

Aplicação de redes neurais artificiais na estimação do empuxo gerado por um conjunto propulsor de drone

Miguel Barcelos de Souza^{[1]*}, Adelson Siqueira Carvalho^[2]

^[1] miguel.barcelos@gsuite.iff.edu.br. Instituto Federal Fluminense (IFF), Campos dos Goytacazes, Rio de Janeiro, Brasil. ORCID: <https://orcid.org/0009-0005-0163-4309>

^[2] adelson.siqueira@gsuite.iff.edu.br. Instituto Federal Fluminense (IFF), Campos dos Goytacazes, Rio de Janeiro, Brasil. ORCID: <https://orcid.org/0000-0003-0641-1903>

* autor correspondente

Resumo

A inteligência artificial e o aprendizado de máquina têm tomado cada vez mais espaço em inúmeras áreas, principalmente para estimação de parâmetros concretos e confiáveis. A modelagem de sistemas dinâmicos é parte fundamental de um projeto de controle, e o resultado de um bom controlador está diretamente ligado à qualidade da modelagem do sistema. Para isso, o uso de ferramentas matemáticas é crucial; contudo, a complexidade dos sistemas não lineares dificulta a fidelidade do modelo. Assim, modelos gerados com Redes Neurais Artificiais (RNA) e algoritmos de aprendizado profundo têm sido utilizados como soluções para melhorar essa etapa de projeto. Veículos Aéreos Não Tripulados (VANTs) têm se tornado elementos indispensáveis na agricultura; o aumento do uso desses equipamentos, principalmente no setor logístico, com possibilidades de atuarem como meios de transporte, traz consigo o desafio de relacionar sistemas de propulsão adequados para transporte e a carga possível que os sistemas de propulsão dos veículos aéreos conseguem transportar. Essa relação impacta diretamente a evolução dessa tecnologia nos implementos. Nesse contexto, a estimativa do empuxo gerado pelos conjuntos propulsores é um foco de interesse de estudo para a evolução do uso de drones em aplicações que necessitam de mais carga. Assim, este artigo propõe um modelo de RNA do tipo *feed-forward backpropagation* para estimar o empuxo de um conjunto motor-hélice, utilizando dados experimentais para analisar o desempenho do modelo e o nível de acurácia. Após treinamento, a rede criada alcançou um Erro Percentual Absoluto Médio (MAPE) de 3,94% comparado ao observado no sistema, e um Erro Médio Absoluto (MAE) de 2,18 gramas. Esses resultados mostram como o uso de redes neurais como ferramenta tem potencial de aplicação na modelagem de sistemas complexos, não lineares, em comparação à modelagem clássica, que apresenta uma matemática complexa e limitada de ser utilizada.

Palavras-chave: drones; empuxo; modelagem; motor *brushless*; rede neural artificial (RNA).

Application of artificial neural networks in estimating the thrust generated by a drone propulsion system

Abstract

Artificial intelligence and machine learning have increasingly expanded into numerous fields, particularly for estimating reliable physical parameters. Dynamic systems modeling is a fundamental component of control design, as controller performance is directly linked to model fidelity. Although mathematical tools are crucial, the inherent complexity of non-linear systems presents significant challenges to traditional modeling. Consequently, models based on Artificial Neural Networks (ANNs) and deep learning algorithms have emerged as effective solutions to improve this design stage. Unmanned Aerial Vehicles (UAVs) have become indispensable in agriculture. However, their growing adoption, especially in logistics and cargo transport, introduces the challenge of relating propulsion systems of brushless motors and propeller propulsion systems to the vehicle's payload requirements. This relationship directly influences the technological evolution of these platforms. This relationship directly affects the technological evolution of these platforms. In this context, estimating the thrust generated by propulsion systems is a focus of study for the evolution of drones use in applications that require a higher payload. Therefore, paper proposes a feed-forward backpropagation ANN model to

estimate the thrust of a motor-propeller assembly, utilizing experimental data to evaluate model performance and accuracy. After training, the created network achieved a Mean Absolute Percentage Error (MAPE) of 3.94% and a Mean Absolute Error (MAE) of 2.18 grams. These results demonstrate the potential of this approach for modeling complex, non-linear systems, offering a robust alternative to classical analytical modeling, which is often mathematically complex and constrained.

Keywords: artificial neural network (ANN); brushless motor; drones; modeling; thrust.

1 Introdução

A adoção de Veículos Aéreos Não Tripulados (VANTs) vem apresentando crescimento expressivo em aplicações industriais, na agricultura e na logística. A necessidade de modelos confiáveis de empuxo para a seleção de componentes, simulação e síntese de controle torna-se fundamental para uma aplicação eficiente e confiável dessa tecnologia. Em particular, o desempenho do conjunto motor-hélice de um drone impacta diretamente a capacidade de carga, autonomia energética e estabilidade dinâmica da aeronave. Em sistemas elétricos de propulsão, a relação não linear entre a velocidade de rotação do motor e o empuxo gerado reduz a precisão de modelos lineares convencionais. O conhecimento do torque de um motor é fundamental para seu uso eficiente, pois representa a força rotacional necessária para um motor girar seu eixo. Assim, uma modelagem precisa do empuxo gerado torna-se elemento central tanto para o dimensionamento do sistema quanto para o desenvolvimento de estratégias avançadas de controle.

Tradicionalmente, aplicações que necessitam de sistemas de controle requerem a modelagem do sistema dinâmico. Na obtenção do modelo matemático deve-se conciliar a simplicidade do modelo e a precisão dos resultados analíticos, para isso, torna-se, frequentemente, necessário ignorar certas propriedades físicas inerentes ao sistema. Em particular, quando se deseja um modelo matemático linear de parâmetros concentrados, é necessário ignorar determinadas não linearidades e parâmetros concentrados: omitem-se determinadas não linearidades e parâmetros distribuídos que podem estar presentes no sistema físico (Ogata, 2005). Embora modelos matemáticos clássicos sejam amplamente utilizados, trabalhos recentes, como o de Jiang, Pourpanah e Hao (2020), demonstram que controladores puramente lineares falham ao lidar com distúrbios de alta frequência e variações bruscas de carga. Adicionalmente, as interações aerodinâmicas não lineares em sistemas propulsores de drones impõem desafios que superam a capacidade da modelagem clássica (Okulski; Ławryńczuk, 2021), tornando as redes neurais artificiais uma alternativa superior para capturar tais dinâmicas.

As técnicas de modelagem de um sistema dinâmico podem ser classificadas em três conceitos fundamentais: o modelo caixa branca, o modelo caixa-preta e o modelo caixa-cinza (Garcia, 2005). O modelo caixa-branca busca aplicar rigorosamente todas as leis físicas que descrevem o sistema, por vezes necessitando uma simplificação, que dificilmente englobam de maneira fidedigna todas as variáveis relacionadas. O modelo caixa preta, não se tem conhecimento a respeito das leis físicas do sistema, utilizando dados de entrada e saída o modelo busca relacionar as variáveis de forma não transparente. Por fim, o modelo caixa cinza busca unir os dois primeiros modelos, utilizando informações físicas auxiliares associadas ao ajuste de parâmetros baseado em dados experimentais.

Embora estudos recentes mostrem que abordagens baseadas em redes neurais, com o objetivo de estimar o empuxo de VANTs, possuem um resultado com precisão estatística elevada ($R^2 > 0,99$), a maior parte dessas abordagens focam em parâmetros estáticos de design, como o diâmetro e o passo da hélice (Goli *et al.*, 2025). Desse modo, constata-se uma lacuna crítica na literatura sobre modelos que incorporem o histórico de operação para mitigar fenômenos elétricos e térmicos de histerese no motor e no ESC. Esses fenômenos, frequentemente ignorados em modelos simplificados, alteram drasticamente o desempenho do motor ao longo do tempo de uso devido ao aquecimento progressivo das bobinas do estator.

Este artigo contribui com o desenvolvimento de um estimador baseado em RNA do tipo *feed-forward backpropagation* que utiliza o tempo decorrido e a corrente elétrica como variáveis fundamentais para capturar a resposta dinâmica e não linear do conjunto propulsor. Diferente das abordagens focadas apenas em parâmetros geométricos, esse modelo permite a predição do empuxo real com um erro médio percentual de 3,94%, dispensando sensores adicionais, facilitando sua

implementação direta em controladores embarcados através de formulações analíticas extraídas da rede.

O restante deste trabalho está organizado da seguinte maneira: na seção 2 será apresentada a fundamentação teórica, abordando a estrutura de um motor *brushless*, hélices e redes neurais. A seção 3 descreve os trabalhos relacionados e o estado da arte. A seção 4 detalha a metodologia utilizada para o treinamento da RNA e a infraestrutura necessária para criação do conjunto de dados. Na seção 5, são apresentados os resultados do experimento, avaliando o desempenho do modelo desenvolvido. Por fim, na seção 6, são apresentadas as conclusões e as observações dos resultados obtidos.


2 Referencial teórico

Nesta seção, serão apresentadas as tecnologias utilizadas na realização do projeto. Serão conceituados os dispositivos estudados e empregados na elaboração deste trabalho, abordando seus funcionamentos e suas características técnicas mais importantes, esse detalhamento será essencial para contextualizar o desenvolvimento do experimento e na análise dos resultados esperados.

2.1 Motores *brushless*

Os motores *brushless* surgiram a partir da evolução dos motores de corrente contínua (CC), sendo a principal mudança a eliminação das escovas, resultando em um motor *brushless*. Os motores BLDC (sigla em inglês para *Brushless Direct Current*) possuem uma construção baseada em um estator com enrolamentos concentrados. O rotor, por sua vez, teve o enrolamento de campo das máquinas síncronas substituído por ímãs, o que reduziu o volume e aumentou sua eficiência (Fernandes, 2006). Na Figura 1 é possível observar um modelo do motor BLDC.

Figura 1 – Partes de um motor *brushless*



Fonte: Analog Circuit Design (2024).

Diferente dos motores CC convencionais, que operam com a alimentação direta, os motores *brushless* necessitam de um dispositivo eletrônico para seu funcionamento, um ESC (sigla em inglês para *Electronic Speed Controller*). Ele realiza o chaveamento entre as fases do motor por meio de dispositivos semicondutores, como MOSFETs, modificando a frequência de energização das bobinas e, consequentemente, a velocidade do motor (Krishnan, 2001). O chaveamento ocorre por meio de curvas trapezoidais, que energizam fases do estator atraindo ou repelindo os ímãs. Essa estratégia de controle é chamada de *six-step*, na qual seis combinações de chaveamento completam um giro.

O uso de motores sem escova ganhou grande destaque no mercado, devido a sua alta eficiência, torque elevado e maior vida útil, proporcionada pela baixa necessidade de manutenção. Isso é evidenciado pela projeção de que, até 2030, tais motores se tornarão a principal tecnologia de transmissão de potência nas indústrias, substituindo gradualmente os motores de indução tradicionais, como sugerem Mohanraj *et al.* (2022) – esses autores informam ainda que o mercado global desses motores deve atingir um valor de 15,2 bilhões de dólares até 2025. Motores com configuração *brushless* estão sendo utilizados por apresentarem melhores resultados de funcionamento, possibilitando aplicações com maior eficiência e versatilidade, em comparação a motores de outras configurações, como motores escovados. O uso em drones, em conjunto com a hélice, torna-se ideal como atuador de propulsão, devido a sua máxima eficiência energética, alto torque e alta velocidade.

2.2 Hélices

A hélice de um drone é composta por um conjunto de pás unidas, essas em formato de asa, semelhante às de aviões. Durante o movimento de rotação, obedece-se ao princípio de Bernoulli e à terceira lei de Newton; assim, com o movimento de rotação da hélice, cria-se uma diferença de pressão entre ambas as superfícies das pás, o que gera o empuxo (Eugenio; Zago, 2019). Numa asa de avião, a sustentação é realizada graças ao formato de aerofólio que é maximizado, parte superior, extradorso a pá possui uma curvatura, enquanto na parte inferior, intradorso é mais plano. A curvatura, combinada ao ângulo de ataque, acelera o fluxo de ar e gera a diferença de pressão responsável pela sustentação.

Assim, a diferença de pressão devido ao fluxo de ar possibilita criar a sustentação (Silva *et al.*, 2020). Nos drones, a premissa se mantém; contudo, a mudança é que não mais o ar acelerado passa pelas pás, mas as pás é que são aceleradas, passando pelo ar. Dessa maneira, o conjunto de pás que formam as hélices podem criar a sustentação necessária para o conjunto do drone levantar voo.

O teorema do empuxo em um conjunto propulsor baseia-se na variação da quantidade de movimento do fluido e na terceira lei de Newton. A rotação das pás da hélice acelera uma massa de ar verticalmente para baixo, como reação a essa variação de momento linear, surge, uma força de igual magnitude e sentido oposto, com direção vertical e sentido para cima, denominada empuxo. Desse modo, para que o veículo aumente sua capacidade de carga, o sistema propulsor deve ser capaz de movimentar um maior volume de ar ou aumentar a velocidade de deflexão do fluxo (Martins; Rodrigues; Andrade, 2022). Para um drone poder gerar mais empuxo e aumentar sua capacidade de carga, é necessário movimentar mais ar pelo conjunto motor-hélice. Uma alternativa é modificar o número de conjuntos propulsores, como quadricópteros e octocópteros, modificar as hélices, aumentando as áreas de superfície ou hélices com mais pás, ou aumentando a velocidade de giro do conjunto propulsor acelerando mais da massa de ar.

Nesse contexto, trabalhos como o de Hoyos, Suárez e Echavarria (2022) demonstram o uso de uma RNA para prever o desempenho aerodinâmico de hélices de drones e na otimização de sua geometria, a integração entre o design da hélice e o desempenho do motor é crucial. Além disso, o controle preciso da velocidade de rotação através de algoritmos inteligentes é fundamental para reduzir vibrações e ruídos acústicos gerados pelo fluxo de ar nas hélices, o que amplia a estabilidade e a vida útil do equipamento em aplicações dinâmicas.

2.3 RNAs

Uma rede neural artificial é composta por um determinado número de entradas, pesos sinápticos e unidades de processamento, denominadas os neurônios. O objetivo de um neurônio artificial é processar valores de entrada, através de pesos sinápticos e vieses (*biases*). Esses parâmetros ajustáveis definem o processo de propagação da informação. Esses elementos relacionam-se por meio de uma função de ativação, que representa o efeito da entrada interna e do estado atual do neurônio na definição do próximo estado de ativação da unidade, resultando na produção de uma saída (Fleck *et al.*, 2016).

Diferente da modelagem clássica, uma RNA busca adquirir o aprendizado, através do poder computacional, assemelhando-se à capacidade humana de identificar padrões, agrupar dados e determinar semelhanças a partir de exposições prévias. Assim, quando devidamente treinada e validada, a rede adquire a aptidão de generalização. Isso permite estimar saídas ou realizar inferências para entradas que não foram apresentadas durante a etapa de aprendizagem, viabilizando a solução de problemas complexos.


A qualidade de um modelo está diretamente ligada à arquitetura escolhida e a qualidade dos dados utilizados na sua construção. Para o treinamento de uma rede, são levantadas e divididas em subconjuntos de treinamento, validação e teste. No treinamento são fornecidas as entradas e suas respectivas saídas para que a RNA estabeleça a relação matemática entre os dados, operando como um modelo do tipo caixa preta.

Uma base de dados com volume e qualidade adequados garante um mapeamento robusto entre as variáveis, além de assegurar um real aprendizado do sistema. Por outro lado, a escassez de dados pode impedir a construção de uma lógica concreta, resultando no sobreajuste (*overfitting*) dos dados,

ou seja, a rede memoriza as amostras de treino no lugar de desenvolver o aprendizado e a capacidade de generalização.

Após o treinamento, os dados separados para teste ou validação são utilizados, fornecendo somente as entradas e, baseado no aprendizado anterior, a rede estima automaticamente os valores de saída, assim, é possível comparar com os valores de saídas reais, obtendo os percentuais de erro. Uma vez verificado que o modelo apresenta um nível de erro aceitável, é possível utilizar a RNA para estimar valores de maneira automática. Esse fluxo de trabalho caracteriza o aprendizado supervisionado (Paixão, 2025), como pode ser observado na Figura 2.

Figura 2 – Visão geral do treinamento de uma RNA



Fonte: elaborada pelos autores.

3 Trabalhos relacionados

A literatura sobre modelagem de sistemas de propulsão em Veículos Aéreos Não Tripulados (VANTs) revela avanços pertinentes, mas ainda apresenta lacunas importantes relacionadas à representação das dinâmicas não lineares e dos efeitos térmicos que influenciam diretamente o empuxo. Trabalhos anteriores, como o desenvolvido por Ost (2015), concentraram-se na modelagem da rotação do conjunto propulsor, utilizando uma abordagem clássica de identificação de sistema baseada em modelos autorregressivos, utilizando ferramentas econométricas e análise estatística. Embora adequados para sistemas lineares, tais métodos mostraram limitações na estimação de grandezas associadas às dinâmicas não lineares do motor *brushless*. O próprio autor reconhece as dificuldades na modelagem, atribuindo-as à perda de informação decorrente das características não lineares do sistema real frente ao seu modelo linear adotado, comprometendo a qualidade do modelo, além disso, destaca a necessidade de incorporar variáveis fundamentais à dinâmica do veículo, em especial o empuxo.

No setor aéreo, o uso de RNAs tem se consolidado, especialmente em aplicações em VANTs. Estudos como o de Mandloi e Inada (2019) evidenciam a adoção de RNAs em diversas camadas da arquitetura de voo, desde controle de atitude até processamento visual, substituindo modelos matemáticos tradicionais por estimadores baseados em dados. No entanto, tais abordagens, com frequência tratam o valor de empuxo como uma entrada direta conhecida, no lugar de uma variável dependente das dinâmicas internas do conjunto propulsor, desconsiderando as não linearidades e variações térmicas típicas de motores elétricos.

Em direção distinta, trabalhos como o de Dalkiran e Toraman (2021) investigam o uso de grandezas elétricas como variáveis de entrada para modelagem. O trabalho evidenciou a presença da histerese térmica como um ponto crítico nos motores elétricos, demonstrando como o aquecimento progressivo altera as características de desempenho do sistema. Modelos que ignoram esse fenômeno tornam-se incapazes de capturar adequadamente a evolução temporal da força propulsora, comprometendo a aplicabilidade em cenários reais.

A limitação dos modelos lineares diante de fenômenos térmicos é amplamente documentada na literatura. A histerese térmica em motores *brushless* constitui um fenômeno não linear complexo, alterando parâmetros operacionais como torque efetivo, eficiência e resposta a comandos elétricos. Nesse contexto, Kirchgässner, Wallscheid e Böcker (2021) demonstram a viabilidade de aplicar aprendizado profundo (*deep learning*) no desenvolvimento de sensores virtuais, abordagem conhecida como *sensorless*, capazes de estimar variáveis térmicas internas baseando-se apenas em grandezas

elétricas, sem a necessidade de instrumentação adicional. Pesquisas mais recentes, como a de Singh (2024), reforçam a tendência de virtualização de sensores, indicando que a integração entre aprendizado de máquina e eletrônica embarcada aumenta significativamente a robustez e a confiabilidade dos sistemas.

A utilização de RNAs para superar limitações de modelos lineares e prever valores é respaldada por outras aplicações correlatas. Trabalhos como o de Furlan Júnior, Donadel e Nunes (2025) aplicaram RNAs para estimar o torque de motores síncronos de ímã permanente (da sigla em inglês PMSM – *Permanent Magnet Synchronous Motor*), obtendo um modelo *sensorless* baseado em tensões e correntes, que dispensa sensores físicos. Essa abordagem destaca como as RNAs podem capturar comportamentos não lineares quando comparadas aos métodos determinísticos clássicos.

Nessa mesma linha, Lin *et al.* (2023) propuseram uma arquitetura de rede neural híbrida que incorpora o conhecimento do domínio físico de motores aeronáuticos para predição de empuxo. Ao decompor a rede em subestruturas que mimetizam os componentes do motor, os autores conseguiram reduzir a dependência exclusiva de dados e garantir robustez do modelo mesmo diante da degradação de performance dos componentes ao longo do tempo, um problema recorrente em conjuntos propulsores submetidos a uso intensivo.

Diante desse panorama, observa-se que, embora existam avanços significativos em modelagem neural e técnicas *sensorless*, persiste uma lacuna específica: a ausência de modelos voltados diretamente para a predição de empuxo de conjuntos motor-hélice submetidos a condições reais de operação, incluindo variações térmicas e dinâmicas não lineares complexas. Assim, o presente artigo propõe o uso de RNAs para capturar as dinâmicas não lineares do conjunto motor-hélice e mitigar os efeitos de histerese térmica, alinhando-se às tendências recentes e às necessidades identificadas na literatura.

O Quadro 1 sintetiza os principais indicadores de desempenho encontrados na literatura, evidenciando que, embora existam modelos precisos, a incorporação de dinâmicas não lineares específicas permanece um desafio central.

Quadro 1 – Indicadores de desempenho da literatura

Autor (Ano)	Entradas	Saídas	Método utilizado	Resultados
Goli <i>et al.</i> (2025)	Diâmetro e passo da hélice e velocidade de rotação	Empuxo	RNA + <i>Scaled Conjugate Gradient</i>	$R^2 > 0,99$ Erro médio = 1,27%
Dalkiran e Toraman (2021)	Velocidade, altitude e temperatura ambiente	Empuxo	RNA multicamadas <i>feed-forward</i>	MSE = 1,2948 Erro médio relativo = 1,35% Maior erro relativo inferior a 5%
Kirchgässne, Wallscheid e Böcker (2021)	Sinais elétricos + térmico	Temp. internas	CNN/RNN com residual	MSE = 3.420 K ² RMSE $\approx$ 58,5 K
Furlan Júnior, Donadel e Nunes (2025)	Sinais elétricos + velocidade do motor	Torque	RNA <i>feed-forward</i>	MSE = 0,664 Erro médio = 2,62% R = 0,99995 R ² = 0,99990;
Lin <i>et al.</i> (2023)	Temperaturas, pressões, velocidades e fluxo de combustível	Empuxo	RNA + <i>domain decomposition</i>	Desvio relativo máximo < 4,0% Desvio relativo médio < 2,0%

Fonte: dados da pesquisa.

4 Método da pesquisa


Nesta seção, será detalhado a metodologia utilizada para obtenção de dados, juntamente a todo equipamento necessário para estruturar a base de dados utilizada no treinamento na rede neural

artificial. Adicionalmente, descrevem-se os procedimentos de seleção e tratamento dos dados brutos, a definição da melhor arquitetura avaliada no aprendizado de máquina, além de procedimentos e escolhas de parâmetros para a obtenção dos resultados.

4.1 Plataforma de aquisição de dados

Para a criação da base de dados voltado ao treinamento da rede neural artificial, foi elaborada uma plataforma automatizada de aquisição de variáveis operacionais do conjunto motor-hélice. A construção da estrutura experimental baseou-se em arquiteturas consolidadas de bancadas estáticas, como é possível observar na Figura 3, alinhando-se às diretrizes metodológicas, conforme apresentado em Cantori e Croce (2024).

Figura 3 – Plataforma de aquisição de dados do conjunto motor-hélice



Fonte: arquivo dos autores.

O sistema de propulsão é constituído por um motor elétrico *brushless* acionado por um controlador eletrônico de velocidade (*Electronic Speed Controller* – ESC), comandado por um microcontrolador ESP32 via sinal PWM do tipo servo. O microcontrolador foi escolhido devido sua precisa capacidade de gerar sinais PWM, permitindo o controle de *duty-cycle* com uma resolução de 16 bits, o que garante uma variação precisa da potência entregue ao motor, além de uma ampla adoção em sistemas embarcados e facilidade em integrar sensores, favorecendo a replicabilidade da plataforma. O sistema atua em malha aberta, permitindo a execução de rotinas automatizadas com diferentes níveis de potência para a aquisição massiva de dados, requisito essencial para o correto treinamento de redes neurais artificiais.

4.1.1 Aquisição de dados

Para realizar a aquisição dos dados experimentais foi utilizado o mesmo microcontrolador ESP32 empregado no acionamento do motor, sua escolha é justificada devido sua capacidade de integração simultânea de múltiplos sensores, temporização consistente das leituras e pela facilidade de comunicação serial com sistemas externos para registro de informações em arquivos estruturados, posteriormente utilizados no treinamento da RNA.

Visando garantir coerência temporal e qualidade dos dados, foram feitos ensaios com variação do comando PWM, convertido para uma escala de 0% a 100%. Para cada variação do comando de potência, adotou-se um intervalo médio de estabilização de cinco segundos. Após esse período, realizou-se a leitura dos sinais de corrente e empuxo, garantindo que os dados coletados representassem o regime permanente do sistema.

A leitura da corrente consumida pelo ESC foi adquirida por meio do sensor de efeito Hall ACS712. Esse dispositivo, possui a capacidade de isolar eletricamente o circuito de medição da linha de corrente, o que torna uma escolha segura e eficiente. Embora sensores baseados em efeito Hall apresentem limitações de resolução e sensibilidade a campos magnéticos externos, sua utilização é adequada para a faixa de corrente do sistema analisado, visto que o sensor foi instalado em local

apropriado para mitigar as interferências eletromagnéticas provenientes do próprio sistema de propulsão.

Já para a variável de empuxo gerado pelo conjunto motor-hélice, foi utilizada uma célula de carga com capacidade máxima de 1 kg, acoplada mecanicamente à estrutura de ensaio impressa em 3D no material ABS. O empuxo gerado pelo conjunto exerce uma força direta sobre a célula de carga, a qual apresenta extensômetros (ou *Strain Gauges*) fixados na sua superfície. Com a deformação do material, existe uma variação de resistência elétrica dos sensores que é convertida em uma tensão proporcional à força aplicada.

O sinal da célula de carga é digitalizado através do módulo HX711, que integra um amplificador de instrumentação e um conversor analógico-digital (ADC) de 24 bits. Sua escolha se justifica pelo fato de que, nesta aplicação, a incerteza da medição de empuxo é predominantemente influenciada por fatores mecânicos de flexão estrutural, e não exclusivamente pelo ruído eletrônico do sistema de aquisição. Assim, o conjunto apresenta desempenho adequado à precisão requisitada para a modelagem proposta. Destaca-se que a célula de carga foi previamente calibrada por meio da aplicação de massas conhecidas, garantindo a linearidade entre o sinal digital e a força aplicada.

A coleta de dados foi realizada em ambiente laboratorial controlado e climatizado, mantendo as condições de temperatura e umidade estáveis. Visando garantir a repetibilidade do experimento e a integridade da plataforma de testes, foram realizados ensaios preliminares em dias distintos, para confirmar a consistência dos valores obtidos do conjunto propulsor. Para a consolidação do banco de dados utilizado no treinamento da RNA, optou-se por agrupar as amostras coletadas ao longo de uma mesma sessão experimental contínua. Essa abordagem foi fundamental para mapear de forma fidedigna os efeitos de histerese térmica e mecânica identificados no início da pesquisa, nos quais o aquecimento progressivo das bobinas do motor altera as características eletromecânicas do sistema ao longo do tempo. Uma sessão contínua garante a integridade e a sucessão cronológica do histórico dos valores medidos, permitindo que a variável temporal forneça à rede o contexto acumulativo necessário para mitigar tais fenômenos de deriva térmica.

O microcontrolador EPS32 foi responsável tanto pela atuação do PWM enviado ao ESC quanto pela leitura do empuxo via HX711 e pela corrente elétrica via ACS712. Foram definidas como variáveis de entrada da base de dados o tempo decorrido do ensaio, o nível de comando PWM aplicado ao motor e a corrente elétrica consumida pelo ESC, enquanto o empuxo medido pela célula de carga foi adotado como variável de saída do sistema, conforme mostra o Quadro 2. Ao todo, consolidou-se um banco de dados composto por 1.603 vetores de amostragem.

Quadro 2 – Parâmetros escolhidos para variáveis de entrada e saída

Tipo de variável	Nome das variáveis
Entradas	Tempo (Decorrido do teste), pot_motor (Valor % do pwm), i_esc (Corrente do sensor)
Saída	empuxo (Valor da célula de carga)

Fonte: dados da pesquisa.

4.2 Tratamento dos dados

Após o processo de aquisição, os dados brutos foram analisados de maneira a verificar algum tipo de erro momentâneo na leitura ou interferência nos sensores. Nessa etapa foi verificado a presença de variações significativas nos dados para um mesmo valor de acionamento. Como exemplo, ao aplicar um comando constante de 12% ao motor, o sensor de corrente registrou 0,17 A no início dos ensaios e atingiu, 0,86 A ao término do teste. Essa variação para um mesmo valor de acionamento do motor está associada à combinação de efeitos de histerese térmica e mecânica do conjunto propulsor.

Com o aquecimento progressivo das bobinas do motor, do ESC e dos sensores através do tempo decorrido provocou variações no sinal de corrente, além de alterar as características eletromecânicas do conjunto motor-hélice. Assim, evidenciou-se que o sistema apresenta um comportamento dependente do histórico de operação. Por esse motivo, incluiu-se, o tempo decorrido da aquisição dos dados como uma das variáveis de entrada da rede, uma vez que tais fenômenos não lineares dependem do histórico de excitação acumulado e não apenas dos valores instantâneos das variáveis.

Diante desse comportamento, realizou-se a normalização linear das variáveis de entrada e de saída para o intervalo entre 0 e 1. O procedimento foi executado por meio da função *mapminmax* no ambiente MATLAB®; essa função mapeia as grandezas físicas para um domínio adimensional, armazenando os parâmetros de escalonamento para a posterior etapa de desnormalização. Essa etapa de pré-processamento é indispensável, uma vez que algoritmos baseados em redes neurais artificiais apresentam elevada sensibilidade à escala dos dados de entrada, podendo apresentar dificuldades de convergência no treinamento caso as amplitudes originais sejam mantidas.

4.3 Definição do método de aprendizagem

Com base na análise de referências consultadas e nas propriedades do conjunto de dados utilizado neste estudo, optou-se pelo uso de uma rede neural do tipo *feed-forward* com algoritmo de treinamento *backpropagation*, desenvolvida no ambiente MATLAB®. Essa arquitetura é amplamente utilizada em problemas de regressão e modelagem de sistemas dinâmicos, sendo adequada para representar a relação das entradas com a saída gerada pelo conjunto motor-hélice. Embora outras ferramentas e abordagens tenham sido consideradas, a escolha desse ambiente se justifica pela robustez das bibliotecas disponíveis, pela ampla utilização na literatura e pela facilidade de reprodutibilidade dos resultados.

Para a camada oculta, utilizou-se a função de ativação sigmoide logística (*logsig*), que mapeia os valores de entrada em um intervalo contínuo entre 0 e 1, sendo amplamente aplicada em problemas de regressão por sua suavidade e diferenciabilidade. Em contrapartida, a camada de saída foi configurada com uma função de ativação linear (*purelin*), permitindo que a rede estime valores contínuos de empuxo sem restrições por saturação nas extremidades do intervalo predito. O algoritmo de otimização utilizado para o ajuste dos pesos sinápticos e *biases* da rede foi o Levenberg-Marquardt (*trainlm*), selecionado nativamente como a configuração padrão da função utilizada *feedforwardnet* no ambiente MATLAB®. A escolha desse algoritmo se justifica por sua alta eficiência computacional e rápida convergência em problemas de regressão não linear. Esse algoritmo prescinde de uma taxa de aprendizado estática, utilizando um parâmetro adaptativo de amortecimento iniciado em 0,001, cujo valor sofre incrementos ou decrementos automáticos a cada época (*epoch*) a depender da evolução da função de desempenho. O processo de treinamento foi configurado para uma execução de até 1.000 épocas. Contudo, optou-se por um critério de parada precoce baseado no desempenho do conjunto de validação. Assim, o algoritmo interrompe o processo caso o erro de validação aumente consecutivamente, mitigando o risco de sobreajuste (*overfitting*) e garantindo a capacidade de generalização do modelo.

Com a definição do ambiente de desenvolvimento e do método de aprendizagem, iniciou-se a etapa de testes para a seleção da topologia da RNA. Para tanto, foi estabelecida a divisão do banco de dados, no qual foram disponibilizados 80% das amostras (1.282 vetores) para treinamento, 10% (160 vetores) para teste, e os 10% restantes (160 vetores) foram destinados à validação do modelo. Foram avaliadas diferentes configurações variando-se o número de neurônios na camada oculta, considerando arquiteturas com 2, 5, 10 e 20 neurônios. Optou-se por uma topologia com apenas uma camada oculta, visto que o acréscimo de camadas intermediárias elevaria o custo computacional, distanciando o modelo do objetivo de uma futura implementação em sistemas embarcados de processamento limitado.


Para a avaliação de cada topologia, o desempenho foi quantificado por meio de quatro critérios estatísticos estabelecidos, o erro médio absoluto (da sigla em inglês MAE – *Mean Absolute Error*), que quantifica a magnitude média do erro em gramas; A raiz do erro quadrático médio (da sigla em inglês RMSE – *Root Mean Squared Error*), métrica que penaliza desvios de maior magnitude e indica a dispersão dos resíduos em relação ao ajuste perfeito. O erro percentual absoluto médio (sigla em inglês MAPE – *Mean Absolute Percentage Error*) é utilizado para expressar a magnitude média do erro das previsões como uma porcentagem dos valores reais. Por fim, o coeficiente de determinação (R^2), uma medida de quanto o modelo explica a variabilidade dos dados explicada pelo modelo matemático. Assim, com esses erros apresentados na Tabela 1, a arquitetura contendo 20 neurônios na camada oculta apresentou o melhor equilíbrio entre precisão e complexidade do modelo, conforme ilustrado na Figura 4, sendo, portanto, adotada para a etapa final de treinamento da rede.

Tabela 1 – Indicadores de desempenho entre os números de neurônios

Nº neurônios	MAE (gramas)	RMSE (gramas)	MAPE (%)	R ²
2	4,3242	5,3233	16,41	0,9950
5	2,8307	3,7286	4,64	0,9973
10	2,5913	3,2427	3,92	0,9982
20	2,1844	2,8141	3,94	0,9984

Fonte: dados da pesquisa.

Figura 4 – Arquitetura da rede neural artificial



Fonte: elaborada pelos autores com o uso do software NN-SVG.

5 Resultados e discussões

A arquitetura selecionada, contendo 20 neurônios na camada oculta, demonstrou o melhor equilíbrio entre capacidade de generalização, estabilidade e baixo erro de previsão no teste, conforme as métricas obtidas. Após as etapas de treinamento, teste e validação, a RNA apresentou um MAE de 2,18 g e um MAPE de 3,94%, evidenciando uma captura consistente na relação não linear entre o comando PWM, a corrente elétrica e o empuxo gerado.


Esses valores estão dentro da faixa observada em estudos recentes aplicados à modelagem de sistemas propulsores de drones, embora superiores aos resultados reportados por Goli *et al.* (2025), que obtiveram MAPE de aproximadamente 1,27%. Essa diferença pode ser atribuída ao fato de que o referido estudo utilizou apenas variáveis estáticas e condições experimentais altamente controladas. Em contrapartida, o presente trabalho incorpora variáveis sujeitas a efeitos de histerese térmica, o que eleva a complexidade do problema, tornando-o mais representativo do comportamento real de um sistema de propulsão elétrico.

O diferencial deste trabalho reside na inclusão do tempo decorrido de funcionamento do sistema propulsor como uma das variáveis de entrada, o que permitiu modelar a histerese térmica e mecânica do conjunto motor-hélice. Durante os ensaios, verificou-se que para um mesmo comando de acionamento (12% de PWM), a corrente variou de 0,17 A para 0,86 A ao longo do tempo. Esse fenômeno de deriva térmica também foi discutido em Dalkiran e Toraman (2021), que demonstram que modelos puramente geométricos ou lineares falham ao buscar estimar o empuxo em regimes de operação prolongados.

A Figura 5 apresenta a comparação entre os valores de empuxo reais e estimados, evidenciando que a RNA acompanha de maneira satisfatória a variação do resultado ao longo do intervalo analisado. Observa-se que as previsões se mantêm próximas aos valores medidos, mesmo em regiões onde a corrente apresenta variações mais abruptas. Esse comportamento reforça a capacidade do modelo em aprender relações não lineares intrínsecas às dinâmicas eletromecânicas do motor *brushless*. Resultados semelhantes foram observados em aplicações análogas, como a estimação de torque em

motores PMSM realizada por Furlan Júnior, Donadel e Nunes (2025), os quais também identificaram que as RNAs capturam com precisão variações não lineares decorrentes de efeitos térmicos e de carga, superando modelos lineares tradicionais.


Figura 5 – Resultados reais versus estimados



Fonte: elaborada pelos autores.

A análise da dispersão apresentada na Figura 6 representa a variabilidade dos erros de estimação do modelo e fornece uma avaliação adicional da robustez do modelo. A proximidade dos pontos em relação à reta $y = x$ indica elevada capacidade preditiva. Desse modo, os pontos que se distanciam dessa linha evidenciam os limites do modelo de previsão em representar determinadas regiões do espaço de dados. Consequentemente, quanto menor a distância de um ponto à reta ideal, maior será a precisão na estimativa de resultado do empuxo.

Figura 6 – Resultados de dispersão



Fonte: elaborada pelos autores.

Pequenos aumentos de erro observados em regiões de maior comando de acionamento do motor podem estar relacionados ao aquecimento das bobinas do motor, alterando temporariamente a resistência interna dos enrolamentos e, consequentemente, a corrente consumida. Tal efeito de histerese térmica é também discutido por Dalkiran e Toraman (2021). Esse comportamento reforça a

importância da inclusão do tempo de operação como variável de entrada, consolidando-se como uma contribuição metodológica relevante deste trabalho.

Para avaliar em que medida as não linearidades do sistema justificam o uso de uma RNA, desenvolveu-se um modelo de regressão linear múltipla utilizando as mesmas variáveis de entrada empregadas na rede neural. Conforme apresentado na Tabela 2, os resultados indicaram o desempenho superior do modelo RNA em comparação ao modelo linear, apresentando valores de MAE e RMSE significativamente maiores, além de um coeficiente de determinação (R^2) substancialmente menor. Esse comportamento indica que o modelo linear gera erros maiores em pontos críticos e é menos capaz de explicar o comportamento físico do sistema.

Esses resultados indicam que a relação entre o tempo decorrido do experimento, a corrente consumida pelo ESC, o nível de comando PWM aplicado ao motor e o empuxo gerado não pode ser adequadamente representada por uma modelagem linear. A Figura 7 ilustra essa limitação ao apresentar a dispersão entre os valores reais e estimados pelo modelo de regressão.


A comparação com a regressão linear funciona, portanto, como uma linha de base para avaliação do desempenho da RNA, evidenciando que a abordagem baseada em redes neurais é mais adequada para representar o comportamento não linear do conjunto propulsor. Esse resultado converge com trabalhos como o de Kirchgässner, Wallscheid e Böcker (2021), que demonstram as limitações modelos lineares na presença de dinâmicas complexas e efeitos acumulativos, como os fenômenos térmicos em sistemas elétricos.

Tabela 2 – Comparação de resultados RNA versus Regressão linear

Modelo	MAE (gramas)	RMSE (gramas)	R^2
Regressão Linear	5,9039	9,2336	0,9855
RNA	2,1844	2,8141	0,9984

Fonte: dados da pesquisa.

Figura 7 – Resultados da regressão linear



Fonte: elaborada pelos autores.

Outro ponto relevante é a extração da formulação analítica da rede treinada. A possibilidade de representar explicitamente a função de ativação e as combinações lineares ponderadas. Na Equação 1 é apresentada a função de ativação da camada oculta na RNA. A Equação 2 descreve a combinação linear entre as entradas e os pesos associados, enquanto, a Equação 3 expressa o empuxo estimado em função dos pesos, *biases* e saídas dos neurônios. Por fim, na Equação 4 é apresentada a função de ativação da camada de saída, na qual a função linear replica o argumento de entrada, atuando como um repassador do ajuste linear final dos pesos sinápticos. Dessa forma, é possível que o modelo seja facilmente implementado em controladores embarcados ou ambientes de simulação.

$$\text{logsig}(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

$$N_k = \text{logsig}((P_{in,k} \times PWM + B_{in,k})) \quad k = 1, 2, 3, 4, 5, \dots, 19, 20 \quad (2)$$

$$\text{Empuxo} = \sum_{i=1}^{k=20} (P_{out,k} \times N_k) + B_{out} \quad (3)$$

$$g(x) = x \quad (4)$$

Essa característica reforça a aplicabilidade prática do método proposto – especialmente em arquiteturas nas quais sensores físicos de empuxo não podem ser utilizados por limitações de peso, custo ou disponibilidade –, alinhado com tendências de controle *sensorless* discutidas por Singh (2024).

Em síntese, os resultados indicam que a RNA desenvolvida apresenta desempenho competitivo com o estado da arte e oferece vantagens específicas de:

- Captura de efeitos térmicos e dinâmicos não considerados em modelos baseados apenas em parâmetros geométricos;
- Capacidade de generalização adequada mesmo diante de ruídos dos sensores;
- Aplicabilidade direta em sistemas reais, com potencial para integração em controladores de VANTs.

Embora o erro percentual não seja o menor reportado pela literatura, ele é consistente e compatível com a complexidade do fenômeno modelado, demonstrando que a abordagem é tecnicamente sólida e aplicável em cenários reais.

6 Conclusão

Este trabalho apresentou em uma abordagem para a obtenção de um modelo de estimação do empuxo de um conjunto motor-hélice por meio de uma rede neural artificial, utilizando método de modelagem tipo caixa preta, com o objetivo de dispensar a necessidade de medições diretas da força propulsora por sensores físicos dedicados. A metodologia proposta demonstrou-se adequada para a modelagem de sistemas não lineares complexos, eliminando a necessidade de linearização matemática do sistema dinâmico.

O modelo implementado neste artigo, baseado em uma RNA do tipo *feed-forward backpropagation*, foi treinada a partir de dados extraídos de uma bancada experimental customizada. O estimador considerou como variáveis de entrada o tempo decorrido do ensaio, o comando de acionamento do motor (PWM) e a corrente elétrica consumida pelo ESC. Os resultados mostraram-se concretos e confiáveis, evidenciando o desempenho satisfatório da rede, que apresentou erro quadrático médio de 2,18 e um erro percentual médio de 3,94% na estimação do empuxo.

Um primeiro ponto relevante foi a inclusão da corrente elétrica como variável de entrada, cuja relação com a potência efetiva do motor e com o comando PWM demonstrou forte sinergia para uma previsão eficaz do empuxo. Outro ponto de extrema importância consistiu na histerese observada na corrente ao longo do experimento, causada pelo aumento da temperatura durante a operação prolongada. O treinamento da RNA mostrou uma convergência coerente ao longo das épocas de aprendizagem, resultando em um modelo estável e consistente. Diante dos resultados obtidos neste trabalho, o modelo demonstra potencial de aplicação em projetos reais de VANTs e em sistemas de controle aeroespaciais, viabilizando a estimação adaptativa do empuxo sem a necessidade de sensores físicos adicionais na aplicação pretendida, assim como a diminuição de custos e complexidade do sistema.

Como trabalhos futuros, sugere-se a incorporação de novas variáveis ao modelo, que se correlacionem com as dinâmicas de acionamento e alimentação, tais como a temperatura das bobinas do estator e a tensão de entrada do ESC, assim como o estudo do impacto do tempo de funcionamento na eficiência do conjunto propulsor. Além disso, recomenda-se a validação do modelo proposto em testes de campo, como plataformas de VANTs em voo livre, permitindo analisar a integração do estimador neural a sistemas sujeitos a dinâmicas aerodinâmicas mais agressivas fora da plataforma de teste.

Por fim, os resultados deste trabalho ressaltam o potencial de utilização de RNAs como ferramentas eficazes de estimação e modelagem de sistemas complexos não lineares, contribuindo para o desenvolvimento de soluções mais eficientes. O uso de metodologias de previsão de resultados

utilizando aprendizagem de máquina possibilita um grande avanço na redução de tempo, custo e segurança em aplicações tecnológicas.

Agradecimentos

Os autores agradecem ao Instituto Federal Fluminense (IFF) – Campus Campos Centro e ao Polo de Inovação Campos dos Goytacazes (PICG) por fornecer o acesso a laboratórios e infraestrutura necessária para a realização deste trabalho.

Financiamento

Esta pesquisa não recebeu financiamento.

Conflito de interesses

Os autores declaram não haver conflito de interesses.

Contribuições ao artigo

SOUZA, M. B.: concepção ou desenho do estudo/pesquisa; análise e/ou interpretação dos dados. **CARVALHO, A. S.:** revisão final com participação crítica e intelectual no manuscrito. Todos os autores participaram da escrita, discussão, leitura e aprovação da versão final do artigo.

Disponibilidade de dados e códigos

Para garantir a reprodutibilidade dos experimentos e colaborar nas práticas de ciência aberta, a base de dados experimentais obtida na bancada estática assim como os códigos desenvolvidos neste trabalho foram armazenados publicamente e receberam o identificador de objeto digital permanente DOI: <https://doi.org/10.5281/zenodo.20549099>.

Referências

ANALOG CIRCUIT DESIGN. Brushless DC Motor. **Analog Circuit Design**, 26 jan. 2024. Disponível em: <https://analogcircuitdesign.com/how-does-a-brushless-dc-motor-work/>. Acesso em: 21 jan. 2026.

CANTORI, D. J.; CROCE, J. A. G. Concepção e fabricação de um dispositivo para medir o empuxo e torque estáticos em sistemas de propulsão de VANT. In: CONGRESSO DE INOVAÇÃO, CIÊNCIA E TECNOLOGIA DO IFSP, 15., 2024, São Carlos. **Anais [...]**. São Carlos: IFSP, 2024. Disponível em: <https://congressos.ifsp.edu.br/conict/article/view/972>. Acesso em: 25 out. 2025.

DALKIRAN, F. Y.; TORAMAN, M. Predicting thrust of aircraft using artificial neural networks. **Aircraft Engineering and Aerospace Technology: An International Journal**, v. 93, n. 1, p. 35-41, 2021. DOI: <https://doi.org/10.1108/AEAT-05-2020-0089>.

EUGENIO, F.; ZAGO, H. **O Livro dos Drones: Um Guia Completo para entender todas as partes e funcionamento**. 1. ed. Alegre: Editora Caufes, 2019.

FERNANDES, E. M. **Estimação de posição e velocidade de uma máquina síncrona a ímã permanente**. 2006. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Campina Grande, Campina Grande, 2006. Disponível em: <https://dspace.sti.ufcg.edu.br/handle/riufcg/3178>. Acesso em: 17 out. 2025.

FLECK, L.; TAVARES, M. H. F.; EYNG, E.; HELMANN, A. C.; ANDRADE, M. A. M. Redes neurais artificiais: princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 7, n. 15, p. 47-57, 2016. DOI: <http://dx.doi.org/10.3895/recit.v7.n15.4330>.

FURLAN JÚNIOR, W.; DONADEL, C. B.; NUNES, R. B. Modelagem de torque em motores síncronos de ímã permanente (PMSM) por meio de redes neurais artificiais. **Revista Mundi: Engenharia, Tecnologia e Gestão**, v. 10, n. 2, 2025. Disponível em: <https://revistas.ifpr.edu.br/index.php/mundietg/article/view/2107>. Acesso em: 17 out. 2025.

GARCIA, C. **Modelagem e Simulação de Processos Industriais e de Sistemas Eletromecânicos**. 3. ed. São Paulo: Edusp, 2005.

GOLI, S.; KURTULUŞ, D. F.; WAQAR, M.; IMRAN, I. H.; ALHEMS, L. M.; KOUSER, T.; MEMON, A. M. Artificial neural network for the evaluation of electric propulsion system in unmanned aerial vehicles. **Neural Computing & Applications**, v. 37, p. 8945-8961, 2025. DOI: <https://doi.org/10.1007/s00521-025-11043-6>.

HOYOS, J.; SUÁREZ, G.; ECHAVARRIA, C. Neural network for propeller performance prediction and CFD validation of its optimal. **Journal of Aeronautics, Astronautics and Aviation**, v. 54, n. 4, p. 367-374, 2022. DOI: [https://doi.org/10.6125/JoAAA.202212_54\(4\).01](https://doi.org/10.6125/JoAAA.202212_54(4).01).

JIANG, F.; POURPANAH, F.; HAO, Q. Design, Implementation, and Evaluation of a Neural-Network-Based Quadcopter UAV System. **IEEE Transactions on Industrial Electronics**, v. 67, n. 3, p. 2076-2085, 2020. DOI: <https://doi.org/10.1109/TIE.2019.2905808>.

KIRCHGÄSSNER, W.; WALLSCHEID, O.; BÖCKER, J. Estimating electric motor temperatures with deep residual machine learning. **IEEE Transactions on Power Electronics**, v. 36, n. 7, p. 7480-7488, 2021. DOI: <https://doi.org/10.1109/TPEL.2020.3045596>.

KRISHNAN, R. **Electric motor drives: Modeling, Analysis, and Control**. 1. ed. Upper Saddle River: Prentice Hall, 2001.

LIN, Z.; XIAO, H.; ZHANG, X.; WANG, Z. Thrust Prediction of Aircraft Engine Enabled by Fusing Domain Knowledge and Neural Network Model. **Aerospace**, v. 10, n. 6, 493, 2023. DOI: <https://doi.org/10.3390/aerospace10060493>.

MANDLOI, Y. S.; INADA, Y. Machine learning approach for drone perception and control. In: INTERNATIONAL CONFERENCE ON ENGINEERING APPLICATIONS OF NEURAL NETWORKS, 20., 2019, Chersonissos. **Proceedings [...]**. Cham: Springer, 2019. (Communications in Computer and Information Science, v. 1000). DOI: https://doi.org/10.1007/978-3-030-20257-6_36.

MARTINS, W. V. A.; RODRIGUES, C. G.; ANDRADE, E. V. O ensino sobre forças de empuxo auxiliando por experimentos de fácil acesso. **Revista Mais Educação**, v. 5, n. 1, p. 1082-1092, 2022. Disponível em: <https://www.revistamaiseducacao.com/artigosv5-n1-marco-2022/84>. Acesso em: 23 out. 2025.

MOHANRAJ, D.; ARULDAVID, R.; VERMA, R.; SATHIYASEKAR, K.; BARNAWI, A. B.; CHOKKALINGAM, B.; MIHET-POPA, L. A review of BLDC motor: state of art, advanced control techniques, and applications. **IEEE Access**, v. 10, p. 54833-54869, 2022. DOI: <https://doi.org/10.1109/ACCESS.2022.3175011>.

OGATA, K. **Engenharia de controle moderno**. 4. ed. São Paulo: Person Prentice Hall, 2005.

OKULSKI, M.; ŁAWRYŃCZUK, M. A Novel Neural Network Model Applied to Modeling of a Tandem-Wing Quadplane Drone. **IEEE Access**, v. 9, n. 3, p. 14159-14178, 2021. DOI: <https://doi.org/10.1109/ACCESS.2021.3051878>.

OST, A. **Modelagem matemática do conjunto ESC-motor-hélice de um VANT utilizando identificação de sistemas**. 2015. Dissertação (Mestrado em Modelagem Matemática) – Universidade Regional do Noroeste do Estado do Rio Grande do Sul (UNIJUI), Ijuí, 2015. Disponível em: <https://bibliodigital.unijui.edu.br/items/2ec60731-54c9-42c5-82bb-db9647369b2b>. Acesso em: 25 out. 2025.

PAIXÃO, J. L. Redes neurais artificiais: estrutura, modelagem matemática e exemplo de aplicação. *In: INOVAÇÕES multidisciplinares na engenharia*. Curitiba: Aurum Editora, 2025. p. 12-22. DOI: <https://doi.org/10.63330/aurumpub.005-002>.

SILVA, A. J.; PINTO, A. R.; OLIVEIRA, D. J. M.; SOUZA, J. O. A.; SILVA, K. A.; KAMIMURA, L. T. Medição das forças de arrasto e sustentação em um túnel de vento didático. **Conexões – Ciência e Tecnologia**, Fortaleza, v. 14, n. 3, p. 125-131, 2020. Disponível em: <https://conexoes.ifce.edu.br/index.php/conexoes/article/view/1423>. Acesso em: 30 out. 2025.

SINGH, U. Sensorless Control Techniques for BLDC Motors: Back-EMF & Observer Methods. **MechTex**, [8 dez. 2024]. Disponível em: <https://mechtex.com/blog/sensorless-control-techniques-for-blcd-motors>. Acesso em: 30 out. 2025.