

UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
CAMPUS DE SÃO JOÃO DA BOA VISTA

MARCY WELLINTON DOS SANTOS BORGES

**Desenvolvimento de uma ferramenta de otimização aerodinâmica de uma asa utilizando
algoritmos genéticos**

São João da Boa Vista

2022

Marcy Wellinton dos Santos Borges

Desenvolvimento de uma ferramenta de otimização aerodinâmica de uma asa utilizando algoritmos genéticos

Trabalho de Graduação apresentado ao Conselho de Curso de Graduação em Engenharia Aeronáutica do Campus de São João da Boa Vista, Universidade Estadual Paulista, como parte dos requisitos para obtenção do diploma de Graduação em Engenharia Aeronáutica .

Orientador: Prof^a Dr^a. Leandra Isabel De Abreu

São João da Boa Vista

2022

B732d Borges, Marcy W.
Desenvolvimento de uma ferramenta de otimização aerodinâmica
de uma asa utilizando algoritmos genéticos / Marcy W. Borges. -- São
João da Boa Vista, 2022
43 p.

Trabalho de conclusão de curso (Bacharelado - Engenharia
Aeronáutica) - Universidade Estadual Paulista (Unesp), Faculdade de
Engenharia, São João da Boa Vista
Orientadora: Leandra Isabel De Abreu

1. Design. 2. Asas. 3. Otimização matemática. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de
Engenharia, São João da Boa Vista. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA - CÂMPUS DE SÃO JOÃO DA BOA VISTA
GRADUAÇÃO EM ENGENHARIA AERONÁUTICA**

TRABALHO DE CONCLUSÃO DE CURSO

**DESENVOLVIMENTO DE UMA FERRAMENTA DE OTIMIZAÇÃO
AERODINÂMICA DE UMA ASA UTILIZANDO ALGORITMOS GENÉTICOS**

Aluno: Marcy Wellinton dos Santos Borges
Orientador: Prof.^a Dr.^a Leandra Isabel de Abreu

Banca Examinadora:

- Leandra Isabel de Abreu (Orientadora)
- Edemar Morsch Filho (Examinador)
- Vagner Candido de Sousa (Examinador)

A ata da defesa com as respectivas assinaturas dos membros encontra-se no prontuário do aluno (Expediente nº 057/2021)
--

São João da Boa Vista, 14 de dezembro de 2022

Aos meus familiares, em especial minha mãe e meu padastro pelo amor e apoio incondicional sempre.

AGRADECIMENTOS

A todos os familiares e amigos que sempre estiveram presentes nessa jornada com apoio incondicional, fazendo com que essa tenha sido muito mais interessante, meus sincero e singelo agradecidamente.

Ao Professor Dr. Luiz Augusto Camargo Aranha Schiavo, que foi meu orientador durante todo desenvolvimento desse trabalho e contribuiu para o desenvolvimento desse com todo seu apoio, paciência e dedicação. À Professora Dr. Leandra Isabel De Abreu que me apoiou e me incentivou na fase final desse trabalho. De modo geral, a todos os professores(as) que puderam contribuir para minha formação desde o ciclo básico ao ensino superior, como todo seu apoio, dedicação, vontade de ensinar e amor pela bela profissão.

A todo suporte acadêmico desenvolvido pela Universidade Estadual Paulista "Julio de Mesquita Filho" e seus colaboradores, em especial os colaboradores do Campus de São da Boa Vista, meus sincero e singelo agradecidamente.

*"We all find time to do what we really want to do."
(William Feather)*

RESUMO

O projeto de uma aeronave é um processo multidisciplinar, extremamente complexo que busca encontrar a solução ótima para um conjunto de variáveis que atendam aos requisitos de projeto. O desenvolvimento de um projeto demanda um processo de coordenação entre síntese, análise e avaliação, pilares que compõem qualquer projeto de design. Essas três operações devem ser integradas e aplicadas interativamente e continuamente ao longo do ciclo de vida do projeto. Nesse contexto são inseridos os métodos de otimização que buscam encontrar a solução ótima ou quase-ótima para o problema de maneira mais eficiente possível.

O presente trabalho descreve a implementar uma ferramenta de otimização baseada em algoritmos genéticos de propósito geral, para otimização aerodinâmica da geometria de asas, utilizando parâmetros de perfil aerodinâmico e da geometria da asa, buscando a geometria ideal em um espaço de busca definido, a fim de otimizar a relação de sustentação por arrasto para uma condição de voo pré-definida.

PALAVRAS-CHAVE: Projeto aerodinâmico. Otimização. Algoritmo genético.

ABSTRACT

The design of an aircraft is an extremely complex multidisciplinary process that seeks to find the optimal solution for a set of variables that meet the design requirements. The development of a project demands a process of coordination between synthesis, analysis and evaluation, pillars that make up any design project. These three operations must be integrated and applied interactively and continuously throughout the project lifecycle. In this context, optimization methods are inserted that seek to find the optimal or quasi-optimal solution to the problem in the most efficient way possible. The present work describes how to implement an optimization tool based on general purpose genetic algorithms, for aerodynamic optimization of wing geometry, using parameters of airfoil and wing geometry, seeking the ideal geometry in a defined search space, in order to to optimize the drag lift ratio for a pre-defined flight condition.

KEYWORDS: Aircraft design. Otimization. Genetic Algorithm.

LISTA DE ILUSTRAÇÕES

Figura 1	Fases de um projeto aeronáutico	14
Figura 2	Processo convencional de design	15
Figura 3	Processo otimizado de design	15
Figura 4	Algoritmos genéticos: classificação por objetivos	18
Figura 5	Exemplo de uso de algoritmo multi-objetivo para otimizar uma treliça tendo como objetivos diminuir a tensão máxima e o volume.	20
Figura 6	Operador crossover	21
Figura 7	Fluxograma de um algoritmo genético	22
Figura 8	Visão geral dos modelos de escoamento aerodinâmico	24
Figura 9	Grau de fidelidade dos métodos aerodinâmicos	24
Figura 10	Discretização da asa em painéis.	25
Figura 11	Condições contorno para o método dos painéis.	25
Figura 12	Lei de Biot-Savart.	26
Figura 13	Nomenclatura Biot-Savart	26
Figura 14	Vórtices ferradura.	27
Figura 15	Integração.	30
Figura 16	Parâmetros da para construção da geometria da asa.	30
Figura 17	Nomenclatura do aerofólio	31
Figura 18	Aerofólios NACA-dígitos	32
Figura 19	Esquema de parametrização para asa.	33
Figura 20	Arquitetura de implementação	34
Figura 21	Etapa e simulação 2D	34
Figura 22	Etapa de simulação 3D	35
Figura 23	Variação do parâmetro número de indivíduos por população	36
Figura 24	Teste de sensibilidade	38
Figura 25	Asa do Cessna 182 T (Condição de cruzeiro - 85 m/s)	39
Figura 26	Evolução do fitness	40
Figura 27	Asa otimizada	40
Figura 28	Efeito do alongamento na asa	41
Figura 29	Esquema de parametrização da asa usando dois perfis.	42

LISTA DE TABELAS

Tabela 1 – Pseudocódigo de um algoritmo genético básico: tipo SGA	19
Tabela 2 – Operadores genéticos utilizados.	35
Tabela 3 – Parâmetros fixos na otimização	36
Tabela 4 – Calibração dos parâmetros do AG	37
Tabela 5 – Limites de variação de cada variável.	37
Tabela 6 – Dados da aeronave Cessna 182T Skylane	39
Tabela 7 – Limites de variação para o estudo de caso.	39
Tabela 8 – Parâmetros finais de otimização.	41

LISTA DE ABREVIATURAS E SIGLAS

AG	Algoritmo Genético
PSO	<i>Particle Sward Optimization</i>
NSGA	<i>Non-dominated Sorting Genetic Algorithm</i>
VLM	<i>Vortex Lattice Method</i>
AVL	<i>Athena Vortex Lattice</i>
BA	Borda de Ataque
LE	<i>Leading Edge</i>
BF	Borda de Fuga
TE	<i>Trailing Edge</i>
SGA	Simple Genetic Algorithms
POO	Programação Orientada a Objeto
DEAP	Distributed Evolutionary Algorithms in Python

LISTA DE SÍMBOLOS

C_L	Coeficiente de sustentação
C_D	Coeficiente de arrasto
C_p	Coeficiente de pressão
C_f	Coeficiente de fricção
ρ	Densidade de massa
t	Tempo
u_j	Vetor de velocidade
W_{ind}	Velocidade induzida
A_{ij}	Coeficiente de escoamento induzido
Γ	Vorticidade
L	Sustentação
A	Arrasto
c	Corda
M_e	Número de Mach do escoamento livre
AR	Alongamento

SUMÁRIO


1	INTRODUÇÃO	14
1.1	Conceitos preliminares	14
1.2	Motivação	16
1.3	Objetivo	16
1.4	Estrutura do trabalho	16
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	Otimização	17
2.1.1	Formulação matemática de problemas de otimização	17
2.2	Algoritmo genético	18
2.2.1	Operadores genéticos	19
2.2.1.1	Inicialização	19
2.2.1.2	Evaluation	20
2.2.1.3	Crossover	21
2.2.1.4	Mutação	21
2.2.1.5	Seleção	22
2.3	Métodos aerodinâmicos	23
2.3.1	Método do Vórtex Lattice (VLM)	23
2.3.2	Método dos painéis	28
2.3.3	Acoplamento dos efeitos viscosos	29
3	METODOLOGIA	30
3.1	Parametrização	31
3.1.1	Geometria	31
3.1.2	Perfil	31
3.1.3	Asa	33
3.2	Arquitetura de desenvolvimento	33
4	RESULTADOS E DISCUSSÕES	36
4.1	Ajuste dos parâmetros do AG	36
4.2	Teste de sensibilidade das variáveis	37
4.3	Estudo de caso para validação	38
5	CONCLUSÃO	42
5.1	Sugestão para trabalhos futuros	42
	REFERÊNCIAS	44

1 INTRODUÇÃO

1.1 CONCEITOS PRELIMINARES

O projeto de aeronaves pode ser dividido em três grandes fases, chamadas de projeto conceitual, projeto preliminar e projeto detalhado, segundo metodologia apresentada por Raymer (2018) conforme na Figura 1. Cada uma dessas com diferentes tarefas, objetivos e níveis de detalhamento a se atingir.

Figura 1 – Fases de um projeto aeronáutico




Fonte: adaptado de Raymer (2018)

No projeto conceitual, a primeira etapa do projeto, questões básicas como arranjo da configuração, tamanho, peso e desempenho são respondidas. Inúmeros conceitos de design alternativos são estudados dentro do espaço de projeto proposto pelos requisitos de projetos que orientam e avaliam o desenvolvimento do arranjo geral da aeronave. Nesse arranjo preliminar inclui-se a geometria geral da asa e da cauda (área, envergadura, corda, *offset*, etc.), forma da fuselagem, carga útil, locais internos para os tripulantes, instalação do motor, entre outros requisitos de design. O nível de detalhe dessa fase não é muito profundo, porém a interação entre todos os componentes e a exploração do espaço de busca são de extrema importância para o desenvolvimento de um bom projeto conceitual.

De forma geral, um aspecto fundamental do projeto conceitual é que esse é um processo muito fluido, e o *layout* do projeto está sempre sendo alterado, a fim de inserir novos conceitos e avaliar o potencial desse novo design. Nesse contexto as ferramentas de otimização são usadas no processo de

design iterativo, buscando acelerar o ciclo de projeto e obter bons resultados de maneira ágil. Para compreender o processo de otimização considere inicialmente um processo convencional usado nos projetos de engenharia, como destacado na Figura 2, nesse processo o projetista toma as decisões baseados na intuição, no conhecimento prévio (*Know-how*) ou baseado em normativas, de maneira geral, essas decisões se destacam por incluírem principalmente o fator humano.


Figura 2 – Processo convencional de design



Fonte: elaborado pelo próprio autor.

O ciclo do projeto na perspectiva de um projeto convencional, inicia-se com o *design* preliminar, que toma como base projetos anteriores e novos conceitos, levando em consideração aspectos e requisitos levantados na fase inicial. Esse então é analisado e avaliado quanto sua performance. O processo considera uma modelagem numérica, a construção de protótipo e teste. Caso o design obtido não atenda os requisitos necessários de qualidade é necessário uma nova iteração. Nessa as modificações no projeto são tomadas conforme a intuição, experiência e estudo de caso do projetista.

Figura 3 – Processo otimizado de design



Fonte: retirado de Martins e Ning (2021)

No processo otimizado de design o fluxo é semelhante ao convencional, ver Figura 3. O levantamento das especificações e do *design* iniciais são as mesmas feitas para o projeto convencional. Contudo, há a necessidade da determinação do problema de otimização, que é composto pelas variáveis de design, pelo objetivo a ser minimizado (ou maximizado) e pela condição de parada. Com essas definições, é possível automatizar o processo iterativo, de modo que a interação do projetista se dá somente na definição do *design* inicial e na definição do problema de otimização, uma vez que esse demanda expertise.

1.2 MOTIVAÇÃO

O projeto de uma aeronave é um processo multidisciplinar extremamente complexo que busca encontrar uma solução ótima para um conjunto de variáveis que atendam aos requisitos do projeto. Como qualquer projeto moderno de engenharia, esse demanda um processo de coordenação entre síntese, análise e avaliação. Essas três operações devem ser integradas e aplicadas iterativamente e continuamente ao longo do ciclo de vida do projeto. Nesse contexto, são inseridos os métodos de otimização que buscam encontrar soluções ótimas ou quase-ótimas para o problema de maneira mais eficiente possível.

1.3 OBJETIVO

O objetivo desse trabalho é o desenvolvimento de uma ferramenta de otimização aerodinâmica, usando métodos aerodinâmicos de baixa fidelidade, para uso em projeto conceitual de aeronaves, através do uso de algoritmos de otimização heurístico, algoritmo genético, que utilizam princípios genéticos para encontrar uma solução ótima em um determinado espaço de busca definido.

1.4 ESTRUTURA DO TRABALHO

O presente trabalho encontra-se dividido em 5 capítulos, da seguinte maneira:

o capítulo 2 apresenta uma visão geral de algoritmos de otimização e os principais operadores que compõem um algoritmo genético, necessários para implementação.

No capítulo 3 são apresentados os métodos aerodinâmicos por trás do *scripts* que serão usados na construção da ferramenta de otimização.

O capítulo 4 será dedicado para detalhar os esquemas de parametrização utilizados para descrever a geometria da asa. Além de detalhar a arquitetura e o fluxo de trabalho por trás da ferramenta desenvolvida.

No capítulo 5 são apresentadas mais algumas decisões de projetos tomadas e os resultados finais obtidos.

No último capítulo são apresentadas as conclusões dos resultados obtidos e sugestões para implementações futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 OTIMIZAÇÃO

O termo otimização muitas vezes é associado a melhoria, mas, de um ponto de vista mais geral, a otimização está intrinsecamente associado à busca pela melhor solução possível, alterando variáveis de controles que parametrizam o problema. Problemas mais simples de otimização até podem ser resolvidos analiticamente por meio técnicas de calculo, como máximos globais e mínimos locais, mas a maioria dos problemas de otimização têm soluções muito complexas e necessitam de técnicas de computação numérica para serem resolvidos (Martins e Ning (2021)).

2.1.1 Formulação matemática de problemas de otimização

De maneira geral, as técnicas de otimização buscam encontrar parâmetros de projeto $x = \{x_1, x_2, \dots, x_n\}$, que possam minimizar uma determinada condição, ainda muitas vezes sujeitas a uma determinada restrição. Isso pode ser representado da seguinte forma:

$$\begin{aligned} &\text{Minimizar } f(x) \text{ e } g(x) \\ &x \in R^n \end{aligned}$$

Sujeito as restrições

$$\begin{aligned} &H_i(x) = 0 \text{ (i = 1,2,...,m)} \\ &H_i(x) < 0 \text{ (i = m+1,m+2,...,n)} \\ &x_l < x < x_u \end{aligned}$$


As funções $f(x)$ e $g(x)$ são denominadas de função objetivo (*fitness function*) que medem a performance do design caracterizado pelos parâmetros de projeto. Para problemas mais simples, essas funções retorna um escalar, que quantifica o design parametrizado. Enquanto as funções $H_i(x)$ são as restrições que delimitam o modelo. Matematicamente existe uma infinidade de algoritmos de otimização, diferenciando-se basicamente pelos métodos ou pelas fundamentações usada para minimizar a função $f(x)$, podendo esses serem mais exatos ou não na busca dos valores ótimos.

Dentro do contexto de algoritmo de otimização, existe diversos algoritmos com abordagens diferentes, focados em otimizações mono-objetivas ou multi-objetivas. Esses algoritmos divide-se, basicamente, em determinísticos e estocásticos. Os algoritmos determinísticos segue procedimentos definidos, de maneira que a resposta final seja sempre a mesma, partindo da mesma condição inicial dada ao problema. Já os algoritmos estocásticos estão atrelados a processos aleatórios, mas os resultados finais esperados são suficientemente iguais. Os algoritmos estocásticos se dividem em duas grandes classes: os algoritmos heurísticos e os meta-heurísticos. Segundo Rayward-Smith (1973) os métodos heurísticos buscam soluções suficientemente ótimas, mas não necessariamente a solução exata, o custo computacional associado ao processo é relativo. Embora os métodos heurísticos não garantam a solução global, muitas técnicas atuais produzem soluções muito adequadas. Sendo os algoritmos

meta-heuréticos um aperfeiçoamento das técnicas heuréticas, esses apresentam melhor desempenho que os heuréticos simples, além de serem caracterizado por buscas randômicas. Esses algoritmos muitas vezes são associado a abstrações da natureza, como os algoritmos genético e Particle Swarm Optimization (PSO).

Os algoritmos genéticos mais básicos (*Simple Genetic Algorithm*), são conhecidos como algoritmos mono-objetivos por terem um único objetivo de otimização e seguem, de modo geral, a implementação que será apresentada no próximo tópico com mais detalhes. Já os algoritmos mais complexos focados em otimizações multi-objetivo tem algumas especificidades de implementação diferentes. Dentre os algoritmos multi-objetivos mais conhecido esta a família de algoritmos NSGA.

Figura 4 – Algoritmos genéticos: classificação por objetivos



Fonte: elaborado pelo próprio autor.

2.2 ALGORITMO GENÉTICO

Os algoritmos genéticos (AG) são os mais conhecidos e mais usados algoritmos do tipo evolutivos. Esses são métodos de busca global, estocásticos que usam os princípios da genética e da seleção natural. Os algoritmos genéticos, diferentemente dos métodos clássicos de otimização baseados em gradiente, buscam aproveitar as melhores soluções e a exploração do espaço de busca. Por esses motivos, esses algoritmos são ditos de proposito geral por conseguirem fazer esse balaço entre a exploração do espaço de busca e das melhores soluções. No campo de otimização aerodinâmicas os algoritmos genéticos não são os mais utilizados, uma vista que os algoritmos baseados em gradientes são mais preciso e mais rápidos. Contudo, os algoritmos genéticos são bem versáteis do ponto de vista implementação e acoplamento com *scripts* externos.

Esses algoritmos empregam uma terminologia herdada da teoria evolutiva neodarwinista. Dessa maneira, um individuo é representado de por um único cromossomo, este por sua vez é composto por genes que representam as variáveis que compõem o problema, usualmente os cromossomos são implementados computacionalmente usando estruturas da dados como listas ou vetores. Embora

a maneira de implementação não seja única, a estrutura básica de um AG segue o esquema do pseudocódigo abaixo:

Tabela 1 – Pseudocódigo de um algoritmo genético básico: tipo SGA

Algoritmo Genético básico	
0:	$t = 0$
1:	Inicializando população $P(t)$
2:	Enquanto (condição de parada não satisfeita) faça:
3:	Enquanto (Pop. não completa) faça:
4:	Crossover
5:	Mutação
6:	Avaliação (função de avaliação / Fitness)
7:	$t = t + 1$
8:	Fim do enquanto
9:	Seleciona os indivíduos para $P(t+1)$ a partir de $P(t)$
10:	Fim do enquanto

Fonte: elaborado pelo autor.

O algoritmo se inicia com inicialização da população, $P(t) = \{x_1^t, x_2^t, \dots, x_n^t\}$, de maneira que cada indivíduo assume alguma estrutura de dados que é composta pelas variáveis do problema. Nesse processo iterativo de otimização, existem operações unitárias (mutação) que criam novos indivíduos através de pequenas modificações nos genes, nas variáveis, existem também operações globais (crossover) que criam novos através da combinação de dois ou mais. Ainda, cada indivíduo passa pela função de avaliação que produz uma medida adaptativa (*fitness*), essa é a métrica que vai compor o processo de seleção dos indivíduos mais bem adaptados, formando assim uma nova população na interação $t + 1$. Há alguns métodos de seleção que além dos mais adaptados também seleciona outros indivíduos menos adaptados para compor a próxima população, evitando assim problemas de elitismo e vícios na população. O critério de parada geralmente, que define a quantidade de iterações no processo de otimização, esta associado ao número de gerações, ou a uma condição que representem uma solução aceitável.

2.2.1 Operadores genéticos

Nessa seção, serão apresentados os principais aspectos dos operadores genéticos que compõem a base dos SGA, destacando as implementações mais comuns.

2.2.1.1 Inicialização


O procedimento de inicialização é aquele responsável por gerar a primeira configuração da população, o método mais usado para isso é a inicialização aleatória. Muitas vezes usando intervalos de validação, ou iniciando a população com uma determinada configuração. É nesse momento também onde se define a codificação do indivíduo. Ou seja, a maneira que o algoritmo vai enxergar os genes que compõem o cromossomo e isso está muito relacionado com as manipulações dos operadores. As codificações mais clássicas são a binária e a por ponto flutuante. A codificação binária converte as variáveis que compõem cada indivíduo para números binários, representando essa variáveis em uma

sequencia de *bits* 0 ou 1. A escolha errada da codificação para representar um problema pode acarretar em problemas como ineficiência, convergência prematura e a geração de inválidos.


2.2.1.2 Evaluation

Evaluation ou função de *fitness* é a responsável por avaliar o nível de adaptação do indivíduo, ou seja, criar uma métrica de avaliação com base nos parâmetros do vetor de design, tomando como base o objetivo a se atingir, maximizando ou minimizando certos parâmetros. Dentro da classe de *evaluations*, existe uma distinção entre os algoritmos de otimização mono-objetivos, responsáveis por avaliar essas medida adaptativas com base em um único objetivo. Os algoritmos que levam mais de um objetivo para criar essas medidas adaptativas, que na maioria das vezes tomam, como base objetivos antagônicos, precisando assim encontrar um equilíbrio entre esses objetivos.

Figura 5 – Exemplo de uso de algoritmo multi-objetivo para otimizar uma treliça tendo como objetivos diminuir a tensão máxima e o volume.



(a) Fronteira de Pareto dos objetivos.




(b) Solução ótima encontrada.

Fonte: elaborado pelo próprio autor.

2.2.1.3 Crossover

O operador de *Crossover* é responsável por criar novos indivíduos a partir da combinação de outros. A ideia por trás desse operador é o compartilhamento genético de informações dos candidatos. Nos algoritmos clássicos, esse operador está atrelado a uma probabilidade fixa de ocorrência dentro da totalidade da população. Os operadores de *Crossover* mais empregados são os de um e dois pontos de troca, podendo ser usados na codificação de ponto flutuante e binário. Esses operadores funcionam comutando segmentos dos genes que configuram o indivíduo em pontos iguais. A Figura 16 exemplifica esse processo.

Figura 6 – Operador crossover



Fonte: elaborado pelo próprio autor.

Um outro operador de *crossover* comumente usado para os cromossomos com codificação de ponto flutuante é conhecido como *crossover* aritmético. Esse operador é definido como a combinação linear dos cromossomos pais x_1 e x_2 , de maneira que os filhos são definidos como:

$$x'_1 = \alpha x_1 + (1 - \alpha)x_2 \quad x'_2 = \alpha x_2 + (1 - \alpha)x_1, \quad \alpha \in [0, 1] \quad (1)$$

2.2.1.4 Mutação

O operador de mutação é responsável por inserir uma pequena aleatoriedade na população, modificando-o de maneira randômica, a partir de uma probabilidade de ocorrência em um ou mais genes do cromossomo. Para a codificação do tipo binária, o operador de mutação mais comumente usado é conhecido como *bit flip*, funcionando alterando o gene para 0 quando esse é 1, e vice-versa.

$$11001001 \Rightarrow 10001001 \quad (2)$$

Outro operador desenvolvido especialmente para codificação de ponto flutuante é o operador de mutação uniforme. Esse seleciona aleatoriamente um gene, x_k , no cromossomo $x = \{x_1, x_2, \dots, x_k, \dots, x_n\}$ e altera esse, substitui-lo pelo x'_k , de maneira que esse é escolhido no intervalo com distribuição uniforme $[x_{lower}, x_{upper}]$, que são os limites inferior e superior, respectivamente, definidos para esse gene.


2.2.1.5 Seleção

Há uma infinidade de mecanismos de seleção usados para compor as próximas gerações no ciclo dos AG. Dentre esses, destaca-se o método da roleta russa, *roulette wheel*, que atribui a cada indivíduo a probabilidade de sobrevivência com base na sua medida adaptativa, popularmente chamada de *fitness*. Assim, quanto maior é o *fitness*, maior é a probabilidade de sobrevivência. Contudo, isso não garante que o melhor indivíduo não seja perdido. Uma alternativa para esse problema é sempre manter as melhores soluções nas próximas gerações, essa solução é conhecida como elitista. Outro método comumente implementado é o da seleção por torneio, no qual os indivíduos são amostrados da população e tem seus *fitness* confrontados, esse processo é realizado até compor uma nova população.

Além dos modelos já citados, existem outros como:

- **Seleção por diversidade:** os indivíduos mais diversos são selecionados;
- **Seleção bi-classista:** os $x\%$ melhores indivíduos e os $(1 - x)\%$ piores são selecionados.

Figura 7 – Fluxograma de um algoritmo genético



Fonte: elaborado pelo próprio autor.

2.3 MÉTODOS AERODINÂMICOS

No desenvolvimento do código de otimização, para o cálculo das medidas adaptativa de cada design de asa, foram utilizados *solvers* aerodinâmicos, baseados em dois métodos clássicos: o Vórtice Lattice (VLM - Vórtice Lattice Method), usado para avaliação tridimensional da asa, e o método dos painéis, método usado para avaliação dos perfis aerodinâmicos para asa.

De maneira geral, os fluidos são governados por três leis: a conservação de massa, de momento e energia. Esse conjunto de leis é descrito matematicamente pelas equações de Navier-Stokes, que são apresentadas abaixo.

Equação da Continuidade - conservação de massa:

O termo ρ na equação abaixo descreve a densidade de massa (massa por volume) e o u representa o vetor de velocidade do escoamento.

$$\frac{\partial \rho}{\partial t} + \frac{\partial \rho u_j}{\partial x_j} = 0 \quad (3)$$

Equação do momento - conservação de momento linear:

A equação representa a variação do momento linear escrita na forma indicial, o termo μ representa a viscosidade cinemática do fluido.

$$\frac{\partial \rho u_i}{\partial t} + u_j \frac{\partial \rho u_i}{\partial x_j} = -\frac{\partial \rho}{\partial x_i} + \frac{\partial \left[\mu \left(\frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i} \right) \right]}{\partial x_j} + \rho g_i \quad (4)$$

Equação da energia - conservação de energia:


$$\frac{\partial \rho}{\partial t} + \frac{\partial [(e + P)u_j - \tau_{ij}u_i + q_{Hj}]}{\partial x_j} = 0 \quad (5)$$

A Figura 22 apresenta os principais modelos derivados a partir das equações de Navier-Stokes, de maneira que o movimento no eixo vertical leva a um aumento das simplificações no modelo. Isso faz com que o custo computacional seja reduzido, mas leva a uma redução da acurácia da solução. As equações classificadas como L3 são modelos de mais alta fidelidade, pois representam com melhor detalhamento do fenômeno físico do problema. As equações classificadas como L1, fazem parte dos modelos de baixa fidelidade, pois não representam com toda a fidelidade a física do problema, mas são métodos muito ágeis, ideais para fases iniciais de projetos.

2.3.1 Método do Vórtex Lattice (VLM)

O *Vortex Lattice Method*, VLM, é método de escoamento potencial, ou seja, invíscido, quase-estático que ignora o vorticidade usado para simulações tridimensionais. Esse é classificado como um método de baixa fidelidade. Métodos como esse não são muito usados em partes avançadas de projetos, porém são muito usados nas partes iniciais, pois mesmo sendo considerado de baixa fidelidade, ver Figura 15, para condições específicas apresentam uma boa estimativa dos coeficientes aerodinâmicos e


Figura 8 – Visão geral dos modelos de escoamento aerodinâmico



Fonte: adaptado de Peerlings (2018)

apresentam baixo custo computacional quando comparado com os demais métodos, o que os torna ideias o processo de otimização, que necessitam explorar uma grande quantidade de possibilidades.

Figura 9 – Grau de fidelidade dos métodos aerodinâmicos




Fonte: elaborado pelo próprio autor.

Esse método assume sua validade para pequenos ângulos de ataque e guinada. O AVL, uma implementação do VLM feita por Drela (2017), considera ainda uma correção para compressibilidade do escoamento por meio da equação de Prandtl-Glauert, válida para valores Mach acima de 0,6.

No método do vórtex Lattice, a asa é modelada por um conjunto de painéis, cada painel, por sua vez contém um vórtice ferradura posicionado a cerca de 25% da corda na seção do painel.


Figura 10 – Discretização da asa em painéis.



Fonte: extraído de (HOUGHTON, 2003)

Para calcular a força sobre cada painel, é necessário aplicar uma condição de contorno de fluxo de superfície em cada painel, ou seja, há a consideração de que o fluxo normal ao painel é nulo. Essa condição é aplicada no ponto de controle posicionado a cerca de 75% do painel, semelhante ao que é feito na Figura 10. A velocidade normal então é decomposta em uma parcela de fluxo livre e outra de fluxo induzido pelos demais painéis. Dessa forma, a equação é válida para cada painel:

Figura 11 – Condições contorno para o método dos painéis.




Fonte: extraído de (HOUGHTON, 2003)

$$V_n = 0 = V_\infty \sin(\theta) + W_{ind} \quad (6)$$

$$W_{ind} = \sum_{j=0}^n A_{i,j} \Gamma_j = -V_\infty \sin(\theta) \quad (7)$$

O coeficiente $A_{i,j}$ representa o escoamento induzido no painel i pelo vórtice j .

Figura 12 – Lei de Biot-Savart.




Fonte: extraído de (HOUGHTON, 2003)

Se todos os painéis forem considerados planos, então a matriz de influencia pode ser calculada pela Lei de Biot-Savart 8, que descreve como um filamento de vórtice induz uma velocidade em um ponto distante P.

$$W_{ind} = \int_{-\infty}^{\infty} \frac{\Gamma}{4\pi} \frac{dl \times r}{|r|^3} \quad (8)$$

Aplicando a equação 8 a cada um dos vórtice sobre o painel de modo a ver a influência no ponto de controle (P), tem-se:

Figura 13 – Nomenclatura Biot-Savart




Fonte: extraído de (HOUGHTON, 2003)

$$W_{ind} = \int \frac{\Gamma}{4\pi} \frac{dl \times r}{|r|^3} = \frac{\Gamma_n}{4\pi r_P} (\cos(\theta_1) - \cos(\theta_2)) \quad (9)$$

Sendo que r_P é a distancia dos seguimentos ao ponto P, que aqui é chamado de ponto C. Resolvendo então a integral para um dos seguimentos que componente o vórtice, tem-se:

Figura 14 – Vórtices ferradura.



Fonte: extraído de (HOUGHTON, 2003)

$$W_{ind} = W_{AB} + W_{A\infty} + W_{B\infty} \quad (10)$$

De forma geral a equação abaixo é válida para todos os seguimentos, mudando somente o valor de vetor r_0 , r_1 e r_2 para os seguimentos.

$$W_{AB} = \frac{\Gamma_n}{4\pi} \frac{r_1 \times r_2}{|r_1 \times r_2|^2} \left[r_0 \frac{r_1}{r_1} - r_0 \frac{r_2}{r_2} \right] \quad (11)$$

Para AB:

$$r_0 = (x_{2n} - x_{1n})i + (y_{2n} - y_{1n})j + (z_{2n} - z_{1n})k \quad (12)$$

$$r_1 = (x - x_{1n})i + (y - y_{1n})j + (z - z_{1n})k \quad (13)$$

$$r_2 = (x - x_{2n})i + (y - y_{2n})j + (z - z_{2n})k \quad (14)$$

Para A ∞ :

$$r_0 = (x_{1n} - x_{3n})i \quad (15)$$

$$r_1 = (x - x_{3n})i + (y - y_{1n})j + (z - z_{1n})k \quad (16)$$

$$r_2 = (x - x_{1n})i + (y - y_{1n})j + (z - z_{1n})k \quad (17)$$

Para B ∞ :

$$r_0 = (x_{1n} - x_{3n})i \quad (18)$$

$$r_1 = (x - x_{3n})i + (y - y_{2n})j + (z - z_{2n})k \quad (19)$$

$$r_2 = (x - x_{1n})i + (y - y_{2n})j + (z - z_{2n})k \quad (20)$$

Para resolver, basta fazer ainda x_3 tendendo a infinito. Para obter a sustentação no painel, considera-se

ainda o teorema de Kutta-Joukowski, na forma:

$$l_i = \rho_\infty V_\infty \Gamma_i \quad (21)$$

$$L = \sum_{i=0}^n l_i \quad (22)$$

O arrasto induzido pelos painéis é dado por:

$$d_i = \rho_\infty V_\infty \Gamma_i \sin(\alpha_i) \quad (23)$$

$$D = \sum_{i=0}^n d_i \quad (24)$$

Com α_i sendo o ângulo de fluxo induzido e podendo ser aproximado para $\alpha_i \approx \frac{W_{ind}}{V_\infty}$.

2.3.2 Método dos painéis

Assim como o método VLM, o método dos painéis, é um método potencial, ou seja, invíscido e irrotacional.

Seja um aerofólio de seção geral, discretizado por painéis retos com distribuição linear de vórtices entre os dois pontos (j e $j + 1$) que delimitam cada painel. Ao longo do painel, há uma distribuição uniforme de vórtices, com intensidade γ_0 , definido uma condição de fluxo livre, velocidade (V_∞) e ângulo de ataque (α). Dessa forma, a intensidade da distribuição varia em cada painel ($j = 1, 2, \dots, N$), contudo os valores nos pontos finais devem ser consistentes.

Considerando ainda uma condição de contorno de fluxo, ou seja, velocidade normal a superfície nula no centro de cada painel. Dessa maneira, teremos um sistema com N equações e $N + 1$ incógnitas. Para satisfazer esse sistema, é necessário ainda adotar uma condição extra, válida para o bordo de fuga, a condição de Kutta, na qual impõem que no bordo de fuga o fluxo deixa a superfície de maneira suave. Dessa maneira, a velocidade do extradorso e do intradorso são iguais em módulo no bordo de fuga, de maneira que a vorticidade é nula.

$$V_{bf}(Extradorso) = -V_{bf}(intradorso) \quad (25)$$

Então, para um painel qualquer i , o campo de velocidade é valido:

$$V_n = \sum_{j=1}^{N+1} (A_{i,j} \gamma) + B_i V_\infty = 0 \quad (26)$$

O termo $A_{i,j}$ refere-se à influência da vorticidade do painel j no ponto de controle no painel i e o termo B_i refere-se à influência do fluxo livre sobre o painel i . Esses coeficientes são função somente da geometria dos painéis, devido à orientação e número de painéis. Resolvendo a equação 27 de maneira matricial, é possível determinar o vetor γ , que pode ser usado posteriormente para determinar o campo de velocidade pela equação 26.

$$A_{i,j}\gamma_i = -B_i V_\infty \quad (27)$$

Para determinar o coeficiente de sustentação é necessário ainda determinar o coeficiente de pressão para cada painel.

$$C_{p_i} = \left(1 - \left(\frac{V_i}{V_\infty} \right)^2 \right) \quad (28)$$

Assim, para pequenos ângulos, o coeficiente de sustentação pode ser calculado como:

$$C_l = \sum_{i=1}^N C_{p_i} \frac{x_i - x_{i+1}}{c} \quad (29)$$

2.3.3 Acoplamento dos efeitos viscosos

Em situações mais reais, corpos imersos em fluidos apresentam duas regiões: a região de escoamento invíscido, no qual os efeitos viscosos podem ser desprezados diante outros fatores, visto que os gradientes de velocidade são pequenos, e a outra região, próximo ao corpo onde a fenômeno de viscosidade não pode ser ignorado.

As equações que modelam a camada limite bidimensional são dadas por na forma integral:

$$\frac{d\theta}{d\epsilon} + (2 + H - M_e^2) \frac{\theta}{u_e} \frac{du_e}{d\epsilon} = \frac{C_f}{2} \quad (30)$$


$$\frac{d\theta^*}{d\epsilon} + (\delta^{**} + 3 - M_e^2) \frac{\theta^*}{u_e} \frac{du_e}{d\epsilon} = 2C_d \quad (31)$$

A equação 30 modela a espessura de quantidade de movimento, enquanto a equação 31 a espessura de energia. Onde o termo θ corresponde à espessura de quantidade de movimento, o termo H ($\frac{\delta^*}{\theta}$) é chamado de fator de forma, podendo ser obtido de forma experimental, u_e , a velocidade do escoamento livre e M_e , o número de Mach o escoamento livre. Dados os valores de u_e e M_e para o escoamento externo é possível integrar e obter a distribuição de espessura da camada limite. Contudo, o conhecimento das variáveis do escoamento livre pressupõe antes uma análise do escoamento invíscido. Uma vez que a camada limite interage com o escoamento externo, atendendo a condição de não escorregamento, deslocando a distribuição de velocidade do escoamento invíscido uma distancia de δ^* . Dessa forma, é preciso recalcular a velocidade do escoamento invíscido considerando essa nova geometria fictícia criada por esse deslocamento. Dessa forma fica claro que existe um acoplamento iterativo entre a parte viscosa e invíscida no problema. Existem algumas formas diferentes de realizar esse acoplamento, mas o Xfoil resolve esse acoplamento de maneira simultânea pelo método de Newton, esse é um processo robusto e que apresenta ótimos resultados de convergência. Para um melhor detalhamento das equações utilizadas e do processo de implementação ver (DRELA, 1987) o próprio artigo desenvolvido por Mark Drela.

3 METODOLOGIA

Visto de uma ótica geral, a implementação da ferramenta aqui proposta é a integração entre *solvers* aerodinâmicos, com um algoritmo de otimização e *scripts* de parametrização para a asa.


Figura 15 – Integração.



Fonte: elaborado pelo próprio autor.

A implementação da ferramenta iniciou-se com a definição do escopo e os objetivos que se buscava atingir. Decidiu-se explorar a otimização de uma asa, parametrizando-a por meio de suas principais características, dentre essas corda, envergadura, enflechamento (*offset*) e torção geométrica, inicialmente mantendo um perfil aerodinâmico fixo em toda sua extensão previamente escolhido.

Figura 16 – Parâmetros da para construção da geometria da asa.



Fonte: elaborado pelo próprio autor.

Como algoritmos de otimização, decidiu-se usar um algoritmos do tipo SGA (*Simple Genetic Algorithm*), do tipo mono-objetivos, ou seja, responsável por buscar valores ótimos através de uma única função objetivo. A escolha desse tipo de algoritmo foi baseado no fato de serem algoritmos multiuso que possibilita de maneira fácil a integração com módulos externos e por serem de fácil desenvolvimento.

3.1 PARAMETRIZAÇÃO


A etapa inicial de qualquer problema de otimização passa pela escolha das variáveis que vão representar o problema de maneira quantitativa. Para isso, são utilizado métodos de parametrização para quantificar uma geometria pelas variáveis de forma.

Há uma infinidade de métodos de parametrização relacionados, principalmente a aerofólios e a uma grande quantidade de artigos publicados a cerca desse conteúdo. As diferenças entre a maioria desse métodos de parametrização estão relacionadas ao polinômio responsável por representar a geometria de interesse Antunes (2014). Além disso, esses métodos são diferenciados pela quantidade de termos necessários para representar a geometria e a ordem dos polinômios.

3.1.1 Geometria

Um aerofólio ou perfil aerodinâmico é a uma estrutura bidimensional de uma superfície projetada para obter uma reação aerodinâmica a partir do escoamento do fluido ao seu redor (RODRIGUES, 2014).

Figura 17 – Nomenclatura do aerofólio



Fonte: extraído de Anderson (2017)

A distância que entre o borda de ataque (BA/LE), ponto mais a frente do perfil, e o borda de fuga (BF/TE), ponto mais ao fim do perfil é denominada corda (c). Essa reta também define o início e o final da linha de curvatura media do perfil, a distancia máxima da linha de curvatura e da linha da corda é denominada arqueamento ou camber.

3.1.2 Perfil

A forma mais simples de representar um aerofólio é por meio da suas coordenadas de maneira discreta, porém está é a menos eficiente do ponto de vista computacional, pois requer uma grande quantidade de parâmetros para descrever o aerofólio com precisão, principalmente próximo as extremidades. Dois dos métodos mais clássicos de parametrização para aerofólios são: a curvas de Bézier

e Parsec a referencia do Antunes (2014) descreve detalhadamente a formulação de cada um desses métodos e traz algumas comparações desses. Parsec (Sobieczky (1998)) é um método que representa o perfil através de dois polinômios de quarta ordem, um representando a distribuição de espessura e outro a distribuição de camber, necessitando no total de 11 parâmetros para descrever o perfil. O método Bézie parametriza curvas através de pontos de controle e um conjunto de curvas que se mesclam e formam a geometria de interesse. O número de pontos de controle está muito associado à ordem das curvas de Bézie que podem variar. As curvas de Bézie são muito sensíveis a variação dos pontos de controle.

A fim de inserir a parametrização do perfil na análise da asa de maneira mais simples, decidiu-se restringir a parametrização a aerofólio NACA 4-Dígitos que podem ser expressos da seguinte forma, conforme (HOUGHTON, 2003):

Figura 18 – Aerofólios NACA-dígitos

NACA MPXX

M: Camber (% da corda)
P: Posição do Camber (% da corda)
XX: Espessura máxima (% da corda)

1. Valores de x variam de 0 até máxima valor da corda c .
2. A linha de camber pode ser obtida em termo de x , M que representa o camber em percentual de corda e P a posição do camber.

$$y_c = \frac{M(2Px - x^2)}{P^2} \quad 0 \leq x \leq P \quad (1)$$

$$y_c = \frac{M[(1 - 2P) + (2Px - x^2)]}{(1 - P)^2} \quad P \leq x \leq c \quad (2)$$

3. Para obter a distribuição de espessura, deve se considerar:

$$\pm y_t = \frac{t(0.2969\sqrt{x} - 0.1260x - 0.3516x^2 + 0.2843x^3 - 0.1015x^4)}{0.2} \quad (3)$$

4. Por fim, para obter as coordenadas do extradorso (X_u , Y_u) e intradorso (X_l , Y_l), usa-se:

$$X_u = x - y_t \sin(\theta) \quad (4)$$

$$Y_u = y_c + y_t \cos(\theta) \quad (5)$$

$$X_l = x + y_t \sin(\theta) \quad (6)$$

$$Y_l = y_c - y_t \cos(\theta) \quad (7)$$


$$\theta = \arctan\left(\frac{dy_c}{dx}\right) \quad (8)$$

Ainda para simplificar o número de variáveis, foram fixadas os valores de $M = 4\%$ e $P = 40\%$, ficando somente dependente da espessura máxima do perfil.

3.1.3 Asa

A parametrização inicial da asa tomou como base as seguintes características de maneira que a semi-asa foi dividida por três seções: uma na raiz, uma na parte central e uma na ponta. A primeira seção, na raiz, é caracterizada somente pela corda ($c1$), a seção centra, pela corda ($c2$), torção do perfil ($tw1$) e *offset* ($of1$) e seção da ponta, da mesma maneira é caracterizada por ($c3$), ($tw2$) e ($of2$). A distância entre as seções são dadas pelos parâmetros $b1$ e $b2$, de modo que a soma é a semi-envergadura da asa.

Figura 19 – Esquema de parametrização para asa.



Fonte: elaborado pelo próprio autor.


A princípio, decidiu-se usar o mesmo aerofólio em toda extensão da asa, a fim de investigar o efeito dos demais parâmetros e minimizar o custo computacional de simular um outro perfil na análise 2D por meio do Xfoil.

3.2 ARQUITETURA DE DESENVOLVIMENTO

Para facilitar a modularidade da implementação, a manutenção e a expansão do código, foi usado a técnica de implementação orientada a objeto (POO), utilizando a linguagem de programação Python, devido à sua sintaxe simples, documentação extensa e uma grande quantidade de bibliotecas existentes.

A esquemática da implementação pode ser vista na Figura 20, inicia-se com vetor de *design* que caracteriza a geometria através de um processo de parametrização, no qual consiste em uma abstração matemática da geometria. Atrélada à parametrização, existe o modulo de avaliação, responsável por gerar uma medida adaptativa da geometria, *fitness*. Para isso, o módulo encapsula *scripts* de automatização e tratamento de dados de *softwares* externos como o AVL e Xfoil, responsável por calcular os coeficientes aerodinâmicos da geometria, entre outros.


Figura 20 – Arquitetura de implementação



Fonte: elaborado pelo próprio autor.

As vareáveis de *design* descritas nos topicos de perfis e de asa caracterizam a estrutura da asa de maneira global. Inicialmente a variável de espessura do perfil é necessária para obter as coordenadas do aerofólio, por meio do *scrip* de parametrização dos perfis, ao gerar a polar $C_d(C_l)$ através da simulação 2D no Xfoil. É por meio da polar $C_d(C_l)$ que os efeitos viscosos são inseridos na simulação da asa. O métodos dos painéis do Xfoil Drela (2001) por natureza também é invíscido, porém, a implementação do Xfoil apresenta uma serie de equações de correção para camada limite incluindo assim o efeitos viscosos, como mencionado no tópico 2.3.3.

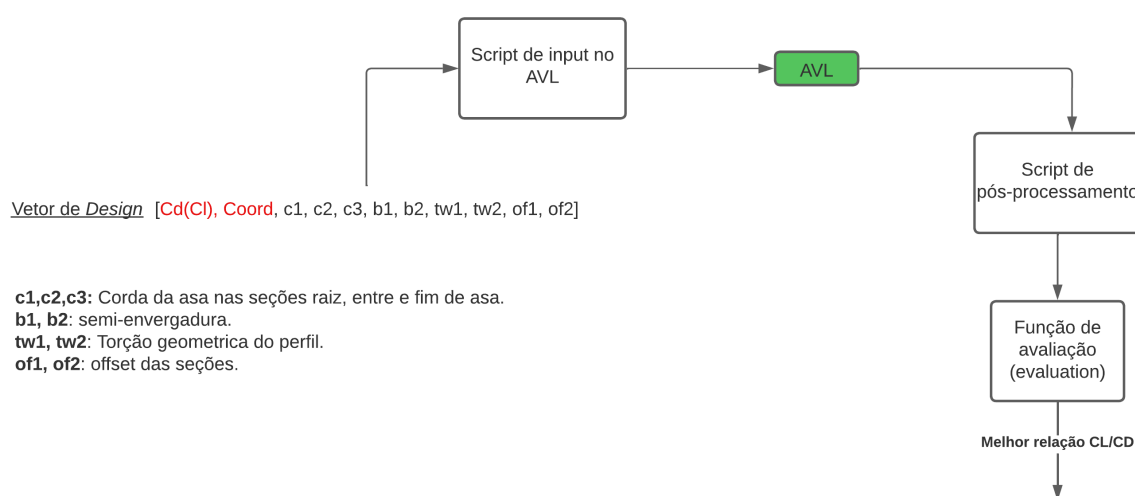
Figura 21 – Etapa e simulação 2D



Fonte: elaborado pelo próprio autor.

Esses dados são extraídos do arquivo de *output* do Xfoil, juntamente com os parâmetros da asa são inseridos na carta do AVL. A medida adaptativa escolhida para quantificar a performance das asa foi a relação $\frac{C_L}{C_D}$ da asa para uma condição específica de velocidade, altitude e fator de carga, parâmetros que são possíveis de se inserir no modulo que faz interface com o AVL. Após a avaliação do design pelos *softwares* aerodinâmicos, o algoritmo de otimização entra com a seleção dos indivíduos que vão compor o próximo processo iterativo. Para evitar que as alterações do próprio AG gere indivíduos, asa, com parâmetros errados que invalidem o design, existe um conjunto de funções que testam se os parâmetros da asa gerados estão dentro dos limites definidos como aceitáveis.

Figura 22 – Etapa de simulação 3D



Fonte: elaborado pelo próprio autor.

Como processo de otimização, para facilitar a integração como os módulos e os tratamentos de exceções decidiu-se usar a biblioteca pre-implementada, a DEAP (FORTIN et al., 2012). Essa, além de contar com uma grande gama de algoritmos genéticos e operadores, é bem documentada e de código aberto, o que facilita sua modificação, tornando implementação mais clara. Dessa forma, foi possível construir o algoritmo genético com os operadores pre-implementados. Com isso, o operador de *crossover* escolhido, foi o método de troca de dois pontos, por proporcionar uma variabilidade genética melhor, como operador de mutação foi escolhido um operador do tipo *bit flip* e como operador de seleção por torneio, que leva para próximo geração os melhores indivíduos selecionado a partir de um torneio que leva a *fitness* de cada individuo como base.

Tabela 2 – Operadores genéticos utilizados.

Operadores Genéticos	
Inicialização	Randomica ¹
Crossover	Crossover de dois pontos
Mutação	<i>Bit flip</i>
Seleção	Torneio

Fonte: elaborado pelo próprio autor.

¹ Dentro do espaço de busca.

4 RESULTADOS E DISCUSSÕES

Com a implementação realizada, iniciou-se a fase de teste e de validação do código. Uma importante etapa no processo de otimização é a verificação do impacto das variáveis no resultado final, tanto as variáveis do algoritmo genético, como probabilidade de mutação, *crossover*, número de indivíduos e de geração, quanto as variáveis de parametrização do problema.

Para validação e calibração da ferramenta, foram tomados com base parâmetros médios de aeronaves semelhantes ao Cessna 182T Skylane, uma aeronave de pequeno porte, com quatro assentos, e dados de voo para condição de voo de cruzeiro. Esses são apresentados na tabela abaixo.


Tabela 3 – Parâmetros fixos na otimização

Parâmetros fixos	Valores
Velocidade [Kts] (m/s)	165 (85)
Ângulo de ataque (AoA) [°]	3
Densidade do ar [kg/m ³]	1,225
Viscosidade do ar [Pa.s]	$1,5 \cdot 10^{-5}$

Fonte: elaborado pelo próprio autor.

4.1 AJUSTE DOS PARÂMETROS DO AG

Figura 23 – Variação do parâmetro número de indivíduos por população



Fonte: elaborado pelo próprio autor.

Nessa etapa, verificou-se o quanto as variáveis do algoritmo genético interferiam na convergência do problema, pois assim, escolheu-se o melhor *setup*, levando em conta o tempo computacional e o resultado final para cada simulação, com a tentativa de ponderar o menor tempo computacional e

manter a precisão no resultado. O exemplo abaixo destaca o tempo de convergência em relação ao número de indivíduos (A0) por cada geração, tomando como base o valor do melhor indivíduo de cada geração plotado no eixo y em relação ao número de gerações

A partir de 80 indivíduos, o *fitness* máxima da população varia muito pouco (Relação C_L/C_D), o que não se justifica o custo computacional, uma vez que essa variação esta relacionada a variação dos parâmetros na casa decimal que de um ponto de vista construtível não chega ser operacional. Contudo, é possível notar que o aumento do número de indivíduos faz com que o ponto de convergência seja antecipado, sendo necessário um número menor de geração até atingir um patamar no valor de *fitness*.

O mesmo procedimento foi realizado para os demais parâmetros do AG, como números de geração (A1), taxa de mutação (A2) e probabilidade de *crossover* (A3). Os melhores valores de convergência ponderadas pelo tempo computacional foram escolhidos e são destacados na tabela 4.

Tabela 4 – Calibração dos parâmetros do AG

Parâmetros	Valor
A0	80
A1	30
A2	20%
A3	55%

Fonte: elaborado pelo próprio autor.

O parâmetro de taxa de mutação foi ponderado em relação a dados da literatura (DEB, 2000), em que é recomendado um valor inferior a 30%, pois quanto maior a taxa de mutação maior a variabilidade de *bits* dentro do um mesmo cromossomo, podendo fazer com que as gerações degenerem. Devido as modificações excessivas causadas pela as mudanças, fazendo com que não propagem os melhores atributos para as próximas gerações.

4.2 TESTE DE SENSIBILIDADE DAS VARIÁVEIS

Tabela 5 – Limites de variação de cada variável.


Espaço de busca para AG			
Parâmetros	Símbolo	Limite inferior	Limite superior
Corda raiz	c1	1,2	1,8
Corda intermediaria	c2	1,0	1,6
Corda na ponta	c3	0,8	1,6
Semi-envergadura 1	b1	2,75	4,75
Semi-envergadura 2	b2	0,75	1,75
Offset 1	of1	0,0	0,3
Offset 2	of2	0,0	0,5
Torção intermediaria	tw1	-3,0	3,0
Torção na ponta	tw2	-3,0	3,0
Perfil	-	Naca 2410	Naca 2424

Fonte: elaborado pelo próprio autor.

Ainda, no proposito de verificar o impacto de cada variável e tendencia dentro do algoritmo de otimização, foi definido um intervalo visualizada na Tabela 5, de variação dos parâmetros médios

escolhidos como base. Foram analisada resultados de C_L e C_D para cada variação de parâmetro, mantendo os demais parâmetros fixos, a Figura 24 destaca essas análises. Cada barra do Figura 24 representa o teste de sensibilidade para aquela variável em específico, onde as demais variáveis foram mantidas fixas e essa em específico variou conforme a Tabela 5.

Figura 24 – Teste de sensibilidade



Fonte: elaborado pelo próprio autor.

Como é possível identificar no gráfico, as duas primeiras variáveis, que representam a corda em seções subseqüente da asa, apresentam variações muito semelhantes tendo quase o mesmo impacto no resultado final, o mesmo não acontece com a terceira variável, uma vez, que é muito menos sensível ao arrasto que as duas anteriores, mas mantém o mesmo padrão para a sustentação. Para as variáveis que descrevem a envergadura, é possível ver o mesmo padrão, a primeira variável é mais sensível que a segunda variável, tanto do ponto de vista de sustentação, quanto por arrasto. O resultado mais notório foi visto na primeira variável de torção (tw1), que se mostrou ser muito sensível tanto para sustentação quanto para o arrasto. Não que de fato essa variável será a que dominará as demais no ponto de vista de eficiência aerodinâmica, mas essa é uma variável que pequenas mudanças podem impactar em grandes alterações na sustentação e no arrasto da asa.

4.3 ESTUDO DE CASO PARA VALIDAÇÃO

Para efeito de validação da plataforma, foi escolhido um estudo de caso para comparação, foram levantados inicialmente os parâmetros da asa do Cessna 182T, destacados na tabela 6. Os valores foram usados para cálculo da razão de eficiência aerodinâmica C_L/C_D da asa em condição de cruzeiro, cerca de $85m/s$, usando o AVL.


Tabela 6 – Dados da aeronave Cessna 182T Skylane

Parâmetros	Valores
Corda na raiz (C_r)	1,48 m
Corda na ponta (C_t)	1,48 m
Envergadura (b)	10,97 m
Torção geométrica	-2,5 °
Perfil aerodinâmico	NACA 2410

Fonte: elaborado pelo próprio autor.

Para essa configuração de voo e parâmetros de asa, foram obtidos um coeficiente de sustentação de 0,40079 e um coeficiente de arrasto (induzido + viscoso) de 0,01428, resultando em uma eficiência aerodinâmica de 28,07.

Figura 25 – Asa do Cessna 182 T (Condição de cruzeiro - 85 m/s)



Fonte: elaborado pelo próprio autor.

Tabela 7 – Limites de variação para o estudo de caso.


Parâmetros	Espaço de busca para AG		
	Símbolo	Limite inferior	Limite superior
Corda raiz	c1	1,0	1,6
Corda intermediária	c2	1,0	1,6
Corda na ponta	c3	0,6	1,1
Semi-envergadura 1	b1	2,0	3,5
Semi-envergadura 2	b2	0,5	2,0
Offset 1	of1	0,0	0,3
Offset 2	of2	0,0	0,6
Torção intermediária	tw1	-3,0	3,0
Torção na ponta	tw2	-3,0	3,0
Perfil	-	Naca 2410	Naca 2410

Fonte: elaborado pelo próprio autor.

Como entrada para otimização, foram usados os mesmos parâmetros de voo, como visto na Tabela 3, e como entradas de parametrização da asa, foram escolhidos valores médios em torno dos parâmetros da asa do Cessna 182T que já foram elencados na Tabela 7. Cerca de duas mil configurações foram

testadas para obtenção dos valores ótimos destacados na Tabela 8, conforme evolução evidenciada na Figura 26 e a geometria da asa na Figura 27.


Figura 26 – Evolução do fitness



Fonte: elaborado pelo próprio autor.

Como resultado final, essa geometria de asa obteve um coeficiente de sustentação de cerca de 0,52274 e um coeficiente de arrasto de 0,01569, obtendo um eficiência aerodinâmica de 33,31, cerca de 18,0% maior do que a do Cessna 182T, mantendo o mesmo perfil aerodinâmico (NACA 2410), com área alar de cerca de 10,88 m^2 contra os 16,24 m^2 do Cessna.

Figura 27 – Asa otimizada




Fonte: elaborado pelo próprio autor.

Esse aumento de eficiência aerodinâmica é facilmente justificável pelo aumento do alongamento da asa, ver equação 1.

$$AR = \frac{b^2}{A} \quad (1)$$

O termo b refere-se à envergadura da asa, e termo A à área alar da asa. Enquanto o alongamento do aeronave Cessna 182T é da ordem de 7,41, a geometria otimizada tem alongamento de 10,52. O alongamento se relaciona a esse efeito modificando a inclinação da curva de sustentação, prolongando ou não a região de estol, fazendo com que, para o mesmo ângulo de ataque, a asa note uma sustentação maior, elevando também o arrasto induzido. O efeito descrito é denominado (*Downwash*), exemplificado na Figura 28 e é decorrente dos efeitos dos vórtices de ponta de asa, que fazem com que o ângulo de ataque na asa varie ao longo da envergadura, modificando a inclinação da curva de sustentação.

Figura 28 – Efeito do alongamento na asa



Fonte: extraído de (GUDMUNDSSON, 2014)

Tabela 8 – Parâmetros finais de otimização.

Parâmetros	Simbolo	Valores ótimos
Corda raiz	c_1	1,14
Corda intermediaria	c_2	1,00
Corda na ponta	c_3	0,80
Envergadura 1	b_1	3,41
Envergadura 2	b_2	1,94
Offset 1	of_1	0,00
Offset 2	of_2	0,28
Torção intermediaria	tw_1	-1,05
Torção na ponta	tw_2	-2,22
Perfil	-	Naca 2410

Fonte: elaborado pelo próprio autor.

É importante destacar que a geometria descrita pelos dados da tabela 8 é a melhor geometria. Ou seja, com maior *fitness*, dentro do espaço de busca dos valores fornecido e dos parâmetros escolhido para AG. A integração e a automatização dos testes de configurações de geometrias de asas permitem ao projetistas fazer inúmeros testes durante a fase preliminar do projeto orientado e embasando melhor suas escolhas de maneira ágil.

5 CONCLUSÃO

Nesse trabalho, foi desenvolvida e testada uma ferramenta de otimização, como foco no projeto conceitual de asas. A ferramenta de otimização tem como implementado um algoritmo genético do tipo SGA, mono-objetivo, que busca otimizar a relação sustentação por arrasto de uma asa, usando como *solves* aerodinâmicos uma implementação do método dos painéis rodando no *script* do Xfoil, que avalia os perfis aerodinâmicos e exporta as polares para inserir no cálculo da asa, e o método VLM, rodando no *script* do AVL, usado para avaliar as geometrias das asas.


Esse trabalho passou pelas nuances da implementação do algoritmo de otimização e frisou a teoria rodando, por trás de cada um dos solves que, embora sejam de baixa fidelidade entregam rapidez, e um resultado muito aceitável para fases iniciais de projeto, o que é ideal para fase preliminar do projeto de uma asa.

Por fim, foi apresentado um estudo de caso em que a ferramenta foi utilizada para gerar uma asa com melhor eficiência aerodinâmica que a de Cessna 182T Skylane, usando como espaço de busca para otimização parâmetros médios semelhantes ao da asa do Cessna.

5.1 SUGESTÃO PARA TRABALHOS FUTUROS

O autor acredita que o uso de ferramenta desenvolvida pode ser bem mais amplo do que supracitado e faz algumas sugestões de trabalhos futuros para aperfeiçoamento. Além disso, o código desenvolvido será compartilhado livremente através da plataforma github, possibilitando a interação com demais desenvolvedores.

Figura 29 – Esquema de parametrização da asa usando dois perfis.



Fonte: elaborado pelo próprio autor.

Para uma primeira implementação, o modelo implementado trabalha somente um único perfil aerodinâmico em toda a extensão da asa, contudo, em situações mais realísticas de projeto, seria importante inserir a possibilidade da variação do perfil aerodinâmico na extensão da asa. Com isso, uma possível implementação seria a inclusão da variável de novo perfil na parametrização da asa, como segue na Figura 29. Ainda, para condições de voos mais amplas é importante inserir mecanismos de avaliação de estol dentro da função de avaliação para melhor representar design realmente possíveis.

Essa implementação foi deixada de lado no primeiro momento, pois a inclusão de nova variável de aerofólio e uma simulação 2D a mais impactaria muito no tempo total da simulação da asa, mas uma implementação que substitua a simulação do Xfoil por a inclusão direta das coordenadas do perfil e das polares, armazenadas em um banco de dados, possivelmente deve resolver esse problema de tempo de simulação. Um outro parâmetro muito relevante que seria importante ser considerado é o efeito de estol que foi desconsiderada nessas análises iniciais.

Uma outra sugestão seria a integração de outras disciplinas no projeto de otimização, como a inclusão da disciplina de estruturas para cálculo preliminar de dimensionamento das longarinas e ou nervuras a partir das cargas aerodinâmicas advindas do próprio AVL, ou mesmo a inclusão da disciplina de desempenho com o cálculo de distância de pouso ou decolagem, contudo, a inclusão dessas outras disciplinas está correlacionada a inclusão de outros parâmetros específicos de cada tipo de aeronave e deve estar alinhadas a parâmetros da simulação da asa, como o parâmetro de Reynolds, viscosidade do ar entre outros.

Cabe ressaltar que as melhorias levantadas não invalidam os resultados já obtidos, mas abrem espaços para melhorias, implementações mais acuradas e novas integrações de disciplinas que compõem o projeto de uma asa.

REFERÊNCIAS

- ANDERSON, J. J. D. **Fundamentals of Aerodynamics**. [S.l.: s.n.], 2017.
- ANTUNES, A. P. **Development of An Open Optimization Framework for Aeronautical Applications**. 315 p. Dissertação (Mestrado) — Instituto Tecnológico de Aeronáutica, São Jose dos Campos, 2014.
- DEB, K. **Multi-Objective Optimization Using Evolutionary Algorithms**. [S.l.]: Wiley, New York, NY, USA, 2000.
- DRELA, H. Y. M. **XFOIL 6.9 User Primer**. 2001.
- DRELA, M. **User Guide to AVL**. 2017.
- DRELA, M. B. G. M. Viscous-inviscid analysis of transonic and low reynolds number airfoil. **Aiaa Journal - AIAA J**, v. 25, p. 1347–1355, 1987.
- FORTIN, F.-A. et al. DEAP: Evolutionary algorithms made easy. **Journal of Machine Learning Research**, v. 13, p. 2171–2175, jul 2012.
- GUDMUNDSSON, S. **General aviation aircraft design: applied methods and procedures**. First edition. Oxford; Waltham, MA: Butterworth-Heinemann, 2014. ISBN 9780123973085.
- HOUGHTON, P. W. C. E. L. **Aerodynamics for Engineering Students - 5 th ed**. [S.l.: s.n.], 2003. ISBN 07506511113.
- MARTINS, J. A.; NING, A. **Engineering Design Optimization**. [S.l.]: John Wiley Sons, 2021. ISBN 0471962805.
- PEERLINGS, B. **A review of aerodynamic flow models, solution methods and solvers – and their applicability to aircraft conceptual design**. 2018.
- RAYMER, D. P. **Aircraft design: a conceptual approach**. Reston, VA: American Institute of Aeronautics and Astronautics, Inc, 2018. (AIAA education series). ISBN 9781624104909.
- RAYWARD-SMITH. **Modern Heuristic Search Methods**. Reston, VA: John Wiley Sons, 1973. ISBN 0471962805.
- RODRIGUES, L. E. M. J. **Fundamentos da Engenharia Aeronáutica com Aplicações ao Projeto SAE com Aplicações ao Projeto SAE AeroDesign: Aerodinâmica e Desempenho**. [S.l.: s.n.], 2014.
- SOBIECZKY, H. Parametric airfoils and wings, notes on numerical fluid mechanics. **edited by K. Fujii and G. S. Dulikravich, Vol. 68**, v. 68, p. 71–88, 1998.