Assim, os resultados obtidos reforçam a pertinência de estratégias de otimização que não apenas minimizem métricas de erro, mas também incorporem fatores de custo computacional, alinhando-se às restrições operacionais do ambiente espacial.

## CONCLUSÕES

O presente trabalho teve como objetivo avaliar a influência da função objetivo no processo de otimização de topologias de redes neurais artificiais aplicadas ao simulador operacional de satélites. A análise comparativa entre as Equações 1 e 2 e as Equações 1 e 3 demonstrou que, embora ambas tenham conduzido a erros de generalização muito próximos — 0,4867% para a topologia 6x9x2x1 e 0,5005% para a topologia 6x6x4x1 —, a escolha da métrica impacta diretamente a complexidade da rede resultante.

O estudo evidenciou que a segunda formulação, ao privilegiar uma topologia mais compacta, reforça a viabilidade de execução em tempo real, aspecto essencial em simuladores como o SimCBERS. Essa constatação converge com resultados recentes da literatura que destacam o potencial de topologias simples para manter desempenho competitivo frente a modelos mais profundos e complexos, ao mesmo tempo em que alerta para o risco de viés de simplicidade, que pode limitar a robustez em cenários de degradação mais acentuada.

Dessa forma, os resultados obtidos contribuem para o avanço das estratégias de modelagem orientada a dados voltadas ao acompanhamento do envelhecimento de satélites. A incorporação de penalidades na função objetivo mostrou-se eficaz para equilibrar acurácia e custo computacional, oferecendo um caminho promissor para aplicações que exigem confiabilidade e desempenho em tempo real.

Como perspectivas futuras, destaca-se a possibilidade de ampliar a análise para outros subsistemas além da bateria, bem como explorar funções objetivo que combinem métricas de erro com indicadores explícitos de custo computacional, aprofundando o compromisso entre precisão e eficiência.

## 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.
- GOODWIN, Graham C.; PAYNE, Robert L. **Dynamic system identification: experiment design and data analysis**. New York: Academic Press, 1977(Mathematics in science and engineering, v 136).
- 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>.
- MAGALHAES, Renato Oliveira de; PINHEIRO, Diego da Silva. CBERS04A power supply simulation and power budget analysis. *In: 2017 BRAZILIAN POWER ELECTRONICS CONFERENCE (COBEP)*, nov. 2017. **2017 Brazilian Power Electronics Conference (COBEP)** [...]. Juiz de Fora: IEEE, nov. 2017. p. 1–7. DOI 10.1109/COBEP.2017.8257310. Disponível em: <http://ieeexplore.ieee.org/document/8257310/>. Acesso em: 14 set. 2025.
- 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.
- SONG, Yuchen; LIU, Datong; HOU, Yandong; YU, Jinxiang; PENG, Yu. Satellite lithium-ion battery remaining useful life estimation with an iterative updated RVM fused with the KF algorithm. **Chinese Journal of Aeronautics**, [s. l.], v. 31, n. 1, p. 31–40, jan. 2018. <https://doi.org/10.1016/j.cja.2017.11.010>.
- 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>.