

INSTITUTO ALPHA LUMEN
2º ANO DO ENSINO MÉDIO

GUSTAVO RODRIGUES ARAUJO
LUÍS MIGUEL DA SILVA PAULA
MICAEL MOREIRA PINATTI

REDES NEURAIIS QUÂNTICAS NA INDÚSTRIA AEROESPACIAL
O uso de novas tecnologias para otimizar o consumo de combustível em veículos
aeroespaciais

SÃO JOSÉ DOS CAMPOS – SP
2025

Gustavo Rodrigues Araujo
Luís Miguel Da Silva Paula
Micael Moreira Pinatti

REDES NEURAIIS QUÂNTICAS NA INDÚSTRIA AEROESPACIAL
O uso de novas tecnologias para otimizar o consumo de combustível em veículos
aeroespaciais

Trabalho de Conclusão de Curso apresentado
ao Instituto Alpha Lumen como parte das
exigências para a obtenção do título de
conclusão da 2ª série do Ensino Médio.

Supervisora: Prof. Ana Cecília Leal

**Orientador: Prof. Me. Juarez Barbosa de
Carvalho**

**Orientador técnico: Prof. Me. Gabriel
Garcia**

SÃO JOSÉ DOS CAMPOS – SP

2025

A Alberto Santos Dumont, eterno “Pai da Aviação”, que fez do céu uma extensão dos sonhos humanos, e a todos os que pavimentaram o caminho para que este estudo se tornasse realidade.

AGRADECIMENTOS

Agradecemos à professora supervisora Ana Cecília, pela dedicação, profissionalismo e atenção aos detalhes que tornaram possível a construção deste trabalho — esperamos que cada vírgula corrigida tenha valido a pena. Ao professor orientador Juarez Carvalho e ao orientador técnico Gabriel Garcia, pela parceria e orientações que guiaram nossa pesquisa. Ao Instituto Alpha Lumen, pelo apoio e confiança. E, por fim, aos nossos familiares, professores e amigos, pelo incentivo e presença em cada etapa desta jornada.

Gustavo Rodrigues Araujo

Agradeço aos meus pais, Edinaldo e Miriam, pelo apoio e dedicação que tornaram possível a realização deste trabalho. Aos meus avós, pelo acolhimento constante, e aos amigos que estiveram presentes em todo o processo. Agradeço também aos meus companheiros de TCC, Luís Miguel e Micael, pela parceria e empenho ao longo desta jornada. Além disso, expresso enorme gratidão ao Marcus Fontoura, meu apoiador do Clube dos Sonhos, responsável por abrir a porta de uma instituição de ensino de excelência em minha vida. E, finalmente, deixo uma homenagem especial à minha tia Eliane, que deixou imensas saudades em minha família neste ano, mas continua presente em minhas lembranças e conquistas.

Luís Miguel da Silva Paula

Agradeço ao meu Senhor Jesus Cristo, centro da minha fé católica que me guia desde meu nascimento. Aos meus pais, Adriano e Bárbara, pelo amparo que sempre ofereceram em favor dos meus estudos, juntamente à minha irmã, Júlia, inspiração para mim e exemplo de esforço e dedicação. Agradeço também à Mariana Obristi, responsável por acender a chama do amor romântico em meu coração, e que me apoia em todas as ocasiões. Sou grato aos meus companheiros de TCC, Gustavo e Micael, que dedicaram seu precioso tempo em prol da realização deste trabalho, e a todos os meus amigos que concederam apoio no decorrer deste processo. Por último, mas não menos importante, demonstro minha gratidão ao Clube dos Sonhos e ao meu apoiador anônimo por me presentear com uma bolsa de estudos parcial no Instituto Alpha Lumen, a qual me proporcionou experiências acadêmicas e sociais únicas.

Micael Moreira Pinatti

Gostaria de expressar meus profundos agradecimentos à minha família, meus pais, Adriana e Márcio, e minha irmã, Sofia pelo cuidado, apoio incondicional e atenção constantes, os quais foram fundamentais para a conclusão deste trabalho. Eles representam para mim exemplos de dedicação, esforço, integridade e caráter. Um agradecimento especial é dirigido ao grupo "Os Sabudos", composto por Luís Miguel, Luis Samuel, Pedro Luís, Gabriel Matias e por mim, cuja assistência foi crucial na localização de materiais e na formação necessária para a realização deste estudo. Agradeço também aos meus amigos Lia Raquel, João Ivo e Arthur Marques, pelo indispensável suporte e pelos momentos de descontração, que foram essenciais para manter o equilíbrio durante este processo. Meu sincero reconhecimento é dedicado aos meus colegas Luís e Gustavo, pela parceria produtiva, dedicação e companheirismo ao longo de toda a jornada de pesquisa e aprendizagem, elementos essenciais para a realização desta tarefa. Por fim, manifesto minha gratidão ao meu apoiador do Clube dos Sonhos, por viabilizar minha formação no Instituto Alpha Lumen. À instituição, meu agradecimento por prover o conhecimento e a base estrutural indispensáveis para a conquista de meus objetivos.

RESUMO

A rede neural quântica (QNN) é um modelo de aprendizado de máquina que une os princípios da computação quântica com as redes neurais artificiais clássicas. O cerne desta investigação é analisar a sua aplicação na otimização do consumo de combustível por aeronaves e astronaves, bem como o seu impacto na indústria tecnológica, nas organizações sociais e no meio ambiente. Através de uma metodologia interdisciplinar que articula a mecânica quântica, a ciência da computação e a engenharia aeronáutica, e baseando-se na revisão de artigos científicos, trabalhos acadêmicos, revistas, portais de notícia e publicações especializadas, este trabalho examina o processo completo deste novo paradigma tecnológico, desde o seu planejamento e desenvolvimento até a sua aplicação prática e manutenção, tanto em contextos atuais quanto em projeções futuras. Os resultados da análise indicam que a implementação da QNN, sob condições operacionais adequadas, tem o potencial de trazer avanços exponenciais nos setores de aeronáutica e astronáutica, promovendo importantes ganhos de eficiência, uma significativa redução na pegada ambiental e transformações na cadeia produtiva e na sua interação com o ecossistema global, redefinindo assim os limites da tecnologia e da sustentabilidade.

Palavras-chave: computação quântica; indústria aeroespacial; inteligência artificial; otimização do consumo de combustíveis; redes neurais.

ABSTRACT

The quantum neural network (QNN) is a machine learning model that combines the principles of quantum computing with classical artificial neural networks. The focus of this research aims to analyze its application in optimizing fuel consumption by aircraft and spacecraft, as well as its impact on the technology industry, social organizations, and the environment. Using an interdisciplinary methodology that combines quantum mechanics, computer science, and aeronautical engineering, and based on the review of scientific articles, academic papers, and specialized publications, this work examines the complete process of this new technological paradigm, from its planning and development to its practical application and maintenance, both in current contexts and in future projections. The results of the analysis indicate that the implementation of QNN, under appropriate operational conditions, has the potential to bring exponential advances in the aeronautics and astronautics sectors, promoting important efficiency gains, a significant reduction in the environmental impacts and transformations in the production chain and its interaction with the global ecosystem, thus redefining the limits of technology and sustainability.

Key-words: quantum computing; aerospace industry; artificial intelligence; fuel consumption optimization; neural networks.

LISTA DE FIGURAS

Figura 1 - Aerodinâmica da aeronave.....	16
Figura 2 - Aerodinâmica do foguete.....	16
Figura 3 - Neurônio biológico.....	17
Figura 4 - Neurônio artificial.....	18
Figura 5 - Rede neural.....	19
Figura 6 - Neurônio Artificial de McCulloch-Pitts.....	20
Figura 7 - Rede neural perceptron.....	21
Figura 8 - Neurônio Artificial perceptron.....	21
Figura 9 - Rede neural feed-forward.....	22
Figura 10 - Rede neural convolucional.....	23
Figura 11 - Rede neural recorrente.....	23
Figura 12 - Rede neural transformer.....	24
Figura 13 - Funções de onda do elétron do átomo de Hidrogênio.....	27
Figura 14 - Módulos da pyACDT.....	34
Figura 15 - Análises feitas por OpenMDAO.....	35
Figura 16 - Áreas em que a IA pode ser aplicada no setor das companhias aéreas.....	38
Figura 17 - Curva PF.....	40
Figura 18 - Manutenção Assistida por IA.....	40
Figura 19 - Aeronave VX4.....	41
Figura 20 - Diagrama comparativo didático.....	43
Figura 21 - Gráfico temporal computacional.....	44

LISTA DE SIGLAS E ABREVIATURAS

Anac	Agência Nacional de Aviação Civil
ANN	Rede neural artificial
Avgas	Gasolina de aviação
CNN	Rede neural convolucional
FFNN	Rede neural feed-forward
GMAT	Ferramenta de análise de missão geral
GNSS	Sistema Global de Navegação por Satélite
Hc	Hamiltoniano de custo
Hm	Hamiltoniano de Mistura
IA	Inteligência artificial
LH2	Hidrogênio líquido
LOX	Oxigênio líquido
ML	Machine learning
Nasa	Agência Nacional de Aeronáutica e Espaço
OCC	Otimização do consumo de combustível
OpenMDAO	Análise e Otimização de Design Multidisciplinar Aberto
QAOA	Algoritmo de Otimização Quântica Aproximada
QAV	Querosene de aviação
QNN	Rede neural quântica
RP	Querosene refinado
SAF	Combustível sustentável de aviação
TCC	Trabalho de Conclusão de Curso
TNN	Rede neural transformer
Unesco	Organização das Nações Unidas para a Educação, a Ciência e a Cultura
WCED	Comissão Mundial sobre Meio Ambiente e Desenvolvimento

SUMÁRIO

INTRODUÇÃO.....	12
1 CONCEITOS INICIAIS.....	14
1.1 Setor aeroespacial.....	14
1.1.1 Histórico do setor.....	14
1.1.2 Princípios físicos e navegação aeroespacial.....	15
1.2 Redes neurais artificiais.....	17
1.2.1 Modelo pioneiro.....	19
1.2.2 Principais tipos.....	20
1.2.2.1 Perceptron.....	20
1.2.2.2 Feed-foward.....	21
1.2.2.3 Convolucionais.....	22
1.2.2.4 Recorrentes.....	23
1.2.2.5 Transformer.....	23
1.2.2.6 Quântica.....	24
1.2.3 Inteligência Artificial.....	25
1.3 Mecânica quântica.....	25
1.3.1 Conceitos fundamentais da mecânica quântica.....	25
1.3.2 Computação quântica.....	27
1.3.3 Algoritmo de otimização quântica aproximada.....	28
1.3.3.1 Hamiltoniano de Custo.....	28
1.3.3.2 Hamiltoniano de Mistura.....	29
1.3.3.3 Porta lógica de Hadamard.....	29
1.3.3.4 Constituição de Farhi.....	29
2 CONSUMO DE COMBUSTÍVEL E REDES NEURAS.....	32
2.1 Fatores impactantes no consumo de combustível.....	32
2.1.1 Tecnologia aeroespacial.....	32
2.1.1.1 Eficiência estrutural e operacional na aeronáutica.....	33
2.1.1.2 Eficiência estrutural e operacional na astronáutica.....	34
2.1.2 Combustíveis alternativos.....	35
2.2 Inteligência Artificial.....	36
2.2.1 Aplicação.....	36
2.2.1.1 Cálculo de rotas.....	37
2.2.1.2 Manutenção preditiva.....	38
2.2.1.3 Otimização de projeto.....	40
2.3 Redes neurais quânticas.....	41
2.3.1 Emaranhamento quântico, paralelismo quântico e espaço de características de dimensão exponencial.....	41
3 IMPACTOS DAS REDES NEURAS QUÂNTICAS.....	44
3.1 Aplicações e benefícios.....	44
3.1.1 Otimização de sistemas aeroespaciais.....	44

3.1.2 Produção e consumo sustentável de combustíveis.....	45
3.2 Limitações e perspectivas futuras.....	45
3.2.1 Restrições atuais de hardware e algoritmos quânticos.....	46
3.2.2 Integração com sistemas clássicos: barreiras financeiras e regulatórias.....	46
3.2.3 Expansão futura da aplicação em transporte, indústria e soluções sustentáveis..	47
CONSIDERAÇÕES FINAIS.....	48
REFERÊNCIAS BIBLIOGRÁFICAS.....	50

INTRODUÇÃO

O ano de 2025 foi definido como o “Ano Internacional da Ciência e Tecnologia Quântica” pela Organização das Nações Unidas para a Educação, a Ciência e a Cultura (Unesco). O principal motivo para essa escolha é a celebração dos 100 anos de desenvolvimento da pesquisa quântica. Em 1925, os alemães Werner Heisenberg, Max Born e Pascual Jordan apresentaram ao mundo a mecânica matricial, a primeira formulação teórica bem-sucedida para explicar os conceitos e leis da nascente mecânica quântica, que vinha sendo observada desde o início dos anos 1900.

O avanço tecnológico acompanha a humanidade de forma exponencial, tornando o ser humano cada vez mais dependente de seus desdobramentos. No panorama atual, discute-se muito sobre o desenvolvimento acelerado da Inteligência Artificial (IA), ao mesmo tempo em que a computação quântica — derivada dos estudos da mecânica quântica — ganha destaque por suas possíveis aplicações. A convergência entre essas áreas têm originado soluções inovadoras, como as redes neurais quânticas (Quantum Neural Networks – QNNs), modelos de aprendizado de máquina que simulam o comportamento de sistemas quânticos.

Enquanto que o setor aeroespacial, historicamente associado a altos investimentos e grande uso e descarte de recursos, vem passando por uma transformação impulsionada pela adoção de tecnologias emergentes e práticas sustentáveis (Fathi; Ansari, Al; Ansari, Alexander, 2023). A indústria tem explorado modelos sustentáveis de produção com o apoio de tecnologias digitais em ascensão (Melo et al., 2020). Dentre elas, destacam-se as redes neurais quânticas, cujo uso direto ainda se encontra em estágios iniciais de desenvolvimento.

A demanda por inovação na indústria aeroespacial é constante, pois envolve problemas de alta complexidade, como a otimização de trajetórias, simulação de materiais, gestão de grandes volumes de dados, e a redução de custos e do impacto ambiental. Nesse contexto, a computação quântica surge como um instrumento promissor para aperfeiçoar ou substituir as soluções atualmente baseadas em métodos clássicos.

Uma vez que as tecnologias de Inteligência Artificial, computação quântica e engenharia aeroespacial estão em crescimento, sua convergência promete revolucionar a maneira como problemas complexos são resolvidos, desde a otimização de rotas até a implementação de sistemas autônomos. Dentre os setores com maior potencial de aplicação dessas tecnologias está a indústria aeroespacial, historicamente impulsionada por investimentos em inovação desde a corrida espacial na segunda metade do século XX.

Conforme Moro e Godoy (2003), a aviação demanda a máxima redução do consumo energético e a extração do maior desempenho possível, pois os veículos aeroespaciais são formados por um conjunto complexo de subsistemas que precisam operar em perfeita sincronia. Por isso, as naves aeroespaciais funcionam sob rigorosas limitações de consumo de energia. Ainda segundo os autores, mesmo com o desenvolvimento de estratégias de otimização ao longo do tempo, à medida que esses veículos se tornam mais complexos, torna-se essencial propor novas metodologias que possibilitem a otimização eficiente de todos os subsistemas integrados de uma aeronave ou cosmonave.

Dessa forma, este estudo busca analisar o potencial teórico e prático da tecnologia do uso de redes neurais quânticas na indústria aeroespacial, com foco na otimização do consumo de combustível em veículos aeroespaciais. Dentre as possibilidades criadas por essa aplicação, estão simulações mais precisas de rotas e condições de voo, maior exatidão na previsão do comportamento de sistemas complexos, além de viabilizar decisões mais rápidas e eficientes durante missões. Embora ainda estejam em fase experimental, as redes neurais quânticas representam uma fronteira tecnológica com potencial transformador, capaz de contribuir significativamente para uma navegação mais econômica, segura e ambientalmente sustentável.

Organiza-se esse estudo em três capítulos principais. O primeiro capítulo busca compreender os principais conceitos relativos à aeronaves, astronaves, física e computação quântica, inteligência artificial e redes neurais. A interconexão desses conceitos se desenvolverá no segundo capítulo, sendo sucedido pelo capítulo terceiro, que apresentará a conclusão do estudo da aplicação desses conceitos e seus impactos na indústria. Por fim, nas considerações finais, verificam-se o alcance dos objetivos propostos e as conclusões gerais sobre a pesquisa quanto à sua execução.

1 CONCEITOS INICIAIS

Para que a discussão acerca das aplicações das QNNs no setor aeroespacial seja de total compreensão, faz-se necessário a presença dos principais conceitos relacionados às áreas que englobam esse tema. Assim, neste capítulo estão presentes os princípios aprofundados da aplicação das redes neurais quânticas na otimização de combustível em veículos do tipo.

1.1 Setor aeroespacial

O setor aeroespacial refere-se a uma das indústrias mais tecnológicas e avançadas do mundo, sendo responsável por transportar cargas e pessoas dentro e fora do globo terrestre com segurança e rapidez. A tecnologia aeroespacial corresponde ao conjunto de conhecimentos, técnicas e ferramentas advindos dos setores aeronáutico e astronáutico, aplicados na produção, aprimoramento e utilização de aeronaves e astronaves. Uma aeronave é entendida, conforme a Anac (2008), como um veículo de transporte utilizado no espaço atmosférico. Já a astronave é definida como um veículo projetado para viajar ao espaço sideral e lá desempenhar suas funções (Antas, 1979). Portanto, o ramo aeroespacial é imprescindível no contexto de um mundo globalizado.

1.1.1 Histórico do setor

As origens do setor aeroespacial remontam ao início do século XX, com os primeiros voos motorizados da história. Em 1903, os irmãos Wright, Orville e Wilbur, realizaram a primeira decolagem controlada e sustentada de uma aeronave, utilizando um trilho de lançamento. Posteriormente, em 1906, o Pai da Aviação e Patrono da Aeronáutica Brasileira, Alberto Santos Dumont, executou o primeiro voo sem auxílio externo, decolando diretamente do solo. Mais especificamente no âmbito espacial, o pioneiro na teoria astronáutica, o russo Konstantin Tsiolkovsky deduziu, em seu trabalho “A Exploração do Espaço Cósmico por Dispositivos de Reação” (1903), a equação do foguete, conhecida também como equação de Tsiolkovsky, e propôs o uso de motores a combustível líquido para obter-se propulsão para atingir o espaço. Anos adiante, o físico estadunidense Robert Goddard efetuou, em 1926, o primeiro lançamento bem-sucedido de um foguete movido a combustível líquido.

Durante a Primeira e a Segunda Guerra Mundial, o desenvolvimento de foguetes, aeronaves e aviões cresceu consideravelmente. Após o término dos conflitos, com o início e a ascensão da Guerra Fria, a elaboração de novos materiais, o melhoramento de motores e a construção e utilização de naves aéreas e cósmicas sofreram grande avanço (Corrêa, Peron e Vergueiro, 2018).

Atualmente, o setor aeroespacial encontra-se em progresso no campo da inovação e tem reivindicado novas demandas relacionadas a custos, agilidade, eficiência e sustentabilidade, impulsionando o uso de tecnologias como a inteligência artificial. A indústria tem promovido o desenvolvimento de diversas áreas, dentre as quais se destaca a otimização do consumo de combustível, tema que tem despertado interesse crescente nas investigações da área (Singh e Sharma, 2015). Ademais, o setor combina avanços multidisciplinares em propulsão, automação, sistemas de localização e materiais, com o objetivo de melhorar a eficiência e o desempenho das naves.

1.1.2 Princípios físicos e navegação aeroespacial

A aerodinâmica é o estudo do movimento de corpos materiais no ar e as forças agentes sobre eles (Nasa, 2023). O funcionamento das aeronaves fundamenta-se nas leis da aerodinâmica básica, que descrevem a interação entre as quatro principais forças atuantes no voo — peso, sustentação, arrasto e empuxo.


A força peso refere-se ao produto da massa da nave e da força gravitacional que opera verticalmente para baixo sobre a aeronave; a sustentação é a força contrária ao peso que permite o nivelamento e a variação de altitude durante o voo. O empuxo é produzido pelos motores (turbofans, turbojatos, turboélices e motores a pistão), que impulsionam o veículo para frente e fornecem a velocidade necessária para as asas desenvolverem sustentação. O arrasto aerodinâmico é a força de resistência oposta ao movimento da aeronave e resultado do atrito com o ar e com as correntes induzidas pela geração de sustentação (Nasa, 2022).

Figura 1 - Aerodinâmica da aeronave

Fonte: Adaptado de Nasa, 2022, n.p.

O sistema de navegação aérea integra princípios da física e tecnologias eletrônicas. Para orientarem-se com exatidão, os aeródinos utilizam sistemas de navegação inercial (INS) — acelerômetros e giroscópios — que usufruem de leis clássicas do movimento para o cálculo de posições (Koifman e Bar-Itzhack, 1999); receptores GNSS (Sistema Global de Navegação por Satélite), que empregam sinais de satélite e princípios de trilateração para determinar coordenadas (Hegarty e Chatre, 2008); sistemas automáticos que processam esses dados e mantêm a aeronave na rota planejada, garantindo precisão e segurança operacional em todas as condições meteorológicas e regiões do globo terrestre (Moallemi e Towhidnejad, 2016).

Durante o lançamento de foguetes, o veículo está sujeito a ação de forças aerodinâmicas; o seu principal desafio é superar o peso e o arrasto através do empuxo produzido pelos motores e atingir a velocidade necessária para entrar em órbita.

Figura 2 - Aerodinâmica do foguete

Fonte: Adaptado de Nasa, 2023, n.p.


Ao atingir o espaço sideral, a espaçonave segue uma órbita previsível, regida pelas leis da astrodinâmica — definida como “o estudo do movimento de objetos feitos pelo homem no espaço, sujeitos a forças naturais e induzidas artificialmente” (Griffin e French, 1991 apud Vallado, 2013, p. 27). Assim, a trajetória da nave é determinada principalmente pelas leis de Newton e de Kepler, que determinam o movimento de um objeto em relação a um astro. O caminho percorrido por um corpo em órbita é, em geral, descrito por equações de cônicas (círculo, elipse, parábola, hipérbole).

A orientação de uma nave espacial se dá através de rastreamento feito por sensores a bordo, como rastreadores solares e de estrelas, giroscópios e acelerômetros, e por estações terrestres que enviam sinais de rádio para a nave. Além disso, muitas astronaves utilizam navegação autônoma, observando corpos celestes para estimar sua localização e, com base nessas informações, ajustar seu direcionamento, corrigindo a trajetória para a execução de manobras adequadas (Nasa, 2025)

1.2 Redes neurais artificiais


Segundo Herculano-Houzel (2012), o cérebro humano possui, em média, 86 bilhões de neurônios. Com isso, o órgão é capaz de processar uma grande quantidade de informações em tempo mínimo. A unidade de processamento do cérebro é o neurônio e por meio dele as informações são transmitidas e processadas.

Figura 3 - Neurônio biológico



Fonte: Infoescola, 1996, n.p.

Figura 4 - Neurônio artificial




Fonte: Medium, 2017, n.p.

Segundo Haykin (1999), uma rede neural artificial (ANN) é um método de inteligência artificial (IA) que ensina computadores a processarem dados de forma inspirada no funcionamento do cérebro humano. Trata-se de um tipo de machine learning (ML), conhecido como aprendizado profundo, que utiliza neurônios artificiais (nós) interconectados em uma estrutura em camadas. Cria-se um sistema adaptativo, no qual os computadores aprendem com os erros e se aprimoram continuamente.

ANNs são capazes de resolver problemas complexos, como resumir documentos ou reconhecer rostos com alta precisão. Atualmente, as aplicações dessa tecnologia são inúmeras: auxiliam diagnósticos médicos, marketing direcionado, previsões financeiras, controle de qualidade, identificação de compostos químicos, entre outros. Com seu aprimoramento contínuo, a tecnologia caminha para moldar um futuro em que estará integrada a praticamente todos os setores da sociedade (Souza, 2011).

Como se pode analisar na figura abaixo, o funcionamento de toda e qualquer rede neural baseia-se em uma estrutura de camadas: camada de entrada, camada oculta, camada de saída. Estas camadas, interconectadas entre si, transmitem dados, ativando e desativando funções coordenadas por algoritmos programados (Cloudflare, 2025).

Figura 5 - Rede neural




Fonte: Cloudflare, 2025, n.p.

1.2.1 Modelo pioneiro

O conceito de rede neural artificial surgiu em 1943, com Warren McCulloch e Walter Pitts. Eles criaram um modelo simples de rede neural utilizando circuitos elétricos. O projeto representou grandes avanços para a época, tanto no campo biológico, ao permitir uma melhor compreensão dos processos cerebrais, quanto no âmbito tecnológico (Nascimento, 2023).

Documentado pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo em 2009, a unidade de processamento da rede, denominada Neurônio Artificial de McCulloch-Pitts, tem seu processamento representado na figura a seguir. De forma simplificada, o funcionamento deste nó acontece da seguinte forma e ordem: a camada de entrada recebe sinais; cada sinal é multiplicado por um número de acordo com seu peso, o que determina sua influência na saída; efetua-se a soma ponderada dos sinais, produzindo um nível de atividade; caso esse nível de atividade exceda um determinado limite (threshold), o nó responde.

Figura 6 - Neurônio Artificial de McCulloch-Pitts

Fonte: Souza, 2011, n.p.


1.2.2 Principais tipos

Não existe um limite para quantidade de camadas de entrada, ocultas ou saída. Dessa forma, diferentes tipos de ANNs foram desenvolvidos ao longo dos anos, cada modelo treinado para uma função específica, seja detecção de texto ou cálculos matemáticos. Embora não haja um número definido de tipos, de modo grosseiro, as ANNs podem ser classificadas em duas categorias: redes neurais rasas e redes neurais profundas. Respectivamente, redes que costumam ter apenas uma camada oculta e redes que têm várias camadas ocultas (Databricks, 2024).

1.2.2.1 Perceptron

A forma mais simples de configuração de uma ANN é aquela denominada perceptron. A sua simplicidade está ligada ao fato de se constituir de apenas uma camada neural, possuindo somente um nó nesta camada. Foi idealizada pelo psicólogo estadunidense Rosenblatt em 1958.

Figura 7 - Rede neural perceptron




Fonte: Cloudflare, 2025, n.p.

Em termos matemáticos, o processamento interno realizado pela unidade de processamento do perceptron é descrito pelas seguintes expressões numéricas:

$$u = \sum_{i=1}^n w_i \cdot x_i - \theta$$

$$y = g(u)$$

Figura 8 - Neurônio Artificial perceptron




Fonte: Medium, 2017, n.p.

1.2.2.2 Feed-foward

Na rede neural feedforward (FFNN), cada camada se conecta à próxima camada, porém não há caminho de volta. Portanto, todas as conexões possuem a mesma direção, no sentido que parte da entrada até a saída (André, 2012).


Figura 9 - Rede neural feed-forward



Fonte: Cloudflare, 2025, n.p.

1.2.2.3 Convolucionais


As redes neurais convolucionais (CNNs) são ANNs especializadas em processamento e análise de dados visuais, como imagens e vídeos. Esse tipo de rede é mais usado em tarefas de classificação e visão computacional. A CNN é uma importante ferramenta de IA justamente pela sua capacidade de reconhecer padrões complexos em dados (Ionos, 2024).

Figura 10 - Rede neural convolucional

Fonte: Ionos, 2024, n.p.

1.2.2.4 Recorrentes

Segundo Abid (2024), as redes neurais recorrentes (RNNs) são um tipo de rede neural frequentemente utilizada no processamento de linguagem natural e no reconhecimento de fala. Um ponto importante na RNN é que ela possui uma memória interna que se lembra de entradas anteriores. É o tipo de ANN utilizada em assistentes virtuais como a Siri, da Apple, e em pesquisas por voz, como a do Google (DataCamp, 2024).


Figura 11 - Rede neural recorrente

Fonte: Cloudflare, 2024, n.p.

1.2.2.5 Transformer

Chamados de “modelos de fundação” por pesquisadores de Stanford, a rede neural transformer (TNN) aprende o significado por meio do contexto, realizando o monitoramento de relações em dados sequenciais. A TNN está entre os mais novos e potentes modelos de ANN já inventados até hoje. Para detectar a influência e dependência de elementos distantes em uma série, o modelo aplica um conjunto em evolução de técnicas matemáticas, chamadas de atenção ou autoatenção. Foram descritos pela primeira vez em um artigo de 2017 do Google (Merritt, 2022).

Figura 12 - Rede neural transformer



Fonte: Nvidia, 2024, n.p.

1.2.2.6 Quântica

Publicado por Santos (2016), as redes neurais quânticas (QNNs) são um modelo de ANN que combina a Computação Quântica com propriedades das ANNs. Por unirem as vantagens da superposição quântica das informações ao processamento paralelo das redes neurais, as QNNs possuem grande potencial. Porém, ainda não existe na literatura uma definição formal do que constitui uma QNN.

As primeiras ideias sobre QNNs foram publicadas em 1995 por Subhash Kak e Ron Chrisley, sua teoria baseia-se na combinação de modelos de ANNs clássicos com as

vantagens da computação quântica, em função do desenvolvimento de algoritmos eficientes (Medium, 2023).

A maioria das QNNs são desenvolvidas como FFNNs, em que, de forma similar à sua conjugada clássica, recebe a entrada de uma camada de qubits e a repassa para outra camada de qubits — essa camada de qubits avalia essas informações e repassa a saída para a próxima camada. Eventualmente, o caminho leva à camada final de qubits. (Gomes et al., 2024).

1.2.3 Inteligência Artificial

Em 1956, John McCarthy foi o primeiro pesquisador a utilizar a expressão “Inteligência Artificial”, em Dartmouth College durante a Dartmouth Conference, em New Hampshire nos EUA. McCarthy definiu a IA como “Fazer a máquina se comportar de tal forma que seja chamada inteligente caso fosse este o comportamento de um ser humano.” (ACATE, 2021). Isso ocorreu dois anos após a morte de Alan Turing, nascido em 1912 na Inglaterra, considerado o pai da inteligência artificial e da computação teórica, responsável pelas primeiras pesquisas sobre IA, que datam por volta de 1950 (Lage, 2022).

Em seu artigo de 1950, “Computing Machinery and Intelligence”, Turing introduz o conceito de Teste de Turing. O teste sugere que uma máquina pode ser considerada inteligente se, durante uma conversa por texto, um ser humano não conseguir distinguir se está interagindo com uma máquina ou com outro humano.


1.3 Mecânica quântica

A Mecânica Quântica é um ramo fundamental da física com vasta aplicação. A teoria quântica fornece descrições precisas para muitos fenômenos previamente inexplicados tais como a radiação de corpo negro e a estabilidade dos átomos. Apesar de, na maioria dos casos, a mecânica quântica ser relevante para descrever sistemas microscópicos, os seus efeitos específicos não são somente perceptíveis em tal escala. A Mecânica Quântica que é tipicamente aplicada em sistemas microscópicos, permite o cálculo de propriedades e comportamentos de sistemas físicos. Sua teoria fundamental se baseia no fato de que é impossível prever com certeza o que irá acontecer (Feynman; Richard, Leighton; Robert, Sands; Matthew, 1964).

1.3.1 Conceitos fundamentais da mecânica quântica

A mecânica quântica não pode prever a localização exata de uma partícula no espaço, apenas a probabilidade de encontrá-la em locais diferentes. Matematicamente, a probabilidade é encontrada através da raiz quadrada do valor absoluto de um número complexo, conhecido como a amplitude de probabilidade, isto é segundo Max Born (1926), chamado de regra de Born. Por exemplo, uma partícula quântica como um elétron pode ser descrita por uma função de onda, que associa a cada ponto no espaço uma amplitude de probabilidade. A aplicação da regra de Born a essas amplitudes fornece uma função de densidade de probabilidade para a posição em que o elétron será encontrado quando um experimento for realizado para medi-lo. Isso é o melhor que a teoria pode fazer; ela não pode dizer com certeza onde o elétron será encontrado.

Segundo Clarendon Press (1978), uma consequência das regras matemáticas da mecânica quântica é o fenômeno da interferência quântica, que geralmente é demonstrado pelo experimento da dupla fenda. Ele acontece quando um feixe de luz atravessa duas fendas e cria um padrão de interferência, que só pode ser explicado por sua natureza de onda. O experimento desafiou a visão clássica de que a matéria é sempre uma partícula e não uma onda, e levou ao entendimento de que as partículas podem exibir um comportamento semelhante a uma onda sob certas condições. A distribuição de elétrons, que inicialmente parece aleatória, na verdade forma um padrão. Este padrão é resultado da interferência construtiva e destrutiva das ondas. Quando o padrão não é observado, as partículas exibem comportamento semelhante a uma onda, passando por ambas as fendas e interferindo umas nas outras. Esse fenômeno, conhecido como princípio da complementaridade, sugere que as partículas não podem exibir comportamento corpuscular e ondulatório ao mesmo tempo.

Figura 13 - Funções de onda do elétron do átomo de Hidrogênio

Fonte: Kyle Forinash, 2008, n.p.

A figura acima representa a descrição matemática do estado quântico de um sistema quântico isolado — as funções de onda do elétron em um átomo de hidrogênio em diferentes níveis de energia. As áreas mais brilhantes representam uma maior probabilidade de encontrar o elétron.

1.3.2 Computação quântica

Computação Quântica é uma área da tecnologia que explora os fenômenos da mecânica Quântica. Em pequena escala, a matéria física apresenta ao mesmo tempo propriedades de partículas e de ondas. A computação quântica a partir da Lei de Moore se aproveita disso através de hardwares especializados. A física clássica não consegue explicar o funcionamento dos dispositivos quânticos e como conseguem realizar operações de formas exponencialmente mais velozes do que a computação clássica (Moore; Gordon, 1965) .

A unidade de informação utilizada na mecânica quântica é o qubit (ou bit quântico). No entanto, ao contrário de um bit clássico, que pode estar em um de dois estados (binário, 0 e 1), um qubit pode existir em uma superposição de seus dois estados "básicos", um estado que está, em um sentido abstrato, "entre" os dois estados básicos. Ao medir um qubit, o

resultado é uma saída probabilística de um bit clássico. Se um computador quântico manipula o qubit de uma maneira específica, os efeitos de interferência de onda podem amplificar os resultados de medição desejados. O projeto de algoritmos quânticos envolve a criação de procedimentos que permitem que um computador quântico realize cálculos de forma eficiente e rápida.

Ruído quântico, conforme cunhado por J. Verdeyen (1995), refere-se a uma das perturbações indesejadas que afetam os sistemas quânticos, levando a erros na computação quântica. Ao contrário do ruído clássico, que pode simplesmente adicionar erros aleatórios a um sinal, além disso pode ter efeitos mais complexos e prejudiciais. É um grande desafio no desenvolvimento de computadores quânticos, pois pode fazer com que os qubits percam seu delicado estado quântico, conhecido como decoerência. Ele pode surgir de várias fontes, incluindo flutuações térmicas, interferência eletromagnética, imperfeições em qubits quânticos e interações com o ambiente. Diferentes tipos afetam os qubits de maneiras distintas. Por exemplo, o ruído de fase altera a fase relativa entre os qubits de base de um qubit, enquanto o ruído de amplitude afeta as probabilidades de medir diferentes estados. Compreender e caracterizar essas fontes de ruído é crucial para a mitigação de erros.

O ruído quântico representa uma barreira significativa para o desenvolvimento de computadores quânticos tolerantes a falhas em larga escala. Mesmo pequenas quantidades de ruído podem levar à decoerência, fazendo com que os qubits percam suas propriedades de superposição e emaranhamento (Clark; Aashish, 2021). Essa perda de informação quântica pode tornar as computações sem sentido e limitar o tamanho e a complexidade de algoritmos quânticos viáveis. Além disso, também complica a implementação de esquemas de correção de erros, pois a correção de um tipo de erro pode inadvertidamente introduzir outros.

Os esforços para mitigar o ruído incluem a melhoria do isolamento físico dos qubits, o desenvolvimento de técnicas de controle mais precisas e a implementação de códigos de correção de erros quânticos (Rudolf F, 1996). A pesquisa para compreender sua natureza e desenvolver métodos para reduzi-lo ou corrigi-lo está em uma área ativa e vital da computação quântica. Alguns algoritmos, como o Algoritmo de Otimização Quântica Aproximada, são projetados para serem mais resilientes ao ruído, tornando-os adequados para dispositivos quânticos de curto prazo.

1.3.3 Algoritmo de otimização quântica aproximada

Algoritmos de otimização quântica, segundo seu criador Edward Farhi (2023), são utilizados para resolver problemas de otimização. A otimização matemática busca a melhor solução para um certo problema de acordo com um critério a partir de um conjunto de soluções possíveis. Na maioria dos casos, problemas de otimização mitigam erros. A solução ideal tem a mínima quantidade de erros, na qual a minimização de falhas depende de qual objetivo se pretende atingir. Diferentes técnicas de otimização são aplicadas em diversas áreas do conhecimento como: engenharia, mecânica e economia, e a medida que a complexidade e a quantidade de dados envolvidos aumenta, são necessárias maneiras mais eficientes de resolver problemas de otimização.

QAOA, ou Algoritmo Quântico de Otimização Aproximada, é um algoritmo quântico-híbrido que visa encontrar soluções aproximadas para problemas de otimização combinatória. Ele combina a computação quântica com otimização clássica, usando circuitos quânticos para explorar espaços de solução e otimizadores clássicos para refinar os parâmetros do circuito (Gutmann Sam, 2014). Para problemas combinatórios, o QAOA teve uma melhor proporção de acerto para um certo problema do que qualquer outro algoritmo em tempo polinomial.

1.3.3.1 Hamiltoniano de Custo

O processo começa transformando o problema em um operador quântico que é uma representação matemática do problema de otimização, chamado Hamiltoniano de custo (H_c), em que a melhor solução corresponde ao seu menor valor de energia. O algoritmo inicia com um estado quântico simples, uma superposição onde todos os possíveis estados clássicos (ex.: $|0\rangle$ e $|1\rangle$ para 1 qubit) têm a mesma amplitude de probabilidade (Benjamin C, 2023).

1.3.3.2 Hamiltoniano de Mistura

Segundo os trabalhos de Qi Chen, Kaixun Tu, Qing Wang (2024) O Hamiltoniano de Mistura é um operador de contraste que não se comunica com o H_c . É usado para transcorrer o espaço de soluções possíveis. A função principal do H_m é garantir que o algoritmo explore diferentes resultados possíveis. Se você tiver apenas o H_c sozinho, o algoritmo não sairá do estado inicial.

1.3.3.3 Porta lógica de Hadamard

O Porta Lógica de Hadamard (ou Porta Lógica Quântica) desenvolvida por Charles Bennett (1997), é uma operação quântica fundamental usada para criar uma superposição de estados de qubit. Ele transforma um qubit em um estado de superposição igual de $|0\rangle$ e $|1\rangle$, e também pode ser usado para transformar um estado de superposição de volta para um estado $|0\rangle$ ou $|1\rangle$. Um qubit em um estado clássico (0 ou 1) é transformado em uma superposição, onde ele existe em ambos os estados simultaneamente com igual probabilidade. O portão de Hadamard também permite a conversão entre a base computacional ($|0\rangle$ e $|1\rangle$) e a base de superposição ($|+\rangle$ e $|-\rangle$), essencial para certos algoritmos quânticos.

Representação pela matriz 2x2:

$$2 \times 2: H = \frac{1}{\sqrt{2}} \times [1, -1]$$

Se aplicado a $|0\rangle$, o resultado é:

$$\frac{|0\rangle + |1\rangle}{\sqrt{2}}.$$

Se aplicado a $|1\rangle$, o resultado é:

$$\frac{|0\rangle - |1\rangle}{\sqrt{2}}.$$

1.3.3.4 Constituição de Farhi

A inicialização dos qubits em um estado simples; uma escolha comum é uma superposição uniforme de todas as possíveis bitstrings (sequência finita de bits, ou seja uma sequência de $|0\rangle$ e $|1\rangle$, no qual posicionam-se todos os bits em estado $|0\rangle$ e então aplica-se o Portão de Hadamard, em que transforma-se em:

$$|+\rangle = \frac{|0\rangle + |1\rangle}{\sqrt{2}}.$$

Isso é o estado inicial $|s\rangle$, que é uma mistura igual de todas as soluções de 2^n para um problema de n-qubit. Dando ao algoritmo uma folha em branco de possibilidades (Farhi, 2014).

Aplicação do Hamiltoniano de Custo por um período γ , que na computação quântica significa aplicar a operação unitária:

$$Uc(\gamma) = e^{-\gamma i H_c}$$

($e \approx 2,718$)

Isto é uma "evolução de fase" do estado de acordo com a função de custo. Estados (bitstrings) com custo mais alto (soluções piores) captam fases diferentes dos estados com custo mais baixo (Marin Ivezic, 2024). Essa etapa às vezes é chamada de separador de fases ou unidade do problema, e γ é um parâmetro ajustável (frequentemente chamado de ângulo de fase).

Aplicação do Hamiltoniano de Mistura por um período — outra operação unitária:

$$Um(\beta) = e^{-\gamma i H_m}$$

por um período β , $Um(\beta)$ é essencialmente uma rotação de cada qubit em torno do eixo X por um ângulo. Isso tem o efeito de misturar a amplitude entre os estados $|0\rangle$ e $|1\rangle$ para cada qubit – em outras palavras, permite que o estado explore diferentes configurações de bits, é outro parâmetro ajustável (frequentemente chamado de ângulo de mistura).

Com a repetição dessas aplicações, escolhe-se um inteiro positivo p , que é o número de camadas do circuito QAOA. Cada camada consiste em uma aplicação H_c seguida por uma aplicação H_m . Quanto maior o p , mais complexo o estado resultante pode ser, pois estamos dando ao circuito quântico mais oportunidades de entrelaçar qubits e esculpir a distribuição de probabilidade das soluções. De fato, Farhi et al. (2016) observaram que a qualidade da solução melhora à medida que p aumenta, aproximando-se, em princípio, da solução ótima à medida que p se torna maior. No entanto, um p maior também significa um circuito mais profundo, mais difícil de executar em hardware real devido ao ruído, portanto, há uma compensação na prática.

Após isso, é medido o estado quântico para obter uma solução candidata. Após todas as camadas, medimos cada qubit na base computacional em base $|0/1\rangle$. Isso produz uma

bitstring, que é uma solução candidata para o nosso problema. Devido à forma como construímos o estado, os resultados da medição são tendenciosos para estados com menor energia sob H_c (ou seja, melhores soluções) – essa é a ideia se os parâmetros foram bem escolhidos. É possível repetir a medição várias vezes para construir estatísticas ou encontrar múltiplas soluções candidatas (BITTEL, 2021).

Ao utilizar um otimizador clássico para ajustar os parâmetros (γ, β) , é necessário utilizar uma estratégia para escolher os ângulos γ_i e β_i que usamos nesses operadores unitários. Inicialmente, pode-se apenas estimar alguns ângulos aleatórios ou usar estimativas fundamentadas (talvez ângulos pequenos ou ângulos inspirados em resultados conhecidos relacionados). Em seguida, avalia-se a qualidade do estado resultante. Normalmente, é possível calcular o valor esperado do hamiltoniano de custo:

$$\langle \psi(\gamma, \beta) | H_c | \psi(\gamma, \beta) \rangle$$

A equação acima representa o valor esperado de um H_c para um estado quântico ψ , onde ψ (Psi) é um estado que depende de parâmetros (γ, β) , no contexto da mecânica quântica. Esta notação é usada para descrever a média de um H_c em um estado específico, e os parâmetros (γ, β) indicam que o estado ψ pode ser uma função de variáveis que são ajustadas, como em um sistema dinâmico ou com parâmetros de controle.

A partir de muitas medições é atingido uma estimativa do objetivo de custo médio para o estado quântico atual. O objetivo é maximizar essa expectativa, se for definida como expectativa alta significando boa qualidade da solução, ou minimizá-la, se menor energia significando melhor, dependendo da formulação. Um algoritmo clássico ajusta então o γ e parâmetros β para tentar maximizar o valor de expectativa. É realizada uma operação na qual há a execução do circuito quântico com os parâmetros atuais, é calculada a expectativa de custo e então são atualizados os parâmetros para uma expectativa melhor. Com o tempo, espera-se que os parâmetros convirjam para um conjunto que produza um estado com alta concentração de boas soluções. Uma vez otimizado, realizamos uma medição final do estado quântico para gerar uma solução.

2 CONSUMO DE COMBUSTÍVEL E REDES NEURAI

Uma vez definidos os principais conceitos que circundam o setor aeroespacial e computacional, com foco em redes neurais e em mecânica quântica, é possível entender a aplicação e a intersecção desses temas. Portanto, nesta seção do presente trabalho, serão introduzidos os fatores e os métodos relacionados à otimização do consumo de combustível em veículos aeroespaciais, que incluem o projeto das naves e os tipos de combustível utilizados nesses meios de transporte, e será desenvolvido mais a fundo o conceito de inteligência artificial e rede neural, apresentando suas aplicações no setor estudado.

2.1 Fatores impactantes no consumo de combustível

No contexto de um mundo globalizado, o setor aeroespacial é afetado diretamente por aspectos diversos em todo o mundo, que vão desde a extração da matéria-prima das naves até as regulamentações político-econômicas de funcionamento e vendas. Singh e Sharma (2015) elencaram dimensões da OCC que causam efeitos diretos e indiretos no consumo de combustível, tendo base em um levantamento bibliográfico focado no consumo de combustível dentro da aviação. Este capítulo busca inserir alguns desses elementos na perspectiva de uma indústria que integra o transporte aéreo e espacial.

2.1.1 Tecnologia aeroespacial


A maior parte do ganho em OCC se dá, principalmente, através da melhoria tecnológica da nave (Singh e Sharma, 2015). Tal aprimoramento ocorre, sobretudo, por meio de três fatores: peso estrutural, aerodinâmica e eficiência específica do combustível e do motor (Grote, Williams e Preston, 2014).

De maneira geral, o refinamento do projeto de design da nave e das práticas operacionais, em solo, ar e espaço cósmico, é o ponto chave da otimização do consumo de combustíveis em veículos aéreos e espaciais. A eficiência operacional é potencializada mediante uma análise precisa de rotas e do clima, um projeto de design apurado, uma interação combustível-motor rentável e a maximização do rendimento da relação carga útil-combustível (Singh e Sharma, 2015).

2.1.1.1 Eficiência estrutural e operacional na aeronáutica

Perez e Martins (2008) analisaram a estrutura conceitual do projeto do aeródino pyACDT (Caixa de ferramentas para projeto conceitual de aeronaves em Python), que abarca diversos módulos sobre as principais análises disciplinares importantes na realização do projeto conceitual, com o objetivo de melhorar, sobretudo, o desempenho ambiental do veículo.

Figura 14 - Módulos da pyACDT



Fonte: Advanced Aircraft Design Lab Royal Military College of Canada, 2024, n.p.

O intuito dos problemas de otimização multidisciplinar de projeto que o estudo apresenta é encontrar configurações aprimoradas e adequadas para aeronaves, baseadas em critérios econômicos, operacionais e ambientais. A pesquisa considerou variáveis de geometria da nave, parâmetros do motor e configurações do cruzeiro. A conclusão foi de que as naves otimizadas para minimizar o consumo de combustível possuem asa de alta razão de aspecto, motores com alta razão de bypass e alta pressão e temperatura no núcleo do motor. Além disso, avaliaram a projeção de aeronaves maiores para curtas distâncias e os resultados evidenciaram que pode-se adquirir a diminuição do peso estrutural através da redução do consumo de combustível (Perez e Martins, 2008).

Atualmente, as práticas operacionais nem sempre são reguladas visando a OCC, o que expõe a necessidade de melhorias relativas à eficiência operacional. Essa eficiência busca aproximar o consumo real de combustível ao mínimo teórico possível. O aumento do fator de carga, a otimização da velocidade e do peso do combustível, a limitação do uso de energia


auxiliar, a eliminação de pesos desnecessários e a redução do peso de taxiamento são importantes estratégias para reduzir o consumo por passageiro-km (Singh e Sharma, 2015).

Ademais, sistemas de planejamento de voo são úteis para melhorar a eficiência do combustível, pois permitem o bom proveito das condições climáticas, o cálculo preciso de cargas de combustível e o estudo de diferentes níveis de voo e velocidade, garantindo um voo mais econômico e uma melhor performance do avião. Os modelos de aperfeiçoamento de trajetórias também apresentam redução no impacto ambiental e melhoria na OCC, apesar das restrições impostas pelo controle do tráfego aéreo priorizarem a segurança (Singh e Sharma, 2015).

2.1.1.2 Eficiência estrutural e operacional na astronáutica

A configuração das astronaves e dos foguetes pode ser otimizada para aumentar a eficiência, melhorar o controle da trajetória e economizar combustível. Harris, Ele e Abdelkhalik (2024) estudaram uma estrutura de co-projeto de controle para incrementar o trajeto seguido pela astronave e o motor do foguete. A estrutura consiste em um software de código aberto e um componente físico do sistema: o cálculo de trajetória se baseia na GMAT (ferramenta de análise de missão geral) e o objeto físico se trata de um modelo de motor de foguete. Foi utilizado o OpenMDAO (Análise e Otimização de Design Multidisciplinar Aberto) para conectar os elementos de controle e físico para a otimização do co-projeto. A conclusão foi de que as otimizações de motor e trajeto acoplados apresentam entre 16% e 20% mais redução no consumo de combustível do que as otimizações tradicionais de trajetória e motor independentes.

Figura 15 - Análises feitas por OpenMDAO



Fonte: GitHub, 2021, n.p.

Em termos estruturais, os foguetes buscam uma alta relação resistência/peso, pois quanto maior for seu valor, maior será o empuxo gerado pelos motores do veículo de propulsão. Assim, é possível refinar o consumo de combustível e viabilizar o transporte de mais carga útil sem comprometer a integridade estrutural do foguete. Na área operacional, tem-se estudos sobre a modelagem matemática de trajetórias percorridas por foguetes, que foi simplificada e detalhada em estudos sobre minifoguetes (Alves, Bento e Marchi, 2021, 2023). Porém, o cálculo matemático de trajetórias se estende também aos veículos feitos para atuar exclusivamente no espaço sideral, atuando em cosmonaves com sistemas computacionais avançados integrados que operam na previsão e execução de manobras certas em órbita (Du et al., 2024).

Devido à queima de propelentes, o foguete suporta níveis de ruído sonoro intensos, o que caracteriza outro fator importante para a sua eficiência estrutural e, consequentemente, operacional. Assim, faz-se necessário um controle requintado das cargas acústicas para preservar a construção do foguete (Neto, Reis e Wehmann, 2022).

2.1.2 Combustíveis alternativos

A propulsão aeronáutica fundamenta-se na atuação dos combustíveis utilizados nos aeródinos. Os principais tipos são o QAV, como o Jet-A e o Jet-A1, utilizado em motores a jato e turboélices, e a Avgas, usada especialmente em motores a pistão. Ambos os tipos de combustível são oriundos de fontes fósseis e apresentam alta contribuição na emissão de poluentes (Bishop e Elvers, 2019).

Nesse cenário, os combustíveis alternativos de aviação procuram preencher as lacunas deixadas pelos combustíveis tradicionais. O desenvolvimento desse tipo alternativo de combustível é motivado, acima de tudo, por fatores econômicos e ambientais, e pela variedade e concorrência relativas aos recursos energéticos (Hileman e Statton, 2014 apud Singh e Sharma, 2015). Destacam-se, dentro desse grupo de combustíveis, os combustíveis sustentáveis de aviação (SAFs), que utilizam matérias-primas renováveis e possuem propriedades similares ao querosene fóssil. Atualmente, enfrentam desafios relacionados a custo e disponibilidade.

Em veículos de lançamento, a interação combustível-motor visa superar atingir o espaço celeste. Os combustíveis de foguetes se dividem em três grupos principais: líquidos, sólidos e híbridos. Os tipos de propelente mais comuns em foguetes, são o LH2, o RP-1, e a

hidrazina, em conjunto com os oxidantes utilizados na combustão, como o LOX (Kapitonova e Bullock, 2023)

Os combustíveis convencionais de foguetes ainda apresentam impasses relativos ao potencial econômico, ambiental e de eficiência. Portanto, uma análise do uso de propelentes menos comuns pode ser a chave para viagens ao espaço mais rentáveis e sustentáveis (Kapitonova e Bullock, 2023).

2.2 Inteligência Artificial

Como mencionado, as ANNs estão revolucionando a IA e possibilitando aplicações incríveis em áreas como reconhecimento de imagens, linguagem natural e robótica. Aprendem padrões complexos a partir de um banco de dados bruto, resolvendo problemas antes impossíveis. Cada tipo de ANN, com sua estrutura específica adaptada para executar determinada tarefa e lidar com diferentes problemas, é o que possibilita o grande número de aplicações desta tecnologia no mundo humano (Spadini, 2024). Dessa forma, analisar-se-ão as aplicações da IA composta de ANNs clássicas no setor aeroespacial no que se diz respeito a OCC, respeitando as circunstâncias avaliadas, desde o design das aeronaves até o cálculo de rotas. Assim, posteriormente, serão apresentados os efeitos da integração de princípios quânticos na ANN para potencializar o êxito na eficiência na OCC.

2.2.1 Aplicação

De acordo com Almeida (2021), as décadas de 1980 e 1990 testemunharam a implantação da IA na aviação. Com capacidade de aprender e generalizar, adquirindo e acumulando conhecimento em seu ambiente com técnicas de ML, a IA tem sido um elemento crucial em diversos setores, e o setor aeroespacial não é exceção. As aplicações dessa tecnologia na indústria de aviões e foguetes são vastas, indo do design de aeronaves, passando pelo melhoramento da navegação e do gerenciamento de tráfego até a melhoria do conforto da cabine e do suporte ao cliente (Cadence, 2025).

Figura 16 - Áreas em que a IA pode ser aplicada no setor das companhias aéreas



Fonte: Vina, 2024, n.p.

Por exemplo, o controle do tráfego aéreo antes das IAs era totalmente manual, o que exigia grande atenção dos controladores. A capacidade da IA de associar dados de entrada carregando informações sobre diferentes circunstâncias, como modelo de aeronave, tipo de combustível, destino, peso e entregar um cenário ideal como saída de forma rápida e eficaz é o que a diferencia de qualquer outro cérebro humano.

A implementação de rotas de voo otimizadas por IA pela British Airways no início de 2023 resultou em uma economia notável de 100.000 toneladas de combustível — o equivalente a US\$ 10 milhões em redução de custos. [...] A parceria da Southwest Airlines com a startup de IA AIXI demonstra essa evolução, na qual a inteligência artificial agora auxilia engenheiros na detecção de defeitos em uma frota de 800 aeronaves, agilizando as operações de manutenção que antes eram totalmente manuais (Lisowski, 2025, n.p.).

2.2.1.1 Cálculo de rotas

A otimização de rotas pode ser entendida como a maneira mais rápida e eficiente de ir de A a B, considerando todos os fatores que podem afetar o trajeto, tais como peso e distribuição de carga, condições meteorológicas e ventos, altitude, arrasto aerodinâmico e design de aeronave, eficiência do motor e tipo de combustível, dados históricos, força gravitacional, velocidade de exaustão, entre outras circunstâncias englobadas (Mighy, 2024).

Com um algoritmo de ML analisando todos esses dados, é possível otimizar rotas e cronogramas de voo, resultando em operações mais eficientes e econômicas (Amtec, 2024).

A empresa Air Space Intelligence desenvolveu um sistema que cria planos de voo que economizam combustível e tempo que está sendo usado pela companhia aérea Alaska Airlines. A piloto da companhia Pasha Saleh afirma: “Todas as rotas são feitas sob medida agora. São rotas que, em muitos casos, nunca existiram antes e levaria um ser humano 30, 40 minutos para descobri-las” (Pancini, 2021, n.p.). Em apenas seis meses de teste, a companhia economizou 500.000 galões de combustível.


O vice-presidente de serviços de tecnologia da informação da aérea, Vikram Baskaran disse: “É parecido com o Google Maps, só que no ar [...] Esse aprimoramento acumulado resultou em uma economia de 41 mil minutos e quase dois milhões de litros de querosene” (Weed, 2024, n.p.). O sistema baseado em IA da Alaska Airlines checa as condições meteorológicas, a possibilidade de fechamento de algum espaço aéreo e todos os planos de voo comerciais e particulares registrados na Administração Federal de Aviação horas antes da decolagem a fim de sugerir as rotas mais eficientes.

2.2.1.2 Manutenção preditiva

Outra aplicação da IA na indústria aeroespacial é o monitoramento contínuo com objetivo de antecipar falhas e otimizar operações. Uma combinação de sensores inteligentes e técnicas de ML com ANNs identifica sinais sutis de anomalias e prevê comportamentos futuros com alta precisão. Para Loureiro et al. (2024, p. 7): “Embora existam desafios, como a necessidade de dados de alta qualidade e a resistência cultural à adoção tecnológica, a manutenção preditiva tem estabelecido um novo paradigma industrial [...]”.

Todo veículo, como qualquer máquina, necessita de manutenção. Ao seguir um plano de manutenção, assegura-se que haverá menos contratempos com as operações. A imagem abaixo ilustra esse plano. Em um gráfico de dois eixos, o eixo vertical representa a performance do equipamento e o eixo horizontal do tempo de operação do equipamento. A curva inicia-se no ponto de falha potencial (P) indo até a falha funcional (Rodrigues, 2023).

Figura 17 - Curva PF



Fonte: Rodrigues, 2023, n.p.

Considerando o uso de ANN para aprender o padrão de falhas recorrentes em aeronaves, o plano de manutenção é automatizado e diminui drasticamente as chances de alcançar uma falha funcional completa. Dessa forma, protege-se o veículo de possíveis erros humanos que podem causar maior gasto de combustível, como panes de motor, vazamentos no sistema e imprecisões (ABRAMAN, 2022).

Figura 18 - Manutenção Assistida por IA



Fonte: ABRAMAN, 2022, n.p.

2.2.1.3 Otimização de projeto

A IA está revolucionando o projeto de veículos aeroespaciais ao possibilitar encontrar a geometria aerodinâmica ideal, criar simulações de voo cada vez mais condizentes com a

realidade, identificar os materiais com condições ideais, automação de tarefas no processo projetista, entre outras possibilidades envolvendo design de projeto (Visure, 2025). Como afirma Máximo (2024, n.p.):

A Inteligência Artificial está abrindo novas possibilidades para o design de aeronaves, tornando-o mais eficiente, inovador e sustentável. Ao aproveitar o poder da IA, os engenheiros podem criar aeronaves mais seguras, mais leves e mais eficientes, contribuindo para um futuro mais sustentável para a aviação. No entanto, é fundamental que a implementação da IA seja feita de forma responsável e segura, garantindo que os benefícios dessa tecnologia sejam maximizados e os riscos minimizados.

Em janeiro de 2025, a britânica Monolith, empresa de software de IA para engenharia, informou que começou a trabalhar com a sua conterrânea Vertical Aerospace, empresa de tecnologia aeroespacial para aviação de emissão zero. A parceria entre as empresas tem o objetivo de desenvolver uma aeronave elétrica para mobilidade aérea (podem ser também chamados de “carros voadores”) denominada VX4 (Basseto, 2025). A empresa de aeroespacial Vertical Aerospace pretende usar a Monolith para acelerar o desenvolvimento da VX4 usando IA para análise de design e simulações mais eficientes.

Figura 19 - Aeronave VX4



Fonte: Divulgação Vertical Aerospace¹, 2025, n.p.

Dessa forma, o projeto de desenvolvimento da aeronave conta com forte influência de IA. O caso evidencia a influência e tendência das empresas do setor aeroespacial de

¹ Disponível em:

<https://www.instagram.com/p/DNqJlaXWI99C/?utm_source=ig_web_copy_link&igsh=MWsyemMyejlhNDZnZA> Acesso em: 10 set, 2025.

penetrarem IA em seus processos internos no desenvolvimento de tecnologias inovadoras, como novos design para seus produtos.

2.3 Redes neurais quânticas

Um computador quântico universal é teoricamente capaz de resolver certos tipos de problemas de forma excessivamente eficiente e em um tempo átmico em relação aos computadores clássicos. Os computadores quânticos são mais rápidos que os computadores clássicos, pois utilizam a superposição, permitindo o paralelismo quântico, com muitos cálculos realizados simultaneamente. Além disso, o emaranhamento conecta os qubits, permitindo que operações em um afetem instantaneamente os outros, e os efeitos quânticos combinados permitem que eles processem problemas complexos em menos etapas do que os sistemas clássicos (IBM, 2021).

2.3.1 Emaranhamento quântico, paralelismo quântico e espaço de características de dimensão exponencial.

Paralelismo Quântico refere-se à execução de múltiplas tarefas ao mesmo tempo, ou seja, um problema com múltiplas soluções pode ter todas as suas soluções encontradas ao mesmo tempo. Por exemplo, ao tentar abrir uma fechadura: um computador clássico verificaria todas as chaves, uma a uma, para destrancar uma fechadura. Um computador quântico, graças ao paralelismo quântico, testa todas as chaves ao mesmo tempo — reduzindo significativamente o tempo necessário (QuEra, 2025).

Figura 20 - Diagrama comparativo didático




Fonte: Rede Globo, 2025, n.p.

Segundo os estudos publicados pela Empresa Chinesa **Spin Q**² em 2025, um dos princípios da mecânica quântica, aquele que torna isso possível, é o Emaranhamento Quântico. Quando qubits estão emaranhados, o espaço de estados possíveis do sistema cresce de forma exponencial a cada qubit adicionado, uma operação simples em um único qubit emaranhado afeta todo o estado do sistema instantaneamente. Um sistema com n qubits tem 2^n estados possíveis. Uma única operação quântica age sobre todos os 2^n estados — para fazer o mesmo um computador clássico precisaria de 2^n processadores trabalhando ao mesmo tempo (Ex: 10 qubits; $2^{10} = 1024$ estados). Alguns problemas, como a otimização de rotas complexas, exigem testar um grande número de combinações. Um computador clássico fica sobrecarregado rapidamente. Por exemplo, com 300 bits, há mais combinações que átomos no universo visível — ou seja, é impossível testar todas. Um computador quântico, em tese, pode explorar esse gigantesco espaço de possibilidades de uma vez, usando uma quantidade significativamente menor de qubits bem controlados (IQM, 2025).

² Fundada em 2018, empresa chinesa focada na industrialização e na popularização de computadores quânticos.

Figura 21 - Gráfico temporal computacional



Fonte: Ciência Hoje, 2019, n.p.

3 IMPACTOS DAS REDES NEURAIS QUÂNTICAS

Como tratado no capítulo anterior, as aplicações dessa tecnologia inovadora — resultante da combinação entre a física quântica e a computação — são inúmeras, possibilitando o acompanhamento integral de todas as etapas, desde o planejamento do design de veículos aeroespaciais até seu funcionamento em operação (Ransbotham; Khodabandeh, Shervin, 2022). As QNNs configuram-se, portanto, como uma tecnologia promissora que abre possibilidades astronômicas para o setor, ainda que haja muito a ser descoberto e desenvolvido para que seu uso prático se consolide.

3.1 Aplicações e benefícios

Relembra-se, então, as principais aplicações e benefícios que a tecnologia pioneira das QNNs pode oferecer ao setor aeroespacial, destacando-se a otimização de trajetórias de voo, o aprimoramento da segurança operacional e o uso mais responsável e eficiente do combustível.

3.1.1 Otimização de sistemas aeroespaciais

Entre as principais aplicações das QNNs no setor aeroespacial, destaca-se a otimização de trajetórias de voo, resultando na redução do consumo de combustível e, consequentemente, na diminuição dos custos operacionais de voos e missões espaciais. Essa economia pode ampliar o acesso a viagens comerciais e aumentar a frequência de testes com foguetes e aeronaves experimentais (Reuters, 2025). Atualmente, empresas como a americana Air Space Intelligence e a britânica Monolith, que já exploram o uso de tecnologias avançadas de aprendizado de máquina no planejamento de rotas e operações aéreas, têm obtido resultados expressivos e atraído crescente volume de investimentos.

Além disso, quanto à aplicação das QNNs em sistemas autônomos de operação e controle, ainda que seja cedo para afirmar sua viabilidade prática, o potencial é notável (Campbell et al., 2019). Uma inteligência artificial estruturada sobre fundamentos de redes neurais quânticas, com sua capacidade de realizar quase infinitas sinapses entre nós por segundo, poderia oferecer níveis de segurança e eficiência inéditos — desde que limitações atuais, como a instabilidade dos qubits, sejam superadas.

As pesquisas na área da aviação têm se concentrado, principalmente, em três eixos: segurança operacional, eficiência energética e inovação tecnológica (Carola, 2024). Desde o início do século XXI, técnicas envolvendo algoritmos de aprendizado de máquina, modelos de séries temporais, aprendizado profundo, modelagem neurofisiológica, otimização computacional, mineração de dados e máquinas de aprendizado reverso vêm sendo utilizadas para aprimorar a segurança aérea e espacial. Esses métodos têm apresentado resultados positivos em análise de dados, gestão meteorológica, prevenção de falhas e aperfeiçoamento de design de naves.

Entretanto, ainda existem limitações quanto à aplicação prática e à atuação em tempo real dessas inteligências artificiais na indústria aeroespacial, devido a imprecisões nos sistemas de apoio à decisão e à dificuldade de adaptar modelos teóricos ao ambiente real. Mesmo assim, sua implementação tem se mostrado promissora (Demir, Moslem e Duleba, 2024). Considerando o desempenho potencial dos computadores quânticos discutido nos capítulos 1 e 2, conclui-se que as redes neurais quânticas apresentam expectativas ainda mais favoráveis para o avanço da segurança aeroespacial, uma vez que possuem maior capacidade teórica para resolver problemas complexos do que os modelos clássicos de inteligência artificial — que, por si só, já têm demonstrado resultados significativos.

3.1.2 Produção e consumo sustentável de combustíveis

Acredita-se que, caso as pesquisas consigam contornar barreiras e encontrar novas maneiras de alavancar a IA, essa tecnologia será uma possível solução para grande parte dos entraves que impedem o desenvolvimento sustentável (Nishant, Kennedy e Corbett, 2020), definido como “desenvolvimento que satisfaz as necessidades do presente sem comprometer a capacidade das gerações futuras de satisfazerem as suas próprias necessidades” (WCED, 1987, n.p.).

A pegada ambiental e o custo por decolagem são afetados fortemente pelo propulsor e pelo combustível do veículo. Assim sendo, o avanço tecnológico e dos processos ligados à produção e ao consumo de combustível tornará o voo aeroespacial mais viável para as empresas privadas e os países em desenvolvimento (Kapitonova e Bullock, 2023).

Como visto anteriormente³, a utilização em larga escala dos SAFs e de propelentes de foguetes alternativos é complexa devido ao custo de produção e à indisponibilidade de

³ Tópico 2.1.2 do trabalho.

matéria-prima. No entanto, a aplicação de modelos de IA são prometedoras em pesquisas sobre conservação de recursos hídricos, conservação de energia e energia renovável e transporte sustentável (Nishant, Kennedy e Corbett, 2020). Espera-se que os modelos quânticos de redes neurais sejam, portanto, promitentes objetos de estudo para as futuras pesquisas dentro da área.

3.2 Limitações e perspectivas futuras

Para treinar os modelos de QNN, são necessários grandes volumes de dados confiáveis. No entanto, em operações aéreas, esses dados podem ser de difícil acesso, como em raros casos de acidentes em aeronaves. Quando os dados disponíveis apresentam baixa qualidade, os resultados obtidos tornam-se inseguros e pouco confiáveis. Além disso, mesmo que os sistemas apresentem excelente desempenho em simulações, eles podem falhar diante de situações inesperadas do mundo real. Na aviação, a exigência de confiabilidade é extremamente alta. Isso evidencia a dificuldade de garantir que as QNNs operem de forma consistente em condições adversas, como mudanças climáticas bruscas, falhas de sensores ou ataques cibernéticos. A utilização de QNNs pode aumentar a eficiência na gestão do tráfego aéreo e no desempenho das aeronaves, o aprendizado de máquina melhora a previsão de trajetórias e a resolução de conflitos e integração de dados otimiza a segurança e a tomada de decisões em operações aéreas. (Carlos; Juan, 2025).

3.2.1 Restrições atuais de hardware e algoritmos quânticos

Os computadores quânticos atuais possuem poucos qubits utilizáveis e eles são extremamente instáveis. Qubits são altamente suscetíveis a ruídos e interferências do ambiente, o que provoca erros nos cálculos e reduz a confiabilidade dos resultados. Essa limitação exige sistemas de correção de erros quânticos, esses que demandam ainda mais qubits, aumentando a complexidade do dispositivo. Outro problema é que a manutenção do estado quântico requer condições físicas específicas, como temperaturas próximas ao zero absoluto⁴, o que torna a tecnologia cara e difícil de ser aplicada (Zaparolli, 2021).

⁴ Temperatura mais baixa teoricamente possível, correspondendo a -273,15 °C. Ocorre quando as partículas têm a energia térmica nula e o movimento molecular para completamente.

3.2.2 Integração com sistemas clássicos: barreiras financeiras e regulatórias

Do ponto de vista da jornalista Elena Canorea (2025), a aplicação das QNNs possui custos financeiros de desenvolvimento, instalação, operação e manutenção elevados, principalmente devido à necessidade de infraestrutura altamente especializada, como sistemas de resfriamento, isolamento contra ruído e equipamentos de precisão. Isso limita o acesso à tecnologia a um poucos centros de pesquisa e grandes empresas, tornando inviável a utilização em larga escala no curto prazo.

A ausência de normas e padrões internacionais para a certificação e uso dessa tecnologia cria incertezas jurídicas e técnicas, atrasando sua aplicação. Como se trata de uma tecnologia emergente, governos e agências reguladoras ainda estão em processo de definir diretrizes para seu uso, o que gera cautela por parte de empresas e instituições interessadas em integrá-la aos seus sistemas clássicos (Harris, 2025).

3.2.3 Expansão futura da aplicação em transporte, indústria e soluções sustentáveis

A computação quântica tem potencial para transformar setores estratégicos. No transporte, pode otimizar rotas e logística, reduzindo custos, consumo de combustível e emissões. Na indústria, conforme publicado pela cientista Amir Abbas em 2024, promete revolucionar os processos produtivos, estimulando inovação e praticidade. Já em soluções sustentáveis, poderá impulsionar a transição energética com o desenvolvimento de novos catalisadores, baterias e tecnologias de captura de carbono. Dessa forma, a expansão da computação quântica aponta para um futuro mais eficiente, inovador e ambientalmente sustentável.

CONSIDERAÇÕES FINAIS

O presente estudo teve como foco a análise do uso da tecnologia resultante da convergência entre os fundamentos da física quântica e da computação: a QNN, aplicada ao setor aeroespacial. O enfoque principal recaiu sobre suas potenciais aplicações voltadas à eficiência operacional e à economia de combustível. A pesquisa foi desenvolvida a partir de apuração teórica com base em fontes acadêmicas e técnicas com autoridade na área, apresentando, no primeiro capítulo, os conceitos fundamentais das áreas que compõem o tema; no segundo, a interseção entre esses conceitos; e, por fim, no terceiro, a conclusão do estudo da aplicação desses conceitos e seus impactos na indústria.

Os resultados obtidos indicam que a integração entre QNNs e engenharia aeroespacial representa um avanço significativo em termos de desempenho e inovação tecnológica. Empresas de ponta que já investem em tecnologias semelhantes têm demonstrado progressos notáveis, reforçando o potencial dessa tecnologia para otimizar trajetórias, reduzir custos e aprimorar a segurança das missões. Entretanto, persistem desafios expressivos para sua aplicação plena, sobretudo em relação à estabilidade dos qubits, à escalabilidade dos sistemas e à adaptação de modelos teóricos à prática industrial. Assim, embora promissora, a implementação das Redes Neurais Quânticas ainda depende de avanços técnicos e científicos que possam consolidar sua viabilidade em larga escala.

Ademais, perduram-se também obstáculos relativos à sustentabilidade dentro do setor, graças aos gastos econômicos, à disponibilidade de recursos e às adaptações necessárias para a ampla fabricação de combustíveis e materiais. As Redes Neurais Quânticas apresentaram boas perspectivas para que se atinja um modelo de transporte aeroespacial mais sustentável, principalmente no âmbito energético. Porém, é necessário ainda tempo para que pesquisas relacionadas ao desenvolvimento sustentável e aos modelos de produção avancem, a fim de encontrar caminhos que viabilizem a otimização do consumo de combustíveis interligada ao crescimento sustentável.

Enfim, a utilização das QNNs no campo aeroespacial promete revolucionar a OCC, elevando os níveis de eficiência e promovendo a sustentabilidade energética no setor. Apesar dos desafios relacionados à aplicabilidade técnica e prática existentes, o crescimento da literatura acerca do assunto indica que a integração dessa tecnologia à indústria tem capacidade imensurável de transformar as práticas operacionais, econômicas e ambientais. Portanto, com dificuldades a serem superadas, a interconexão entre computação quântica e

inteligência artificial reescreve os limites tecnológicos, fazendo surgir a esperança de um futuro mais favorável a um dos setores mais relevantes do planeta, o setor aeroespacial.

REFERÊNCIAS BIBLIOGRÁFICAS

ABBAS, Amira et al. The power of quantum neural networks. **Nature Computational Science**, v. 1, n. 6, p. 403-409, 2021. Disponível em: <https://www.nature.com/articles/s43588-021-00084-1>. Acesso em: 10 Ago. 2025.

ABRAMAN. **Manutenção Assistida por IA: Como o uso de Inteligência Artificial redefine processos na Manutenção industrial**. 2022. Disponível em: <https://abramanoficial.org.br/publicacoes/noticias/pmanutencao-assistida-por-ia-como-o-uso-d-e-inteligencia-artificial-redefine-processos-na-manutencao-industrialp>. Acesso em 29 de ago. 2025.

ACATE. **O que é Inteligência Artificial?** 2021. Disponível em: <https://www.acate.com.br/blog-da-acate/o-que-e-inteligencia-artificial/>. Acesso em 26 de ago. 2025.

ALMEIDA, Idlom Fernando dos Reis. **O uso da inteligência artificial aplicada à aviação de médio e pequeno portes e a sua contribuição para segurança de voo**. 2021. Trabalho de Conclusão de Curso (Graduação em Ciências Aeronáuticas) – Pontifícia Universidade Católica de Goiás, Escola de Gestão e Negócios, Goiânia, 2021. Disponível em: <https://repositorio.pucgoias.edu.br/jspui/handle/123456789/2173>. Acesso em: 2 de set. 2025.

ALVES, André Luíz; BENTO, Sérgio Souza; MARCHI, Carlos Henrique. Movimento Vertical de Minifoguetes: Equações de Trajetórias e Análises Gráficas. **Revista Brasileira de Ensino de Física**, v. 43, p. e20200479, 2021. Disponível em: <https://www.scielo.br/j/rbef/a/bhDT7KJ9Sj8jHvNjFYFBzrh/?format=html&lang=pt>. Acesso em: 22 Ago. 2025

ALVES, André Luís; BENTO, Sérgio Souza; MARCHI, Carlos Henrique. Soluções analíticas e numéricas para o movimento vertical de um minifoguete. **Revista Brasileira de Ensino de Física**, v. e20230229, 2023. Disponível em: <https://www.scielo.br/j/rbef/a/RqQY3t6pmfhqbVxzjX9z9Yh/?format=html&lang=pt>. Acesso em: 22 Ago. 2025

AMTEC. **The Future is Automated: How AI is Shaping Aerospace Careers**. 2024. Disponível em: <https://www.amtec.us.com/blog/the-future-is-automated-how-ai-is-shaping-aerospace-careers>. Acesso em 5 de set. 2025.

ANAC. **Aeronave**. 2008. Disponível em: <https://www2.anac.gov.br/anacpedia/por-ing/tr1227.htm>. Acesso em: 13 Jul. 2025

ANAC. **Nave espacial**. 2008. Disponível em: <https://www2.anac.gov.br/anacpedia/por-esp/tr915.htm>. Acesso em: 13 Jul. 2025

ARTHUR, D. W. CTH Baker, The Numerical Treatment of Integral Equations (Clarendon Press; Oxford University Press, 1978), xiv+ 1034 pp., £ 22–50. **Proceedings of the Edinburgh Mathematical Society**, v. 22, n. 1, p. 67-67, 1979. Disponível em <https://www.cambridge.org/core/journals/proceedings-of-the-edinburgh-mathematical-society/article/cth-baker-the-numerical-treatment-of-integral-equations-clarendon-press-oxford-univer>

[sity-press-1978-xiv1034-pp-2250/FCB7E9DDEDB9CFB497A152D8638BFF7A](#). Acesso em 8 de Jul. 2025.

AWAN, Abid Ali. **Tutorial sobre redes neurais recorrentes (RNNs)**. 2024. Disponível em: <https://www.datacamp.com/pt/tutorial/tutorial-for-recurrent-neural-network>. Acesso em 13 de jul. 2025.

BASSETO, Murilo. **Fabricante de aeronaves Vertical Aerospace escolhe empresa para fornecer IA para engenharia**. 2025. Disponível em: <https://aeroin.net/fabricante-de-aeronaves-vertical-aerospace-escolhe-empresa-para-fornecer-ia-para-engenharia/>. Acesso em 5 de set. de 2025.

BENNETT, Charles H. et al. Strengths and weaknesses of quantum computing. **SIAM journal on Computing**, v. 26, n. 5, p. 1510-1523, 1997. Disponível em: <https://epubs.siam.org/doi/abs/10.1137/S0097539796300933>. Acesso em 18 Jul. 2025.

BISHOP, Geoff J.; ELVERS, Barbara. Aviation fuels. **Ullmann's Encyclopedia of Industrial Chemistry**, p. 1-16, 2000. Disponível em: https://onlinelibrary.wiley.com/doi/10.1002/14356007.a03_201.pub3. Acesso em: 08 Set. 2025

BITTEL, Lennart ; KLIESCH, Martin . Training Variational Quantum Algorithms Is NP-Hard. **Physical Review Journal**, 2021. Disponível em: <https://journals.aps.org/prl/abstract/10.1103/PhysRevLett.127.120502>. Acesso em: 17 set. 2025.

BRUNDTLAND, Gro Harlem. **Our common future world commission on environment and development**. 1987.

CADENCE. **Artificial Intelligence in Aerospace**. 2025. Disponível em: https://www.cadence.com/en_US/home/ai/aerospace.html. Acesso em 26 de ago. 2025.

CAMPBELL, E.; KHURANA, A.; MONTANARO, A. Applying quantum algorithms to constraint satisfaction problems. 2019. **Quantum**, **3**:167.

CANOREA, Elena . Quantum Computing: Potential and Challenges ahead. **Plain Concepts**, 2025. Disponível em: <https://www.plainconcepts.com/quantum-computing-potential-challenges>. Acesso em: 07 out. 2025.

CAROLA, Gabriel Alves. **Aplicações de inteligência artificial em sistemas de controle autônomo..** 2024. Tese (Graduação em Ciência da Computação) – PUC Goiás, Goiás, 2024. Disponível em: <https://repositorio.pucgoias.edu.br/jspui/handle/123456789/8367>. Acesso em: 8 de set. 2025.

CECCON, Denny. **Os tipos de redes neurais**. 2020. Disponível em: <https://iaexpert.academy/2020/06/08/os-tipos-de-redes-neurais/>. Acesso em 10 jul. 2025.

CHEN, Qi; TU, Kaixun; WANG, Qing. Hamiltonian formulation of the Rothe-Stamatescu model and field mixing. **Physical Review D**, v. 110, n. 3, p. 034510, 2024. Disponível em: <https://journals.aps.org/prd/abstract/10.1103/PhysRevD.110.034510>. Acesso em 17 jul. 2025.

CLOUDFLARE. **O que é uma rede neural?** 2025. Disponível em: <https://www.cloudflare.com/pt-br/learning/ai/what-is-neural-network/>. Acesso em 10 jul. 2025.

CORRÊA, Fernanda das Graças; PERON, Alcides Eduardo dos Reis; VERGUEIRO, Luiz Fabricio Thaumaturgo. Geopolítica e o domínio aeroespacial: da supremacia da aviação militar à exploração espacial por fusão nuclear. **Revista Brasileira de Estudos de Defesa**, [S. l.], v. 5, n. 1, 2018. Disponível em: <https://rbed.abedef.org/rbed/article/view/75053>. Acesso em: 13 jul. 2025.

DEMIR, Gülay; MOSLEM, Sarbast; DULEBA, Szabolcs. Artificial intelligence in aviation safety: systematic review and biometric analysis. **International Journal of Computational Intelligence Systems**, v. 17, n. 1, p. 279, 2024. Disponível em: <https://link.springer.com/article/10.1007/s44196-024-00671-w>. Acesso em: 08 Out. 2025

DU, Chongrui et al. A novel calculation method for low-thrust transfer trajectories in the Earth-Moon restricted three-body problem. **Aerospace Science and Technology**, v. 147, p. 109048, 2024. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1270963824001810?via%3Dihub>. Acesso em: 23 Ago. 2025

FARHI, Edward et al. The quantum approximate optimization algorithm and the Sherrington-Kirkpatrick model at infinite size. **Quantum**, v. 6, p. 759, 2022. Disponível em: <https://quantum-journal.org/papers/q-2022-07-07-759/>. Acesso em 16 Jul. 2025.

FARHI, Edward; GOLDSTONE, Jeffrey; GUTMANN, Sam. A quantum approximate optimization algorithm. **arXiv preprint arXiv:1411.4028**, 2014. Disponível em: <https://arxiv.org/abs/1411.4028>. Acesso em 17 jul. 2025.

FEYNMAN, Richard Phillips. **The Feynman lectures on physics**. (No Title), v. 1, p. 46, 1963. Disponível em: <https://cir.nii.ac.jp/crid/1370285712509472388>. Acesso em 7 jul. 2025.

CAMERO, Rosa; RICÓN, Juan; TAFUR, Cristian; SAENZ Edwin RODRÍGUEZ, Didier. Applications of artificial intelligence in air operations. **ScienceDirect**, 2025. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2590123024019856>. Acesso em: 06 out. 2025.

GALVÃO, Ernesto F.; BROD, Daniel J. Quantum and classical bounds for two-state overlaps. **Physical Review A**, v. 101, n. 6, p. 062110, 2020. Disponível em: <https://iopscience.iop.org/article/10.1088/1367-2630/ab7a30/meta>. Acesso em 13 Jul 2025

GOMES, Naomy Duarte et al. Introduction to quantum machine learning, its applications and advantages. **Revista Brasileira de Ensino de Física**. São Paulo. 2024. Disponível em: <https://www.scielo.br/j/rbef/a/PswxKzK6NXJtG6t9XDPjDdd/?format=html&lang=pt>. Acesso em 2 de set. 2025.

GONÇALVES, André Ricardo. **Redes Neurais Artificiais**. 2021. UNICAMP. Disponível em: https://andrerico.github.io/files/pdfs/redes_neurais.pdf. Acesso em 28 de jul. 2025

GROTE, Matt; WILLIAMS, Ian; PRESTON, John. Direct carbon dioxide emissions from civil aircraft. **Atmospheric Environment**, v. 95, p. 214-224, 2014. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1352231014004889>. Acesso em: 03 Set. 2025

GU, S. Q. et al. Photoluminescence and excitation spectroscopy of Er-doped As₂S₃ glass: Novel broad band excitation mechanism. **Journal of applied physics**, v. 77, n. 7, p. 3365-3371, 1995. Disponível em: <https://pubs.aip.org/aip/jap/article-abstract/77/7/3365/291422/Photoluminescence-and-excitation-spectroscopy-of>. Acesso em 13 Jul. 2025.

HARRIS, Gage W.; HE, Ping; ABDELKHALIK, Ossama O. Control co-design optimization of spacecraft trajectory and system for interplanetary missions. **Journal of Spacecraft and Rockets**, v. 61, n. 4, p. 939-952, 2024. Disponível em: <https://arc.aiaa.org/doi/abs/10.2514/1.A35680>. Acesso em: 19 Ago. 2025

HARRIS, Matt . A era dos qubits. **GOWLING WLG**, 2025. Disponível em: <https://gowlingwlg.com/en/insights-resources/articles/2025/quantum-computing-legal-issues-the-risks-and-opportunities>. Acesso em: 06 out. 2025.

HAYKIN, S. **Redes Neurais, Princípios e práticas**. 2. ed. [S.l]: Bookman, 1999.

HEGARTY, Christopher J.; CHATRE, Eric. Evolution of the global navigation satellite system (gnss). **Proceedings of the IEEE**, v. 96, n. 12, p. 1902-1917, 2009. Disponível em: <https://ieeexplore.ieee.org/document/4745647>. Acesso em: 14 Jul. 2025

HERCULANO-HOUZEL, S. **Cérebro humano: 86 bilhões de neurônios**. [S. l.: s. n.], 2012. 1 vídeo (5 min). Publicado pelo canal Folha de S.Paulo. Disponível em: <https://youtu.be/KwIzJqN6CC0>. Acesso em: 26 ago. 2025.

HIRAI, Hirotoishi . Practical application of quantum neural network to materials informatics. **NATURE**, 2024. Disponível em: <https://www.nature.com/articles/s41598-024-59276-0>. Acesso em: 07 out. 2025.

IBM. **O que é uma rede neural?** 2020. Disponível em: <https://www.ibm.com/br-pt/think/topics/neural-networks>. Acesso em 10 jul. 2025.

ICMC USP. **Redes Neurais Artificiais**. Disponível em: <https://sites.icmc.usp.br/andre/research/neural/>. Acesso em 12 de jul. 2025.

IONOS. **Convolutional Neural Network: Redes neurais convolucionais**. Disponível em: <https://www.ionos.com/pt-br/digitalguide/sites-de-internet/desenvolvimento-web/convolutional-neural-network/>. Acesso em 13 jul. 2025.

KAPITONOVA, Tatiana; BULLOCK, Steve. What is the optimal fuel for space flight? Efficiency, cost, and environmental impact. **Journal of Emerging Investigators**, v. 6, p. 1-9,

2023. Disponível em: <https://emerginginvestigators.org/articles/22-238>. Acesso em: 08 Set. 2025

KRAUSE-REHBERG, R. et al. Mechanical damage in GaAs wafers introduced by a diamond saw: A study by means of positron annihilation and electron microscopy. **physica status solidi (a)**, v. 158, n. 2, p. 377-383, 1996. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/pssa.2211580205>. Acesso em 15 Jul. 2025

KOIFMAN, Mark; BAR-ITZHACK, Itzhack Y. Inertial navigation system aided by aircraft dynamics. **IEEE transactions on control systems technology**, v. 7, n. 4, p. 487-493, 2002. Disponível em: <https://ieeexplore.ieee.org/document/772164>. Acesso em: 14 Jul. 2025

LAGE, Fernanda de Carvalho. Manual de Inteligência Artificial no Direito Brasileiro. 2. ed. **Editora Jus Podivm**, 2022. Disponível em: https://juspodivmdigital.com.br/cdn/arquivos/jus2235_previa-do-livro.pdf. Acesso em 21 de jul. 2025.

LISOWSKI, Edwin. **AI in the Aviation Industry: Top 5 Use Cases**. 2025. Disponível em: <https://addepto.com/blog/ai-in-the-aviation-industry-top-5-use-cases/>. Acesso em 26 de ago. 2025.

LOUREIRO, Fábio Adriano dos Santos et al. **Manutenção preditiva com inteligência artificial: caminhos para eficiência operacional e sustentabilidade**. 2024. Tese (Graduação em Engenharia Mecânica) – Faculdade UNA Itabira, Itabira, 2024. Disponível em: <https://share.google/OrbaLcnlvdQDrZVeW>. Acesso em: 2 de set. 2025.

MARTINS, Roberto. **O SURGIMENTO DA MECÂNICA QUÂNTICA—UMA OU DUAS TEORIAS?** Disponível em: <https://www.ghc.usp.br/livros%20RM%202022/Studia-4-2-web.pdf>. Acesso em: 7 jul. 2025.

MÁXIMO, Yasmin de Souza. **A Inteligência Artificial no Design de Aeronaves: Uma Nova Era na Aviação**. 2024. Disponível em: <https://pt.linkedin.com/pulse/intelig%C3%Aancia-artificial-design-de-aeronaves-uma-nova-d-e-souza-m%C3%A1ximo-xhf0c>. Acesso em 5 de set. 2025.

MAXWELL. PUC-Rio. **Redes Neurais Artificiais**. Disponível em: https://www.maxwell.vrac.puc-rio.br/5566/5566_6.PDF. Acesso em 2 de set. 2025.

MERRITT, Rick. **O que é um Modelo Transformer?** 2022. Disponível em: <https://blog.nvidia.com.br/blog/o-que-e-um-modelo-transformer/>. Acesso em 17 de jul. 2025.

MIGHTY TRAVELS. **Understanding Flight Plans How Airlines Navigate the Complex Web of Air Routes**. 2024. Disponível em: <https://www.mightytravels.com/2024/11/understanding-flight-plans-how-airlines-navigate-the-complex-web-of-air-routes/>. Acesso em 26 de ago. 2025.

MOALLEMI, Mohammad; TOWHIDNEJAD, Massood. B-737 autopilot design and implementation for simulated flight management system. In: **Proceedings of the 49th Annual Simulation Symposium**. 2016. p. 1-7. Disponível em:

https://www.researchgate.net/publication/316856912_B-737_autopilot_design_and_implementation_for_simulated_flight_management_system. Acesso em: 17 Jul. 2025

MODARRESS FATHI, Batoul; ANSARI, Al; ANSARI, Alexander. Green commercial aviation supply chain—A European path to environmental sustainability. **Sustainability**, v. 15, n. 8, p. 6574, 2023. Disponível em: <https://www.mdpi.com/2071-1050/15/8/6574>. Acesso em: 02 Jul. 2025

MOORE, Gordon E. et al. **Cramming more components onto integrated circuits** [em linha]. 19 abr. 1965. Disponível em <https://ieeexplore.ieee.org/abstract/document/4785860>. Acesso em 9 Jul. 2025

NASA. Guide to Aerodynamics. **Beginners Guide to Aeronautics**, 2023. Disponível em: <https://www1.grc.nasa.gov/beginners-guide-to-aeronautics/learn-about-aerodynamics/>. Acesso em: 05 Jul. 2025

NASA. **5.0 Guidance, Navigation, and Control**. 2025. Disponível em: <https://www.nasa.gov/smallsat-institute/sst-soa/guidance-navigation-and-control/>. Acesso em: 20 Jul. 2025

NEAR LOCATION. **A otimização de rotas com base em IA está transformando a logística**. 2024. Disponível em: <https://nearlocation.com.br/otimizacao-de-rotas-com-base-em-ia/>. Acesso em 28 de ago. 2025.

NETO, João Martins Gomes; REIS, Marcello; WEHMANN, Claus Franz. Predição da carga acústica de foguete durante o lançamento. **Revista Brasileira de Física Tecnológica Aplicada**, v. 9, n. 2, 2022. Disponível em: <https://periodicos.utfpr.edu.br/rbfta/article/view/15169>. Acesso em: 27 Ago. 2025

NISHANT, Rohit; KENNEDY, Mike; CORBETT, Jacqueline. Artificial intelligence for sustainability: Challenges, opportunities, and a research agenda. **International journal of information management**, v. 53, p. 102104, 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0268401220300967>. Acesso em: 09 Out. 2025

OLIVEIRA, Marcelo. **Neurônios**. 2025. Disponível em: <https://www.infoescola.com/sistema-nervoso/neuronios/>. Acesso em 17 de jul. 2025.

ONORATI, Emilio et al. Mixing properties of stochastic quantum Hamiltonians. **Communications in Mathematical Physics**, v. 355, n. 3, p. 905-947, 2017. Disponível em: <https://link.springer.com/article/10.1007/s00220-017-2950-6#citeas>. Acesso em: 15 Ago. 2025.

PANCINI, Laura. **Companhia aérea usa inteligência artificial para aperfeiçoar rotas de voo**. 2021. Disponível em: <https://exame.com/inovacao/companhia-aerea-inteligencia-artificial-rotas-de-voo/>. Acesso em 26 de ago. 2025.

PEREZ, Ruben; MARTINS, Joaquim RRA. pyACDT: An object-oriented framework for aircraft design modelling and multidisciplinary optimization. In: **12th AIAA/ISSMO**

Multidisciplinary Analysis and Optimization Conference. 2008. p. 5955. Disponível em: <https://arc.aiaa.org/doi/abs/10.2514/6.2008-5955>. Acesso em: 11 Ago. 2025

PINHEIRO MELO, Sofia et al. Sustainability assessment and engineering of emerging aircraft technologies—Challenges, methods and tools. **Sustainability**, v. 12, n. 14, p. 5663, 2020. Disponível em: <https://www.mdpi.com/2071-1050/12/14/5663>. Acesso em: 02 Jul. 2025

PRASAD, Archiki et al. Adapt: As-needed decomposition and planning with language models. **arXiv preprint arXiv:2311.05772**, 2023. Disponível em: <https://arxiv.org/abs/2311.05772>. Acesso em: 14 Jul. 2025.

RANSBOTHAM, Sam; KHODABANDEH, Shervin. **IA no setor aeroespacial**. 2022. Disponível em: <https://mitsloanreview.com.br/ia-no-setor-aeroespacial/>. Acesso em 9 de set. 2025.

REUTERS. **Embraer vai intensificar testes com combustível de aviação sustentável**. 2025. Disponível em: <https://www.cnnbrasil.com.br/economia/negocios/embraer-vai-intensificar-testes-com-combustivel-de-aviacao-sustentavel/>. Acesso em 10 de set. 2025.

RODRIGUES, Gabriel. **O que é Curva PF e como ela faz sua empresa economizar na manutenção**. 2023. Disponível em: <https://www.blog.auvo.com/curva-pf>. Acesso em 28 de ago. 2025.

RUELA, André Siqueira. **Redes Neurais Feedforward e Backpropagation**. 2012. Disponível em: https://www2.decom.ufop.br/imobilis/wp-content/uploads/2012/06/03_Feedforward-e-Backpropagation1.pdf. Acesso em 14 de jul. 2025.

SANTOS, Priscila Gabriele Marques dos. **Um estudo sobre modelos de redes neurais quânticas**. 2016. Tese (Graduação em Ciência da Computação) – Departamento de Estatística e Informática, Universidade Federal Rural de Pernambuco, Recife, 2016. Disponível em: <http://www.bcc.ufrpe.br/sites/www.bcc.ufrpe.br/files/TCC%20-%20Priscila%20Santos.pdf>. Acesso em 17 de jul. 2025.

SINGH, Vedant et al. **European Transport Research Review**, v. 7, n. 2, p. 12, 2015. Disponível em: <https://etr.springeropen.com/articles/10.1007/s12544-015-0160-x>. Acesso em: 06 Jul. 2025

SINGH, Vedant; SHARMA, Somesh Kumar. **Fuel consumption optimization in air transport: a review, classification, critique, simple meta-analysis, and future research implications**.

SOUZA, Y.N.; SIMAS FILHO E.F.; FARIAS C.T.T.; LEITE V.L.C.; SOUZA I.S.; LOPES J.L.S.; ARAUJO P.R.A. **Avaliação Não Destrutiva da Integridade Estrutural de Compósitos de Alumínio e Epoxi Utilizando Processamento Estatístico e Redes Neurais Artificiais como Ferramenta de Auxílio**. In: CONFERÊNCIA SOBRE TECNOLOGIA DE EQUIPAMENTOS. 11º COTEQ, Ipojuca/PE, 2011.

SPADINI, Allan. **Arquitetura de redes neurais: aplicações na IA**. 2024. Disponível em: <https://www.alura.com.br/artigos/arquiteturas-de-redes-neurais>. Acesso em 26 de ago. 2025.

SPINQ. **Quantum Parallelism: Why Quantum Computers Are So Fast**. 2025. Disponível em:

<https://www.spinquanta.com/news-detail/quantum-parallelism-why-quantum-computers-are-so-fast>. Acesso em: 15 ago. 2025.

STUART, Emilia . Your Quick Guide to Quantum and AI: The Future of Computing or Just Hype?. **IQM**, 2025. Disponível em:

<https://meetiqm.com/blog/quantum-ai-the-future-of-computing-or-just-hype>. Acesso em: 20 Ago. 2025.

SYMONS, Benjamin CB et al. A practitioner's guide to quantum algorithms for optimisation problems. **Journal of Physics A: Mathematical and Theoretical**, v. 56, n. 45, p. 453001, 2023. Disponível em <https://iopscience.iop.org/article/10.1088/1751-8121/ad00f0/meta>. Acesso em 7 Ago. 2025.

VALLADO, David A. **Fundamentals of astrodynamics and applications**. Springer Science & Business Media, 2001. Disponível em:

https://books.google.com.br/books?hl=pt-BR&lr=&id=PJLIWzMBKjkC&oi=fnd&pg=PA1&dq=fundamentals+of+astrodynamics&ots=V5m-2ws8qo&sig=7rqwVtCMOlwb2xdZ_635vj78RUY&redir_esc=y#v=onepage&q=fundamentals%20of%20astrodynamics&f=false. Acesso em: 18 Jul. 2025

VERTICAL AEROSPACE. 22 de ago. de 2025. Disponível em:

https://www.instagram.com/p/DNqJlaWI99C/?utm_source=ig_web_copy_link&igsh=MWsyemMyejlhNDZnZA==. Acesso em 5 de set. 2025.

VINA, Abirami. **IA na aviação: Uma pista para aeroportos mais inteligentes**. 2024. Disponível em:

<https://www.ultralytics.com/pt/blog/ai-in-aviation-a-runway-to-smarter-airports>. Acesso em 7 de set. 2025.

VINICIUS, Anderson. **Redes Neurais Artificiais**. 2017. Disponível em:

<https://medium.com/@avinicius.adorno/redes-neurais-artificiais-418a34ea1a39>. Acesso em 17 de jul. 2025.

VISURE. **IA na indústria aeroespacial: redefinindo a engenharia**. 2025. Disponível em:

<https://visuresolutions.com/pt/aeroespacial-e-defesa/intelig%C3%A2ncia-artificial/>. Acesso em 2 de set. 2025.

VULETIĆ, Vladan et al. Quantum Parallelism. **QuEra**, 2025. Disponível em:

<https://www.quera.com/glossary/parallelism>. Acesso em: 20 jul. 2025.

WEED, Julie. **Entenda como a inteligência artificial já é usada por companhias aéreas para evitar atrasos em conexões e desvio de bagagem**. 2024. Disponível em:

<https://oglobo.globo.com/boa-viagem/noticia/2024/05/24/entenda-como-a-inteligencia-artificial-ja-e-usada-por-companhias-aereas-para-evitar-atraso-em-conexoes-e-desvio-de-bagagem.g.html>

ZAPAROLLI, Domingos. A era dos qubits. **FAPESP**, 2021. Disponível em: <https://revistapesquisa.fapesp.br/a-era-dos-qubits>. Acesso em: 06 out. 2025.

ZORZETTO, Ricardo. **Números em revisão: Recontagem de neurônios põe em xeque ideias da neurociência.** 2012. Disponível em: <https://revistapesquisa.fapesp.br/n%C3%BAmeros-em-revis%C3%A3o/>. Acesso em 17 de jul. 2025.